

Année 2024

APPORT DE L'INTELLIGENCE ARTIFICIELLE AU DIAGNOSTIC VÉTÉRINAIRE

THÈSE

pour obtenir le diplôme d'État de
DOCTEUR VÉTÉRINAIRE
présentée et soutenue publiquement devant
la Faculté de Médecine de Créteil (UPEC)
le 21 juin 2024

par

Hadrien DIDELOT

sous la direction de

Sylvain BELLIER

JURY

Président du jury :	M. Henry CHATEAU	Professeur à l'EnvA
Directeur de thèse :	M. Sylvain BELLIER	Professeur à l'EnvA
Examinatrice :	Mme Ghita BENCHEKROUN	Maître de Conférences à l'EnvA

Liste des enseignants intervenant dans l'encadrement des thèses de Doctorat vétérinaire



version Janvier 2024

Liste des Professeurs et Maîtres de conférences titulaires de l'HDR

M	Adjou	Karim	Professeur	DPASP
M	Audigié	Fabrice	Professeur	DEPEC
M	Bellier	Sylvain	Professeur	DSBP
Mme	Benckekroun	Ghita	Maître de conférences HDR	DEPEC
M	Blaga	Radu	Professeur	DSBP
M	Blot	Stéphane	Professeur	DEPEC
M	Boulouis	Henri-Jean	Professeur émérite	DSBP
Mme	Chahory	Sabine	Professeur	DEPEC
Mme	Chastant	Sylvie	Professeur	DPASP
M	Chateau	Henry	Professeur	DSBP
Mme	Chatboul	Valerie	Professeur	DEPEC
Mme	Crepeaux	Guillemette	Maître de conférences HDR	DSBP
Mme	Crevier-Denoix	Nathalie	Professeur	DSBP
M	Degueuroe	Christophe	Professeur	DSBP
M	Denoix	Jean-Marie	Professeur	DEPEC
M	Desquilbet	Loïc	Professeur	DSBP
Mme	Dufour	Barbara	Professeur émérite	DPASP
M	Fayolle	Pascal	Professeur émérite	DEPEC
M	Federighi	Michel	Professeur	DPASP
M	Fontbonne	Alain	Professeur	DEPEC
Mme	Gilbert	Caroline	Professeur	DSBP
M	Grandjean	Dominique	Professeur	DEPEC
Mme	Grimard-Ballif	Bénédicte	Professeur	DPASP
Mme	Haddad-Hoang Xuan	Nadia	Professeur	DPASP
M	Jouvion	Gregory	Professeur	DSBP
M	Kohlhauer	Matthias	Professeur	DSBP
Mme	La Poder	Sophie	Professeur	DSBP
Mme	La Roux	Delphine	Maître de conférences HDR	DSBP
M	Manassero	Mathieu	Professeur	DEPEC
Mme	Maurey-Guéneq	Christelle	Professeur	DEPEC
M	Millemann	Yves	Professeur	DPASP
M	Ponter	Andrew	Professeur	DPASP
Mme	Risco-Castillo	Véronica	Maître de conférences HDR	DSBP
Mme	Rivière	Julie	Professeur	DPASP
Mme	Robert	Céline	Professeur	DSBP
M	Tiret	Laurent	Professeur	DSBP
M	Tissier	Renaud	Professeur	DSBP
M	Verwaerde	Patrick	Professeur	DEPEC
Mme	Viateau	Véronique	Professeur	DEPEC

Liste des Maîtres de conférences et Ingénieurs de recherche DMV

M	Arné	Pascal	Maître de conférences	DPASP
Mme	Barassin	Isabelle	Maître de conférences	DPASP
Mme	Barbarino	Alix	Ingénieur de recherche (DMV)	DEPEC
Mme	Bertoni	Lelia	Maître de conférences	DEPEC
Mme	Canonne-Guibert	Morgane	Maître de conférences	DEPEC
Mme	Chevallier	Lucie	Maître de conférences	DSBP
Mme	Cochet-Faivre	Noëlle	Maître de conférences	DEPEC
Mme	Cordonnier-Lefort	Nathalie	Maître de conférences	DSBP
Mme	Coudry	Virginie	Ingénieur de recherche (DMV)	DEPEC
M	Crozet	Guillaume	Maître de conférences	DPASP
Mme	De Paula Reis	Alline	Maître de conférences	DPASP
M	Delsart	Maxime	Maître de conférences	DPASP
Mme	Denis	Marine	Ingénieur de recherche (DMV)	DPASP
M	Deshuillers	Pierre	Maître de conférences	DSBP
M	Gauthier	Michel	Maître de conférences associé	DPASP
Mme	Guérin	Virginie	Maître de conférences	DSBP
Mme	Guélin-Poirier	Valentine	Maître de conférences	DPASP
Mme	Jacquet	Sandrine	Ingénieur de recherche (DMV)	DEPEC
M	Kurtz	Maxime	Ingénieur de recherche (DMV)	DEPEC
Mme	Lagrée	Anne-Claire	Maître de conférences	DSBP
Mme	Le Dudal	Marine	Ingénieur de recherche (DMV)	DSBP
Mme	Legrand	Chantal	Maître de conférences associé	DSBP
M	Mammeri	Mohamed	Maître de conférences	DSBP
Mme	Manguin	Estelle	Maître de conférences	DEPEC
Mme	Marignac	Genevieve	Maître de conférences	DSBP
Mme	Marotto	Stéphanie	Ingénieur de recherche (DMV)	DEPEC
Mme	Maurice	Emeline	Ingénieur de recherche (DMV)	DEPEC
Mme	Mespoules-Rivière	Céline	Ingénieur de recherche (DMV)	DEPEC
Mme	Mtimet	Narjès	Maître de conférences	DPASP
M	Mortier	Jérémy	Maître de conférences associé	DEPEC
M	Nudelmann	Nicolas	Maître de conférences	DEPEC
M	Pignon	Charly	Ingénieur de recherche (DMV)	DEPEC
M	Polack	Bruno	Maître de conférences	DSBP
Mme	Quére	Émilie	Ingénieur de recherche (DMV)	DEPEC
Mme	Ravary-Plumioën	Bérangère	Ingénieur de recherche (DMV)	DPASP
M	Reyes-Gomez	Edouard	Maître de conférences	DSBP
Mme	Rose	Hélène	Maître de conférences associé	DSBP
M	Tanquerel	Ludovic	Maître de conférences	DEPEC

Remerciements

Au Président du Jury de cette thèse, M. Henry CHATEAU, Professeur à l'EnvA,
Pour m'avoir fait l'honneur d'accepter la présidence du jury de ma thèse,
Hommages respectueux.

À M. Sylvain BELLIER, Professeur à l'EnvA,
Pour m'avoir proposé ce sujet et m'avoir guidé pendant la réalisation de cette thèse,
Sincères remerciements.

À Mme Ghita BENCHEKROUN, Maitre de conférences à l'EnvA,
Pour avoir accepté de participer à mon jury de thèse,
Sincères remerciements.

À, M. Matthias KOHLHAUER, Professeur à l'EnvA,
Pour avoir accepté initialement la présidence du jury de ma thèse,
Sincères remerciements.

Table des matières

Liste des figures.....	1
Liste des tableaux	3
Liste des abréviations.....	5
Introduction	7
Partie I – Le <i>Big Data</i> et l’intelligence artificielle à grande échelle : définitions, fonctionnement, limites et intérêts	9
1. Le fonctionnement d’un algorithme d’intelligence artificielle : concepts essentiels.....	9
A. <i>Le Big Data</i>	9
a. Les définitions du <i>Big Data</i>	9
b. Les technologies actuelles du <i>Big Data</i>	11
c. <i>Le Big Data</i> en médecine humaine et en médecine vétérinaire	14
B. <i>L’élaboration d’un algorithme d’intelligence artificielle</i>	18
a. Des données brutes à un algorithme intelligent	18
b. Les différents types d’intelligences artificielles	20
c. L’interface homme-machine	22
C. <i>Le Machine Learning, socle des intelligences artificielles actuelles</i>	22
a. Les différents types d’apprentissage.....	22
b. Les approches de <i>Machine Learning</i> les plus fréquemment rencontrées	23
c. <i>Le Deep Learning</i> , une approche particulière	29
2. Les intérêts et applications fondamentales des algorithmes de <i>Machine Learning</i> contemporains	31
A. <i>La course à l’intelligence artificielle</i>	31
a. Les GAFAM, acteurs majeurs du <i>Big Data</i> et des intelligences artificielles	31
b. Les tendances actuelles du développement des intelligences artificielles	31
B. <i>Les capacités générales du Machine Learning grand public</i>	33
a. L’analyse visuelle : traitement d’images ou vidéos	33
b. L’analyse du langage naturel : interprétation du langage parlé ou écrit	36
c. La génération de données, le point fort des intelligences artificielles modernes	37
3. L’intelligence artificielle, un domaine encore peu réglementé et avec ses propres limites	38
A. <i>La réglementation face à l’essor des intelligences artificielles</i>	38
a. La réglementation actuelle des intelligences artificielles	38
b. Les limites des réglementations et usages actuels	39
c. De nouvelles régulations pour un usage des intelligences artificielles sûr et innovant	39
B. <i>Des limites connues et encore à découvrir</i>	40
a. Les considérations éthiques intrinsèques au développement d’un modèle de <i>Machine Learning</i>	40
b. Les intelligences artificielles : des exploits techniques aux retombées non négligeables	42
c. Quelles solutions pour développer des intelligences artificielles plus sûres et plus éthiques ?.....	46
Partie II – Les applications concrètes pour le praticien d’aujourd’hui, inscrites dans le mouvement <i>One Health</i>	49
1. Quelques domaines d’application de l’intelligence artificielle en médecine humaine	49
A. <i>L’intelligence artificielle pour le diagnostic en médecine humaine</i>	49
B. <i>L’imagerie médicale, un domaine d’application en plein essor</i>	51
2. Les apports de l’intelligence artificielle en médecine vétérinaire : de la prévention au diagnostic	52
A. <i>Le secteur rural, pionnier dans l’implémentation de l’intelligence artificielle</i>	52
a. L’intelligence artificielle prédictive bovine.....	53
b. L’intelligence artificielle pour le diagnostic de maladies bovines	56
c. L’intelligence artificielle dans les élevages porcins	63

d. L'intelligence artificielle dans les élevages aviaires.....	64
e. L'intelligence artificielle pour d'autres animaux de production.....	67
f. Les intelligences artificielles comme modèles de prédiction de foyers infectieux.....	67
B. L'intelligence artificielle : un outil d'aide au diagnostic pour les animaux de compagnie et les chevaux	71
a. L'intelligence artificielle prédictive pour les animaux de compagnie et les chevaux	71
b. L'intelligence artificielle, un outil encore orienté vers l'espèce canine	72
c. L'émergence de l'intelligence artificielle chez le chat	78
d. L'intelligence artificielle équine	78
C. L'usage de l'intelligence artificielle en imagerie médicale.....	79
a. La radiomique, une méthode prometteuse pour l'intelligence artificielle	79
b. Les applications chez les animaux de compagnie.....	80
c. Les applications chez le cheval	87
D. L'usage de l'intelligence artificielle dans les autres examens diagnostics.....	87
a. L'intelligence artificielle pour automatiser les examens complémentaires.....	87
b. Les apports de l'intelligence artificielle en anatomopathologie	89
E. Le rôle de l'intelligence artificielle dans la relation entre le propriétaire et ses animaux grâce au diagnostic de l'état émotionnel	94
a. Le diagnostic de l'état émotionnel et de la douleur des animaux de compagnie	94
b. La détection de la douleur chez le cheval	95
c. Le diagnostic de l'état émotionnel chez les animaux de production	96
d. La détection de la douleur chez les animaux de laboratoire.....	96
3. La place et le rôle de l'intelligence artificielle dans le diagnostic et la pratique généraliste et ses conséquences pour la profession	97
A. Une relation vétérinaire – propriétaire – patient qui doit évoluer avec les apports de l'intelligence artificielle.....	97
a. Une relation particulière	97
b. Les vétérinaires au cœur des changements apportés par l'intelligence artificielle	97
c. Les propriétaires et leurs animaux, un point de vue différent	100
B. La place de l'intelligence artificielle dans la structure vétérinaire : un diagnostic qui commence au chevet du patient	101
a. Le défi technique et économique de l'intégration de l'intelligence artificielle au sein d'une structure	101
b. Le développement d'une médecine intégrée et continue	102
c. L'éthique animale, le dernier défi pour déterminer la place de l'intelligence artificielle	102
C. L'inscription de l'intelligence artificielle dans le mouvement One Health et l'émergence de nouvelles possibilités entre deux médecines	103
Conclusion.....	105
Annexe 1 – Tableau récapitulatif.....	107
Liste des références bibliographiques	115

Liste des figures

Figure 1 : Fonctionnement-type de la collecte, transformation et analyse du <i>Big Data</i> . Licence CC-BY (Raja <i>et al.</i> , 2020).	13
Figure 2 : Les différentes sources de <i>Big Data</i> . Licence CC-BY (McCue et McCoy, 2017).	17
Figure 3 : Chronologie du développement et de l'usage de l'IA en médecine. Utilisée avec l'autorisation de Kaul <i>et al.</i> (2020).	20
Figure 4 : Exemple d'un réseau bayésien simple. Travail personnel.....	21
Figure 5 : Exemple de l'utilisation d'un SVM. Utilisée avec l'autorisation de Yoo <i>et al.</i> (2012).	24
Figure 6 : Arbre décisionnel classant un trouble hépatique selon des critères cliniques. Utilisée avec l'autorisation de Awaysheh <i>et al.</i> (2019).	25
Figure 7 : Réseau de neurones artificiels à une seule couche. Utilisée avec l'autorisation de Awaysheh <i>et al.</i> (2019).	26
Figure 8 : Réseau de neurones artificiels multicouche. Utilisée avec l'autorisation de Awaysheh <i>et al.</i> (2019).	27
Figure 9 : Exemple d'un réseau de neurones récurrents. Utilisée avec l'autorisation de LeCun <i>et al.</i> (2015).	29
Figure 10 : Exemple d'une connexion résiduelle (He <i>et al.</i> , 2016). © 2016 IEEE.	30
Figure 11 : Évolution de la puissance de calcul, en FLOPS, nécessaire à l'entraînement des IA sur la période 1952 - 2022 (Sevilla <i>et al.</i> , 2022). © 2022 IEEE.	32
Figure 12 : Fonctionnement d'un réseau neuronal convolutif. Utilisé avec l'autorisation de LeCun <i>et al.</i> (2015).	34
Figure 13 : Fonctionnement des neurones à champs réceptifs. Licence CC BY-NC (Nielsen, 2015).	35
Figure 14 : Fonctionnement des neurones de mise en commun. Licence CC BY-NC (Nielsen, 2015).	35
Figure 15 : Structure générale d'un transformeur (Vaswani <i>et al.</i> , 2017). © 2017 Google.....	36
Figure 16 : Courbes ROC de plusieurs modèles détectant la présence de calculs rénaux sur des images de tomodensitométrie canine. Licence CC BY (Ji <i>et al.</i> , 2023).	44
Figure 17 : Interprétation d'une image par l'IA proposée par Arikan <i>et al.</i> pour détecter un œstrus chez une vache laitière. Licence CC BY (Arikan <i>et al.</i> , 2023).	57
Figure 18 : Interprétation d'une image infrarouge par l'IA proposée par Wang <i>et al.</i> pour détecter une mammite chez une vache laitière. Licence CC BY-NC-ND (Y. Wang <i>et al.</i> , 2022).	59

Figure 19 : Fonctionnement de l'IA proposée par Gupta <i>et al.</i> pour le diagnostic d'une KCI. Licence CC BY (Gupta <i>et al.</i> , 2023).....	62
Figure 20 : Fonctionnement de l'IA proposée par Kittichai <i>et al.</i> pour le diagnostic du paludisme aviaire. Licence CC BY (Kittichai <i>et al.</i> , 2021).....	65
Figure 21 : Prédiction de la survenue d'un foyer de norovirus dans la baie de la Louisiane entre 2011 et 2014 selon l'IA proposée par Chenar et Deng. Utilisée avec l'autorisation de Chenar et Deng (2018).	70
Figure 22 : Interprétations de trois images par les modèles proposés par Smith <i>et al.</i> pour diagnostiquer une patte saine, une pododermatite ou une masse tumorale chez le chien. Licence CC BY-NC (Smith <i>et al.</i> , 2023).....	73
Figure 23 : Images de cornées utilisées pour l'entraînement de l'IA proposée par Kim <i>et al.</i> pour le diagnostic d'une KCS chez le chien. Licence CC BY (J. Y. Kim <i>et al.</i> , 2022).....	76
Figure 24 : Images utilisées pour l'entraînement de l'IA proposée par Jung <i>et al.</i> pour le diagnostic d'une luxation médiale de la rotule chez le chien. Licence CC BY (Jung <i>et al.</i> , 2023).....	77
Figure 25 : Les différentes méthodes d'analyse radiomique. Utilisée avec l'autorisation de Currie et Rohren (2022a).	80
Figure 26 : Annotations permettant le calcul du VHS sur des radiographies thoraciques de deux chiens. Utilisée avec l'autorisation de Zhang <i>et al.</i> (2021).	82
Figure 27 : Arbre de décision proposé par Burti <i>et al.</i> pour le diagnostic de lésions hépatiques focales chez le chien grâce à un examen tomodensitométrique. Licence CC BY (Burti <i>et al.</i> , 2021).	85
Figure 28 : Interprétation d'une coupe histologique par l'IA proposée par Aubreville <i>et al.</i> pour détecter automatiquement la zone la plus active d'une tumeur. Licence CC BY (Aubreville <i>et al.</i> , 2020).....	90
Figure 29 : Interprétation d'une coupe histologique d'un histiocytome par l'IA proposée par Fragoso-Garcia <i>et al.</i> pour diagnostiquer automatiquement des tumeurs canines. Licence CC BY (Fragoso-Garcia <i>et al.</i> , 2023).....	92
Figure 30 : Interprétation d'une image par l'IA proposée par Bonicelli <i>et al.</i> pour le diagnostic d'une pneumonie porcine. Licence CC BY (Bonicelli <i>et al.</i> , 2021).	93
Figure 31 : Repères faciaux félines utilisés pour déterminer l'état douloureux. Licence CC BY (Steagall <i>et al.</i> , 2023).	95
Figure 32 : Un modèle de gestion personnalisée et continue de la santé augmentée par l'IA. Utilisée avec l'autorisation de Goecks <i>et al.</i> (2020).	102

Liste des tableaux

Tableau 1 : Tableau résumant les principales maladies des animaux de compagnie servant de modèles pour des maladies humaines D'après Kol *et al.* (2015)103

Liste des abréviations

AI ou **IA** : *Artificial Intelligence*, ou « intelligence artificielle » ;

AUC : *Area Under the Curve* ou « aire sous la courbe (ROC) » ;

CNN : *Convolutional neural network*, ou « réseau neuronal convolutif » ;

DAP : *Dog Aging Project* ;

DL : *Deep Learning*, ou « apprentissage profond » ;

DT : *Decision Tree*, ou « arbre décisionnel » ou « arbre de décision » ;

ECG : Électrocardiogramme ;

ETL : *Processus Extract – Transform – Load*, ou « extraction – transformation, chargement » ;

FDA : *Food and Drug Administration* ;

GAFAM : Acronyme regroupant les entreprises *Google, Apple, Facebook, Amazon* et *Microsoft* ;

GRLS : *Golden Retriever Lifetime Study* ;

IA ou **AI** : Intelligence artificielle, ou *Artificial Intelligence* ;

IRM : Imagerie par résonance magnétique ;

KCS : Kérato-conjonctivite sèche ;

LLM : *Large Language Model*, ou « grand modèle de langage » ;

ML : *Machine Learning*, ou « apprentissage automatique » ;

MRC : Maladie rénale chronique ;

NCR : Neurone à Champ Réceptif ;

NEC : Note d'État Corporel ;

NLP : *Natural Language Processing*, ou « traitement du langage naturel » ;

(A)NN : (*Artificial*) *Neural Network*, ou « réseau de neurones (artificiels) » ;

OCT : *Optical Coherence Tomography*, ou « tomographie en cohérence optique » ;

RAG : *Retrieval-Augmented Generation*, ou « génération augmentée de récupération » ;

RF : *Random Forest*, ou « forêt d'arbres décisionnels » ;

RGPD ou **GDPR** : Règlement Général sur la Protection des Données ou *General Data Protection Regulation* ;

RNN : *Recurrent Neural Network*, ou « réseau de neurones récurrents » ;

ROC : *Receiver Operating Characteristic* ou « caractéristique de fonctionnement du récepteur », plus utilisé sous la forme « courbe ROC » pour « fonction d'efficacité du récepteur » ;

SHAP : *SHapley Additive exPlanations* ;

SNC : Système Nerveux Central ;

SORB : Syndrome obstructif respiratoire des races brachycéphales ;

SVM : *Support Vector Machine*, ou « séparateur à vaste marge » ;

UE : Union Européenne ;

VCPR : *Veterinarian – Client – Patient Relationship*, ou « relation vétérinaire – propriétaire – patient » ;

VHS : *Vertebral Heart Score* ;

XAI : *eXplainable Artificial Intelligence*, ou « intelligence artificielle explicable ».

Introduction

L'intelligence artificielle est une solution à un problème contemporain : la croissance exponentielle des données disponibles et la complexité de leur interprétation. Un domaine de l'intelligence artificielle en particulier, le *Machine Learning*, permet de développer des algorithmes capables d'apprendre de manière autonome à partir de grands jeux de données. Ces ensembles de taille importante forment ce qu'on appelle le *Big Data* et permettent aux intelligences artificielles d'identifier de nouvelles relations et d'en tirer des conclusions. Si la biochimie, l'anatomie pathologique et la génomique sont historiquement les principaux domaines d'intérêt (Larrañaga *et al.*, 2005), des applications inédites sont envisageables avec l'arrivée sur le marché de nouveaux types d'intelligences artificielles, plus polyvalents et plus accessibles. La sensibilisation des vétérinaires à ces technologies, qu'ils soient déjà diplômés ou encore étudiants, est donc primordiale, comme l'évoquait déjà Roxane Perrin dans sa thèse, en 2019.

Ces dernières années, en particulier depuis 2020, ont vu le développement et le déploiement rapide de nouveaux algorithmes de *Machine Learning*, dont la facilité d'utilisation les a fait connaître auprès du grand public. De nombreux modèles existent et les tendances actuelles sont à l'augmentation de la part d'intelligence artificielle dans la vie quotidienne. Les entreprises à la pointe des secteurs technologiques ont tous incorporé de tels programmes dans leurs produits, notamment dans le secteur médical (Alt et Zimmermann, 2021). Toutefois, cette présence grandissante soulève des questions pour lesquelles les réponses ne sont pas toutes connues. En particulier, l'évolution des dispositifs d'intelligence artificielle doit être envisagée sous ses aspects technique, éthique et réglementaire, à la fois par les législateurs et par la profession vétérinaire. Une bonne compréhension des intelligences artificielles est donc essentielle afin de s'assurer de leur bon usage. Les données utilisées par ces algorithmes, leur fonctionnement et leurs limites seront présentés dans la première partie de cette thèse.

L'intelligence artificielle permet des apports concrets dès aujourd'hui. Grâce à la quantité importante de données analysées, le *Machine Learning* peut, dans le domaine médical, identifier des facteurs permettant de prédire, diagnostiquer voire traiter certaines affections. En s'appuyant sur de très nombreux cas, le *Machine Learning* est capable d'établir des relations parfois inconnues jusque-là. L'évolution des connaissances et des techniques montre l'intérêt grandissant de la profession à l'égard de l'intelligence artificielle et ouvre également la voie à de nouvelles possibilités entre médecines humaine et vétérinaire. Dans l'optique du mouvement *One Health*, la mise en commun des données humaines et vétérinaires et la création de nouveaux modèles partagés laissent présager de nouvelles découvertes (McCue et McCoy, 2017). Ces aspects seront traités dans la seconde partie.

Partie I – Le *Big Data* et l'intelligence artificielle à grande échelle : définitions, fonctionnement, limites et intérêts

Appleby et Basran (2022) expliquent l'importance d'une compréhension globale de l'intelligence artificielle (IA) en médecine vétérinaire en utilisant l'analogie suivante : même s'il n'est pas strictement nécessaire pour un praticien de savoir créer et développer une technique ELISA, il doit néanmoins posséder les connaissances nécessaires à sa compréhension. Cela lui permet d'avoir confiance dans les tests qu'il réalise en routine et de pouvoir les présenter à ses clients.

La bonne compréhension du fonctionnement d'une IA, en particulier d'un logiciel issu du *Machine Learning*, est donc cruciale pour le vétérinaire qui est amené à l'utiliser. Ainsi, il pourra l'utiliser efficacement dans sa démarche thérapeutique tout en gardant un recul critique sur les résultats fournis par l'algorithme.

1. Le fonctionnement d'un algorithme d'intelligence artificielle : concepts essentiels

A. Le *Big Data*

Quelle que soit la forme de l'IA employée, ces algorithmes ont pour particularité d'utiliser de très grands jeux de données, formant un ensemble appelé le *Big Data* (Fang *et al.*, 2016). Ainsi, pour comprendre le fonctionnement d'une IA, il est essentiel de comprendre ce que sont ces données, leur origine et la façon dont elles sont exploitées.

a. Les définitions du *Big Data*

- *L'évolution des définitions*

Le *Big Data* est un concept acceptant plusieurs définitions en raison de la variété des données traitées et des différents types d'algorithmes de traitement (Ward et Barker, 2013). Le terme *Big Data* regroupe généralement l'ensemble des technologies et pratiques en lien avec l'analyse d'un grand volume de données (Lugmayr *et al.*, 2016).

Cette notion remonte historiquement aux années 1958, sous le terme « *Business Intelligence* ». L'entreprise américaine IBM en est à l'origine, lors du développement d'un système automatisé visant à enregistrer, encoder, stocker puis partager des informations internes (Luhn, 1958). Le système décrit permettait d'analyser puis de trier automatiquement des quantités massives de documents pour l'époque. Ceux-ci étaient ensuite stockés de manière à être facilement accessibles. Le but de ce système était très proche de celui des algorithmes actuels : permettre de mieux comprendre les relations au sein d'une grande quantité de données et d'exploiter ces relations pour atteindre un objectif précis.

La popularisation du terme *Big Data*, dans le sens actuel d'ensemble de grande taille de données variées, est généralement attribuée au scientifique américain John R. Mashey, à la fin des années 1990 (Diebold, 2012 ; Mashey, 1998). Aujourd'hui, la définition la plus explicite du *Big Data* correspond à un ensemble de données trop important pour être géré simplement par des logiciels ou du matériel non spécialisés (Oracle Cloud, 2022). Ces outils sont présentés dans la partie **I.1.a.b.**. Trois caractéristiques sont initialement identifiées pour justifier l'utilisation d'outils spécifiques : il s'agit des « trois V », pour *Variety*, *Volume* et *Velocity*. Ces données sont de natures variées, elles sont en quantité massive et elles sont reçues ou traitées de manière rapide (Laney, 2001).

- *Les 3V du Big Data*

En 2001, Doug Laney, alors analyste pour l'entreprise Gartner (anciennement nommée Meta), publie un article introduisant les trois caractéristiques fondamentales du *Big Data* (Laney, 2001). Sa description souligne que le *Big Data* n'est pas qu'une simple augmentation de la quantité de données, mais bien une catégorie de données à part entière.

Le premier V évoqué concerne la nature variée des données. Ce point souligne que les données du *Big Data* peuvent être très diverses, surtout en médecine. Il peut ainsi s'agir de résultats structurés, qui sont formatés de manière précise (des résultats d'analyse par exemple), ou au contraire de données non structurées (des textes écrits en langage naturel, des photos ou des vidéos par exemple). Bien que plus complexes à analyser, ces données non structurées représentent désormais 90 % des données stockées (Patgiri et Ahmed, 2016).

Le deuxième V concerne le volume de données. De nombreuses sources peuvent désormais créer des données et le volume total atteint souvent les pétaoctets (soit plusieurs milliers de téraoctets). L'entreprise *Intel* explique ainsi que le *Big Data* concerne des entreprises qui génèrent une médiane de 300 To de données par semaine (Ward et Barker, 2013).

Enfin, le dernier V concerne la vitesse. Deux types de vitesse coexistent : celles de la création des données (plusieurs sources alimentent en temps réel les logiciels du *Big Data*) et la rapidité avec laquelle ces données doivent être enregistrées et analysées (ces données doivent être traitées rapidement pour fournir des indications pertinentes) (Kitchin et McArdle, 2016).

Cependant, les auteurs contemporains s'accordent à dire qu'il existe plusieurs formes de *Big Data* : une définition par les 3V est alors insuffisante (Kitchin et McArdle, 2016 ; Lugmayr *et al.*, 2016 ; Patgiri et Ahmed, 2016). Dès 2012, Gartner ajoute un 4^e V, celui de la Vérité (Laney et Beyer, 2012). La vérité des données englobe également leur précision et leur pertinence et représente la caractéristique qui permet d'obtenir des résultats fiables et utilisables. Cette caractéristique est d'autant plus importante qu'il est difficile de s'assurer individuellement de la vérité de chaque donnée, étant donné les volumes massifs traités (Patgiri et Ahmed, 2016). D'autres caractéristiques sont couramment évoquées mais ne font pas l'objet de consensus : l'exhaustivité (car, à l'inverse de la démarche scientifique classique, le *Big Data* utilise généralement des jeux de données complets plutôt que des échantillons) ; la résolution fine (dans le sens où les données concernent des entités individuelles plutôt que des groupes) ; la valeur (qui est extraite des données) ; et la variabilité (car les résultats obtenus à partir de mêmes données peuvent varier selon le contexte utilisé lors de leur analyse).

Kitchin et McArdle (2016) ont tenté de définir les caractéristiques essentielles du *Big Data* et ses caractéristiques secondaires en fonction des types de données traitées. Les auteurs ont identifié vingt-six grands types de *Big Data* et ont conclu que la vitesse et l'exhaustivité étaient les seuls paramètres nécessaires. Les autres caractéristiques sont importantes, mais ne sont pas suffisantes. En particulier, le volume et la variété des données, c'est-à-dire deux des 3V déterminés en 2001, ne sont pas des critères suffisants.

Une tentative de définition « non-ambiguë » a également été réalisée par Baro *et al.* en 2015. Les auteurs ont étudié les jeux de données créés pour la publication de 48 études et ont pu déterminer que le *Big Data* peut être classé selon la quantité d'information stockée. Leur équipe a d'abord défini n comme le nombre d'individus étudiés (qui n'est pas forcément un individu physique, il peut par exemple s'agir d'une séquence génétique) et p comme le nombre de variables mesurées par individu. La valeur *cut-off* à partir de laquelle il est possible de parler de *Big Data* a alors été définie par la formule $\log(n \times p) \geq 7$. Cette proposition a l'avantage de définir le *Big Data* en considérant à la fois sa taille et sa complexité (McCue et McCoy, 2017).

La croissance colossale du *Big Data* s'est accompagnée du développement d'applications spécifiques, aptes à enregistrer, traiter et stocker ces données. Seuls ces outils permettent de donner un sens aux données brutes et d'en tirer des applications pratiques. Les principaux concepts sont présentés dans la partie suivante.

b. Les technologies actuelles du Big Data

- *La nécessité de technologies distribuées*

Face à la quantité massive de données, la plupart des technologies du *Big Data* sont dites « distribuées ». Les ressources nécessaires, qu'il s'agisse de puissance de calcul ou de stockage, sont ainsi réparties sur différentes machines qui fonctionnent en parallèle. Les technologies utilisées diffèrent toutefois en fonction du but recherché.

La plupart des bases de données sont dites « relationnelles », car le logiciel enregistre les données en associant une « clé » à une « valeur »¹. Ce fonctionnement est particulièrement adapté à l'ajout, à la mise à jour, à la recherche et à la récupération de quelques données à la fois. Pour cet usage, les bases de données relationnelles sont optimisées : elles sont rapides et déployées facilement. Cependant, ces optimisations logicielles présentent d'autres problématiques. Utilisées avec du matériel performant, il n'existe pas de réelle limite quant à la taille de la base de données, mais plus la quantité de données augmente, plus l'analyse d'un large ensemble de données devient longue (Jacobs, 2009).

S'il est toujours possible d'obtenir du matériel informatique plus puissant, une limite est rapidement atteinte : celle de l'efficacité financière et énergétique. Au-delà d'une certaine demande en ressources, il devient plus avantageux d'utiliser de nombreuses machines fonctionnant en parallèle plutôt qu'une seule machine puissante.

¹ De telles bases de données sont donc représentées sous la forme de tableaux. Chaque ligne est identifiée par une clé et permet de stocker n valeurs. Dans un modèle relationnel, une ligne peut contenir une valeur correspondant à une « clé étrangère », qui redirige vers une ligne stockée dans une autre table. Il est donc possible de créer des relations entre deux tables pouvant stocker des données différentes (McCue et McCoy, 2017).

En 2004, Google annonce le dépôt d'un brevet et le développement d'un nouveau principe de programmation : *MapReduce* (Dean et Ghemawat, 2008, 2010). *MapReduce* comporte deux étapes : l'étape de *Mapping* qui divise et répartit le traitement des données sur plusieurs machines, puis l'étape de *Reducing* qui regroupe et interprète les résultats de la première étape de manière centralisée. Ce concept est au cœur du *framework* (ou environnement de développement) *Hadoop*, dont la première version stable est publiée par la *Apache Software Foundation* en 2011 (ASF, 2023a, 2023b). Ce logiciel permet aux développeurs de ne pas réimplémenter certaines tâches compliquées (faire fonctionner plusieurs processus sur plusieurs machines de manière concomitante, valider le bon traitement des données, assurer la bonne marche des opérations malgré une panne matérielle, etc.). L'abstraction de ces tâches facilite et accélère le développement d'algorithmes pour le traitement du *Big Data*.

Hadoop comprend également d'autres modules formant un écosystème quasiment clé-en-main pour les développeurs. Ce *framework* constitue le point de départ des technologies actuelles et un tournant dans le développement du *Big Data* et des intelligences artificielles.

- *L'usage actuel des technologies du Big Data*

Aujourd'hui, un autre projet également développé par la fondation Apache est très utilisé, il s'agit de *Spark*. Cet écosystème logiciel a été développé avec l'objectif de surmonter certaines limites de *Hadoop*, notamment en améliorant les performances des algorithmes de *Machine Learning*. Si *Hadoop* est encore utilisé, *Spark* est l'un des projets *open-source*² les plus actifs dans le domaine du *Big Data* (ASF, 2023c ; Wang et Alexander, 2020).

Toutefois, seules les grandes entreprises, telles que les GAFAM³, peuvent utiliser ces logiciels sur leurs propres machines. Les compétences et le budget nécessaire à la maintenance d'infrastructures suffisamment efficaces sont en effet prohibitifs (Oracle Cloud, 2022). Des solutions restent néanmoins disponibles pour les équipes plus modestes, il s'agit du *cloud computing*, aussi traduit en français par « l'informatique en nuage ». Cette pratique ne se limite pas seulement à du stockage en ligne : elle regroupe en réalité toutes les technologies permettant d'utiliser des serveurs internet à distance. Les offres de *cloud* sont variées : l'hébergeur peut gérer uniquement la partie matérielle ou bien gérer l'intégralité de la maintenance, y compris logicielle (par exemple, la maintenance de *Spark* ou *Hadoop*). Chaque acteur du *Big Data* peut donc utiliser le service qui correspond le mieux à ses capacités et besoins techniques.

- *Le stockage des données, un défi à part entière*

Les jeux de données actuels atteignent des valeurs jamais observées auparavant. En 2017, l'*International Data Corporation* a estimé que la quantité mondiale de données atteindrait 163 Zo⁴ en 2025 (Reinsel et al., 2017). Les installations scientifiques, notamment celles du secteur

² Un logiciel *open-source* est un logiciel dont le code source est public et maintenu par une communauté, à l'inverse d'un logiciel propriétaire dont le code source est privé.

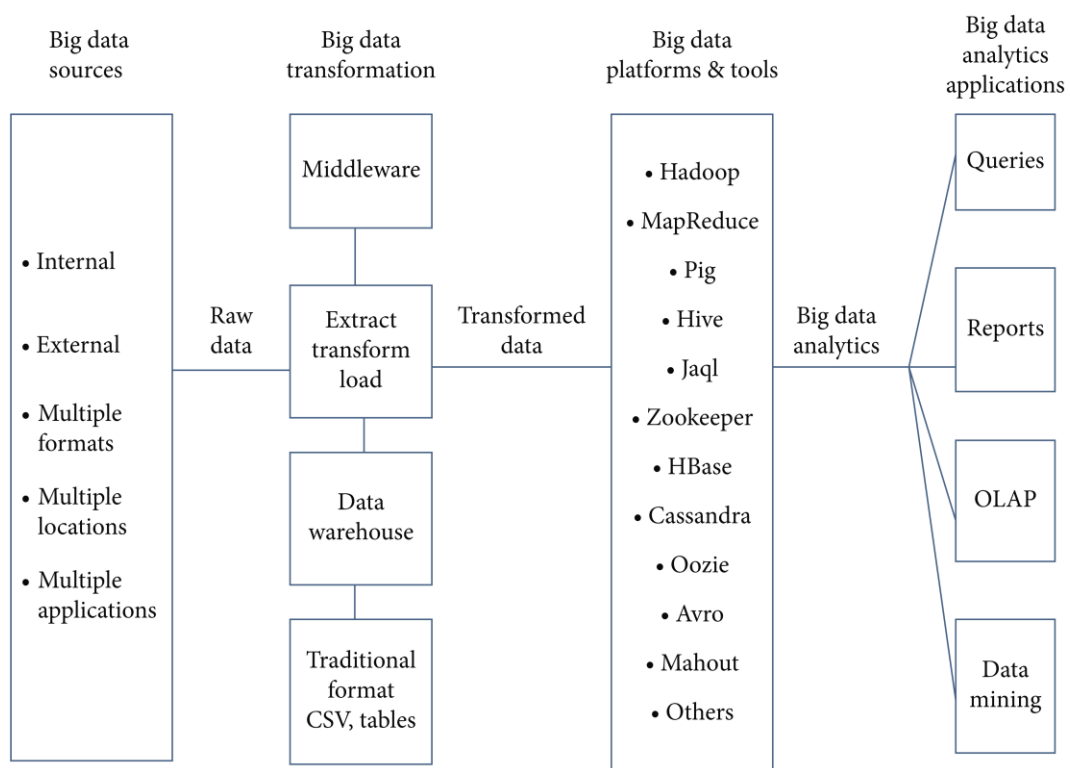
³ Cet acronyme regroupe les entreprises américaines à la tête du secteur informatique : Google, Apple, Facebook, Amazon et Microsoft.

⁴ Un zettaoctet (Zo) correspond à 1 000 000 000 téraoctets (To).

médical, sont parmi les plus grands producteurs de données (Raja *et al.*, 2020). De tels besoins de stockage ont conduit au développement de nouvelles méthodes plus adaptées.

La méthode de traitement habituelle, illustré par la **Figure 1**, est un processus appelé « *Extract – Transform – Load* » (ETL), ou « extraction – transformation – chargement ». Concrètement, les données sont d'abord récupérées depuis une ou plusieurs sources (phase *Extract*). Elles sont ensuite préparées et potentiellement nettoyées (phase *Transform*, expliquée dans la partie **I.1.b.a.**), puis stockées sur une plateforme spéciale appelée en anglais une *Data Warehouse*, ou « entrepôt de données ». Cette méthode est efficace mais présente toutefois des limites, comme le cloisonnement des données. Selon l'architecture et le type d'analyse, il peut être difficile de mettre en relation différents jeux de données (Oracle Cloud, 2022 ; Raja *et al.*, 2020 ; Sow *et al.*, 2013 ; Wang et Alexander, 2020).

Figure 1 : Fonctionnement-type de la collecte, transformation et analyse du *Big Data*.
Licence [CC-BY](https://creativecommons.org/licenses/by/4.0/) (Raja *et al.*, 2020).



Dans les années 2010, le développement d'une offre plus diversifiée et plus efficace de *cloud computing* a permis son adoption par un grand nombre d'entreprises. Le stockage est ainsi devenu une ressource relativement peu onéreuse et surtout quasiment infinie. Ces innovations ont profité aux *Data Warehouse* et ont permis la création de nouveaux usages. Au lieu de devoir traiter les données avant leur stockage, le *Big Data* peut désormais être stocké immédiatement et analysé plus tard, selon un nouveau processus appelé « *Extract – Load – Transform* ». Les données sont stockées telles quelles, dans des *Data Lake*. Ces « lacs de données » sauvegardent des fichiers entiers, sans structure ou hiérarchie particulière, jusqu'à ce qu'un algorithme d'analyse en ait besoin (Oracle Cloud, 2022).

c. Le Big Data en médecine humaine et en médecine vétérinaire

- *Les différentes origines du Big Data en médecine humaine*

Les sources de *Big Data* se sont multipliées ces dernières années, particulièrement dans le domaine médical. En médecine humaine, les IA sont principalement entraînées grâce aux données des dossiers médicaux électroniques, aux enregistrements de bases de données officielles et aux données issues d'appareils connectés (Piovani et Bonovas, 2022).

Les dossiers électroniques ont permis une centralisation des données utilisables, en associant des caractéristiques de base (âge, sexe, etc.) à des caractéristiques détaillées, comme des résultats d'analyse. Ces données ont facilité le développement de systèmes plus avancés de gestion et de traitement (Cheng *et al.*, 2020). D'autres systèmes sont en mesure d'analyser des données non structurées, transformant ainsi des rapports écrits ou des interprétations textuelles de résultats d'analyse en autant de données utilisables par les outils du *Big Data* (Stein *et al.*, 2019).

Les bases de données officielles peuvent également être des sources de *Big Data*, par exemple dans les pays disposant d'une sécurité sociale nationale où les dossiers électroniques sont centralisés. La grande quantité de données permet d'étudier des maladies rares, difficiles à analyser avec des méthodes traditionnelles (Wang *et al.*, 2019). Des consortiums internationaux peuvent également être à l'origine de la création de bases de données internationales pouvant par la suite être utilisées pour l'entraînement des IA (Cheng *et al.*, 2020).

Enfin, lorsque les données issues d'appareils connectés sont enregistrées pendant suffisamment longtemps et chez un nombre important de sujets, elles forment une catégorie de *Big Data* appelée le *Crowd Source Data*, c'est-à-dire des données dont la production est participative (Cheng *et al.*, 2020 ; Wang et Alexander, 2020). Les appareils générant ces données peuvent être destinés au grand public (applications pour téléphone, montres connectées, etc.) ou être des dispositifs médicaux (appareils de surveillance de la glycémie, de la température, etc.). Bien qu'il existe des limites à l'exploitation de telles données, elles présentent l'avantage de faciliter le recrutement d'individus et de pouvoir suivre l'évolution des données en temps réel (Dimitrov, 2016).

- *Le Big Data vétérinaire « passif »*

Comme en médecine humaine, le *Big Data* vétérinaire peut utiliser des bases de données regroupant des dossiers électroniques. Ce type de *Big Data* pourrait donc être qualifié de « passif », car, au moment où les praticiens enregistrent leurs données, l'objectif principal n'est pas forcément de créer du *Big Data* (Cheng *et al.*, 2020).

Ces bases de données sont généralement publiques et accessibles sur demande. Ces données sont issues : des dossiers électroniques issus de regroupements de cliniques vétérinaires ou d'écoles vétérinaires ; des enregistrements de compagnies d'assurances vétérinaires ; ou bien recueillies dans le cadre de projets de recherche de grande envergure (Paynter *et al.*, 2021).

Aux États-Unis, l'un des plus importants groupements vétérinaires, le *Banfield Pet Hospital*, collecte et regroupe les données cliniques de plus de 2,5 millions de chiens et 500 000 chats via un logiciel propriétaire unique pour l'ensemble de leurs lieux d'exercices (Banfield Pet Hospital, 2023). Les enregistrements contiennent notamment la localisation géographique de l'animal, ses résultats d'analyse, ses traitements et ses diagnostics, ce qui permet la réalisation d'études

épidémiologiques (Glickman *et al.*, 2006). Cette source de *Big Data* reste toutefois difficile d'accès, les données restant la propriété d'une entreprise privée (Paynter *et al.*, 2021).

Vingt-six universités américaines et canadiennes fournissent les données d'une base nommée la *Veterinary Medical Database* (University of Missouri, 2014). En 2014, elle contenait les dossiers médicaux de plus de sept millions d'animaux. Leur analyse a permis la publication de plusieurs études, relevant toutefois plutôt de l'analyse du *Big Data* que de la création d'une IA compte-tenu de la présence de biais (Paynter *et al.*, 2021 ; Villamil *et al.*, 2011).

En 2008, l'Association Vétérinaire Britannique des Petits Animaux de compagnie et l'Université de Liverpool ont créé le *Small Animal Veterinary Surveillance Network* (SAVSNET), une base de données regroupant les enregistrements de plusieurs cliniques et laboratoires vétérinaires britanniques (Radford *et al.*, 2010 ; University of Liverpool, 2023). L'un des objectifs principaux est la réalisation d'analyses épidémiologiques, mais l'élaboration d'IA à partir de cette base de données a fait l'objet de quelques publications (Fins *et al.*, 2024 ; Noble *et al.*, 2021).

De façon similaire, le programme VetCompass (*Veterinary Companion Animal Surveillance System*) collecte automatiquement les données générées par plus de 1 800 cliniques britanniques, dans le but de réaliser des enquêtes épidémiologiques (Royal Veterinary College, 2022). Des projets annexes existent ou sont en phase d'essai, notamment en Australie où les écoles vétérinaires collaborent pour la création d'une base de données nationale (McGreevy *et al.*, 2017). Certains types de données sont toutefois manquants, par exemple concernant le mode de vie et l'environnement des animaux (Kennedy *et al.*, 2019 ; Paynter *et al.*, 2021). Cela ralentit la création d'IA à partir de ce jeu de données, mais des IA entraînées avec VetCompass existent déjà et sont présentées dans la partie II (Schofield *et al.*, 2021).

Comme en médecine humaine, les bases de données des assureurs vétérinaires peuvent aussi être utilisées. Leur principal avantage est leur homogénéité et la présence systématique de certaines informations. Dans les pays avec une faible proportion d'animaux assurés, il existe toutefois un risque de mauvaise représentativité des données (Paynter *et al.*, 2021).

Enfin, en France, les mouvements d'animaux de production sont enregistrés, conformément à la réglementation ou de manière spontanée par des organismes privés, ce qui peut également constituer une source de *Big Data* vétérinaire (Ezanno *et al.*, 2021).

- *Le Big Data vétérinaire « actif »*

Les données du *Big Data* peuvent aussi être activement collectées par des chercheurs ou des entreprises, lors de l'élaboration d'un produit commercial ou dans le cadre d'un projet scientifique. Trois de ces études scientifiques de grande envergure sont présentées ci-dessous : la *Golden Retriever Lifetime Study* (GRLS) concernant des Golden Retrievers américains, *DogsLife* concernant des Labrador Retrievers britanniques et le *Dog Aging Project* (DAP) qui collecte les données de chiens vivant aux États-Unis, toutes races confondues (Clements *et al.*, 2013 ; Creevy *et al.*, 2022 ; Labadie *et al.*, 2022).

Les avantages d'une collecte active sont la diversité et l'exhaustivité des données. Des questionnaires concernant le mode de vie et l'état de santé des animaux sont régulièrement envoyés aux propriétaires enrôlés dans ces projets. Les Golden Retrievers de la cohorte GRLS sont examinés au moins une fois par an et des échantillons de sang, d'urine, de selles et de poils sont systématiquement prélevés. Certains chiens du DAP sont également soumis à des examens

plus poussés. Des séquençages ADN, des analyses du microbiome ou des électrocardiogrammes permettent ainsi de former des sous-jeux de données spécifiques. Pour chacun de ces projets, une médecine unique dans le cadre du mouvement *One Health* est aussi un des objectifs principaux (Clements *et al.*, 2013 ; Creevy *et al.*, 2022 ; Labadie *et al.*, 2022).

Ces projets rapportent des taux de réponse élevés, malgré la charge de travail importante pour les propriétaires. Le principal obstacle rencontré est la présence d'erreurs ou d'inexactitudes dans les réponses pouvant introduire des biais. En dépit de ces avantages, il existe en 2023 encore peu de publications sur l'élaboration d'IA à partir de ces sources spécifiques de *Big Data* vétérinaire (Clements *et al.*, 2013 ; Creevy *et al.*, 2022 ; Labadie *et al.*, 2022).

- *Le Big Data, des données obtenues sur le terrain*

En résumé, les données formant le *Big Data* sont donc collectées à différents niveaux. Toute catégorie confondue, les capteurs et appareils connectés créent le plus grand volume de données et constituent la majeure partie des données exploitées aujourd'hui (Wang et Alexander, 2020). Les niveaux de collecte du *Big Data* sont présentés ci-dessous et illustrés par la **Figure 2** (Fang *et al.*, 2016 ; McCue et McCoy, 2017) :

- données omiques⁵ (séquences ADN, séquences protéiques...). La métabolomique peut être regroupée dans cette catégorie ou avec les données générées par une machine ;
- données cliniques (âge, température, fréquence cardiaque...) ;

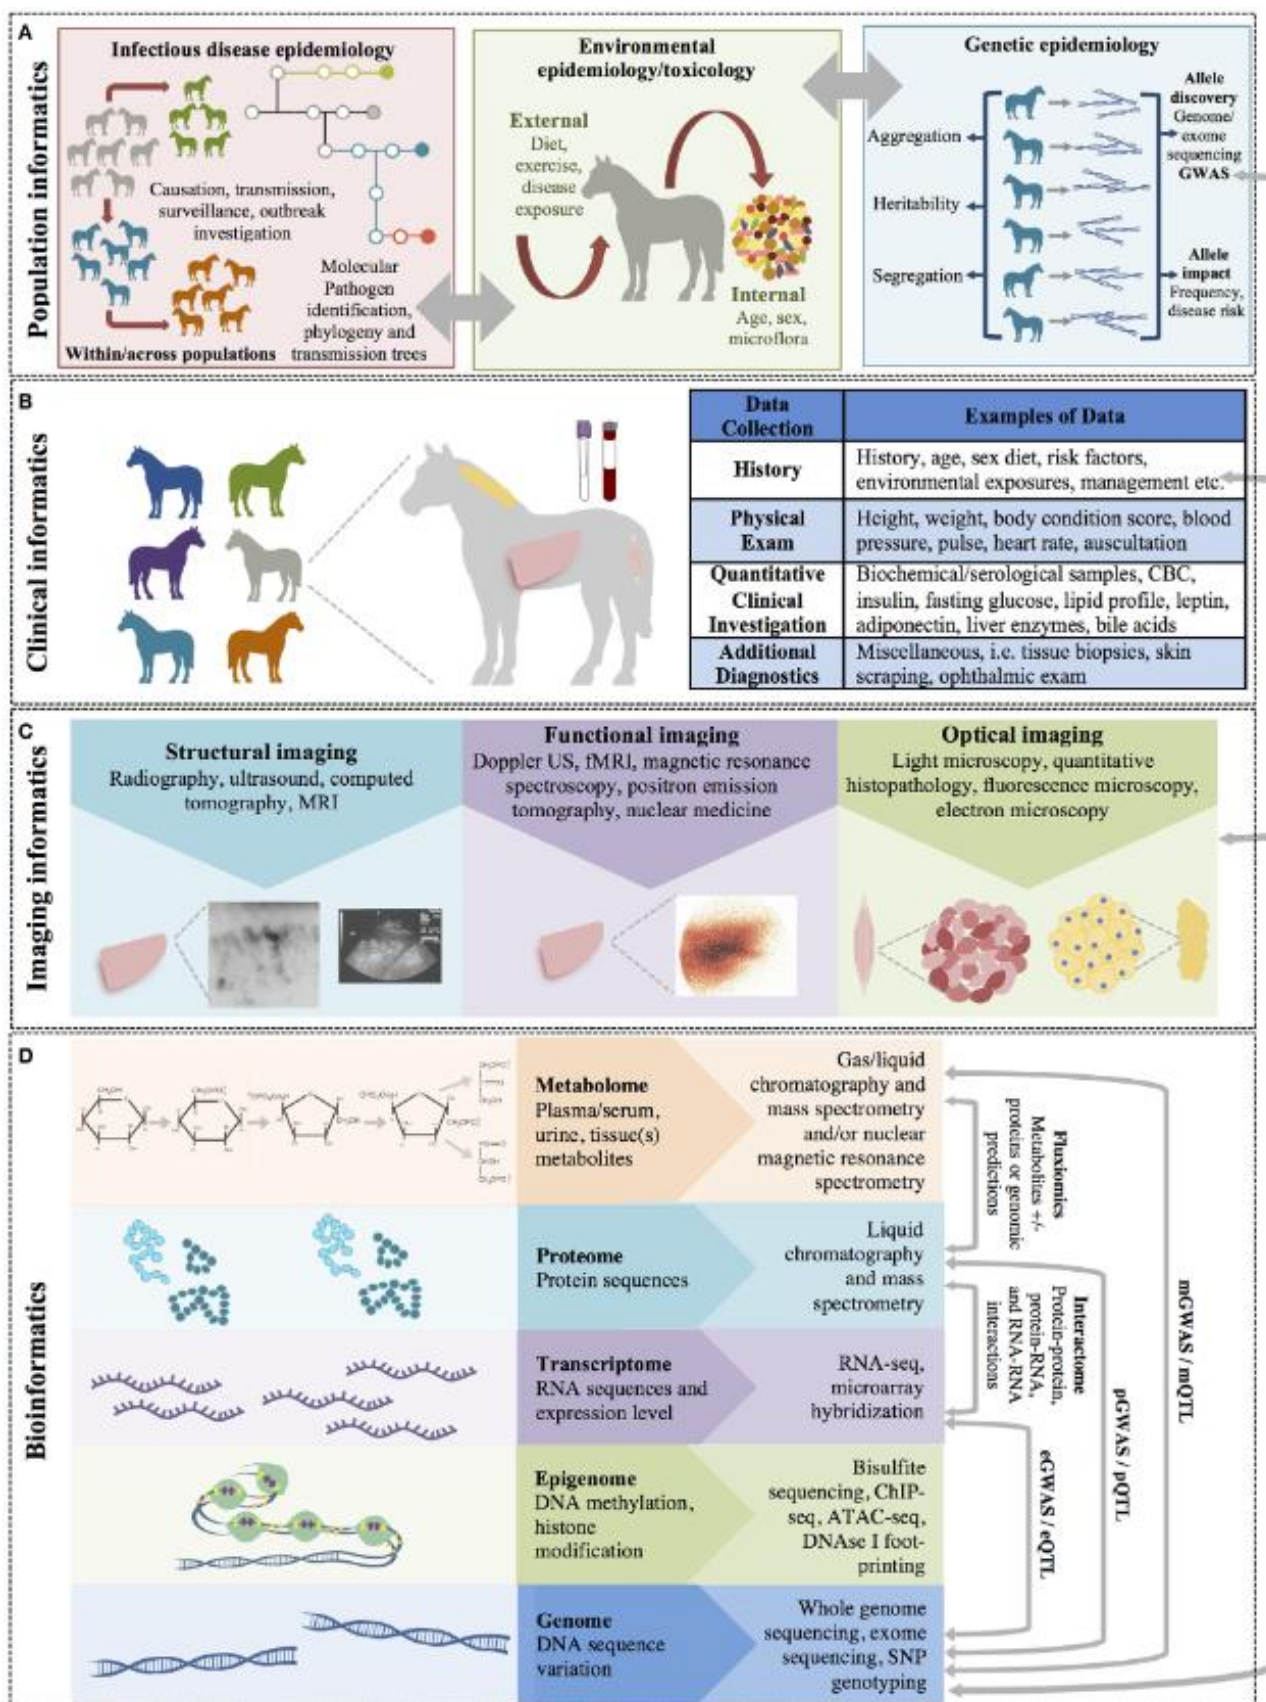
Pour les humains en particulier, les données peuvent aussi être biométriques (empreintes digitales, empreintes iriennes...) (Raja *et al.*, 2020). ;

- données générées par un humain (notes prises par un médecin ou un vétérinaire, interprétations de résultats d'analyse...) ;
- données générées une machine (métabolomique, biochimie, imagerie, capteurs variés connectés ou non...) ;
- données administratives (transactions financières avec des organismes assureurs, réseaux sociaux...) ;
- données à l'échelle des populations (prévalence de maladies, répartition géographique...), qui peuvent ensuite être utilisées pour l'étude de maladies infectieuses ou l'analyse de prédispositions environnementales ou génétiques.

⁵ Les sciences omiques regroupent la génomique, l'épigénomique, la transcriptomique, la protéomique et la métabolomique, qui étudient respectivement le génome, l'épigénome, le transcriptome, le protéome et le métabolome (McCue et McCoy, 2019).

Figure 2 : Les différentes sources de **Big Data**.

Licence [CC-BY](https://creativecommons.org/licenses/by/4.0/) (McCue et McCoy, 2017).



L'étude de Baro *et al.* évoquée dans la partie **I.1.a.a.**, qui a introduit les termes n et p pour définir le *Big Data*, propose une répartition des jeux de données en trois catégories. La première est caractéristique des études omiques, avec un très grand nombre de variables mesurées sur une population restreinte (petit n , grand p) ; la seconde, la plus courante, est définie par une quantité modérée à importante de données collectées chez une population moyenne à importante (grand n , grand p) ; la troisième est celle retrouvée lors d'études épidémiologiques, qui mesurent un nombre de variables restreint sur de très grandes populations (grand n , petit p).

Le *Big Data* est donc une sous-catégorie de données dites *Real-World Data*, c'est-à-dire des données « obtenues sur le terrain » plutôt qu'à la suite d'essais cliniques. Selon l'Association des Industries Pharmaceutiques Anglaises, cette notion est définie comme « toute donnée obtenue de manière non interventionnelle et qui décrit ce qui se passe dans le cadre d'une pratique clinique normale » (ABPI, 2011). Si des risques de mauvaise interprétation existent et sont détaillés dans la partie **I.3.b.**, l'utilisation raisonnée de ces données peut permettre d'aboutir plus rapidement à des résultats (Piovani et Bonovas, 2022). L'enjeu principal du *Big Data* médical est donc l'extraction d'informations utiles, ouvrant la voie à des études à la méthodologie classique ou permettant l'élaboration d'intelligences artificielles. Les moyens disponibles actuellement pour y parvenir sont présentés dans la partie suivante.

B. L'élaboration d'un algorithme d'intelligence artificielle

a. Des données brutes à un algorithme intelligent

- *Le pré-traitement*

Une fois les données nécessaires obtenues, l'étape suivante consiste en leur analyse. Celle-ci commence par un pré-traitement visant à écarter les données de mauvaise qualité. Cette étape est généralement réalisée de manière décentralisée, par exemple avec les *frameworks Hadoop* ou *Spark* (Banaee *et al.*, 2013 ; Fang *et al.*, 2016).

Pour les données issues de mesures biochimiques ou de capteurs, celles-ci peuvent faire l'objet d'un « nettoyage ». Lorsque les mesures sont continues (par exemple un ECG), différents filtres permettent de lisser et améliorer le signal obtenu. Lorsque les données sont discontinues (par exemple, des mesures répétées de glycémie), d'autres filtres peuvent supprimer automatiquement les valeurs aberrantes. Enfin, quel que soit le type de mesure, une interpolation peut être réalisée pour combler d'éventuelles données manquantes. Lorsque de nombreux capteurs sont utilisés simultanément, il est aussi parfois nécessaire de les synchroniser ou de normaliser leurs résultats (Banaee *et al.*, 2013 ; Fang *et al.*, 2016).

Les dossiers médicaux électroniques sont les sources d'informations les plus riches, mais également les plus difficiles à traiter. Il existe des standards internationaux de codes médicaux visant à normaliser les diagnostics, comme le SNOMED-CT utilisé pour la *Veterinary Medical Database*, mais ceux-ci ne sont pas suffisamment mis en place en pratique pour permettre une extraction d'informations efficace. Les auteurs insistent aussi sur le manque d'exhaustivité des dossiers. Ce manque nécessite la réalisation d'un tri préalable et peut parfois empêcher totalement l'analyse des dossiers électroniques (Sow *et al.*, 2013).

- *L'extraction des données*

Les données ainsi traitées sont généralement redondantes et doivent subir une dernière étape avant de pouvoir être utilisées par une IA : une « extraction/sélection ». Cette étape permet de réduire l'ensemble des données recueillies à un plus petit jeu de données, sans perte d'information importante et en restant représentatif des données initiales (Banaee *et al.*, 2013). Cela est possible en éliminant les variables les moins significatives. Cette étape permet également de réduire les ressources nécessaires au traitement des données par l'IA, tout en permettant généralement d'obtenir des résultats plus précis (Fang *et al.*, 2016).

Par exemple, en utilisant la notation de l'étude de Baro *et al.*, si on considère un ensemble de données où l'on a mesuré p variables par individu, alors il est possible de représenter ces données dans un espace à p dimensions (Altman et Krzywinski, 2018). Toutefois, chaque dimension n'est pas forcément utile pour décrire la répartition de ces données. Les dimensions superflues peuvent même créer du bruit et rendre les IA imprécises. Ce phénomène, appelé l'*overfitting*, est dû à des calculs statistiques incorrects⁶ et se caractérise par une mauvaise adaptabilité de l'IA face à des données inédites. Cette limite est présentée plus en détail dans la partie **I.3.b.b.** (Altman et Krzywinski, 2018 ; Banaee *et al.*, 2013).

Le *Principal Component Analysis (PCA)* est l'algorithme d'extraction/sélection le plus courant. Il analyse l'ensemble des données, qui est donc un espace à p dimensions, puis projette ces données dans un espace à $p-1$ dimensions. En choisissant la projection appropriée, le nouveau jeu de données est plus petit mais reste représentatif (Banaee *et al.*, 2013).

L'extraction de données à partir de dossiers médicaux électroniques est généralement complexe en raison de leur nature non structurée et nécessite l'utilisation d'algorithmes de *Natural Language Processing (NLP)*, ou « traitement du langage naturel » (Turchin et Florez Builes, 2021). Le NLP est lui-même un domaine en constante évolution et les outils de NLP récents sont souvent des IA, comme expliqué dans la partie **I.2.b.b.**.

Le NLP peut être utilisé de plusieurs manières. D'une part, cet outil peut servir uniquement à l'extraction et à la réduction de la dimension des données. Kwong *et al.* (2019) ont par exemple traduit des prescriptions et posologies en codes médicaux vétérinaires standardisés. D'autre part, le NLP peut faire office à la fois d'extracteur de données et d'IA. Fins *et al.* (2024) ont par exemple obtenu un algorithme d'aide à la surveillance du diabète en entraînant une IA sur des données brutes des dossiers médicaux.

Quelles que soient les méthodes utilisées, les données obtenues à cette étape peuvent désormais être analysées ou être utilisées pour créer ou entraîner une IA (Fang *et al.*, 2016).

⁶ Une augmentation, même modeste, du nombre de mesures par individu entraîne une augmentation massive du nombre de combinaisons mesurées possibles et donc du nombre d'observations nécessaires pour pouvoir réaliser des statistiques (Altman et Krzywinski, 2018 ; Bandeira, 2020).

Bandeira présente l'exemple suivant : pour pouvoir réaliser l'échantillonnage de l'intervalle $[0,1]$ à 0,01 près, 100 observations suffisent si elles sont bien réalisées. Toutefois, si on veut échantillonner un cube à cinq dimensions (c'est-à-dire, lorsqu'on réalise cinq mesures par individu) de la même manière, alors il faudrait cette fois réaliser 10^{10} observations, ce qui est en pratique impossible. Réduire la dimension du jeu de données étudié est donc essentiel.

b. Les différents types d'intelligences artificielles

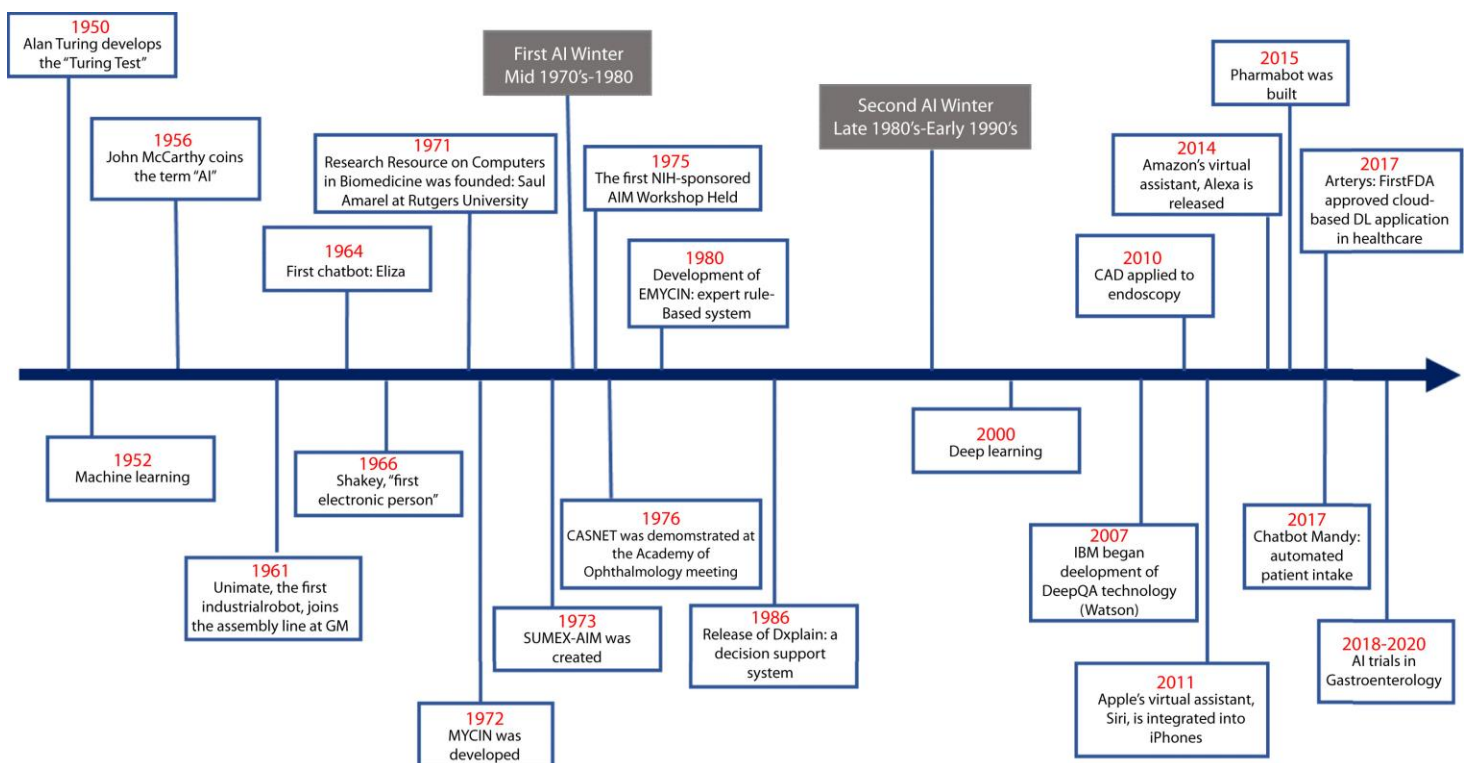
Le terme « intelligence artificielle » est également un concept pouvant accepter plusieurs définitions. Utilisé pour la première fois en 1955-1956 par le scientifique américain John McCarthy, ce terme désigne de manière générale un algorithme imitant l'intelligence humaine, quel que soit le domaine considéré (Appleby et Basran, 2022 ; Russell et Norvig, 2020, chap. 1). L'IA n'est donc pas un concept récent, mais son développement s'est surtout accéléré ces dernières années, avec l'avènement du *Big Data*.

On distingue habituellement trois grandes phases dans l'histoire de l'IA, qui sont représentées sur la **Figure 3** (Kaul *et al.*, 2020) :

- Des années 1950 à 1970, les prémices de l'IA se concentrent sur des tâches simples mais nouvelles. La médecine ne s'approprie pas encore ce nouvel outil, mais cette phase permet la numérisation de données qui serviront par la suite.
- Les années 1970 à 2000 sont une période où l'intérêt pour l'IA et son développement sont fortement réduits. En 1970, les limitations techniques de l'époque deviennent évidentes et constituent une première crise. La seconde crise a lieu au début des années 1990, suite aux coûts de maintenance et de stockage alors prohibitifs.
- Enfin, à partir des années 2000, les IA peuvent désormais tirer profit du *Big Data*. Le domaine médical se rend compte des possibilités offertes par les IA. Ce type d'IA devient de plus en plus accessible.

Figure 3 : Chronologie du développement et de l'usage de l'IA en médecine.

Utilisée avec l'autorisation de Kaul *et al.* (2020).



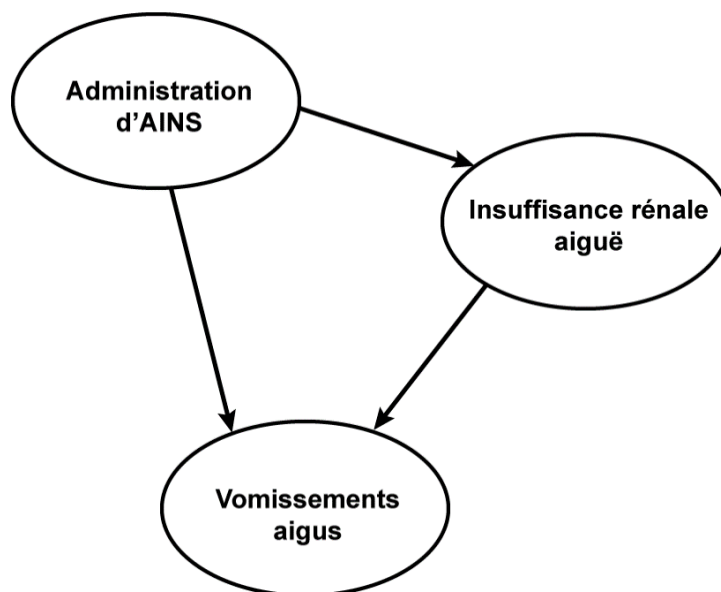
Les algorithmes au cœur des IA ont évolué avec le temps. Les IA les plus simples sont programmées « manuellement ». Il peut s'agir d'algorithmes suivant des procédés mathématiques simples, comme des régressions, ou bien de logiciels faisant preuve d'inférence logique. À partir d'un jeu de règles définies à l'avance, l'algorithme effectue une suite de déductions aboutissant à un résultat final (Johnson-Laird, 2010 ; Russell et Norvig, 2020, chap. 8).

Ce type de raisonnement est relativement efficace, mais présente néanmoins des limites. En effet, la création d'un jeu de règles suffisamment complet est complexe et l'inférence logique ne permet pas de simuler subtilement une intelligence humaine (Johnson-Laird, 2010). L'aspect manquant à ces IA est l'association d'une probabilité à leur conclusion.

Pour raisonner de manière probabiliste, plusieurs concepts existent et le plus utilisé est celui des réseaux bayésiens, formalisés à la fin des années 1990 (Russell et Norvig, 2020, chap. 1). Un réseau bayésien est un graphe orienté où chaque nœud représente une variable discrète ou continue et possède des probabilités conditionnelles de se produire⁷ (Russell et Norvig, 2020, chap. 14). Un tel réseau représente donc l'ensemble des connaissances d'une IA et lui permet aussi de calculer la probabilité de survenue d'un événement dans un contexte précis.

Dans le domaine médical, une variable pourrait par exemple représenter un symptôme, une maladie ou une action. Chaque lien correspondrait alors à la probabilité qu'une maladie donnée ait causé un symptôme particulier, comme illustré par la **Figure 4**.

Figure 4 : Exemple d'un réseau bayésien simple.
Travail personnel.



⁷ Un graphe orienté est un diagramme représentant des nœuds reliés par des flèches (voir la **Figure 4**). Chaque nœud possède donc un ou plusieurs parents. Pour chaque nœud, il est alors possible de définir des probabilités conditionnelles : la probabilité de survenue d'un nœud dépend de la survenue ou non de chacun de ses propres parents (Russell et Norvig, 2020, chap. 14).

De nouveaux usages et des versions dérivées plus complexes des réseaux bayésiens ont par la suite émergé. Des algorithmes permettent ainsi de déterminer approximativement les valeurs des probabilités conditionnelles lorsqu'elles sont inconnues et d'autres peuvent même déterminer la structure du réseau la plus adaptée au problème étudié (Russell et Norvig, 2020, chap. 18). Ce fonctionnement constitue une forme d'apprentissage, appelée le *Machine Learning*. Ce concept au cœur du fonctionnement des IA modernes est présenté plus bas.

c. L'interface homme-machine

Après avoir été entraînée, l'IA peut désormais fournir de nouvelles informations aux utilisateurs. La manière exacte dont celles-ci sont présentées dépend surtout du contexte. Des exemples d'interfaces d'IA vétérinaires sont données dans la partie II. Le passage de données multidimensionnelles à des données en 2D ou 3D s'accompagne également d'une perte d'informations qu'il convient de prendre en compte lors de l'utilisation d'une IA. Les algorithmes les plus courants limitent en partie cette perte, mais nécessitent des ajustements subtils (Huang *et al.*, 2022).

Une représentation graphique peut elle-même constituer une forme de données. Une fois les visualisations graphiques obtenues, d'autres IA peuvent extraire et créer de nouvelles données. Une IA pourrait par exemple résumer des visualisations graphiques détaillées ou bien créer un lot de différentes représentations avant de choisir la plus adaptée à la demande de l'utilisateur (Wu *et al.*, 2022).

C. Le *Machine Learning*, socle des intelligences artificielles actuelles

Le *Machine Learning* (ML) est une sous-catégorie d'IA spécifiquement conçue pour « apprendre » à partir d'un jeu de données (Goecks *et al.*, 2020). Contrairement à une IA classique qui imite l'intelligence humaine, un algorithme de ML vise à améliorer ses performances au fur et à mesure de son entraînement. En pratique, un tel algorithme utilise des outils statistiques et mathématiques pour optimiser son fonctionnement interne (Benke et Benke, 2018). Le ML peut prendre différentes formes selon les besoins et il existe par conséquent plusieurs façons d'entraîner un algorithme de ML. Les notions essentielles pour la compréhension du ML sont présentées ci-dessous.

a. Les différents types d'apprentissage

Les algorithmes d'entraînement sont généralement classés dans une de ces trois catégories : l'apprentissage supervisé, l'apprentissage non supervisé et l'apprentissage par renforcement (Awaysheh *et al.*, 2019).

L'apprentissage d'une IA est dit supervisé lorsqu'il est entraîné sur un jeu de données étiqueté, c'est-à-dire pour lequel chaque groupe de mesures (par exemple, une race, un âge, une fréquence cardiaque, *etc.*) est associé à une catégorie (par exemple, l'animal est « malade » ou « non malade ») (Goecks *et al.*, 2020). Une partie du jeu de données est généralement utilisée pour l'entraînement de l'IA et la partie restante permet de tester l'IA en vérifiant ses prédictions. Ce type d'entraînement a pour but d'aboutir à une IA capable de généraliser son apprentissage et de prédire des résultats lorsqu'elle est confrontée à de nouvelles données (Yoo *et al.*, 2012).

À l'inverse, l'apprentissage non supervisé utilise des données qui ne sont pas étiquetées. L'IA doit elle-même découvrir la structure des données auxquelles elle est confrontée (Goecks *et al.*, 2020). Ce type d'apprentissage est intéressant pour certaines études, lorsqu'un large ensemble de données est disponible mais que peu d'informations sur ces données sont connues,

par exemple pour les données issues des sciences omiques. Une fois entraînée, l'IA est capable de décrire efficacement les données qui lui sont présentées. Le plus souvent, l'objectif est de découvrir des relations jusqu'alors inconnues (Yoo *et al.*, 2012).

En pratique, les données non étiquetées sont plus abondantes et plus facilement générées que les données étiquetées, qui sont générées par des humains (Yoo *et al.*, 2012). Il existe ainsi un apprentissage mixte, appelé semi-supervisé, où l'IA est entraînée avec des données en partie étiquetées et en grande partie non étiquetées (Russell et Norvig, 2020, chap. 18).

Enfin, lors d'apprentissage par renforcement, l'IA est récompensée en fonction de la justesse de sa réponse. Si celle-ci est juste, alors l'IA est encouragée à poursuivre son apprentissage. Le calcul de cette récompense est automatique et unique à chaque problème rencontré. Il s'agit parfois du seul type de ML utilisable, notamment lorsque le problème est trop complexe pour qu'un humain puisse évaluer précisément les choix de l'IA à chaque étape de son raisonnement. L'IA a une récompense une fois sa réponse finale donnée et elle détermine seule quelles sont les étapes optimales pour arriver à ce résultat (Russell et Norvig, 2020, chap. 21).

b. Les approches de Machine Learning les plus fréquemment rencontrées

Il n'existe pas d'approche unique pour résoudre tous les problèmes rencontrés par une IA et le ML est donc une discipline vaste. Les approches les plus fréquemment rencontrées et celles utilisées par les IA vétérinaires présentées dans la partie II sont décrites ci-dessous.

- *Le clustering*

Le *data clustering*, ou « partitionnement de données », est une technique qui regroupe les éléments avec des caractéristiques communes en *clusters*. La notion de *cluster* diffère selon le problème étudié, expliquant l'existence de plusieurs algorithmes de *clustering*. Le *clustering* est généralement utilisé lors d'apprentissage non supervisé. L'IA identifie seule les caractéristiques optimales pour catégoriser les données (Fang *et al.*, 2016 ; Yoo *et al.*, 2012).

Le « regroupement hiérarchique » est un type de *clustering* qui crée progressivement des paires de groupes de plus en plus petits (ou de plus en plus grands selon l'approche de l'algorithme) en fonction de leur similarité. Cette méthode offre des qualités de visualisation intéressantes, mais elle est lente et coûteuse en ressources (Fang *et al.*, 2016 ; Yoo *et al.*, 2012).

Un autre type de *clustering* peut être qualifié de « centroïde ». Ces algorithmes choisissent d'abord des points aléatoires pour former des *clusters* de départ. Chaque nouvelle donnée est ensuite attribuée au *cluster* dont le centre est le plus proche. En répétant ces étapes avec des points de départ différents, l'algorithme peut déterminer les meilleurs *clusters*. Cette méthode est capable de traiter des jeux de données importants, mais elle est sensible à la présence d'éléments isolés, qui ne font partie d'aucun *cluster*. Les points de départ des *clusters* peuvent également engendrer des différences de classement conséquentes (Fang *et al.*, 2016 ; Yoo *et al.*, 2012).

Une autre méthode de *clustering* utilise la densité des données pour créer des groupes. L'algorithme le plus courant est *DBSCAN*. Cet algorithme analyse chaque point de donnée et les points alentour. Si la densité est suffisamment élevée, ces points sont regroupés dans un même *cluster*. *DBSCAN* est donc capable de créer autant de *clusters* que nécessaire et peut identifier des points isolés. En contrepartie, cette méthode est relativement lente sur des données de taille importante et nécessite un choix minutieux des paramètres internes (Fang *et al.*, 2016).


- Le support vector machine

Aussi appelé séparateur à vaste marge⁸ (SVM), cet algorithme attribue chaque donnée à l'une des deux populations déterminées à l'avance. Lors de son entraînement, l'IA cherche à déterminer le plan optimal de séparation entre les deux catégories. Les deux populations étant déjà connues, il s'agit d'un apprentissage supervisé (Russell et Norvig, 2020, chap. 18).

Par exemple, sur la **Figure 5**, on peut considérer un ensemble d'individus dont on a mesuré le cholestérol et la pression artérielle et qui sont répartis en une population « à risque » (*risky*) et une population « saine » (*safe*) (Yoo *et al.*, 2012). L'IA pourra alors déterminer que la droite 2 est celle qui permet de mieux caractériser ces individus selon leurs valeurs de cholestérol et de pression artérielle, car c'est celle dont les marges sont les plus grandes.

Figure 5 : Exemple de l'utilisation d'un SVM.

Utilisée avec l'autorisation de Yoo *et al.* (2012).



Le SVM a plusieurs avantages : une bonne précision, une tolérance aux erreurs de classifications, une absence de connaissances pré-requises et il est efficace même sur de petits jeux de données. En effet, si les données fournies ne permettent pas d'obtenir un plan de séparation satisfaisant, alors l'algorithme peut calculer de nouvelles caractéristiques pour chaque individu afin d'obtenir un espace de données de dimension supérieure. Dans ce nouvel espace, il sera peut-être possible d'observer un plan (ou un hyperplan si l'espace est à plus de trois dimensions) qui sépare la population en deux (Banaee *et al.*, 2013 ; Russell et Norvig, 2020, chap. 18). Le SVM requiert cependant d'importantes ressources lors de l'entraînement et s'adapte difficilement à une classification en plus de deux catégories (Fang *et al.*, 2016 ; Yoo *et al.*, 2012).

Dans l'exemple de l'équipe de Yoo, l'espace des données est initialement de dimension deux. Si l'algorithme n'avait pas pu séparer les deux populations, il aurait été possible de calculer une valeur dérivée pour chaque individu, afin d'obtenir une espace de dimension trois. Par exemple, la valeur calculée aurait pu être « *cholestérol²* ».

⁸ Sur la **Figure 5**, les marges correspondent à la distance entre la droite 2 et les droites en pointillés. Ces droites pointillées représentent les vecteurs de support. Ce sont des droites parallèles à la droite 2 et qui passent chacune par un point de mesure.

- *Les réseaux bayésiens*

Les réseaux bayésiens ont été présentés dans la partie **I.1.b.b.**. Dans le cadre du ML, il s'agit d'apprentissage supervisé et plusieurs cas de figure existent (Goecks *et al.*, 2020).

Souvent, il est possible de donner un point de départ à l'IA en élaborant le réseau bayésien contenant les relations causales les plus communément admises. Pendant son entraînement, l'IA compare les probabilités conditionnelles observées avec les probabilités déjà calculées auparavant et peut les recalculer si nécessaire pour que le réseau corresponde mieux à la réalité (Awaysheh *et al.*, 2019 ; Russell et Norvig, 2020, chap. 20).

Toutefois, il est possible que ce réseau causal ne puisse pas être créé, par exemple car il n'existe pas de consensus scientifique. Dans ce cas, un réseau bayésien vierge peut être fourni à l'algorithme de ML. Celui-ci doit alors déterminer le réseau le plus efficace pour classer les cas qui lui sont soumis et calculer les probabilités du réseau pour qu'il soit pertinent (Awaysheh *et al.*, 2019 ; Russell et Norvig, 2020, chap. 20).

- *Les arbres de décision*

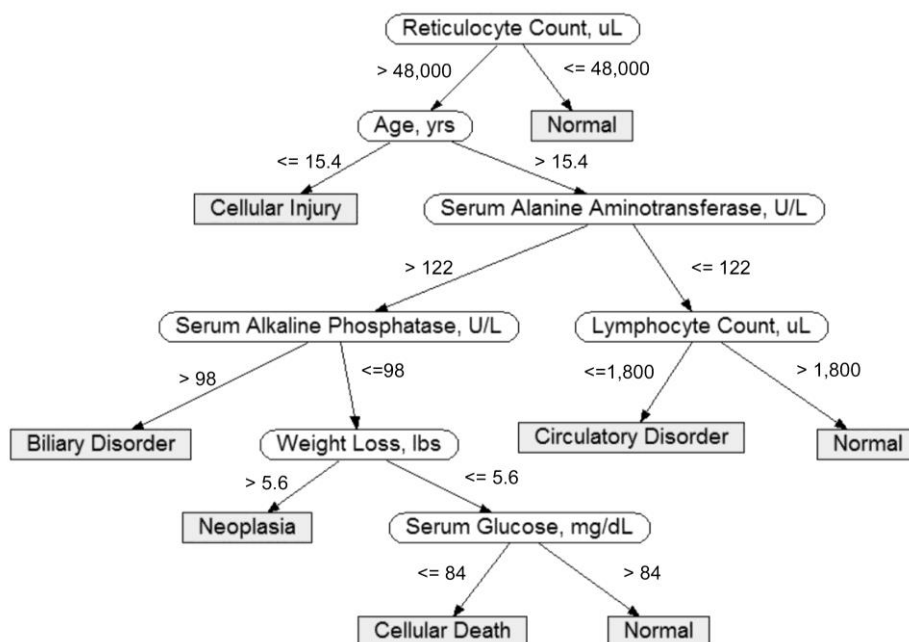
- Les arbres de décision simples

Les IA conçues avec un arbre décisionnel (DT, acronyme de *Decision Tree*) sont entraînées de manière supervisée (Banaee *et al.*, 2013). À partir d'un jeu de données, l'IA va progressivement créer ou supprimer des nœuds, jusqu'à obtenir l'arbre permettant de classer les cas le plus efficacement possible (Russell et Norvig, 2020, chap. 18).

Les DT sont relativement simples à implémenter et peuvent être compris par un humain, comme illustré par la **Figure 6**, mais ils sont plus sensibles à l'*overfitting* (Fang *et al.*, 2016). Ces IA sont moins efficaces en présence d'un grand nombre de paramètres et elles sont moins aptes à découvrir des corrélations inconnues entre paramètres (Banaee *et al.*, 2013).

Figure 6 : Arbre décisionnel classant un trouble hépatique selon des critères cliniques.

Utilisée avec l'autorisation de Awaysheh *et al.* (2019).



□ Les forêts d'arbres décisionnels et l'ensemble learning

Les arbres de décision peuvent être regroupés en « forêts d'arbres décisionnels » (RF, acronyme de *Random Forest*). Dans ce modèle, chaque arbre analyse les données d'entrée et renvoie un résultat de manière indépendante. La forêt agrège ensuite ces résultats et retourne la valeur qui a été sélectionnée le plus souvent par les DT. Les RF permettent généralement une meilleure précision et limitent l'apparition d'*overfitting*, au prix d'une interprétabilité fortement réduite (Hastie *et al.*, 2009, chap. 15). Il est en réalité possible de regrouper de cette façon de nombreux modèles de ML afin d'obtenir de meilleures performances, une méthode alors appelée l'*ensemble learning*.

• *Les réseaux de neurones artificiels*

□ Le fonctionnement d'un réseau neuronal simple

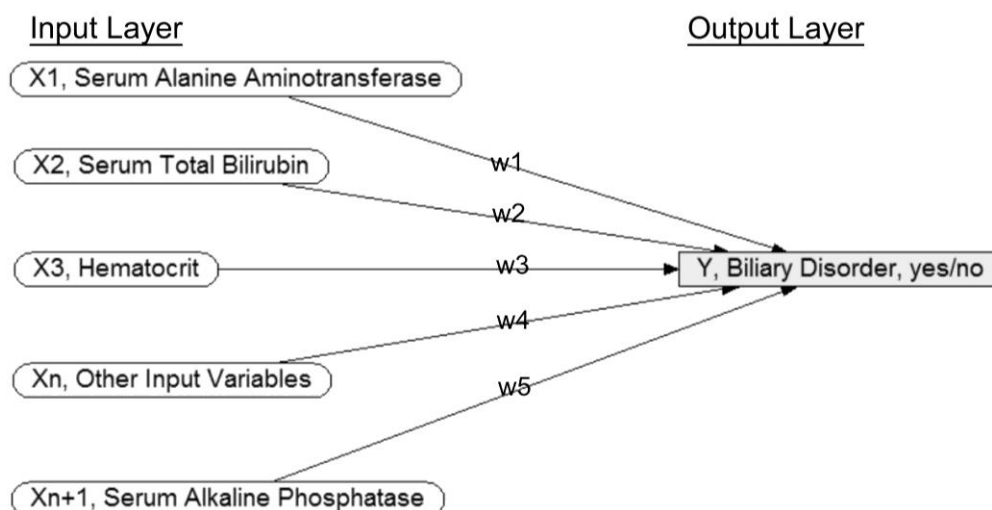
Les réseaux neuronaux, ou *neural networks* (NN) en anglais, sont des algorithmes qui imitent le fonctionnement du cerveau. Les NN peuvent être utilisés lors d'apprentissage supervisé ou lors d'apprentissage non supervisé. Dans ce type de ML, le réseau est composé de nœuds, représentant chacun un neurone. Chaque neurone est relié à d'autres neurones par des connexions possédant chacune un « poids ». Ces neurones sont organisés en couches : chaque couche reçoit des valeurs d'entrée puis calcule et transmet de nouvelles valeurs à la couche suivante (Awaysheh *et al.*, 2019 ; Nielsen, 2015, chap. 1 ; Yoo *et al.*, 2012).

Les neurones d'un NN possèdent chacun une fonction d'activation, un terme technique décrivant comment le neurone transforme la valeur qu'il reçoit en une autre valeur. Cette fonction dépend du type d'IA à entraîner : elle peut par exemple être linéaire, sigmoïde, *etc.* La valeur reçue par chaque neurone correspond à la somme pondérée des valeurs des neurones connectés en amont, à laquelle il rajoute un nombre appelé le « biais ». Chaque neurone possède son propre biais (LeCun *et al.*, 2015 ; Nielsen, 2015, chap. 1 ; Russell et Norvig, 2020, chap. 18).

Un exemple concret de NN est présenté dans la **Figure 7**, qui reprend le thème de la **Figure 6**. Ce réseau neuronal simple possède une seule couche et détermine s'il existe un trouble biliaire en fonction de plusieurs paramètres mesurés.

Figure 7 : Réseau de neurones artificiels à une seule couche.

Utilisée avec l'autorisation de Awaysheh *et al.* (2019).



Dans cet exemple, chaque valeur mesurée X_n est multipliée par le poids w_n de sa connexion avec le neurone de sortie, à droite de la figure, puis la somme totale est calculée et le biais (non représenté sur la figure) du neurone de sortie est ajouté. Ce neurone utilise enfin sa fonction d'activation pour afficher une nouvelle valeur correspondant à la présence ou non d'un trouble (Awaysheh *et al.*, 2019). Concrètement, la formule utilisée pour calculer ici la valeur Y du neurone de sortie est $Y = f(b + \sum_{i=1}^5 X_i \times w_i)$, où b est le biais et f la fonction d'activation.

La signification de la valeur affichée par le neurone de sortie est propre à chaque IA. Le plus souvent, une dernière étape permet de normaliser la valeur entre 0 et 1. Plus la valeur est proche de 1, plus l'indication fournie par le neurone de sortie est probable (Nielsen, 2015, chap. 1).

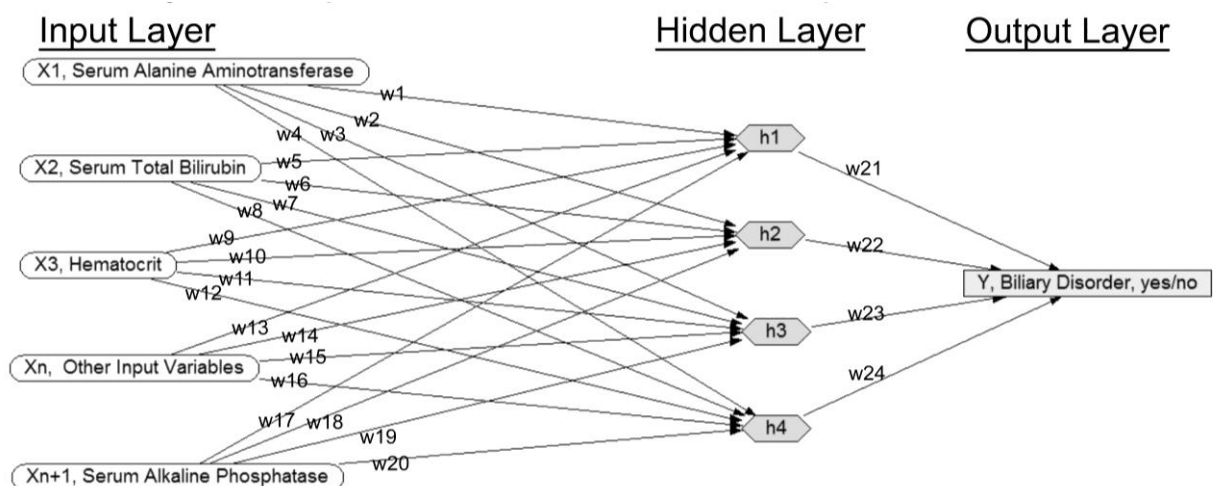
□ Le fonctionnement d'un réseau neuronal multicouches

Lorsque les données à analyser sont très complexes, un NN à une seule couche peut être insuffisant. Dans ce cas, il est possible d'ajouter des couches de neurones supplémentaires. Les couches intermédiaires entre la couche d'entrée et la couche de sortie sont dites « cachées ». Ces neurones supplémentaires fonctionnent de la même façon que précédemment : chaque neurone intermédiaire est connecté en amont à d'autres neurones, ce qui permet de réaliser une somme pondérée. Ce neurone intermédiaire retourne une nouvelle valeur qui est passée à la couche de neurones suivante, et ainsi de suite jusqu'à la dernière couche (Awaysheh *et al.*, 2019 ; LeCun *et al.*, 2015 ; Nielsen, 2015, chap. 1 ; Russell et Norvig, 2020, chap. 18).

Ce fonctionnement est illustré par la **Figure 8**, en utilisant l'exemple précédent. Un NN identifiant un trouble biliaire pourrait ainsi avoir une couche supplémentaire, dont les neurones notés h_1 à h_4 reçoivent chacun une somme pondérée des valeurs X_1 à X_n . Les valeurs de ces neurones h sont transmises au neurone de sortie, à droite, qui réalise un nouveau calcul et affiche une valeur indiquant ou non la présence d'un trouble (Awaysheh *et al.*, 2019).

Figure 8 : Réseau de neurones artificiels multicouche.

Utilisée avec l'autorisation de Awaysheh *et al.* (2019).



□ Les avantages et inconvénients d'un réseau de neurones

Le principal avantage des NN est leur capacité à traiter des données complexes et de grande taille. Ils sont utiles dans les tâches de classement et sont capables de découvrir des corrélations qui sont difficiles à détecter intuitivement (Banaee *et al.*, 2013 ; Fang *et al.*, 2016 ; Yoo *et al.*, 2012). En outre, plusieurs démonstrations mathématiques prouvent que, quel que soit le problème à modéliser, il existe toujours au moins un NN capable d'approximer correctement les solutions de ce problème. Théoriquement, l'approximation devient meilleure avec l'augmentation du nombre de neurones cachés (Nielsen, 2015, chap. 4).

Le développement et l'entraînement d'un tel NN n'est cependant pas toujours réalisable avec les technologies actuelles. L'entraînement d'un réseau neuronal viable exige une grande quantité de données, suffisamment variées afin d'éviter l'*overfitting* (Nielsen, 2015, chap. 3 ; Russell et Norvig, 2020, chap. 18). L'entraînement est long, coûteux en ressources et devient de plus en plus compliqué avec l'augmentation du nombre de couches cachées. Cela a d'ailleurs motivé le développement d'une discipline spécialisée appelée le *Deep Learning*, présentée dans la partie suivante (Nielsen, 2015, chap. 5). Par ailleurs, la structure du NN (nombre de neurones, de couches, *etc.*) est choisie empiriquement, alors qu'il s'agit d'un facteur majeur de son efficacité finale (Yoo *et al.*, 2012). Enfin, surtout lorsqu'ils sont multicouches, le fonctionnement interne des NN est opaque pour l'utilisateur et pour les scientifiques qui l'élaborent. Les paramètres sont déterminés de manière autonome par l'algorithme d'apprentissage et n'ont pas toujours de signification concrète. À l'inverse des approches de ML présentées précédemment, les experts peuvent donc difficilement s'approprier les nouvelles connaissances apportées par les NN (Fang *et al.*, 2016 ; Yoo *et al.*, 2012).

Pour mieux comprendre ce dernier inconvénient, il est nécessaire de comprendre comment se déroule l'entraînement d'un NN. L'algorithme le plus couramment utilisé, appelé *backpropagation* ou « rétropropagation du gradient », a été initialement proposé en 1986 et est présenté succinctement ci-dessous (Rumelhart *et al.*, 1986).

□ L'apprentissage d'un réseau neuronal

La structure optimale du NN est d'abord déterminée de manière empirique, en s'appuyant sur d'autres travaux de recherche ou après des essais préalables (Yoo *et al.*, 2012). Les valeurs des poids et des biais sont attribuées aléatoirement. Le plus souvent, les poids sont initialisés entre -1 et 1 et les biais sont initialisés à 0 (Nielsen, 2015, chap. 2).

La notion de « gradient » de la *backpropagation* correspond à l'utilisation d'un « algorithme de descente du gradient ». Un gradient représente l'évolution d'une fonction selon ses différents paramètres. En d'autres termes, pour une fonction multiparamétrique donnée, il faut déterminer comment sa valeur de sortie évolue selon les variations de chacun de ses paramètres pris séparément. Mathématiquement, étudier l'évolution d'une fonction selon un de ses paramètres revient à calculer une dérivée partielle (Nielsen, 2015, chap. 2 ; Russell et Norvig, 2020, chap. 18). Pour l'exemple de la **Figure 8**, le gradient pourrait correspondre à l'évolution de la valeur de sortie du neurone de droite⁹ en fonction du paramètre w_1 , du paramètre w_2 , *etc.* Concrètement, le

⁹ De manière plus exacte, l'algorithme calcule le gradient d'une *loss function*, ou « fonction objectif ». Cette fonction représente l'écart entre la valeur attendue et la valeur obtenue. Elle est utilisée car elle possède des propriétés mathématiques plus intéressantes. Le choix de la fonction dépend notamment du type d'IA à entraîner et du type de valeurs qu'elle retourne (Nielsen, 2015, chap. 2 & 3).

gradient indique donc comment l'erreur du résultat fourni par l'IA augmente ou diminue lorsque la valeur d'un poids ou d'un biais est modifiée (LeCun *et al.*, 2015).

La terme « rétro » de la rétropropagation fait référence à la façon dont les poids et biais sont mis à jour : de la dernière couche vers la première. Cet aspect est mathématique et correspond à la façon dont sont calculées les dérivées partielles (Nielsen, 2015, chap. 2).

Une fois la formule du gradient déterminée, l'apprentissage peut commencer. Un lot de mesures est fourni à l'IA et les résultats obtenus sont comparés aux résultats attendus. En fonction de l'écart observé, l'algorithme détermine comment faire varier chacun des paramètres pour que le NN soit plus performant la prochaine fois (LeCun *et al.*, 2015 ; Nielsen, 2015, chap. 2 ; Russell et Norvig, 2020, chap. 18). Au terme de nombreux petits ajustements, l'IA devient capable de fournir des résultats précis. L'apprentissage est donc entièrement automatique et l'humain n'intervient que pour étiqueter les données initiales (Awaysheh *et al.*, 2019 ; Banaee *et al.*, 2013).

c. Le Deep Learning, une approche particulière

Le *Deep Learning* (DL), ou « apprentissage profond », est une discipline de l'IA qui utilise des NN composés d'un grand nombre de couches cachées. Le DL utilise le plus souvent l'apprentissage supervisé, mais l'apprentissage non supervisé est également possible (LeCun *et al.*, 2015 ; Nielsen, 2015, chap. 6 ; Schmidhuber, 2015).


De manière générale, chaque couche d'un modèle de DL décompose les données d'entrée en un concept plus large. Par exemple, un texte peut être décomposé en syllabes, puis en mots, puis en phrase, *etc.* ; une image peut être décomposée en contours, puis en formes, *etc.* Cette décomposition est possible pour la plupart des données générées naturellement, permettant d'utiliser le DL pour de nombreux problèmes (LeCun *et al.*, 2015). Différents modèles de DL ont été développés afin de contourner les difficultés d'entraînement dues au nombre important de couches (Nielsen, 2015, chap. 6). Quelques modèles de DL fréquemment utilisés sont présentés simplement ci-dessous.

Les NN présentés jusqu'ici sont des « réseaux neuronaux à propagation avant » : les valeurs sont calculées et transmises d'avant en arrière, soit de la couche à gauche vers la couche à droite sur la **Figure 8**. Une autre approche de DL utilise des réseaux de neurones dont certaines connexions sont cycliques, comme illustré par la **Figure 9**. Un tel NN est appelé *recurrent neural network* (RNN), ou « réseau de neurones récurrents ». Les RNN sont capables de traiter des données séquentielles et de taille variable. Grâce à leur structure, les informations extraites des entrées précédentes sont « gardées en mémoire » (LeCun *et al.*, 2015 ; Schmidhuber, 2015).

Figure 9 : Exemple d'un réseau de neurones récurrents.

Utilisée avec l'autorisation de LeCun *et al.* (2015).


Le réseau de droite est une représentation du réseau de gauche lorsque la connexion récurrente est « déroulée ».



L'entraînement d'un RNN par la méthode classique de la *backpropagation* est toutefois compliquée et cette difficulté s'aggrave avec l'augmentation du nombre de couches. Les recherches montrent ainsi que ces IA peinent à apprendre comment stocker les informations passées. Une façon de contourner cette limite consiste à utiliser des « connexions résiduelles ». Une connexion résiduelle consiste à réinjecter telles quelles des données fournies en entrée à une couche, à une autre couche, plus loin dans le réseau. Les données qui transitent par cette connexion « sautent » donc plusieurs couches et ne sont pas traitées de la même façon (He *et al.*, 2016). Ce principe est illustré par la **Figure 10**, où la flèche de droite représente une connexion résiduelle passant outre deux couches.

Figure 10 : Exemple d'une connexion résiduelle (He *et al.*, 2016).

© 2016 IEEE.



Une autre approche est décrite pour la première fois en 2017 par une équipe de Google, il s'agit des *transformers*, appelés en français « transformeurs » ou « modèles auto-attentifs » (Vaswani *et al.*, 2017). Ces architectures constituent les piliers de certaines IA modernes telles que *GPT* (acronyme de *Generative Pre-trained Transformer*, ou « transformeur génératif pré-entraîné ») (OpenAI, 2023). Les transformeurs reprennent certains des concepts précédents, tout en les adaptant pour proposer un modèle de DL qui peut être utilisé de manière distribuée. Les transformeurs peuvent donc être entraînés beaucoup plus rapidement que les autres modèles. Ils constituent un point de départ pour la création des IA contemporaines (Vaswani *et al.*, 2017).

Les transformeurs peuvent être utilisés pour l'analyse d'images, mais le modèle le plus utilisé à cet effet reste actuellement le *convolutional neural network* (CNN), ou « réseau neuronal convolutif ». Les CNN reprennent l'architecture des NN multicouches habituels, mais les couches qui les composent effectuent des opérations mathématiques spécifiques. Un de ces traitements est la convolution, dont le fonctionnement global est évoqué dans la partie **I.2.b.a.** (LeCun *et al.*, 2015 ; Nielsen, 2015, chap. 6).

Le DL est une approche efficace pour généraliser les connaissances apprises lors de l'entraînement. Ces modèles peuvent gérer des quantités de données importantes et être entraînés de manière non supervisée. En fonction du modèle utilisé, les IA peuvent être entraînés en utilisant plusieurs machines en parallèle, ce qui accélère le processus. Leur entraînement nécessite toutefois des calculs intensifs et le modèle final est souvent opaque, à l'instar des NN classiques (Fang *et al.*, 2016).

2. Les intérêts et applications fondamentales des algorithmes de *Machine Learning* contemporains

La recherche scientifique autour de l'IA s'est récemment accélérée. En particulier, l'apparition de matériel plus performant et de technologies de *Big Data* plus efficaces a permis l'élaboration de nouveaux modèles de DL. Ces innovations sont surtout portées par les GAFAM et aboutissent à des modèles très généraux et accessibles au plus grand nombre.

A. La course à l'intelligence artificielle

a. Les GAFAM, acteurs majeurs du Big Data et des intelligences artificielles

Comme évoqué précédemment, le *Big Data* est difficile à traiter en interne par de petites équipes en raison de la nécessité d'une source de données importante et de capacités de stockage suffisantes. L'analyse du *Big Data* requiert également du matériel de pointe et des compétences spécialisées. Le *Big Data* et les IA ont ainsi profité des investissements des grandes entreprises du secteur informatique, les GAFAM : Google (ou sa maison-mère Alphabet), Apple, Facebook (ou sa maison-mère Meta), Amazon et Microsoft.

L'atout majeur des GAFAM est leur domaine d'activité. Leur modèle d'entreprise repose notamment sur l'enregistrement et l'exploitation des données de leurs utilisateurs, pour améliorer les services fournis ou prendre les décisions les plus rentables (Arte Distribution, 2021 ; Gleiß *et al.*, 2021). Par exemple, Alphabet développe *Android*, *Google Search* et *Google Maps* ; Apple gère l'écosystème logiciel de nombreux produits ; Meta détient *Facebook*, *Instagram* ou *WhatsApp* ; et Amazon et Microsoft offrent des services de *cloud computing* (Gleiß *et al.*, 2021).

Les GAFAM bénéficient donc déjà de matériel performant et d'experts informatiques. Leurs services sont utilisés par des millions de personnes dans le monde et ont permis le développement de technologies spécialisées. Il est ainsi très difficile de traiter le *Big Data* sans utiliser les capacités des GAFAM (Arte Distribution, 2021 ; Gleiß *et al.*, 2021). Cette réalité est à l'origine du rôle majeur des GAFAM dans la *MedTech*, l'industrie des données médicales et des technologies développées pour leur analyse.

b. Les tendances actuelles du développement des intelligences artificielles

- *Dans le secteur médical*

Dans le domaine médical, Alphabet est la première entreprise à avoir offert ses services, avec la commercialisation de *Google Health*, un logiciel de gestion de dossiers médicaux électroniques, entre 2008 et 2013. Des partenariats avec le NHS au Royaume-Uni ou la Clinique Mayo aux États-Unis ont également permis le développement d'IA médicales (Arte Distribution, 2021 ; Ozalp *et al.*, 2021). D'autres applications voient également le jour après 2013. Une filiale d'Alphabet, Verily, propose par exemple un processus simplifié de recrutement pour des études scientifiques en sélectionnant les meilleurs patients possibles selon leur profil (Verily, 2023).

Apple intervient dans le secteur de la santé dès 2014. Son implication reste toutefois limitée au lancement de fonctionnalités liées à certains produits, d'abord l'iPhone, puis l'Apple Watch à partir de 2015. La collecte massive de données de santé est l'atout majeur d'Apple. Le développement de solutions logicielles comme le *ResearchKit* permet par exemple aux développeurs et chercheurs d'utiliser les données récoltées (Gleiß *et al.*, 2021 ; Ozalp *et al.*, 2021).

Parmi les GAFAM, Facebook est l'entreprise la moins investie dans le secteur médical, avec un seul service majeur à ce jour, le programme *Preventive Health*, qui permet par exemple d'utiliser des IA pour détecter précocement des troubles suicidaires ou mentaux. Comme Apple, l'atout majeur de Facebook réside dans ses capacités de collecte de données (Ozalp *et al.*, 2021).

À l'inverse, Amazon est l'entreprise proposant les services les plus diversifiés et uniques parmi les GAFAM. En 2018, elle a par exemple acquis Pillpack, une société de vente en ligne de médicaments sur prescription, et proposait également une mutuelle en ligne jusque fin 2022. Le développement de son offre de *cloud computing* permet aussi à Amazon de passer des partenariats avec des agences gouvernementales ou des startups dans le domaine de l'IA (Arte Distribution, 2021 ; Bindal, 2022 ; Gleiß *et al.*, 2021 ; Ozalp *et al.*, 2021).


Enfin, les produits de Microsoft se concentrent principalement sur des services aux entreprises. Sa suite de productivité et son offre de *cloud computing* lui permettent de conclure de nombreux partenariats avec des hôpitaux ou des agences gouvernementales (Ozalp *et al.*, 2021).

- *Dans le domaine des intelligences artificielles génératives*

L'amélioration des technologies de DL permet aussi l'émergence d'IA génératives plus performantes, qui peuvent désormais répondre à des requêtes formulées en langage naturel. Les IA deviennent plus accessibles, ce qui démarre une « course à l'IA ». Les GAFAM sont à l'origine de ce développement, car elles disposent de la puissance nécessaire pour entraîner les IA. Cette puissance ne cesse d'ailleurs d'augmenter, comme l'illustre la **Figure 11**.

Figure 11 : Évolution de la puissance de calcul, en FLOPS¹⁰, nécessaire à l'entraînement des IA sur la période 1952 - 2022 (Sevilla *et al.*, 2022).

© 2022 IEEE.



¹⁰ Un FLOPS (en anglais, *floating-point operations per second*) représente le nombre d'opérations en virgule flottante effectuées en une seconde. Un nombre en virgule flottante s'écrit sous la forme $\pm a \times 10^b$: il s'agit d'une notation scientifique adaptée à la façon dont les ordinateurs stockent les nombres réels.

Cette demande accrue rend le domaine de l'IA difficile d'accès pour les équipes de recherches et pour les entreprises plus modestes (Sevilla *et al.*, 2022). Elle soulève également des enjeux liés à la protection de l'environnement. Des entreprises chinoises, comme Baidu, des organisations à but non lucratif ou des startups, comme Anthropic, commencent toutefois à investir dans le domaine de l'IA (The Economist, 2023).

En 2019, Microsoft investit un milliard de dollars dans OpenAI, sous forme de fonds ou de matériel (Microsoft, 2019). Cela accélère la sortie des modèles GPT-2 puis GPT-3, qui sont initialement privés : OpenAI souhaite prévenir les usages détournés de ses technologies. Google et Meta suivent la même approche avec leurs modèles respectifs (Chow *et al.*, 2023).

En 2022, la startup Stability AI publie toutefois Stable Diffusion, la première AI génératrice d'image accessible au grand public. OpenAI donne alors accès à DALL-E puis à ChatGPT quelques mois plus tard. Les AI développées par les autres GAFAM sont à leur tour dévoilées au grand public (Chow *et al.*, 2023). Ainsi, Google annonce la sortie de Bard et son partenariat avec Anthropic, Meta annonce son IA LLaMA, Amazon devient le partenaire de Stability AI et Microsoft investit de nouveau près de dix milliards de dollars dans OpenAI (Bindal, 2022 ; Google, 2023 ; Microsoft, 2023 ; Pichai, 2023 ; Touvron *et al.*, 2023a).

B. Les capacités générales du *Machine Learning* grand public

Les IA modernes grand public utilisent des modèles complexes de DL. Les compétences des IA vétérinaires présentées dans la partie II sont issues des capacités de ces IA générales. En particulier, l'analyse visuelle ou textuelle et la génération de données sont détaillées ci-dessous.

a. L'analyse visuelle : traitement d'images ou vidéos

- *Les contraintes associées à l'analyse d'une image*

Les IA à la pointe de l'analyse d'images sont des CNN, une architecture présentée dans la partie I.1.c.c.. Cette architecture présente un avantage majeur : les CNN sont capables de reconnaître des motifs dans une image, même s'ils sont placés ou orientés différemment que lors de leur entraînement (LeCun *et al.*, 2015 ; Nielsen, 2015, chap. 6).

De plus, la structure des CNN permet l'analyse d'images de grande taille. Une image est généralement représentée sous la forme de trois matrices 2D (c'est-à-dire sous la forme de tableaux), contenant respectivement la valeur des pixels rouges, des pixels verts et des pixels bleus (LeCun *et al.*, 2015). Pour qu'un NN usuel enregistre l'intégralité des données d'une image haute définition, il devrait donc posséder plus de six millions de neurones d'entrée ($3 \times 1\,080 \times 1\,920$ pixels) et encore davantage de connexions, ce qui est techniquement impossible.


Enfin, en étant représentées par trois matrices à deux dimensions, les images sont des ensembles de données de dimension élevée. Une étude statistique est donc difficilement réalisable : l'IA doit impérativement diminuer la dimension des images pour pouvoir les analyser. L'architecture des CNN a également été conçue dans cet objectif (Altman et Krzywinski, 2018 ; Nielsen, 2015, chap. 6).

- *Le fonctionnement global d'un réseau neuronal convolutif*

Les capacités d'un CNN reposent sur trois concepts-clés : les neurones de champs réceptifs (NCR), les neurones de mise en commun (*pooling neurons*) et le fait que les poids des neurones de champs réceptifs soient communs au sein d'une même couche (Nielsen, 2015, chap. 6). La structure d'un CNN est présentée dans la **Figure 12**.

Figure 12 : Fonctionnement d'un réseau neuronal convolutif.

Utilisé avec l'autorisation de LeCun *et al.* (2015).



La première étape de l'analyse est la décomposition de l'image en rouge, vert et bleu. La première couche cachée, celle des NCR, est ensuite utilisée. Un NCR est un neurone connecté aux pixels d'une petite portion de l'image d'entrée. Par exemple, dans la **Figure 13**, le premier NCR est connecté à une portion de 5x5 pixels d'une image d'entrée de 28x28 pixels. Les poids des 25 connexions sont identiques pour tous les NCR de cette couche et forment un ensemble appelé un « filtre ». Le deuxième NCR est connecté à une autre portion de 5x5 pixels et ainsi de suite. Le résultat obtenu après avoir scanné l'ensemble de l'image est un tableau de 24x24 neurones, appelé une *feature map*. La *feature map* peut être représentée sous la forme d'une image et représente une des caractéristiques (*feature*) de l'image (Nielsen, 2015, chap. 6). Sur la **Figure 12**, les *features* extraites de l'image d'origine sont situées sur la 2^{ème} ligne en partant du bas.

Concrètement, à partir d'une grande image, l'IA crée donc une autre image plus petite qui décrit une caractéristique de l'image d'origine : par exemple, si elle contient des traits verticaux. En répétant cette étape avec d'autres filtres (c'est-à-dire, en répétant cette étape, mais avec 25 poids différents), la première couche de NN peut théoriquement décrire toutes les caractéristiques de l'image : présence de traits verticaux, de traits horizontaux, de cercles, *etc.*

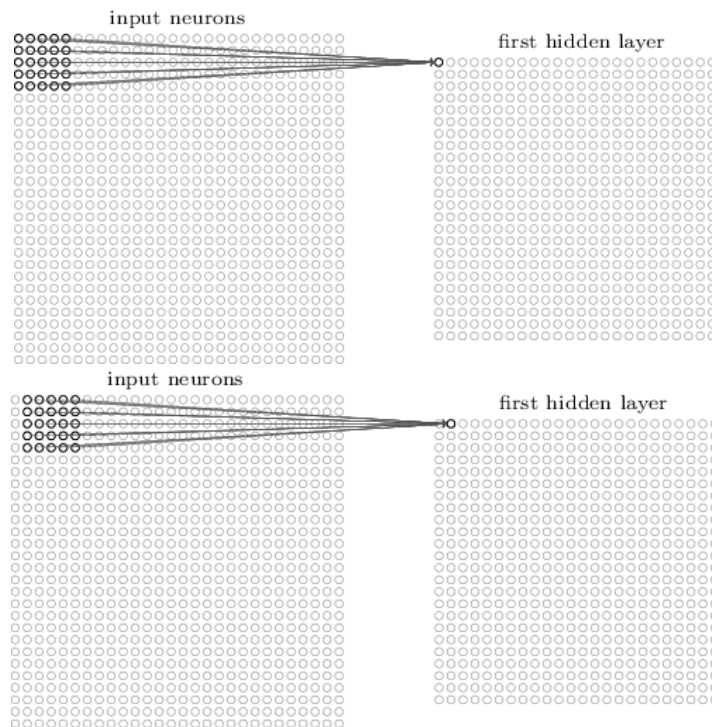
Cette étape donne son nom au CNN : l'opération mathématique réalisée par le NCR lorsqu'il applique le filtre à une partie de l'image est appelée une convolution¹¹. La mention *ReLU* dans la **Figure 12** fait référence à la fonction d'activation utilisée, appelée *Rectified Linear Unit*¹², qui fonctionne mieux pour les CNN (LeCun *et al.*, 2015).

¹¹ La convolution est définie mathématiquement par la formule $(f * g)(x) = \int_{-\infty}^{+\infty} f(x-t)g(t)dt$ où f et g sont deux fonctions réelles ou complexes (Russell et Norvig, 2020, chap. 24).

¹² Cette fonction est définie par la formule $f(x) = \max(0, x)$ (LeCun *et al.*, 2015).

Figure 13 : Fonctionnement des neurones à champs réceptifs.


Licence [CC BY-NC](https://creativecommons.org/licenses/by-nc/4.0/) (Nielsen, 2015).



L'étape suivante consiste à condenser l'information contenue dans les *features map*. Le fonctionnement le plus courant, appelé le *max pooling*, est illustré concrètement par la **Figure 14**. Dans cet exemple, chaque neurone de mise en commun enregistre la valeur maximale parmi quatre NCR de la couche précédente. Cette étape est répétée pour chacune des *features* extraites et l'IA obtient alors des tableaux de 12x12 neurones (Nielsen, 2015, chap. 6). Ces neurones peuvent aussi être représentés sous la forme d'une image. Sur la **Figure 12**, ces images sont sur la 3^{ème} ligne en partant du bas.

Figure 14 : Fonctionnement des neurones de mise en commun.

Licence [CC BY-NC](https://creativecommons.org/licenses/by-nc/4.0/) (Nielsen, 2015).



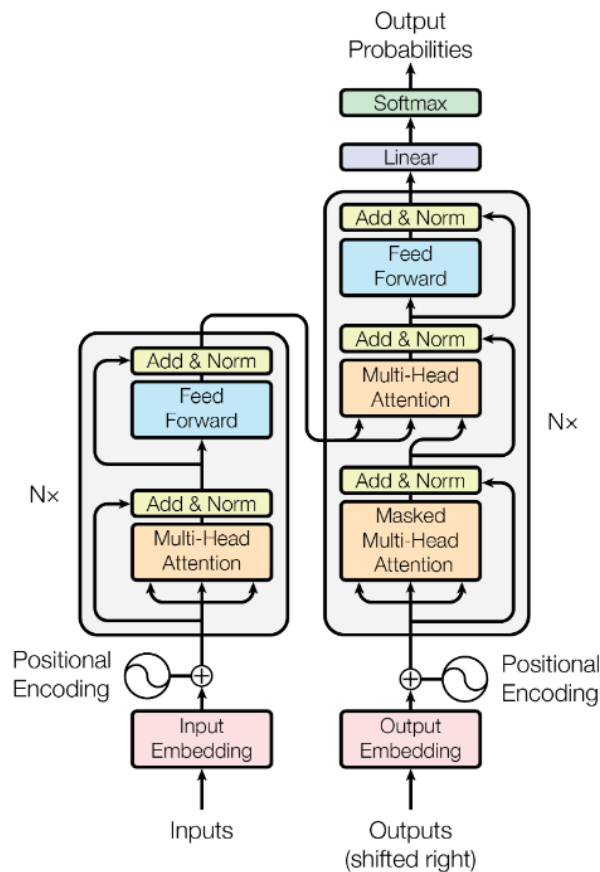
Ces étapes sont répétées plusieurs fois, en général jusqu'à quelques dizaines de fois pour les IA modernes (LeCun *et al.*, 2015 ; Nielsen, 2015, chap. 6). Enfin, une couche de neurones classiques est connectée. Elle contient les neurones de sortie qui indiquent avec quelle probabilité l'IA a reconnu les éléments de l'image. En pratique, cette couche contient autant de neurones que d'éléments qu'est capable de reconnaître l'IA. Par exemple, si l'IA peut reconnaître les chiffres de 0 à 9, alors il y aura dix neurones de sortie (Nielsen, 2015, chap. 6).

Ce principe de reconnaissance d'éléments est généralisable à de nombreux problèmes : détection d'objets, de visages, de lésions tissulaires, etc. Cette architecture peut aussi être combinée à d'autres technologies. Par exemple, en ajoutant un modèle d'analyse de texte, il est possible de créer une IA capable de décrire des images (Radford *et al.*, 2021).

b. L'analyse du langage naturel : interprétation du langage parlé ou écrit

Le langage naturel est la façon normale dont les humains parlent ou écrivent. Historiquement, les IA utilisaient des modèles uniquement probabilistes, mais les IA modernes utilisent des modèles particuliers de DL, appelés transformeurs, une architecture introduite dans la partie I.1.c.c. (OpenAI, 2023 ; Radford *et al.*, 2023 ; Vaswani *et al.*, 2017). Les transformeurs utilisés par ces IA sont des architectures complexes. Seul leur fonctionnement global, nécessaire pour comprendre leurs limites, sera présenté. Leur structure est illustrée sur la **Figure 15**.

Figure 15 : Structure générale d'un transformeur (Vaswani *et al.*, 2017).
© 2017 Google.



Les IA analysant le texte de cette manière sont appelées des *large language models* (LLM), ou « grands modèles de langage », car le volume des données d'entraînement est très important. GPT-3 a par exemple utilisé plus de 410 milliards de *tokens*. Les LLM subissent généralement un apprentissage semi-supervisé (Brown *et al.*, 2020). Les jeux de données d'entraînement d'une IA de reconnaissance de la parole sont également importants, mais l'entraînement est plutôt un apprentissage supervisé. Par exemple, l'IA Whisper de l'entreprise OpenAI a été entraînée sur plus de 680 000 heures d'enregistrements (Radford *et al.*, 2023).

Les données d'entrée, sous la forme d'un texte, sont tout d'abord décomposées en éléments simples, appelés des *tokens*. Concrètement, un *token* est un mot ou un symbole (un signe de ponctuation par exemple). Chaque *token* est alors fourni un par un au transformeur : ce sont les *inputs* représentés en bas à gauche de la **Figure 15** (Vaswani *et al.*, 2017).

Toutefois, un NN ne peut utiliser que des nombres comme donnée d'entrée. L'étape d'*input embedding*, aussi appelée *word embedding* ou « prolongement lexical » en français, permet de représenter le sens de chaque mot sous la forme d'un ensemble de nombres. Ces nombres sont choisis par un autre NN simple. Pour une langue donnée, ces nombres sont toujours identiques et plus deux mots ont un sens proche, plus ils auront des nombres similaires. Enfin, l'étape de *positional encoding*, ou « encodage positionnel », attribue d'autres nombres au *token* selon sa position dans le texte (Vaswani *et al.*, 2017).

Le concept d'*attention*, illustré sur la **Figure 15** par les mentions *Multi-Head Attention* est une autre force des transformeurs. Concrètement, un autre NN attribue un ensemble de nombres au *token* fourni. Ces nombres représentent la relation du *token* avec les autres *tokens* du texte. Plusieurs NN peuvent être utilisés en parallèle pour attribuer plusieurs ensembles de nombres à chaque mot, afin de mieux représenter les différentes relations possibles (Vaswani *et al.*, 2017).

L'ensemble de ces étapes mises bout à bout forment une structure appelée un *encodeur*, à gauche sur la **Figure 15**. Chaque NN qui la compose possède des poids et des biais qui peuvent être ajustés après un apprentissage. À ce stade, l'état interne de l'encodeur, c'est-à-dire la valeur de tous les neurones, est une représentation du sens global du texte fourni (Vaswani *et al.*, 2017).

Les encodeurs utilisés lors de l'analyse d'une onde sonore sont légèrement différents, mais fonctionnent de manière similaire (Radford *et al.*, 2023).

c. La génération de données, le point fort des intelligences artificielles modernes

- *Le principe de la génération de données*

Pour générer de nouvelles données, l'encodeur est connecté à une autre structure similaire (un « décodeur », à droite sur la **Figure 15**), qui a des poids et biais différents. Le décodeur est connecté à un dernier NN simple (identifié par les mentions *linear* et *softmax*, en haut à droite la figure) qui fournit le *token* le plus probable qui va suivre le texte que l'IA a analysé jusque-là (Jia, 2019 ; Vaswani *et al.*, 2017).

En résumé, une IA génératrice est généralement composée de deux parties. La première, l'encodeur, décompose mot à mot le texte fourni analysant chaque mot et son contexte pour déterminer le sens global du texte. La seconde partie, le décodeur, récupère les données fournies par l'encodeur et détermine quel est le mot idéal pour continuer le texte. En entraînant correctement un décodeur puis en le connectant à un encodeur, il est donc possible d'obtenir des IA capables de créer de nouvelles données.

Par exemple, si le décodeur a été entraîné avec des textes dans une autre langue, alors l'IA qui l'utilise peut traduire un texte d'une langue à une autre. L'IA analyse d'abord le texte initial pour en extraire le sens général. Puis, mot après mot, l'IA crée la phrase la plus probable pour retranscrire la signification de la phrase d'origine (Jia, 2019).

Un autre exemple est ChatGPT, un *chatbot* qui utilise GPT pour répondre à l'utilisateur. GPT utilise une structure particulière composée uniquement d'un décodeur, mais le principe global

reste identique. Lorsque l'utilisateur envoie une requête à ChatGPT, sa signification est d'abord extraite, puis ChatGPT renvoie un à un les mots les plus probables pour compléter le texte initial (Brown *et al.*, 2020 ; OpenAI, 2023).

La génération d'image est un processus plus complexe, mais qui utilise les mêmes principes. Un exemple est DALL-E, une IA développée par OpenAI, capable de générer une image à partir d'un texte. DALL-E utilise d'abord un encodeur de texte sur le texte fourni par l'utilisateur. L'encodage textuel obtenu est ensuite transformé en un encodage d'image grâce à un NN spécialisé. Enfin, un décodeur d'image crée une nouvelle image pouvant correspondre à cet encodage d'image (Ramesh *et al.*, 2021).

- *Un entraînement particulier*

Lors de leur entraînement, les *chatbots* subissent également une étape appelée *fine-tuning* ou « ajustement fin ». Cette dernière étape est une forme d'apprentissage par renforcement : des humains interagissent directement avec l'IA en indiquant si le résultat fourni est correct ou non. Par exemple, dans le cas de *ChatGPT*, le *fine-tuning* a pour objectif d'éviter la génération de propos inappropriés ou illégaux (OpenAI, 2023).

3. L'intelligence artificielle, un domaine encore peu réglementé et avec ses propres limites

A. La réglementation face à l'essor des intelligences artificielles

a. La réglementation actuelle des intelligences artificielles

L'IA a connu une accélération massive de son développement ces dernières années. Cette expansion n'est pas sans danger, car la recherche et la législation concernant la sécurité des IA n'est pas toujours adaptée (Chow *et al.*, 2023).

Aux États-Unis, la *Food and Drug Administration*¹³ (FDA) est l'autorité régulant les logiciels médicaux utilisant des IA. En 2016, la FDA a exempté certains appareils (tels que les montres connectées) de la mention « dispositif médical », afin de faciliter leur commercialisation. Jusqu'en 2021, la FDA ne proposait toutefois pas de processus d'évaluation séparé pour les autres logiciels utilisant des IA : l'agence évaluait le rapport bénéfice-risque pour l'usage prévu, à travers un processus parfois long et compliqué (Harvey et Gowda, 2020). La régulation de ces logiciels était également compliquée par le fonctionnement opaque des modèles de DL : en l'absence d'informations claires, les experts peuvent difficilement étudier et vérifier le bon fonctionnement d'une IA (Harvey et Gowda, 2020 ; Yoo *et al.*, 2012).

Les données de santé américaines, y compris celles traitées par les IA, sont également couvertes par le *Health Insurance Portability and Accountability Act*. Ce règlement impose des mesures spécifiques pour la protection des données médicales (Pesapane *et al.*, 2018).

¹³ La *Food and Drug Administration* est l'agence fédérale américaine chargée de la sûreté des aliments et médicaments. La publication des réglementations concernant les dispositifs de santé est également de son ressort. Cette administration s'apparente à l'ANSES en France.

Dans l'Union Européenne (UE), l'IA est régulée par plusieurs textes. Les logiciels médicaux comprenant une IA étaient initialement évalués comme des dispositifs médicaux. En 2020 puis en 2022, les réglementations européennes nommées *Medical Devices Regulation* et *In Vitro Diagnostic Medical Device Regulation* sont officiellement appliquées afin de faciliter la régulation des IA et d'améliorer leur cadre légal (Pesapane *et al.*, 2018).

Les IA médicales sont également concernées par le RGPD (Règlement Général sur la Protection des Données). Celui-ci détaille les mesures de protection des « données à caractère personnel », ce qui englobe donc les données médicales. Ce règlement a été débattu entre 2012 et 2016, avant d'être appliqué dans les États membres en 2018 (Meszaros *et al.*, 2022 ; Pesapane *et al.*, 2018 ; Union Européenne, 2016).

De manière générale, le RGPD limite le recueil des données de santé et interdit tout traitement automatisé les concernant, à l'exception de certains cas spécifiques. Lorsque la collecte de données médicales est nécessaire, le RGPD requiert par ailleurs le consentement des patients. Ce point représente une limite légale importante, la collecte de large jeux de données s'en retrouvant largement compliquée (Meszaros *et al.*, 2022).

b. Les limites des réglementations et usages actuels

Les réglementations actuelles font aussi face à des problèmes pratiques et éthiques. Le fonctionnement opaque des NN se heurte par exemple au respect de l'article 15 du RGPD, qui statue que les patients ont le droit d'être informés sur la façon dont sont prises les décisions les concernant (Meszaros *et al.*, 2022 ; van der Velden *et al.*, 2022).

Les recherches dans le domaine du *Big Data* et de l'IA peuvent également être amenées à traiter d'anciennes données avec des objectifs scientifiques qui n'étaient pas prévus initialement. Bien que l'article 9 du RGPD prévoit certaines exceptions, la recherche scientifique fait donc face à des contraintes importantes (Meszaros *et al.*, 2022).

Enfin, Currie et Hawk (2021) prennent l'exemple d'un algorithme utilisant un CNN entraîné pour détecter des épanchements pleuraux sur des radiographies. Le but, dans le cadre de la réglementation actuelle, est de signaler ces cas comme nécessitant un traitement prioritaire. Mais il est possible que les publications et la promotion de l'IA mettent en avant ses capacités surpassant celles d'un humain, alors qu'elle n'est pas prévue ni régulée dans cet optique.

c. De nouvelles réglementations pour un usage des intelligences artificielles sûr et innovant

La FDA travaille sur une nouvelle approche de 2019 à 2021. Elle vise à alléger les contraintes imposées aux développeurs, tout en assurant les devoirs de surveillance et de régulation qui incombent à la FDA (Harvey et Gowda, 2020). Cette nouvelle méthode classe les IA en quatre niveaux de risque, avec le niveau IV étant le plus haut. La catégorisation s'effectue en fonction des capacités du modèle et des situations auxquelles il peut être appliqué (Currie et Hawk, 2021).

L'UE cherche également à améliorer la réglementation entourant l'usage de l'IA. En 2021, la Commission Européenne propose un règlement européen nommé en anglais l'*AI Act* (Commission Européenne, 2021). Ce règlement fonctionne en définissant des niveaux de risques selon le domaine d'application et les capacités de l'IA et interdit désormais l'application de l'IA dans les domaines jugés sensibles. Comme pour le RGPD, il est probable que l'*AI Act* soit encore

débatu au Parlement Européen et ne soit pas mis en application avant plusieurs années (Meszaros *et al.*, 2022). Un communiqué de presse du Conseil de l'UE présente un premier accord provisoire le 9 décembre 2023 (Conseil de l'UE, 2023).

Il n'existe pas de réglementation spécifique concernant l'usage de l'IA en médecine vétérinaire (Appleby et Basran, 2022 ; Cohen et Gordon, 2022). L'application directe des règlements cités plus haut est par ailleurs difficilement envisageable. Les IA présentées dans la partie II permettent d'établir un diagnostic et seraient donc classées dans une catégorie de risque « moyenne ». Selon certains auteurs, il est même probable que la plupart des algorithmes soient des IA à « haut risque », car les vétérinaires peuvent pratiquer des euthanasies (Cohen et Gordon, 2022).

Un cadre légal plus clair est donc nécessaire en médecine vétérinaire et les législations actuelles et futures doivent être adaptées. Si leur absence peut faciliter le déploiement de l'IA, il n'est pas exclu que la profession doive faire face à d'importantes problématiques à l'avenir. Les limites de l'IA devraient donc être considérées dès à présent.

B. Des limites connues et encore à découvrir

a. Les considérations éthiques intrinsèques au développement d'un modèle de Machine Learning

- *Des données à l'acquisition et au traitement controversés*

La transparence autour de l'acquisition des données du *Big Data* est un premier écueil. Comme évoqué précédemment, la législation européenne impose le recueil du consentement des propriétaires des données avant qu'elles ne soient traitées. En médecine vétérinaire, ce recueil n'est pas toujours explicitement détaillé (Cohen et Gordon, 2022).

Par ailleurs, les données récoltées sont sensibles, car ce sont des données médicales. La commercialisation d'une IA soulève donc des questions de confidentialité et de sécurité. Une grande quantité de données est utilisée lors de l'entraînement et ces données sont ensuite exportées lorsque l'IA est commercialisée ou publiée (Currie et Hawk, 2021). Les données d'entraînement, même si elles ne sont pas facilement accessibles, sont toujours présentes dans le modèle : une attaque sophistiquée peut permettre de les obtenir (Nasr *et al.*, 2023). Malgré des idées reçues, la sécurité des données concerne également la médecine vétérinaire. La collecte de données concernant des animaux de compagnie pourrait révéler des informations sensibles sur leurs propriétaires (Coghlan et Quinn, 2023). Même s'il est probable qu'une fuite de données ait des conséquences moins dramatiques pour un animal, les vétérinaires doivent tout de même respecter le code de déontologie et le secret médical de leurs patients (Cohen et Gordon, 2022). Les méthodes de sécurité actuelles font appel à un contrôle strict de l'accès et au chiffrement des données, mais il est également important d'établir des mesures de mitigation en cas d'intrusion (Wang et Alexander, 2020).

En médecine vétérinaire, l'utilisation de l'IA fait également face au défi de la propriété des données. Dans une même base de données, les données peuvent appartenir à différents acteurs voire être sans propriétaire clairement établi (Ezanno *et al.*, 2021). Les auteurs prennent comme exemple les données collectées sur des animaux de production, qui pourraient appartenir au

propriétaire des animaux, à l'organisme qui a collecté les données (le contrôle laitier par exemple) ou même à un regroupement d'éleveurs.

Le processus d'entraînement des IA et la classification des données peut également être problématique. Les IA grand public sont régulièrement critiquées, car leur *fine-tuning* (voir p. 38) repose parfois sur une main-d'œuvre humaine aux conditions de travail controversées, comme cela a pu être le cas pour ChatGPT ou Bard (Davey, 2023 ; Perrigo, 2023). Si les IA vétérinaires ne sont pas directement élaborées de cette manière, il reste envisageable que les technologies dont elles sont issues le soient.

Enfin, la valeur attribuée aux données constitue une dernière limite. Les entreprises utilisent des données publiques ou privées pour développer des IA rentables, sans toutefois rémunérer les auteurs de ces données (Cohen et Gordon, 2022). Actuellement, plusieurs entreprises développant des IA font face à des procès suite à des accusations portées par des collectifs d'artistes ou d'autres entreprises (Chow *et al.*, 2023). En médecine, le consentement d'un patient ne devrait donc être valide que dans le cas où celui-ci a été correctement informé de la valeur monétaire de ses données (Cohen et Gordon, 2022).

- *Des intelligences artificielles à l'origine d'erreurs convaincantes*

Les IA modernes souffrent pour la plupart d'un phénomène appelé « hallucinations » (Chow *et al.*, 2023). Ce terme désigne du contenu factuellement faux ou des contenus aberrants par rapport au contexte (OpenAI, 2023). Cette particularité peut être particulièrement dangereuse dans certains cas, comme celui des IA génératives, car les propos tenus sont particulièrement convaincants. Les avancées dans le domaine de l'IA permettent de limiter ce phénomène, mais son éradication complète semble compliquée (OpenAI, 2023).

Le risque d'erreur est souvent majoré lors d'entraînement non supervisé, car la véracité des données d'entrée n'est plus vérifiable (Currie et Hawk, 2021). Les erreurs commises par les IA sont ainsi inévitables et la responsabilité du praticien est donc de pouvoir comprendre le risque d'erreurs, pour pouvoir les reconnaître et y réagir le cas échéant (Currie et Hawk, 2021). Le défi de la responsabilité des praticiens lors de l'usage d'une IA est détaillé dans la partie **II.3.**

Différentes applications auront cependant différentes tolérances à l'erreur (Goecks *et al.*, 2020). L'utilisation actuelle des IA est prévue pour améliorer et aider des spécialistes. En ce sens, l'IA ne doit pas être tenue à la pratique d'une médecine « de base », mais bien à l'exercice d'une médecine suivant les meilleures pratiques, comme celle exercée par des spécialistes (Cohen et Gordon, 2022). Pouvoir quantifier la précision des résultats et la confiance avec laquelle l'IA répond est donc essentiel. De nouvelles approches, comme l'IA explicable, sont présentées par la suite et tentent de contrer ce problème de confiance entre le praticien et l'IA.

- *L'évaluation difficile des intelligences artificielles*

Les apports des IA actuelles sont souvent difficilement objectivables. D'une part, une majorité d'études techniques relatives au ML sont publiées sous forme de *pre-print*, donc sans relecture par des pairs (Kelly *et al.*, 2019). D'autre part, dans un contexte médical, les études comparant les IA aux praticiens sont parfois peu rigoureuses, sans essai clinique associé ou conduites d'une manière qui ne peut pas être répliquée (Briganti et Le Moine, 2020 ; Kelly *et al.*, 2019). En particulier, peu d'études comparent les IA et les praticiens en leur soumettant les mêmes données de test (Briganti et Le Moine, 2020).

Les articles rapportant des bénéfices à l'utilisation pratique des IA doivent également être analysés avec un certain recul, car ils souffrent parfois de biais de sélection et d'échantillons trop restreints (Briganti et Le Moine, 2020). Même si l'IA peut être plus performante sur certains points, ceux-ci ne correspondent pas toujours à des éléments applicables en situation réelle (Kelly *et al.*, 2019). Face à ces limites, des lignes de conduite ont été élaborées, notamment dans le domaine de l'imagerie médicale (vétérinaire ou non) (Joslyn et Alexander, 2022).

La comparaison de plusieurs IA entre elles n'est également pas facilement réalisable, car il n'existe pas de données de test standardisées (Kelly *et al.*, 2019). De plus, comme expliqué dans la partie suivante, la présence ou non de biais dans les données d'entraînement peut influencer le comportement de l'IA selon la population de patients à laquelle elle est appliquée.

Finalement, la meilleure évaluation pourrait ne pas se limiter à une comparaison directe entre l'IA et un praticien, mais plutôt à étudier leurs interactions. Ainsi, la combinaison d'une intelligence humaine et d'une intelligence artificielle est souvent supérieure à chacune prise séparément (Briganti et Le Moine, 2020).

b. Les intelligences artificielles : des exploits techniques aux retombées non négligeables

- *Le Big Data, socle fragile des intelligences artificielles*

Le traitement du *Big Data* est à la fois une prouesse technique de l'IA et une de ses limites. La préparation des données d'entraînement constitue souvent la plus grande difficulté, car la qualité des données a une grande influence sur la qualité de l'analyse (Goecks *et al.*, 2020). Un *Big Data* de mauvaise qualité risque de mener à une IA inadéquate, réalisant des inférences causales incorrectes ou des analyses trop optimistes (Piovani et Bonovas, 2022).

Ce point est d'autant plus important que le *Big Data* utilisé n'est parfois pas créé dans un but académique. En particulier, les données générées de manière « passive » et les dossiers électroniques peuvent être incomplets ou imprécis, formant un ensemble difficile à agréger et à analyser (Cheng *et al.*, 2020 ; Piovani et Bonovas, 2022).

La diversité des espèces soignées et des acteurs impliqués en médecine vétérinaire entraîne également une hétérogénéité importante des données collectées. Il est ainsi indispensable de développer des méthodes spécifiques et des standards pour assurer l'interopérabilité des données (Ezanno *et al.*, 2021). Même au sein d'une unique espèce, des erreurs de classification des données peuvent encore exister. Appleby et Basran (2022) prennent l'exemple des diagnostics établis à partir d'une radiographie, qui peuvent différer selon les praticiens et leur sensibilité.

- L'overfitting

Un des obstacles rencontrés lors de la création d'une IA est l'*overfitting*. Cette notion peut être définie comme l'incapacité d'une IA à s'adapter à des cas inédits (Awaysheh *et al.*, 2019). Autrement dit, l'IA a (involontairement) été entraînée et optimisée pour l'analyse des données d'entraînement : elle est précise et juste pour ces données, mais renvoie parfois des résultats incorrects dans les autres cas (Kottler, 2020).

L'*overfitting* peut aussi se manifester par des attentes particulières de l'IA. Par exemple, une IA pourrait n'être capable de traiter efficacement que des radiographies de bonne qualité et

réalisées avec un positionnement parfait, ce qui n'est pas toujours le cas en pratique vétérinaire (Appleby et Basran, 2022 ; Kottler, 2020). Un test standardisé des performances d'une IA et une totale transparence des résultats obtenus sont donc importants pour faire confiance aux IA (Cohen et Gordon, 2022)

L'*overfitting* est un phénomène lié à une trop grande dimensionalité des données d'entraînement. Plus le nombre de variables étudiées augmente, plus les données ont tendance à être éparses et donc plus les corrélations entre les variables sont imprécises (Altman et Krzywinski, 2018). Certaines données sont plus sensibles à l'*overfitting*, c'est par exemple le cas de celles issues des sciences omiques, qui mesurent un nombre important de variables sur un nombre restreint d'individus (McCue et McCoy, 2017).

La collecte de données dans le domaine de l'IA est donc différente de celle de la démarche scientifique classique, où l'abondance de données est souvent préférable. Limiter les données d'entraînement permet ici de détecter correctement des relations (Altman et Krzywinski, 2018). Le choix des méthodes de pré-traitement et d'extraction des données (voir la partie **I.1.b.a.**, p. 18) a également un effet sur la qualité finale du modèle (Awaysheh *et al.*, 2019 ; Crone *et al.*, 2006). En particulier, les algorithmes de ML sont particulièrement sensibles au choix des caractéristiques retenues lors de l'étape d'extraction/sélection du *Big Data* (Awaysheh *et al.*, 2019). Wang *et al.* (2010) ont par exemple montré que certains modèles de ML fonctionnent à l'identique voire plus efficacement après la suppression de 96 % des caractéristiques des données initiales.

Des algorithmes spéciaux de statistiques et de ML existent pour mitiger ce phénomène et peuvent être utilisés en combinaison pour de meilleurs résultats (Awaysheh *et al.*, 2019). Ces approches ne sont toutefois pas infaillibles et une expertise scientifique reste nécessaire lors de l'élaboration et de l'utilisation d'une IA (Altman et Krzywinski, 2018).

□ Les conséquences de données d'entraînement déséquilibrées

Les données d'entraînement, qu'elles soient issues du *Big Data* ou d'une étude individuelle, peuvent parfois présenter un déséquilibre. Selon le sujet étudié, il est ainsi possible que certaines catégories de données soient sur-représentées, un phénomène appelé déséquilibre des classes ou *class imbalance*. Deux catégories de déséquilibre existent (He et Ma, 2013, chap. 1 & 2).

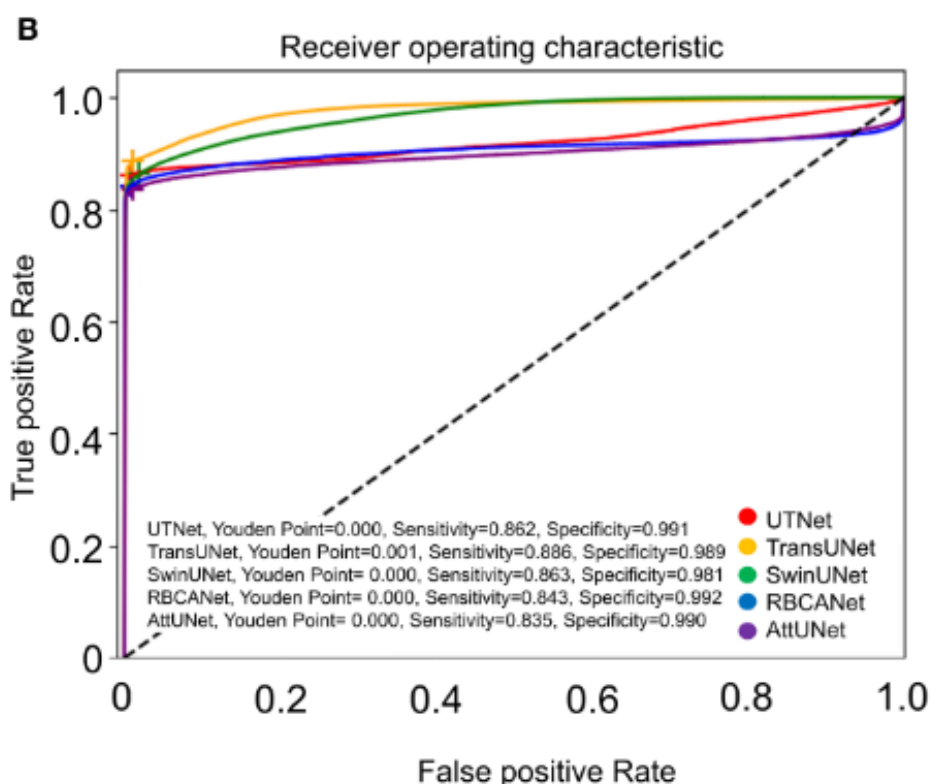
Le premier déséquilibre est absolu, par exemple lorsqu'il y a beaucoup plus de données disponibles pour les animaux sains que pour les animaux malades. Ce type de déséquilibre peut être résolu en collectant davantage de cas. Le second type de déséquilibre est relatif et survient lorsque la probabilité d'une classe est très supérieure à celle des autres. Cela peut par exemple être le cas d'une maladie rare. Ce type de déséquilibre est plus difficile à contourner. Une solution courante est le rééquilibrage des données d'entraînement, ce qui peut augmenter le risque d'*overfitting* (He et Ma, 2013, chap. 1 & 2).

Le déséquilibre relatif a des conséquences sur les performances de l'IA. Puisque la plupart des modèles sont entraînés pour améliorer leur précision, ils peuvent développer une stratégie consistant à détecter plus fréquemment la classe majoritaire, alors que les données ne permettent pas cette conclusion. La précision d'une IA ne reflète alors pas ses performances réelles. Pour résoudre cette limite, le modèle doit être entraîné d'une façon différente ou ses performances doivent être évaluées avec d'autres indicateurs (He et Ma, 2013, chap. 1 & 2).

En particulier dans le domaine médical, il peut être intéressant de préférer une précision globale plus faible afin d'obtenir un meilleur taux de vrais positifs. Un des indicateurs permettant de juger la performance d'une IA est la courbe de la fonction d'efficacité du récepteur (courbe ROC, acronyme de *Receiver Operating Characteristic*), qui mesure la performance globale d'une IA à classer les cas. Son tracé est représenté sur la **Figure 16** : il correspond au taux de vrais positifs en fonction du taux de faux positifs (c'est-à-dire la sensibilité en fonction de « 1 – spécificité »). Plus l'aire sous cette courbe (AUC) est élevée, plus l'IA est efficace. À l'inverse, un classificateur aléatoire a un tracé rectiligne et une aire sous la courbe de 0,5 (He et Ma, 2013, chap. 8).

Figure 16 : Courbes ROC de plusieurs modèles détectant la présence de calculs rénaux sur des images de tomodensitométrie canine.

Licence [CC BY](https://creativecommons.org/licenses/by/4.0/) (Ji et al., 2023).



□ La présence de biais

Les algorithmes de ML sont sensibles aux biais présents dans leurs données d'entraînement, notamment si certaines populations ne sont pas correctement représentées (Currie et Hawk, 2021). Ce biais est parfois difficilement décelable, car les données permettant d'entraîner l'IA et de la tester proviennent souvent des mêmes institutions ou des mêmes groupes de recherche, notamment pour des raisons techniques (Awaysheh et al., 2019 ; Joslyn et Alexander, 2022).

En médecine humaine, ce biais peut se manifester sous différentes formes. L'IA peut avoir des biais sociétaux, par exemple en étant moins performante pour certaines populations ethniques (Kelly et al., 2019). Il est aussi possible que des IA fonctionnant bien dans de grands centres hospitaliers ne soient pas aussi performantes dans des régions plus rurales (Goecks et al., 2020). En médecine vétérinaire, ces biais peuvent être présents si les données d'entraînement sont issues d'animaux dont l'environnement n'est pas suffisamment similaire à celui des animaux traités (Ezanno et al., 2021).

□ La présence de facteurs de confusion

La façon dont les données sont produites ou rédigées peut varier au cours du temps, en particulier pour les données issues de dossiers électroniques. Ainsi, l'évolution des pratiques administratives ou médicales et les changements démographiques au sein des données peuvent empêcher l'IA d'être pleinement performante (Briganti et Le Moine, 2020 ; Kelly *et al.*, 2019). Un entraînement continu est alors nécessaire afin de s'assurer que l'IA s'adapte à ces changements en temps réel (Briganti et Le Moine, 2020).

De façon similaire à l'*overfitting*, il est possible qu'une IA apprenne des relations en utilisant des caractéristiques peu fiables (Kelly *et al.*, 2019). Ribeiro *et al.* (2016) prennent ainsi l'exemple d'une IA distinguant efficacement les loups des chiens sur des images, mais qui a en réalité appris à reconnaître des arrière-plans enneigés. Cette possibilité peut avoir des répercussions majeures sur les IA médicales. Winkler *et al.* (2019) ont par exemple découvert qu'une IA, approuvée en Europe pour la reconnaissance des mélanomes, étaient fortement influencée par la présence de traces de marqueurs chirurgicaux sur la peau.

Les CNN sont particulièrement sensibles, car ils ne comprennent pas réellement le contenu de l'image qui leur est présentée. Un humain peut facilement identifier les caractéristiques les plus importantes, mais l'IA ne perçoit qu'un ensemble de motifs, sans qu'aucun n'ait plus d'importance qu'un autre. Si l'image à analyser n'est pas habituelle ou a été manipulée, il est possible de fausser volontairement les résultats de l'IA (Heaven, 2019 ; Kelly *et al.*, 2019).

Cette fragilité présente un risque bien réel dès aujourd'hui. Finlayson *et al.* (2019) ont examiné une autre IA capable de reconnaître des mélanomes et ont trouvé un moyen relativement simple de fausser le diagnostic. En appliquant sur l'image un filtre quasiment imperceptible pour un humain, l'IA classe systématiquement la photographie présentée comme maligne. Les auteurs imaginent alors plusieurs cas de figures, dont celui d'un praticien malhonnête qui pourrait utiliser cette technique pour pratiquer davantage d'actes ou de ventes.

- *Les enjeux économiques, énergétiques et environnementaux autour de l'intelligence artificielle*

De nombreux investissements financiers ont été réalisés dans le domaine de l'IA cette dernière décennie. Dans le domaine des IA grand public, de larges investissements sont initialement réalisés afin de proposer des services peu onéreux voire gratuits. L'objectif est d'acquérir la plus grande part de marché possible ou d'établir un monopole permettant par la suite de mieux contrôler le marché (Chow *et al.*, 2023). Les start-ups suivant ce modèle ne sont donc pas rentables initialement et dépendent uniquement des apports initiaux.

Dans le domaine médical, l'objectif est également d'obtenir d'importants retours sur investissements (Groves *et al.*, 2013). Bakker *et al.* (2020) ont réalisé une revue de 71 articles concernant l'utilisation de l'IA dans le domaine médical. Ils ont observé que les études ont encore peu de recul sur les résultats financiers des IA ou ne donnent que des résultats partiels. Bien que les analyses partielles rapportent généralement des économies conséquentes, seule la moitié des analyses complètes (soit 11 sur 22) en rapportent. Alors que les bénéfices attendus sont importants, comme les milliards de dollars d'économie envisagés pour le système de santé américain s'il utilisait des IA personnalisées, ils restent pour le moment difficilement objectivables (Bakker *et al.*, 2020 ; Groves *et al.*, 2013).

En l'absence de monopole clair, les IA grand public sont actuellement proposées à perte (Chow *et al.*, 2023). Par exemple, chaque conversation avec ChatGPT coûte quelques centimes à OpenAI. Face à ces pertes, les GAFAM explorent déjà des méthodes afin de monétiser leurs IA. OpenAI propose par exemple un abonnement payant, tandis que Microsoft et Google ajoutent des résultats générés par IA dans leurs moteurs de recherche respectifs.

De manière générale, les modèles de ML utilisés par les IA modernes sont imposants. À titre d'exemple, GPT-3 possède plus de 175 milliards de paramètres représentant plus de 800 Go de données à stocker (Brown *et al.*, 2020). Comme illustré sur la **Figure 11 (p. 32)**, l'entraînement de modèles aussi complexes requiert une puissance de calcul croissante et une forte dépendance au *cloud computing* (Sevilla *et al.*, 2022).

L'usage d'une IA entraînée avec des données massives ou fonctionnant dans le *cloud* nécessite donc de grandes quantités d'énergie et de grandes quantités de matériels électroniques, dont la fabrication demande parfois des ressources rares (Hagendorff, 2022). Même si elles sont utilisées pour le bénéfice d'un patient, certaines IA ont une répercussion environnementale qui n'est parfois pas négligeable.

Certaines mesures sont déjà envisagées, comme la publication *open-source* du modèle de DL développé par Meta, LlamA (Touvron *et al.*, 2023a). Les auteurs espèrent notamment permettre aux chercheurs d'éviter la coûteuse phase d'entraînement. Ils proposent également des modèles comportant moins de paramètres et nécessitant donc moins de ressources.

c. Quelles solutions pour développer des intelligences artificielles plus sûres et plus éthiques ?

- *Une implication humaine plus importante*

Le manque de transparence autour de l'IA et la complexité de son fonctionnement peut entraîner un manque d'implication humaine. Pourtant, il est essentiel que son développement soit guidé par des valeurs éthiques, afin d'éviter les limites mentionnées ci-dessus.

Il est également important d'intégrer le raisonnement humain dans le fonctionnement des IA, afin de proposer des solutions qui pourront être appliquées et qui répondent aux besoins de la société (Ezanno *et al.*, 2021). Par exemple, pour la plupart des maladies animales réglementées, un levier d'action consiste à restreindre les mouvements d'animaux. Mais cela a souvent pour effet d'entraîner des ventes prématurées de la part des éleveurs et donc de diminuer l'efficacité des mesures sanitaires (Tago *et al.*, 2016).

Ce concept peut être appliqué dès la conceptualisation et le développement d'une IA, en utilisant des méthodes participatives. En intégrant activement des propriétaires, des éleveurs, des industries agro-alimentaires et des décideurs publics, il est ainsi possible de construire des outils plus compréhensibles, plus efficaces et donc plus utiles (Cohen et Gordon, 2022 ; Ezanno *et al.*, 2021). De tels outils seront également importants pour permettre une meilleure utilisation et une meilleure acceptation par les praticiens, comme expliqué dans la partie **II.3.a.**

- *Vers des intelligences artificielles explicables*

L'intelligence artificielle explicable (XAI) est un domaine de recherche qui vise à rendre le fonctionnement des modèles de ML le plus compréhensible possible (Giacobbe *et al.*, 2023). Certains modèles simples, par exemple les SVM (voir **p. 24**), peuvent être expliqués directement

en observant leur fonctionnement. À l'inverse, un modèle de DL est difficilement compréhensible, car les nombreux neurones et couches qui le composent forment un ensemble complexe dont les relations ne sont pas linéaires (van der Velden *et al.*, 2022). Il existe donc actuellement un compromis entre la performance d'un modèle et son explicabilité (Kelly *et al.*, 2019).

Les algorithmes d'XAI établissent une approximation du fonctionnement de l'IA, sans chercher à l'expliquer entièrement (Giacobbe *et al.*, 2023). Selon leur fonctionnement, ils peuvent être spécifiques ou non à un modèle de ML. Deux approches sont principalement utilisées aujourd'hui : LIME et SHAP (Linardatos *et al.*, 2020).

La méthode LIME (acronyme de *Local Interpretable Model-agnostic Explanations*) consiste à expliquer l'interprétation de l'IA de manière locale, c'est-à-dire en expliquant un cas en particulier plutôt qu'en étudiant le fonctionnement du modèle dans sa globalité. Concrètement, à partir d'un cas donné, l'algorithme génère plusieurs nouveaux cas avec des caractéristiques proches et identifie comment l'IA les aurait classés. LIME peut alors déterminer quelles sont les caractéristiques qui ont la plus grande influence sur la classification du cas initial (Linardatos *et al.*, 2020 ; Ribeiro *et al.*, 2016).

SHAP (acronyme de *SHapley Additive exPlanations*) utilise une formule mathématique spécialement conçue pour estimer la participation de chaque caractéristique dans la classification finale. De manière globale, pour un cas donné, l'algorithme évalue comment se comporte le modèle lorsqu'une ou plusieurs caractéristiques ne sont pas prises en compte (Linardatos *et al.*, 2020 ; Lundberg et Lee, 2017).

L'utilisation de l'XAI comporte des avantages importants. En particulier, LIME et SHAP sont des algorithmes utilisables pour tout type de ML et fournissent des explications imagées (Lundberg et Lee, 2017 ; Ribeiro *et al.*, 2016). En comprenant mieux l'IA, les utilisateurs finaux peuvent avoir une meilleure confiance dans les résultats fournis. En exploitant les algorithmes d'XAI dès la conception d'une IA, il est même possible d'écarter précocement les mauvais modèles si les scientifiques identifient de mauvaises interprétations. L'exemple évoqué plus haut d'une IA reconnaissant des loups grâce à un arrière-plan enneigé pourrait ainsi être évité (Ribeiro *et al.*, 2016).

L'utilisation de l'XAI ne résout cependant pas tous les problèmes de compréhension liés aux IA (van der Velden *et al.*, 2022). Ces algorithmes, y compris ceux présentés ci-dessus, n'expliquent que partiellement le fonctionnement et peuvent ne pas être entièrement justes. Selon le modèle auxquels ils sont appliqués, ils nécessitent également des calculs intensifs et un fin ajustement de leurs paramètres.

En 2020, Lewis *et al.* (2020) ont présenté un nouveau type de génération de texte, la *Retrieval-Augmented Generation* (RAG), ou « génération augmentée de récupération ». Cette structure cherche à limiter les hallucinations et à améliorer les connaissances des IA. La RAG utilise un ensemble de documents textuels et fonctionne en deux temps : un premier modèle identifie les passages des documents les plus en lien avec la requête, puis un second modèle classique (basé sur GPT, par exemple) les combine avec la requête initiale et renvoie une réponse cohérente et factuelle. La RAG permet à l'IA d'avoir des connaissances à jour sur un domaine précis et de pouvoir citer les documents dont elle s'est servie, mais cette technique demande des ressources supplémentaires et reste dépendante de la qualité des documents fournis.

Partie II – Les applications concrètes pour le praticien d’aujourd’hui, inscrites dans le mouvement *One Health*

Avant cette dernière décennie, le *Big Data* ne pouvait souvent pas être traité de manière efficace, car la plupart des données n’étaient pas structurées (Cheng *et al.*, 2020). Le *Big Data* est complémentaire des études traditionnelles. Son analyse peut suivre une étude préliminaire avec une hypothèse large et permettre de la valider ; ou elle peut permettre de dégager des hypothèses précises qui seront ensuite validées par une démarche scientifique traditionnelle (McCue et McCoy, 2017, 2019). En particulier, le *Big Data* a désormais la capacité d’apporter de nouvelles connaissances concernant des maladies pour lesquelles la collecte prospective de données présente encore un coût trop important (McCue et McCoy, 2017).

Les applications de l’IA, qui découlent du *Big Data*, sont multiples en médecine humaine et en médecine vétérinaire. Quelques applications humaines sont présentées, car, dans le cadre d’une médecine unique (*One Health*), des applications vétérinaires pourront éventuellement en découler (Basran et Appleby, 2022). L’usage de l’IA modifiera également la façon d’exercer la médecine vétérinaire et en particulier, pourra modifier les relations avec le propriétaire et son implication dans la démarche diagnostique (Basran et Appleby, 2022 ; Coghlan et Quinn, 2023).

1. Quelques domaines d’application de l’intelligence artificielle en médecine humaine

A. L’intelligence artificielle pour le diagnostic en médecine humaine

Une utilisation de l’IA parmi les premières autorisées en médecine est la détection de fibrillations atriales, directement au chevet des patients (Briganti et Le Moine, 2020). La détection d’arythmies est aujourd’hui proposée par plusieurs entreprises, notamment des GAFAM comme Apple (Dorado-Díaz *et al.*, 2019 ; Turakhia *et al.*, 2019). La détection d’autres maladies comme un infarctus du myocarde ou une insuffisance cardiaque est également possible, parfois plus précocement qu’avec des outils classiques (Briganti et Le Moine, 2020 ; Dorado-Díaz *et al.*, 2019).

En ophtalmologie, il existe plusieurs bases de données médicales spécifiques, qui permettent aux praticiens de vérifier leurs plans de traitement et de comparer leurs diagnostics (Cheng *et al.*, 2020). La grande quantité de données disponibles permet aussi le développement d’IA d’analyses d’images, présentées plus bas.

En pneumologie, l’IA est principalement utilisée pour prédire la survenue de cancers pulmonaires, pour les diagnostiquer ou pour aider le praticien à choisir le meilleur plan de traitement (Mikhael *et al.*, 2023 ; Pei *et al.*, 2022). Récemment, l’intérêt de l’IA a surtout été démontré face à la pandémie de Covid-19. Des algorithmes de ML ont pu être mis en place rapidement après le début de la crise pour aider les praticiens à diagnostiquer et traiter les patients atteints de troubles pulmonaires (Izquierdo *et al.*, 2023).

En gastroentérologie, l'IA peut déjà être utilisée pour le diagnostic de plusieurs maladies. Elle peut par exemple aider le praticien à choisir l'examen le plus adapté pour établir un diagnostic (des biopsies ciblées ou aléatoires lors de suspicion de néoplasies œsophagiennes, par exemple) (Kröner *et al.*, 2021). D'autres IA permettent de prendre en compte les données cliniques des patients pour détecter ou prédire des maladies telles qu'une maladie inflammatoire chronique de l'intestin, une pancréatite, une insuffisance hépatique ou des reflux gastro-œsophagiens (Briganti et Le Moine, 2020 ; Kröner *et al.*, 2021). Enfin, l'IA peut également prévoir la réponse à un traitement particulier, par exemple lors de saignements gastrointestinaux (Das *et al.*, 2003).

En néphrologie, plusieurs applications sont déjà envisagées, mais la recherche est limitée par les faibles effectifs disponibles (Briganti et Le Moine, 2020). Par exemple, il existe des IA pouvant prédire une baisse du débit de filtration glomérulaire lors de polykystose rénale ou d'autres capables de prédire une insuffisance rénale chez certains patients (Niel et Bastard, 2019).

En neurologie, une des applications phares de l'IA est le diagnostic (et le suivi) de crises d'épilepsie généralisées, notamment grâce au port de capteurs aux poignets (Regalia *et al.*, 2019). L'utilisation d'appareils connectés permettrait par ailleurs le développement de la « téléneurologie », une nouvelle façon d'assurer des soins à distance. En particulier dans cette discipline où de nombreuses maladies sont débilitantes, la téléneurologie pourrait bénéficier à plus de patients et assurer un meilleur confort de vie (Bruno *et al.*, 2018 ; Dorsey *et al.*, 2018). Plusieurs maladies sont concernées par l'IA, comme la maladie de Parkinson ou la maladie d'Huntington (Briganti et Le Moine, 2020 ; Dorsey *et al.*, 2018).

En médecine d'urgence, l'IA présente un intérêt particulier, car son usage pourrait permettre des prises de décision rapides et un triage accéléré. La plupart des études ne sont cependant que des preuves de concept¹⁴ et les applications concrètes sont donc encore limitées (Chenais *et al.*, 2023). Parmi les usages évoqués, l'IA peut être appliquée au triage préhospitalier ou hospitalier. Des *chatbots* comme ChatGPT pourraient ainsi intervenir avant l'admission pour encourager un triage autonome ou pour proposer des diagnostics simples (Dave *et al.*, 2023). L'application de l'IA à la médecine d'urgence pourrait limiter la mortalité avant la prise en charge médicale, mais elle fait face à plus d'implications légales que dans d'autres spécialités, ce qui limite d'autant plus son usage (Chenais *et al.*, 2023).

En endocrinologie, une des premières applications a été le suivi de la glycémie en temps réel, ce qui permet aux IA de détecter précocement des épisodes d'hypoglycémie (Briganti et Le Moine, 2020). Le diagnostic du diabète est également une application possible de l'IA, aux côtés d'autres maladies, comme des troubles minéraux (secondaires à une hyperparathyroïdie par exemple), des troubles thyroïdiens ou des troubles des glandes surrénales (Giorgini *et al.*, 2023).

Enfin, l'oncologie est un domaine profitant d'IA qui peuvent d'ores et déjà identifier de nombreux cancers lors d'analyses histologiques (Briganti et Le Moine, 2020). En dermatologie plus spécifiquement, il existe des systèmes capables d'identifier des tumeurs sur des photographies de lésions cutanées (Winkler *et al.*, 2019). D'autres IA peuvent utiliser des images de dermoscopie pour améliorer les diagnostics de rosacée ou d'autres maladies inflammatoires. Certaines sont

¹⁴ Une preuve de concept (ou POC pour *proof of concept*) est une démonstration visant uniquement à prouver la faisabilité d'un projet ou d'une méthode.

également entraînées pour lire des coupes histologiques et peuvent alors détecter des tumeurs, des dermatites, du psoriasis ou certaines maladies infectieuses (N. Luo *et al.*, 2023 ; Patel *et al.*, 2021). Toutefois, tous ces algorithmes sont unimodaux : ils ne prennent en compte que des images pour établir un diagnostic. Des IA multimodales, prenant en compte à la fois des images et un résumé des symptômes ou examens cliniques, commencent à émerger et présentent une meilleure précision (N. Luo *et al.*, 2023). Enfin, comme en neurologie, ces IA laissent envisager le développement de la « télédermatologie », qui permettrait un accès facilité à une médecine de qualité (Patel *et al.*, 2021).

B. L'imagerie médicale, un domaine d'application en plein essor

L'imagerie médicale est un domaine déterminant pour l'IA. Comme l'expliquent Liu *et al.* (2019), il s'agit d'un moyen diagnostique très important, mais qui requiert systématiquement une interprétation humaine. Cette interprétation nécessite elle-même des compétences particulières. Un diagnostic assisté par l'IA pourrait ainsi répondre au problème de la disponibilité de praticiens expérimentés.

En médecine humaine, il existe déjà plusieurs dizaines d'IA dont l'usage est approuvé par des organismes régulateurs comme la FDA. L'analyse de Liu *et al.* (2019) met en évidence que l'IA est souvent utilisée pour diagnostiquer des cancers, mais il existe également d'autres usages, dont certains sont présentés ci-dessous.

En cardiologie, l'IA est très utilisée pour analyser des échocardiographies. Historiquement, l'IA constituait une aide pour mieux différencier les différentes structures, mais elle permet désormais d'établir des diagnostics (Dorado-Díaz *et al.*, 2019). Des algorithmes de DL ont ainsi été utilisés pour identifier des sténoses des artères coronaires ou pour aider le praticien à différencier certaines myocardiopathies (Sengupta *et al.*, 2016 ; Zreik *et al.*, 2018).

L'imagerie médicale est également utilisée en gastroentérologie, lors d'endoscopies et d'échographies (Briganti et Le Moine, 2020). La détection d'anomalies lors de ces examens est très dépendante de l'opérateur. L'IA pourrait ainsi normaliser le taux de détection parmi les praticiens, en les aidant à identifier des maladies inflammatoires de l'intestin, des polypes ou des néoplasies (Kröner *et al.*, 2021).

En ophtalmologie, des algorithmes de DL sont souvent utilisés pour analyser des photographies (notamment des fonds d'œil) et des résultats de tomographie en cohérence optique. Des IA ont par exemple été développées pour le diagnostic de rétinopathies ou d'anomalies du disque optique et pour la détection précoce d'anomalies cardiovasculaires (Cheng *et al.*, 2020).

En endocrinologie, l'utilisation de l'IA permet d'assister les praticiens pour le diagnostic de rétinopathies secondaires à un diabète et pour le diagnostic de certaines tumeurs, lors d'examens échographiques ou tomodensitométriques (Giorgini *et al.*, 2023).

Enfin, l'imagerie assistée par IA est utilisée plus marginalement en pneumologie, traumatologie ou orthopédie (Liu *et al.*, 2019). Des troubles pulmonaires telles que la tuberculose, une pneumonie ou un pneumothorax peuvent par exemple être diagnostiqués par une IA (Hwang *et al.*, 2019). L'IA pourrait aussi être utilisée pour donner un premier avis en l'absence d'un spécialiste, par exemple dans un contexte d'urgence en diagnostiquant certains types de fractures des hanches (Urakawa *et al.*, 2019).

2. Les apports de l'intelligence artificielle en médecine vétérinaire : de la prévention au diagnostic

Comme présenté dans la partie **I.1.a.c.**, les données médicales vétérinaires peuvent prendre des formes variées : notes textuelles, résultats d'imagerie médicale, coupes histologiques, résultats d'analyses biochimiques, *etc.* Pour tous ces types de données, il existe un algorithme de ML adapté à son traitement (Basran et Appleby, 2022). L'IA peut donc être utilisée à plusieurs étapes du diagnostic vétérinaire. Elle peut prédire des symptômes ou des maladies, les diagnostiquer pendant un contrôle de routine alors que les anomalies cliniques sont invisibles pour le praticien ou bien aider ce dernier à diagnostiquer un patient malade. Elle peut également assurer le suivi du patient en diagnostiquant toute rechute et elle permet d'adopter une démarche thérapeutique idéale (Goecks *et al.*, 2020).

L'IA a également des apports diagnostics plus indirects. Grâce aux grands jeux de données, le ML peut découvrir de nouveaux paramètres pour identifier des individus susceptibles d'être malades. Ces paramètres pourraient se révéler être de bons biomarqueurs suite à d'autres travaux de recherche (McCue et McCoy, 2017). Les études de ce type sont encore peu nombreuses en médecine vétérinaire. Broughton-Neiswanger *et al.* (2020) ont par exemple utilisé une RF (voir **p. 26**) pour identifier plusieurs métabolites urinaires félines indiquant la présence de lésions rénales induites par du meloxicam. Gal *et al.* (2022) ont réalisé une étude similaire avec un DT (voir **p. 25**) et ont identifié des métabolites urinaires du cortisol qui pourraient permettre d'identifier plus facilement un chien atteint d'hypercorticisme.

La plupart des études en médecine vétérinaire décrivent la collecte de données, puis l'entraînement d'un algorithme de ML et son test avec des données indépendantes (qui n'ont pas servies à entraîner l'IA). Même si les résultats sont souvent prometteurs, l'objectif reste limité à la publication d'une preuve de concept (voir **p. 50**) (Appleby et Basran, 2022 ; Joslyn et Alexander, 2022). Il peut également arriver que certaines équipes cherchent à entraîner des IA sur des problèmes trop complexes, ce qui entraîne une précision médiocre, de l'*overfitting* (voir **p. 42**) et finalement un faible potentiel d'application en pratique : seules 20 à 25 % des IA deviennent des logiciels utilisables ou commercialisables (Fuentes *et al.*, 2022).

A. Le secteur rural, pionnier dans l'implémentation de l'intelligence artificielle

L'apparition de l'IA en médecine vétérinaire a commencé par le secteur rural. Les élevages produisent d'importantes quantités de données, dont seule une partie est exploitée par l'éleveur. La prise de décision s'appuie donc principalement sur les observations et l'expérience de l'éleveur plutôt que sur une analyse objective des données, ce qui n'est pas toujours la solution économiquement idéale. L'IA en élevage a donc un potentiel important : les données sont faciles à obtenir et l'IA a des applications concrètes (Slob *et al.*, 2021). En particulier, de nombreuses IA interviennent dans le domaine de la reproduction, un des piliers de la conduite d'élevage.

a. *L'intelligence artificielle prédictive bovine*

- *L'intelligence artificielle pour prévoir et améliorer les performances de reproduction*

- Prédiction du diagnostic de gestation

Une fois l'œstrus détecté, il peut être utile pour l'éleveur de pouvoir déterminer à l'avance la probabilité d'une gestation, notamment en cas d'insémination artificielle, car il existe un vaste choix de semences avec des coûts potentiellement élevés (Hempstalk *et al.*, 2015). Les études sur ce sujet font cependant face à des problèmes de performances et la précision des IA reste médiocre. Il est généralement difficile de prédire le résultat pour une vache donnée, mais il est possible d'identifier des groupes d'animaux plus fertiles au sein d'un troupeau (De Vries *et al.*, 2023).

Par ailleurs, la fécondation *in vitro* est une méthode de fécondation fréquemment utilisée dans certaines régions du monde. Le succès de la gestation dépend alors de la qualité des ovocytes prélevés et des blastocytes obtenus. L'évaluation de ces structures par des humains est toutefois longue et les résultats sont variables selon l'observateur : ce processus pourrait donc bénéficier des apports de l'IA (Costa *et al.*, 2023 ; Rocha *et al.*, 2017).

Costa *et al.* (2023) ont entraîné un CNN (voir p. 33) à l'aide de 994 images microscopiques d'ovocytes bovins. Chaque image a été associée au résultat du développement de l'ovocyte en blastocyte ou non. Le modèle obtenu a une précision de 61 %, une sensibilité de 51 % et une spécificité de 67 % et l'AUC (voir p. 43) est de 0,69. L'IA a donc une performance équivalente à celle des évaluateurs humains, mais un temps d'exécution réduit. Rocha *et al.* (2017) ont mené une étude similaire pour l'analyse automatique des blastocytes à l'aide de 482 images microscopiques. Après un pré-traitement, les données obtenues ont permis d'entraîner un NN. Ce réseau atteint une précision de 76 %. L'AUC a été calculée mais n'est pas communiquée. Les performances de l'IA ont toutefois motivé le développement d'un produit commercial par les auteurs.

- Prédiction d'un avortement

Keshavarzi *et al.* (2020) ont étudié la faisabilité d'une IA pouvant déterminer le risque d'avortement chez une vache. Ils ont récolté les données issues de six élevages, dont le rang de lactation, le stade de lactation, le stade de gestation, les informations génétiques du taureau inséminateur et le statut des animaux vis-à-vis de mammites en cours ou passées. Plusieurs modèles ont été testés par les auteurs, dont un réseau bayésien (voir p. 25), des RF, des DT et un NN, mais leurs précisions restent comprises entre 30 et 70 %, avec une AUC comprise entre 0,863 et 0,893. L'utilisation d'une IA est donc envisageable, mais d'autres travaux sont encore nécessaires pour améliorer les performances de l'IA.

- Prédiction des conditions du vêlage

La mise-bas est un moment critique pour l'éleveur, car son mauvais déroulement a des conséquences sur la santé des animaux et des retombées économiques importantes. Sa détection repose habituellement sur l'observation du comportement des animaux gestants, mais celui-ci n'est pas toujours identique d'un animal à l'autre et l'agrandissement des troupeaux réduit le temps disponible pour l'observation (Vázquez-Diosdado *et al.*, 2023). Les IA sont donc une approche utile à ce problème, en permettant à la fois de prédire le moment du vêlage et son déroulé.

- Prédiction de la date de parturition

Borchers *et al.* (2017) sont parmi les premiers à avoir utilisé une combinaison de capteurs et à atteindre une bonne efficacité. Des capteurs ruminiaux et des colliers mesurant notamment le nombre de pas, le temps passé debout et le nombre de couchés ou relevés ont été installés chez 53 vaches. Les données collectées ont permis d'entraîner trois modèles. Le plus performant est un NN capable de prédire une mise-bas dans les 24 heures avec 100 % de sensibilité et 87 % de spécificité et une mise-bas dans les 8 heures avec 83 % de sensibilité et 80 % de spécificité. Keceli *et al.* (2020) ont utilisé des données similaires pour entraîner un RNN (voir p. 29). Ce réseau peut prédire la date de mise-bas avec une sensibilité comprise entre 84 % et 100 % et une spécificité comprise entre 80 % et 100 %.

Les solutions nécessitant plusieurs capteurs par animal sont toutefois onéreuses et plus compliquées à installer. La température étant reliée à l'imminence du vêlage, plusieurs études se sont concentrées sur des dispositifs installés dans le vagin, le rumen ou sur la queue ou l'oreille. Les résultats obtenus sont variables, les IA atteignant au maximum 90 % de sensibilité et spécificité (Vázquez-Diosdado *et al.*, 2023).

- Prédiction d'une dystocie

Dès 2003, plusieurs équipes ont étudié la faisabilité d'une IA pour prédire le risque de dystocie. Toutefois, toutes ces études ont incorporé dans leurs données d'entraînement des éléments qui ne peuvent être connus qu'une fois la mise-bas effectuée ou sur lesquels l'éleveur n'a pas de moyen d'action, limitant en partie l'intérêt de l'IA. Parmi ces données, les auteurs ont par exemple utilisé le sexe du veau, la durée de gestation ou la saison de la mise-bas. Face à ce constat, Alshaf *et al.* (2023) ont utilisé les comptes-rendus de mise-bas de plus de 55 000 vaches issues de 775 élevages pour entraîner une IA capable de prédire la survenue d'une dystocie à l'aide de facteurs connus uniquement avant l'insémination (artificielle ou non). Pour chaque mise-bas, les chercheurs ont identifié le niveau de difficulté avec lequel elle s'est déroulée, parmi les cinq niveaux suivants : aisé, normal, vêlage difficile, aide d'un vétérinaire ou césarienne requise. Leur équipe a obtenu une RF modifiée avec une AUC de 0,73, utilisant plus de 274 caractéristiques et en particulier les index génétiques des parents.

- Prédiction d'une métrite

Les métrites sont des affections *postpartum* fréquentes chez les vaches laitières, engendrant des pertes économiques parfois importantes. Leur diagnostic précoce pourrait donc bénéficier des apports de l'IA. De nombreuses études se sont intéressées à prédire la survenue d'une métrite, en utilisant des données variées et différents algorithmes. Vidal *et al.* (2023) ont pu prouver que l'usage d'une RF est l'approche la plus performante, puisqu'elle atteint une précision de plus de 98 %, une sensibilité de 94 % et une spécificité de 98 %. Les auteurs ont déterminé que l'activité physique et l'activité du rumen étaient les principaux paramètres.

- Prédiction d'une mammite *post-partum*

J. S. Thompson *et al.* (2023) ont publié une RF modifiée capable de déterminer si une vache allait conserver un faible taux de cellules somatiques durant les 30 jours suivant un vêlage. Indirectement, cette IA peut donc déterminer le risque de mammite chez une vache. Leur équipe a utilisé les données de 84 élevages, dont des résultats d'analyses laitières, le rang de lactation et les concentrations cellulaires de la lactation précédente. Le modèle final a atteint une précision de 83 %, une sensibilité de 99 %, mais une spécificité de 6 %. Les auteurs ont aussi utilisé SHAP

(voir p. 47) : les trois paramètres les plus importants sont le taux d'infection du troupeau durant les périodes sèches des six derniers mois, le rang de lactation et la concentration cellulaire moyenne de la lactation précédente.

□ Prédiction du premier jour de production laitière après le vêlage

La période de transition entre deux lactations est critique pour les vaches laitières, car 30 à 50 % des animaux développent des troubles (mammite, métrite, etc.). Toutefois les méthodes diagnostiques traditionnelles et la plupart des IA nécessitent la collecte d'échantillons de lait ou de sang, ce qui requiert une implication importante de l'éleveur. Salamone *et al.* (2022) ont développé une IA pouvant prédire la quantité de lait produite en début de lactation, à partir de données collectées en routine seulement. Ils ont récolté les données de 102 élevages, comprenant notamment des informations sur la lactation et le vêlage, pour entraîner trois RF différentes à l'aide de Spark (voir p. 12). L'IA finale atteint une précision moyenne de 87 %.

• *Prédiction du risque de cétose subclinique*

La cétose subclinique est une maladie métabolique courante de la vache laitière, qui se manifeste par une augmentation de la concentration en corps cétoniques sans signes cliniques. La cétose subclinique a tout de même des conséquences économiques, car elle peut causer une diminution de la production laitière, une baisse de la fertilité et favoriser la survenue d'autres troubles tels des métrites. Le diagnostic habituel est réalisé en mesurant le taux sanguin de β -hydroxybutyrate à l'aide de dispositifs portables, mais l'IA pourrait permettre un diagnostic précoce, en identifiant les animaux à risque à l'aide de données collectées en routine (Sturm *et al.*, 2020).

Ehret *et al.* (2015) sont parmi les premiers chercheurs à avoir développé une telle IA. Ils ont pour cela collecté les données génomiques et laitières de 218 animaux allemands entre 2008 et 2010 pour entraîner plusieurs NN. Les auteurs ne communiquent pas sur les performances précises de leurs modèles, mais annoncent que le NN le plus performant utilise seulement les données laitières (production et composition) et atteint de bons résultats. Sturm *et al.* (2020) ont élaboré un modèle de ML combinant un réseau bayésien et un algorithme de *clustering* centroïde (voir p. 23) pour créer une IA prédisant le risque de cétose subclinique durant les deux premières semaines de lactation. Les chercheurs ont entraîné ce modèle avec l'activité et les données de santé de 2 700 vaches laitières, enregistrées quelques semaines avant la mise-bas. Le modèle final atteint une précision, une sensibilité et une spécificité de 73 %, 67 % et 74 % respectivement et a permis d'identifier les paramètres les plus importants.

De manière similaire mais plus approfondie, Xu *et al.* (2019) ont développé une IA capable de prédire le statut métabolique des animaux en début de lactation. Les auteurs ont collecté les données de 334 animaux, entre une et sept semaines de lactation, mesurées en routine (poids, production, etc.) pour entraîner plusieurs modèles. Les plus performants sont une RF et un SVM (voir p. 24), qui peuvent prédire les concentrations plasmatiques en β -hydroxybutyrate, acides gras libres, glucose, insuline et facteurs de croissance avec une précision comprise entre 73 % et 88 % et entre 79 % et 88 % respectivement.

• *Prédiction & détection précoce d'une dermatite interdigitée*

Les dermatites interdigitées sont des affections fréquentes chez les vaches laitières et sont responsables de troubles locomoteurs et d'une baisse de la fertilité et de la production (Magana *et al.*, 2023). La détection précoce des dermatites permet de limiter les traitements nécessaires et un

meilleur pronostic de récupération (Cerneke *et al.*, 2020). Ce diagnostic repose cependant sur une analyse visuelle des animaux, une approche longue et peu pratique à laquelle l'IA pourrait être une alternative (Cerneke *et al.*, 2020 ; Magana *et al.*, 2023).

Cerneke *et al.* (2020) font partie des premières équipes à avoir développé une IA pour détecter les dermatites interdigitées. Les chercheurs ont tout d'abord créé une base de plus de 3 000 images d'espaces interdigités, récoltées dans deux élevages américains. Ces images ont également été annotées par un observateur humain, afin de pouvoir évaluer l'efficacité de l'IA. Un CNN pré-entraîné¹⁵ (YOLOv2) a ensuite été entraîné avec ces images. Le modèle final atteint une précision de 88 %, avec une meilleure efficacité pour détecter des cas non infectieux. Ces résultats prouvent la faisabilité de l'IA pour la détection de ces lésions, à condition d'utiliser de plus grandes bases de données et de mieux les équilibrer (voir **p. 43**). Les données de l'étude comportaient en effet moins d'images de stades infectieux.

Magana *et al.* (2023) ont utilisé des données d'activité, mesurées grâce à un capteur porté à l'oreille, pour entraîner leur modèle. Les données ont été collectées pendant 60 jours consécutifs chez 180 animaux et comprenaient notamment la température de l'oreille, le niveau d'activité et les temps passés à la prise alimentaire, à la rumination et au repos. Les sabots de tous les animaux étaient inspectés visuellement chaque matin. Deux DT ont été entraînés : un permettant de détecter une dermatite interdigitée une fois les signes cliniques présents et un autre capable de prédire sa survenue dans les deux jours (avant que les signes cliniques ne soient présents). Les modèles atteignent une précision de 79 % et 64 % respectivement. Grâce à SHAP, Magana *et al.* ont également pu déterminer que l'activité est le facteur le plus important dans la détection d'une dermatite interdigitée, ce qui est cohérent avec les études antérieures.

b. L'intelligence artificielle pour le diagnostic de maladies bovines

- *L'intelligence artificielle pour diagnostiquer des troubles de la reproduction*

- Détection de l'œstrus

La détection de l'œstrus des vaches est habituellement effectuée par l'éleveur lui-même, *via* l'observation de leur comportement, ce qui n'est pas toujours aisé. Une mauvaise détection peut également avoir des conséquences médicales ou économiques (Wang *et al.*, 2020).

Le plus souvent, des capteurs portés par les animaux mesurent leur position, leur activité et leur température. L'équipe de Wang *et al.* (2020) a par exemple entraîné un NN avec les données de position et d'activité mesurées sur 12 vaches pendant 12 jours. Pour cette étude, deux observateurs étaient chargés de déterminer si ces vaches étaient effectivement en chaleur. Le NN final a atteint une sensibilité de plus de 88 %, une spécificité d'environ 60 % et une précision de plus de 88 %. L'utilisation de ce type de capteurs est donc faisable, mais des études avec davantage d'animaux sont nécessaires.

¹⁵ Un (C)NN pré-entraîné (voir notamment GPT **p. 37** et les LLM *open-source* comme LLamA, **p. 44**) est un modèle de DL qui a déjà été entraîné par l'équipe qui le publie. Il est ensuite possible de le « spécialiser » en l'entraînant avec de nouvelles données. Cette méthode est moins coûteuse en temps et en ressources, car seule une partie des paramètres est modifiée. Elle peut également être plus efficace, car l'IA profite de ses apprentissages antérieurs. Cette technique est également appelée l'apprentissage par transfert, ou *transfer learning*.

D'autres capteurs moins courants peuvent aussi être utilisés avec des précisions variables. Il est par exemple possible d'utiliser des dispositifs vaginaux mesurant la température et la conductivité électrique des tissus (Higaki *et al.*, 2019) ; d'analyser le comportement alimentaire d'un troupeau de vache (Cairo *et al.*, 2020) ; d'étudier les fluctuations de la température de la face ventrale de la queue (Higaki *et al.*, 2021) ; ou d'utiliser des enregistrements sonores provenant de capteurs placés dans l'élevage ou sur les animaux (Jung *et al.*, 2021 ; Wang *et al.*, 2023).

D'autres approches plus récentes utilisent des CNN. Arıkan *et al.* (2023) décrivent un ensemble de plusieurs NN connectés dont l'analyse est présentée sur la **Figure 17**. Un premier analyse les images en temps réel pour détecter la monte entre deux animaux (à gauche sur la figure), puis deux autres réseaux identifient les animaux grâce à leur robe et leurs traits physiques (à droite sur la figure). Les résultats sont précis et présentent l'avantage de ne pas nécessiter de matériel spécialisé (Arıkan *et al.*, 2023).

Figure 17 : Interprétation d'une image par l'IA proposée par Arıkan *et al.* pour détecter un œstrus chez une vache laitière.

Licence [CC BY](#) (Arıkan *et al.*, 2023).



□ Diagnostic de gestation

Le diagnostic de gestation est réalisé par un vétérinaire qui effectue une palpation transrectale, mais l'analyse des modifications du lait par une IA pourrait permettre une meilleure efficacité. En particulier, l'analyse spectrométrique du lait en lumière infrarouge peut être reliée à sa composition. Les études traditionnelles cherchant à établir un lien entre ces données et la gestation de l'animal ont cependant obtenu des résultats variables (Brand *et al.*, 2021). Face à cette situation, Brand *et al.* sont les premiers à avoir utilisé un algorithme de DL. Leur équipe a soumis les images de 10 000 spectres à un CNN pré-entraîné (DenseNet). Le modèle final a atteint une précision de 88 %, une sensibilité de 89 % et une spécificité de 86 %, rendant possible une application en situation réelle.

□ Diagnostic d'une endométrite

L'endométrite subclinique est la maladie utérine la plus fréquente chez la vache laitière. Elle est toutefois sous-diagnostiquée : le diagnostic d'une endométrite subclinique repose sur l'analyse cytologique d'échantillons d'endomètre et le comptage des granulocytes, ce qui est parfois subjectif et ne peut pas être réalisé facilement par un vétérinaire dans un élevage. Sadeghi *et al.* (2022) ont donc utilisé les images cytologiques obtenues après coloration du matériel récolté par

cytobrosse sur 116 vaches et un CNN pré-entraîné (YOLOv3) pour développer leur IA. Plusieurs colorations et méthodes d'analyses ont été testées. Le modèle le plus performant atteint une précision, une sensibilité et une spécificité respectives de 96 %, 93 % et 96 %, lorsque l'animal est considéré comme malade s'il y a plus de 10 % de granulocytes. Ces valeurs diminuent mais restent acceptables lorsque le seuil diagnostique diminue ($> 5 \%$ ou $\geq 1 \%$ de granulocytes).

- *Diagnostic d'une mammites ou de son origine*

En 2021, la revue de la littérature réalisée par Slob *et al.* a mis en évidence que la majorité des IA utilisées en élevages laitiers se concentraient sur le diagnostic des mammites cliniques ou subcliniques. Le diagnostic classique est effectué en surveillant l'aspect macroscopique du lait et sa concentration cellulaire, mais ces paramètres sont fluctuants. L'usage d'une IA permettrait un diagnostic plus fiable et plus rapide (Ebrahimie *et al.*, 2018a).

Ce raisonnement n'est pas récent et les premières IA de diagnostic ont été développées dans les années 1990. Les modèles utilisés n'étaient toutefois pas suffisamment performants pour pouvoir être utilisés convenablement en situation réelle (Kamphuis *et al.*, 2010). En particulier, ces IA utilisaient les mesures de conductivité électrique effectuées par les robots de traite. L'utilisation isolée de ce paramètre ne fournit pas les meilleurs résultats et les études effectuées ne dépassaient pas 60 à 80 % de sensibilité et spécificité (Samarasinghe *et al.*, 2018). Différentes approches dont les DT, les NN et les SVM ont été testées au cours des dix dernières années, mais les études comparatives les plus récentes divergent concernant leurs efficacités respectives : le meilleur choix semble dépendre des données utilisées (Bobbo *et al.*, 2023 ; W. Luo *et al.*, 2023).

L'amélioration des capteurs utilisés par les robots a permis leur intégration dans des IA plus efficaces. Kamphuis *et al.* (2010) ont par exemple entraîné des DT en utilisant les données de traite, dont la conductivité électrique du lait, son absorbance et le débit de production. Les modèles obtiennent des AUC entre 0,60 et 0,65, des sensibilités entre 20 % et 57 % et des spécificités entre 93 % et 99,8 %. Durant la même période, Sun *et al.* (2010) ont utilisé les mêmes paramètres pour entraîner des NN, dont le meilleur atteint une sensibilité de 87 % et une spécificité de 91 %. Cette approche a aussi été récemment adaptée par un des auteurs, pour développer une IA capable d'identifier différents stades de mammites (Samarasinghe *et al.*, 2018). Les années suivantes, plusieurs groupes de recherche ont tenté d'utiliser davantage de paramètres : Panchal *et al.* (2016) ont par exemple développé des NN plus complexes, qui obtiennent des AUC jusqu'à 0,98 et jusqu'à 98 % de sensibilité et spécificité.

L'émergence du *Big Data* a plus tard permis d'identifier de nouveaux marqueurs liés aux mammites, comme la concentration du lait en lactose (Ebrahimie *et al.*, 2018a). En utilisant ce nouveau paramètre et les données de traite de cette étude, leur équipe a pu entraîner un DT atteignant une précision de 88 % (Ebrahimie *et al.*, 2018b). La démocratisation d'outils de mesure tels que les spectromètres de masse MALDI-TOF a également permis à J. Thompson *et al.* (2023) d'entraîner une RF grâce à 226 échantillons de lait. Pour chaque échantillon, un algorithme de traitement automatisé a identifié la présence de pics, puis a enregistré leur intensité et le rapport masse/charge associé. Le modèle final utilise l'intensité de neuf pics spécifiques pour classer un échantillon, avec une précision de 85 %, une sensibilité de 89 % et une spécificité de 81 %.

Plus récemment, l'utilisation de CNN a été envisagée. Zhang *et al.* (2020) ont par exemple combiné des images infrarouges à un système de détection de la silhouette des vaches et des différentes parties de leur corps, comme illustré sur la **Figure 18**. Leur IA a alors été entraînée en

mesurant la température de la surface des globes oculaires (qui est proche de la température rectale) et la température des mamelles (qui augmente préférentiellement en cas de mammite) chez des vaches en sortie de la salle de traite. En comparant ces deux valeurs de température, l'IA peut détecter une mammite avec une précision, une sensibilité et une spécificité de 83 %, 92 % et 76 % respectivement. Une partie de l'équipe de recherche a repris ces travaux, en mesurant séparément la température des quartiers gauches et droits. Le modèle final est plus performant : il obtient une précision de 88 %, une sensibilité de 96 % et une spécificité de 85 % (Y. Wang *et al.*, 2022).

Figure 18 : Interprétation d'une image infrarouge par l'IA proposée par Wang *et al.* pour détecter une mammite chez une vache laitière.

Licence CC [BY-NC-ND](https://creativecommons.org/licenses/by-nc-nd/4.0/) (Y. Wang *et al.*, 2022).



Enfin, l'utilisation d'une RF pour diagnostiquer le type environnemental ou contagieux d'une mammite a également été rapportée. En utilisant les données de 1 000 élevages, Hyde *et al.* (2020) ont développé une IA atteignant une AUC satisfaisante et une précision de 81 %.

- *Diagnostic de la santé des trayons*

La santé des mamelles est également un point important de la gestion des mammites. Toutefois, l'évaluation de leur aspect nécessite généralement un contrôle visuel manuel, réalisé le plus souvent en salle de traite. Il s'agit donc d'un processus long et dont le résultat dépend fortement de l'évaluateur. L'usage d'une IA pourrait donc être bénéfique. Porter *et al.* (2021) ont collecté un ensemble de 398 images de trayons prises avec la caméra d'un téléphone, réparties sur deux fermes hébergeant plus de 5 500 vaches au total. Ces images ont été annotées manuellement par un des auteurs puis ont permis d'entraîner un CNN. Le modèle final atteint une précision de 47 % sur les données de test, malgré une AUC comprise entre 0,542 et 0,920. Ce score médiocre est expliqué par les auteurs par la qualité variable des images et leur faible diversité, mais ce résultat prouve néanmoins la faisabilité d'une telle IA en pratique.

- *Diagnostic précoce des troubles respiratoires*

Les troubles respiratoires forment un ensemble de maladies bovines fréquentes, dont le diagnostic est habituellement établi grâce à l'observation du comportement des animaux et de leurs éventuels signes cliniques. D'autres examens complémentaires peuvent également confirmer la présence d'un agent infectieux spécifique. Il s'agit donc d'un processus long et demandant un entraînement particulier : une IA pourrait permettre aux éleveurs et aux vétérinaires de diagnostiquer précocement ces troubles respiratoires, ce qui améliorerait le bien-être animal, limiterait l'usage des antibiotiques et maintiendrait la rentabilité de l'élevage (Puig *et al.*, 2022).

L'utilisation de capteurs d'activité (podomètres, accéléromètres, quantité d'eau ou de nourriture ingérée, etc.) est l'approche la plus souvent rapportée (Puig *et al.*, 2022). Cantor *et al.* (2022) ont par exemple utilisé les données de 106 veaux pour entraîner un modèle de ML capable de prédire le statut clinique d'un veau jusqu'à six jours avant son diagnostic par un vétérinaire, avec une précision de 90 %. D'autres approches existent également, comme l'utilisation d'un CNN pour identifier les spectrogrammes d'enregistrements sonores correspondant à de la toux ou d'un CNN pour identifier le comportement respiratoire des animaux (Jung *et al.*, 2021 ; Wu *et al.*, 2023).

- *Diagnostic de troubles locomoteurs*

Les troubles locomoteurs sont également un ensemble de maladies fréquentes dans les élevages de vaches laitières. Les conséquences sont multiples, puisque le bien-être des animaux, leur production laitière, leur fertilité et leur longévité sont généralement diminués. Ces maladies représentent un coût important pour les éleveurs : leur diagnostic précoce grâce à l'IA présente un réel intérêt pratique. L'automatisation du diagnostic est également utile, car ce processus demande une surveillance constante de la part de l'éleveur, qui émet un avis subjectif et a tendance à sous-estimer la prévalence des boiteries dans son élevage (Anagnostopoulos *et al.*, 2023 ; Nejati *et al.*, 2023).

Les technologies utilisant de l'IA pour détecter des troubles locomoteurs utilisent généralement la vision par ordinateur (qui comprend des techniques comme le *tracking*¹⁶ et les CNN) ou des capteurs contenant des accéléromètres (Nejati *et al.*, 2023). D'autres approches moins usitées sont aussi rapportées, comme l'analyse sonore des animaux marchant sur une zone spécialement conçue (Volkman *et al.*, 2021).

- Diagnostic de troubles locomoteurs grâce à la vision par ordinateur

Les recherches dans ce domaine remontent au début des années 2000, mais nécessitent alors une intervention humaine pour délimiter les zones d'intérêt dans les images à analyser. Ces premiers systèmes font également face à une qualité médiocre des vidéos enregistrées. L'utilisation d'algorithmes de *tracking* permet une automatisation progressive de ces systèmes. Les premiers essais nécessitaient une préparation de l'animal (avec la pose de marqueurs physiques, par exemple), ce qui n'est désormais plus le cas. Les études plus récentes utilisent parfois des caméras 3D, qui permettent de contourner certaines limitations inhérentes à la perspective des caméras 2D. Les algorithmes utilisés varient, il peut s'agir de RF, SVM ou NN (Nejati *et al.*, 2023).

Les études actuelles permettent d'obtenir des systèmes très performants. Une équipe anglaise a par exemple créé un prototype d'IA entièrement automatisée grâce aux enregistrements de 250 vaches. Ces vidéos ont permis d'entraîner un CNN pour détecter la silhouette des animaux et un DT capable de détecter une boiterie avec une précision de 100 % et d'en déterminer la sévérité avec une précision de 94 % (Barney *et al.*, 2023).

CattleEye est un logiciel déjà commercialisé qui surveille la survenue de troubles locomoteurs au sein d'un troupeau grâce à des caméras de surveillance placées à la sortie de la salle de traite (CattleEye, 2023). Sur ces images, l'IA identifie d'abord la vache à l'aide de sa robe et de la forme de sa tête, puis elle est trackée par un second algorithme. Les images obtenues

¹⁶ Le *video tracking* est une technologie permettant de localiser une région d'intérêt sur une vidéo (par exemple, un animal ou une partie de son corps) et de suivre sa position au cours du temps.

sont finalement analysées par un CNN. Ce réseau renvoie un score entre 0 et 100 décrivant la bonne ou mauvaise mobilité de l'animal, selon sa démarche (Anagnostopoulos *et al.*, 2023). Les auteurs ont analysé l'efficacité de ce système, en comparant 6 040 scores de mobilité calculés par CattleEye à ceux attribués par deux vétérinaires. Ils ont pu démontrer une efficacité similaire pour la détection de lésions douloureuses (confirmées par la suite par un examen clinique), puisque la précision, la sensibilité et la spécificité de l'IA atteignent respectivement 74 %, 52 % et 81 %.

□ Diagnostic de troubles locomoteurs grâce à des accéléromètres

Des capteurs de mouvement, le plus souvent placés au niveau des membres, peuvent également être utilisés par des IA. Il s'agit de l'approche la plus répandue ces dernières années. Elle présente cependant les inconvénients de ne pas pouvoir détecter toutes les boiteries et de nécessiter du matériel supplémentaire. Les algorithmes utilisés sont le plus souvent des SVM et des DT (Nejati *et al.*, 2023). Une étude a par exemple utilisé les données d'activité (notamment le temps passé à ruminer, se déplacer, se nourrir ou se reposer), la production laitière et le poids de 164 vaches laitières durant 11 mois, pour entraîner un DT. Le modèle final atteint une AUC de 0,85, une sensibilité de 78 % et une spécificité de 78 % dans la détection des boiteries. Ces performances prouvent la faisabilité d'une telle IA, qui utilise par ailleurs des capteurs déjà disponibles sur le marché (Borghart *et al.*, 2021).

• *Mesure automatisée de la note d'état corporelle*

La note d'état corporel (NEC) est un outil permettant de surveiller les réserves énergétiques d'une vache. En particulier, la NEC lors du vêlage et l'importance de sa diminution *postpartum* permettent de diagnostiquer des troubles de la fertilité, des troubles de la production laitière et des troubles locomoteurs. Les travaux de recherche sur des systèmes capables de déterminer automatiquement la NEC des animaux ont commencé au début des années 2000, en utilisant des images 2D. Ces études atteignent des performances élevées (jusqu'à plus de 90 % selon les études) et leur facilité et leur coût d'installation (de simples caméras de surveillance ou de téléphone peuvent être utilisées) permet leur déploiement sur le terrain. Ces systèmes présentent néanmoins l'inconvénient majeur de ne pas être entièrement automatisées : un humain doit généralement intervenir au début de l'analyse (Siachos *et al.*, 2023).

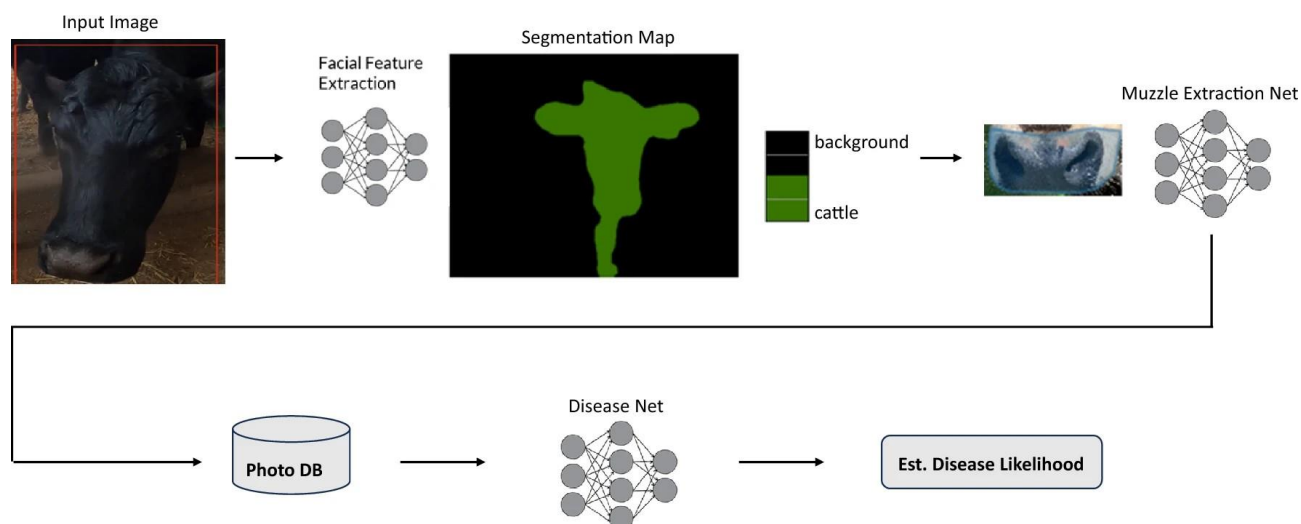
CattleEye (voir ci-dessus) est capable de mesurer automatiquement la NEC des vaches laitières de manière autonome en utilisant des images 2D et un CNN (Siachos *et al.*, 2023). Les auteurs ont collecté 31 150 images de vaches annotées avec la NEC correspondante. Le modèle final présente de bonnes performances, malgré une moindre précision par rapport aux vétérinaires pour des NEC extrêmes (inférieures à 2,5 ou supérieures à 4). Les auteurs suggèrent également qu'un entraînement comprenant plus de scores extrêmes permettrait d'améliorer ces résultats.

Les autres IA automatisées utilisent généralement une caméra 3D dont les données sont fournies à un CNN, pouvant être pré-entraîné selon les études. Les études développant de tels systèmes décrivent des précisions pouvant atteindre plus de 90 % (Siachos *et al.*, 2023). Une étude récente rapporte également que l'utilisation concomitante de trois caméras 3D avec différents angles permet d'améliorer la précision de l'IA (Summerfield *et al.*, 2023). Il existe également des IA commercialisées fonctionnant avec des caméras 3D, comme DeLaval BCS par l'entreprise DeLaval ou BMF par l'entreprise Ingenera SA, dont les performances sont satisfaisantes selon certains auteurs (Mullins *et al.*, 2019 ; O' Leary *et al.*, 2020).

- *Diagnostic précoce de la kérato-conjonctivite infectieuse bovine*

La kérato-conjonctivite infectieuse (KCI) est la maladie oculaire bovine la plus fréquente, avec des retombées économiques importantes et un fort impact sur le bien-être de l'animal. Gupta *et al.* (2023) ont ainsi cherché un paramètre permettant un diagnostic plus précoce. L'épithélium cornéen étant très innervé, les auteurs ont supposé que les stades débutants de la maladie étaient relativement douloureux : une IA pourrait être capable de relever de subtiles modifications de l'apparence du museau afin de s'en servir comme d'un marqueur indirect d'une KCI. Le fonctionnement de l'IA est présenté sur la **Figure 19** et comprend plusieurs étapes : les premiers modèles isolent la tête de l'animal puis identifient où se situe son museau et transmettent la portion de l'image correspondante à un CNN qui prédit l'état de santé. L'IA a été entraînée grâce à une banque de 4 500 images de museau, dont 800 images issues de vaches malades. L'IA finale est capable de détecter des signes de KCI avant les vétérinaires et est parvenue à identifier des animaux malades sans signes cliniques. La sensibilité du modèle atteint 99 % et sa spécificité est de 98 %. Les auteurs soulignent toutefois que d'autres maladies pourraient modifier l'aspect du museau de manière similaire et la spécificité de leur IA nécessite donc davantage de recherche.

Figure 19 : Fonctionnement de l'IA proposée par Gupta *et al.* pour le diagnostic d'une KCI.
Licence [CC BY](https://creativecommons.org/licenses/by/4.0/) (Gupta *et al.*, 2023).



- *Diagnostic précoce d'une anaplasmosse*

L'anaplasmosse bovine est une maladie infectieuse avec d'importantes conséquences économiques pour les élevages. Son diagnostic repose sur des analyses sanguines et microscopiques, longues, coûteuses et difficilement réalisables à l'échelle d'un troupeau. L'utilisation d'une IA pour détecter précocement cette maladie pourrait donc être utile. Teixeira *et al.* (2022) ont développé une IA pouvant identifier efficacement une anaplasmosse chez des veaux jusqu'à trois jours avant l'apparition des signes cliniques. Leur équipe a collecté les données de rumination et d'activité grâce à des colliers portés par 23 veaux âgés d'environ 120 jours, avant, pendant et après l'inoculation d'*Anaplasma marginale*. Des examens cliniques étaient également réalisés quotidiennement. Plusieurs RNN ont ensuite été entraînés avec toutes ou une partie de ces données. Les modèles les plus performants sont ceux utilisant les données des cinq à sept jours précédents, la nature des données n'influençant pas de manière significative leur efficacité : leur précision, sensibilité et spécificité sont comprises entre 90 % et 100 %.

- *Diagnostic de troubles infectieux ou inflammatoires du système nerveux central*

Les troubles du système nerveux central (SNC) sont une cause importante de mortalité et de baisse de la production et du rendement des élevages laitiers. Ferrini *et al.* (2023) ont utilisé les données de 184 vaches italiennes, comprenant notamment leur identification, la localisation du trouble et les résultats d'analyse du liquide cébrospinal, pour les classer en deux catégories (malade ou non malade). Six modèles de ML ont ensuite été entraînés, dans le but d'obtenir une IA capable de diagnostiquer un trouble du SNC et d'aider le vétérinaire dans sa démarche. Le modèle le plus performant obtient une AUC de 0,907 et une précision de 84 %. Ces performances ont par ailleurs motivé le développement d'une application sur internet.

c. L'intelligence artificielle dans les élevages porcins

Les élevages porcins présentent la particularité d'être particulièrement denses et d'avoir une production très élevée. L'observation des animaux par les éleveurs est donc vouée à devenir de plus en plus complexe. Les apports de l'IA porcine sont ainsi nombreux, notamment dans le domaine du diagnostic (S. Wang *et al.*, 2022).

□ L'intelligence artificielle appliquée aux enregistrements sonores

Certains sons produits par les animaux sont la manifestation clinique de maladies porcines, en particulier de troubles respiratoires. Ces maladies, qui peuvent atteindre des taux de mortalité jusqu'à 15 %, pourraient donc être détectées plus facilement grâce à l'IA. Comme pour les autres espèces, les enregistrements sonores sont souvent convertis en spectrogrammes avant d'être analysés par des modèles de ML (CNN, SVM, DT, *etc.*). Les études récentes atteignent des précisions élevées, aux alentours de 95 %, pour la détection d'une toux (S. Wang *et al.*, 2022).

Une des meilleures IA a par exemple été développée par Shen *et al.* (2021). Leur équipe a enregistré 4 551 sons, contenant à la fois des toux et des sons divers (grognements, bruits mécaniques, *etc.*), à l'aide d'un microphone situé à 1,4 m du sol. Une IA composée d'un CNN et d'un SVM a ensuite été entraînée et atteint une précision de 98 %. Des systèmes commerciaux utilisant ce principe existent déjà, comme SoundTalks, commercialisé par l'entreprise Boehringer Ingelheim (Boehringer Ingelheim, 2023).

Les enregistrements sonores peuvent également permettre la détection des œstrus, un exercice habituellement compliqué par la densité des élevages. Chen *et al.* (2021) ont collecté 400 sons d'œstrus pour entraîner un CNN pré-entraîné, qui a atteint une précision finale de 95 %.

□ L'intelligence artificielle appliquée aux enregistrements vidéo

La majorité des IA analysant des images de porcheries utilisent des images de caméras de surveillance, afin d'identifier et de classer le comportement des animaux. Grâce à des algorithmes de *tracking*, chaque porc est suivi et ses caractéristiques comportementales sont enregistrées (prise de boisson, repos, toux, monte, interactions négatives, *etc.*). Un changement de comportement peut alors être interprété (par un humain) pour prévenir certaines maladies (S. Wang *et al.*, 2022).

À l'instar des IA bovines, des équipes ont développé des IA capables de détecter des signes d'œstrus, grâce la détection de comportements de monte sur des images ou des vidéos de surveillance. Li *et al.* (2020) ont par exemple utilisé 192 heures d'enregistrements vidéo pour

entraîner un CNN à détecter différents types de comportement. En particulier, leur IA atteint une précision de 97 % pour la détection des épisodes de monte.

Enfin, un dernier aspect étudié est la détection d'interactions intraspécifiques négatives. Les IA peuvent être développées dans le but de détecter un comportement globalement négatif, par exemple *via* la posture des animaux, ou bien des événements particuliers, comme des morsures à la queue (S. Wang *et al.*, 2022). Hakansson et Jensen (2023) ont par exemple proposé une IA utilisant un CNN qui détecte ces morsures avec une AUC de 0,74 et une précision de 71 %, après l'avoir entraîné avec plus de 200 enregistrements vidéo.

d. L'intelligence artificielle dans les élevages aviaires

- *Diagnostic de maladies infectieuses*

- Grippe aviaire

La grippe aviaire est une maladie réglementée grave et est le sujet de nombreuses recherches sur l'IA. Deux approches sont principalement utilisées : l'analyse sonore de bruits et cris produits par les animaux et l'analyse d'images de surveillance (Franzo *et al.*, 2023).

L'IA développée par Cuan *et al.* (2020) est présentée comme celle ayant les meilleures performances pour l'analyse sonore. Les auteurs ont enregistré 8 000 sons provenant d'animaux sains et d'animaux infectés expérimentalement pour entraîner différents modèles. Le plus performant est un CNN, qui atteint une précision moyenne de 95 %.

Pour le développement de leur IA, Zhuang *et al.* (2018) ont collecté les images de dix poules saines et dix poules infectées expérimentalement. Les auteurs ont ensuite testé différents algorithmes afin d'extraire les informations concernant la posture de l'animal, puis ces informations ont permis d'entraîner un SVM. Le SVM final peut identifier le statut malade ou sain d'un animal avec une précision de 99 %, mais le risque d'*overfitting* reste présent compte-tenu des effectifs réduits. Une autre équipe a utilisé des caméras thermiques pour collecter des images d'animaux sains et infectés (Sadeghi *et al.*, 2023). Après un pré-traitement, les images ont permis d'entraîner un SVM à détecter les animaux malades. L'IA finale atteint une précision de 97 %, une sensibilité de 100 % et une spécificité de 94 %.

- Bronchite infectieuse

Mahdavian *et al.* (2021) ont collecté les sons produits par 150 animaux dans le but d'entraîner une IA à identifier acoustiquement les animaux atteints. Une partie de ces animaux a été infectée expérimentalement. Après un pré-traitement pour isoler les bruits animaux des bruits parasites, les 20 000 sons identifiés ont été utilisés pour entraîner un SVM. Le modèle final peut diagnostiquer la maladie précocement plus efficacement que des experts vétérinaires : l'IA atteint une précision entre 69 % (deux jours après l'inoculation) et 90 % (quatre jours après l'inoculation).

- Maladie de Newcastle

La maladie de Newcastle est une maladie respiratoire réglementée, avec d'importantes répercussions sur le bien-être des animaux et le rendement de l'élevage. Plusieurs équipes ont développé des IA visant à faciliter ou accélérer son diagnostic (Cuan *et al.*, 2022).

Dans leur article, Mahdavian *et al.* (2021) ont également étudié des animaux atteints expérimentalement de la maladie de Newcastle. En suivant le même principe opératoire, leur IA

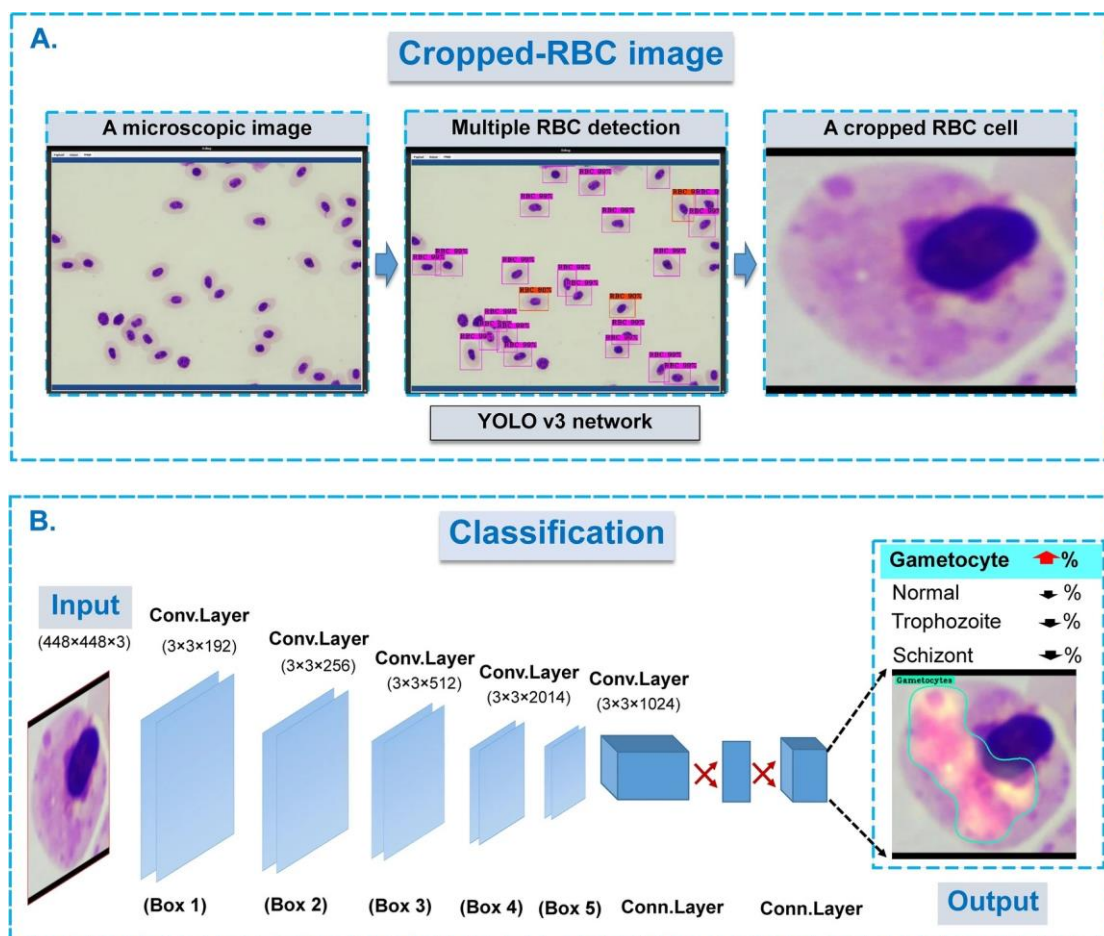
atteint une précision comprise entre 62 % (deux jours après l'inoculation) et 88 % (six jours après l'inoculation), soit une performance similaire ou meilleure que celle d'observateurs humains. L'équipe de Cuan *et al.* (2022), qui avait déjà étudié la grippe aviaire, a développé une autre IA en utilisant les enregistrements sonores d'animaux infectés expérimentalement. Plusieurs modèles ont été testés et le plus performant est un RNN qui atteint une précision comprise entre 82 % et 99 %, selon le nombre de jours après l'inoculation.

□ Paludisme aviaire

Le paludisme aviaire est une maladie causée par un parasite, *Plasmodium gallinaceum*, et est à l'origine d'un taux de mortalité pouvant atteindre 80 % si elle n'est pas traitée. Comme pour l'Homme, le parasite est transmis par des vecteurs et sa présence peut être détectée sur des frottis sanguins. Kittichai *et al.* (2021) ont collecté 432 images de globules rouges infectés par un parasite, sur lesquelles un vétérinaire a identifié le stade évolutif du parasite. Le fonctionnement global de l'IA est présenté sur la **Figure 20**. Après un pré-traitement, ces données ont servi à entraîner un CNN pré-entraîné (YOLOv3) pour qu'il détecte les globules rouges (partie A de la figure). Un second modèle a ensuite été entraîné à détecter la présence du parasite et son stade (partie B de la figure). L'IA finale atteint une précision, une sensibilité et une spécificité de 99 %, ainsi qu'une AUC comprise entre 0,987 et 1,000. Les auteurs notent toutefois le déséquilibre important des données d'entraînement.

Figure 20 : Fonctionnement de l'IA proposée par Kittichai *et al.* pour le diagnostic du paludisme aviaire.

Licence [CC BY](https://creativecommons.org/licenses/by/4.0/) (Kittichai *et al.*, 2021).



□ Entérite nécrotique à *Clostridium perfringens*

Clostridium perfringens est une bactérie anaérobie responsable d'entérites nécrotiques chez les poulets de chair. La maladie se manifeste par des symptômes peu spécifiques et aboutit souvent à la mort de l'animal. Sadeghi *et al.* (2015) ont développé une IA dans le but de détecter les animaux atteints grâce à des différences dans leurs vocalises. Les auteurs ont collecté 30 enregistrements sonores standardisés au sein d'un groupe d'animaux infectés expérimentalement et d'un groupe contrôle. Après un pré-traitement, les données ont été fournies à un NN. Le modèle final est capable d'identifier les animaux malades deux jours après l'inoculation avec une précision de 67 % et huit jours après l'inoculation avec une précision de 100 %. Ces résultats sont issus de faibles effectifs, mais prouvent la faisabilité d'une telle IA.

• *Diagnostic des maladies des poulets de chair*

□ Diagnostic d'une ascite

Une des premières IA étudiant les poulets de chair a été développée par Roush *et al.* (1996). Les auteurs ont collecté les données physiologiques (hématocrite, saturation de l'hémoglobine en oxygène, fréquence cardiaque, etc.) de 171 animaux à intervalles réguliers pendant plusieurs semaines. Au cours de leur étude, les auteurs ont induit expérimentalement une ascite, avant d'euthanasier les animaux quelques semaines plus tard. Ces données ont permis d'entraîner un NN qui atteint une précision de 100 % (Roush *et al.*, 1996). Ce système prouve la faisabilité de l'IA dans ce domaine, mais certains des paramètres mesurés ne peuvent être collectés qu'après la mort de l'animal (le poids du ventricule droit, par exemple) ce qui limite fortement la mise en pratique d'un tel NN.

□ Diagnostic d'une pododermatite de contact

Les pododermatites de contact, ou *hock burns* en anglais, touchent principalement les poulets de chair et surviennent après un contact prolongé avec une litière riche en ammonium. Ces lésions ont différents stades de gravité, allant d'une lésion superficielle à un ulcère profond. Elles traduisent l'état de santé et de bien-être général des animaux. Hepworth *et al.* (2012) ont collecté les données produites en 3 ans par un élevage anglais de plusieurs milliers d'animaux, notamment la surface au sol, le nombre d'animaux et leurs entrées ou sorties. La proportion d'animaux atteints de pododermatites de contact a également été enregistrée auprès de l'abattoir. Au total, 6 912 enregistrements, dont 1 728 cas de dermatites, ont servi à l'entraînement d'un SVM. Le modèle final obtient une AUC de 0,78 et atteint une précision de 78 %.

• *Identification d'une dispersion anormale des animaux*

L'activité physique et la répartition des animaux au sein d'un élevage de poulets de chair est un des indicateurs de la bonne santé des animaux. En particulier pour certaines races très actives, il est possible d'effectuer des rondes et de juger visuellement l'activité des animaux. Cette pratique est toutefois longue et présente un risque d'introduction d'agents pathogènes : l'utilisation d'une IA permettrait d'automatiser ce processus (Chen *et al.*, 2023).

Dans ce contexte, Chen *et al.* ont développé un système automatisé analysant l'activité dans les bâtiments et capable d'identifier des densités ou des mouvements d'animaux anormaux. Des enregistrements vidéo ont été collectés pour créer une base de données de 1 000 images sur lesquelles plus de 146 000 animaux ont été manuellement identifiés. Un premier CNN pré-entraîné (YOLOv7) a été entraîné à reconnaître les animaux sur une image. Un deuxième algorithme

détermine ensuite la densité et la répartition des animaux sur l'image. Enfin, un autre algorithme traque le mouvement des animaux identifiés par le CNN et les quantifie. L'analyse de ces mouvements sur une longue durée a également permis de définir les « mouvements normaux ». Chacun des composants de ce système présente de bonnes performances et le système global a également réussi à identifier les événements anormaux lors d'un test de plusieurs semaines.

e. L'intelligence artificielle pour d'autres animaux de production

La surra est une maladie touchant plusieurs espèces (dont le chien, le chat, le cheval ou le dromadaire) due à une espèce africaine de trypanosome, *Trypanosoma evansi*, transmise par des animaux hématophages. La forme aiguë de la maladie se manifeste notamment par une anémie, une anorexie ou des avortements et son issue est le plus souvent fatale. Benfodil *et al.* (2022) ont collecté les données de 115 dromadaires algériens (âge, sexe, historique médical, *etc.*) et le résultat de leur test sérologique, pour entraîner un NN. Après l'entraînement, l'IA obtenue atteint une précision de 93 %, mais les effectifs sont réduits et déséquilibrés.

Les élevages de truites arc-en-ciel peuvent également connaître des épisodes infectieux. Plusieurs espèces sont fréquemment impliquées, comme *Lactococcus garvieae* et *Vagococcus* spp., et ont des conséquences économiques parfois importantes. Yilmaz *et al.* (2023) ont développé une IA visant à diagnostiquer précocement ces infections. Les auteurs ont collecté les données environnementales dans un élevage (température, pH, concentrations en oxygène, *etc.*) deux fois par mois pendant trois mois. Les auteurs ont également mesuré les concentrations en métaux lourds (chrome, cuivre, cadmium et plomb), compte-tenu de leurs effets connus sur l'organisme des poissons. Plusieurs modèles de ML ont été entraînés et le plus performant est un SVM, qui atteint une précision, une sensibilité et une spécificité de 93 %, 100 % et 75 % respectivement.

f. Les intelligences artificielles comme modèles de prédiction de foyers infectieux

La plupart des modèles épidémiologiques actuels sont issus de régressions logistiques, qui sont plus adaptées à l'identification de facteurs de risques qu'à la prédiction. Des modèles de ML pourraient être donc utilisés conjointement avec les modèles de prédiction déjà existants, permettant à l'IA de nouveaux apports diagnostics (Punyapornwithaya *et al.*, 2022).

- *Modèles de maladies des ruminants*

- Fièvre aphteuse

La fièvre aphteuse est une maladie contagieuse, à l'origine de vésicules épidermiques douloureuses évoluant en ulcères, surtout dans la région de la bouche et des sabots. Les conséquences économiques de la maladie sont également très importantes, justifiant sa réglementation dans de nombreux pays. La prédiction d'un foyer de fièvre aphteuse, grâce à l'IA, constitue donc un intérêt majeur. Punyapornwithaya *et al.* (2022) ont collecté les données d'élevages (introduction récente d'animaux, pâturage ou non, source d'eau, présence d'axes de transport, *etc.*) de 833 fermes impliquées dans des enquêtes suite à des foyers de fièvre aphteuse en Thaïlande. Plusieurs modèles ont ensuite été entraînés. Le plus performant est une RF, qui présente une AUC de 0,83, une précision de 74 %, une sensibilité de 32 % et une spécificité de

88 %. Ce modèle présente donc des performances acceptables, ce qui permettrait d'améliorer l'efficacité des systèmes thaïlandais déjà en place.

□ Tuberculose bovine

La tuberculose bovine est une maladie réglementée dont le diagnostic repose sur des tests cutanés (intradermotuberculation simple ou comparative). Ces tests requièrent un délai de quelques jours avant leur interprétation et sont imparfaits, compliquant l'élaboration de plans d'action contre la maladie (Romero *et al.*, 2022). Les apports de l'IA concernant le diagnostic de la tuberculose sont donc multiples et plusieurs approches ont déjà été développées.

Denholm *et al.* (2020) rapportent le développement d'un CNN capable d'identifier des vaches positives au test cutané à partir d'une analyse de lait. Les auteurs ont collecté les données de plus de 1,6 millions d'animaux anglais entre 2012 et 2019, dont la composition de leur lait et son spectre en lumière infrarouge, les données de reproduction et leur statut vis-à-vis de la maladie. L'IA finale atteint une précision de 95 %, une sensibilité de 96 % et une spécificité de 94 %. Son utilisation ne nécessite par ailleurs pas de matériel spécialisé ou de changement des méthodes d'élevage ; elle pourrait donc permettre aux éleveurs de détecter précocement les animaux malades pour les retirer du troupeau et limiter la propagation de la maladie.

Entre 2020 et 2022, l'équipe de Romero *et al.* a publié une série d'articles détaillant le développement d'une IA pour améliorer la gestion de foyers de tuberculose bovine au Royaume-Uni. Ils ont ainsi obtenu une RF capable de prédire la survenue d'un cas de tuberculose dans une zone donnée, en fonction d'une dizaine de paramètres comme la date du dernier incident ou les résultats des précédents tests (Romero *et al.*, 2021). Les performances varient selon la zone étudiée, mais restent élevées. Une deuxième RF permet quant à elle de prédire si un troupeau présentant un résultat d'intradermotuberculation douteux obtiendra un résultat positif lors du second test 60 jours plus tard (Romero *et al.*, 2022). L'IA atteint une AUC supérieure à 0,80, son utilisation permettrait donc d'éviter une propagation de la maladie durant ces deux mois.

□ Peste des petits ruminants

La peste des petits ruminants est une maladie réglementée touchant principalement les moutons et les chèvres. La maladie est aiguë et fatale chez les caprins, où les animaux sont apathiques, avec de la fièvre, des sécrétions nasales ou oculaires et une diarrhée. Elle est plus souvent subaiguë ou inapparente chez les ovins. Pour prédire le risque de survenue d'un foyer infectieux, Niu *et al.* (2020), ont d'abord collecté les données épidémiologiques des précédentes crises entre 2008 et 2018, ainsi que les données météorologiques les concernant (notamment la température, le niveau de précipitations, l'altitude, *etc.*). Une partie de ces données a permis l'entraînement de plusieurs modèles. Le plus performant est une RF qui atteint une précision de 99 %, une sensibilité de 98 % et une spécificité de 99,9 %.

• *Modèles de maladies aviaires*

□ Influenza aviaire

L'influenza aviaire est une maladie réglementée aux conséquences économiques importantes et causée par un virus dont il existe de nombreux sous-types (voir **p. 64**). Certaines souches présentent également un danger zoonotique. Face à ces enjeux, plusieurs équipes ont cherché à améliorer les modèles prédictifs actuels. Liu *et al.* (2023) ont collecté les données épidémiologiques des crises dues à la souche H9N2 (date, mortalité, *etc.*) et certaines données

météorologiques associées (température, humidité, *etc.*). Ces données ont permis d'entraîner une RF à identifier un élevage susceptible d'être atteint dans les trois prochains jours. L'IA finale atteint une AUC de plus de 0,85 et une précision d'environ 92 %.

□ Contamination d'un élevage par *Listeria* spp.

Le genre *Listeria* comprend plusieurs espèces, dont *L. monocytogenes*, à l'origine d'une infection zoonotique. Son contrôle représente donc un enjeu de santé publique. Golden *et al.* (2019) ont collecté des échantillons de sol de pâture et d'excréments, ainsi que les données météorologiques de plusieurs élevages pour entraîner une IA à prédire le risque de contamination d'un élevage par *Listeria* spp., car la présence de ce genre de bactérie augmente la probabilité de la présence de *L. monocytogenes*. Plus de 1 500 échantillons ont été prélevés dans onze élevages en plein air, ainsi que les paramètres météorologiques associés, comme la température, la vitesse du vent et la quantité de précipitations. Plusieurs modèles ont été entraînés et le plus performant est une RF modifiée, qui atteint une AUC de 0,905, une sensibilité de 79 % et une spécificité de 87 %.

• *Modèles de maladies porcines*

L'industrie porcine est très sensible aux crises sanitaires, notamment à cause des fortes densités de population en élevage. Des maladies bactériennes ou virales peuvent notamment provoquer des diarrhées ou des troubles respiratoires, à l'origine d'une mortalité pouvant atteindre jusqu'à 10 % dans les cas extrêmes. Les modalités d'élevage rendent difficile une surveillance par les éleveurs et les vétérinaires, qui pourraient donc bénéficier de l'aide d'une IA pour prédire l'apparition d'un foyer infectieux et y remédier le plus rapidement possible (Halev *et al.*, 2023).

□ Diarrhée épidémique porcine

Une des premières applications du ML dans ce domaine concerne la prédiction de crises dues au virus de la diarrhée épidémique porcine, un virus responsable de diarrhées parfois fatales chez le jeune (Machado *et al.*, 2019).

Machado *et al.* ont utilisé les données de 980 élevages impliqués dans l'épidémie de 2014 aux États-Unis pour entraîner une IA à prédire la survenue d'une crise avec quelques jours d'avance. Ces données incluent notamment les mouvements des animaux, les informations sur les élevages voisins et les données environnementales (vent, température, *etc.*) sur l'ensemble de l'année 2014. L'IA finale utilise une RF, qui obtient une AUC de 0,96, une précision de 97 %, une sensibilité de 65 % et une spécificité de 95 %.

Une étude similaire a été menée par Paploski *et al.* (2021). Leur équipe a développé une IA capable de prédire pratiquement en temps réel la survenue d'un foyer infectieux. Leur modèle utilise les informations des cinq semaines précédentes, mais tient aussi compte des mouvements d'animaux prévus pour la semaine à venir. Les auteurs insistent cependant sur leur jeu de données peu équilibré, qui pourrait fausser la précision de 99 % de leur IA.

□ Peste porcine africaine

La peste porcine africaine est une fièvre hémorragique mortelle et ses conséquences socioéconomiques justifient sa réglementation dans de nombreux pays. Pour leur étude, Liang *et al.* (2020) ont collecté les informations concernant les crises enregistrées par l'Organisation mondiale de la santé animale (lieux, date, nombre d'animaux, *etc.*) et les données météorologiques les concernant. Le plus performant des modèles entraînés est une RF, qui peut

prédire la survenue d'un foyer avec une précision, une sensibilité et une spécificité de 80 %, 69 % et 90 % respectivement et obtient une AUC de 0,972.

□ Syndrome dysgénésique et respiratoire du porc

Ce syndrome est causé par un virus à l'origine de troubles de la reproduction, de pneumonies et d'une sensibilité accrue à des infections bactériennes. De façon similaire aux études précédentes, Shamsabardeh *et al.* (2022) ont utilisé les données météorologiques et les mouvements des animaux d'élevages américains, pour entraîner plusieurs modèles. La RF est le modèle final le plus performant, avec une AUC de 0,88.

□ Approche globale

Halev *et al.* (2023) ont récemment tenté une approche globale, en élaborant une IA capable de prédire une diarrhée épidémique porcine, un syndrome dysgénésique et respiratoire, une grippe et une infection à *Mycoplasma hyopneumoniae* dans les sept jours suivants ou dans le mois à venir. Leur équipe a pour cela collecté les données de plusieurs élevages américains (densité de population, élevages voisins, conditions météorologiques, *etc.*) et les résultats de tests diagnostiques pour ces maladies afin d'entraîner plusieurs modèles. Le plus performant est une RF, qui atteint une précision moyenne de 85 %.


• *Modèle de crises de norovirus dues aux huîtres*

Les norovirus sont un genre de virus responsables de la majeure partie des gastro-entérites non bactériennes chez l'Homme. En particulier, ces virus peuvent être accumulés par les huîtres lorsque l'eau de leur élevage est contaminée. Une accumulation trop importante lors de la période de récolte est donc un enjeu important de santé publique et l'usage de l'IA pourrait permettre de prédire l'apparition d'un foyer infectieux (Chenar et Deng, 2018).

Chenar et Deng ont développé une IA capable de prédire ces crises deux jours à l'avance, en utilisant six paramètres collectés quotidiennement dans la partie américaine du golfe du Mexique. Pour l'entraîner, ils ont collecté les données épidémiologiques (dates, lieu, durée, *etc.*) des crises enregistrées entre 1996 et 2010, ainsi que les données environnementales des élevages (température, hauteur et salinité de l'eau, précipitations, vent et intensité des radiations solaires). Le modèle final est un NN capable de prédire une crise deux jours avant sa venue. Ses performances ont été mesurées en comparant les crises enregistrées entre 2011 et 2014 et les prédictions de l'IA avec les données collectées durant cette période, comme illustré sur la **Figure 21**. Le modèle obtient une AUC de 0,80 et atteint une précision de 99,8 %, une sensibilité et 100 % et une spécificité de 99,8 %.

Figure 21 : Prédiction de la survenue d'un foyer de norovirus dans la baie de la Louisiane entre 2011 et 2014 selon l'IA proposée par Chenar et Deng.

Utilisée avec l'autorisation de Chenar et Deng (2018).



B. L'intelligence artificielle : un outil d'aide au diagnostic pour les animaux de compagnie et les chevaux

Si les applications de l'IA concernent historiquement les animaux de production, l'essor récent du *Big Data*, du ML et des objets connectés laissent présager un usage de plus en plus important pour les animaux de compagnie (McCue et McCoy, 2017). Il existe encore peu d'IA prédictives pour les animaux de compagnie et peu d'IA pour l'espèce féline : la majorité des IA sont à destination des chiens et permettent d'assister le vétérinaire dans diverses démarches diagnostiques.

a. L'intelligence artificielle prédictive pour les animaux de compagnie et les chevaux

- *Prédiction de la nécessité d'une prise chirurgicale d'une colique chez le cheval*

Les coliques sont une des affections les plus fréquemment rencontrées par les praticiens équin. Leur origine est variée, car il peut s'agir de spasmes coliques bénins comme d'une obstruction pouvant être fatale. La majorité des coliques est traitée médicalement et entre 4 % à 10 % des cas nécessitent une intervention chirurgicale. Pour accélérer et faciliter cette prise en charge, Fraiwan et Abutarbush (2020) ont développé une IA visant à déterminer la nécessité chirurgicale et le pronostic de cette chirurgie lorsqu'un cheval présente une colique. Les auteurs ont collecté les dossiers médicaux de 285 chevaux présentés avec des signes cliniques évoquant uniquement une colique. Les données pertinentes (âge, sexe, durée des symptômes, chirurgie effectuée, etc.) ont été extraites pour entraîner plusieurs modèles. L'IA finale utilise une RF pour déterminer si les conditions de l'animal nécessitent une chirurgie et un réseau bayésien pour déterminer s'il survivra à cette chirurgie, avec des précisions de 74 % et 97 % respectivement.

- *Prédiction d'une rupture du ligament croisé antérieur chez le Labrador Retriever*

La rupture du ligament croisé antérieur est une affection fréquente du chien, à laquelle certaines races sont prédisposées. Dans ce contexte, Baker *et al.* (2020) ont développé une IA dans le but de prédire la survenue d'une rupture du ligament croisé en utilisant les informations génétiques de l'animal. Les auteurs ont collecté puis séquencé l'ADN de 622 labradors. Le statut médical de chaque animal a été évalué cliniquement par un spécialiste, puis la rupture du ligament a été confirmée lors d'une chirurgie. Ces données ont permis d'entraîner plusieurs modèles, en prenant ou non en compte plusieurs facteurs de confusion (poids, sexe, etc.). La RF prenant en compte ces facteurs de confusion est le modèle le plus performant, avec une AUC de 0,702, bien que davantage de données d'entraînement soient nécessaires pour améliorer sa précision.

- *Prédiction d'une maladie rénale chronique chez le chien ou le chat*

Bradley *et al.* (2019) sont parmi les premiers à avoir développé une IA pouvant efficacement déterminer le risque d'apparition d'une maladie rénale chronique (MRC) dans les deux ans suivant l'examen. Cette IA est commercialisée sous le nom RenalTech par la société Antech, une filiale américaine de *Mars Incorporated* depuis 2017. Bradley *et al.* ont utilisé les données de plus de 100 000 chats âgés de 1,5 à 22 ans et présentés dans un des centres *Banfield Pet Hospital* (voir **p. 14**) au moins trois fois entre 1995 et 2017. Ces données comprenaient notamment les informations de l'animal et ses résultats d'analyses urinaires et sanguines, soit 35 variables au total. Une étape d'extraction/sélection (voir **p. 19**) a permis de ne conserver que les quatre

variables les plus importantes : l'âge lors de la consultation, la concentration plasmatique en créatinine, la fraction azotée de l'urée dans le sang (BUN) et la densité urinaire. Après son entraînement, un RNN est capable d'utiliser les valeurs historiques de ces paramètres pour prédire une MRC imminente avec une sensibilité de 91 % et une spécificité de 99 %. Il peut également prédire la survenue d'une MRC dans les 12 mois suivants avec une sensibilité de 63 % et dans les 24 mois suivants avec une sensibilité de 44 %. Dans les deux cas, la spécificité est de 99 %. Cette IA a donc un potentiel clinique important, car elle ne requiert que des examens réalisés en routine et présente une bonne précision.

Biourge *et al.* (2020), dans une autre étude financée par *Mars Incorporated*, ont travaillé sur une IA visant à mieux prédire la survenue d'une MRC chez les chats âgés. Contrairement aux travaux de Bradley *et al.*, cette IA est conçue pour être efficace dès la première visite. Elle n'a pas besoin de l'historique des animaux, mais réalise des prédictions pour les 12 mois suivants seulement. Les auteurs ont collecté les données de 218 chats présentés au moins deux fois au *Royal Veterinary College* (Londres) pour l'entraînement et les données de plus de 3 500 chats présentés au *Royal Veterinary College* ou dans un des centres *Banfield Pet Hospital* pour la validation de ses performances. La seconde consultation permet de confirmer l'absence de MRC dans les 12 mois suivant la visite. L'étape d'extraction/sélection a permis de ne conserver que trois paramètres : la concentration plasmatique en créatinine, la fraction azotée de l'urée dans le sang et la densité urinaire. Le modèle final peut prédire l'apparition d'une MRC dans les 12 mois suivant la visite d'un chat de plus de sept ans avec une précision, une sensibilité et une spécificité de 88 %, 87 % et 70 % respectivement.

L'équipe de Kokkinos *et al.* (2022) a étudié un concept similaire chez le chien. Les auteurs ont collecté les données de plus de 50 000 chiens pour développer une IA capable de prédire la survenue d'une MRC chez un chien dans les 24 mois suivant sa consultation. L'extraction/sélection des données a permis d'entraîner un RNN avec six paramètres : l'âge et le poids lors de la consultation, la concentration plasmatique en créatinine, la fraction azotée de l'urée dans le sang ainsi que la densité urinaire et la concentration urinaire en protéines. Le modèle final peut détecter une MRC imminente avec une précision de 93 %, une sensibilité de 91 % et une spécificité de 97 %. Il peut également déterminer la survenue d'une MRC dans les 12 mois avec une précision, une sensibilité et une spécificité de 85 %, 69 % et 98 % respectivement et dans les 24 mois avec une précision, une sensibilité et une spécificité de 73 %, 45 % et 99 % respectivement. En particulier, la valeur prédictive négative du modèle est de plus de 99 % quelle que soit la période de prédiction envisagée, faisant de l'IA un outil efficace pour identifier les patients à faible risque.

b. L'intelligence artificielle, un outil encore orienté vers l'espèce canine

- ***Détection d'une crise prurigineuse grâce au collier Whistle FIT***


Carson *et al.* (2023) ont étudié les effets de l'utilisation d'un accéléromètre embarqué (dans le collier *Whistle FIT*, déjà commercialisé par l'entreprise Mars Petcare) sur la détection du prurit et sa prise en charge par les vétérinaires et les propriétaires. Ce collier est couplé à une application qui utilise une IA (dont le fonctionnement a déjà été validé dans d'autres études) pour identifier le comportement et l'activité des chiens. Les auteurs ont utilisé les informations de plus de 1 000 chiens et ont pu démontrer l'intérêt de l'IA, puisque le taux de consultation chez un vétérinaire était significativement différent lors de l'émission d'une alerte d'un épisode prurigineux.

- *Diagnostic d'une pododermatite et d'une masse tumorale*

Smith *et al.* (2023) ont développé une IA visant à diagnostiquer la présence d'une pododermatite ou d'une masse tumorale (carcinome épidermoïde, mélanome, ostéosarcome, mastocytome ou autre sarcome des tissus mous). Les auteurs ont collecté 575 images de la face palmaire d'une patte, permettant la création de trois jeux d'entraînement afin de tester l'influence des méthodes d'annotation. Chaque jeu de données a été annoté par un ou plusieurs vétérinaires, avant de permettre l'entraînement de différents CNN pré-entraînés (YOLOv4, 5 ou 7). Le diagnostic d'une masse tumorale a par ailleurs été établi après la réalisation d'examens complémentaires. Les analyses réalisées par chacun des modèles et pour les trois jeux de données créés sont présentées sur la **Figure 22**. Le meilleur modèle est celui où les données ont été annotées par un unique observateur pour entraîner Tiny YOLOv4 : l'IA atteint alors une précision de 86 %.

Figure 22 : Interprétations de trois images par les modèles proposés par Smith *et al.* pour diagnostiquer une patte saine, une pododermatite ou une masse tumorale chez le chien.

Licence [CC BY-NC](https://creativecommons.org/licenses/by-nc/4.0/) (Smith *et al.*, 2023).



- *Diagnostic précoce d'un syndrome obstructif respiratoire des races brachycéphales*

Le syndrome obstructif respiratoire des races brachycéphales (SORB) est un syndrome obstructif des voies respiratoires supérieures d'origine anatomique. De nombreuses structures respiratoires sont concernées et une prise en charge précoce permet d'améliorer le bien-être des chiens atteints. Cependant, le diagnostic clinique habituellement réalisé est subjectif et dépend de

l'expérience du praticien. Une IA pourrait donc permettre de détecter un SORB plus tôt et de manière standardisée. Oren *et al.* (2023) ont élaboré une IA permettant d'identifier un SORB grâce à l'analyse d'un enregistrement de bruits respiratoires. Les auteurs ont enregistré 366 sons à l'aide d'un stéthoscope électronique, produits par 148 chiens brachycéphales (majoritairement des carlins). Ces sons ont été enregistrés avant et après un test d'effort de 15 minutes. Ils ont ensuite été décrits par des vétérinaires, en distinguant notamment leur intensité et leur origine (stridor, stertor, *etc.*). Après une extraction/sélection des données, les caractéristiques les plus importantes ont permis d'entraîner un ensemble de modèles (voir p. 26). L'IA finale atteint une précision entre 65 % et 85 % selon les races.

- *Diagnostic de maladies infectieuses grâce à l'intelligence artificielle*

- Diagnostic d'une leishmaniose

La leishmaniose est une maladie infectieuse zoonotique, présente notamment en Amérique Latine sous une forme viscérale pouvant être mortelle. Les chiens représentent un important réservoir de la maladie et un diagnostic rapide, par exemple grâce à l'IA, constitue donc un enjeu majeur pour le contrôle de la maladie (Larios *et al.*, 2021).

Plusieurs équipes ont développé des approches diagnostiques utilisant une IA. Une équipe a par exemple utilisé uniquement des signes cliniques courants (dermatite, alopecie, uvéite, onychogryphose, *etc.*) et un NN pour déterminer la présence du parasite (Torrecilha *et al.*, 2017). Les auteurs ont utilisé les informations de 55 chiens (parmi lesquels 35 ont eu un test PCR positif) pour entraîner leur IA qui atteint une précision finale de 87 %. Cette IA pourrait donc remplacer avantageusement un test PCR lorsque celui-ci n'est pas disponible.

Une autre approche repose sur une analyse spectrophotométrique. Larios *et al.* (2021) ont par exemple développé une méthode diagnostique reposant sur l'analyse en lumière infrarouge d'un échantillon de sérum. Les auteurs ont entraîné plusieurs modèles avec les analyses de 144 échantillons canins, dont 84 prélevés sur des animaux malades. Ces échantillons incluaient par ailleurs ceux d'animaux infectés par *Trypanosoma evansi*, pour lesquels les tests diagnostiques de la leishmaniose sont souvent faussement positifs. L'IA finale atteint une précision globale comprise entre 85 % et 100 %. Plus récemment, Coelho *et al.* (2023) ont utilisé l'analyse en lumière ultraviolette pour parvenir à un diagnostic. Leur équipe a collecté les échantillons sanguins de 52 chiens, dont la moitié étaient infectés, pour entraîner plusieurs modèles. Le SVM est le modèle le plus performant et peut identifier un animal infecté avec une précision moyenne de 75 %.

- Diagnostic précoce d'une leptospirose

La leptospirose est une maladie bactérienne zoonotique aux manifestations cliniques variées et pouvant être graves. Toutefois, une prise en charge précoce est associée à un bon pronostic. Un diagnostic rapide est donc nécessaire et l'IA pourrait être un meilleur outil que ceux disponibles actuellement. Reagan *et al.* (2022a) se sont intéressés au développement d'une IA utilisant des résultats d'analyses de routine, comme un hémogramme, une analyse biochimique et une analyse d'urine. Ces données ont été collectées auprès de 413 chiens, dont 91 cas de leptospirose. Plusieurs SVM ont ensuite été entraînés avec une partie des données. Les modèles finaux obtiennent une AUC entre 0,955 et 0,959, une sensibilité de 100 % et une spécificité comprise entre 91 % et 93 %, ils sont donc plus performants que les outils de diagnostic précoce actuels.

□ Diagnostic d'une infection par *Babesia canis*

Babesia canis est un parasite des globules rouges transmis par les tiques et responsable de la piroplasmose. Cette maladie grave se manifeste par des anomalies à l'hémogramme, comme une anémie ou une thrombocytopenie. Pijnacker *et al.* (2022) ont développé une IA visant à déterminer la présence du parasite, selon les paramètres sanguins de l'animal. Les auteurs ont collecté les hémogrammes de 357 animaux, dont 63 cas confirmés par un frottis sanguin ou une PCR, pour entraîner plusieurs modèles. Le plus performant est une RF et obtient une AUC de 0,994, une sensibilité de 100 % et une spécificité de 96 %. En utilisant SHAP, les auteurs ont également déterminé que la numération et la concentration plaquettaire, le volume plaquettaire moyen et la numération des éosinophiles et neutrophiles étaient les paramètres les plus importants.

• *Diagnostic de maladies endocriniennes grâce à l'intelligence artificielle*

□ Diagnostic d'une hypothyroïdie

Le diagnostic d'une hypothyroïdie peut être compliqué, car les tests réalisés habituellement comme le dosage de l'hormone T4 ou de l'hormone thyroïdienne peuvent être modifiés par de nombreux facteurs. Ainsi, l'usage d'une IA pourrait assister le praticien dans sa démarche ou éviter la réalisation de tests ou traitements inutiles. Dans ce contexte, Corsini *et al.* (2023) ont collecté les données de 315 chiens pour entraîner leur IA. Ces données comprenaient notamment un hémogramme et un bilan biochimique habituel. Les résultats de tests fonctionnels thyroïdiens ont permis d'établir le diagnostic : aucun animal présentant des résultats équivoques n'a été inclus dans l'étude et 82 animaux présentaient une hypothyroïdie. Après une extraction/sélection, les auteurs ont conservé les paramètres suivants : présence d'anomalies cutanées ou d'abattement, valeur de l'hématocrite et concentrations plasmatiques en cholestérol, créatinine, T4 totale et hormone thyroïdienne. Plusieurs modèles ont ensuite été entraînés, avec tous ou une partie des paramètres cités. L'IA finale présente des performances encourageantes, avec une précision comprise entre 85 % et 97 %. Les auteurs n'ont toutefois pas utilisé de données indépendantes (qui n'ont pas servi à entraîner les modèles) pour obtenir ces statistiques : d'autres études seront encore nécessaires pour confirmer l'efficacité de ces modèles.

□ Diagnostic d'une maladie d'Addison

La maladie d'Addison est un hypocorticisme pouvant mettre en jeu la vie de l'animal. Dans sa forme chronique, la maladie présente cependant des signes frustes ou communs à d'autres maladies, à l'origine d'un probable sous-diagnostic. L'utilisation d'une IA pourrait donc permettre de prendre en charge plus efficacement les patients. Reagan *et al.* (2020) sont parmi les premiers à développer une IA permettant le diagnostic de cette maladie grâce à des examens réalisés en routine. Les auteurs ont tout d'abord collecté les hémogrammes et les résultats d'examens biochimiques de 1 041 chiens pour lesquels un dosage du cortisol avait également été réalisé. Un diagnostic positif a été établi pour 133 animaux. Une RF modifiée a ensuite été entraînée avec une partie de ces données. L'IA finale atteint une AUC de 0,994, une sensibilité de 96 % et une spécificité de 97 %, prouvant son utilité chez les animaux présentant des signes ou des anomalies sanguines frustes mais compatibles avec une maladie d'Addison. La même équipe a continué ces travaux en 2022 en prouvant que leur IA était utilisable chez tous les animaux, qu'ils présentent des signes évocateurs ou non, motivant par ailleurs le dépôt d'un brevet (Reagan *et al.*, 2022b).

□ Diagnostic d'une maladie de Cushing

Le diagnostic d'une maladie de Cushing peut être compliqué à réaliser rapidement, compte-tenu des signes cliniques pouvant ressembler aux symptômes d'autres maladies et des différents tests à réaliser. Une IA pourrait permettre un triage et un diagnostic plus rapide. Pour développer leur IA, Schofield *et al.* (2021) ont donc collecté les données de 1 000 chiens aux signes évocateurs, grâce au programme VetCompass (voir p. 15). Le diagnostic d'une maladie de Cushing a effectivement été établi pour 419 d'entre eux. Après une extraction/sélection, les principaux signes cliniques et paramètres biochimiques de ces animaux ont permis d'entraîner plusieurs modèles. L'IA finale obtient une AUC de 0,85, une sensibilité de 71 % et une spécificité de 82 %.

• *Diagnostic de maladies oculaires grâce à l'intelligence artificielles*

□ Diagnostic d'un ulcère cornéen


Kim *et al.* (2019) ont développé une IA capable de distinguer une cornée saine d'une cornée atteinte d'un ulcère superficiel ou profond. Les auteurs ont collecté 130 images de cornées (36 saines, 47 présentant un ulcère superficiel et 47 présentant un ulcère profond) provenant de chiens. Toutes les images ont été obtenues sans coloration à la fluorescéine et ont été classées par le vétérinaire spécialiste ayant pris l'image. Après un pré-traitement, une partie des données a permis d'entraîner des CNN pré-entraînés. Tous les modèles dépassent 90 % de précision.

□ Diagnostic d'une kérato-conjonctivite sèche

La kérato-conjonctivite sèche (KCS) est un trouble du film lacrymal. Le test de Schirmer permet un diagnostic en pratique généraliste, mais il est peu reproductible et parfois peu fiable. Des techniques de mesures non invasives du temps de rupture existent, mais ne sont utilisées que dans les plus grandes structures. Dans ce contexte, J. Y. Kim *et al.* (2022) ont développé une IA pouvant assister un praticien n'ayant pas ce matériel à diagnostiquer une KCS de manière plus fiable. Les auteurs ont conçu un test utilisant une lampe à fente pour projeter une grille de lumière sur la cornée de l'animal, comme illustré sur la **Figure 23**. Ce dispositif a ensuite permis d'enregistrer 95 vidéos issues de 52 chiens, afin d'entraîner un CNN pré-entraîné (YOLOv5). Le modèle final est capable de déterminer si la réflexion visible sur la cornée est normale ou non avec une précision de 94 %.

Figure 23 : Images de cornées utilisées pour l'entraînement de l'IA proposée par Kim *et al.* pour le diagnostic d'une KCS chez le chien.

Licence [CC BY](https://creativecommons.org/licenses/by/4.0/) (J. Y. Kim *et al.*, 2022).



- *Diagnostic de troubles locomoteurs grâce à l'intelligence artificielle*

L'évaluation des troubles locomoteurs, qu'ils soient d'origine orthopédiques ou neurologiques, présente un degré de subjectivité important, même lorsqu'elle est menée par un spécialiste. L'usage d'une IA permettrait donc de normaliser et de faciliter ce diagnostic (Engelsman *et al.*, 2022 ; Figueirinhas *et al.*, 2022).

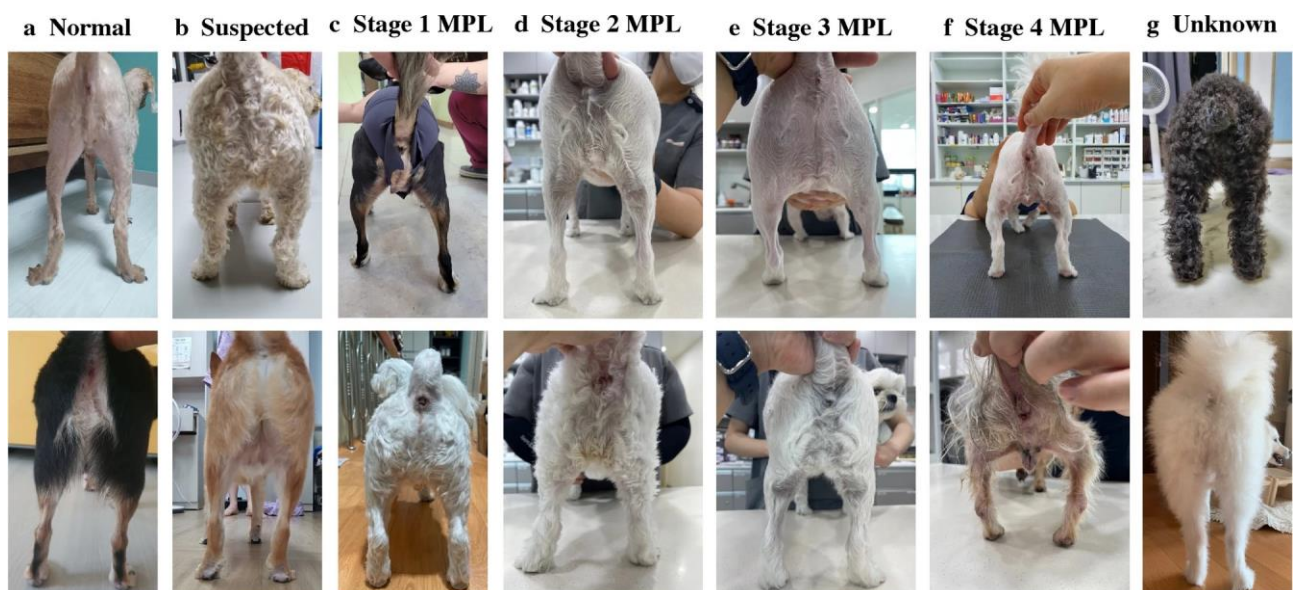
Une équipe s'est par exemple intéressée au développement d'une IA pour évaluer une démarche ataxique (Engelsman *et al.*, 2022). À l'aide d'un téléphone portable placé sur le dos de l'animal, les auteurs ont collecté les enregistrements de 78 chiens, dont 23 étaient ataxiques, au cours d'une consultation dans un service de neurologie. Plusieurs modèles ont été entraînés et le plus performant est capable de diagnostiquer une démarche ataxique avec une précision de 96 %.

Une seconde équipe rapporte une preuve de concept concernant une IA capable de diagnostiquer une boiterie d'un membre pelvien (Figueirinhas *et al.*, 2022). Les auteurs ont utilisé des accéléromètres pour collecter les données de 12 chiens, dont 5 boiteux, afin d'entraîner un RNN. Les auteurs rapportent une précision finale de 86 %, mais soulignent que l'IA a été testée avec de nouvelles données issues de trois chiens seulement.

Récemment, Jung *et al.* (2023) ont développé une IA pour identifier une luxation médiale de la rotule à l'aide d'une seule image où les deux membres postérieurs sont visibles. Leur IA fonctionne en deux parties : un CNN pré-entraîné analyse et extrait les caractéristiques de l'image, puis les caractéristiques les plus importantes sont transmises à un ensemble de modèles qui détermine si le chien est atteint ou non. Les auteurs ont collecté 2 563 images provenant de races variées, dont quelques exemples sont illustrés sur la **Figure 24**. Le diagnostic était établi par le vétérinaire examinant le chien lors de la prise de vue. Après un pré-traitement, une partie des images a permis d'entraîner une IA qui atteint une précision de 93 %. Les auteurs ont également comparé ses performances avec des vétérinaires expérimentés sur un jeu d'images inédites. L'IA atteint alors une précision de 93 % alors que les vétérinaires n'atteignent que 56 %.

Figure 24 : Images utilisées pour l'entraînement de l'IA proposée par Jung *et al.* pour le diagnostic d'une luxation médiale de la rotule chez le chien.

Licence [CC BY](https://creativecommons.org/licenses/by/4.0/) (Jung *et al.*, 2023).



c. L'émergence de l'intelligence artificielle chez le chat

Un des rares domaines d'intérêt pour les IA félines actuelles est la distinction entre un lymphome intestinal et une maladie inflammatoire chronique de l'intestin. Ces maladies sont deux troubles gastrointestinaux fréquents chez le chat, mais leur aspect échographique est semblable, rendant parfois complexe l'établissement d'un diagnostic en l'absence d'une analyse histologique réalisée sur une biopsie (Awaysheh *et al.*, 2016).

Awaysheh *et al.* ont ainsi développé une IA capable de déterminer si un animal est sain, atteint d'un lymphome ou atteint d'une maladie inflammatoire à partir d'un hémogramme et d'un bilan biochimique. Les auteurs ont collecté les données de 120 chats, répartis en trois groupes de 40 animaux. Le diagnostic final des animaux malades a été établi grâce à l'analyse histologique d'une biopsie réalisée par endoscopie. Ces données ont permis d'entraîner différents modèles, le meilleur étant un réseau bayésien. Ce dernier atteint une AUC de 0,83, une sensibilité moyenne de 73 % et une spécificité moyenne de 85 %. En particulier, il est plus efficace pour distinguer les animaux sains des animaux malades.

D'autres études permettant d'aider le praticien à interpréter des images échographiques ambiguës sont présentées page 84 et des IA assistant l'anatomopathologiste dans sa démarche, notamment lors de biopsie endoscopique ambiguë, sont présentées page 91.

d. L'intelligence artificielle équine

• Diagnostic d'une uvéite

May *et al.* (2022) ont développé une IA permettant de diagnostiquer une uvéite récurrente équine, une maladie débilitante pouvant aboutir à une cécité permanente. Les auteurs ont collecté 2 607 images sur plus de 650 chevaux. Chaque cheval a été examiné par un spécialiste grâce à la réalisation d'un examen ophtalmologique complet, permettant ensuite d'établir un diagnostic. Chaque image a alors été classée comme « normale », « uvéite » ou « autre maladie ». Les images ont par ailleurs été prises dans différentes conditions d'éclairage et selon différents angles pour une meilleure représentativité. Après un pré-traitement, ces données ont permis d'entraîner un CNN. L'IA finale atteint une précision de 97 %, motivant le développement d'une application internet pour illustrer la faisabilité d'une mise en pratique. Les auteurs soulignent toutefois leur IA ne peut juger que l'aspect extérieur de l'œil, limitant ses capacités diagnostiques.

• Diagnostic d'une anomalie sur un électrocardiogramme

La morphologie d'un électrocardiogramme (ECG) équin diffère significativement de celle de l'ECG d'un humain ou d'un petit mammifère. Ainsi, les algorithmes traditionnels ne sont pas ou peu applicables pour aider les praticiens à interpréter ces examens, alors que leur analyse permet de détecter des arythmies pouvant être fatales chez le cheval. Van Steenkiste *et al.* (2020) ont développé une IA capable d'analyser automatiquement un ECG. Les auteurs ont d'abord entraîné un CNN avec la base de données MIT-BIH, comprenant plus de 230 000 battements cardiaques humains. Avant leur utilisation, les signaux étaient nettoyés et filtrés (voir **p. 18**), puis un algorithme spécifique identifiait le signal QRS pour isoler correctement le signal correspondant à un battement. Ce CNN pré-entraîné atteint une précision de 98 % dans sa classification. Il a ensuite été réentraîné, cette fois avec un jeu de données comprenant plus de 20 000 battements cardiaques équins. L'IA finale peut identifier et classer ces battements avec une précision de 97 %.

- *Troubles locomoteurs des chevaux*

L'analyse des allures équines est un sujet de recherche ancien et les premiers modèles employés sont des NN, entraînés pour classer automatiquement les allures ou identifier des boiteries, avec des performances variables (Mouloodi *et al.*, 2021).

Schobesberger et Peham (2002) ont par exemple utilisé une caméra infrarouge et des marqueurs placés sur les animaux pour enregistrer les mouvements de la tête et des membres de 175 chevaux. Ces données, une fois traitées, ont permis d'entraîner un NN à détecter une boiterie d'un membre thoracique avec une précision de 79 %.

Différentes équipes ont depuis développé des capteurs spécifiques à l'espèce équine. Bosch *et al.* (2018) ont par exemple validé le fonctionnement du système EquiMoves, un ensemble de huit capteurs sans fils à disposer sur différentes parties du corps de l'animal. Ce type de capteurs peut être utilisé par d'autres algorithmes de ML, pour améliorer la classification des allures et éventuellement identifier des boiteries. Parmentier *et al.* (2023) ont par exemple utilisé ce système pour collecter les données de 24 chevaux marchant ou trotant sur un tapis. Après un pré-traitement ces données ont permis d'entraîner un RNN. L'IA finale est capable de déterminer la composante verticale de la force de réaction au sol pour chaque membre et d'en déduire la présence d'une boiterie ou non. D'autres utilisations sont également possibles : Darbandi *et al.* (2023) ont par exemple entraîné un SVM avec EquiMoves pour diagnostiquer la fatigue et le surmenage chez les chevaux, avec une précision comprise entre 83 % et 95 %.

Les progrès technologiques des téléphones portables permettent aussi de pouvoir les utiliser comme des capteurs et de se passer de systèmes plus complexes comme EquiMoves. Davíðsson *et al.* (2023) ont ainsi collecté les données d'un téléphone placé dans la poche du cavalier pour entraîner un RNN. Le modèle final peut identifier cinq allures avec une précision de 94 %, ouvrant la voie à d'autres études facilitant le diagnostic de troubles locomoteurs. L'utilisation de caméras de téléphone, sans utiliser de marqueurs apposés sur l'animal, est aussi rapportée. Feuser *et al.* (2022) ont par exemple filmé 30 chevaux dont 22 boiteux pour entraîner une IA à identifier des boiteries. Sur chaque vidéo, un humain a annoté la position de différents repères anatomiques (narine, yeux, articulations, *etc.*). Ces vidéos ont ensuite permis l'entraînement d'un CNN pré-entraîné pour qu'il puisse reconnaître et traquer la posture d'un cheval sur une vidéo. Les auteurs ont montré qu'il était possible d'analyser ces résultats pour déterminer la présence d'une boiterie et une prochaine IA pourrait réaliser automatiquement cette analyse.

C. L'usage de l'intelligence artificielle en imagerie médicale

a. La radiomique, une méthode prometteuse pour l'intelligence artificielle

À l'instar des sciences omiques traditionnelles (voir **p. 16**), la radiomique est l'étude de paramètres quantitatifs extraits d'examens d'imagerie, englobant donc les domaines de la radiographie, de la tomodensitométrie, de l'imagerie par résonance magnétique (IRM) ou de l'échographie. Concrètement, une région d'intérêt est d'abord identifiée sur une image, puis un grand nombre de caractéristiques en sont extraites. L'étude de ces données à une grande échelle permet d'identifier les caractéristiques (appelées *features*) les plus importantes (Currie et Rohren, 2022a).

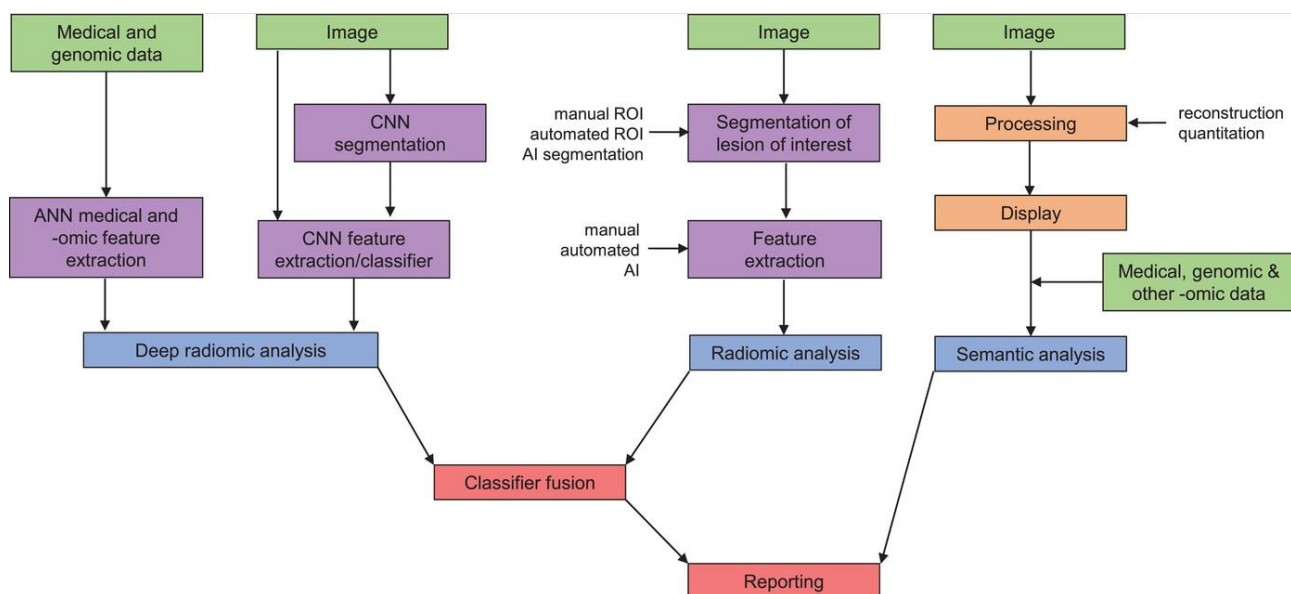
Les caractéristiques extraites peuvent correspondre à des descriptions concrètes ou à des informations plus abstraites et sans signification clinique. On distingue d'abord les paramètres de premier ordre, qui décrivent la répartition spatiale du signal (forme, taille, intensité, *etc.*), puis les

paramètres du deuxième ordre, qui décrivent les relations mathématiques entre les différents pixels ou voxels (texture, etc.), et les paramètres du troisième ordre, qui résultent de transformations mathématiques (Currie et Rohren, 2022a).

Les apports de l'IA à la radiomique se situent à plusieurs niveaux et sont illustrés sur la **Figure 25**. Il est possible de développer des IA pouvant identifier automatiquement les zones d'intérêts (*segmentation*), des IA capables d'identifier quelles sont les caractéristiques importantes à extraire, ou des IA conçues pour analyser ces caractéristiques de manière pertinente (pour établir un diagnostic, par exemple). Il est aussi envisageable de développer des modèles (comme un CNN, à gauche sur la figure) intégrant l'ensemble de ces étapes en une seule analyse voire des IA prenant également en compte d'autres données omiques (Currie et Rohren, 2022a).

Par ailleurs, si les caractéristiques du premier ordre ont déjà été étudiées et sont déjà utilisées manuellement en pratique, l'IA peut être en mesure de découvrir de nouvelles caractéristiques inconnues jusqu'alors. Les limites déjà évoquées dans la partie **I.3.b.** s'appliquent néanmoins : l'utilité clinique de ces nouvelles caractéristiques reste parfois à démontrer et selon l'entraînement de l'IA, il est possible qu'elles ne puissent pas toujours être correctement extraites sur des images prises en situation réelle. L'IA a donc un intérêt à être utilisée conjointement à une analyse classique (à droite sur la figure) (Currie et Rohren, 2022a).

Figure 25 : Les différentes méthodes d'analyse radiomique.
Utilisée avec l'autorisation de Currie et Rohren (2022a).



b. Les applications chez les animaux de compagnie

En imagerie, les applications de l'IA découlent donc de l'usage de la radiomique. L'IA est utilisée principalement pour la détection, la délimitation ou la classification d'éléments particuliers sur une image. La détection consiste à identifier une structure particulière (un nodule pulmonaire par exemple) ; la délimitation permet de déterminer précisément les contours d'une structure donnée ; et la classification assigne l'image à une catégorie en particulier (par exemple, « malade » ou « non malade ») (Appleby et Basran, 2022 ; Currie et Rohren, 2022b).

- *Diagnostic d'affections musculosquelettiques*

McEvoy et Amigo (2013) sont parmi les premiers auteurs à avoir utilisé des modèles de ML pour l'interprétation de radiographies musculosquelettiques. En particulier, ils ont collecté 256 images de la région coxofémorale de 60 chiens pour entraîner plusieurs modèles, dont un NN, à détecter une dysplasie des hanches. Le modèle final atteint une précision de 91 %, une sensibilité de 86 % et une spécificité de 100 %. Ce travail a été poursuivi par McEvoy *et al.* (2021) en utilisant cette fois deux CNN pré-entraînés (YOLOv3), respectivement pour identifier les articulations et classer la dysplasie. Plus de 11 000 radiographies pelviennes ont été collectées et des spécialistes ont décrit manuellement la zone d'intérêt et le grade de l'éventuelle dysplasie. Leur IA atteint une sensibilité et une spécificité de 53 % et 92 % respectivement et des valeurs prédictives positives et négatives de 91 % et 81 % respectivement. D'autres équipes ont mené des travaux similaires et atteignent les mêmes performances, bien qu'une meilleure sensibilité et spécificité semblent être atteintes en utilisant des données combinant des radiographies et des IRM (Pereira *et al.*, 2023).

Ergün et Güney (2021) ont entraîné plusieurs CNN et un SVM à déterminer la maturité osseuse des chiens, à identifier des fractures des os longs et le cas échéant, à les dater. Trois jeux de données ont donc été créés, comprenant respectivement 1 000, 410 et 2 027 radiographies, chacune décrite par un vétérinaire. Les CNN se sont révélés être meilleurs quelle que soit la tâche, avec une précision comprise entre 80 % et 89 %. Hennessey *et al.* (2022) regrettent toutefois l'absence de données fiables sur l'historique des chiens, issus de refuges.

Des équipes ont aussi travaillé sur le diagnostic de la dystrophie musculaire chez le Golden Retriever. Duda *et al.* (2018) ont par exemple entraîné des SVM et des RF en utilisant les examens IRM de chiens atteints à différents stades. Cinq animaux sains et cinq animaux malades ont été étudiés sur une période de 14 mois, permettant la création de 38 examens au total. L'IA finale atteint une précision de 81 %, mais le faible effectif utilisé doit être considéré. L'étude a néanmoins permis d'identifier 17 textures musculaires d'intérêts, qui pourraient être utilisées pour des études futures avec davantage d'animaux.

Enfin, Ye *et al.* (2021) ont étudié l'utilisation de la tomographie en cohérence optique¹⁷ pour le diagnostic des sarcomes des tissus mous. En particulier, les auteurs se sont intéressés à son usage en temps réel lors de l'exérèse, pour remplacer avantageusement la vérification post-opératoire des marges de la tumeur. Les auteurs ont collecté 220 images de 24 chiens lors de l'exérèse d'un sarcome et ont annoté manuellement chacune d'entre-elles. La moitié des images contenait un sarcome. Une partie de ces données a permis l'entraînement d'un CNN, qui atteint une AUC de 0,994 et une précision, une sensibilité et une spécificité de 98 %.

- *Diagnostic d'affections thoraciques*

- Affections cardiaques

Li *et al.* (2020) ont réalisé une étude pilote sur les radiographies thoraciques (en vue latérale droite) de 792 chiens présentés pour une suspicion d'une dilatation de l'atrium gauche, confirmée ou réfutée par une échocardiographie. Ces cas ont permis d'entraîner deux CNN, qui atteignent

¹⁷ La tomographie en cohérence optique, ou OCT, est une technique d'imagerie similaire à l'échographie par ultrasons. Elle utilise une onde lumineuse (en infrarouge proche) ce qui permet une résolution de l'ordre du micromètre, mais une pénétration de quelques millimètres au maximum (Ye *et al.*, 2021).


une AUC de 0,88 et 0,84, une précision de 83 % et 79 %, une sensibilité de 69 % et 74 % et une spécificité de 81 % et 87 %, soit des performances proches de celles de spécialistes. De manière similaire, Valente *et al.* (2023) ont entraîné un CNN à diagnostiquer le stade d'une maladie valvulaire dégénérative mitrale grâce à 1 242 radiographies thoraciques canines (en vue latérale, dorsoventrale ou ventrodorsale). Le diagnostic de chaque animal a été établi après la réalisation d'une échocardiographie. Le modèle final est meilleur lors de l'interprétation de clichés en vue latérale : il atteint alors une AUC de 0,88 et une précision moyenne de 71 %. Enfin, Burti *et al.* (2020) ont entraîné des CNN pré-entraînés à détecter une cardiomégalie canine en utilisant 1 465 radiographies thoraciques (en vue latérale droite) sur lesquelles le *Vertebral Heart Score* (VHS) avait été calculé par des vétérinaires. Le meilleur modèle atteint une AUC de 0,973.

Plusieurs automatisations du calcul du VHS ont également été rapportées. Zhang *et al.* (2021) ont par exemple entraîné un CNN pré-entraîné (HRNet) avec 1 875 radiographies de chiens annotées par des vétérinaires. Ces annotations comprennent 12 vertèbres thoraciques et 4 points cardinaux situés sur le cœur, comme illustré par la **Figure 26**. Le modèle final peut placer ces repères avec une précision de 91 % et donc calculer le VHS et déterminer le statut de l'animal avec efficacité. La même année, une étude de Boissady *et al.* (2021) rapporte que le logiciel PicoxIA (voir ci-dessous), utilisant un CNN fonctionnant de manière similaire, peut calculer le VHS chez des chiens ou des chats avec une performance semblable à celle d'un spécialiste en imagerie ou en cardiologie.

Figure 26 : Annotations permettant le calcul du VHS sur des radiographies thoraciques de deux chiens.

Utilisée avec l'autorisation de Zhang *et al.* (2021).

Les points bleus et rouges sont les points placés par un vétérinaire et par l'IA, respectivement.



Enfin, chez le chat, Rho *et al.* (2023) ont entraîné un ensemble de CNN à diagnostiquer une myocardiopathie hypertrophique en utilisant 231 radiographies thoraciques (en vue ventrodorsale). Le statut sain ou malade de chaque animal a été établi après la lecture de la radiographie par un spécialiste. L'IA finale atteint une précision de 90 %.

□ Affections pulmonaires

Marschner *et al.* (2017) ont collecté les images d'exams tomodensitométriques de 35 chiens, dont 7 présentaient une embolie pulmonaire et 22 présentaient d'autres maladies, pour entraîner plusieurs modèles. Le plus performant est un SVM capable de différencier un chien en bonne santé d'un chien atteint d'une maladie pulmonaire, avec une AUC, une sensibilité et une spécificité

de 0,997, 99 % et 100 % respectivement. Cependant, si cette IA peut diagnostiquer une maladie, elle ne parvient pas à en établir la cause (embolie ou autre).

Arsomngern *et al.* (2019) ont entraîné un CNN à identifier une lésion alvéolaire, bronchique, interstitielle ou un poumon normal sur un cliché radiographique. Un total de 2 862 images de chiens et chats (en vue de face ou de profil) a été annoté par des spécialistes. Le modèle final atteint une précision de 79 %, une sensibilité de 76 % et une spécificité de 70 %. Dumortier *et al.* (2022) ont développé une IA semblable et spécifique au chat en utilisant 500 images. Un ensemble de 200 CNN, pré-entraînés avec ImageNet¹⁸ et des radiographies thoraciques humaines, a ensuite été entraîné. L'IA finale atteint une précision de 82 %, une sensibilité de 88 % et une spécificité de 75 %.

Ott *et al.* (2021) ont entraîné des CNN à détecter des lésions pulmonaires plus spécifiques, dues à une coccidioïdomycose. Les auteurs ont collecté 1 174 images de chien (en vue de face ou de profil), dont 405 issues d'animaux malades, puis chacune a été interprétée par un vétérinaire. Le meilleur modèle a une AUC de 0,991, une sensibilité de 85 % et une spécificité de 99,6 %. Les auteurs n'ont toutefois pas testé si les NN étaient en mesure de différencier les lésions de coccidioïdomycose d'autres lésions pulmonaires pouvant y ressembler (Hennessey *et al.*, 2022).

□ Interprétation globale d'une radiographie thoracique

Yoon *et al.* (2018) sont parmi les premiers à avoir développé une IA capable de reconnaître de multiples anomalies sur une radiographie thoracique. Plus de 7 000 clichés de chien sains ou malades ont été utilisés pour entraîner un CNN à reconnaître une cardiomégalie, une anomalie de l'aspect des poumons, un déplacement du médiastin, un épanchement pleural ou un pneumothorax. L'IA finale a une précision comprise entre 93 % et 97 %, une sensibilité entre 92 % et 100 % et une spécificité entre 94 % et 96 % selon l'anomalie détectée. D'autres équipes ont depuis proposé des IA similaires et performantes. Banzato *et al.* (2021a) ont par exemple utilisé plus de 3 800 radiographies pour créer une IA pouvant diagnostiquer une cardiomégalie, une lésion alvéolaire, bronchique ou interstitielle, une masse thoracique, un épanchement pleural, un pneumothorax ou un mégacœsophage chez le chien. La même équipe a entraîné un autre CNN à détecter les mêmes anomalies thoraciques (à l'exception du mégacœsophage et de la masse) chez le chat, avec des performances similaires (Banzato *et al.*, 2021b).

Les IA d'aide à l'interprétation radiologique commercialisées utilisent aujourd'hui cette approche globale. Boissady *et al.* (2020) ont par exemple publié une preuve de concept en 2020, à l'origine du logiciel PicoxIA. Les auteurs ont collecté plus de 14 000 radiographies thoraciques de chiens et chats (en vue latérale) pour entraîner trois CNN (DenseNet). Le premier était un CNN classique, le deuxième était pré-entraîné avec ImageNet et le troisième avec ImageNet puis CheXpert, une banque de radiographies thoraciques humaines. Ces radiographies étaient par ailleurs associées à un diagnostic lésionnel, récupéré automatiquement par un algorithme de NLP dans le rapport établi par un spécialiste (voir **p. 36**). Le deuxième modèle est le plus performant et peut identifier quinze anomalies avec une AUC de 0,86 et une précision moyenne d'environ 89 %,

¹⁸ ImageNet est une banque publique d'images, comprenant plusieurs millions de photographies de la vie quotidienne, classées manuellement en plusieurs milliers de catégories (Deng *et al.*, 2009). Il s'agit généralement du jeu de données utilisé lors du pré-entraînement d'un CNN. En 2023, ImageNet comprend plus de 14 millions d'images et plus de 20 000 catégories.

soit de meilleures performances que certains vétérinaires. Hespel *et al.* (2022) ont également comparé les performances de cette IA à celles de treize spécialistes dans une étude rétrospective de 50 radiographies thoraciques canines. Les auteurs rapportent que les vétérinaires étaient plus performants pour le diagnostic de huit anomalies et inversement pour une anomalie. Les deux groupes avaient des performances équivalentes pour le reste des anomalies.

Les performances d'un autre logiciel d'aide à l'interprétation, Vetology AI, ont été étudiées par E. Kim *et al.* (2022) et Müller *et al.* (2022). La première équipe (dont certains auteurs ont participé au développement du logiciel) a comparé les résultats de l'IA et ceux de spécialistes lors de la détection d'un œdème pulmonaire cardiogénique sur 418 clichés. Les auteurs rapportent une précision de 92 %, une sensibilité de 91 % et une spécificité de 92 %. La seconde équipe s'est intéressée aux performances du logiciel pour la détection d'un épanchement pleural. Avec une méthodologie similaire à E. Kim *et al.* et en utilisant 62 clichés, les auteurs rapportent une précision de 89 %, une sensibilité de 90 % et une spécificité de 82 %.

Pour ces deux logiciels, certains auteurs regrettent néanmoins que les interprétations effectuées par les spécialistes ne soient pas toujours vérifiées cliniquement par la suite (par exemple avec un examen histologique). L'interprétation de certaines images pourrait donc être incorrecte et la validation des performances des IA pourrait au final être insuffisante. Ainsi, la commercialisation de ces logiciels peut sembler prématurée (Müller *et al.*, 2022).

- *Diagnostic d'affections abdominales des animaux de compagnie*

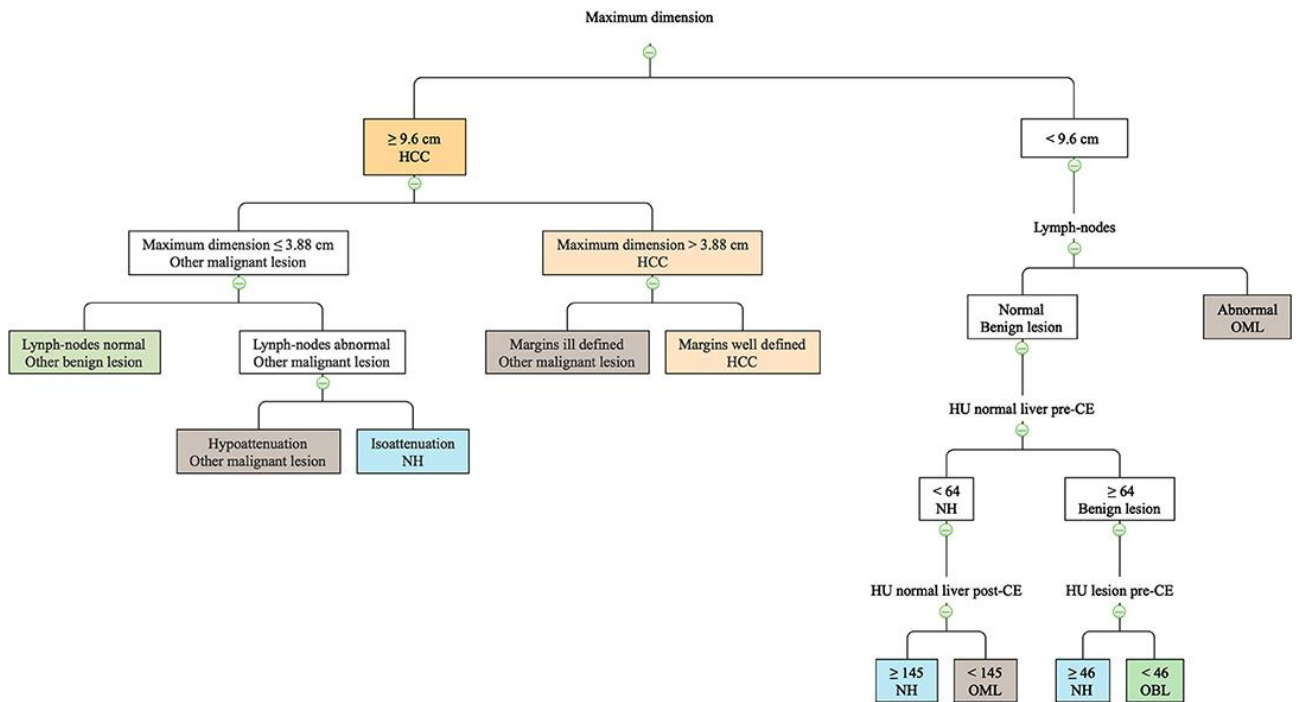
Banzato *et al.* (2018b) ont développé une IA capable de diagnostiquer des maladies hépatiques chez le chien (cholestase, stéatose, cirrhose et hépatopathie vacuolaire) à partir d'images échographiques. Les auteurs ont collecté les images de 48 animaux, associés à un examen histopathologique établissant le diagnostic final, pour entraîner un CNN pré-entraîné (AlexNet). Le modèle final atteint une AUC, une précision, une sensibilité et une spécificité de 0,91, 82 %, 100 % et 83 % respectivement. Les auteurs ont aussi comparé ces performances aux examens cytologiques réalisés en parallèle : l'IA est plus efficace, ce qui suggère son utilité lorsque les tests réalisés en routine ne sont pas concluants.

Entre 2012 et 2021, plusieurs équipes ont également entraîné des IA à déterminer la malignité d'une masse hépatique à l'aide d'angiogrammes et d'examens tomodensitométriques. Les auteurs rapportent cependant des performances médiocres (Hennessey *et al.*, 2022). Shaker *et al.* (2021) ont développé une IA utilisant seulement la texture des masses au scanner pour déterminer leur malignité. Les auteurs ont utilisé les images et les résultats histologiques de 40 chiens. Chacune des masses visibles sur les images a été annotée manuellement et les *features* radiomiques associées (taille, forme, texture, *etc.*) ont ensuite été calculées automatiquement. Le modèle final atteint une précision de 90 %, une sensibilité de 67 % et une spécificité de 100 %. Avec une méthodologie similaire, Burti *et al.* (2021) ont développé un DT capable de classer une lésion focale hépatique visible au scanner parmi une de ces catégories : carcinome, hyperplasie nodulaire ou autre maladie maligne ou bénigne. Après un entraînement avec 69 cas, l'IA finale atteint une précision globale de 81 %. Le DT obtenu est présenté sur la **Figure 27**.

Figure 27 : Arbre de décision proposé par Burti *et al.* pour le diagnostic de lésions hépatiques focales chez le chien grâce à un examen tomographique.

Licence [CC BY](https://creativecommons.org/licenses/by/4.0/) (Burti *et al.*, 2021).

HCC : carcinome hépatocellulaire ; NH : hyperplasie nodulaire



En 2022, cette équipe a appliqué la même méthodologie pour développer une IA pouvant classer une lésion focale splénique sur l'examen tomographique d'un chien. Les auteurs ont utilisé les examens de 62 chiens pour entraîner un DT. Le modèle final peut identifier un sarcome, une hyperplasie nodulaire ou une lésion autre (bénigne) avec une précision moyenne de 82 %. Le modèle n'est toutefois pas performant pour identifier la présence d'une tumeur à cellules rondes (Burti *et al.*, 2022).

Ji *et al.* (2023) ont rapporté le développement d'une IA pour détecter automatiquement la présence d'un calcul rénal sur l'examen tomographique d'un chien. Leur IA est également capable de délimiter ce calcul et d'en extraire des informations (taille, forme, *etc.*). Les auteurs ont pour cela collecté plus de 34 000 images provenant de 76 examens, puis chaque image a été manuellement analysée par un vétérinaire. Une partie de ces données a permis d'entraîner plusieurs modèles. Le modèle final est un transformeur (voir **p. 29**), qui peut détecter un calcul rénal avec une AUC, une précision, une sensibilité et une spécificité de 0,98, 99 %, 89 % et 99 % respectivement.

Basran *et al.* (2023) ont collecté les données de 149 chats dans le but d'entraîner une IA à diagnostiquer des troubles intestinaux. Ces données comprenaient des images échographiques (annotées manuellement avec les zones d'intérêt), des bilans sanguins, ainsi que des analyses histologiques sur des biopsies afin d'établir le diagnostic de chaque animal. Plusieurs modèles ont été entraînés avec différents objectifs : distinguer des intestins sains d'intestins anormaux ; identifier les images échographiques justifiant ou non la réalisation d'une biopsie ; et diagnostiquer des intestins sains, un lymphome intestinal, une maladie inflammatoire chronique de l'intestin ou une autre maladie. Après l'entraînement, seuls les modèles capables de distinguer des intestins sains d'intestins anormaux ou d'indiquer si une biopsie est nécessaire sont performants, avec des

précisions maximales comprises entre 90 % et 96 %. En particulier, les auteurs rapportent que l'utilisation séparée des données biochimiques ou échographiques permet de meilleures performances que leur utilisation conjointe.

- *Diagnostic d'affections du système nerveux central des animaux de compagnie*

Banzato *et al.* ont publié trois études dans lesquelles les auteurs ont développé des IA étudiant des méningiomes canins sur une IRM. L'étude de 2017 utilise un algorithme de ML entraîné avec 58 cas pour réaliser une analyse de la texture des méningiomes et déterminer leur malignité, avec des performances allant jusqu'à une AUC de 0,987, une précision de 91 %, une sensibilité de 97 % et une spécificité de 95 %. Ces résultats correspondent toutefois aux performances sur les données d'entraînement (Banzato *et al.*, 2017). L'étude réalisée en 2018 utilise 56 cas pour comparer les performances de deux CNN, dont un est pré-entraîné. Le meilleur modèle peut déterminer le stade histologique d'un méningiome avec une précision de 82 % (Banzato *et al.*, 2018c). La dernière étude rapporte l'entraînement d'un CNN pré-entraîné avec les examens de 80 chiens, dont 56 présentaient un méningiome et 24 présentaient un gliome. Le modèle final peut identifier ces tumeurs avec une précision de 94 % (Banzato *et al.*, 2018a). Toutes ces études utilisent les résultats d'une analyse histologique pour confirmer le diagnostic, mais souffrent d'effectifs réduits.

Wanamaker *et al.* (2021) ont également utilisé la texture de structures extraites d'une IRM pour entraîner une IA à détecter et différencier un gliome d'une méningoencéphalite inflammatoire. Les auteurs ont collecté les examens IRM et histologiques de 119 chiens sur lesquels un vétérinaire a manuellement délimité la zone d'intérêt. Le modèle final est une RF qui atteint une précision de 85 %, une sensibilité de 89 % et une spécificité de 81 %. Les auteurs ont également tenté d'entraîner le modèle à classer les différents types de méningoencéphalites inflammatoires, mais la précision n'atteint alors que 65 %. Barge *et al.* (2023) ont développé une IA visant à déterminer le type histologique et le grade d'un gliome en utilisant leur texture à l'IRM. Les auteurs ont utilisé les examens de 38 chiens (soit 40 masses) et le résultat d'une analyse histologique pour entraîner trois modèles de ML. Le SVM est le modèle le plus performant et peut identifier le type de tumeur avec une précision allant jusqu'à 94 % et peut identifier le grade avec une précision allant jusqu'à 87 %, la précision variant selon la séquence de l'IRM analysée.

Spiteri *et al.* (2019) ont développé une IA capable d'identifier la présence d'une syringomyélie et d'une malformation Chiari-*like* à l'origine de douleurs chez les Cavaliers King Charles. Les auteurs ont utilisé les examens d'IRM de 32 animaux (sains ou atteints) pour entraîner un SVM. Leur étude a permis d'identifier plusieurs *features* radiomiques et le modèle final peut identifier les chiens présentant une malformation avec une AUC, une sensibilité et une spécificité de 0,74, 82 % et 69 % respectivement.

Biercher *et al.* (2021) ont eu une approche plus globale et ont développé une IA visant à identifier plusieurs myélopathies, comme une embolie fibrocartilagineuse, une hernie discale, une syringomyélie ou un processus néoplasique. Les auteurs ont utilisé 2 693 images provenant de 375 chiens. Pour chacun des cas, les résultats d'histologie, les rapports chirurgicaux ou l'interprétation des images et des signes cliniques par des spécialistes a permis d'établir le diagnostic final. Le CNN final peut détecter précisément une hernie discale et une embolie, mais peine à identifier une syringomyélie ou une néoplasie.

c. Les applications chez le cheval

Chez le cheval, la sésamoïdite est une cause courante de boiterie, qui augmente le risque de survenue de traumatismes tendineux et de mauvaises performances, en particulier chez le jeune. Le diagnostic de ce trouble n'est pas toujours aisé, car certains animaux ne présentent aucun signe clinique évident. Guo *et al.* (2024) ont collecté 255 clichés radiographiques en vue dorsolatérale-palmaromédiale oblique ou dorsomédiale-palmarolatérale oblique, obtenus sur des animaux sains et à des stades divers d'inflammation. Deux CNN sont utilisés en série : le premier identifie la zone d'intérêt sur la radiographie et le second classe la gravité de l'éventuelle lésion observée. L'IA finale atteint une précision globale de 93 %, mais les auteurs soulignent sa tendance à classer les cas légers en cas modérés.

D. L'usage de l'intelligence artificielle dans les autres examens diagnostics

a. L'intelligence artificielle pour automatiser les examens complémentaires

- *L'intelligence artificielle dans des appareils automatisés déjà commercialisés*

Plusieurs entreprises proposent déjà des analyseurs utilisant de l'IA. L'entreprise Zoetis commercialise par exemple Vetscan Imagyst. L'entreprise revendique des performances intéressantes pour les analyses de cristaux urinaires, les examens de cytologie dermatologiques, l'analyse de frottis sanguins et la recherche de parasites dans les selles (« VETSCAN IMAGYST », 2023). La compagnie Idexx commercialise également SediVue Dx, un appareil utilisant une IA pour identifier des éléments figurés dans un échantillon d'urine (« IDEXX SediVue Dx », 2021). Un nouvel analyseur complet et ressemblant à Vetscan Imagyst, nommé inVue Dx, sera aussi proposé à la vente en 2024 (« IDEXX inVue Dx », 2024).

Ces appareils ne font cependant pas toujours l'objet de publications relues par des pairs. Seules les performances de l'analyse des selles de Vetscan Imagyst ont par exemple été étudiées (voir ci-dessous). Plusieurs équipes ont également comparé les performances d'une analyse par le SediVue Dx à celles d'une analyse classique : l'analyseur d'Idexx présente des résultats globalement satisfaisants pour les chiens et les chats, malgré des difficultés de détection de certains éléments figurés comme les cellules épithéliales (Hernandez *et al.*, 2019).

- *L'intelligence artificielle pour le diagnostic automatisé de parasites sur des échantillons de selles*

- Parasites des animaux de compagnie

Nagamori *et al.* (2021) ont comparé les performances de l'analyse fécale de Vetscan Imagyst à celles de parasitologues expérimentés. Les auteurs ont collecté et préparé 110 échantillons de selles de chats ou chiens, dont 100 comprenaient chacun au moins un de ces parasites : *Ancylostoma* spp., *Toxocara cati*, *Cystoisospora* spp. et *Giardia* spp. Les résultats révèlent que l'IA est performante, car elle atteint une sensibilité comprise entre 76 % et 100 % et une spécificité comprise entre 93 % et 100 % en fonction des espèces. Leur étude met toutefois en lumière les limites du système : les performances sont moins bonnes lorsque les lames comptent moins de 50 œufs visibles et les analyses de l'étude requièrent une préparation différente pour chaque parasite, ce qui n'est pas réaliste au sein d'une clinique généraliste (Joao *et al.*, 2023).

Inácio *et al.* (2020) ont eu une approche similaire sans automate. Ils ont collecté et préparé des échantillons provenant de 104 chiens pour créer plus de 10 000 images. Parmi ces images, plus de 3 000 représentent un parasite (*Ancylostoma* spp., *Trichuris* spp., *Toxocara* spp. ou *Giardia* spp.), le restant représentant des impuretés (débris végétal, élément non digéré, etc.). Ces données ont permis d'entraîner un CNN à détecter et à détourner les régions de l'image contenant un parasite, puis un SVM a été entraîné à identifier le genre du parasite. Les performances réelles de l'IA ne sont pas fournies, mais ses résultats sont cohérents avec ceux de parasitologues expérimentés. Joao *et al.* (2023) ont repris ces travaux pour développer un système capable d'identifier trois espèces de parasites félines et cinq espèces de parasites canins. L'entraînement est réalisé grâce à des échantillons provenant de 122 chiens et 75 chats. L'IA finale peut détecter des parasites chez le chat et le chien avec des précisions respectives de 95 % et 84 %.

□ Parasites des poules

La coccidiose est une infection parasitaire fréquente de la poule, mais souvent diagnostiquée tardivement, une fois l'infection du cheptel importante. Plusieurs équipes ont développé des IA visant à diagnostiquer précocement la présence de ces parasites ou à faciliter des examens de routine tels que des coproscopies (Franzo *et al.*, 2023). Récemment, He *et al.* (2023) ont utilisé une base de données publique, publiée en 2007 par une équipe brésilienne, comportant des images microscopiques d'oocystes de sept espèces d'*Eimeria*. Au total, 4 243 images annotées ont été utilisées pour l'étude. Après un pré-traitement, les auteurs ont entraîné un CNN à identifier un parasite parmi ces sept espèces : *E. acervulina*, *E. brunetti*, *E. maxima*, *E. mitis*, *E. necatrix*, *E. praecox* et *E. tenella*. Le modèle final obtient une AUC de 0,998 et une précision de 97 %.

□ Parasites des moutons

Li *et al.* (2019) rapportent le développement d'une IA dans le but de diagnostiquer facilement et à moindre coût la présence de parasites intestinaux dans les selles de mouton. Les auteurs ont récolté des échantillons d'excréments qui ont ensuite été préparés de manière standardisée. Un microscope portable et peu coûteux, que les auteurs jugent utilisable sur le terrain, a permis la capture de 951 images annotées par un observateur humain, dont 643 contenaient des œufs de parasites (trichures, coccidies, strongles ou ascaris). Le CNN final est capable d'identifier les portions d'images contenant un œuf et d'en donner le genre avec une précision comprise entre 92 % et 96 %, motivant par ailleurs le dépôt d'un brevet par les auteurs.

□ Parasites des reptiles

Parra *et al.* (2022) ont élaboré la première base publique d'images microscopiques d'excréments de reptiles. Ces images proviennent de 354 échantillons prélevés chez 29 espèces de reptiles élevés en captivité, comprenant par exemple des tortues, des serpents et des lézards. Les échantillons ont été préparés de manière standardisée puis examinés au microscope par un vétérinaire. Un total de 3 616 images et 26 vidéos (comportant 4 889 images) ont été collectées et annotées. Chacune de ces images contient exactement un de ces parasites : *Ophionyssus natricis*, *Blastocystis* spp., *Rhytidoides similis*, *Strongyloides*, *Taenia* spp. ou des oxyures. Après un pré-traitement, les données ont permis d'entraîner un CNN pré-entraîné (MobileNet). L'IA atteint une AUC moyenne de 0,996 et une précision moyenne de 94 %.

- *Automatisation de la méthode Famacha chez le mouton et la chèvre*

La méthode Famacha est une méthode de *scoring* de l'anémie utilisée chez le mouton et la chèvre dans le cadre d'un plan de traitement contre l'haemonchose. Un score de 1 ou 2 laisse supposer un animal en bonne santé, tandis qu'un score de 3 à 5 permet de suspecter une anémie et motive l'administration d'un traitement antihelminthique. Il s'agit d'une technique efficace, mais qui doit être effectuée régulièrement et nécessite du personnel. Plusieurs essais d'automatisation ont déjà été menés pour cette technique, mais les IA obtenues n'avaient jusqu'alors qu'une précision limitée (de Souza *et al.*, 2023). Les auteurs ont développé la première IA n'utilisant pas de capteurs et avec des performances satisfaisantes. À l'aide d'une photographie des conjonctives prise avec un téléphone portable, leur IA classe l'animal comme « en bonne santé » ou « malade ». Les auteurs ont utilisé 317 images de moutons brésiliens, qui étaient également évaluées par un vétérinaire. Deux modèles ont ensuite été entraînés et le meilleur est un SVM qui atteint une AUC de 0,88 et une précision de 87 %, motivant le développement d'une application pour téléphone.

b. Les apports de l'intelligence artificielle en anatomopathologie

- *Les applications générales de l'intelligence artificielle*

L'IA présente un intérêt particulier en anatomopathologie, car l'interprétation d'une coupe est un processus pouvant être long et méticuleux. L'IA est en mesure d'aider le praticien en automatisant la mesure de certains paramètres, en mettant en évidence des lésions subtiles, voire en automatisant toute la démarche diagnostique.


Le comptage des figures de mitose, dans la région la plus active d'une coupe histologique, est un paramètre important pour grader certains types de tumeurs comme les mastocytomes. Cependant, ce comptage est dépendant du choix de la région active, qui peut parfois être ambigu et varier d'un spécialiste à un autre. Aubreville *et al.* (2020) ont ainsi développé une IA identifiant automatiquement la région la plus active au sein d'une coupe. Les auteurs ont collecté 32 coupes histologiques de mastocytomes canins, pour lesquelles toutes les figures de mitose ont été annotées manuellement. Deux CNN ont été entraînés : le premier identifie et détoure les portions de l'image pouvant contenir une figure de mitose puis le second détermine si elle est effectivement présente dans la portion fournie. L'IA fournit alors une image indiquant les zones les plus actives au sein de la coupe, représentée sur la **Figure 28 (p. 90)**. L'IA se révèle aussi performante voire plus performante que les vétérinaires dans certaines conditions.

Haghofer *et al.* (2023) ont développé une IA capable de mesurer automatiquement la taille des noyaux des lymphocytes sur une coupe histologique, qui peut par exemple être utilisée pour différencier certains types de lymphomes, mais n'est pas mesurée en routine compte-tenu du temps requis pour le faire. Les auteurs ont collecté 116 cas de lymphomes canins pour entraîner un CNN à identifier les noyaux cellulaires (et donc indirectement, à les mesurer). Le modèle final atteint une précision allant jusqu'à 92 %, soit une meilleure performance que le calcul réalisé par des anatomopathologistes. Les auteurs ont par la suite réentraîné le même modèle avec des cas de lymphomes félines. L'IA atteint alors une précision allant jusqu'à 84 %.

Figure 28 : Interprétation d'une coupe histologique par l'IA proposée par Aubreville *et al.* pour détecter automatiquement la zone la plus active d'une tumeur.

Licence [CC BY](#) (Aubreville *et al.*, 2020).

Le *mitotic count* correspond au nombre de figures de mitoses par dix champs microscopiques standardisés et observés au grossissement 400.



Un dispositif médical, nommé HT Vista et commercialisé par l'entreprise HT BioImaging, est capable de déterminer la malignité d'une masse cutanée ou sous-cutanée. Son fonctionnement a été proposé puis validé en 2023 par deux études successives (Dank *et al.*, 2023a, 2023b). Cet équipement réchauffe la masse de 7 °C pendant dix secondes à l'aide d'une LED, puis mesure la façon dont la masse diffuse la chaleur durant les 50 secondes suivantes grâce à une caméra infrarouge. L'appareil comporte également une caméra traditionnelle, qui permet au praticien d'indiquer la masse à analyser et une zone de tissu adjacent. Le SVM permettant le fonctionnement du dispositif a été entraîné grâce aux résultats d'une analyse cytologique ou histologique des masses, associés à plusieurs *features* extraites des images infrarouges (Dank *et al.*, 2023a). L'étude validant le procédé a inclus 248 chiens, soit 431 masses dont 53 masses malignes. Le modèle final atteint une précision, une sensibilité et une spécificité de 69 %, 85 % et 67 % respectivement. L'IA atteint par ailleurs une valeur prédictive négative de 97 % : HT Vista est commercialisé en vue d'écarter une hypothèse de masse maligne (Dank *et al.*, 2023b).

- **Diagnostic automatisé d'une hémorragie pulmonaire induite à l'effort chez le cheval**

L'hémorragie pulmonaire induite à l'effort est une maladie respiratoire du cheval sportif, diagnostiquée par l'analyse cytologique du fluide de lavage bronchoalvéolaire. Les macrophages visibles sont classés en cinq catégories selon leur contenu en hémosidérine (Marzahl *et al.*, 2020). Marzahl *et al.* ont utilisé 17 lames obtenues après cyto centrifugation de fluides de lavage bronchoalvéolaire pour identifier manuellement plus de 78 000 macrophages et leur stade. Les auteurs ont ensuite entraîné un CNN pré-entraîné à identifier ces cellules. Le modèle final atteint une précision globale de 66 %. En 2023, le même groupe de recherche a repris ces travaux (Bertram *et al.*, 2023). Les auteurs ont collecté 52 échantillons et identifié plus de 158 000 cellules pour entraîner un CNN. Ils ont alors pu prouver que l'examen automatisé était plus rapide et moins sensible aux erreurs de lecture que des vétérinaires. L'IA peut diagnostiquer la maladie avec une précision de 92 %, là où les vétérinaires atteignent une précision de 76 %.

- *L'utilisation de l'intelligence artificielle en oncologie*

- Diagnostic d'un lymphome intestinal chez le chien ou le chat

La différenciation histologique entre une maladie inflammatoire intestinale et un lymphome intestinal peut être complexe sur des biopsies endoscopiques. Dans ce contexte, Li *et al.* (2023) ont collecté les coupes de 72 chats, présentant l'une ou l'autre des deux affections, pour entraîner une IA. Pour chaque coupe, un des auteurs a établi un diagnostic à l'aveugle. En cas de désaccord avec le rapport déjà établi, chaque cas a été discuté indépendamment jusqu'à parvenir à un consensus. Ces données ont permis d'entraîner plusieurs CNN : un premier visant à distinguer une maladie inflammatoire d'un lymphome et trois autres modèles visant à identifier plus précisément le type de lymphome le cas échéant. Les modèles finaux sont performants et le premier modèle en particulier atteint une précision de 88 %.

- Diagnostic d'un sarcome canin

Les sarcomes canins sont des tumeurs relativement fréquentes. Cependant, la détermination de leur grade, essentielle pour une prise en charge adéquate, dépend de plusieurs facteurs dont l'évaluation est longue et variable selon les observateurs. Morisi *et al.* (2023) ont développé une IA pouvant automatiquement détecter les zones nécrotiques sur une coupe, un des facteurs de gradation. Les auteurs ont collecté les coupes de 90 tumeurs des parois vasculaires (chacune décomposée en plusieurs milliers de zones de 256 pixels de large et décrite par un humain) pour entraîner un CNN pré-entraîné (DenseNet). Le modèle final atteint une précision de 93 %.

- Approche généraliste multi-espèces

AbdulJabbar *et al.* (2023) ont développé une approche plus généraliste et multi-espèces pour leur IA. Les auteurs d'abord publié un atlas de coupes histologiques colorées à l'hématoxyline – éosine et annotées au niveau cellulaire par des anatomopathologistes vétérinaires. Cet atlas regroupe 20 espèces différentes, parmi lesquelles des mammifères, des reptiles, des oiseaux et des amphibiens.

Les auteurs ont ensuite sélectionné 120 coupes histologiques au sein de cet atlas, dont 88 mélanomes canins, 12 carcinomes prostatiques canins et 20 tumeurs variées chez plusieurs espèces, qu'ils ont soumis à une IA déjà publiée en 2020 capable de reconnaître des tumeurs pulmonaires chez l'Homme. Cette IA identifie tout d'abord les contours de chaque cellule sur la coupe, puis extrait ses *features* morphologiques (surface, périmètre, *etc.*) pour la classer dans une de ces catégories : cellule cancéreuse, lymphocyte, fibroblaste ou cellule endothéliale, et autre cellule (macrophage, pneumocyte ou cellule non identifiée). La constance de l'aspect morphologique des cellules tumorales leur a permis d'utiliser l'IA sans modification sur la plupart des espèces.

Leur équipe rapporte que la détection d'une cellule cancéreuse atteint une précision de plus de 70 % chez 19 espèces et de plus de 80 % chez 12 espèces. Chez le chien, la détection d'une cellule cancéreuse prostatique atteint une précision globale de 87 %. Selon le type de cellule, l'IA obtient une AUC comprise entre 0,872 et 0,936, une précision entre 63 % et 97 %, une sensibilité entre 82 % et 91 % et une spécificité entre 90 % et 98 %. Par ailleurs, les auteurs ont pu démontrer que l'usage d'un modèle spécifiquement entraîné pour les maladies canines n'apportait pas de réel bénéfice.

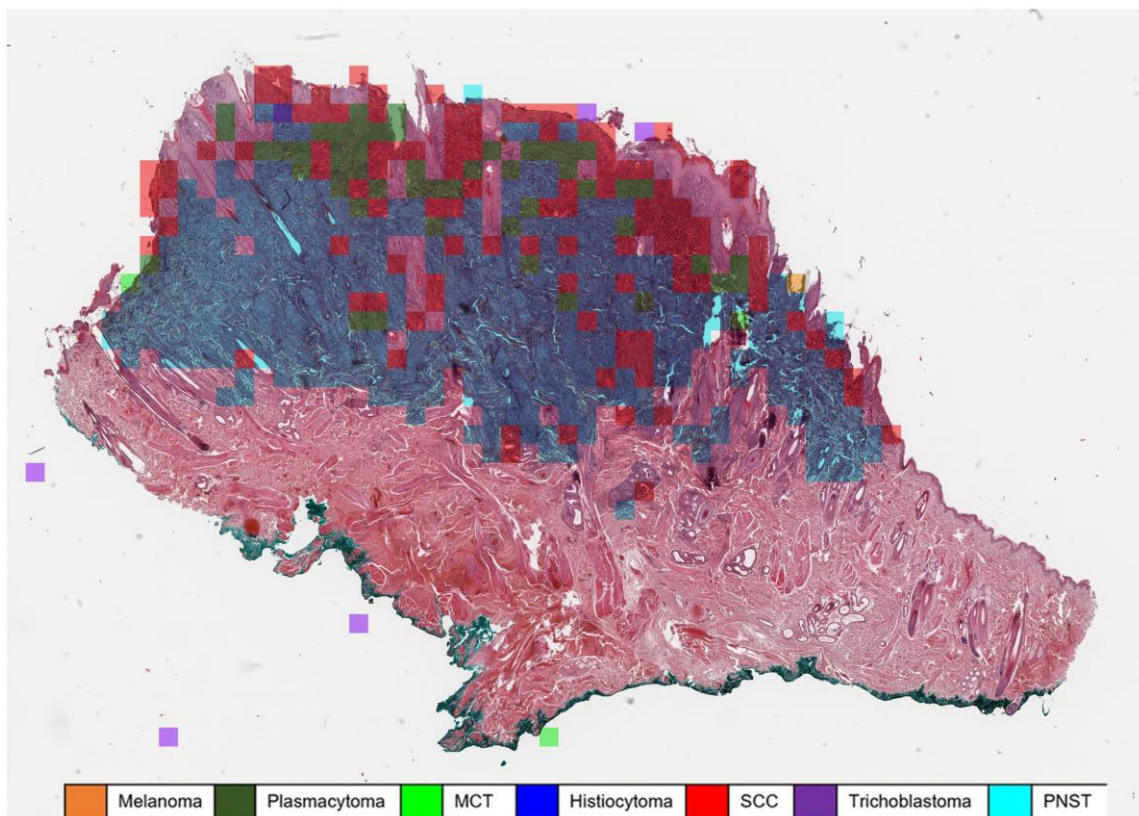
□ Diagnostic automatisé de plusieurs tumeurs canines

Fragoso-Garcia *et al.* (2023) ont développé une IA capable de diagnostiquer automatiquement sept tumeurs canines sur des coupes histologiques. Un premier CNN identifie les différentes régions de l'image et segmente la coupe en zones « tumorales » et « non-tumorales ». Les zones tumorales sont alors divisées en plus petites images, des « patches », qui sont analysées par un second CNN capable d'identifier les tumeurs suivantes : mélanome, histiocytome, plasmocytome, trichoblastome, mastocytome, carcinome épidermoïde ou tumeur des gaines nerveuses périphériques. Le diagnostic établi à l'échelle de la coupe correspond alors au diagnostic majoritairement effectué à l'échelle des patches, comme illustré sur la **Figure 29**. Pour entraîner, valider et tester leurs modèles, les auteurs ont utilisé 350 coupes annotées manuellement par des spécialistes. L'IA finale peut diagnostiquer une tumeur avec une précision de 95 %, là où les anatomopathologistes (différents de ceux ayant annotés les données d'entraînement) atteignent une précision moyenne de 98 %.

Figure 29 : Interprétation d'une coupe histologique d'un histiocytome par l'IA proposée par Fragoso-Garcia *et al.* pour diagnostiquer automatiquement des tumeurs canines.

Licence [CC BY](#) (Fragoso-Garcia *et al.*, 2023).

MCT : mastocytome ; SCC : carcinome épidermoïde



• *Apports de l'intelligence artificiel lors d'une autopsie*

□ Lésions respiratoires lors de l'autopsie d'un bovin sur le terrain

Les troubles respiratoires des bovins, évoqués **p. 59**, sont responsables d'une plus forte mortalité au sein de l'élevage. La réalisation d'une autopsie peut permettre un diagnostic *post-mortem*, mais ce sont des procédures potentiellement longues. Une IA pourrait donc assister le vétérinaire dans cette procédure. Bortoluzzi *et al.* (2023) ont réalisé 398 photographies mettant en évidence les

organes visibles sur la droite de l'animal (une fois la cage thoracique écartée) et collecté les analyses histopathologiques associées. Chaque image a été classée parmi une de ces catégories : pneumonie interstitielle aiguë, bronchopneumonie interstitielle, bronchopneumonie infectieuse enzootique ou autre (poumons sains ou autre maladie). Plusieurs modèles ont été entraînés et présentent des précisions entre 34 % et 41 % et des sensibilités et spécificités très variables selon les maladies (entre 0 % et 100 %). Ces modèles sont encore peu utilisables, mais constituent une première étape vers la création d'IA assistant le vétérinaire sur le terrain.

□ Lésions respiratoires lors de l'évaluation des carcasses de porc à l'abattoir

Les troubles respiratoires des porcs ont d'importantes répercussions sur leur bien-être et la rentabilité des élevages. Deux catégories de maladies sont très fréquentes : les pneumonies et les pleurésies. Ces maladies se manifestent à l'abattoir par des lésions qui font l'objet d'un *scoring* par un vétérinaire ou un technicien entraîné. Ce diagnostic est cependant chronophage et répétitif et pourrait bénéficier de l'aide d'une IA (Bonicelli *et al.*, 2021 ; Trachtman *et al.*, 2020).


Trachtman *et al.* (2020) ont collecté 5 902 images de demi-carcasses de porc, chacune annotée d'un score entre 0 et 3 selon la sévérité de la pleurésie et décomposée en différentes zones (diaphragme, vertèbre, lésion de pleurésie, *etc.*) pour entraîner un CNN modifié. L'IA atteint une précision, une sensibilité et une spécificité moyennes respectives de 85,5 %, 92 % et 96 %.

Une partie de cette équipe a également développé une IA capable d'attribuer un score à des porcs atteints de pneumonies (Bonicelli *et al.*, 2021). Les auteurs ont recueilli 7 564 images, chacune décomposée en trois zones par des vétérinaires (« poumon », « lésion » ou « lobe crânial ») et associée à l'état sain ou malade de l'animal, comme illustré sur la **Figure 30**. Un CNN a ensuite été entraîné et atteint une spécificité de 99 % et une sensibilité de 81 % pour les petites lésions (moins de 2 % de la surface pulmonaire) et 100 % pour les autres lésions. Une telle IA a donc des applications diagnostiques réelles, même si l'automatisation du système n'est pas encore complète.

Figure 30 : Interprétation d'une image par l'IA proposée par Bonicelli *et al.* pour le diagnostic d'une pneumonie porcine.

Licence [CC BY](https://creativecommons.org/licenses/by/4.0/) (Bonicelli *et al.*, 2021).

a : image à analyser ; b : annotations réalisées par le vétérinaire ; c : annotations réalisées par l'IA
Les plages violettes et rouges correspondent respectivement à des tissus sains et lésés.



E. Le rôle de l'intelligence artificielle dans la relation entre le propriétaire et ses animaux grâce au diagnostic de l'état émotionnel

Ces dernières années, plusieurs équipes ont pu élaborer des techniques d'analyse non invasives pour déterminer l'état émotionnel des animaux, dont les états de bien-être, le stress, la peur et la douleur. Ces techniques reposent notamment sur l'étude de la posture, des expressions faciales ou des paramètres vitaux (Neethirajan, 2021). En particulier, il existe des grilles de *scoring* des expressions faciales développées pour de nombreuses espèces, dont les chiens, les chats, les lapins, les chevaux et les moutons, permettant d'objectiver leur douleur (Feighelstein *et al.*, 2022).

La mise en application d'une grille de *scoring* est toutefois longue et il n'est pas toujours envisageable de le faire en routine. Le *scoring* pourrait donc être réalisé et interprété de manière automatisée par une IA, pour aider les éleveurs, les propriétaires et les vétérinaires (Neethirajan, 2021). L'IA permettrait également de ne pas fausser les signes extériorisés par les animaux suite à la présence d'un humain (McLennan et Mahmoud, 2019). Globalement, l'IA pourrait donc améliorer le bien-être animal et permettre de mieux détecter certaines maladies.

a. Le diagnostic de l'état émotionnel et de la douleur des animaux de compagnie

Les études menées sur les animaux de compagnie sont généralement réalisées dans un contexte clinique, le plus souvent dans une structure hospitalière, où les animaux ont une certaine liberté de mouvement et ont donc des comportements relativement représentatifs (Broomé *et al.*, 2023).

Mao et Liu (2023) ont entraîné une IA capable de déterminer l'état émotionnel des chiens, grâce à 315 images que des observateurs humains avaient au préalable classées comme « normal », « joyeux », « triste », « agressif » ou « apeuré ». Leur IA est composée de plusieurs étapes : un premier modèle (développé par une autre équipe) identifie la région de l'image comprenant la face de l'animal, puis un deuxième modèle détecte les repères faciaux (yeux, nez, oreilles, *etc.*). La portion de l'image englobant l'ensemble de ces points clés est alors extraite, convertie en noir et blanc, puis fournie à un CNN. L'IA finale obtient une précision comprise entre 80 % et 90 % environ selon l'émotion reconnue. Une autre étude récente par Zhu *et al.* (2023) présente un système automatisé similaire utilisant l'intégralité de l'animal pour diagnostiquer un état douloureux avec une précision moyenne de 77 %.

Les études menées sur les chats se concentrent principalement sur la détection de leur douleur, qui est souvent difficile à évaluer (Feighelstein *et al.*, 2023b). La première étude visant à une automatisation du diagnostic de la douleur chez le chat a été menée par Feighelstein *et al.* (2022). Les auteurs ont utilisé 464 images de 29 chattes européennes prises avant, pendant et après une ovariohystérectomie, qui ont ensuite été classées en « chat douloureux » et « chat non douloureux » par un humain. Un second jeu de données a également été créé en annotant manuellement les images avec des repères faciaux d'intérêt. Deux CNN ont été entraînés séparément et atteignent des performances similaires, avec une précision de 72 % environ. La même équipe a réalisé en 2023 un autre entraînement, en utilisant cette fois les images de 84 chats de race, sexe et antécédents médicaux variés, qui sont donc plus représentatives. L'IA finale atteint une précision de 77 % lorsque les images sont annotées et 65 % dans le cas contraire (Feighelstein *et al.*, 2023b).

Une autre équipe a récemment publié une IA entièrement automatisée, comprenant un premier modèle capable d'identifier les repères faciaux sur une image, qu'un second modèle utilise

ensuite pour déterminer l'intensité de la douleur du chat. Plus de 3 000 images ont été utilisées pour l'entraînement de l'IA. Elle atteint une précision de 96 %, motivant le développement d'une application pour téléphone (Steagall *et al.*, 2023). Les repères faciaux utilisés par toutes ces équipes sont issus de la *Feline Grimace Scale*, qui compte 37 repères séparés en cinq catégories, présentés sur la **Figure 31**.

Figure 31 : Repères faciaux félines utilisés pour déterminer l'état douloureux.

Licence [CC BY](#) (Steagall *et al.*, 2023).

Les repères rouges, bleus clairs, verts, bleus foncés et roses identifient respectivement la position des oreilles, des paupières, du museau, des vibrisses et de la tête. Les animaux à gauche de la figure ne sont pas douloureux et les animaux à droite de l'image sont douloureux.



La première étude s'intéressant à la détection automatisée de la douleur chez le lapin a été publiée par Feighelstein *et al.* (2023a). Les auteurs ont collecté les enregistrements vidéo de 24 lapins en période préopératoire et postopératoire pour développer une IA utilisant un CNN pré-entraîné. En utilisant les expressions faciales et la posture des animaux sur ces vidéos, l'IA peut détecter un état douloureux avec une précision de 81 %. Les auteurs ont également développé un second modèle, qui a été entraîné uniquement avec des images extraites des vidéos et pour lesquelles le premier modèle avait une confiance élevée en son analyse. L'ajout de ce modèle permet à l'IA finale d'atteindre une précision de 87 %.

b. La détection de la douleur chez le cheval

Dans ce contexte, les chevaux sont généralement étudiés lorsqu'ils sont au box, à l'aide de caméras statiques, bien que quelques études aient été menées à l'extérieur avec des caméras fixes visualisant alors l'intégralité du corps de l'animal. De manière générale, les IA récentes et entièrement automatisées utilisent des techniques semblables à celle étudiées pour les autres espèces : deux modèles distincts sont responsables d'identifier la portion de l'image correspondant à la tête du cheval puis d'attribuer un score à l'expression faciale. Chez le cheval en particulier, l'analyse temporelle (à partir d'enregistrements vidéo) est plus informative que l'analyse d'images et permet d'atteindre de meilleures performances, au prix d'une plus grande puissance de calcul nécessaire. Une revue récente rapporte que ces IA atteignent généralement une précision de 75 % (Broomé *et al.*, 2023).

c. Le diagnostic de l'état émotionnel chez les animaux de production

□ Détection d'un stress chez les poules pondeuses et les poulets de chair

Ces dernières décennies, plusieurs équipes se sont intéressées aux signaux de détresse émis par les poules. Du *et al.* (2020) ont par exemple utilisé les enregistrements sonores d'un élevage chinois pour entraîner un SVM à identifier des cris de détresse liés à un stress thermique. Les animaux étaient répartis dans différentes zones thermiques et 2 368 cris de quatre sortes différentes ont été enregistrés et identifiés manuellement par des humains. Le SVM a alors été entraîné à identifier et classer ces cris et atteint une précision et une sensibilité de 98 % et 95 % respectivement. L'IA finale est automatisée grâce à plusieurs composants : un premier algorithme isole les cris des bruits de fond et le transmet au SVM, puis le SVM identifie si ce cri est un cri de détresse ou non et un dernier algorithme analyse qualitativement et quantitativement les cris pour estimer le confort thermique des animaux. L'IA peut alors alerter précocement les éleveurs.

D'autres équipes ont cherché à identifier la détresse de manière plus générale. Mao *et al.* (2022) ont par exemple développé une IA pouvant identifier les spectrogrammes correspondant à des cris de détresse au sein d'un élevage de poulets de chair. Leur équipe a enregistré les sons d'un élevage de quelques milliers d'animaux. Trois sons différents ont été annotés par des humains : les cris de détresse, les bruits causés par le personnel et les bruits autres. Un total de 5 336 échantillons sonores a été compilé, dont 3 363 cris de détresse. Plusieurs modèles ont été entraînés avec ces sons et le plus performant est un CNN qui atteint une précision de 95 %. Les auteurs ont également prouvé la faisabilité de l'IA, car elle peut être utilisée pour analyser des enregistrements continus : elle atteint alors une précision de 88 %.

□ Détection de la douleur

La plupart des études concernant la détection de la douleur chez les animaux de production ne sont pour l'instant que des preuves de concepts à l'application pratique difficile, mais avec des résultats cependant prometteurs (Neethirajan, 2021). McLennan et Mahmoud (2019) rapportent par exemple le développement d'une IA utilisant la vision par ordinateur et un SVM pour classer des moutons sur une échelle de *scoring* de la douleur.

d. La détection de la douleur chez les animaux de laboratoire

Les animaux de laboratoire pourraient également bénéficier des apports de ce type d'intelligence artificielle. Ces animaux sont traditionnellement placés dans des cages transparentes permettant leur observation. L'intégralité de la cage est donc filmée par une caméra fixe, mais seules les images montrant la face des animaux sont utilisées par les IA (Broomé *et al.*, 2023). Ces conditions très contrôlées permettent d'atteindre des précisions plus élevées que pour les autres espèces (Feighelstein *et al.*, 2022). Tuttle *et al.* (2018) et Andresen *et al.* (2020) ont élaboré des IA capables de détecter et classer les expressions faciales de souris de laboratoire, respectivement de souris blanches et de souris noires. Les deux équipes ont utilisé une méthodologie similaire aux études évoqués précédemment : à partir d'enregistrements vidéo ou de photos, un premier modèle est chargé de détecter la tête des souris, puis un second modèle attribue un score de douleur. Lorsque ces résultats sont comparés à ceux d'un observateur humain, l'IA de Tuttle *et al.* atteint une précision de 94 % et celle d'Andresen *et al.* atteint jusqu'à 99 % selon le CNN employé. D'autres solutions partiellement automatisées ont également été développées pour d'autres espèces comme le rat ou les macaques rhésus (Broomé *et al.*, 2023 ; Feighelstein *et al.*, 2022).

3. La place et le rôle de l'intelligence artificielle dans le diagnostic et la pratique généraliste et ses conséquences pour la profession

A. Une relation vétérinaire – propriétaire – patient qui doit évoluer avec les apports de l'intelligence artificielle

a. Une relation particulière

Grâce à ses nombreuses applications possibles en médecine vétérinaire, l'IA a le potentiel de révolutionner la façon d'établir un diagnostic. Mais ses apports ne se limitent pas à l'aspect scientifique : c'est bien l'ensemble de la démarche diagnostique qui peut être bouleversée, à commencer par la relation vétérinaire – propriétaire – patient (ou VCPR pour *Veterinarian – Client – Patient Relationship*).

La médecine vétérinaire est particulière, car la VCPR est tripartite (AVMA, 2023). Bien que les intérêts du patient soient primordiaux, les animaux ne peuvent évidemment pas exprimer leur consentement et la décision finale revient toujours au propriétaire (Coghlan et Quinn, 2023). Par ailleurs, la pratique vétérinaire est le plus souvent financée directement par les propriétaires, avec une couverture santé qui reste variable selon les pays. En cas de difficultés financières, des compromis doivent être réalisés et certains vétérinaires ou propriétaires peuvent opter pour des diagnostics ou des traitements inférieurs (Coghlan et Quinn, 2023). Ainsi, les apports de l'IA dans la démarche diagnostique vétérinaire soulèvent leurs propres enjeux éthiques, distincts de ceux observés en médecine humaine.

b. Les vétérinaires au cœur des changements apportés par l'intelligence artificielle

- ***Les vétérinaires, des praticiens parfois réticents au changement***

Le premier changement de la VCPR concerne les vétérinaires, mais ces derniers sont divisés concernant l'utilisation de l'IA. L'étude de Currie *et al.* (2023) a par exemple interrogé 84 vétérinaires et auxiliaires vétérinaires australiens concernant l'apport de l'IA. Les auteurs rapportent que l'acceptation de l'IA est haute pour les « tâches de moindre importance » (gestion des dossiers, triage, *etc.*), avec un intérêt majeur pour l'automatisation de tâches longues. Pour autant, l'usage de l'IA n'était pas toujours accepté pour les « tâches importantes », comme l'interprétation de résultats d'imagerie. Le constat est similaire pour le questionnaire réalisé par Ruffinoni (2023) dans le cadre d'une thèse d'exercice vétérinaire sur les outils numériques à disposition des vétérinaires praticiens. Les réponses recueillies auprès de 112 vétérinaires français révèlent que 30 % environ utilisent ces outils et que seule la moitié d'entre eux environ prévoit leur adoption dans les cinq prochaines années.

Plusieurs raisons sont couramment avancées pour expliquer la réticence des vétérinaires. La première est à relier au manque de connaissances fondamentales dans ce domaine (Briganti et Le Moine, 2020 ; Ezanno *et al.*, 2021). L'atlas démographique de la profession vétérinaire établit par ailleurs l'âge moyen des praticiens à 43 ans environ (Observatoire national démographique de la profession vétérinaire, 2023). C'est donc une part importante de la population vétérinaire qui n'a pas connu les développements de l'IA au cours de son cursus et qui doit être formée. La deuxième

raison est la crainte d'un éventuel remplacement des praticiens par les IA. Enfin, une dernière raison est liée à l'encadrement insuffisant de l'IA et aux dilemmes éthiques qui sont associés à son usage (Briganti et Le Moine, 2020 ; Ezanno *et al.*, 2021). Ces points sont traités individuellement dans la partie suivante.

- *Les réflexions actuelles autour des réticences liées à l'intelligence artificielle vétérinaire et ses implications*

L'adoption de l'IA en médecine vétérinaire ne pourra se faire que si son incorporation dans une démarche diagnostique est sûre (Basran et Appleby, 2022). À cette fin, Wilson *et al.* (2021) ont proposé en médecine humaine une approche en quatre phases : une phase de conceptualisation avec la création d'une équipe spécialisée capable de prendre en compte les aspects pratiques et éthiques ; une phase de récolte des données, en respectant leur confidentialité et leur qualité ; une phase de mise en application où l'IA est créée, testée et adaptée de manière collaborative ; puis une phase de maintenance. Cette approche peut facilement être adaptée pour une IA vétérinaire, si l'équipe de conception comprend des spécialistes vétérinaires (Basran et Appleby, 2022).

- La complexité des intelligences artificielles

Une enquête réalisée en 2022 révèle que 70 % des praticiens en médecine humaine jugent que les avancées technologiques récentes (dont l'IA) sont de nouvelles contraintes exigeantes. Ces praticiens pensent ainsi que le temps nécessaire pour comprendre et apprendre à se servir de ces technologies aurait en réalité pu servir aux patients (Coghlan et Quinn, 2023).

En effet, il est certain que les IA et les travaux nécessaires pour aboutir à leur conception sont complexes, ce qui constitue un obstacle à leur adoption. Néanmoins, même si elles ne constituent pas forcément la meilleure alternative ou l'alternative la plus fiable, le développement d'applications plus simples peut être envisagé (Ezanno *et al.*, 2021). C'est également la voie suivie par les GAFAM et leurs LLM (voir la partie **I.2.b.b.**, p. 36). Les modèles *open-source* les plus récents ont par exemple un nombre de paramètres fortement réduit (Touvron *et al.*, 2023b).

L'utilisation d'XAI (voir p. 46) pourra également faciliter l'adoption de l'IA par les praticiens, qui pourront comprendre comment elle raisonne (Kelly *et al.*, 2019). Ce principe permettra de pouvoir faire confiance aux résultats d'analyse fournis, de justifier les traitements mis en place (y compris l'euthanasie qui pourra éventuellement être proposée par des IA futures) et de détecter des erreurs de jugement (Coghlan et Quinn, 2023 ; Cohen et Gordon, 2022 ; Kelly *et al.*, 2019).

- La crainte infondée d'un remplacement par l'intelligence artificielle

- Des vétérinaires et des intelligences artificielles plus utiles ensemble

Il est peu probable et même non désirable que les IA remplacent entièrement les vétérinaires : l'IA vise plutôt à les assister pour les rendre meilleurs, plus précis et plus rapides (Ezanno *et al.*, 2021 ; Topol, 2019). En apportant une vision nouvelle, l'IA peut enrichir les informations que le praticien utilise pour son diagnostic final (Goecks *et al.*, 2020). Comme évoqué dans la partie **I.3.b.a.**, il n'y a donc pas toujours d'intérêt à comparer directement les performances d'un praticien à celles d'une IA. Il est plus judicieux d'évaluer dans quelles proportions la démarche diagnostique d'un praticien assisté d'une IA est améliorée (Briganti et Le Moine, 2020).

Les attentes sociétales en termes d'éthique et de bien-être animal sont également trop importantes pour que la gestion de la vie d'un animal ne soit laissée à une machine, sans

rétroaction possible par un humain (Ezanno *et al.*, 2021 ; Topol, 2019). Cet usage hybride de l'IA est par ailleurs bien mieux accueilli par les praticiens (Cohen et Gordon, 2022).

- L'intelligence artificielle au service du bien-être des vétérinaires

Si certains craignent une déshumanisation de la VCPR par l'IA, elle a en réalité le potentiel inverse. En automatisant les tâches longues ou répétitives, il devient possible de passer plus de temps auprès des animaux et d'accorder davantage d'importance à la construction d'une relation de confiance avec les propriétaires (Briganti et Le Moine, 2020 ; Cohen et Gordon, 2022).

Le temps récupéré grâce à l'IA pourrait aussi bénéficier aux vétérinaires eux-mêmes. L'augmentation des besoins de santé des animaux de compagnie a entraîné une forte hausse des charges de travail vétérinaires ces dernières années (Basran et Appleby, 2022). Cette demande accrue n'est malheureusement pas sans danger pour la santé de la profession, qui souffre déjà d'un taux de suicide élevé (Roberts *et al.*, 2013). En facilitant et accélérant la démarche diagnostique, l'IA a le potentiel de soulager les praticiens (Basran et Appleby, 2022).

Enfin, comme en médecine humaine, l'apparition de « téléconseillers » est un des apports envisageables de l'IA. Entraînés spécifiquement, ces conseillers sauront comprendre, transmettre et expliquer correctement les recommandations des IA aux propriétaires. En disposant des bonnes données, ils pourront aussi être en mesure de fournir des informations personnalisées en temps réel. Sans remplacer les praticiens diplômés, il s'agirait ainsi d'un moyen de réduire leur charge de travail tout en instaurant une relation plus personnelle avec les patients (Dimitrov, 2016).

- Le questionnement autour de l'encadrement de l'intelligence artificielle en médecine vétérinaire

Le cadre légal des IA, détaillé dans la partie **I.3.a.**, est encore relativement inadapté, même si de nouvelles mesures sont en discussion. Comme le craint la profession, l'absence d'encadrement soulève effectivement des questions de responsabilité, les devoirs du vétérinaire au sein de la VCPR n'étant plus adéquatement définis. La loi devra par exemple clarifier si l'usage d'une IA s'apparente ou non à référer un cas. Et dans cette situation, il faudra notamment déterminer qui parmi l'équipe scientifique, l'équipe de développement, l'organisme régulateur, l'IA, la clinique ou bien le vétérinaire devra être désigné responsable en cas de défaillance (Coghlan et Quinn, 2023 ; Cohen et Gordon, 2022).

Cette difficulté à définir une responsabilité claire est aggravée par le fonctionnement souvent opaque des IA et leurs hallucinations (voir **p. 41**). Ce manque de transparence peut avoir des conséquences non négligeables lors de son usage. Topol (2019) prend ainsi l'exemple de l'entreprise IBM et de son IA Watson, utilisée pour la recommandation de traitements oncologiques. À plusieurs reprises, celle-ci a proposé l'usage de molécules incorrectes, voire contraindiquées et dangereuses. L'IA a le potentiel d'être une source majeure de fautes médicales et d'autres troubles iatrogènes.

Au-delà de ce cadre légal, les vétérinaires devront également assumer une responsabilité morale lors de l'usage de l'IA, en particulier lorsqu'elle concerne l'euthanasie (Cohen et Gordon, 2022). Selon Coghlan et Quinn (2023), il n'existe actuellement pas d'IA suggérant l'euthanasie comme traitement, mais cela pourrait être envisagé à l'avenir. Il devient alors fortement possible que certaines recommandations puissent influencer les choix du propriétaire et du praticien et conduire à des euthanasies peu justifiées. L'effet inverse est également possible et une IA pourrait

encourager les propriétaires à poursuivre des traitements onéreux ou inutiles à un patient moribond (Coghlan et Quinn, 2023 ; Quain *et al.*, 2021).

Enfin, même s'ils sont actuellement interdits, l'usage de systèmes entièrement autonomes n'est pas non plus à exclure à l'avenir, ce qui implique également un changement des responsabilités portées par les cliniciens (Currie et Hawk, 2021).

- ***Le diagnostic par l'IA, une démarche améliorée mais pas sans danger***

Les vétérinaires doivent donc faire attention à la façon dont ils utilisent l'IA dans leur démarche, car le risque de biais d'automatisation est important. Ce biais consiste à accepter un résultat généré par une machine (une IA en l'occurrence) sans prendre suffisamment de recul sur le cas. On distingue les erreurs par commission (lorsque le praticien suit aveuglément un diagnostic de l'IA sans tenir compte du contexte) et les erreurs par omission (lorsque le praticien accorde une trop grande confiance à l'IA et ne remarque pas une anomalie) (Cohen et Gordon, 2022). Les auteurs suggèrent également que ce risque soit exacerbé en l'absence d'un spécialiste pouvant être consulté, notamment lors d'interprétation d'examen d'imagerie médicale.

Un risque découlant de ce biais est le surdiagnostic. Il s'agit de la découverte fortuite ou du diagnostic de maladies qui ne sont pas dangereuses pour le patient. Ces découvertes ont tout de même des conséquences importantes, comme la réalisation de tests ou de traitements superflus (Quain *et al.*, 2021). Un usage de plus en plus important de l'IA, par exemple lors d'examen de *screening* d'animaux sains, pourrait aggraver ce problème (Coghlan et Quinn, 2023). Le surdiagnostic peut également être une source importante de stress pour les vétérinaires, notamment concernant la communication autour de ces découvertes fortuites (Quain *et al.*, 2021).

Ce risque est particulièrement connu en médecine d'urgence, où le *monitoring* constant est répandu (Chenais *et al.*, 2023). Une surveillance permanente pourrait aussi conduire l'IA à alerter trop fréquemment le praticien, qui risque à terme d'ignorer ces avertissements. Ce phénomène est appelé l'*alert fatigue*, ou « désensibilisation aux alertes de sécurité » (Kelly *et al.*, 2019).

Une dernière possibilité évoquée est la perte progressive des compétences suite à une trop grande dépendance aux IA (Coghlan et Quinn, 2023). De manière similaire au biais d'automatisation, l'usage de plus en plus fréquent de l'IA pourrait entraîner une dépendance des utilisateurs au système et une certaine complaisance, en particulier dans des domaines où ils sont moins informés ou moins expérimentés (OpenAI, 2023).

c. Les propriétaires et leurs animaux, un point de vue différent

À l'inverse des vétérinaires, la médecine assistée par l'IA rencontre généralement un franc succès auprès des patients, car elle permet une « médecine des 4P » (Briganti et Le Moine, 2020). Ce modèle, théorisé par Hood et Flores (2012), comporte quatre volets : elle est prédictive, personnalisée, préventive et participative. Ce concept s'appuie donc naturellement sur la technologie, pour transférer une partie du contrat de soins au patient (ou au propriétaire) : celui-ci devient autonome et l'acteur central de ses soins (Briganti et Le Moine, 2020 ; Orth *et al.*, 2019). L'usage de la télémedecine précédemment évoquée est souvent apprécié des propriétaires. Une étude conduite sur environ 400 personnes a par exemple révélé une meilleure qualité de la communication, même si près de 60 % des téléconsultations ont nécessité une consultation de suivi en personne (Roca et McCarthy, 2019). L'usage de la télémedecine assistée par une IA pourrait également améliorer la perception du propriétaire envers le praticien. Lenharo (2024)

rapporte par exemple que les explications et l'empathie d'un LLM médical avait été mieux perçues que celles des médecins humains lors d'une téléconsultation fictive.

L'usage de l'IA implique cependant la collecte souvent massive de données médicales. À l'instar de la médecine humaine, les propriétaires doivent donc décider s'ils souhaitent que les données de leurs animaux soient enregistrées et traitées en permanence (Briganti et Le Moine, 2020). Comme l'oblige le RGPD (voir p. 38), il est d'ailleurs essentiel pour les propriétaires de pouvoir déterminer si leurs données sont utilisées par une IA, dans quelles situations et avec quelles mesures de protection (Cohen et Gordon, 2022 ; Currie et Hawk, 2021).

À l'avenir, les vétérinaires pourront aussi faire face à des propriétaires refusant des soins s'ils utilisent des IA dans leur démarche diagnostique. Le niveau de transparence à adopter sera alors fondamental. Les vétérinaires devront déterminer dans quelles conditions les propriétaires devront être informés et quels seront les usages où l'IA n'est qu'un outil d'aide au diagnostic (Currie et Hawk, 2021). Currie et Hawk insistent également sur le fait que les patients (ou les propriétaires) ne possèdent pas toujours les compétences nécessaires pour définir leurs attentes et leurs besoins vis-à-vis de l'IA. Une discussion honnête est alors essentielle, notamment pour ne pas imposer de point de vue particulier. Selon les préférences et le choix des propriétaires, l'XAI permettrait aussi un meilleur usage de l'IA (Coghlan et Quinn, 2023).

Enfin, il est nécessaire de déterminer si l'intervention d'une IA dans la prise de décision pourra être à l'origine de disparités concernant l'accès aux soins. Comme en médecine humaine, il n'est pas exclu que l'usage de l'IA puisse augmenter le coût de certains actes ou que des biais dans l'algorithme puissent introduire des inégalités de traitements entre différents propriétaires ou leurs animaux (Currie et Hawk, 2021).

B. La place de l'intelligence artificielle dans la structure vétérinaire : un diagnostic qui commence au chevet du patient

a. Le défi technique et économique de l'intégration de l'intelligence artificielle au sein d'une structure

Le coût technique, financier et énergétique de l'IA a des conséquences sur son utilisation. La puissance requise pour le fonctionnement d'une IA peut par exemple nécessiter l'utilisation de *cloud computing* (voir p. 12). Proposer des solutions augmentées par l'IA doit donc impérativement s'accompagner d'une gestion des coûts et du temps requis, afin d'offrir les bonnes informations au bon moment (Ezanno *et al.*, 2021). Les services de *cloud computing* ne sont par ailleurs pas infaillibles et des solutions de secours doivent être prévues en cas d'interruption.

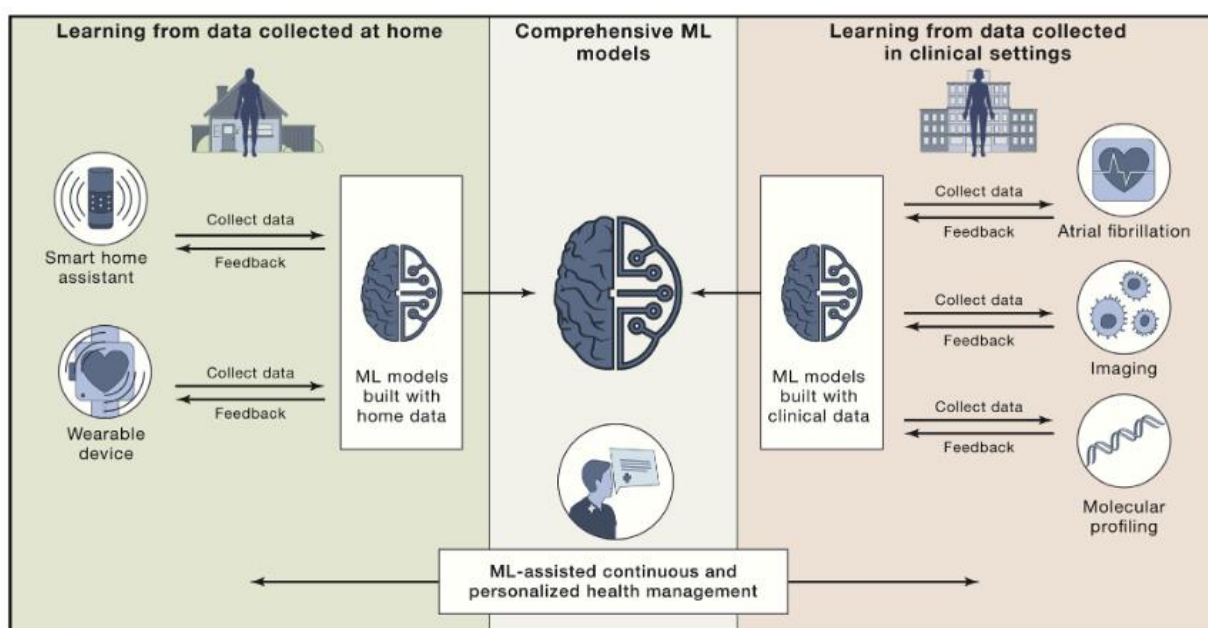
L'intégration de l'IA dans le modèle économique d'une structure médicale pourra également faire évoluer la médecine vétérinaire (Ezanno *et al.*, 2021). Historiquement, les praticiens sont rémunérés en l'échange d'un rendez-vous réalisé en personne. Ce modèle économique crée un biais dans la façon d'exercer la médecine : les technologies autour de la télémedecine sont fortement défavorisées. Il est donc nécessaire de réaliser une transition de cette médecine, nommée *fee-for-service*, ou « honoraires pour les services », vers un modèle fondé sur la valeur des soins et des conseils apportés (Dimitrov, 2016).

b. Le développement d'une médecine intégrée et continue

Comme commencent à le proposer les GAFAM en médecine humaine, il est envisageable que des *chatbots* puissent constituer une alternative intéressante au triage téléphonique classique (Gleiß *et al.*, 2021). Accessibles en permanence et disponibles sur téléphone, ces IA permettraient aux propriétaires de bénéficier facilement d'une télémédecine de première intention (Basran et Appleby, 2022). Les modèles de NLP actuels restent toutefois imprécis ou biaisés (voir la partie **I.3.b.**, p. 40). Si des solutions sont en cours de recherche, il est essentiel de traiter ces risques avant d'envisager la mise en service réelle d'un tel *chatbot* (Dave *et al.*, 2023).

Certains auteurs envisagent également des changements dans la gestion des patients. Plutôt que de traiter individuellement chaque maladie, la médecine pourra évoluer vers une gestion globale de la santé. Il ne faudra plus diagnostiquer une maladie en particulier, mais bien surveiller le bon vieillissement des patients au cours de leur vie et détecter précocement les anomalies. Comme illustré sur la **Figure 32**, la médecine de l'avenir sera personnalisée et continue, du domicile à la clinique. Différentes IA pourront centraliser et analyser les informations pour aider le praticien et le patient dans leur démarche (Goecks *et al.*, 2020).

Figure 32 : Un modèle de gestion personnalisée et continue de la santé augmentée par l'IA.
Utilisée avec l'autorisation de Goecks *et al.* (2020).



c. L'éthique animale, le dernier défi pour déterminer la place de l'intelligence artificielle

Les études récentes révèlent que les recherches éthiques ont jusqu'à présent peu pris en considération les conséquences de l'IA sur les animaux, qu'elles soient directes (les IA vétérinaires par exemple) ou indirectes (l'impact des IA sur l'environnement par exemple) (Coghlan et Parker, 2023). En tout état de cause, l'usage de l'IA peut avoir des conséquences importantes lorsqu'elle est utilisée pour établir un diagnostic, car les pressions éthiques ou légales sont moindres (Coghlan et Quinn, 2023 ; Quain *et al.*, 2021).

L'usage des IA pourrait devenir un moyen d'augmenter les ventes d'actes ou de produits (voir p. 45), en particulier dans des structures de taille plus modestes. L'IA vétérinaire pourrait aussi constituer une façon détournée d'expérimenter de nouvelles technologies ou de nouvelles approches avant un usage en médecine humaine. Enfin, les IA vétérinaires présentent un risque important d'être moins bien entraînées et donc d'être moins fiables, car le *Big Data* vétérinaire n'est souvent pas standardisé (voir p. 42) et car les moyens financiers sont plus limités (Coghlan et Quinn, 2023 ; Quain *et al.*, 2021).

C. L'inscription de l'intelligence artificielle dans le mouvement *One Health* et l'émergence de nouvelles possibilités entre deux médecines

Le concept de médecine unique, ou *One Health*, cherche à promouvoir la collaboration entre différents secteurs, car la santé humaine, la santé animale et la santé environnementale sont inextricablement liées (OHHLEP *et al.*, 2022). Dans ce contexte, il existe un potentiel important pour la recherche comparative en médecine vétérinaire. En particulier, les apports de l'IA dans le diagnostic vétérinaire peuvent avoir des retombées utiles à la médecine humaine et inversement, car les animaux peuvent avoir des maladies dont l'étiologie, l'évolution et la réponse au traitement peuvent être similaires à celles de l'Homme (Basran et Appleby, 2022 ; Kol *et al.*, 2015).

Les avancées scientifiques de la collecte massive de données génétiques et phénotypiques a permis la baisse du coût de son usage en médecine vétérinaire. Il devient alors possible d'étudier des maladies apparaissant spontanément et de récolter autant voire plus de données qu'en médecine humaine. Les animaux peuvent ainsi servir de modèles pour plusieurs maladies humaines (McCue et McCoy, 2017). Plusieurs de ces maladies ont été présentées précédemment et sont résumées dans le **Tableau 1**.

Tableau 1 : Tableau résumant les principales maladies des animaux de compagnie servant de modèles pour des maladies humaines

D'après Kol *et al.* (2015)

Domaine	Espèce	Maladie
Ophtalmologie	Chien	Kérato-conjonctivite sèche
Cardiologie	Chien	Myocardiopathie dilatée
	Chat	Myocardiopathie hypertrophique
Musculosquelettique	Cheval	Blessures tendineuses
	Chien	Rupture du ligament croisé antérieur
Neurologie	Chien	Hernie discale
Gastroentérologie	Chat	Maladie inflammatoire chronique de l'intestin
Génétique	Chien	Dystrophie musculaire
Oncologie	Chien et chat	Lymphome, sarcome, <i>etc.</i>

L'étude des maladies animales chez les animaux de compagnie tels que les chiens, les chats ou les grands animaux de production présente de nombreux avantages par rapport à leurs

équivalents humains : les animaux se reproduisent plus, plus rapidement et dans des conditions qui peuvent être contrôlées ; leur environnement peut être surveillé et similaire à celui dans lequel vivent les humains ; il est possible de récolter des échantillons biologiques plus facilement ; ils sont plus représentatifs pour l'Homme par rapport à de plus petits animaux comme les souris de laboratoire, en particulier pour des maladies telles qu'un cancer ou de l'arthrose ; et il est plus éthique d'étudier des maladies survenant naturellement chez des animaux (Kol *et al.*, 2015 ; McCue et McCoy, 2017 ; Paynter *et al.*, 2021).

Certaines de ces études présentent toutefois des limites : elles ne sont pas toujours conçues pour en tirer des applications en médecine humaine ou peuvent ne pas être menées correctement. Il peut également subsister des différences génétiques ou métaboliques entre l'humain et les animaux, pouvant freiner l'interprétation de certains résultats (Kol *et al.*, 2015).

Conclusion

L'intelligence artificielle a un rôle prometteur à jouer dans le diagnostic vétérinaire, car les avancées technologiques de ces dernières décennies offrent de nouvelles possibilités d'analyse des données. Le *Big Data*, l'intelligence artificielle et le *Machine Learning* regroupent des technologies variées, mais dont le fonctionnement est souvent complexe. Leur compréhension est néanmoins essentielle pour garantir leur bon usage. Les architectures les plus fréquemment rencontrées en médecine vétérinaire sont probablement les forêts d'arbres décisionnels et les réseaux de neurones convolutifs, mais il en existe de nombreuses autres dont certaines ont été présentées.

Le secteur rural est historiquement le premier bénéficiaire de l'intelligence artificielle, car la production de données d'élevage est accessible et massive grâce à l'utilisation progressive de caméras, de capteurs et de robots de traite. L'augmentation constante du nombre d'animaux de compagnie laisse cependant supposer un marché important pour des intelligences artificielles assistant les vétérinaires à dominante canine dans leurs démarches diagnostiques. Des opportunités uniques ont ainsi été présentées, allant de la détection précoce de nombreuses maladies à l'interprétation d'examens d'imagerie médicale et d'analyses sanguines.

Il est cependant crucial d'identifier les défis liés à l'utilisation de l'intelligence artificielle. Il existe ainsi des limites d'ordre technologique, directement liées aux modèles de ML utilisés, mais aussi des enjeux éthiques. Pour garantir une utilisation responsable de l'intelligence artificielle, un cadre légal adapté et une validation rigoureuse des données et des modèles sont indispensables. Une approche multidisciplinaire sera également requise pour intégrer l'intelligence artificielle dans une pratique quotidienne, car la relation vétérinaire – propriétaire – animal, au cœur de la profession, en sera profondément modifiée.

La médecine humaine pourra également être bouleversée par les apports de l'intelligence artificielle vétérinaire, car il existe de nombreuses similitudes entre les maladies humaines et animales et des études multi-espèces existent déjà. L'utilisation raisonnée de l'intelligence artificielle a le potentiel de faire avancer la science et une médecine unique pour l'environnement, l'Homme et les animaux.

Annexe 1 – Tableau récapitulatif

Tableau résumant les IA citées dans la partie II.2, par espèce, par domaine et par objectif

RX : radiographie ; CT : tomodensitométrie ; US : échographie ; IRM : imagerie par résonance magnétique ;
OCT : tomographie en cohérence optique

Espèce	Domaine	Objectif affiché de l'IA	Référence
Animaux de compagnie			
Chien <i>Canis lupus familiaris</i>	Maladie infectieuse	Diagnostic d'une leishmaniose viscérale	(Coelho <i>et al.</i> , 2023 ; Larios <i>et al.</i> , 2021 ; Torrecilha <i>et al.</i> , 2017)
		Diagnostic automatisé de parasites présents dans les selles	(Inácio <i>et al.</i> , 2020 ; Joao <i>et al.</i> , 2023) Appareils Vetscan Imagyst (voir le rapport de Nagamori <i>et al.</i> (2021)) et SediVue dx
		Diagnostic d'une piroplasmose	(Pijnacker <i>et al.</i> , 2022)
		Diagnostic d'une leptospirose	(Reagan <i>et al.</i> , 2022a)
	Endocrinologie	Diagnostic d'une hypothyroïdie	(Corsini <i>et al.</i> , 2023)
		Diagnostic d'une maladie d'Addison	(Reagan <i>et al.</i> , 2020, 2022b)
		Diagnostic d'une maladie de Cushing	(Schofield <i>et al.</i> , 2021)
	Trouble locomoteur	Prédiction du risque de rupture du ligament croisé crânial	(Baker <i>et al.</i> , 2020)
		Diagnostic d'une luxation médiale de la rotule	(Jung <i>et al.</i> , 2023)
		Diagnostic d'une ataxie	(Engelsman <i>et al.</i> , 2022)
		Diagnostic d'une boiterie d'un membre postérieur	(Figueirinhas <i>et al.</i> , 2022)
	Ophtalmologie	Diagnostic d'un ulcère cornéen	(Kim <i>et al.</i> , 2019)
		Diagnostic d'une kérato-conjonctivite sèche	(J. Y. Kim <i>et al.</i> , 2022)
	Dermatologie	Diagnostic d'une pododermatite ou d'une néoplasie	(Smith <i>et al.</i> , 2023)

	Aide à la détection d'un épisode prurigineux	(Carson <i>et al.</i> , 2023)
Oncologie	Aide à la gradation histologique d'un lymphome	(Haghofer <i>et al.</i> , 2023)
	Aide à la gradation histologique d'un sarcome	(Morisi <i>et al.</i> , 2023)
	Diagnostic non invasif de la malignité d'une masse cutanée ou sous-cutanée	(Dank <i>et al.</i> , 2023a, 2023b)
	Diagnostic automatisé de sept types de tumeurs cutanées	(Fragoso-Garcia <i>et al.</i> , 2023)
	Voir également les revues de Hennessey <i>et al.</i> (2022) et Pereira <i>et al.</i> (2023).	
Imagerie médicale	Diagnostic d'une dysplasie des hanches (RX)	(McEvoy et Amigo, 2013 ; McEvoy <i>et al.</i> , 2021)
	Diagnostic d'une fracture des os longs et de son âge ; diagnostic de la maturité osseuse de l'animal (RX)	(Ergün et Güney, 2021)
	Diagnostic d'une dystrophie musculaire (IRM)	(Duda <i>et al.</i> , 2018)
	Diagnostic d'un sarcome des tissus mous / identification de ses marges (OCT)	(Ye <i>et al.</i> , 2021)
	Diagnostic d'une cardiomégalie ; calcul automatisé du VHS (RX)	(Boissady <i>et al.</i> , 2021 ; Burti <i>et al.</i> , 2020 ; S. Li <i>et al.</i> , 2020 ; Zhang <i>et al.</i> , 2021)
	Détermination du stade d'une maladie valvulaire dégénérative mitrale (RX)	(Valente <i>et al.</i> , 2023)
	Diagnostic d'une lésion pulmonaire (RX)	(Arsonngern <i>et al.</i> , 2019 ; Marschner <i>et al.</i> , 2017 ; Ott <i>et al.</i> , 2021)
	Diagnostic d'une anomalie thoracique (RX)	(Banzato <i>et al.</i> , 2021a ; Yoon <i>et al.</i> , 2018) Logiciels PicoxIA (voir les rapports de Boissady <i>et al.</i> (2020) et Hespel <i>et al.</i> (2022)) et Vetology AI (voir les rapports de Kim <i>et al.</i> (2022) et Müller <i>et al.</i> (2022))
	Diagnostic d'une maladie hépatique (US)	(Banzato <i>et al.</i> , 2018b)
	Détermination de la malignité d'une masse hépatique (CT)	(Burti <i>et al.</i> , 2021 ; Shaker <i>et al.</i> , 2021)

		Détermination de la malignité d'une masse splénique (CT)	(Burti <i>et al.</i> , 2022)
		Détection d'un calcul rénal (CT)	(Ji <i>et al.</i> , 2023)
		Diagnostic et <i>scoring</i> d'un méningiome ; aide à la différenciation avec un gliome (IRM)	(Banzato <i>et al.</i> , 2018a, 2018c, 2017)
		Détermination du type et grade d'un gliome ; différenciation avec une méningoencéphalite inflammatoire (IRM)	(Barge <i>et al.</i> , 2023 ; Wanamaker <i>et al.</i> , 2021)
		Diagnostic d'une malformation Chiari- <i>like</i> (IRM)	(Spiteri <i>et al.</i> , 2019)
		Diagnostic d'une myélopathie (IRM)	(Biercher <i>et al.</i> , 2021)
	Bien-être animal	Détection de l'état émotionnel, dont la douleur	(Mao et Liu, 2023 ; Zhu <i>et al.</i> , 2023)
	Autre	Diagnostic précoce d'une MRC	(Kokkinos <i>et al.</i> , 2022)
		Diagnostic d'un SORB	(Oren <i>et al.</i> , 2023)
Chat <i>Felis catus</i>	Maladie infectieuse	Diagnostic automatisé de parasites présents dans les selles	(Joao <i>et al.</i> , 2023) Appareils Vetscan Imagyst (voir le rapport de Nagamori <i>et al.</i> (2021)) et SediVue dx
	Oncologie	Diagnostic non invasif (bilans sanguins) d'une MICI ou d'un lymphome intestinal	(Awaysheh <i>et al.</i> , 2016)
		Diagnostic d'une MICI ou d'un lymphome intestinal grâce à une biopsie endoscopique	(li <i>et al.</i> , 2023)
		Aide à la gradation histologique d'un lymphome	(Haghofer <i>et al.</i> , 2023)
	Imagerie médicale	Voir également les revues de Hennessey <i>et al.</i> (2022) et Pereira <i>et al.</i> (2023).	
		Diagnostic d'une myocardopathie hypertrophique (RX)	(Rho <i>et al.</i> , 2023)
		Diagnostic d'une lésion pulmonaire (RX)	(Dumortier <i>et al.</i> , 2022)

		Diagnostic d'une anomalie thoracique (RX)	(Banzato <i>et al.</i> , 2021b) Logiciels PicoxIA et Vetology AI
		Diagnostic d'une anomalie intestinale ou d'une indication à la réalisation d'une biopsie (US)	(Basran <i>et al.</i> , 2023)
	Bien-être animal	Détection de la douleur	(Feighelstein <i>et al.</i> , 2022, 2023b ; Steagall <i>et al.</i> , 2023)
	Autre	Diagnostic précoce d'une MRC	(Biourge <i>et al.</i> , 2020 ; Bradley <i>et al.</i> , 2019)
Lapin <i>Oryctolagus cuniculus</i>	Bien-être animal	Détection de la douleur	(Feighelstein <i>et al.</i> , 2023a)
Souris <i>Mus musculus</i>	Bien-être animal	Détection de la douleur	(Andresen <i>et al.</i> , 2020 ; Tuttle <i>et al.</i> , 2018)
Chevaux			
Cheval <i>Equus caballus</i>	Trouble locomoteur	Diagnostic d'une boiterie	Voir la revue de Mouloudi <i>et al.</i> (2021) (Feuser <i>et al.</i> , 2022 ; Parmentier <i>et al.</i> , 2023 ; Schobesberger et Peham, 2002)
		Diagnostic d'un surmenage physique	(Darbandi <i>et al.</i> , 2023)
	Imagerie médicale	Diagnostic d'une inflammation de l'os sésamoïde proximal	(Guo <i>et al.</i> , 2024)
	Bien-être animal	Détection de la douleur	Voir la revue de Broomé <i>et al.</i> (2023)
	Autre	Prédiction du besoin d'une prise en charge chirurgicale d'une colique ; établissement du pronostic	(Fraiwan et Abutarbush, 2020)
		Diagnostic d'une uvéite	(May <i>et al.</i> , 2022)
		Diagnostic d'une anomalie sur l'ECG	(Van Steenkiste <i>et al.</i> , 2020)
		Comptage automatisé des hémosidérophages et diagnostic automatisé d'une hémorragie pulmonaire induite à l'effort	(Bertram <i>et al.</i> , 2023 ; Marzahl <i>et al.</i> , 2020)

Animaux de production

Vache <i>Bos taurus</i>	Reproduction	Prédiction du risque d'avortement	(Keshavarzi <i>et al.</i> , 2020)
		Prédiction de la date de vêlage	(Borchers <i>et al.</i> , 2017 ; Keceli <i>et al.</i> , 2020 ; Vázquez-Diosdado <i>et al.</i> , 2023)
		Prédiction de la difficulté au vêlage	(Alsahaf <i>et al.</i> , 2023)
		Diagnostic précoce d'une métrite	(Vidal <i>et al.</i> , 2023)
		Prédiction d'une mammite <i>post-partum</i>	(J. S. Thompson <i>et al.</i> , 2023)
		Prédiction du premier jour de production laitière après le vêlage	(Salamone <i>et al.</i> , 2022)
		Détection de l'œstrus	(Arkan <i>et al.</i> , 2023 ; Cairo <i>et al.</i> , 2020 ; Higaki <i>et al.</i> , 2019, 2021 ; Jung <i>et al.</i> , 2021 ; Wang <i>et al.</i> , 2020, 2023)
		Diagnostic de la qualité des ovocytes et blastocytes	(Costa <i>et al.</i> , 2023 ; Rocha <i>et al.</i> , 2017)
		Diagnostic de gestation	(Brand <i>et al.</i> , 2021)
		Diagnostic d'une endométrite	(Sadeghi <i>et al.</i> , 2022)
Maladie métabolique	Prédiction du risque de cétose subclinique	(Ehret <i>et al.</i> , 2015 ; Sturm <i>et al.</i> , 2020)	
	Détermination du statut métabolique d'un animal en début de lactation	(Xu <i>et al.</i> , 2019)	
Maladie infectieuse	Diagnostic précoce d'une kérato-conjonctivite infectieuse bovine	(Gupta <i>et al.</i> , 2023)	
	Diagnostic précoce d'une anaplasmose	(Teixeira <i>et al.</i> , 2022)	
	Diagnostic précoce d'un trouble respiratoire	(Cantor <i>et al.</i> , 2022 ; Jung <i>et al.</i> , 2021 ; Puig <i>et al.</i> , 2022 ; Wu <i>et al.</i> , 2023)	
	Prédiction d'une crise de fièvre aphteuse	(Punyapornwithaya <i>et al.</i> , 2022)	

		Détection précoce d'un animal positif au test cutané de la tuberculose ; prédiction d'un cas de tuberculose ; prédiction de la positivité d'un animal avec un test cutané douteux	(Denholm <i>et al.</i> , 2020 ; Romero <i>et al.</i> , 2021, 2022)	
		Diagnostic d'une mammite	(Ebrahimie <i>et al.</i> , 2018a, 2018b ; Hyde <i>et al.</i> , 2020 ; Kamphuis <i>et al.</i> , 2010 ; Samarasinghe <i>et al.</i> , 2018 ; Sun <i>et al.</i> , 2010 ; J. Thompson <i>et al.</i> , 2023 ; Y. Wang <i>et al.</i> , 2022 ; Zhang <i>et al.</i> , 2020)	
		Diagnostic de l'état des mamelles	(Porter <i>et al.</i> , 2021)	
		Diagnostic d'un trouble infectieux ou inflammatoire du SNC	(Ferrini <i>et al.</i> , 2023)	
	Trouble locomoteur		Prédiction et détection précoce d'une dermatite interdigitée	(Cerneke <i>et al.</i> , 2020 ; Magana <i>et al.</i> , 2023)
			Détection d'une boiterie	(Anagnostopoulos <i>et al.</i> , 2023 ; Barney <i>et al.</i> , 2023 ; Borghart <i>et al.</i> , 2021 ; Nejati <i>et al.</i> , 2023 ; Volkmann <i>et al.</i> , 2021)
	Autre		Détermination de la NEC	(Mullins <i>et al.</i> , 2019 ; O' Leary <i>et al.</i> , 2020 ; Siachos <i>et al.</i> , 2023 ; Summerfield <i>et al.</i> , 2023)
Mouton <i>Ovis aeries</i>	Maladie infectieuse	Diagnostic automatisé de parasites présents dans les selles	(Li <i>et al.</i> , 2019)	
	Bien-être animal	Détection de la douleur	(McLennan et Mahmoud, 2019)	
Chèvre (ou mouton) <i>Capra hircus</i>	Maladie infectieuse	Prédiction d'un foyer de peste des petits ruminants	(Niu <i>et al.</i> , 2020)	
		Automatisation de la méthode Famacha pour le diagnostic d'une haemonchose	(de Souza <i>et al.</i> , 2023)	
Porc <i>Sus domesticus</i>	Reproduction	Détection de l'œstrus	Voir la revue de Wang <i>et al.</i> (2022) (Chen <i>et al.</i> , 2021 ; D. Li <i>et al.</i> , 2020)	
	Maladie infectieuse	Diagnostic d'un trouble respiratoire	Voir la revue de Wang <i>et al.</i> (2022) (Halev <i>et al.</i> , 2023 ; Shen <i>et al.</i> , 2021)	
		Prédiction d'un foyer de diarrhée épidémique porcine	(Halev <i>et al.</i> , 2023 ; Machado <i>et al.</i> , 2019 ; Pappas <i>et al.</i> , 2021)	

		Prédiction d'un foyer de peste porcine africaine	(Liang <i>et al.</i> , 2020)
		Prédiction d'un foyer de virus du syndrome dysgénésique et respiratoire du porc	(Halev <i>et al.</i> , 2023 ; Shamsabardeh <i>et al.</i> , 2022)
	Autre	Diagnostic de morsures à la queue	Voir la revue de Wang <i>et al.</i> (2022) (Hakansson et Jensen, 2023)
Poule domestique <i>Gallus gallus domesticus</i>	Maladie infectieuse	Prédiction d'une crise d'influenza aviaire	(Liu <i>et al.</i> , 2023)
		Prédiction du risque de contamination d'un élevage par <i>Listeria</i> spp.	(Golden <i>et al.</i> , 2019)
		Diagnostic d'une grippe aviaire	Voir la revue de Franzo <i>et al.</i> (2023) (Cuan <i>et al.</i> , 2020 ; Sadeghi <i>et al.</i> , 2023 ; Zhuang <i>et al.</i> , 2018)
		Diagnostic d'une bronchite infectieuse	(Mahdavian <i>et al.</i> , 2021)
		Diagnostic d'une maladie de Newcastle	(Cuan <i>et al.</i> , 2022 ; Mahdavian <i>et al.</i> , 2021)
		Diagnostic d'une infection à <i>Clostridium perfringens</i>	(Sadeghi <i>et al.</i> , 2015)
		Détection de <i>Plasmodium gallinaceum</i> et diagnose de son stade sur un frottis sanguin	(Kittichai <i>et al.</i> , 2021)
		Diagnose d'oocytes d' <i>Eimeria</i> présents dans les selles	Voir la revue de Franzo <i>et al.</i> (2023) (He <i>et al.</i> , 2023)
	Trouble locomoteur	Diagnostic d'une pododermatite de contact	(Hepworth <i>et al.</i> , 2012)
	Bien-être animal	Diagnostic d'un stress thermique	(Du <i>et al.</i> , 2020)
		Diagnostic de l'état émotionnel	Voir la revue de Franzo <i>et al.</i> (2023) (Mao <i>et al.</i> , 2022)
	Autre	Diagnostic d'une ascite	(Roush <i>et al.</i> , 1996)
		Diagnostic d'une activité physique insuffisante ou d'une répartition anormale des animaux	(Chen <i>et al.</i> , 2023)

Dromadaire <i>Camelus dromedarius</i>	Maladie infectieuse	Diagnostic d'une surra	(Benfodil <i>et al.</i> , 2022)
Huître <i>Ostreidae spp.</i>	Autre	Prédiction d'un foyer de norovirus pouvant être transmis à l'Homme	(Chenar et Deng, 2018)
Truite arc-en-ciel <i>Oncorhynchus mykiss</i>	Maladie infectieuse	Diagnostic d'une infection à <i>Lactococcus garvieae</i> ou <i>Vagococcus sp.</i>	(Yilmaz <i>et al.</i> , 2023)
Autres animaux			
Reptiles	Maladie infectieuse	Diagnostic automatisé de parasites présents dans les selles	(Parra <i>et al.</i> , 2022)

Liste des références bibliographiques

- ABDULJABBAR, K., CASTILLO, S.P., HUGHES, K., *et al.* (2023) Bridging clinic and wildlife care with AI-powered pan-species computational pathology. *Nature Communications* vol. 14, n° 1, p. 2408. [<https://doi.org/10.1038/s41467-023-37879-x>]
- ABPI (2011) Demonstrating value with Real World data, communication écrite.
- ALSAHAF, A., GHEORGHE, R., HIDALGO, A.M., *et al.* (2023) Pre-insemination prediction of dystocia in dairy cattle. *Preventive Veterinary Medicine* vol. 210, p. 105812. [<https://doi.org/10.1016/j.prevetmed.2022.105812>]
- ALT, R., ZIMMERMANN, H.-D. (2021) The digital transformation of healthcare - An interview with Werner Dorfmeister. *Electronic Markets* vol. 31, n° 4, p. 895-899. [<https://doi.org/10.1007/s12525-021-00476-1>]
- ALTMAN, N., KRZYWINSKI, M. (2018) The curse(s) of dimensionality. *Nature Methods* vol. 15, n° 6, p. 399-400. [<https://doi.org/10.1038/s41592-018-0019-x>]
- ANAGNOSTOPOULOS, A., GRIFFITHS, B.E., SIACHOS, N., *et al.* (2023) Initial validation of an intelligent video surveillance system for automatic detection of dairy cattle lameness. *Frontiers in Veterinary Science* vol. 10, p. 1111057. [<https://doi.org/10.3389/fvets.2023.1111057>]
- ANDRESEN, N., WÖLLHAF, M., HOHLBAUM, K., *et al.* (2020) Towards a fully automated surveillance of well-being status in laboratory mice using deep learning: Starting with facial expression analysis. *PLoS One* vol. 15, n° 4, p. e0228059. [<https://doi.org/10.1371/journal.pone.0228059>]
- APPLEBY, R.B., BASRAN, P.S. (2022) Artificial intelligence in veterinary medicine. *Journal of the American Veterinary Medical Association* vol. 260, n° 8, p. 819-824. [<https://doi.org/10.2460/javma.22.03.0093>]
- ARIKAN, İ., AYAV, T., SEÇKIN, A.Ç., *et al.* (2023) Estrus Detection and Dairy Cow Identification with Cascade Deep Learning for Augmented Reality-Ready Livestock Farming. *Sensors* vol. 23, n° 24, p. 9795. [<https://doi.org/10.3390/s23249795>]
- ARSOMNGERN, P., NUMCHAROENPINIJ, N., PIRIYATARAVET, J., *et al.* (2019) Computer-Aided Diagnosis for Lung Lesion in Companion Animals from X-ray Images Using Deep Learning Techniques. In *2019 IEEE 10th International Conference on Awareness Science and Technology (ICAST)*. Morioka, Japan, 23-25 octobre, IEEE, p. 1-6. [<https://doi.org/10.1109/ICAwST.2019.8923126>]
- ARTE DISTRIBUTION (2021) When Big Tech Targets Healthcare. [https://distribution.arte.tv/fiche/Main_basse_sur_votre_medecine] (consulté le 08/11/2023).
- ASF (2023a) Apache Hadoop Documentation. [<https://hadoop.apache.org/docs/stable/>] (consulté le 31/10/2022).
- ASF (2023b) Index of /dist/hadoop/common. [<https://archive.apache.org/dist/hadoop/common/>] (consulté le 31/10/2022).
- ASF (2023c) Apache Spark [Logiciel].
- AUBREVILLE, M., BERTRAM, C.A., MARZAHN, C., *et al.* (2020) Deep learning algorithms outperform veterinary pathologists in detecting the mitotically most active tumor region. *Scientific Reports* vol. 10, n° 1, p. 16447. [<https://doi.org/10.1038/s41598-020-73246-2>]
- AVMA (2023) Veterinarian-client-patient relationship. In *American Veterinary Medical Association*. [<https://www.avma.org/resources-tools/avma-policies/veterinarian-client-patient-relationship>] (consulté le 24/11/2023).
- AWAYSHEH, A., WILCKE, J., ELVINGER, F., *et al.* (2019) Review of Medical Decision Support and Machine-Learning Methods. *Veterinary Pathology* vol. 56, n° 4, p. 512-525. [<https://doi.org/10.1177/0300985819829524>]
- AWAYSHEH, A., WILCKE, J., ELVINGER, F., *et al.* (2016) Evaluation of supervised machine-learning algorithms to distinguish between inflammatory bowel disease and alimentary

- lymphoma in cats. *Journal of Veterinary Diagnostic Investigation* vol. 28, n° 6, p. 679-687. [<https://doi.org/10.1177/1040638716657377>]
- BAKER, L.A., MOMEN, M., CHAN, K., *et al.* (2020) Bayesian and Machine Learning Models for Genomic Prediction of Anterior Cruciate Ligament Rupture in the Canine Model. *G3* vol. 10, n° 8, p. 2619-2628. [<https://doi.org/10.1534/g3.120.401244>]
- BAKKER, L., AARTS, J., UYL-DE GROOT, C., *et al.* (2020) Economic evaluations of big data analytics for clinical decision-making: a scoping review. *Journal of the American Medical Informatics Association* vol. 27, n° 9, p. 1466-1475. [<https://doi.org/10.1093/jamia/ocaa102>]
- BANAEI, H., AHMED, M.U., LOUFI, A. (2013) Data mining for wearable sensors in health monitoring systems: a review of recent trends and challenges. *Sensors* vol. 13, n° 12, p. 17472-17500. [<https://doi.org/10.3390/s131217472>]
- BANDEIRA, A.S. (2020) Lecture Notes for Mathematics of Data Science, communication écrite.
- BANFIELD PET HOSPITAL (2023) State of Pet Health. In *Banfield Pet Hospital*. [<https://www.banfield.com/pet-health/State-of-pet-health>] (consulté le 04/03/2023).
- BANZATO, T., BERNARDINI, M., CHERUBINI, G.B., *et al.* (2018a) A methodological approach for deep learning to distinguish between meningiomas and gliomas on canine MR-images. *BMC Veterinary Research* vol. 14, n° 1, p. 317. [<https://doi.org/10.1186/s12917-018-1638-2>]
- BANZATO, T., BERNARDINI, M., CHERUBINI, G.B., *et al.* (2017) Texture analysis of magnetic resonance images to predict histologic grade of meningiomas in dogs. *American Journal of Veterinary Research* vol. 78, n° 10, p. 1156-1162. [<https://doi.org/10.2460/ajvr.78.10.1156>]
- BANZATO, T., BONSEMBIANTE, F., ARESU, L., *et al.* (2018b) Use of transfer learning to detect diffuse degenerative hepatic diseases from ultrasound images in dogs: A methodological study. *Veterinary Journal* vol. 233, p. 35-40. [<https://doi.org/10.1016/j.tvjl.2017.12.026>]
- BANZATO, T., CHERUBINI, G.B., ATZORI, M., *et al.* (2018c) Development of a deep convolutional neural network to predict grading of canine meningiomas from magnetic resonance images. *Veterinary Journal* vol. 235, p. 90-92. [<https://doi.org/10.1016/j.tvjl.2018.04.001>]
- BANZATO, T., WODZINSKI, M., BURTI, S., *et al.* (2021a) Automatic classification of canine thoracic radiographs using deep learning. *Scientific Reports* vol. 11, n° 1, p. 3964. [<https://doi.org/10.1038/s41598-021-83515-3>]
- BANZATO, T., WODZINSKI, M., TAUCERI, F., *et al.* (2021b) An AI-Based Algorithm for the Automatic Classification of Thoracic Radiographs in Cats. *Frontiers in Veterinary Science* vol. 8, p. 731936. [<https://doi.org/10.3389/fvets.2021.731936>]
- BARGE, P., OEVERMANN, A., MAIOLINI, A., *et al.* (2023) Machine learning predicts histologic type and grade of canine gliomas based on MRI texture analysis. *Veterinary Radiology & Ultrasound* vol. 64, n° 4, p. 724-732. [<https://doi.org/10.1111/vru.13242>]
- BARNEY, S., DLAY, S., CROWE, A., *et al.* (2023) Deep learning pose estimation for multi-cattle lameness detection. *Scientific Reports* vol. 13, n° 1, p. 4499. [<https://doi.org/10.1038/s41598-023-31297-1>]
- BARO, E., DEGOUL, S., BEUSCART, R., *et al.* (2015) Toward a Literature-Driven Definition of Big Data in Healthcare. *BioMed Research International* vol. 2015. [<https://doi.org/10.1155/2015/639021>]
- BASRAN, P.S., APPLEBY, R.B. (2022) The unmet potential of artificial intelligence in veterinary medicine. *American Journal of Veterinary Research* vol. 83, n° 5, p. 385-392. [<https://doi.org/10.2460/ajvr.22.03.0038>]
- BASRAN, P.S., SHCHERBAN, N., FORMAN, M., *et al.* (2023) Combining ultrasound radiomics, complete blood count, and serum biochemical biomarkers for diagnosing intestinal disorders in cats using machine learning. *Veterinary Radiology & Ultrasound* vol. 64, n° 5, p. 890-903. [<https://doi.org/10.1111/vru.13250>]
- BENFODIL, K., BENBOURAS, M.A., ANSEL, S., *et al.* (2022) Prediction of *Trypanosoma evansi* infection in dromedaries using artificial neural network (ANN). *Veterinary Parasitology* vol. 306, p. 109716. [<https://doi.org/10.1016/j.vetpar.2022.109716>]
- BENKE, K., BENKE, G. (2018) Artificial Intelligence and Big Data in Public Health. *International Journal of Environmental Research and Public Health* vol. 15, n° 12, p. 2796. [<https://doi.org/10.3390/ijerph15122796>]

- BERTRAM, C.A., MARZAHN, C., BARTEL, A., *et al.* (2023) Cytologic scoring of equine exercise-induced pulmonary hemorrhage: Performance of human experts and a deep learning-based algorithm. *Veterinary Pathology* vol. 60, n° 1, p. 75-85. [https://doi.org/10.1177/03009858221137582]
- BIERCHER, A., MELLER, S., WENDT, J., *et al.* (2021) Using Deep Learning to Detect Spinal Cord Diseases on Thoracolumbar Magnetic Resonance Images of Dogs. *Frontiers in Veterinary Science* vol. 8, p. 721167. [https://doi.org/10.3389/fvets.2021.721167]
- BINDAL, A. (2022) Stability AI builds foundation models on Amazon SageMaker. *In AWS Machine Learning Blog*. [https://aws.amazon.com/blogs/machine-learning/stability-ai-builds-foundation-models-on-amazon-sagemaker/] (consulté le 15/04/2023).
- BIOURGE, V., DELMOTTE, S., FEUGIER, A., *et al.* (2020) An artificial neural network-based model to predict chronic kidney disease in aged cats. *Journal of Veterinary Internal Medicine* vol. 34, n° 5, p. 1920-1931. [https://doi.org/10.1111/jvim.15892]
- BOBBO, T., MATERA, R., PEDOTA, G., *et al.* (2023) Exploiting machine learning methods with monthly routine milk recording data and climatic information to predict subclinical mastitis in Italian Mediterranean buffaloes. *Journal of Dairy Science* vol. 106, n° 3, p. 1942-1952. [https://doi.org/10.3168/jds.2022-22292]
- BOEHRINGER INGELHEIM (2023) SoundTalks. [https://www.soundtalks.com/] (consulté le 21/12/2023).
- BOISSADY, E., DE LA COMBLE, A., ZHU, X., *et al.* (2021) Comparison of a Deep Learning Algorithm vs. Humans for Vertebral Heart Scale Measurements in Cats and Dogs Shows a High Degree of Agreement Among Readers. *Frontiers in Veterinary Science* vol. 8, p. 764570. [https://doi.org/10.3389/fvets.2021.764570]
- BOISSADY, E., DE LA COMBLE, A., ZHU, X., *et al.* (2020) Artificial intelligence evaluating primary thoracic lesions has an overall lower error rate compared to veterinarians or veterinarians in conjunction with the artificial intelligence. *Veterinary Radiology & Ultrasound* vol. 61, n° 6, p. 619-627. [https://doi.org/10.1111/vru.12912]
- BONICELLI, L., TRACHTMAN, A.R., ROSAMILIA, A., *et al.* (2021) Training Convolutional Neural Networks to Score Pneumonia in Slaughtered Pigs. *Animals* vol. 11, n° 11, p. 3290. [https://doi.org/10.3390/ani11113290]
- BORCHERS, M.R., CHANG, Y.M., PROUDFOOT, K.L., *et al.* (2017) Machine-learning-based calving prediction from activity, lying, and ruminating behaviors in dairy cattle. *Journal of Dairy Science* vol. 100, n° 7, p. 5664-5674. [https://doi.org/10.3168/jds.2016-11526]
- BORGHART, G.M., O'GRADY, L.E., SOMERS, J.R. (2021) Prediction of lameness using automatically recorded activity, behavior and production data in post-parturient Irish dairy cows. *Irish Veterinary Journal* vol. 74, n° 1, p. 4. [https://doi.org/10.1186/s13620-021-00182-6]
- BORTOLUZZI, E.M., SCHMIDT, P.H., BROWN, R.E., *et al.* (2023) Image Classification and Automated Machine Learning to Classify Lung Pathologies in Deceased Feedlot Cattle. *Veterinary Sciences* vol. 10, n° 2, p. 113. [https://doi.org/10.3390/vetsci10020113]
- BOSCH, S., SERRA BRAGANÇA, F., MARIN-PERIANU, M., *et al.* (2018) EquiMoves: A Wireless Networked Inertial Measurement System for Objective Examination of Horse Gait. *Sensors* vol. 18, n° 3, p. 850. [https://doi.org/10.3390/s18030850]
- BRADLEY, R., TAGKOPOULOS, I., KIM, M., *et al.* (2019) Predicting early risk of chronic kidney disease in cats using routine clinical laboratory tests and machine learning. *Journal of Veterinary Internal Medicine* vol. 33, n° 6, p. 2644-2656. [https://doi.org/10.1111/jvim.15623]
- BRAND, W., WELLS, A.T., SMITH, S.L., *et al.* (2021) Predicting pregnancy status from mid-infrared spectroscopy in dairy cow milk using deep learning. *Journal of Dairy Science* vol. 104, n° 4, p. 4980-4990. [https://doi.org/10.3168/jds.2020-18367]
- BRIGANTI, G., LE MOINE, O. (2020) Artificial Intelligence in Medicine: Today and Tomorrow. *Frontiers in Medicine* vol. 7, p. 27. [https://doi.org/10.3389/fmed.2020.00027]
- BROOMÉ, S., FEIGHELSTEIN, M., ZAMANSKY, A., *et al.* (2023) Going Deeper than Tracking: A Survey of Computer-Vision Based Recognition of Animal Pain and Emotions. *International*

- Journal of Computer Vision* vol. 131, n° 2, p. 572-590. [<https://doi.org/10.1007/s11263-022-01716-3>]
- BROUGHTON-NEISWANGER, L.E., RIVERA-VELEZ, S.M., SUAREZ, M.A., *et al.* (2020) Urinary chemical fingerprint left behind by repeated NSAID administration: Discovery of putative biomarkers using artificial intelligence. *PLoS One* vol. 15, n° 2, p. e0228989. [<https://doi.org/10.1371/journal.pone.0228989>]
- BROWN, T.B., MANN, B., RYDER, N., *et al.* (2020) Language Models are Few-Shot Learners. [<https://doi.org/10.48550/arXiv.2005.14165>] (consulté le 20/07/2023).
- BRUNO, E., SIMBLETT, S., LANG, A., *et al.* (2018) Wearable technology in epilepsy: The views of patients, caregivers, and healthcare professionals. *Epilepsy & Behavior* vol. 85, p. 141-149. [<https://doi.org/10.1016/j.yebeh.2018.05.044>]
- BURTI, S., LONGHIN OSTI, V., ZOTTI, A., *et al.* (2020) Use of deep learning to detect cardiomegaly on thoracic radiographs in dogs. *Veterinary Journal* vol. 262, p. 105505. [<https://doi.org/10.1016/j.tvjl.2020.105505>]
- BURTI, S., ZOTTI, A., BONSEMBIANTE, F., *et al.* (2022) A Machine Learning-Based Approach for Classification of Focal Splenic Lesions Based on Their CT Features. *Frontiers in Veterinary Science* vol. 9, p. 872618. [<https://doi.org/10.3389/fvets.2022.872618>]
- BURTI, S., ZOTTI, A., BONSEMBIANTE, F., *et al.* (2021) Diagnostic Accuracy of Delayed Phase Post Contrast Computed Tomographic Images in the Diagnosis of Focal Liver Lesions in Dogs: 69 Cases. *Frontiers in Veterinary Science* vol. 8, p. 611556. [<https://doi.org/10.3389/fvets.2021.611556>]
- CAIRO, F.C., PEREIRA, L.G.R., CAMPOS, M.M., *et al.* (2020) Applying machine learning techniques on feeding behavior data for early estrus detection in dairy heifers. *Computers and Electronics in Agriculture* vol. 179, p. 105855. [<https://doi.org/10.1016/j.compag.2020.105855>]
- CANTOR, M.C., CASELLA, E., SILVESTRI, S., *et al.* (2022) Using Machine Learning and Behavioral Patterns Observed by Automated Feeders and Accelerometers for the Early Indication of Clinical Bovine Respiratory Disease Status in Prewaned Dairy Calves. *Frontiers in Animal Science* vol. 3. [<https://doi.org/10.3389/fanim.2022.852359>]
- CARSON, A., KRESNYE, C., RAI, T., *et al.* (2023) Response of pet owners to Whistle FIT® activity monitor digital alerts of increased pruritic activity in their dogs: a retrospective observational study. *Frontiers in Veterinary Science* vol. 10, p. 1123266. [<https://doi.org/10.3389/fvets.2023.1123266>]
- CATTLEEYE (2023) CattleEye. [<https://cattleeye.com/>] (consulté le 20/12/2023).
- CERNEK, P., BOLLIG, N., ANKLAM, K., *et al.* (2020) Hot topic: Detecting digital dermatitis with computer vision. *Journal of Dairy Science* vol. 103, n° 10, p. 9110-9115. [<https://doi.org/10.3168/jds.2019-17478>]
- CHEN, B.-L., CHENG, T.-H., HUANG, Y.-C., *et al.* (2023) Developing an automatic warning system for anomalous chicken dispersion and movement using deep learning and machine learning. *Poultry Science* vol. 102, n° 12, p. 103040. [<https://doi.org/10.1016/j.psj.2023.103040>]
- CHEN, P., TANG, W., YIN, D., *et al.* (2021) Sow Estrus Diagnosis from Sound Samples Based on Improved Deep Learning. In Sun, X., Zhang, X., Xia, Z., *et al.* (Éd.), *Advances in Artificial Intelligence and Security, Communications in Computer and Information Science*. Cham, Springer International Publishing, p. 132-143. [https://doi.org/10.1007/978-3-030-78615-1_12]
- CHENAIS, G., LAGARDE, E., GIL-JARDINÉ, C. (2023) Artificial Intelligence in Emergency Medicine: Viewpoint of Current Applications and Foreseeable Opportunities and Challenges. *Journal of Medical Internet Research* vol. 25. [<https://doi.org/10.2196/40031>]
- CHENAR, S.S., DENG, Z. (2018) Development of artificial intelligence approach to forecasting oyster norovirus outbreaks along Gulf of Mexico coast. *Environment International* vol. 111, p. 212-223. [<https://doi.org/10.1016/j.envint.2017.11.032>]
- CHENG, C.-Y., SOH, Z.D., MAJITHIA, S., *et al.* (2020) Big Data in Ophthalmology. *The Asia-Pacific Journal of Ophthalmology* vol. 9, n° 4, p. 291. [<https://doi.org/10.1097/APO.0000000000000304>]

- CHOW, A.R., PERRIGO, B., DICKSTEIN, L., *et al.* (2023) The AI Arms Race Is On. Start Worrying. *In Time*. [<https://time.com/6255952/ai-impact-chatgpt-microsoft-google/>] (consulté le 13/04/2023).
- CLEMENTS, D.N., HANDEL, I.G., ROSE, E., *et al.* (2013) Dogslife: a web-based longitudinal study of Labrador Retriever health in the UK. *BMC Veterinary Research* vol. 9, p. 13. [<https://doi.org/10.1186/1746-6148-9-13>]
- COELHO, M.L., FRANÇA, T., FONTOURA MATEUS, N.L., *et al.* (2023) Canine visceral leishmaniasis diagnosis by UV spectroscopy of blood serum and machine learning algorithms. *Photodiagnosis and Photodynamic Therapy* vol. 42, p. 103575. [<https://doi.org/10.1016/j.pdpdt.2023.103575>]
- COGHLAN, S., PARKER, C. (2023) Harm to Nonhuman Animals from AI: a Systematic Account and Framework. *Philosophy & Technology* vol. 36, n° 2, p. 25. [<https://doi.org/10.1007/s13347-023-00627-6>]
- COGHLAN, S., QUINN, T. (2023) Ethics of using artificial intelligence (AI) in veterinary medicine. *AI & Society*. [<https://doi.org/10.1007/s00146-023-01686-1>]
- COHEN, E.B., GORDON, I.K. (2022) First, do no harm. Ethical and legal issues of artificial intelligence and machine learning in veterinary radiology and radiation oncology. *Veterinary Radiology & Ultrasound* vol. 63, n° S1, p. 840-850. [<https://doi.org/10.1111/vru.13171>]
- COMMISSION EUROPÉENNE (2021) Proposition de Règlement du Parlement Européen et du Conseil établissant des règles harmonisées concernant l'intelligence artificielle. [<https://digital-strategy.ec.europa.eu/fr/library/proposal-regulation-laying-down-harmonised-rules-artificial-intelligence>] (consulté le 01/01/2024).
- CONSEIL DE L'UE (2023) Législation sur l'intelligence artificielle : le Conseil et le Parlement parviennent à un accord sur les premières règles au monde en matière d'IA. *In Consilium*. [<https://www.consilium.europa.eu/fr/press/press-releases/2023/12/09/artificial-intelligence-act-council-and-parliament-strike-a-deal-on-the-first-worldwide-rules-for-ai/>] (consulté le 10/12/2023).
- CORSINI, A., LUNETTA, F., ALBONI, F., *et al.* (2023) Development and internal validation of diagnostic prediction models using machine-learning algorithms in dogs with hypothyroidism. *Frontiers in Veterinary Science* vol. 10, p. 1292988. [<https://doi.org/10.3389/fvets.2023.1292988>]
- COSTA, M., STRUMANE, A., RAES, A., *et al.* (2023) Deep-Learning Based Quantification of Bovine Oocyte Quality From Microscopy Images. *Annual International Conference of the IEEE Engineering in Medicine and Biology Society* vol. 2023, p. 1-4. [<https://doi.org/10.1109/EMBC40787.2023.10340258>]
- CREEVY, K.E., AKEY, J.M., KAEBERLEIN, M., *et al.* (2022) An open science study of ageing in companion dogs. *Nature* vol. 602, n° 7895, p. 51-57. [<https://doi.org/10.1038/s41586-021-04282-9>]
- CRONE, S.F., LESSMANN, S., STAHLBOCK, R. (2006) The impact of preprocessing on data mining: An evaluation of classifier sensitivity in direct marketing. *European Journal of Operational Research* vol. 173, n° 3, p. 781-800. [<https://doi.org/10.1016/j.ejor.2005.07.023>]
- CUAN, K., ZHANG, T., HUANG, J., *et al.* (2020) Detection of avian influenza-infected chickens based on a chicken sound convolutional neural network. *Computers and Electronics in Agriculture* vol. 178, p. 105688. [<https://doi.org/10.1016/j.compag.2020.105688>]
- CUAN, K., ZHANG, T., LI, Z., *et al.* (2022) Automatic Newcastle disease detection using sound technology and deep learning method. *Computers and Electronics in Agriculture* vol. 194, p. 106740. [<https://doi.org/10.1016/j.compag.2022.106740>]
- CURRIE, G., HAWK, K.E. (2021) Ethical and Legal Challenges of Artificial Intelligence in Nuclear Medicine. *Seminars in Nuclear Medicine, Artificial Intelligence in Nuclear Medicine* vol. 51, n° 2, p. 120-125. [<https://doi.org/10.1053/j.semnuclmed.2020.08.001>]
- CURRIE, G., HESPEL, A.-M., CARSTENS, A. (2023) Australian perspectives on artificial intelligence in veterinary practice. *Veterinary Radiology & Ultrasound* vol. 64, n° 3, p. 473-483. [<https://doi.org/10.1111/vru.13234>]
- CURRIE, G., ROHREN, E. (2022a) The deep radiomic analytics pipeline. *Veterinary Radiology & Ultrasound* vol. 63 Suppl 1, p. 889-896. [<https://doi.org/10.1111/vru.13147>]

- CURRIE, G., ROHREN, E. (2022b) Intelligent imaging: Applications of machine learning and deep learning in radiology. *Veterinary Radiology & Ultrasound* vol. 63 Suppl 1, p. 880-888. [https://doi.org/10.1111/vru.13144]
- DANK, G., BUBER, T., POLLIACK, G., *et al.* (2023a) A pilot study for a non-invasive system for detection of malignancy in canine subcutaneous and cutaneous masses using machine learning. *Frontiers in Veterinary Science* vol. 10, p. 1109188. [https://doi.org/10.3389/fvets.2023.1109188]
- DANK, G., BUBER, T., RICE, A., *et al.* (2023b) Training and validation of a novel non-invasive imaging system for ruling out malignancy in canine subcutaneous and cutaneous masses using machine learning in 664 masses. *Frontiers in Veterinary Science* vol. 10, p. 1164438. [https://doi.org/10.3389/fvets.2023.1164438]
- DARBANDI, H., MUNSTERS, C., PARMENTIER, J., *et al.* (2023) Detecting fatigue of sport horses with biomechanical gait features using inertial sensors. *PLoS One* vol. 18, n° 4, p. e0284554. [https://doi.org/10.1371/journal.pone.0284554]
- DAS, A., BEN-MENACHEM, T., COOPER, G.S., *et al.* (2003) Prediction of outcome in acute lower-gastrointestinal haemorrhage based on an artificial neural network: internal and external validation of a predictive model. *The Lancet* vol. 362, n° 9392, p. 1261-1266. [https://doi.org/10.1016/S0140-6736(03)14568-0]
- DAVE, T., ATHALURI, S.A., SINGH, S. (2023) ChatGPT in medicine: an overview of its applications, advantages, limitations, future prospects, and ethical considerations. *Frontiers in Artificial Intelligence* vol. 6. [https://doi.org/10.3389/frai.2023.1169595]
- DAVEY, A. (2023) Google's AI Chatbot Is Trained by Humans Who Say They're Overworked, Underpaid and Frustrated. *In Bloomberg*. [https://www.bloomberg.com/news/articles/2023-07-12/google-s-ai-chatbot-is-trained-by-humans-who-say-they-re-overworked-underpaid-and-frustrated] (consulté le 20/08/2023).
- DAVÍÐSSON, H.B., REES, T., ÓLAFSDÓTTIR, M.R., *et al.* (2023) Efficient Development of Gait Classification Models for Five-Gaited Horses Based on Mobile Phone Sensors. *Animals* vol. 13, n° 1, p. 183. [https://doi.org/10.3390/ani13010183]
- DE VRIES, A., BLIZNYUK, N., PINEDO, P. (2023) Invited Review: Examples and opportunities for artificial intelligence (AI) in dairy farms. *Applied Animal Science* vol. 39, n° 1, p. 14-22. [https://doi.org/10.15232/aas.2022-02345]
- DEAN, J., GHEMAWAT, S. (2010) System and method for efficient large-scale data processing. US7650331B1. [https://patents.google.com/patent/US7650331/en] (consulté le 31/07/2023).
- DEAN, J., GHEMAWAT, S. (2008) MapReduce: simplified data processing on large clusters. *Communications of the ACM* vol. 51, n° 1, p. 107-113. [https://doi.org/10.1145/1327452.1327492]
- DENG, J., DONG, W., SOCHER, R., *et al.* (2009) ImageNet: A large-scale hierarchical image database. *In 2009 IEEE Conference on Computer Vision and Pattern Recognition*. Miami, FL, États-Unis, 20-25 juin, IEEE, p. 248-255. [https://doi.org/10.1109/CVPR.2009.5206848]
- DENHOLM, S.J., BRAND, W., MITCHELL, A.P., *et al.* (2020) Predicting bovine tuberculosis status of dairy cows from mid-infrared spectral data of milk using deep learning. *Journal of Dairy Science* vol. 103, n° 10, p. 9355-9367. [https://doi.org/10.3168/jds.2020-18328]
- DE SOUZA, L.F., COSTA, M.H., RIET-CORREA, B. (2023) Mobile app for targeted selective treatment of haemonchosis in sheep. *Veterinary Parasitology* vol. 316, p. 109902. [https://doi.org/10.1016/j.vetpar.2023.109902]
- DIEBOLD, F.X. (2012) On the Origin(s) and Development of the Term « Big Data ». *PIER Working Paper* n° 12. [https://doi.org/10.2139/ssrn.2152421]
- DIMITROV, D. (2016) Medical Internet of Things and Big Data in Healthcare. *Healthcare Informatics Research* vol. 22, p. 156. [https://doi.org/10.4258/hir.2016.22.3.156]
- DORADO-DÍAZ, P.I., SAMPEDRO-GÓMEZ, J., VICENTE-PALACIOS, V., *et al.* (2019) Applications of Artificial Intelligence in Cardiology. The Future is Already Here. *Revista Española de Cardiología (English Edition)* vol. 72, n° 12, p. 1065-1075. [https://doi.org/10.1016/j.rec.2019.05.014]

- DORSEY, E.R., GLIDDEN, A.M., HOLLOWAY, M.R., *et al.* (2018) Teleneurology and mobile technologies: the future of neurological care. *Nature Reviews Neurology* vol. 14, n° 5, p. 285-297. [<https://doi.org/10.1038/nrneurol.2018.31>]
- DU, X., CARPENTIER, L., TENG, G., *et al.* (2020) Assessment of Laying Hens' Thermal Comfort Using Sound Technology. *Sensors* vol. 20, n° 2, p. 473. [<https://doi.org/10.3390/s20020473>]
- DUDA, D., AZZABOU, N., DE CERTAINES, J.D. (2018) Multi-muscle Texture Analysis for Dystrophy Development Identification in Golden Retriever Muscular Dystrophy Dogs. In Saeed, K., Homenda, W. (Éd.), *Computer Information Systems and Industrial Management, Lecture Notes in Computer Science*. Cham, Springer International Publishing, p. 3-15. [https://doi.org/10.1007/978-3-319-99954-8_1]
- DUMORTIER, L., GUÉPIN, F., DELIGNETTE-MULLER, M.-L., *et al.* (2022) Deep learning in veterinary medicine, an approach based on CNN to detect pulmonary abnormalities from lateral thoracic radiographs in cats. *Scientific Reports* vol. 12, n° 1, p. 11418. [<https://doi.org/10.1038/s41598-022-14993-2>]
- EBRAHIMIE, E., EBRAHIMI, F., EBRAHIMI, M., *et al.* (2018a) A large-scale study of indicators of sub-clinical mastitis in dairy cattle by attribute weighting analysis of milk composition features: highlighting the predictive power of lactose and electrical conductivity. *Journal of Dairy Research* vol. 85, n° 2, p. 193-200. [<https://doi.org/10.1017/S0022029918000249>]
- EBRAHIMIE, E., EBRAHIMI, F., EBRAHIMI, M., *et al.* (2018b) Hierarchical pattern recognition in milking parameters predicts mastitis prevalence. *Computers and Electronics in Agriculture* vol. 147, p. 6-11. [<https://doi.org/10.1016/j.compag.2018.02.003>]
- EHRET, A., HOCHSTUHL, D., KRATTENMACHER, N., *et al.* (2015) Short communication: Use of genomic and metabolic information as well as milk performance records for prediction of subclinical ketosis risk via artificial neural networks. *Journal of Dairy Science* vol. 98, n° 1, p. 322-329. [<https://doi.org/10.3168/jds.2014-8602>]
- ENGELSMAN, D., SHERIF, T., MELLER, S., *et al.* (2022) Measurement of Canine Ataxic Gait Patterns Using Body-Worn Smartphone Sensor Data. *Frontiers in Veterinary Science* vol. 9, p. 912253. [<https://doi.org/10.3389/fvets.2022.912253>]
- ERGÜN, G.B., GÜNEY, S. (2021) Classification of Canine Maturity and Bone Fracture Time Based on X-Ray Images of Long Bones. *IEEE Access* vol. 9, p. 109004-109011. [<https://doi.org/10.1109/ACCESS.2021.3101040>]
- EZANNO, P., PICAULT, S., BEAUNÉE, G., *et al.* (2021) Research perspectives on animal health in the era of artificial intelligence. *Veterinary Research* vol. 52, n° 1, p. 40. [<https://doi.org/10.1186/s13567-021-00902-4>]
- FANG, R., POUYANFAR, S., YANG, Y., *et al.* (2016) Computational Health Informatics in the Big Data Age: A Survey. *ACM Computing Surveys* vol. 49, n° 1. [<https://doi.org/10.1145/2932707>]
- FEIGHELSTEIN, M., EHRLICH, Y., NAFTALY, L., *et al.* (2023a) Deep learning for video-based automated pain recognition in rabbits. *Scientific Reports* vol. 13, n° 1, p. 14679. [<https://doi.org/10.1038/s41598-023-41774-2>]
- FEIGHELSTEIN, M., HENZE, L., MELLER, S., *et al.* (2023b) Explainable automated pain recognition in cats. *Scientific Reports* vol. 13, n° 1, p. 8973. [<https://doi.org/10.1038/s41598-023-35846-6>]
- FEIGHELSTEIN, M., SHIMSHONI, I., FINKA, L.R., *et al.* (2022) Automated recognition of pain in cats. *Scientific Reports* vol. 12, n° 1, p. 9575. [<https://doi.org/10.1038/s41598-022-13348-1>]
- FERRINI, S., ROLLO, C., BELLINO, C., *et al.* (2023) A novel machine learning-based web application for field identification of infectious and inflammatory disorders of the central nervous system in cattle. *Journal of Veterinary Internal Medicine* vol. 37, n° 2, p. 766-773. [<https://doi.org/10.1111/jvim.16664>]
- FEUSER, A.-K., GESELL-MAY, S., MÜLLER, T., *et al.* (2022) Artificial Intelligence for Lameness Detection in Horses—A Preliminary Study. *Animals* vol. 12, n° 20, p. 2804. [<https://doi.org/10.3390/ani12202804>]

- FIGUEIRINHAS, P., SANCHEZ, A., RODRÍGUEZ, O., *et al.* (2022) Development of an Artificial Neural Network for the Detection of Supporting Hindlimb Lameness: A Pilot Study in Working Dogs. *Animals* vol. 12, n° 14, p. 1755. [<https://doi.org/10.3390/ani12141755>]
- FINLAYSON, S.G., BOWERS, J.D., ITO, J., *et al.* (2019) Adversarial attacks on medical machine learning. *Science* vol. 363, n° 6433, p. 1287-1289. [<https://doi.org/10.1126/science.aaw4399>]
- FINS, I.S., DAVIES, H., FARRELL, S., *et al.* (2024) Evaluating ChatGPT text mining of clinical records for companion animal obesity monitoring. *Veterinary Record* vol. 194, n° 3, p. e3669. [<https://doi.org/10.1002/vetr.3669>]
- FRAGOSO-GARCIA, M., WILM, F., BERTRAM, C.A., *et al.* (2023) Automated diagnosis of 7 canine skin tumors using machine learning on H&E-stained whole slide images. *Veterinary Pathology* vol. 60, n° 6, p. 865-875. [<https://doi.org/10.1177/03009858231189205>]
- FRAIWAN, M.A., ABUTARBUSH, S.M. (2020) Using Artificial Intelligence to Predict Survivability Likelihood and Need for Surgery in Horses Presented With Acute Abdomen (Colic). *Journal of Equine Veterinary Science* vol. 90, p. 102973. [<https://doi.org/10.1016/j.jevs.2020.102973>]
- FRANZO, G., LEGNARDI, M., FAUSTINI, G., *et al.* (2023) When Everything Becomes Bigger: Big Data for Big Poultry Production. *Animals* vol. 13, n° 11, p. 1804. [<https://doi.org/10.3390/ani13111804>]
- FUENTES, S., GONZALEZ VIEJO, C., TONGSON, E., *et al.* (2022) The livestock farming digital transformation: implementation of new and emerging technologies using artificial intelligence. *Animal Health Research Reviews* vol. 23, n° 1, p. 59-71. [<https://doi.org/10.1017/S1466252321000177>]
- GAL, A., FRIES, R., KADOTANI, S., *et al.* (2022) Canine urinary lactate and cortisol metabolites in hypercortisolism, nonadrenal disease, congestive heart failure, and health. *Journal of Veterinary Diagnostic Investigation* vol. 34, n° 4, p. 622-630. [<https://doi.org/10.1177/10406387221099916>]
- GIACOBBE, D.R., ZHANG, Y., DE LA FUENTE, J. (2023) Explainable artificial intelligence and machine learning: novel approaches to face infectious diseases challenges. *Annals of Medicine* vol. 55, n° 2. [<https://doi.org/10.1080/07853890.2023.2286336>]
- GIORGINI, F., DI DALMAZI, G., DICIOTTI, S. (2023) Artificial intelligence in endocrinology: a comprehensive review. *Journal of Endocrinological Investigation*. [<https://doi.org/10.1007/s40618-023-02235-9>]
- GLEISS, A., POUSTTCHI, K., KOHLHAGEN, M. (2021) An apple a day – how the platform economy impacts value creation in the healthcare market. *Electronic Markets* vol. 31, n° 849-876. [<https://doi.org/10.1007/s12525-021-00467-2>]
- GLICKMAN, L.T., MOORE, G.E., GLICKMAN, N.W., *et al.* (2006) Purdue University–Banfield National Companion Animal Surveillance Program for Emerging and Zoonotic Diseases. *Vector-Borne and Zoonotic Diseases* vol. 6, n° 1, p. 14-23. [<https://doi.org/10.1089/vbz.2006.6.14>]
- GOECKS, J., JALILI, V., HEISER, L.M., *et al.* (2020) How Machine Learning Will Transform Biomedicine. *Cell* vol. 181, n° 1, p. 92-101. [<https://doi.org/10.1016/j.cell.2020.03.022>]
- GOLDEN, C.E., ROTHROCK, M.J., MISHRA, A. (2019) Comparison between random forest and gradient boosting machine methods for predicting *Listeria* spp. prevalence in the environment of pastured poultry farms. *Food Research International* vol. 122, p. 47-55. [<https://doi.org/10.1016/j.foodres.2019.03.062>]
- GOOGLE (2023) Anthropic Forges Partnership With Google Cloud to Help Deliver Reliable and Responsible AI. *In Google Cloud Press Releases*. [<https://www.googlecloudpresscorner.com/2023-02-03-Anthropic-Forges-Partnership-With-Google-Cloud-to-Help-Deliver-Reliable-and-Responsible-AI>] (consulté le 15/04/2023).
- GROVES, P., KAYYALI, B., KNOTT, D., *et al.* (2013) The « big data » revolution in healthcare: Accelerating value and innovation, communication écrite.
- GUO, L., YU, X., THAIR, A., *et al.* (2024) Deep learning model shows promise for detecting and grading sesamoiditis in horse radiographs. *American Journal of Veterinary Research* vol. 85, n° 1, p. ajvr.23.07.0173. [<https://doi.org/10.2460/ajvr.23.07.0173>]

- GUPTA, S., KUEHN, L.A., CLAWSON, M.L. (2023) Early detection of infectious bovine keratoconjunctivitis with artificial intelligence. *Veterinary Research* vol. 54, n° 1, p. 122. [https://doi.org/10.1186/s13567-023-01255-w]
- HAGENDORFF, T. (2022) Blind spots in AI ethics. *AI and Ethics* vol. 2, n° 4, p. 851-867. [https://doi.org/10.1007/s43681-021-00122-8]
- HAGHOFER, A., FUCHS-BAUMGARTINGER, A., LIPNIK, K., *et al.* (2023) Histological classification of canine and feline lymphoma using a modular approach based on deep learning and advanced image processing. *Scientific Reports* vol. 13, n° 1, p. 19436. [https://doi.org/10.1038/s41598-023-46607-w]
- HAKANSSON, F., JENSEN, D.B. (2023) Automatic monitoring and detection of tail-biting behavior in groups of pigs using video-based deep learning methods. *Frontiers in Veterinary Science* vol. 9, p. 1099347. [https://doi.org/10.3389/fvets.2022.1099347]
- HALEV, A., MARTÍNEZ-LÓPEZ, B., CLAVIJO, M., *et al.* (2023) Infection prediction in swine populations with machine learning. *Scientific Reports* vol. 13, n° 1, p. 17738. [https://doi.org/10.1038/s41598-023-43472-5]
- HARVEY, H.B., GOWDA, V. (2020) How the FDA Regulates AI. *Academic Radiology* vol. 27, n° 1, p. 58-61. [https://doi.org/10.1016/j.acra.2019.09.017]
- HASTIE, T., TIBSHIRANI, R., FRIEDMAN, J.H. (2009) The elements of statistical learning: data mining, inference, and prediction, 2ème édition. New York, Springer.
- HE, H., MA, Y. (2013) Imbalanced learning: foundations, algorithms, and applications. Hoboken, New Jersey, John Wiley & Sons, Inc.
- HE, K., ZHANG, X., REN, S., *et al.* (2016) Deep Residual Learning for Image Recognition. In *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Las Vegas, NV, États-Unis, 27-30 juin, p. 770-778. [https://doi.org/10.1109/CVPR.2016.90]
- HE, P., CHEN, Z., HE, Y., *et al.* (2023) A reliable and low-cost deep learning model integrating convolutional neural network and transformer structure for fine-grained classification of chicken *Eimeria* species. *Poultry Science* vol. 102, n° 3, p. 102459. [https://doi.org/10.1016/j.psj.2022.102459]
- HEAVEN, D. (2019) Why deep-learning AIs are so easy to fool. *Nature* vol. 574, n° 7777, p. 163-166. [https://doi.org/10.1038/d41586-019-03013-5]
- HEMPSTALK, K., MCPARLAND, S., BERRY, D.P. (2015) Machine learning algorithms for the prediction of conception success to a given insemination in lactating dairy cows. *Journal of Dairy Science* vol. 98, n° 8, p. 5262-5273. [https://doi.org/10.3168/jds.2014-8984]
- HENNESSEY, E., DIFAZIO, M., HENNESSEY, R., *et al.* (2022) Artificial intelligence in veterinary diagnostic imaging: A literature review. *Veterinary Radiology & Ultrasound* vol. 63, n° S1, p. 851-870. [https://doi.org/10.1111/vru.13163]
- HEPWORTH, P.J., NEFEDOV, A.V., MUCHNIK, I.B., *et al.* (2012) Broiler chickens can benefit from machine learning: support vector machine analysis of observational epidemiological data. *Journal of the Royal Society* vol. 9, n° 73, p. 1934-1942. [https://doi.org/10.1098/rsif.2011.0852]
- HERNANDEZ, A.M., BILBROUGH, G.E.A., DENICOLA, D.B., *et al.* (2019) Comparison of the performance of the IDEXX SediVue Dx® with manual microscopy for the detection of cells and 2 crystal types in canine and feline urine. *Journal of Veterinary Internal Medicine* vol. 33, n° 1, p. 167-177. [https://doi.org/10.1111/jvim.15341]
- HESPEL, A.-M., BOISSADY, E., DE LA COMBLE, A., *et al.* (2022) Comparison of error rates between four pretrained DenseNet convolutional neural network models and 13 board-certified veterinary radiologists when evaluating 15 labels of canine thoracic radiographs. *Veterinary Radiology & Ultrasound* vol. 63, n° 4, p. 456-468. [https://doi.org/10.1111/vru.13069]
- HIGAKI, S., DARHAN, H., SUZUKI, C., *et al.* (2021) An attempt at estrus detection in cattle by continuous measurements of ventral tail base surface temperature with supervised machine learning. *Journal of Reproduction and Development* vol. 67, n° 1, p. 67-71. [https://doi.org/10.1262/jrd.2020-075]

- HIGAKI, S., MIURA, R., SUDA, T., *et al.* (2019) Estrous detection by continuous measurements of vaginal temperature and conductivity with supervised machine learning in cattle. *Theriogenology* vol. 123, p. 90-99. [<https://doi.org/10.1016/j.theriogenology.2018.09.038>]
- HOOD, L., FLORES, M. (2012) A personal view on systems medicine and the emergence of proactive P4 medicine: predictive, preventive, personalized and participatory. *New Biotechnology*. [<https://doi.org/10.1016/j.nbt.2012.03.004>]
- HUANG, H., WANG, Y., RUDIN, C., *et al.* (2022) Towards a comprehensive evaluation of dimension reduction methods for transcriptomic data visualization. *Communications Biology* vol. 5, n° 1, p. 719. [<https://doi.org/10.1038/s42003-022-03628-x>]
- HWANG, E.J., PARK, S., JIN, K.-N., *et al.* (2019) Development and Validation of a Deep Learning-Based Automated Detection Algorithm for Major Thoracic Diseases on Chest Radiographs. *JAMA network open* vol. 2, n° 3, p. e191095. [<https://doi.org/10.1001/jamanetworkopen.2019.1095>]
- HYDE, R.M., DOWN, P.M., BRADLEY, A.J., *et al.* (2020) Automated prediction of mastitis infection patterns in dairy herds using machine learning. *Scientific Reports* vol. 10, n° 1, p. 4289. [<https://doi.org/10.1038/s41598-020-61126-8>]
- IDEXX inVue Dx (2024) . In *IDEXX France*. [<https://www.idexx.fr/fr/veterinary/analyzers/invue-dx-analyzer/>] (consulté le 26/01/2024).
- IDEXX SediVue Dx (2021) . In *IDEXX France*. [<https://www.idexx.fr/fr/veterinary/analyzers/sedivue-dx-analyzer/>] (consulté le 31/12/2021).
- II, T., CHAMBERS, J.K., NAKASHIMA, K., *et al.* (2023) Application of automated machine learning for histological evaluation of feline endoscopic samples. *The Journal of Veterinary Medical Science*. [<https://doi.org/10.1292/jvms.23-0299>]
- INÁCIO, S.V., FERREIRA GOMES, J., XAVIER FALCÃO, A., *et al.* (2020) Automated Diagnosis of Canine Gastrointestinal Parasites Using Image Analysis. *Pathogens* vol. 9, n° 2, p. 139. [<https://doi.org/10.3390/pathogens9020139>]
- IZQUIERDO, J.L., OESTE, C.L., HERNÁNDEZ MEDRANO, I. (2023) Artificial Intelligence in Pneumology: Diagnostic and Prognostic Utilities. *Archivos De Bronconeumologia* vol. 59, n° 2, p. 67-68. [<https://doi.org/10.1016/j.arbres.2022.07.007>]
- JACOBS, A. (2009) The Pathologies of Big Data: Scale up your datasets enough and all your apps will come undone. What are the typical problems and where do the bottlenecks generally surface? *Queue* vol. 7, n° 6, p. 10-19. [<https://doi.org/10.1145/1563821.1563874>]
- JI, Y., HWANG, G., LEE, S.J., *et al.* (2023) A deep learning model for automated kidney calculi detection on non-contrast computed tomography scans in dogs. *Frontiers in Veterinary Science* vol. 10, p. 1236579. [<https://doi.org/10.3389/fvets.2023.1236579>]
- JIA, Y. (2019) Attention Mechanism in Machine Translation. *Journal of Physics: Conference Series* vol. 1314, n° 1, p. 012186. [<https://doi.org/10.1088/1742-6596/1314/1/012186>]
- JOAO, L.M., PROENÇA, L.R., LOIOLA, S.H.N., *et al.* (2023) Toward automating the diagnosis of gastrointestinal parasites in cats and dogs. *Computers in Biology and Medicine* vol. 163, p. 107203. [<https://doi.org/10.1016/j.compbiomed.2023.107203>]
- JOHNSON-LAIRD, P. (2010) Deductive reasoning. *WIREs Cognitive Science* vol. 1, n° 1, p. 8-17. [<https://doi.org/10.1002/wcs.20>]
- JOSLYN, S., ALEXANDER, K. (2022) Evaluating artificial intelligence algorithms for use in veterinary radiology. *Veterinary Radiology & Ultrasound* vol. 63, n° S1, p. 871-879. [<https://doi.org/10.1111/vru.13159>]
- JUNG, D.-H., KIM, N.Y., MOON, S.H., *et al.* (2021) Deep Learning-Based Cattle Vocal Classification Model and Real-Time Livestock Monitoring System with Noise Filtering. *Animals* vol. 11, n° 2, p. 357. [<https://doi.org/10.3390/ani11020357>]
- JUNG, J., PARK, G., KIM, G. (2023) Detecting medial patellar luxation with ensemble deep convolutional neural network based on a single rear view image of the hindlimb. *Scientific Reports* vol. 13, n° 1, p. 17113. [<https://doi.org/10.1038/s41598-023-43872-7>]
- KAMPHUIS, C., MOLLENHORST, H., FEELDERS, A., *et al.* (2010) Decision-tree induction to detect clinical mastitis with automatic milking. *Computers and Electronics in Agriculture* vol. 70, n° 1, p. 60-68. [<https://doi.org/10.1016/j.compag.2009.08.012>]

- KAUL, V., ENSLIN, S., GROSS, S.A. (2020) History of artificial intelligence in medicine. *Gastrointestinal Endoscopy* vol. 92, n° 4, p. 807-812. [https://doi.org/10.1016/j.gie.2020.06.040]
- KECELI, A.S., CATAL, C., KAYA, A., *et al.* (2020) Development of a recurrent neural networks-based calving prediction model using activity and behavioral data. *Computers and Electronics in Agriculture* vol. 170, p. 105285. [https://doi.org/10.1016/j.compag.2020.105285]
- KELLY, C.J., KARTHIKESALINGAM, A., SULEYMAN, M., *et al.* (2019) Key challenges for delivering clinical impact with artificial intelligence. *BMC Medicine* vol. 17, p. 195. [https://doi.org/10.1186/s12916-019-1426-2]
- KENNEDY, N., BRODBELT, D.C., CHURCH, D.B., *et al.* (2019) Detecting false-positive disease references in veterinary clinical notes without manual annotations. *Digital Medicine* vol. 2, n° 1. [https://doi.org/10.1038/s41746-019-0108-y]
- KESHAVARZI, H., SADEGHI-SEFIDMAZGI, A., MIRZAEI, A., *et al.* (2020) Machine learning algorithms, bull genetic information, and imbalanced datasets used in abortion incidence prediction models for Iranian Holstein dairy cattle. *Preventive Veterinary Medicine* vol. 175, p. 104869. [https://doi.org/10.1016/j.prevetmed.2019.104869]
- KIM, E., FISCHETTI, A.J., SREETHARAN, P., *et al.* (2022) Comparison of artificial intelligence to the veterinary radiologist's diagnosis of canine cardiogenic pulmonary edema. *Veterinary Radiology & Ultrasound* vol. 63, n° 3, p. 292-297. [https://doi.org/10.1111/vru.13062]
- KIM, J.Y., HAN, M.G., CHUN, J.H., *et al.* (2022) Developing a diagnosis model for dry eye disease in dogs using object detection. *Scientific Reports* vol. 12, n° 1, p. 21351. [https://doi.org/10.1038/s41598-022-25867-y]
- KIM, J.Y., LEE, H.E., CHOI, Y.H., *et al.* (2019) CNN-based diagnosis models for canine ulcerative keratitis. *Scientific Reports* vol. 9, n° 1, p. 14209. [https://doi.org/10.1038/s41598-019-50437-0]
- KITCHIN, R., MCARDLE, G. (2016) What makes Big Data, Big Data? Exploring the ontological characteristics of 26 datasets. *Big Data & Society* vol. 3, n° 1, p. 2053951716631130. [https://doi.org/10.1177/2053951716631130]
- KITTICHAJ, V., KAEWTHAMASORN, M., THANEE, S., *et al.* (2021) Classification for avian malaria parasite Plasmodium gallinaceum blood stages by using deep convolutional neural networks. *Scientific Reports* vol. 11, n° 1, p. 16919. [https://doi.org/10.1038/s41598-021-96475-5]
- KOKKINOS, Y., MORRISON, J., BRADLEY, R., *et al.* (2022) An early prediction model for canine chronic kidney disease based on routine clinical laboratory tests. *Scientific Reports* vol. 12, n° 1, p. 14489. [https://doi.org/10.1038/s41598-022-18793-6]
- KOL, A., ARZI, B., ATHANASIOU, K.A., *et al.* (2015) Companion animals: Translational scientist's new best friends. *Science Translational Medicine* vol. 7, n° 308, p. 308ps21. [https://doi.org/10.1126/scitranslmed.aaa9116]
- KOTTLER, N. (2020) Artificial Intelligence: A Private Practice Perspective. *Journal of the American College of Radiology* vol. 17, n° 11, p. 1398-1404. [https://doi.org/10.1016/j.jacr.2020.09.029]
- KRÖNER, P.T., ENGELS, M.M., GLICKSBERG, B.S., *et al.* (2021) Artificial intelligence in gastroenterology: A state-of-the-art review. *World Journal of Gastroenterology* vol. 27, n° 40, p. 6794-6824. [https://doi.org/10.3748/wjg.v27.i40.6794]
- KWONG, M., GARDNER, H.L., DIETERLE, N., *et al.* (2019) Optimization of Electronic Medical Records for Data Mining Using a Common Data Model. *Topics in Companion Animal Medicine* vol. 37. [https://doi.org/10.1016/j.tcam.2019.100364]
- LABADIE, J., SWAFFORD, B., DEPENA, M., *et al.* (2022) Cohort profile: The Golden Retriever Lifetime Study (GRLS). *PLoS One* vol. 17, n° 6. [https://doi.org/10.1371/journal.pone.0269425]
- LANEY, D. (2001) 3D data management: Controlling data volume, velocity and variety. *META group research note* vol. 6, n° 70, p. 1.
- LANEY, D., BEYER, M. (2012) The Importance of « Big Data »: A Definition, communication écrite.

- LARIOS, G., RIBEIRO, M., ARRUDA, C., *et al.* (2021) A new strategy for canine visceral leishmaniasis diagnosis based on FTIR spectroscopy and machine learning. *Journal of Biophotonics* vol. 14, n° 11, p. e202100141. [<https://doi.org/10.1002/jbio.202100141>]
- LARRAÑAGA, P., CALVO, B., SANTANA, R., *et al.* (2005) Machine learning in bioinformatics. *Briefings In Bioinformatics* vol. 7, n° 1, p. 86-112.
- LECUN, Y., BENGIO, Y., HINTON, G. (2015) Deep learning. *Nature* vol. 521, n° 7553, p. 436-444. [<https://doi.org/10.1038/nature14539>]
- LENHARO, M. (2024) Google AI has better bedside manner than human doctors — and makes better diagnoses. *Nature* vol. 625, n° 7996, p. 643-644. [<https://doi.org/10.1038/d41586-024-00099-4>]
- LEWIS, P., PEREZ, E., PIKTUS, A., *et al.* (2020) Retrieval-Augmented Generation for Knowledge-Intensive NLP Tasks. In *Advances in Neural Information Processing Systems*. Online conference, 6-12 décembre, Red Hook, NY, États-Unis, Curran Associates, p. 9459-9474.
- LI, D., ZHANG, K., LI, Z., *et al.* (2020) A Spatiotemporal Convolutional Network for Multi-Behavior Recognition of Pigs. *Sensors* vol. 20, n° 8, p. 2381. [<https://doi.org/10.3390/s20082381>]
- LI, S., WANG, Z., VISSER, L.C., *et al.* (2020) Pilot study: Application of artificial intelligence for detecting left atrial enlargement on canine thoracic radiographs. *Veterinary Radiology & Ultrasound* vol. 61, n° 6, p. 611-618. [<https://doi.org/10.1111/vru.12901>]
- LI, Y., ZHENG, R., WU, Y., *et al.* (2019) A low-cost, automated parasite diagnostic system via a portable, robotic microscope and deep learning. *Journal of Biophotonics* vol. 12, n° 9, p. e201800410. [<https://doi.org/10.1002/jbio.201800410>]
- LIANG, R., LU, Y., QU, X., *et al.* (2020) Prediction for global African swine fever outbreaks based on a combination of random forest algorithms and meteorological data. *Transboundary and Emerging Diseases* vol. 67, n° 2, p. 935-946. [<https://doi.org/10.1111/tbed.13424>]
- LINARDATOS, P., PASTEFANOPOULOS, V., KOTSIANTIS, S. (2020) Explainable AI: A Review of Machine Learning Interpretability Methods. *Entropy* vol. 23, n° 1, p. 18. [<https://doi.org/10.3390/e23010018>]
- LIU, X., FAES, L., KALE, A.U., *et al.* (2019) A comparison of deep learning performance against health-care professionals in detecting diseases from medical imaging: a systematic review and meta-analysis. *The Lancet Digital Health* vol. 1, n° 6, p. e271-e297. [[https://doi.org/10.1016/S2589-7500\(19\)30123-2](https://doi.org/10.1016/S2589-7500(19)30123-2)]
- LIU, Y., ZHUANG, Y., YU, L., *et al.* (2023) A Machine Learning Framework Based on Extreme Gradient Boosting to Predict the Occurrence and Development of Infectious Diseases in Laying Hen Farms, Taking H9N2 as an Example. *Animals* vol. 13, n° 9, p. 1494. [<https://doi.org/10.3390/ani13091494>]
- LUGMAYR, A., STOCKLEBEN, B., SCHEIB, C., *et al.* (2016) A Comprehensive survey on Big Data research and its implications. In *Proceedings of the 20th Pacific-Asian Conference on Information Systems*. Chiayi, Taïwan, 27 juin - 01 juillet.
- LUHN, H.P. (1958) A Business Intelligence System. *IBM Journal of Research and Development* vol. 2, n° 4, p. 314-319. [<https://doi.org/10.1147/rd.24.0314>]
- LUNDBERG, S.M., LEE, S.-I. (2017) A unified approach to interpreting model predictions. In *Proceedings of the 31st International Conference on Neural Information Processing Systems*. Long Beach, CA, États-Unis, 04-09 décembre, Red Hook, NY, États-Unis, Curran Associates, p. 4768-4777.
- LUO, N., ZHONG, X., SU, L., *et al.* (2023) Artificial intelligence-assisted dermatology diagnosis: From unimodal to multimodal. *Computers in Biology and Medicine* vol. 165, p. 107413. [<https://doi.org/10.1016/j.compbiomed.2023.107413>]
- LUO, W., DONG, Q., FENG, Y. (2023) Risk prediction model of clinical mastitis in lactating dairy cows based on machine learning algorithms. *Preventive Veterinary Medicine* vol. 221, p. 106059. [<https://doi.org/10.1016/j.prevetmed.2023.106059>]
- MACHADO, G., VILALTA, C., RECAMONDE-MENDOZA, M., *et al.* (2019) Identifying outbreaks of Porcine Epidemic Diarrhea virus through animal movements and spatial neighborhoods. *Scientific Reports* vol. 9, n° 1, p. 457. [<https://doi.org/10.1038/s41598-018-36934-8>]

- MAGANA, J., GAVOJDIAN, D., MENAHEM, Y., *et al.* (2023) Machine learning approaches to predict and detect early-onset of digital dermatitis in dairy cows using sensor data. *Frontiers in Veterinary Science* vol. 10, p. 1295430. [<https://doi.org/10.3389/fvets.2023.1295430>]
- MAHDAVIAN, A., MINAEI, S., MARCHETTO, P.M., *et al.* (2021) Acoustic features of vocalization signal in poultry health monitoring. *Applied Acoustics* vol. 175, p. 107756. [<https://doi.org/10.1016/j.apacoust.2020.107756>]
- MAO, A., GIRAUDET, C.S.E., LIU, K., *et al.* (2022) Automated identification of chicken distress vocalizations using deep learning models. *Journal of the Royal Society* vol. 19, n° 191, p. 20210921. [<https://doi.org/10.1098/rsif.2021.0921>]
- MAO, Y., LIU, Y. (2023) Pet dog facial expression recognition based on convolutional neural network and improved whale optimization algorithm. *Scientific Reports* vol. 13, n° 1, p. 3314. [<https://doi.org/10.1038/s41598-023-30442-0>]
- MARSCHNER, C.B., KOKLA, M., AMIGO, J.M., *et al.* (2017) Texture analysis of pulmonary parenchymateous changes related to pulmonary thromboembolism in dogs - a novel approach using quantitative methods. *BMC Veterinary Research* vol. 13, n° 1, p. 219. [<https://doi.org/10.1186/s12917-017-1117-1>]
- MARZAH, C., AUBREVILLE, M., BERTRAM, C.A., *et al.* (2020) Deep Learning-Based Quantification of Pulmonary Hemosiderophages in Cytology Slides. *Scientific Reports* vol. 10, n° 1, p. 9795. [<https://doi.org/10.1038/s41598-020-65958-2>]
- MASHEY, J.R. (1998) Big Data... and the Next Wave of InfraStress, présentation écrite.
- MAY, A., GESELL-MAY, S., MÜLLER, T., *et al.* (2022) Artificial intelligence as a tool to aid in the differentiation of equine ophthalmic diseases with an emphasis on equine uveitis. *Equine Veterinary Journal* vol. 54, n° 5, p. 847-855. [<https://doi.org/10.1111/evj.13528>]
- MCCUE, M.E., MCCOY, A.M. (2019) Harnessing big data for equine health. *Equine Veterinary Journal* vol. 51, n° 4, p. 429-432. [<https://doi.org/10.1111/evj.13080>]
- MCCUE, M.E., MCCOY, A.M. (2017) The Scope of Big Data in One Medicine: Unprecedented Opportunities and Challenges. *Frontiers in Veterinary Science* vol. 4, p. 194. [<https://doi.org/10.3389/fvets.2017.00194>]
- MCEVOY, F.J., AMIGO, J.M. (2013) Using machine learning to classify image features from canine pelvic radiographs: evaluation of partial least squares discriminant analysis and artificial neural network models. *Veterinary Radiology & Ultrasound* vol. 54, n° 2, p. 122-126. [<https://doi.org/10.1111/vru.12003>]
- MCEVOY, F.J., PROSCHOWSKY, H.F., MÜLLER, A.V., *et al.* (2021) Deep transfer learning can be used for the detection of hip joints in pelvis radiographs and the classification of their hip dysplasia status. *Veterinary Radiology & Ultrasound* vol. 62, n° 4, p. 387-393. [<https://doi.org/10.1111/vru.12968>]
- MCGREEVY, P., THOMSON, P., DHAND, N.K., *et al.* (2017) VetCompass Australia: A National Big Data Collection System for Veterinary Science. *Animals* vol. 7, n° 10, p. 74. [<https://doi.org/10.3390/ani7100074>]
- MCLENNAN, K., MAHMOUD, M. (2019) Development of an Automated Pain Facial Expression Detection System for Sheep (*Ovis Aries*). *Animals* vol. 9, n° 4, p. 196. [<https://doi.org/10.3390/ani9040196>]
- MESZAROS, J., MINARI, J., HUYS, I. (2022) The future regulation of artificial intelligence systems in healthcare services and medical research in the European Union. *Frontiers in Genetics* vol. 13, p. 57-67. [<https://doi.org/10.3389/fgene.2022.927721>]
- MICROSOFT (2023) Microsoft and OpenAI extend partnership. In *Microsoft Corporate Blogs*. [<https://blogs.microsoft.com/blog/2023/01/23/microsoftandopenaiextendpartnership/>] (consulté le 15/04/2023).
- MICROSOFT (2019) OpenAI forms exclusive computing partnership with Microsoft to build new Azure AI supercomputing technologies. In *Microsoft News Center*. [<https://news.microsoft.com/2019/07/22/openai-forms-exclusive-computing-partnership-with-microsoft-to-build-new-azure-ai-supercomputing-technologies/>] (consulté le 15/04/2023).
- MIKHAEL, P.G., WOHLWEND, J., YALA, A., *et al.* (2023) Sybil: A Validated Deep Learning Model to Predict Future Lung Cancer Risk From a Single Low-Dose Chest Computed

- Tomography. *Journal of Clinical Oncology* vol. 41, n° 12, p. 2191-2200. [https://doi.org/10.1200/JCO.22.01345]
- MORISI, A., RAI, T., BACON, N.J., *et al.* (2023) Detection of Necrosis in Digitised Whole-Slide Images for Better Grading of Canine Soft-Tissue Sarcomas Using Machine-Learning. *Veterinary Sciences* vol. 10, n° 1, p. 45. [https://doi.org/10.3390/vetsci10010045]
- MOULOODI, S., RAHMANPANA, H., GOHARI, S., *et al.* (2021) What can artificial intelligence and machine learning tell us? A review of applications to equine biomechanical research. *Journal of the Mechanical Behavior of Biomedical Materials* vol. 123, p. 104728. [https://doi.org/10.1016/j.jmbbm.2021.104728]
- MÜLLER, T.R., SOLANO, M., TSUNEMI, M.H. (2022) Accuracy of artificial intelligence software for the detection of confirmed pleural effusion in thoracic radiographs in dogs. *Veterinary Radiology & Ultrasound* vol. 63, n° 5, p. 573-579. [https://doi.org/10.1111/vru.13089]
- MULLINS, I.L., TRUMAN, C.M., CAMPLER, M.R., *et al.* (2019) Validation of a Commercial Automated Body Condition Scoring System on a Commercial Dairy Farm. *Animals* vol. 9, n° 6, p. 287. [https://doi.org/10.3390/ani9060287]
- NAGAMORI, Y., SEDLAK, R.H., DEROSA, A., *et al.* (2021) Further evaluation and validation of the VETSCAN IMAGYST: in-clinic feline and canine fecal parasite detection system integrated with a deep learning algorithm. *Parasites & Vectors* vol. 14, n° 1, p. 89. [https://doi.org/10.1186/s13071-021-04591-y]
- NASR, M., CARLINI, N., HAYASE, J., *et al.* (2023) Scalable Extraction of Training Data from (Production) Language Models. [https://doi.org/10.48550/arXiv.2311.17035]
- NEETHIRAJAN, S. (2021) The Use of Artificial Intelligence in Assessing Affective States in Livestock. *Frontiers in Veterinary Science* vol. 8, p. 715261. [https://doi.org/10.3389/fvets.2021.715261]
- NEJATI, A., BRADTMUELLER, A., SHEPLEY, E., *et al.* (2023) Technology applications in bovine gait analysis: A scoping review. *PLoS One* vol. 18, n° 1, p. e0266287. [https://doi.org/10.1371/journal.pone.0266287]
- NIEL, O., BASTARD, P. (2019) Artificial Intelligence in Nephrology: Core Concepts, Clinical Applications, and Perspectives. *American Journal of Kidney Diseases* vol. 74, n° 6, p. 803-810. [https://doi.org/10.1053/j.ajkd.2019.05.020]
- NIELSEN, M. (2015) Neural Networks and Deep Learning. Determination Press.
- NIU, B., LIANG, R., ZHOU, G., *et al.* (2020) Prediction for Global Peste des Petits Ruminants Outbreaks Based on a Combination of Random Forest Algorithms and Meteorological Data. *Frontiers in Veterinary Science* vol. 7, p. 570829. [https://doi.org/10.3389/fvets.2020.570829]
- NOBLE, P.-J.M., APPLETON, C., RADFORD, A.D., *et al.* (2021) Using topic modelling for unsupervised annotation of electronic health records to identify an outbreak of disease in UK dogs. *PLoS One* vol. 16, n° 12. [https://doi.org/10.1371/journal.pone.0260402]
- O' LEARY, N., LESO, L., BUCKLEY, F., *et al.* (2020) Validation of an Automated Body Condition Scoring System Using 3D Imaging. *Agriculture* vol. 10, n° 6, p. 246. [https://doi.org/10.3390/agriculture10060246]
- OBSERVATOIRE NATIONAL DÉMOGRAPHIQUE DE LA PROFESSION VÉTÉRINAIRE (2023) Atlas démographique de la profession vétérinaire.
- OHHLEP, ADISASMITO, W.B., ALMUHAIRI, S., *et al.* (2022) One Health: A new definition for a sustainable and healthy future. *PLOS Pathogens* vol. 18, n° 6, p. e1010537. [https://doi.org/10.1371/journal.ppat.1010537]
- OPENAI (2023) GPT-4 Technical Report. [https://doi.org/10.48550/arXiv.2303.08774] (consulté le 02/11/2023).
- ORACLE CLOUD (2022) What Is Big Data? [https://www.oracle.com/big-data/what-is-big-data/] (consulté le 26/10/2022).
- OREN, A., TÜRKÇÜ, J.D., MELLER, S., *et al.* (2023) BrachySound: machine learning based assessment of respiratory sounds in dogs. *Scientific Reports* vol. 13, n° 1, p. 20300. [https://doi.org/10.1038/s41598-023-47308-0]
- ORTH, M., AVERINA, M., CHATZIPANAGIOTOU, S., *et al.* (2019) Opinion: redefining the role of the physician in laboratory medicine in the context of emerging technologies, personalised

- medicine and patient autonomy ('4P medicine'). *Journal of Clinical Pathology* vol. 72, n° 3, p. 191-197. [https://doi.org/10.1136/jclinpath-2017-204734]
- OTT, J., BRUYETTE, D., ARBUCKLE, C., *et al.* (2021) Detecting pulmonary Coccidioidomycosis with deep convolutional neural networks. *Machine Learning with Applications* vol. 5, p. 100040. [https://doi.org/10.1016/j.mlwa.2021.100040]
- OZALP, H., OZCAN, P., DINCKOL, D., *et al.* (2021) Platforms in Highly Regulated Industries: An Analysis of GAFAM Entry into Healthcare and Education. *Academy of Management Proceedings* vol. 2021, p. 14549. [https://doi.org/10.5465/AMBPP.2021.14549abstract]
- PANCHAL, I., SAWHNEY, I.K., SHARMA, A.K., *et al.* (2016) Classification of healthy and mastitis Murrah buffaloes by application of neural network models using yield and milk quality parameters. *Computers and Electronics in Agriculture* vol. 127, p. 242-248. [https://doi.org/10.1016/j.compag.2016.06.015]
- PAPLOSKI, I.A.D., BHOJWANI, R.K., SANHUEZA, J.M., *et al.* (2021) Forecasting viral disease outbreaks at the farm-level for commercial sow farms in the U.S. *Preventive Veterinary Medicine* vol. 196, p. 105449. [https://doi.org/10.1016/j.prevetmed.2021.105449]
- PARMENTIER, J.I.M., BOSCH, S., VAN DER ZWAAG, B.J., *et al.* (2023) Prediction of continuous and discrete kinetic parameters in horses from inertial measurement units data using recurrent artificial neural networks. *Scientific Reports* vol. 13, n° 1, p. 740. [https://doi.org/10.1038/s41598-023-27899-4]
- PARRA, C., GRIJALVA, F., NÚÑEZ, B., *et al.* (2022) Automatic identification of intestinal parasites in reptiles using microscopic stool images and convolutional neural networks. *PLOS ONE* vol. 17, n° 8, p. e0271529. [https://doi.org/10.1371/journal.pone.0271529]
- PATEL, S., WANG, J.V., MOTAPARTHI, K., *et al.* (2021) Artificial intelligence in dermatology for the clinician. *Clinics in Dermatology* vol. 39, n° 4, p. 667-672. [https://doi.org/10.1016/j.clindermatol.2021.03.012]
- PATGIRI, R., AHMED, A. (2016) Big Data: The V's of the Game Changer Paradigm. In *18th IEEE High Performance Computing and Communications*. Sydney, Australie, 12-14 décembre, IEEE, p. 17-24. [https://doi.org/10.1109/HPCC-SmartCity-DSS.2016.0014]
- PAYNTER, A.N., DUNBAR, M.D., CREEVY, K.E., *et al.* (2021) Veterinary Big Data: When Data Goes to the Dogs. *Animals* vol. 11, n° 7, p. 1872. [https://doi.org/10.3390/ani11071872]
- PEI, Q., LUO, Y., CHEN, Y., *et al.* (2022) Artificial intelligence in clinical applications for lung cancer: diagnosis, treatment and prognosis. *Clinical Chemistry and Laboratory Medicine* vol. 60, n° 12, p. 1974-1983. [https://doi.org/10.1515/cclm-2022-0291]
- PEREIRA, A.I., FRANCO-GONÇALO, P., LEITE, P., *et al.* (2023) Artificial Intelligence in Veterinary Imaging: An Overview. *Veterinary Sciences* vol. 10, n° 5, p. 320. [https://doi.org/10.3390/vetsci10050320]
- PERRIGO, B. (2023) The \$2 Per Hour Workers Who Made ChatGPT Safer. In *Time*. [https://time.com/6247678/openai-chatgpt-kenya-workers/] (consulté le 22/04/2023).
- PERRIN, R. (2019) Emergence de l'intelligence artificielle et utilisation des technologies Big Data en médecine vétérinaire : importance de la sensibilisation des futurs vétérinaires. Thèse Méd. Vét., École nationale vétérinaire d'Alfort.
- PESAPANE, F., VOLONTÉ, C., CODARI, M., *et al.* (2018) Artificial intelligence as a medical device in radiology: ethical and regulatory issues in Europe and the United States. *Insights into Imaging* vol. 9, n° 5, p. 745-753. [https://doi.org/10.1007/s13244-018-0645-y]
- PICHAJ, S. (2023) An important next step on our AI journey. In *Google The Keyword*. [https://blog.google/technology/ai/bard-google-ai-search-updates/] (consulté le 15/04/2023).
- PIJNACKER, T., BARTELS, R., VAN LEEUWEN, M., *et al.* (2022) Identification of parameters and formulation of a statistical and machine learning model to identify Babesia canis infections in dogs using available ADVIA hematology analyzer data. *Parasites & Vectors* vol. 15, n° 1. [https://doi.org/10.1186/s13071-022-05163-4]
- PIOVANI, D., BONOVAS, S. (2022) Real World—Big Data Analytics in Healthcare. *International Journal of Environmental Research and Public Health* vol. 19, n° 18. [https://doi.org/10.3390/ijerph191811677]

- PORTER, I.R., WIELAND, M., BASRAN, P.S. (2021) Feasibility of the use of deep learning classification of teat-end condition in Holstein cattle. *Journal of Dairy Science* vol. 104, n° 4, p. 4529-4536. [<https://doi.org/10.3168/jds.2020-19642>]
- PUIG, A., RUIZ, M., BASSOLS, M., *et al.* (2022) Technological Tools for the Early Detection of Bovine Respiratory Disease in Farms. *Animals* vol. 12, n° 19, p. 2623. [<https://doi.org/10.3390/ani12192623>]
- PUNYAPORNWITHAYA, V., KLAHARN, K., ARJKUMPA, O., *et al.* (2022) Exploring the predictive capability of machine learning models in identifying foot and mouth disease outbreak occurrences in cattle farms in an endemic setting of Thailand. *Preventive Veterinary Medicine* vol. 207, p. 105706. [<https://doi.org/10.1016/j.prevetmed.2022.105706>]
- QUAIN, A., WARD, M.P., MULLAN, S. (2021) Ethical Challenges Posed by Advanced Veterinary Care in Companion Animal Veterinary Practice. *Animals* vol. 11, n° 11, p. 3010. [<https://doi.org/10.3390/ani11113010>]
- RADFORD, A., KIM, J.W., HALLACY, C., *et al.* (2021) Learning Transferable Visual Models From Natural Language Supervision. [<https://doi.org/10.48550/arXiv.2103.00020>]
- RADFORD, A., KIM, J.W., XU, T., *et al.* (2023) Robust speech recognition via large-scale weak supervision. *In Proceedings of the 40th International Conference on Machine Learning*. Honolulu, Hawaii, États-Unis, 23-29 juillet, JMLR, p. 28492-28518.
- RADFORD, A., TIERNEY, A., COYNE, K.P., *et al.* (2010) Developing a network for small animal disease surveillance. *The Veterinary Record* vol. 167, n° 13, p. 472-474. [<https://doi.org/10.1136/vr.c5180>]
- RAJA, R., MUKHERJEE, I., SARKAR, B.K. (2020) A Systematic Review of Healthcare Big Data. *Scientific Programming* vol. 2020. [<https://doi.org/10.1155/2020/5471849>]
- RAMESH, A., PAVLOV, M., GOH, G., *et al.* (2021) Zero-Shot Text-to-Image Generation. [<https://doi.org/10.48550/arXiv.2102.12092>]
- REAGAN, K.L., DENG, S., SHENG, J., *et al.* (2022a) Use of machine-learning algorithms to aid in the early detection of leptospirosis in dogs. *Journal of Veterinary Diagnostic Investigation* vol. 34, n° 4, p. 612-621. [<https://doi.org/10.1177/10406387221096781>]
- REAGAN, K.L., PIRES, J., QUACH, N., *et al.* (2022b) Evaluation of a machine learning tool to screen for hypoadrenocorticism in dogs presenting to a teaching hospital. *Journal of Veterinary Internal Medicine* vol. 36, n° 6, p. 1942-1946. [<https://doi.org/10.1111/jvim.16566>]
- REAGAN, K.L., REAGAN, B.A., GILOR, C. (2020) Machine learning algorithm as a diagnostic tool for hypoadrenocorticism in dogs. *Domestic Animal Endocrinology* vol. 72, p. 106396. [<https://doi.org/10.1016/j.domaniend.2019.106396>]
- REGALIA, G., ONORATI, F., LAI, M., *et al.* (2019) Multimodal wrist-worn devices for seizure detection and advancing research: Focus on the Empatica wristbands. *Epilepsy Research* vol. 153, p. 79-82. [<https://doi.org/10.1016/j.eplepsyres.2019.02.007>]
- REINSEL, D., GANTZ, J., RYDNING, J. (2017) Data Age 2025 : The Evolution of Data to Life-Critical, communication écrite.
- RHO, J., SHIN, S.-M., JHANG, K., *et al.* (2023) Deep learning-based diagnosis of feline hypertrophic cardiomyopathy. *PLOS ONE* vol. 18, n° 2, p. e0280438. [<https://doi.org/10.1371/journal.pone.0280438>]
- RIBEIRO, M.T., SINGH, S., GUESTRIN, C. (2016) « Why Should I Trust You? »: Explaining the Predictions of Any Classifier. *In Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. San Francisco, CA, États-Unis, 13-17 août, New York, NY, États-Unis, Association for Computing Machinery, p. 1135-1144. [<https://doi.org/10.1145/2939672.2939778>]
- ROBERTS, S.E., JAREMIN, B., LLOYD, K. (2013) High-risk occupations for suicide. *Psychological Medicine* vol. 43, n° 6, p. 1231-1240. [<https://doi.org/10.1017/S0033291712002024>]
- ROCA, R.Y., MCCARTHY, R.J. (2019) Impact of Telemedicine on the Traditional Veterinarian-Client-Patient Relationship. *Topics in Companion Animal Medicine* vol. 37, p. 100359. [<https://doi.org/10.1016/j.tcam.2019.100359>]

- ROCHA, J.C., PASSALIA, F.J., MATOS, F.D., *et al.* (2017) A Method Based on Artificial Intelligence To Fully Automatize The Evaluation of Bovine Blastocyst Images. *Scientific Reports* vol. 7, n° 1, p. 7659. [https://doi.org/10.1038/s41598-017-08104-9]
- ROMERO, M.P., CHANG, Y.-M., BRUNTON, L.A., *et al.* (2022) Machine learning classification methods informing the management of inconclusive reactors at bovine tuberculosis surveillance tests in England. *Preventive Veterinary Medicine* vol. 199, p. 105565. [https://doi.org/10.1016/j.prevetmed.2021.105565]
- ROMERO, M.P., CHANG, Y.-M., BRUNTON, L.A., *et al.* (2021) A comparison of the value of two machine learning predictive models to support bovine tuberculosis disease control in England. *Preventive Veterinary Medicine* vol. 188, p. 105264. [https://doi.org/10.1016/j.prevetmed.2021.105264]
- ROUSH, W.B., KIRBY, Y.K., CRAVENER, T.L., *et al.* (1996) Artificial neural network prediction of ascites in broilers. *Poultry Science* vol. 75, n° 12, p. 1479-1487. [https://doi.org/10.3382/ps.0751479]
- ROYAL VETERINARY COLLEGE (2022) VetCompass. [https://www.rvc.ac.uk/vetcompass] (consulté le 05/10/2023).
- RUFFINONI, P. (2023) Les outils digitaux à disposition des vétérinaires praticiens auprès des animaux de compagnie : revue et enquête auprès de 112 vétérinaires. Thèse Méd. Vét., VetAgro Sup.
- RUMELHART, D.E., HINTON, G.E., WILLIAMS, R.J. (1986) Learning representations by back-propagating errors. *Nature* vol. 323, n° 6088, p. 533-536. [https://doi.org/10.1038/323533a0]
- RUSSELL, S.J., NORVIG, P. (2020) Artificial Intelligence: A Modern Approach, 4ème édition. Londres, Pearson.
- SADEGHI, H., BRAUN, H.-S., PANTI, B., *et al.* (2022) Validation of a deep learning-based image analysis system to diagnose subclinical endometritis in dairy cows. *PLOS ONE* vol. 17, n° 1, p. e0263409. [https://doi.org/10.1371/journal.pone.0263409]
- SADEGHI, M., BANAKAR, A., KHAZAEI, M., *et al.* (2015) An Intelligent Procedure for the Detection and Classification of Chickens Infected by Clostridium Perfringens Based on their Vocalization. *Brazilian Journal of Poultry Science* vol. 17, p. 537-544. [https://doi.org/10.1590/1516-635X1704537-544]
- SADEGHI, M., BANAKAR, A., MINAEI, S., *et al.* (2023) Early Detection of Avian Diseases Based on Thermography and Artificial Intelligence. *Animals* vol. 13, n° 14, p. 2348. [https://doi.org/10.3390/ani13142348]
- SALAMONE, M., ADRIAENS, I., VERVAET, A., *et al.* (2022) Prediction of first test day milk yield using historical records in dairy cows. *Animal* vol. 16, n° 11, p. 100658. [https://doi.org/10.1016/j.animal.2022.100658]
- SAMARASINGHE, S., KOHLI, M., KULASIRI, D. (2018) Neural Networks for Robotic Detection of Mastitis in Dairy Cows: Netherlands and New Zealand Perspectives. In Bi, Y., Kapoor, S., Bhatia, R. (Éd.), *Proceedings of SAI Intelligent Systems Conference (IntelliSys) 2016, Lecture Notes in Networks and Systems*. Cham, Springer International Publishing, p. 989-996. [https://doi.org/10.1007/978-3-319-56991-8_75]
- SCHMIDHUBER, J. (2015) Deep learning in neural networks: An overview. *Neural Networks* vol. 61, p. 85-117. [https://doi.org/10.1016/j.neunet.2014.09.003]
- SCHOBESBERGER, H., PEHAM, C. (2002) Computerized detection of supporting forelimb lameness in the horse using an artificial neural network. *Veterinary Journal* vol. 163, n° 1, p. 77-84. [https://doi.org/10.1053/tvjl.2001.0608]
- SCHOFIELD, I., BRODBELT, D.C., KENNEDY, N., *et al.* (2021) Machine-learning based prediction of Cushing's syndrome in dogs attending UK primary-care veterinary practice. *Scientific Reports* vol. 11, p. 9035. [https://doi.org/10.1038/s41598-021-88440-z]
- SENGUPTA, P.P., HUANG, Y.-M., BANSAL, M., *et al.* (2016) Cognitive Machine-Learning Algorithm for Cardiac Imaging. *Circulation: Cardiovascular Imaging* vol. 9, n° 6, p. e004330. [https://doi.org/10.1161/CIRCIMAGING.115.004330]

- SEVILLA, J., HEIM, L., HO, A., *et al.* (2022) Compute Trends Across Three Eras of Machine Learning. *In 2022 International Joint Conference on Neural Networks*. Padoue, Italie, 18-23 juillet, IEEE. [<https://doi.org/10.1109/IJCNN5064.2022.9891914>]
- SHAKER, R., WILKE, C., OBER, C., *et al.* (2021) Machine learning model development for quantitative analysis of CT heterogeneity in canine hepatic masses may predict histologic malignancy. *Veterinary Radiology & Ultrasound* vol. 62, n° 6, p. 711-719. [<https://doi.org/10.1111/vru.13012>]
- SHAMSABARDEH, M., MARTÍNEZ-LÓPEZ, B., O'HARA, K.C., *et al.* (2022) Machine Learning Framework for Porcine Reproductive and Respiratory Syndrome Outbreak Forecasting. [<https://doi.org/doi.org/10.21203/rs.3.rs-1785633/v1>]
- SHEN, W., TU, D., YIN, Y., *et al.* (2021) A new fusion feature based on convolutional neural network for pig cough recognition in field situations. *Information Processing in Agriculture* vol. 8, n° 4, p. 573-580. [<https://doi.org/10.1016/j.inpa.2020.11.003>]
- SIACHOS, N., LENNOX, M., ANAGNOSTOPOULOS, A., *et al.* (2023) Development and validation of a fully automated 2D imaging system generating body condition scores for dairy cows using machine learning. *Journal of Dairy Science* p. à paraître. [<https://doi.org/10.3168/jds.2023-23894>]
- SLOB, N., CATAL, C., KASSAHUN, A. (2021) Application of machine learning to improve dairy farm management: A systematic literature review. *Preventive Veterinary Medicine* vol. 187, p. 105237. [<https://doi.org/10.1016/j.prevetmed.2020.105237>]
- SMITH, A., CARROLL, P.W., ARAVAMUTHAN, S., *et al.* (2023) Computer vision model for the detection of canine pododermatitis and neoplasia of the paw. *Veterinary Dermatology* p. à paraître. [<https://doi.org/10.1111/vde.13221>]
- SOW, D., TURAGA, D.S., SCHMIDT, M. (2013) Mining of Sensor Data in Healthcare: A Survey. *In Managing and Mining Sensor Data*. Boston, MA, Springer US, p. 459-504. [https://doi.org/10.1007/978-1-4614-6309-2_14]
- SPITERI, M., KNOWLER, S.P., RUSBRIDGE, C., *et al.* (2019) Using machine learning to understand neuromorphological change and image-based biomarker identification in Cavalier King Charles Spaniels with Chiari-like malformation-associated pain and syringomyelia. *Journal of Veterinary Internal Medicine* vol. 33, n° 6, p. 2665-2674. [<https://doi.org/10.1111/jvim.15621>]
- STEAGALL, P.V., MONTEIRO, B.P., MARANGONI, S., *et al.* (2023) Fully automated deep learning models with smartphone applicability for prediction of pain using the Feline Grimace Scale. *Scientific Reports* vol. 13, n° 1, p. 21584. [<https://doi.org/10.1038/s41598-023-49031-2>]
- STEIN, J.D., RAHMAN, M., ANDREWS, C., *et al.* (2019) Evaluation of an Algorithm for Identifying Ocular Conditions in Electronic Health Record Data. *JAMA Ophthalmology* vol. 137, n° 5, p. 491-497. [<https://doi.org/10.1001/jamaophthalmol.2018.7051>]
- STURM, V., EFROSININ, D., ÖHLSCHUSTER, M., *et al.* (2020) Combination of Sensor Data and Health Monitoring for Early Detection of Subclinical Ketosis in Dairy Cows. *Sensors* vol. 20, n° 5, p. 1484. [<https://doi.org/10.3390/s20051484>]
- SUMMERFIELD, G.I., DE FREITAS, A., VAN MARLE-KOSTER, E., *et al.* (2023) Automated Cow Body Condition Scoring Using Multiple 3D Cameras and Convolutional Neural Networks. *Sensors* vol. 23, n° 22, p. 9051. [<https://doi.org/10.3390/s23229051>]
- SUN, Z., SAMARASINGHE, S., JAGO, J. (2010) Detection of mastitis and its stage of progression by automatic milking systems using artificial neural networks. *Journal of Dairy Research* vol. 77, n° 2, p. 168-175. [<https://doi.org/10.1017/S0022029909990550>]
- TAGO, D., HAMMITT, J.K., THOMAS, A., *et al.* (2016) The Impact of Farmers' Strategic Behavior on the Spread of Animal Infectious Diseases. *PLOS ONE* vol. 11, n° 6. [<https://doi.org/10.1371/journal.pone.0157450>]
- TEIXEIRA, V.A., LANA, A.M.Q., BRESOLIN, T., *et al.* (2022) Using rumination and activity data for early detection of anaplasmosis disease in dairy heifer calves. *Journal of Dairy Science* vol. 105, n° 5, p. 4421-4433. [<https://doi.org/10.3168/jds.2021-20952>]

- THE ECONOMIST (2023) The race of the AI labs heats up. *In The Economist*. [https://www.economist.com/business/2023/01/30/the-race-of-the-ai-labs-heats-up] (consulté le 13/04/2023).
- THOMPSON, J., EVERHART NUNN, S.L., SARKAR, S., *et al.* (2023) Diagnostic Screening of Bovine Mastitis Using MALDI-TOF MS Direct-Spotting of Milk and Machine Learning. *Veterinary Sciences* vol. 10, n° 2, p. 101. [https://doi.org/10.3390/vetsci10020101]
- THOMPSON, J.S., GREEN, M.J., HYDE, R., *et al.* (2023) The use of machine learning to predict somatic cell count status in dairy cows post-calving. *Frontiers in Veterinary Science* vol. 10, p. 1297750. [https://doi.org/10.3389/fvets.2023.1297750]
- TOPOL, E.J. (2019) High-performance medicine: the convergence of human and artificial intelligence. *Nature Medicine* vol. 25, n° 1, p. 44-56. [https://doi.org/10.1038/s41591-018-0300-7]
- TORRECILHA, R.B.P., UTSUNOMIYA, Y.T., BATISTA, L.F. da S., *et al.* (2017) Prediction of lymph node parasite load from clinical data in dogs with leishmaniasis: An application of radial basis artificial neural networks. *Veterinary Parasitology* vol. 234, p. 13-18. [https://doi.org/10.1016/j.vetpar.2016.12.016]
- TOUVRON, H., LAVRIL, T., IZACARD, G., *et al.* (2023a) LLaMA: Open and Efficient Foundation Language Models. [https://doi.org/10.48550/arXiv.2302.13971]
- TOUVRON, H., MARTIN, L., STONE, K., *et al.* (2023b) Llama 2: Open Foundation and Fine-Tuned Chat Models. [https://doi.org/10.48550/arXiv.2307.09288]
- TRACHTMAN, A.R., BERGAMINI, L., PALAZZI, A., *et al.* (2020) Scoring pleurisy in slaughtered pigs using convolutional neural networks. *Veterinary Research* vol. 51, n° 1, p. 51. [https://doi.org/10.1186/s13567-020-00775-z]
- TURAKHIA, M.P., DESAI, M., HEDLIN, H., *et al.* (2019) Rationale and design of a large-scale, app-based study to identify cardiac arrhythmias using a smartwatch: The Apple Heart Study. *American Heart Journal* vol. 207, p. 66-75. [https://doi.org/10.1016/j.ahj.2018.09.002]
- TURCHIN, A., FLOREZ BUILES, L.F. (2021) Using Natural Language Processing to Measure and Improve Quality of Diabetes Care: A Systematic Review. *Journal of Diabetes Science and Technology* vol. 15, n° 3, p. 553-560. [https://doi.org/10.1177/19322968211000831]
- TUTTLE, A.H., MOLINARO, M.J., JETHWA, J.F., *et al.* (2018) A deep neural network to assess spontaneous pain from mouse facial expressions. *Molecular Pain* vol. 14, p. 1744806918763658. [https://doi.org/10.1177/1744806918763658]
- UNION EUROPÉENNE (2016) Règlement (UE) 2016/679 du Parlement européen et du Conseil du 27 avril 2016 relatif à la protection des personnes physiques à l'égard du traitement des données à caractère personnel et à la libre circulation de ces données, OJ L. [https://eur-lex.europa.eu/legal-content/FR/TXT/PDF/?uri=CELEX:32016R0679] (consulté le 01/01/2024).
- UNIVERSITY OF LIVERPOOL (2023) Small Animal Veterinary Surveillance Network. [https://www.liverpool.ac.uk/savsnet/] (consulté le 05/03/2023).
- UNIVERSITY OF MISSOURI (2014) The Veterinary Medical Databases. [https://vmdb.org/] (consulté le 04/10/2023).
- URAKAWA, T., TANAKA, Y., GOTO, S., *et al.* (2019) Detecting intertrochanteric hip fractures with orthopedist-level accuracy using a deep convolutional neural network. *Skeletal Radiology* vol. 48, n° 2, p. 239-244. [https://doi.org/10.1007/s00256-018-3016-3]
- VALENTE, C., WODZINSKI, M., GUGLIELMINI, C., *et al.* (2023) Development of an artificial intelligence-based method for the diagnosis of the severity of myxomatous mitral valve disease from canine chest radiographs. *Frontiers in Veterinary Science* vol. 10, p. 1227009. [https://doi.org/10.3389/fvets.2023.1227009]
- VAN DER VELDEN, B.H.M., KUIJF, H.J., GILHUIJS, K.G.A., *et al.* (2022) Explainable artificial intelligence (XAI) in deep learning-based medical image analysis. *Medical Image Analysis* vol. 79. [https://doi.org/10.1016/j.media.2022.102470]
- VAN STEENKISTE, G., VAN LOON, G., CREVECOEUR, G. (2020) Transfer Learning in ECG Classification from Human to Horse Using a Novel Parallel Neural Network Architecture. *Scientific Reports* vol. 10, n° 1, p. 186. [https://doi.org/10.1038/s41598-019-57025-2]

- VASWANI, A., SHAZEER, N., PARMAR, N., *et al.* (2017) Attention is All you Need. *In Proceedings of Advances in Neural Information Processing Systems 30*. Long Beach, CA, États-Unis, 04-09 décembre, Red Hook, NY, États-Unis, Curran Associates. [https://doi.org/10.1109/GrC.2010.104]
- VÁZQUEZ-DIOSDADO, J.A., GRUHIER, J., MIGUEL-PACHECO, G.G., *et al.* (2023) Accurate prediction of calving in dairy cows by applying feature engineering and machine learning. *Preventive Veterinary Medicine* vol. 219, p. 106007. [https://doi.org/10.1016/j.prevetmed.2023.106007]
- VERILY (2023) Viewpoint Recruit. [https://verily.com/solutions/viewpoint/recruit] (consulté le 14/04/2023).
- VETSCAN IMAGYST (2023) . *In Zoetis US*. [https://www.VetscanImagyst.com/] (consulté le 05/05/2023).
- VIDAL, G., SHARPNACK, J., PINEDO, P., *et al.* (2023) Impact of sensor data pre-processing strategies and selection of machine learning algorithm on the prediction of metritis events in dairy cattle. *Preventive Veterinary Medicine* vol. 215, p. 105903. [https://doi.org/10.1016/j.prevetmed.2023.105903]
- VILLAMIL, J.A., HENRY, C.J., BRYAN, J.N., *et al.* (2011) Identification of the most common cutaneous neoplasms in dogs and evaluation of breed and age distributions for selected neoplasms. *Journal of the American Veterinary Medical Association* vol. 239, n° 7, p. 960-965. [https://doi.org/10.2460/javma.239.7.960]
- VOLKMANN, N., KULIG, B., HOPPE, S., *et al.* (2021) On-farm detection of claw lesions in dairy cows based on acoustic analyses and machine learning. *Journal of Dairy Science* vol. 104, n° 5, p. 5921-5931. [https://doi.org/10.3168/jds.2020-19206]
- WANAMAKER, M.W., VERNAU, K.M., TAYLOR, S.L., *et al.* (2021) Classification of neoplastic and inflammatory brain disease using MRI texture analysis in 119 dogs. *Veterinary Radiology & Ultrasound* vol. 62, n° 4, p. 445-454. [https://doi.org/10.1111/vru.12962]
- WANG, H., KHOSHGOFTAAR, T.M., VAN HULSE, J. (2010) A Comparative Study of Threshold-Based Feature Selection Techniques. *In 2010 IEEE International Conference on Granular Computing*. San Jose, CA, États-Unis, 14-16 août, IEEE, p. 499-504. [https://doi.org/10.1109/GrC.2010.104]
- WANG, H.-H., WANG, Y.-H., LIANG, C.-W., *et al.* (2019) Assessment of Deep Learning Using Nonimaging Information and Sequential Medical Records to Develop a Prediction Model for Nonmelanoma Skin Cancer. *JAMA Dermatology* vol. 155, n° 11, p. 1277-1283. [https://doi.org/10.1001/jamadermatol.2019.2335]
- WANG, J., BELL, M., LIU, X., *et al.* (2020) Machine-Learning Techniques Can Enhance Dairy Cow Estrus Detection Using Location and Acceleration Data. *Animals* vol. 10, n° 7, p. 1160. [https://doi.org/10.3390/ani10071160]
- WANG, Jun, CHEN, H., WANG, Jianping, *et al.* (2023) Identification of oestrus cows based on vocalisation characteristics and machine learning technique using a dual-channel-equipped acoustic tag. *Animal* vol. 17, n° 6, p. 100811. [https://doi.org/10.1016/j.animal.2023.100811]
- WANG, L., ALEXANDER, C.A. (2020) Big data analytics in medical engineering and healthcare: methods, advances and challenges. *Journal of Medical Engineering & Technology* vol. 44, n° 6, p. 267-283. [https://doi.org/10.1080/03091902.2020.1769758]
- WANG, S., JIANG, H., QIAO, Y., *et al.* (2022) The Research Progress of Vision-Based Artificial Intelligence in Smart Pig Farming. *Sensors* vol. 22, n° 17, p. 6541. [https://doi.org/10.3390/s22176541]
- WANG, Y., KANG, X., HE, Z., *et al.* (2022) Accurate detection of dairy cow mastitis with deep learning technology: a new and comprehensive detection method based on infrared thermal images. *Animal* vol. 16, n° 10, p. 100646. [https://doi.org/10.1016/j.animal.2022.100646]
- WARD, J.S., BARKER, A. (2013) Undefined By Data: A Survey of Big Data Definitions. [https://doi.org/10.48550/arXiv.1309.5821]
- WILSON, A., SAEED, H., PRINGLE, C., *et al.* (2021) Artificial intelligence projects in healthcare: 10 practical tips for success in a clinical environment. *BMJ Health & Care Informatics* vol. 28, n° 1, p. e100323. [https://doi.org/10.1136/bmjhci-2021-100323]

- WINKLER, J.K., FINK, C., TOBERER, F., *et al.* (2019) Association Between Surgical Skin Markings in Dermoscopic Images and Diagnostic Performance of a Deep Learning Convolutional Neural Network for Melanoma Recognition. *JAMA Dermatology* vol. 155, n° 10, p. 1135-1141. [<https://doi.org/10.1001/jamadermatol.2019.1735>]
- WU, A., WANG, Y., SHU, X., *et al.* (2022) AI4VIS: Survey on Artificial Intelligence Approaches for Data Visualization. *IEEE Transactions on Visualization and Computer Graphics* vol. 28, n° 12, p. 5049-5070. [<https://doi.org/10.1109/TVCG.2021.3099002>]
- WU, D., HAN, M., SONG, H., *et al.* (2023) Monitoring the respiratory behavior of multiple cows based on computer vision and deep learning. *Journal of Dairy Science* vol. 106, n° 4, p. 2963-2979. [<https://doi.org/10.3168/jds.2022-22501>]
- XU, W., KNEGSEL, A.T.M. van, VERVOORT, J.J.M., *et al.* (2019) Prediction of metabolic status of dairy cows in early lactation with on-farm cow data and machine learning algorithms. *Journal of Dairy Science* vol. 102, n° 11, p. 10186-10201. [<https://doi.org/10.3168/jds.2018-15791>]
- YE, Y., SUN, W.W., XU, R.X., *et al.* (2021) Intraoperative assessment of canine soft tissue sarcoma by deep learning enhanced optical coherence tomography. *Veterinary and Comparative Oncology* vol. 19, n° 4, p. 624-631. [<https://doi.org/10.1111/vco.12747>]
- YILMAZ, M., ÇAKIR, M., ORAL, M.A., *et al.* (2023) Evaluation of disease outbreak in terms of physico-chemical characteristics and heavy metal load of water in a fish farm with machine learning techniques. *Saudi Journal of Biological Sciences* vol. 30, n° 4, p. 103625. [<https://doi.org/10.1016/j.sjbs.2023.103625>]
- YOO, I., ALAFAIREET, P., MARINOV, M., *et al.* (2012) Data mining in healthcare and biomedicine: a survey of the literature. *Journal of Medical Systems* vol. 36, n° 4, p. 2431-2448. [<https://doi.org/10.1007/s10916-011-9710-5>]
- YOON, Y., HWANG, T., LEE, H. (2018) Prediction of radiographic abnormalities by the use of bag-of-features and convolutional neural networks. *Veterinary Journal* vol. 237, p. 43-48. [<https://doi.org/10.1016/j.tvjl.2018.05.009>]
- ZHANG, M., ZHANG, K., YU, D., *et al.* (2021) Computerized assisted evaluation system for canine cardiomegaly via key points detection with deep learning. *Preventive Veterinary Medicine* vol. 193, p. 105399. [<https://doi.org/10.1016/j.prevetmed.2021.105399>]
- ZHANG, X., KANG, X., FENG, N., *et al.* (2020) Automatic recognition of dairy cow mastitis from thermal images by a deep learning detector. *Computers and Electronics in Agriculture* vol. 178, p. 105754. [<https://doi.org/10.1016/j.compag.2020.105754>]
- ZHU, H., SALGIRLI, Y., CAN, P., *et al.* (2023) Video-based estimation of pain indicators in dogs. In *2023 11th International Conference on Affective Computing and Intelligent Interaction*. Cambridge, MA, États-Unis, 10-13 septembre, IEEE, p. 1-8. [<https://doi.org/10.1109/ACII59096.2023.10388142>]
- ZHUANG, X., BI, M., GUO, J., *et al.* (2018) Development of an early warning algorithm to detect sick broilers. *Computers and Electronics in Agriculture* vol. 144, p. 102-113. [<https://doi.org/10.1016/j.compag.2017.11.032>]
- ZREIK, M., LESSMANN, N., VAN HAMERSVELT, R.W., *et al.* (2018) Deep learning analysis of the myocardium in coronary CT angiography for identification of patients with functionally significant coronary artery stenosis. *Medical Image Analysis* vol. 44, p. 72-85. [<https://doi.org/10.1016/j.media.2017.11.008>]

APPORT DE L'INTELLIGENCE ARTIFICIELLE AU DIAGNOSTIC VÉTÉRINAIRE

AUTEUR : Hadrien DIDELOT

RÉSUMÉ :

L'intelligence artificielle est une technologie complexe dont le fonctionnement requiert des données en très grande quantité, appelées parfois le *Big Data*. Plusieurs approches sont présentées, telles que les réseaux bayésiens, les séparateurs à vastes marges, les arbres décisionnels et les réseaux neuronaux. Leurs variantes plus récentes comme les réseaux neuronaux récurrents, les réseaux neuronaux convolutifs et les transformeurs sont également décrites, afin de mieux comprendre les défis et les limites de leur usage.

En médecine vétérinaire, l'intelligence artificielle a un potentiel novateur pour le diagnostic et une analyse de ses différentes applications est présentée dans cette thèse. Cette technologie a historiquement été développée pour le secteur rural en utilisant des données descriptives, notamment grâce à l'usage de robots de traite. Les approches envisagées pour les animaux de compagnie sont davantage axées sur les examens complémentaires et permettent d'assister le praticien dans sa démarche. L'intelligence artificielle peut ainsi contribuer à la détection précoce de nombreuses maladies et à l'interprétation d'examens d'imagerie médicale ou d'analyses sanguines. Les études vétérinaires restent cependant souvent limitées à des preuves de concept et davantage de recherche sont encore nécessaires dans plusieurs domaines d'intérêt.

Il est par ailleurs essentiel de reconnaître les défis intrinsèques à l'intelligence artificielle. L'origine, la variabilité et l'usage des données permettant leur entraînement constitue un des premiers enjeux et nécessitera une gestion prudente et une réglementation appropriée. Une collaboration étroite entre les vétérinaires et les propriétaires sera également primordiale pour intégrer l'intelligence artificielle le plus efficacement possible dans une pratique quotidienne, afin de continuer à assurer des soins de qualité respectant les enjeux éthiques liés aux animaux. Le potentiel de l'intelligence artificielle vétérinaire n'est pas négligeable et son utilisation raisonnée permettra également de faire avancer la médecine humaine, dans l'optique « *One Health* » d'une médecine unique pour l'environnement, l'Homme et les animaux.

MOTS CLÉS :

BIG DATA, INTELLIGENCE ARTIFICIELLE, MACHINE LEARNING, DIAGNOSTIC, *ONE HEALTH*

JURY :

Président : Pr Henry CHATEAU

Directeur de thèse : Pr Sylvain BELLIER

Examinatrice : Dr Ghita BENCHEKROUN

CONTRIBUTIONS OF ARTIFICIAL INTELLIGENCE TO VETERINARY DIAGNOSIS

AUTHOR: Hadrien DIDELOT

SUMMARY:

Artificial intelligence is a complex concept that requires large amounts of data, sometimes referred to as Big Data. This thesis describes various artificial intelligence architectures, including Bayesian networks, support vector machines, decision trees and neural networks, as well as recent variants such as recurrent neural networks, convolutional neural networks and transformers, to provide a better understanding of the challenges and limitations surrounding their use.

Artificial intelligence offers a significant opportunity for creating innovative diagnostic tools in veterinary medicine. As such, this thesis describes various use cases. Historically, artificial intelligence has been developed for the rural sector using descriptive data, particularly through the use of milking robots. Approaches for companion animals, however, are more focused on assisting veterinarians in their clinical decision-making. Artificial intelligence can therefore be used to provide early diagnosis of several diseases and to provide insights when assessing a radiography or a blood analysis. However, studies are often limited to proofs of concept and more research may be needed to achieve the desired results.

Acknowledging the inherent challenges associated with the use of artificial intelligence is crucial. Careful management and regulation are required to address primary concerns regarding the way data is used for training and its origin. Effective integration of artificial intelligence into daily veterinary practice while ensuring ethical and high-quality care will also require close collaboration between veterinarians and pet owners. Veterinary artificial intelligence also presents significant opportunities for human medicine and its use should aim for a unified One Health approach.

KEYWORDS:

BIG DATA, ARTIFICIAL INTELLIGENCE, MACHINE LEARNING, DIAGNOSIS, ONE HEALTH

JURY:

Chairperson: Pr Henry CHATEAU

Thesis Director: Pr Sylvain BELLIER

Reviewer: Dr Ghita BENCHEKROUN