



HAL
open science

Mise au point d'un algorithme de Deep Learning dédié au diagnostic radiographique de l'occlusion digestive chez le lapin

Benjamin Piedra

► To cite this version:

Benjamin Piedra. Mise au point d'un algorithme de Deep Learning dédié au diagnostic radiographique de l'occlusion digestive chez le lapin. Médecine vétérinaire et santé animale. 2024. dumas-04835787

HAL Id: dumas-04835787

<https://dumas.ccsd.cnrs.fr/dumas-04835787v1>

Submitted on 13 Dec 2024

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

MISE AU POINT D'UN ALGORITHME DE DEEP LEARNING DÉDIÉ AU DIAGNOSTIC RADIOGRAPHIQUE DE L'OCCLUSION DIGESTIVE CHEZ LE LAPIN

THESE D'EXERCICE

pour obtenir le titre de
DOCTEUR VÉTÉRINAIRE

DIPLOME D'ÉTAT

*présentée et soutenue publiquement
devant l'Université Paul-Sabatier de Toulouse
par*

PIEDRA Benjamin, Jean, Gabriel

Directeur de thèse : M. Fabrice CONCHOU

JURY

PRESIDENT :

M. Giovanni MOGICATO

Professeur à l'Ecole Nationale Vétérinaire de TOULOUSE

ASSESEURS :

M. Fabrice CONCHOU

Mme Catherine LAYSSOL-LAMOUR

Maître de Conférences à l'Ecole Nationale Vétérinaire de TOULOUSE

Ingénieure de recherche à l'Ecole Nationale Vétérinaire de TOULOUSE

**Ministère de l'Agriculture et de l'Alimentation
ÉCOLE NATIONALE VÉTÉRINAIRE DE TOULOUSE**

Liste des directeurs/assesseurs de thèse de doctorat vétérinaire

Directeur : Professeur Pierre SANS

PROFESSEURS CLASSE EXCEPTIONNELLE

- M. **BAILLY Jean-Denis**, *Hygiène et industrie des aliments*
- M. **BERTAGNOLI Stéphane**, *Pathologie infectieuse*
- Mme **BOURGES-ABELLA Nathalie**, *Histologie, anatomie pathologique*
- M. **BOUSQUET-MELOU Alain**, *Pharmacologie, thérapeutique*
- M. **BRUGERE Hubert**, *Hygiène et industrie des aliments d'origine animale*
- M. **CONCORDET Didier**, *Mathématiques, statistiques, modélisation*
- M. **DELVERDIER Maxence**, *Anatomie pathologique*
- M. **FOUCRAS Gilles**, *Pathologie des ruminants*
- Mme **GAYRARD-TROY Véronique**, *Physiologie de la reproduction, endocrinologie*
- M. **GUERIN Jean-Luc**, *Aviculture et pathologie aviaire*
- Mme **HAGEN-PICARD Nicole**, *Pathologie de la reproduction*
- M. **JACQUIET Philippe**, *Parasitologie et maladies parasitaires*
- M. **MEYER Gilles**, *Pathologie des ruminants*
- M. **SCHELCHER François**, *Pathologie médicale du bétail et des animaux de basse-cour*
- Mme **TRUMEL Catherine**, *Biologie médicale animale et comparée*

PROFESSEURS 1^{ère} CLASSE

- Mme **CADIERGUES Marie-Christine**, *Dermatologie vétérinaire*
- Mme **DIQUELOU Armelle**, *Pathologie médicale des équidés et des carnivores*
- M. **DUCOS Alain**, *Zootchnie*
- M. **GUERRE Philippe**, *Pharmacie et toxicologie*
- Mme **LACROUX Caroline**, *Anatomie pathologique, animaux d'élevage*
- Mme **LETRON-RAYMOND Isabelle**, *Anatomie pathologique*
- M. **LEFEBVRE Hervé**, *Physiologie et thérapeutique*
- M. **MAILLARD Renaud**, *Pathologie des ruminants*
- Mme **MEYNADIER Annabelle**, *Alimentation animale*
- M. **MOGICATO Giovanni**, *Anatomie, imagerie médicale*

PROFESSEURS 2^{ème} CLASSE

- Mme **BOULLIER Séverine**, *Immunologie générale et médicale*
- Mme **CAMUS Christelle**, *Biologie cellulaire et moléculaire*
- M. **CORBIERE Fabien**, *Pathologie des ruminants*
- Mme **FERRAN Aude**, *Physiologie-Thérapeutique*
- M. **MATHON Didier**, *Pathologie chirurgicale*
- M. **NOUVEL Laurent**, *Pathologie de la reproduction*
- Mme **PAUL Mathilde**, *Epidémiologie, gestion de la santé des élevages avicoles*
- M. **VOLMER Romain**, *Microbiologie et infectiologie*

MAITRES DE CONFERENCES HORS CLASSE

- M. **BERGONIER Dominique**, *Pathologie de la reproduction*
Mme **BIBBAL Delphine**, *Hygiène et industrie des denrées alimentaires d'origine animale*
M. **JAEG Jean-Philippe**, *Pharmacie et toxicologie*
Mme **LALLEMAND Elodie**, *Chirurgie des équidés*
M. **LIENARD Emmanuel**, *Parasitologie et maladies parasitaires*
M. **LYAZRHI Faouzi**, *Statistiques biologiques et mathématiques*
Mme **PALIERNE Sophie**, *Chirurgie des animaux de compagnie*
Mme **PRIYMENKO Nathalie**, *Alimentation*

MAITRES DE CONFERENCES CLASSE NORMALE

- M. **ASIMUS Erik**, *Pathologie chirurgicale*
Mme **BRET Lydie**, *Physique et chimie biologiques et médicales*
Mme **BOUHSIRA Emilie**, *Parasitologie, maladies parasitaires*
M. **CARTIAUX Benjamin**, *Anatomie, imagerie médicale*
M. **COMBARROS Daniel**, *Dermatologie vétérinaire*
M. **CONCHOU Fabrice**, *Imagerie médicale*
Mme **DANIELS Hélène**, *Immunologie, bactériologie, pathologie infectieuse*
Mme **DAVID Laure**, *Hygiène et industrie des aliments*
M. **DIDIMO IMAZAKI Pedro**, *Hygiène et industrie des aliments*
M. **DOUET Jean-Yves**, *Ophthalmologie vétérinaire et comparée*
M. **FERCHIOU Ahmed**, *Economie et gestion des entreprises vétérinaires agricoles*
M. **FUSADE-BOYER Maxime**, *Microbiologie et infectiologie*
M. **GAIDE Nicolas**, *Histologie, anatomie pathologique*
Mme **GRANAT Fanny**, *Biologie médicale animale*
Mme **JOURDAN Géraldine**, *Anesthésie, analgésie*
M. **JOUSSERAND Nicolas**, *Médecine interne des animaux de compagnie*
Mme **LAVOUE Rachel**, *Médecine Interne*
M. **LE GRAVERAND Quentin**, *Alimentation animale*
M. **LE LOC'H Guillaume**, *Médecine zoologique et santé de la faune sauvage*
Mme **MEYNAUD-COLLARD Patricia**, *Pathologie chirurgicale*
Mme **MILA Hanna**, *Elevage des carnivores domestiques*
M. **OTAVIANO DO REGO Renato**, *Chirurgie*
Mme **PIERRON Alix**, *Pharmacie-Toxicologie*
M. **VERGNE Timothée**, *Santé publique vétérinaire, maladies animales règlementées*
Mme **WASET-SZKUTA Agnès**, *Production et pathologie porcine*

INGENIEURS DE RECHERCHE

- M. **AUMANN Marcel**, *Urgences, soins intensifs*
M. **AUVRAY Frédéric**, *Santé digestive, pathogénie et commensalisme des entérobactéries*
M. **CASSARD Hervé**, *Pathologie des ruminants*
M. **CROVILLE Guillaume**, *Virologie et génomique cliniques*
Mme **DIDIER Caroline**, *Anesthésie, analgésie*
M. **DELPONT Mattias**, *Clinique Aviaire*
Mme **DUPOUY GUIRAUTE Véronique**, *Innovations thérapeutiques et résistances*
Mme **GAILLARD Elodie**, *Urgences, soins intensifs*
Mme **GEFFRE Anne**, *Biologie médicale animale et comparée*
Mme **GRISEZ Christelle**, *Parasitologie et maladies parasitaires*
Mme **JEUNESSE Elisabeth**, *Bonnes pratiques de laboratoire*
Mme **LAYSSOL-LAMOUR Catherine**, *Imagerie Médicale*
Mme **POUJADE Agnès**, *Anatomie pathologique Vétérinaire*
Mme **PRESSANTI Charline**, *Dermatologie vétérinaire*
M. **RAMON PORTUGAL Felipe**, *Innovations thérapeutiques et résistances*
M. **REYNOLDS Brice**, *Médecine interne des animaux de compagnie*
Mme **ROUCH BUCK Pétra**, *Médecine préventive*
Mme **SAADA Chloé**, *Gestion intégrée de la santé des ruminants*

REMERCIEMENTS

À Monsieur le Président du Jury :

Monsieur Giovanni MOGICATO

Professeur à l'Ecole Nationale Vétérinaire de Toulouse

Anatomie

Merci de nous faire l'honneur de présider ce jury aujourd'hui et pour le vif intérêt que suscite votre méthode d'enseignement de l'anatomie.

Aux membres du jury de thèse :

Monsieur Fabrice CONCHOU

Professeur à l'Ecole Nationale Vétérinaire de Toulouse

Service imagerie

Merci pour m'avoir fait confiance et m'avoir guidé durant l'élaboration de ce travail ainsi que pour avoir fait naître mon attrait pour l'imagerie. Trouvez ici l'expression de ma sincère reconnaissance.

Madame Catherine Layssol-Lamour

Professeur à l'Ecole Nationale Vétérinaire de Toulouse

Service imagerie

Merci de me faire l'honneur d'être présente et pour m'avoir accompagné lors de mon mois d'approfondissement d'imagerie. Hommages respectueux.

À l'équipe de PicoxIA :

Madame Émilie Boissady

Docteur Vétérinaire, ex-membre de PicoxIA

Merci pour m'avoir proposé ce sujet passionnant et m'avoir accompagné au début de la thèse.

Monsieur Benjamin TONI, Monsieur Guilhem CODRON et Yanis SCHUBLIN

Membres de PicoxIA

Merci pour votre aide, votre pédagogie et votre réactivité tout au long de la rédaction de ce travail.

TABLE DES MATIÈRES

INTRODUCTION

PREMIÈRE PARTIE : Formations des rayons-X et interactions avec la matière organique

1.1 Définition et bases physiques des rayons X

1.1.1 Définition des rayonnements ionisants

1.1.2 Rayons X et pouvoir de pénétration

1.2 Formation des rayons X et fonctionnement de l'appareil radiographique

1.2.1 Emission générale et caractéristique

1.2.2 Fonctionnement de l'appareil radiographique

1.3 Interactions entre les rayons X et la matière organique et formation de l'image radiographique

1.3.1 Interactions RX-Matière : effet photoélectrique et effet compton

1.3.2 Formation de l'image radiographique

1.3.3 Effets néfastes radio-induits : effet déterministes et aléatoires

1.4 Radioprotection

1.4.1 Grandeurs radiobiologiques

1.4.2 Principes de radioprotection et réglementation

DEUXIÈME PARTIE : Utilisation de la radiographie dans le diagnostic de l'occlusion digestive chez le lapin

2.1 Réalisation d'une radiographie de l'abdomen de lapin

2.1.1 Spécificités de la radiographie du lapin

2.1.2 Résultats radiographiques normaux de l'abdomen de lapin

- a) Tractus gastro-intestinal
- b) Foie
- c) Pancréas
- d) Rate

- e) Tractus urinaire
- f) Organes génitaux

2.2 L'Occlusion digestive chez le lapin

2.2.1 Définition et informations générales de l'occlusion digestive du lapin

2.2.2 Diagnostic et gestion de l'occlusion digestive chez le lapin

- a) Examen clinique
- b) Analyse sanguine
- c) Gestion de l'occlusion digestive

2.3 Diagnostic radiographique de l'occlusion digestive chez le lapin

2.3.1 Aspect radiographique du lapin en stase digestive

2.3.2 Signes radiographiques du lapin en occlusion digestive

TROISIÈME PARTIE : Fonctionnement de l'intelligence artificielle et rôle en radiographie vétérinaire

3.1 Définition de l'intelligence artificielle et applications en médecine vétérinaire

3.2 Mise en place de l'algorithme d'apprentissage profond (Deep Learning)

3.2.1 Définition de l'apprentissage profond

3.2.2 Organisation du système neuronal

3.2.2.1 Composition et fonctionnement d'un réseau de neurones à propagation avant

3.2.2.2 Entraînement d'un réseau de neurones et optimisation

- a) Fonction de perte
- b) Descente du gradient
- c) Optimisation du modèle

3.2.3 Application à la lecture radiographique

3.2.3.1 Composition et fonctionnement d'un réseau neuronal de convolution (RNC)

- a) Architecture en couches de 3 dimensions du RNC
- b) Types de couches au sein d'un RNC
- c) Analogie avec le cerveau humain

3.2.3.2 Aperçu d'applications de RNC en imagerie médicale

3.3 Evaluation des performances du réseau neuronal de reconnaissance d'images

QUATRIÈME PARTIE : Exécution de l'apprentissage de réseau appliqué au diagnostic d'occlusion digestive chez le lapin

4.1 Caractéristiques du modèle utilisé

4.2 Annotation binaire des radiographies

4.2.1 Base de données

4.2.2 Méthode d'annotation

4.2.3 Critères d'annotation

4.2.4 Pool final d'apprentissage

4.3 Evaluation de l'algorithme mis en place et analyse des résultats

4.3.1 Evaluation de l'algorithme mis en place avec les radiographies non recadrées

4.3.2 Evaluation de l'algorithme mis en place avec les radiographies recadrées

4.3.3 Comparaison des deux réseaux obtenus

4.4 Discussion et limites

CONCLUSION

RÉFÉRENCES BIBLIOGRAPHIQUES

ANNEXES

Annexe 1 : Ensemble des métriques d'évaluation du réseau entraîné avec les images recadrées

Annexe 2 : Ensemble des métriques d'évaluation du réseau entraîné avec les images non recadrées

TABLE DES ILLUSTRATIONS

Figure 1 : Spectre électromagnétique [8]

Figure 2 : Pouvoir de pénétration des rayonnements ionisants [9]

Figure 3 : Formation d'un rayon X, émission générale et caractéristique [8]

Figure 4 : Fonctionnement du tube radiogène [12]

Figure 5 : Effet photoélectrique [8]

Figure 6 : Effet Compton [8]

Figure 7 : Classification des effets néfastes radio-induits [13]

Figure 8 : Radiographie en vue ventrodorsale d'un lapin [15]

Figure 9 : Radiographie abdominale de lapin en vue latérale [14]

Figure 10 : Valeurs de glycémie moyenne en fonction du statut clinique d'après l'étude d'Harcourt-Brown (2012) [20]

Figure 11 : Radiographie ventro-dorsale et latérale d'un lapin en stase gastro-intestinale [17]

Figure 12 : Radiographie latérale d'un lapin en occlusion digestive distale [17]

Figure 13 : Paramètres radiographiques de l'estomac, de l'intestin grêle et du gros intestin chez le lapin en occlusion digestive et sans occlusion digestive [16]

Figure 14 : Radiographie latérale d'un lapin en occlusion digestive : Mesure de la longueur et de la largeur gastrique, perpendiculaire l'une et l'autre, ainsi que de la longueur L1-articulation coxo-fémorale

Figure 15 : Série de radiographies d'un lapin avec suspicion d'occlusion digestive [16]

Figure 16 : Traitement de l'information par un neurone pour une fonction d'activation sigmoïde [26]

Figure 17 : Types de fonctions d'activation et indications sur leur potentielles utilisations [26][28]

Figure 18 : Différentes allures de la fonction de perte en fonction du taux d'apprentissage [29]

Figure 19 : recherche du minimum de la fonction de perte en fonction du poids selon l'algorithme du gradient stochastique

Figure 20 : représentation de la descente du gradient pour une fonction de perte à plusieurs variables [31]

Figure 21 : représentation de la descente du gradient stochastique avec et sans l'optimiseur "momentum" [32]

Figure 22 : Organisation de couches du RNC en 3 dimensions adaptées au traitement d'images [29]

Figure 23 : fonctionnement d'une couche de convolution [33].

Figure 24 : Illustration du max-pooling et du average-pooling [34]

Figure 25 : Analogie entre le fonctionnement des cellules du complexe visuel primaire et un RNC [39]

Figure 26 : Tableau de contingence

Figure 27 : Courbe Précision-Rappel

Figure 28 : Méthodes de scaling [47]

Figure 29 : Accuracy de modèles sur la base de données ImageNet en fonction de leur taille [47]

Figure 30 : CAM du modèle EfficientNet après la méthode de scaling composé. Le modèle permet à l'algorithme de se concentrer sur des régions plus pertinentes contenant les détails des objets considérés.

Figure 31 : Exemple de radiographie annotée afin d'établir ou non le diagnostic d'occlusion

Figure 32 : Métriques d'évaluation du meilleur réseau entraîné avec des images non recadrées

Figure 33 : Métriques d'évaluation du meilleur réseau entraîné avec des images recadrées

Figure 34 : Courbes précision-rappel pour les deux algorithmes mis au point.

INTRODUCTION

Grâce à son développement récent, l'intelligence artificielle (IA), initialement confinée aux sphères scientifiques et aux laboratoires, a intégré le quotidien de la population. Désormais, ces outils permettent aussi bien de répondre aux questions des particuliers, à l'instar d'un moteur de recherche, que d'assister des professionnels dans leurs tâches, que ce soit dans des domaines artistiques (graphisme, vidéo...) ou scientifiques, comme la médecine humaine et vétérinaire.

En 1950, Alan Turing, mathématicien britannique, s'interroge sur la possibilité d'utiliser un ordinateur afin de simuler un comportement intelligent et un esprit critique, inventant ainsi un test destiné à évaluer cette capacité. Suite à ces réflexions, le terme "intelligence artificielle" est créé en 1956 par John McCarthy, mathématicien américain, qui le définit comme "la science et l'ingénierie de la fabrication de machines intelligentes" [1]. Afin d'appréhender ce concept, il convient alors de définir ce qu'on appelle l'intelligence. Selon le Centre National de Ressources Textuelles et Lexicales, la notion d'intelligence correspond à l'aptitude à appréhender et organiser les données de la situation, à mettre en rapport les procédés à employer avec le but à atteindre, à choisir les moyens ou à découvrir les solutions originales qui permettent l'adaptation aux exigences de l'action [2]. Par conséquent l'intelligence artificielle, de la même manière que l'intelligence humaine, peut être définie comme un ensemble de procédés ayant pour objectif de traiter des données afin de répondre à un problème donné, de manière similaire à l'intelligence humaine, en apprenant, prenant en compte les résultats précédents, anticipant différentes possibilités, etc.

En 1976, l'un des premiers prototypes utilisant l'intelligence artificielle dans le domaine de la médecine est développé à l'université Rutgers du New Jersey [3]. Il s'agit d'un système informatique permettant d'assister une consultation pour glaucome, du diagnostic jusqu'à la prise en charge du patient. D'autres programmes générant des diagnostics différentiels à propos d'informations sur les patients sont développés entre 1970 et 2000, mais ces incursions de l'intelligence artificielle dans la médecine restent marginales.

Il faudra attendre un changement de paradigme dans les modes d'apprentissage et de raisonnement de l'IA avant d'observer des avancements

majeurs. Les systèmes traditionnels sont basés sur des raisonnements déductifs (raisonnement qui présente des conclusions à partir d'informations données) et inductifs (raisonnement qui revient aux causes à partir des conséquences), comme c'est le cas du programme d'aide à la consultation pour glaucome évoqué précédemment. En 2007, la multinationale américaine IBM (International Business Machine Corporation) se lance dans le développement d'une intelligence artificielle ayant pour but de concurrencer l'humain lors d'un quiz télévisé [4]. Pour ce faire, l'IA doit retenir un grand nombre d'informations sur des domaines variés, avoir des capacités linguistiques permettant de saisir précisément l'objet des questions, et évaluer si la confiance en sa réponse est suffisante pour appuyer sur le buzzer. Un type de raisonnement, dit abductif, est alors intégré à la technologie. Ce raisonnement permet d'évaluer et de hiérarchiser les réponses probables à une question donnée. Le succès de Watson, l'intelligence artificielle développée par IBM, ne s'est pas limité à sa victoire au jeu télévisé en 2011. En effet, la technologie sur laquelle Watson se base, appelée DeepQA, a ensuite été utilisée à des fins médicales, de la synthèse de publications scientifiques au diagnostic d'une forme rare de leucémie en 2016 [5]. Avec les avancées récentes et notamment l'utilisation de l'apprentissage profond reposant sur des réseaux de neurones artificiels, l'intelligence artificielle est désormais appliquée à de nombreux domaines de la médecine humaine.

L'intégration de cette technologie dans le domaine médical soulève évidemment de nombreux questionnements éthiques et légaux [6]. Des informations erronées, dues à un dossier médical incomplet par exemple, peuvent entraîner des recommandations inadaptées, tant sur le plan thérapeutique que financier. Une autre considération importante est l'effet "boîte noire". Sans compréhension et visibilité sur le fonctionnement de l'algorithme, un résultat donné par l'intelligence artificielle perd en valeur et peut paraître abscons pour le clinicien. Ainsi, il convient d'être prudent et raisonné dans l'utilisation de l'intelligence artificielle, qui ne doit pas se substituer au jugement de l'humain.

Des applications de l'IA à la médecine vétérinaire sont disponibles, bien que plus marginales. L'entreprise française PicoxIA, qui m'accompagne dans la rédaction de cette thèse, propose par exemple une assistance à la lecture radiographique, disponible pour les praticiens. Le domaine de l'imagerie médicale est l'une des

applications prometteuses de l'IA, qui obtient pour certains cas des résultats comparables à ceux de techniciens expérimentés. Une étude de 2018, a abouti à la conclusion qu'un algorithme de Deep Learning, avait des performances similaires à celles d'un spécialiste dans la détection de nombreuses affections thoraciques, à partir de radiographies thoraciques [7]. Ces outils peuvent permettre d'améliorer les performances humaines en proposant une seconde lecture, et ainsi diminuer les potentielles baisses de performance du clinicien dues à la fatigue oculaire ou mentale.

C'est dans ce contexte que s'inscrit le sujet de ma thèse, qui consiste à la mise au point d'un algorithme de Deep Learning dédié au diagnostic radiographique de l'occlusion digestive chez le lapin, une pathologie pour laquelle la radiographie est l'un des principaux outils diagnostiques.

PREMIÈRE PARTIE : Formations des rayons-X et interactions avec la matière organique

1.1 Définition et bases physiques des rayons X

1.1.1 Définition des rayonnements électromagnétiques et rayonnements ionisants [8]

Les rayons X font partie de la famille des rayonnements électromagnétiques comme la lumière visible, les ondes radio et les rayons gamma. À l'instar des autres ondes électromagnétiques, les rayons X se propagent à la vitesse de la lumière en ligne droite c et peuvent être décomposés en ondes monochromatiques de longueurs d'onde λ et de fréquences ν différentes. Les trois grandeurs sont reliées par la formule $\nu = c/\lambda$, ν étant exprimé en Hz, c en m/s et λ en mètre.

La relation de Planck-Einstein définit l'énergie E d'un photon, corpuscule de masse nulle associée à une radiation électromagnétique monochromatique selon la formule : $E = h.\nu$, E étant exprimé en J, h étant la constante de Planck exprimée en J.s et ν étant la fréquence, exprimée en Hz. Les rayons X sont caractérisés par une longueur d'onde inférieure à celle de la lumière et donc à une fréquence plus élevée (de 10^{16} à 10^{20} Hz).

Ainsi un rayon X est un rayonnement bien plus énergétique que la lumière, et est donc un rayonnement ionisant ($E > 10$ électrovolts), c'est-à-dire un rayonnement assez énergétique pour arracher des électrons aux atomes et aux molécules.

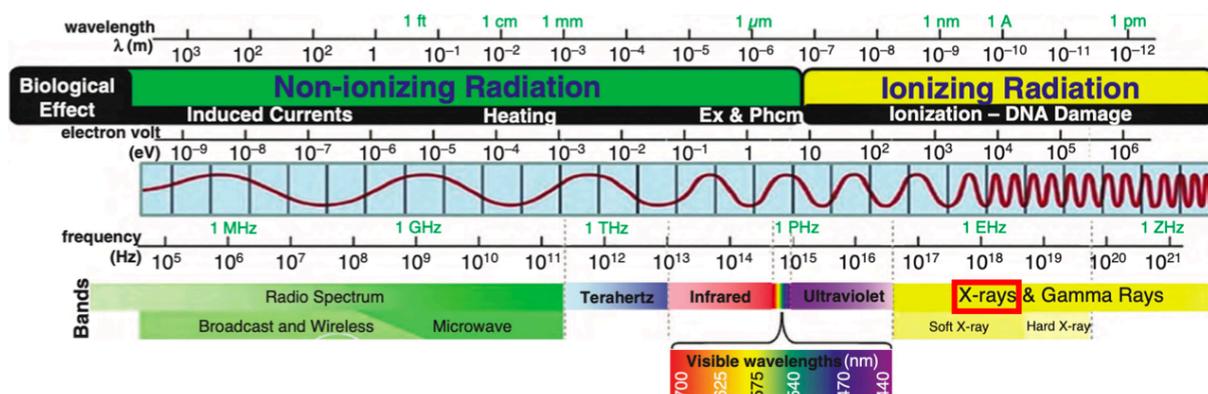


Figure 1 : Spectre électromagnétique (Bushberg, 2012 [8])

1.1.2. Rayons X et pouvoir de pénétration

Pour chaque rayonnement ionisant, un pouvoir de pénétration est défini, qui correspond à la distance sur laquelle se fait le transfert d'énergie du rayonnement. Ainsi, pour un transfert linéique d'énergie faible, le pouvoir de pénétration associé sera fort, l'énergie étant distribuée lentement, sur une grande distance. Le pouvoir de pénétration associé à un rayonnement conditionne les matériaux nécessaires pour arrêter le rayonnement et s'en protéger.




Figure 2 : Pouvoir de pénétration des rayonnements ionisants (CEA, 2015 [9])

Les noyaux d'hélium des particules alpha, au faible pouvoir de pénétration, sont arrêtés par une feuille de papier. Les rayons X transfèrent leur énergie sur plusieurs centaines de mètres dans l'air et ont donc une très grande pénétration. Une épaisseur de plomb permet de s'en protéger.

1.2 Formation des rayons X et formation de l'image radiographique

1.2.1. Emission générale et caractéristique [10][11]

La formation des rayons X est permise par deux mécanismes : l'émission générale, mode principal de formation des rayons X et l'émission caractéristique.

La trajectoire d'un électron chargé négativement est déviée par l'attraction Coulombienne lors de son passage à proximité d'un noyau chargé positivement. En supplément de cette déviation, l'électron est freiné. L'énergie cinétique perdue est rayonnée sous forme de photon sous la forme d'un rayon X. Plus l'électron passe près du noyau, plus la déviation et la perte d'énergie sont conséquentes, et plus le rayonnement de freinage (également appelé Bremsstrahlung) émis est énergétique.

La nature de l'atome influe également puisque plus le numéro atomique de l'atome approché est élevé, plus le nombre de charges positives au sein de son noyau est important, et plus le rayonnement émis est énergétique.

L'émission caractéristique est un mode de formation mineur des rayons X. Elle se produit lorsqu'un électron à grande vitesse en percute un autre, qui appartient aux couches électroniques de l'atome approché. Lorsque l'énergie de l'électron incident est supérieure à l'énergie de liaison de l'électron percuté, ce dernier est éjecté et est remplacé par l'électron d'une couche plus externe.

Les énergies de liaisons des électrons sont décroissantes avec la distance au noyau. La différence entre l'énergie de liaison de l'électron éjecté et celle de l'électron le remplaçant est émise sous forme de rayon X. Contrairement à l'émission générale, le spectre des rayons X produits par ce mécanisme est une variable discrète qui dépend de l'atome concerné, d'où son nom : "émission caractéristique".

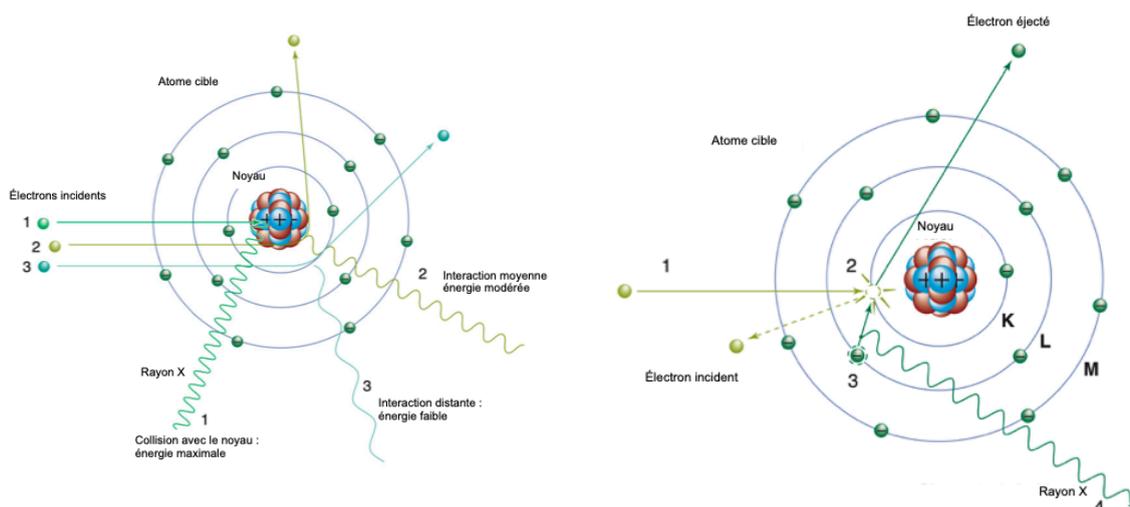


Figure 3 : Formation d'un rayon X, émission générale et caractéristique (Bushberg, 2012 [8])

1.2.2 Fonctionnement de l'appareil radiographique [10]

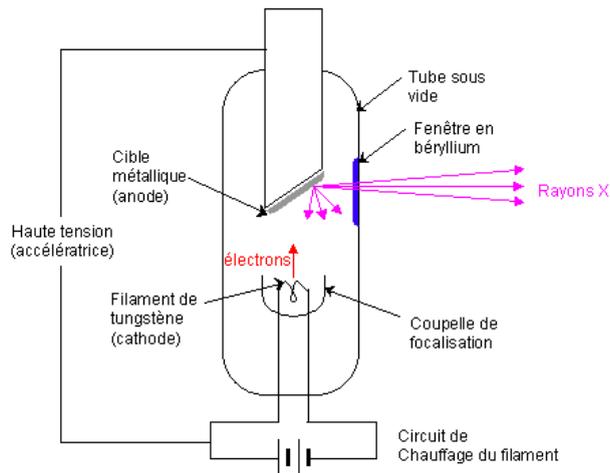


Figure 4 : Fonctionnement du tube radiogène (Simand et al., 2009 [12])

Un appareil à rayons X est constitué d'un tube radiogène, d'un générateur de haute tension et d'une console de contrôle. Au sein du tube radiogène, une cathode, chargée négativement est chauffée à très haute température de façon à créer un nuage d'électrons par effet thermo-ionique. Les électrons sont attirés par une anode (chargée positivement) du fait de leur charge négative. Lorsqu'ils frappent l'anode, des rayons X sont produits par les émissions générale et caractéristique.

Afin d'obtenir une image de qualité, il faut régler au préalable les constantes d'exposition : l'intensité, la tension et le temps d'exposition. Ces paramètres dépendent du format et de la localisation de la zone d'intérêt et sont associés au noircissement de l'image radiographique. Une augmentation de la tension (en kV) ou de l'intensité (en mA) entraîne une augmentation du degré de noircissement du film radiographique.

1.3 Interactions entre les rayons X et la matière organique et formation de l'image radiographique [10]

1.3.1 Interactions RX-Matière : effet photoélectrique et effet compton

En radiographie, les interactions des rayons X avec la matière sont essentielles pour comprendre la formation des images. L'effet photoélectrique se produit avec des rayons X de faible énergie (≤ 70 kV). Un rayon X incident est absorbé par un électron des couches internes de l'atome, ce qui éjecte un photoélectron avec une énergie cinétique égale à celle du rayon X incident, qui peut conduire à des ionisations ultérieures ou être absorbé par le milieu. Un électron des

couches supérieures remplace l'électron éjecté, ce qui émet un rayon X secondaire de faible énergie, rapidement absorbé par l'organisme. Cet effet prédomine avec les rayons X de basse énergie, la matière de forte densité et les tissus avec un numéro atomique élevé (Z élevé) comme l'iode (Z=53) et le plomb (Z=82). Hormis l'irradiation du personnel, cet effet a pour conséquence le contraste de l'image radiographique, c'est-à-dire la différence de noircissement entre deux régions du film.

L'effet Compton, quant à lui, se produit avec des rayons X de haute énergie (≥ 100 kV). Un rayon X incident frappe un électron libre ou faiblement lié, transférant une partie de son énergie à l'électron éjecté et émettant un rayon X diffusé avec une énergie proche de celle du rayon incident. Ce rayon X diffusé dévie de sa direction initiale. Cet effet prédomine avec les rayons X de haute énergie et la matière de densité moyenne, et il est indépendant du numéro atomique Z. Les principales conséquences de cet effet sont une irradiation importante du personnel et l'altération de la qualité de l'image, avec un voile réduisant la netteté et les contrastes.

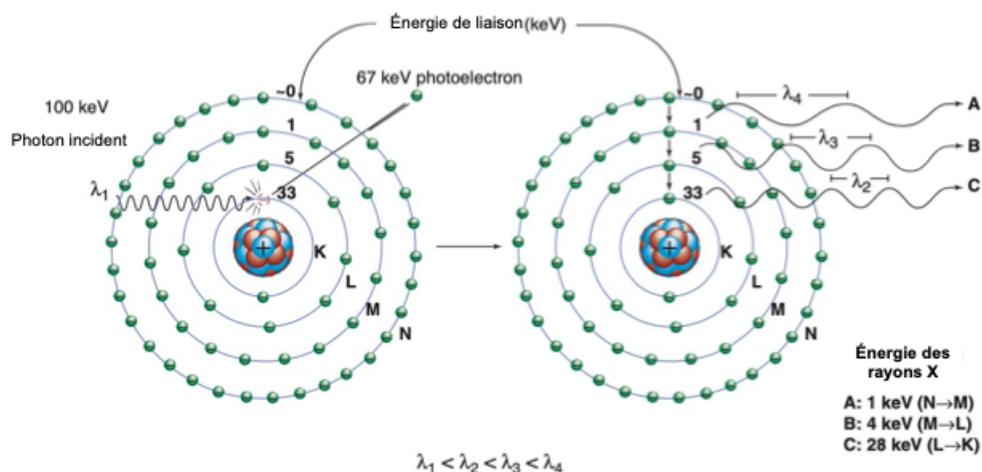


Figure 5 : Effet photoélectrique (Bushberg. 2012 [8])

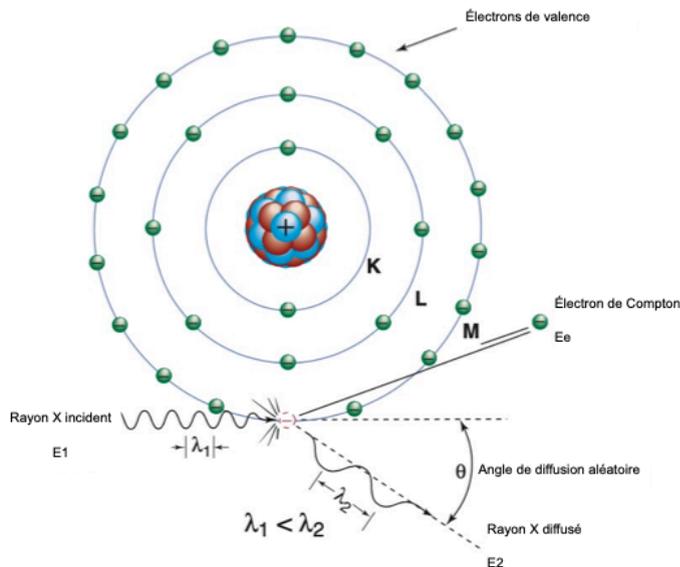


Figure 6 : Effet Compton (Bushberg. 2012 [8])

Ainsi, les rayons X peuvent être transmis, absorbés (créant une image par effet photoélectrique), ou déviés (effet Compton).

1.3.2 Formation de l'image radiographique

L'image radiographique est formée par noircissement d'un film radiographique par les rayons X. Lors du passage de milieux de diverses épaisseurs, densités et compositions atomiques, le faisceau incident de rayons X subit une diminution d'intensité appelée atténuation par absorption ou diffraction (par effet Compton et photoélectrique). Ainsi, si le rayon est transmis, l'image sera noire, tandis que s'il est absorbé, on observe des niveaux de gris. Pour des rayons X très absorbés, on se rapprochera du blanc, c'est pourquoi les os apparaissent clairs à la radiographie. L'atténuation est fonction de l'épaisseur du milieu traversé, de sa densité/ masse volumique ainsi que de son numéro atomique Z. Ces mécanismes aboutissent à l'existence de cinq types d'opacités principales en radiographie (de la plus sombre à la plus claire) : aérique, grasseuse, tissulaire, osseuse et minérale.

1.3.3 Effets néfastes radio-induits : effets déterministes et aléatoires

Les effets néfastes dus à l'utilisation de rayons X sont classiquement répartis en deux catégories. Premièrement, les effets déterministes sont obligatoires : si la dose reçue est au-dessus du seuil, il y a apparition de ces derniers de manière certaine, avec une gravité proportionnelle à l'intensité des rayonnements diffusés. Ils ne sont normalement jamais atteints si les seuils d'exposition sont respectés. Ces

effets apparaissent en général suite à des situations accidentelles d'exposition à fort débit de dose. Les effets aléatoires ou stochastiques peuvent se produire de manière aléatoire dès que le corps est exposé à une dose de rayons X. Leur gravité est indépendante de la dose et leur fréquence d'apparition est proportionnelle à l'exposition. Ces effets comprennent l'apparition de cancers notamment de la thyroïde, organe particulièrement sensible chez l'homme, mais également des effets héréditaires par atteinte des cellules germinales. Cette classification tend à évoluer pour mieux représenter la réalité des circonstances d'apparition de ces effets radio-induits.

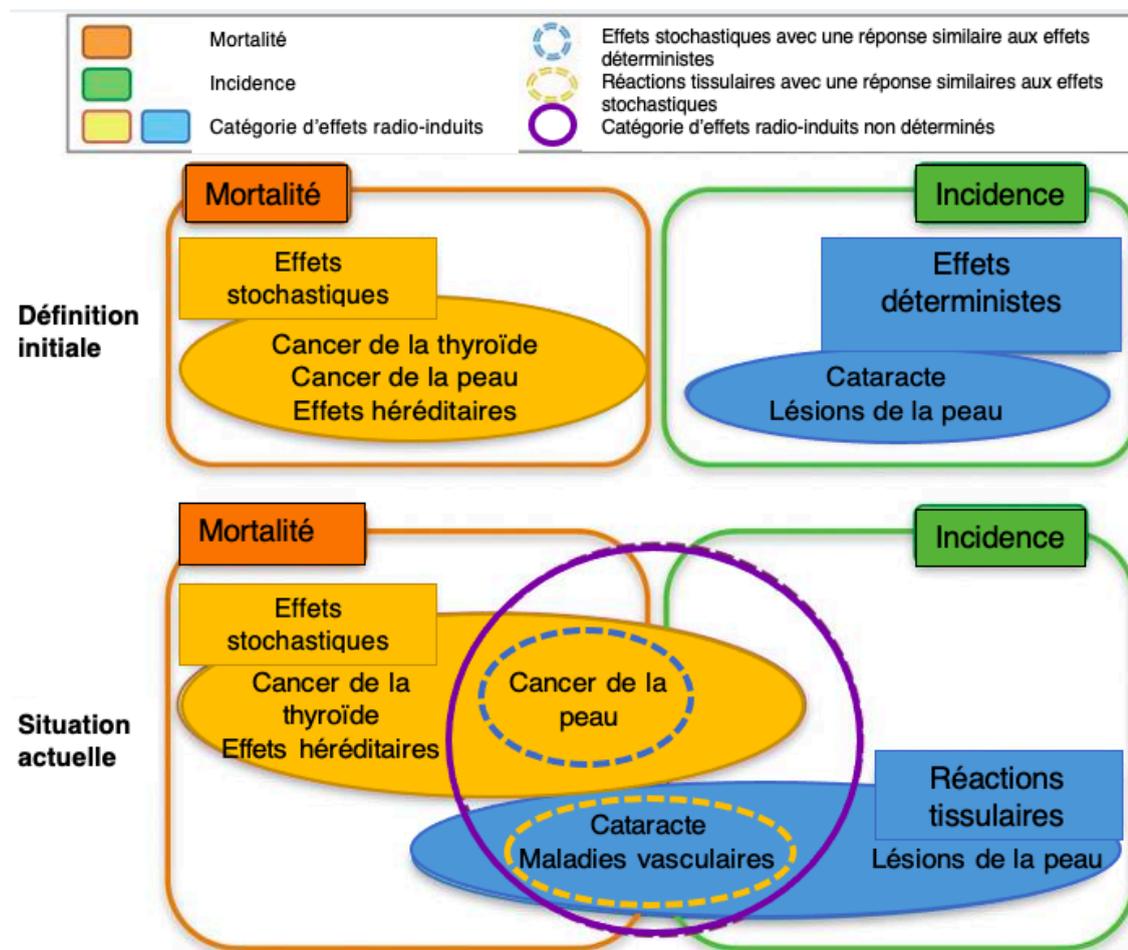


Figure 7 : Classification des effets néfastes radio-induits [13]

1.4 Radioprotection [10]

1.4.1 Grandeurs radiobiologiques

Trois grandeurs sont principalement utilisées en radioprotection. La dose absorbée (D) est une grandeur mesurable en Gray (Gy). Un Gray équivaut à un Joule par kilogramme. La dose équivalente (H), exprimée en Sievert (Sv) est une grandeur calculée qui correspond à la dose absorbée par un tissu ou un organe. Elle est égale à la somme des doses absorbées multipliée par un facteur de pondération radiologique égal à 1 pour les rayons X. Enfin, la dose efficace est une grandeur fictive correspondant à la dose qui, administrée de manière homogène au corps entier, entraînerait les mêmes dégâts tardifs que l'ensemble des doses reçues à des moments distincts par les différents organes.

1.4.2 Principes de radioprotection et réglementation

Trois catégories de personnes sont définies pour la radioprotection : le public, les patients et les travailleurs. Il n'existe actuellement pas de réglementation pour les animaux. La réglementation de radioprotection se base sur trois principes fondamentaux :

- Le principe de justification indique qu'il faut être capable de justifier la nécessité d'une radiographie.
- Le principe d'optimisation exige de maintenir l'exposition aussi basse que possible. Plusieurs mesures permettent de réduire la dose efficace, notamment pour les travailleurs : limiter le nombre de radiographies, agir sur la source avec un contrôle et une maintenance correcte du générateur etc.
- Le principe de limitation de dose qui fixe réglementairement des valeurs limites contrôlées par le port de dosimètre personnel, des dosimètres témoins et d'ambiance, des contrôles réguliers du générateur...

DEUXIÈME PARTIE : Utilisation de la radiographie dans le diagnostic de l'occlusion digestive chez le lapin

2.1 Réalisation d'une radiographie de l'abdomen de lapin

2.1.1 Spécificités de la radiographie du lapin

Les propriétaires de nouveaux animaux de compagnie (NAC) en médecine vétérinaire représentent désormais un pourcentage non négligeable de la clientèle. Les connaissances concernant les particularités anatomiques, physiologiques et pathophysiologiques de ces espèces s'accroissent donc naturellement, de pair avec la demande grandissante pour des soins de qualité. Les appareils radiographiques les plus couramment utilisés en pratique vétérinaire sont en général adaptés à la radiographie des lapins. Les réglages de temps d'exposition, de tension et d'intensité doivent cependant être adaptés au comportement, au format de l'animal ainsi qu'à la zone d'intérêt du diagnostic (thorax, abdomen...). Ainsi pour un lapin radiographié vigile, un temps d'exposition de moins de 0.02s est recommandé pour éviter le flou cinétique engendré par de potentiels mouvements [14]. Le positionnement et la contention des lapins suit les mêmes principes que chez les chats et les chiens, une sédation peut être nécessaire en cas d'animal compliqué à manipuler. Cependant la région lombaire étant particulièrement fragile chez cette espèce, la contention doit être adaptée afin d'éviter une paralysie irréversible des membres postérieurs.

2.1.2 Résultats radiographiques normaux de l'abdomen de lapin

L'opacité de tous les organes abdominaux est similaire. Le contraste d'une radiographie abdominale dépend principalement du degré d'embonpoint de l'animal. Le gras ayant une opacité inférieure aux parenchymes de ces organes, les dépôts mésentériques et rétropéritonéaux permettent d'en définir les contours et d'augmenter le contraste de la radiographie.

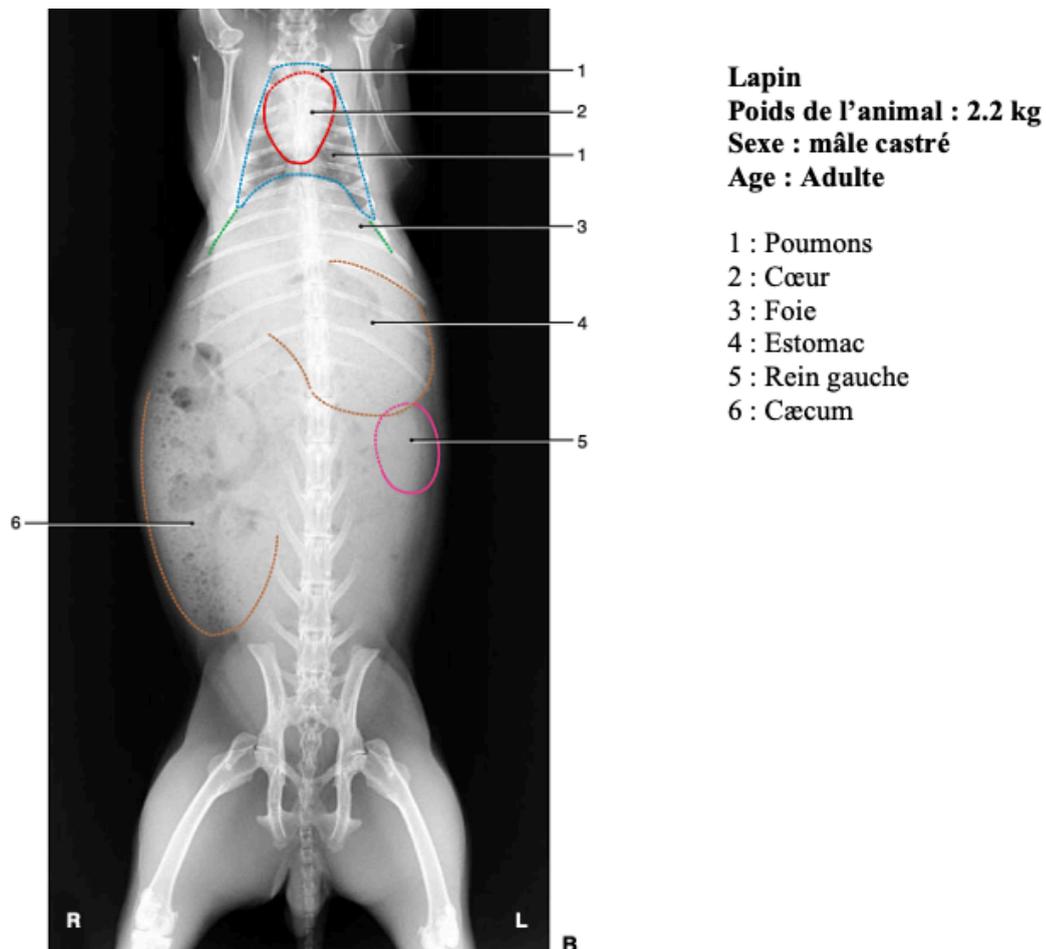


Figure 8 : Radiographie en vue ventrodorsale d'un lapin [15]

a) Tractus gastro-intestinal

Physiologiquement, le tractus gastro-intestinal est rempli de façon uniforme par un contenu d'opacité liquidienne non homogène et parsemé de petites bulles de gaz d'opacité gazeuse. Les matières fécales sont rondes chez le lapin. L'estomac, situé à gauche, s'étend particulièrement sur la droite chez le lapin, le pylore touchant presque la paroi abdominale droite. Caudalement, dépendant du positionnement et de son état de réplétion, un à deux tiers de l'organe dépassent de l'arc costal. L'intestin grêle ne peut pas être identifié avec certitude chez le lapin. Il se situe principalement sur la gauche, caudalement à l'estomac. Le cæcum est principalement situé sur la partie droite de la paroi abdominale ventrale et s'étend caudalement vers la gauche, prenant 1/3 de l'abdomen. La superposition de ce dernier avec le colon complique leur différenciation à la radiographie.

b) Foie

Le foie présente une opacité homogène de tissu mou. Physiologiquement, son bord ventro-caudal ne dépasse pas du cercle de l'hypochondre.

c) Pancréas

Le pancréas n'est pas visible radiographiquement chez le lapin.

d) Rate

Physiologiquement, la rate ne peut pas être identifiée sur une radiographie de lapin.

e) Tractus urinaire

Les reins sont situés dans le rétropéritoine, contre la paroi abdominale dorsale. Le rein gauche est habituellement situé en regard de L3-L5, et le rein droit étant légèrement plus crânial, en regard de T13-L1. Les uretères ne sont pas observables à la radiographie, de même que l'urètre. La forme de la vessie, située dans la cavité pelvienne, varie selon son état de réplétion.

f) Organes génitaux

Physiologiquement et en dehors d'une gestation, la majorité des organes génitaux ne peut être différenciée à la radiographie.

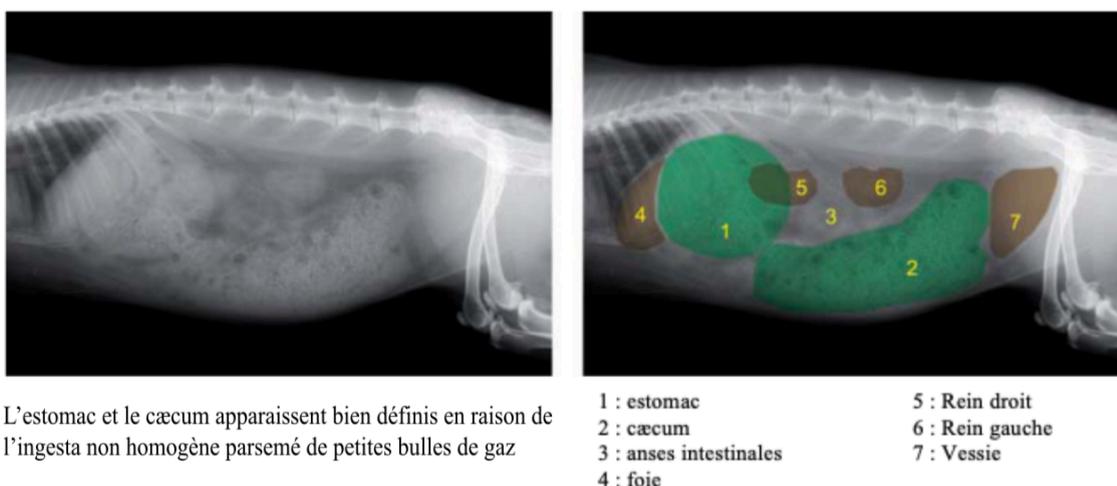


Figure 9 : Radiographie abdominale de lapin en vue latérale [14]

2.2 L'Occlusion digestive chez le lapin

2.2.1 Définition et informations générales de l'occlusion digestive du lapin [16]

L'occlusion digestive du lapin est une affection aiguë qui engage le pronostic vital de l'animal. Elle correspond à l'obstruction d'une partie du tube digestif par un corps étranger, un trichobézoard le plus fréquemment, ou tout autre phénomène diminuant la taille de la lumière intestinale (néoplasie, kyste, hernie...). L'affection est donc un iléus mécanique, c'est-à-dire un arrêt du transit focal avec une dilatation du tractus gastro-intestinal en amont de l'occlusion. En raison de leur incapacité à vomir, en cas d'obstruction complète de l'intestin, la dilatation gastro-intestinale est rapide. De plus, le site de l'occlusion impacte la vitesse d'évolution. L'un des plus courants est le duodénum proximal (rétrécissement physiologique), ce qui conduit à la mort de l'animal en 6 à 8h sans prise en charge. Des occlusions plus distales peuvent survenir, conduisant en moyenne à la mort de l'animal en 24h pour une localisation au niveau du jéjunum et en 36 à 48h pour l'iléon. [17]

2.2.2 Diagnostic et gestion de l'occlusion digestive chez le lapin [18][19]

Un large panel de signes cliniques sont associés à l'occlusion digestive, de l'anorexie et l'abattement à la mort subite. Une douleur aiguë est entraînée par la compression de la veine cave caudale et de l'artère aorte, causée par la dilatation gastrique, qui peut mener à terme à des désordres électrolytiques et même à un choc hypovolémique en l'absence de prise en charge. À terme, l'inflammation peut causer de l'ulcération voire de la nécrose intestinale, pouvant entraîner une péritonite et une rupture gastrique ou intestinale.

Le diagnostic de l'occlusion digestive chez le lapin est plus compliqué que chez les autres animaux de compagnie, notamment en raison de leur plus faible expression de la douleur et de l'absence de vomissement. Les outils diagnostiques principaux sont l'examen clinique, les analyses sanguines et la radiographie. Un des enjeux du diagnostic est de différencier l'occlusion des autres causes d'anorexie, notamment de la stase digestive. Le terme de stase gastro-intestinale est utilisé pour décrire une absence ou une réduction de la motilité gastro-intestinale, cause d'anorexie à laquelle les lapins sont particulièrement sujets.

a) Examen clinique

La palpation abdominale doit être systématiquement effectuée dans le cas d'un lapin anorexique. La dilatation de l'estomac entraîne une tension détectable à la palpation semblable à celle d'un ballon, différente de l'aspect ferme, pâteux et dépressible de l'estomac déshydraté du lapin en stase gastro-intestinale. Un examen clinique approfondi doit être conduit afin de détecter de potentiels freins à une décision chirurgicale en cas d'atteinte respiratoire par exemple. Bien que la fréquence cardiaque soit utile afin d'évaluer la douleur chez les autres espèces, la plage de valeurs physiologique chez lapin allant de 150 à 300 bpm, ce paramètre n'est pas très significatif. En effet, dans ce contexte, une fréquence cardiaque élevée est difficile à interpréter.

b) Analyse sanguine

La glycémie est un paramètre accessible et informatif, ce qui le rend particulièrement intéressant dans le cadre de l'occlusion digestive. En effet, la glycémie des lapins ayant des affections abdominales sévères monte rapidement à des niveaux élevés qui peuvent atteindre 30 mmol/L. En outre, la glycémie a un intérêt diagnostique supplémentaire selon une étude d'Harcourt-Brown de 2012 [20] portant sur l'intérêt clinique des valeurs de glycémie. Les conclusions de cette étude indiquent que les lapins pour qui une occlusion digestive était confirmée avaient des valeurs de glycémie significativement supérieures à celles de lapins en stase gastrique.

Statut clinique	Glycémie moyenne (mmol/L)
Absence d'anomalies cliniques	8,4
Stase digestive confirmée par radiographie	8,5
Suspicion d'occlusion digestive	17,4
Occlusion digestive confirmée à la chirurgie ou à l'examen post-mortem	24,7

Figure 10 : Valeurs de glycémie moyenne en fonction du statut clinique d'après l'étude d'Harcourt-Brown (2012) [20]

Les changements biochimiques les plus fréquents hormis l'hyperglycémie sont l'azotémie, l'hyponatrémie, ainsi qu'une activité augmentée des ASAT [21].

c) Gestion de l'occlusion digestive [17]

La gestion de l'occlusion digestive doit être rapide car la survie de l'animal est menacée. L'animal doit dans un premier lieu être stabilisé : en cas d'hypothermie, une source de chaleur externe doit immédiatement être apportée, l'état de choc doit être traité, l'estomac décompressé, les déséquilibres électrolytiques corrigés et la douleur contrôlée. Une fois l'état de choc pris en charge par l'administration d'une fluidothérapie avec un cristalloïde isotonique à dose de choc (60-90 mL/kg/h pendant une heure), la décompression de l'estomac peut être entreprise. Il est déconseillé d'effectuer une décompression percutanée à l'aide d'un trocart en raison du risque de rupture de l'estomac. La décompression est effectuée via un sondage oro-gastrique à l'aide d'une sonde orogastrique ou trachéale (16 à 18 Fr) suffisamment longue, lubrifiée et du plus gros diamètre possible [17]. La sédation est conseillée dans la plupart des cas. Un repère est placé sur la sonde après avoir mesuré la distance entre le nez et la dernière côte. La sonde est ensuite introduite dans l'œsophage jusqu'à l'estomac. Souvent bouchée par des poils, la sonde doit être rincée à plusieurs reprises et l'animal sondé plusieurs fois afin de décompresser l'estomac. Si l'état de l'animal ne s'améliore pas, que l'estomac se collecte à nouveau de gaz et de liquide, ou que la glycémie ne retourne pas à la normale, il convient d'envisager un traitement chirurgical pour lever l'occlusion. Un traitement médical peut également être envisagé en cas de restrictions financières ou de risque anesthésique élevé par exemple. Une étude de 2014 par Schuhmann et Cope [19] a porté sur 145 cas de dilatation gastrique traités par une combinaison de métoclopramide, de métamizole, de fluidothérapie au glucose et d'alimentation à la seringue. Pour 130 des individus, la dilatation gastrique a été résolue avec une moyenne de traitement de 3 jours.

2.3 Diagnostic radiographique de l'occlusion digestive chez le lapin

2.3.1 Aspect radiographique du lapin en stase gastro-intestinale

La stase gastro-intestinale est une cause d'anorexie différente de l'occlusion digestive, pouvant également être diagnostiquée par radiographie. L'aspect radiographique de l'abdomen du lapin en stase gastro-intestinale varie selon la

sévérité de l'affection. Dans tous les cas, l'estomac contient de l'ingesta, ce qui est particulièrement suggestif dans le cas d'un animal anorexique depuis plusieurs jours. L'ingesta apparaît dense, dû à sa déshydratation, et peut être entouré d'un halo de gaz. Le reste du tractus gastro-intestinal peut être modérément à sévèrement dilaté par du gaz, notamment le caecum.

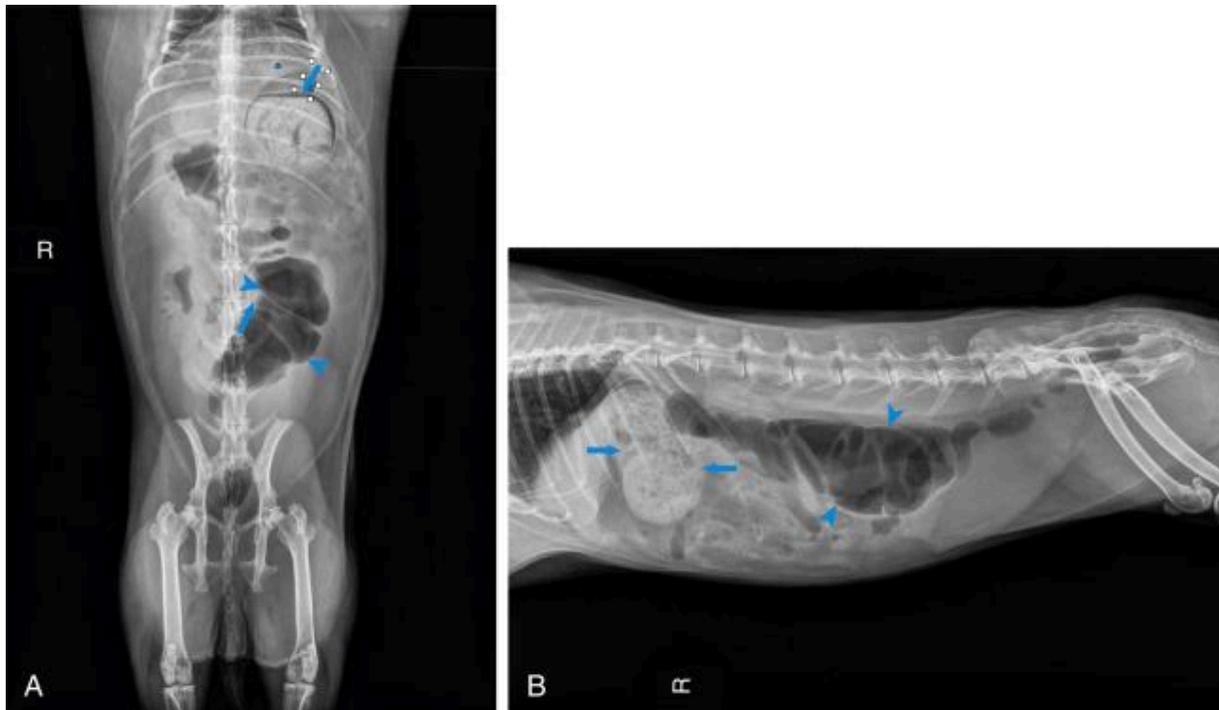


Figure 11 : Radiographie ventro-dorsale (A) et latérale (B) d'un lapin en stase gastro-intestinale : On note la densité accrue de l'ingesta ferme (flèche) et la quantité importante de gaz dans le caecum, caractéristique de la stase gastro-intestinale (tête de flèche) [17]

2.3.2 Signes radiographiques du lapin en occlusion digestive



Figure 12 : Radiographie latérale d'un lapin en occlusion digestive distale : On note la sévère dilatation de l'estomac rempli de liquide avec une bulle d'air (flèche) et la quantité importante de gaz dedans les anses intestinales (tête de flèche) [17]

L'aspect habituel de l'estomac du lapin en occlusion digestive est très différent de celui du lapin en stase gastro-intestinale. L'estomac du lapin en occlusion digestive est habituellement décrit comme étant rempli de fluide et de gaz. Cela peut lui conférer à la radiographie un aspect caractéristique en "œuf au plat", dû à l'accumulation d'une bulle de gaz par gravité, au niveau du centre de la zone de projection de l'estomac, sur le profil latéral. En 2019, une étude de Debenham et al. [16], portant sur 63 cas de lapin en occlusion digestive et 50 cas de lapin sans obstruction, a établi une liste de paramètres permettant d'affiner le diagnostic radiographique de l'affection. La taille de l'estomac était l'un des aspects évalués au travers de plusieurs critères : la somme de la longueur et de la largeur gastrique comparée à la longueur L1-articulation coxofémorale, l'extension caudale de l'estomac comparée à l'extension caudale de L2, l'existence d'un contact direct entre la paroi gastrique et l'abdomen ventral. Concernant le reste du tractus gastro-intestinal, la présence ou non de gaz dans le cæcum et le gros intestin était observée ainsi que la dilatation des anses digestives de l'intestin grêle.

Mesure de la taille de l'estomac	Obstruction (n=63)	Non-obstruction (n=50)
Somme de la longueur et de la largeur gastrique supérieure ou égale à la longueur L1-articulation coxofémorale	62 (98%)	6 (12%)
Extension caudal de l'estomac au-delà de l'extension caudal de L2	42 (65%)	0 (0%)
Contact direct entre la paroi gastrique et l'abdomen ventral	58 (92%)	6 (12%)
Contenu gastrique		
Liquide avec une bulle de gaz	58 (92%)	1 (2%)
Ingesta normal avec beaucoup de gaz	4 (6%)	3 (6%)
Ingesta normal (avec ou sans silhouette de gaz)	1 (2%)	46 (92%)
Autres paramètres radiographiques		
Dilatation de l'intestin grêle par du liquide/ gaz	30 (48%)	2 (4%)
Grande quantité de gaz dans le gros intestin	4 (6%)	19 (38%)

Figure 13 : Paramètres radiographiques de l'estomac, de l'intestin grêle et du gros intestin chez le lapin en occlusion digestive et sans occlusion digestive [16]

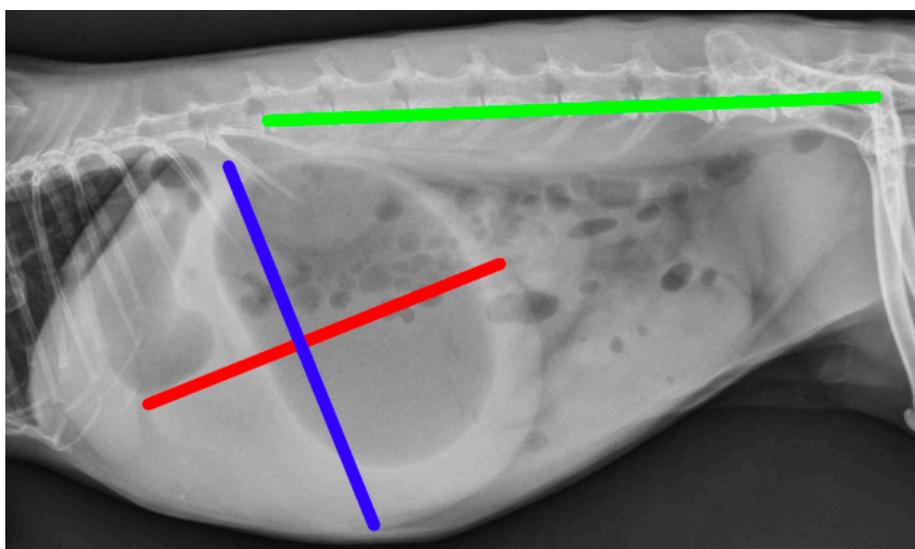
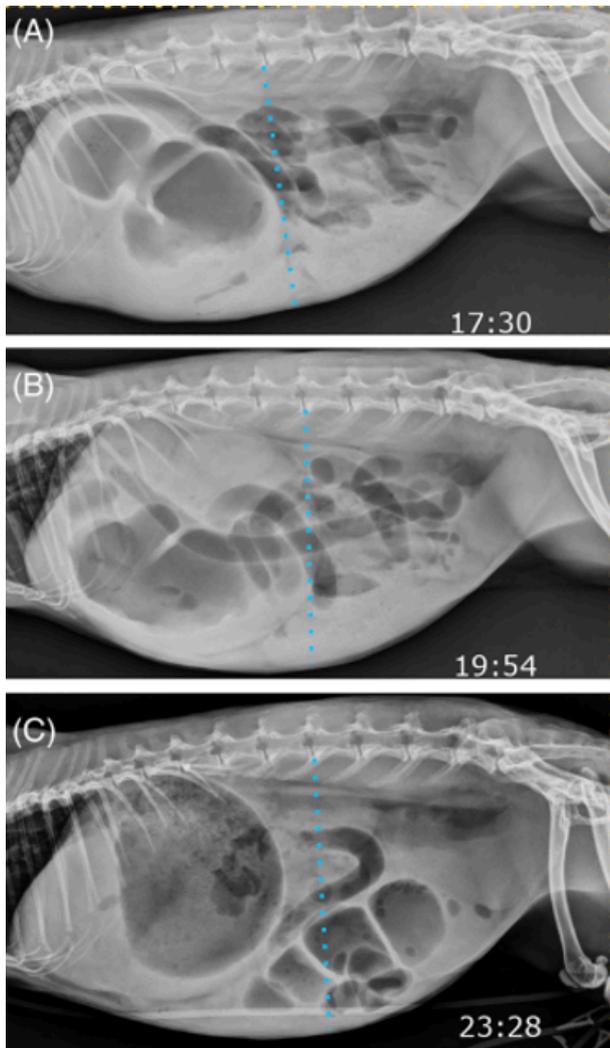


Figure 14 : Radiographie latérale d'un lapin en occlusion digestive : Mesure de la longueur (ligne bleue) et de la largeur gastrique (ligne rouge), perpendiculaire l'une et l'autre, ainsi que de la longueur L1-articulation coxo-fémorale (ligne verte) [16]

Le seul moyen de confirmer le diagnostic d'occlusion digestive est l'évaluation post-mortem ou la chirurgie. Cependant, certains paramètres radiographiques sont particulièrement évocateurs. Bien que l'échantillon traité par l'étude soit restreint, et

que la validité des résultats doit être confortée par d'autres études sur des échantillons de population différents, la taille de l'estomac semble bien être un indice important d'occlusion digestive. La somme de la longueur et de la largeur gastrique comparée à la longueur L1-articulation coxo-fémorale a été le paramètre le plus sensible dans l'échantillon de l'étude. Le dépassement de l'extension caudale de L2 par l'extension caudale de l'estomac a été un paramètre particulièrement spécifique. Il convient tout de même de noter que la dilatation gastrique peut se produire pour d'autres affections telles que l'entérite mucoïde du lapin, l'iléus paralytique etc.

Il convient de garder tous les paramètres considérés par l'étude à l'esprit, incluant donc la nature de l'ingesta. En effet, 92% des individus en occlusion avait un aspect de l'estomac caractéristique de l'occlusion digestive, c'est-à-dire rempli de fluide avec une bulle d'air, contre seulement 2% des lapins sans occlusion. Le reste du tractus gastro-intestinal semble également apporter au diagnostic. En effet, il semble logique qu'en cas d'occlusion du duodénum distal, du jéjunum ou de l'iléon, il y ait une distension des anses en amont. La présence de grandes quantités de gaz dans le cæcum, bien que rares dans le cas d'occlusion, est un paramètre à interpréter avec précaution, puisqu'il peut être indicateur d'un déplacement de l'obstruction distalement jusqu'au caecum. Il est également important de noter que l'aspect de l'abdomen du lapin évolue avec l'affection, et qu'une série de radiographies peut faciliter l'interprétation et aider à prendre une décision chirurgicale ou non.



Série de radiographie d'un lapin avec suspicion d'occlusion digestive.

(A) La radiographie initiale montre une distension gastrique avec un contenu principalement liquide avec une bulle d'air. Les anses intestinales sont distendues et il y a un peu de gaz dans le gros intestin.

(B) Une radiographie 2 heures plus tard montre un élargissement de l'estomac, qui s'étend désormais au-delà de l'extension caudale de L2.

(C) Une autre radiographie après 3.5 heures montre une réduction de la taille de l'estomac et de grandes quantités de gaz dans le cæcum.

Ligne bleue en pointillé : extension ventrale de l'extension caudale de L2.

Figure 15 : Série de radiographies d'un lapin avec suspicion d'occlusion digestive [16]

TROISIÈME PARTIE : Fonctionnement de l'intelligence artificielle et rôle en radiographie vétérinaire

3.1 Définition de l'intelligence artificielle et applications en médecine vétérinaire

L'Intelligence artificielle (IA) s'est considérablement développée ces dernières années ce qui a notamment permis l'apparition de nombreux outils destinés au vétérinaire praticien. Les applications les plus répandues concernent l'analyse d'échantillons et l'établissement d'un diagnostic clinique, par exemple avec la lecture radiographique assistée par IA. Ainsi dans le cadre de la médecine vétérinaire, et plus précisément de l'imagerie médicale, nous pouvons nous baser sur la définition du groupe d'expert de haut niveau sur l'intelligence artificielle nommé par la Commission Européenne. L'intelligence artificielle y est définie comme le propre des logiciels percevant leur environnement grâce à l'acquisition de données et qui permettent d'atteindre un objectif complexe par l'interprétation et le traitement de ces données, tout en adaptant leur comportement en fonction des résultats précédents. [22]

Comme évoqué précédemment, parmi les applications de l'intelligence artificielle disponibles dans le quotidien du praticien vétérinaire, l'analyse d'échantillons est l'une des plus accessibles et des plus répandues. L'analyseur SediVue Dx d'Idexx par exemple, génère et analyse lui-même des images à partir d'un échantillon de sédiments urinaires, indiquant la présence ou non de bactéries, de cylindres urinaires, le type de cellules présentes etc [23]. L'imagerie est également l'un des principaux domaines d'application de l'intelligence artificielle en médecine vétérinaire. Vetology AI, commercialisé en 2017, a été l'un des premiers logiciels destinés aux praticiens vétérinaires permettant une aide à l'interprétation de radiographies. En France, Picoxia est une entreprise proposant également aux praticiens une aide à la lecture de radiographies du thorax, de l'abdomen ou des hanches. L'un des principaux facteurs de l'essor de l'intelligence artificielle, notamment dans le secteur de la médecine vétérinaire, a été le développement de l'apprentissage profond ("deep learning" en anglais).

3.2 Mise en place de l'algorithme d'apprentissage profond (Deep Learning)

3.2.1 Définition de l'apprentissage profond [24]

L'apprentissage automatique (*machine learning* en anglais) désigne la capacité d'une machine à extraire les informations pertinentes à partir d'une base de données d'entraînement. L'apprentissage profond (*deep learning en anglais*) est un procédé d'apprentissage automatique utilisant des réseaux neuronaux possédant plusieurs couches de neurones cachées. Ces procédés marquent une rupture avec la programmation traditionnelle, au sein de laquelle une machine ne faisait qu'exécuter des consignes.

3.2.2 Organisation des systèmes neuronaux

3.2.2.1 Composition et fonctionnement d'un réseau de neurones à propagation avant

Un réseau est composé de nombreuses couches de neurones interconnectées. Un ensemble de données, appelé couche d'inputs, est présenté à la première couche de neurone. Chaque couche reçoit et traite les données reçues par la couche précédente. Dans le cas des phases d'entraînement du modèle (par opposition aux phases de validation de l'entraînement), le réseau de neurones est dit à propagation avant : l'information va donc avancer dans un seul sens, depuis la couche d'inputs, et être traitée jusqu'à la réponse de l'intelligence artificielle appelée la couche d'outputs. Les couches entre la couche d'inputs et d'outputs sont appelées les couches cachées. [25]

Chaque neurone est associé à une valeur x_i , résultat du traitement de l'ensemble des informations reçues par les couches précédentes, ainsi qu'à un paramètre b_i , le biais. Chaque connexion reçue d'un neurone précédent par un neurone est pondérée par un paramètre w_i , appelé poids. Le couple d'informations (x_i, w_i) de chaque neurone précédent est systématiquement traité de la même manière, par une fonction dite de pré-activation. Cette fonction est la somme de la multiplication des x_i avec les w_i , à laquelle est ajouté le biais b_i .

Le résultat de la fonction de pré-activation est ensuite traité par la fonction d'activation du neurone. Cette fonction peut être de nature variée mais ne doit pas être linéaire. En effet, si la fonction d'activation est linéaire, le réseau de neurones pourrait être simplifié en une seule couche de neurones et fonctionnerait comme une simple régression linéaire [26].

$$\text{Activation} = f(x) = \frac{1}{(1 + e^{-x})} = \frac{1}{(1 + e^{-10})} = 0,999954602131298$$

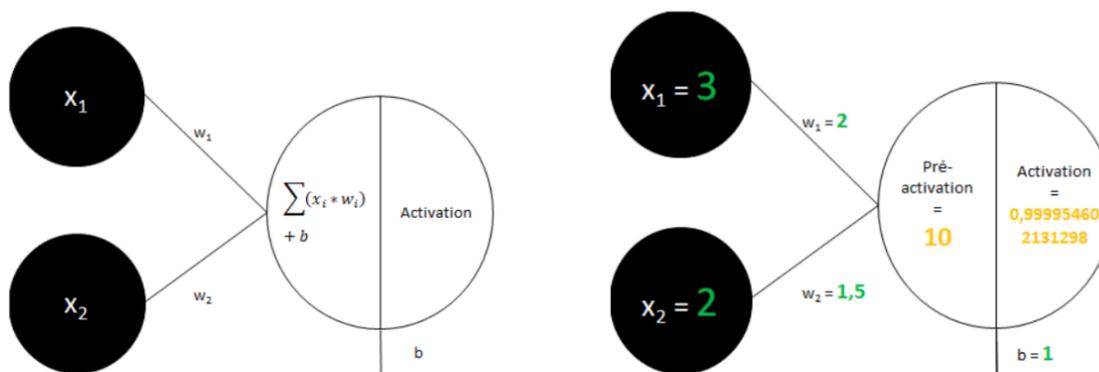
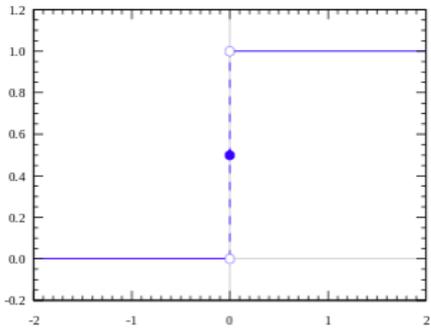
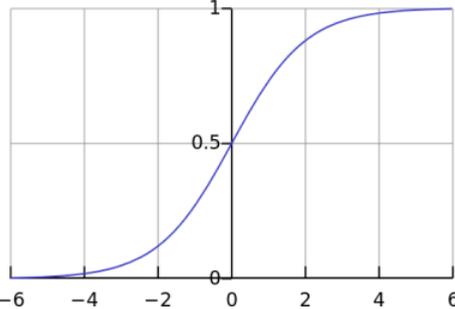
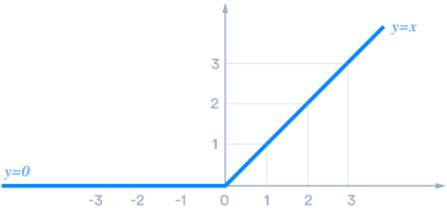


Figure 16 : Traitement de l'information par un neurone pour une fonction d'activation sigmoïde [26]

Nous pouvons définir deux objectifs principaux pour un algorithme d'apprentissage profond appliqué à l'imagerie médicale. L'objectif de classification est d'obtenir une couche d'outputs en plusieurs classes discrètes, permettant par exemple de détecter ou non la présence de pathologies. L'objectif de régression est de donner une valeur continue à partir des images données. Cette valeur peut par exemple être l'âge du patient, ou un score associée à la pertinence clinique de la radiographie (cadrage, contraste, qualité du cliché...). De nombreux types de fonctions d'activation, adaptées à ces différents objectifs, sont communément utilisés : les fonctions step, sigmoïde, ReLU, LReLU, Softmax etc.

Types de fonction d'activation	Allure de la fonction	Commentaire/ Utilisation
Step		<p>Fonction peu utilisée. Utile lorsque les outputs sont binaires : pathologie présente ou non, dans le cas de figure de la lecture radiographique.</p>
Sigmoidé		<p>Adaptée si les outputs sont des probabilités puisqu'une valeur entre 0 et 1 est donnée. L'une des fonctions d'activation les plus anciennes et les plus populaires.</p>
ReLU		<p>Très populaire car elle permet un entraînement plus rapide étant plus légère et "désactivant" certains neurones. Cependant cette caractéristique peut également diminuer la puissance de calcul, assignant une valeur de 0 à certains neurones, qui ne contribuent alors pas au processus d'apprentissage. Ce phénomène est appelé le problème "dying ReLU" [27].</p>

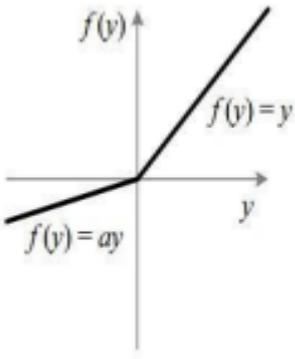
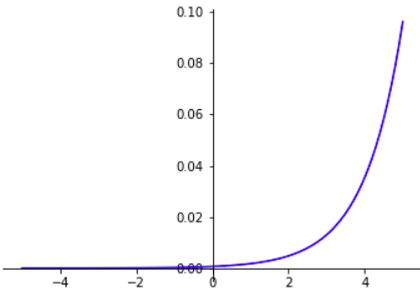
LReLU		Peut-être utilisée en cas de problème “dying ReLU”.
Softmax		Utilisée dans le cas d'une classification multi-classes, par opposition à une classification binaire. Permet par exemple de répondre à la question “Quel organe apparaît sur l'image?”.

Figure 17 : Types de fonctions d'activation et indications sur leur potentielles utilisations [26][28]

3.2.2.2 Entraînement d'un réseau de neurones et optimisation

a) Fonction de perte

Lorsqu'un réseau de neurones s'entraîne, les valeurs de poids et de biais assignés sont initialement aléatoires. L'IA va ainsi fournir ses premiers résultats et corriger les valeurs des paramètres en les comparant avec les résultats attendus. On appelle cette phase de validation du modèle la rétropropagation, puisque les paramètres vont être mis à jour en fonction des résultats, et des différents paramètres qui en découlent.

L'écart entre les prévisions du modèles et les observations réelles du jeu de données utilisé pendant l'entraînement est quantifié par la fonction de perte (fonction de coût ou encore loss function). Le but est donc de minimiser cette fonction à chaque cycle d'apprentissage (ou epoch), et l'entraînement est fini lorsque la fonction de perte est inférieure à un seuil défini au préalable. Le taux d'apprentissage est un hyperparamètre, c'est-à-dire un paramètre dont la valeur est utilisée pour contrôler le processus d'apprentissage. Il influe sur la rapidité avec laquelle le réseau va s'ajuster. Selon la valeur de cet hyperparamètre, la valeur de la perte en fonction de

l'époque va avoir différentes allures. Par exemple, pour un taux d'apprentissage trop bas, la valeur de la perte aura un aspect linéaire. Pour un taux d'apprentissage trop élevé, la valeur de la perte ne convergera jamais vers un minimum. Dans le cas d'un taux d'apprentissage optimal, l'allure de la fonction de perte se rapprochera de celle d'une fonction exponentielle.

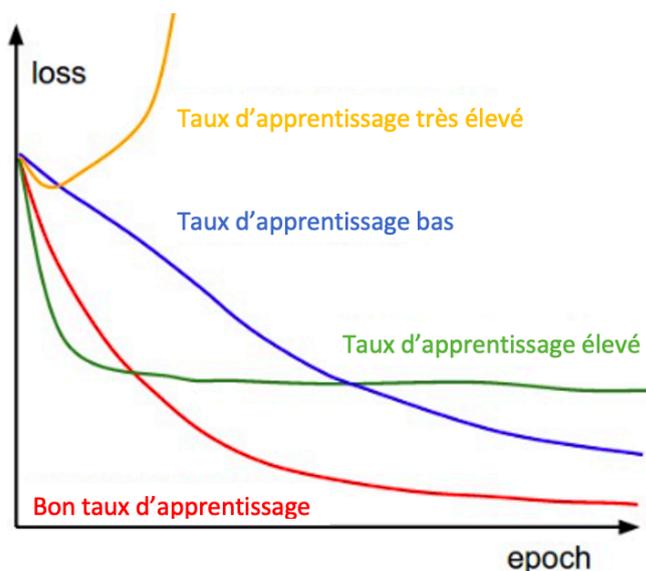


Figure 18 : Différentes allures de la fonction de perte en fonction du taux d'apprentissage [29]

Dans le cas de la régression, l'output étant une valeur continue, la fonction de perte L la plus utilisée est l'erreur quadratique moyenne [30]. Soit un ensemble de données D , composé de n échantillons d'entraînement, et m_{θ} étant notre modèle, avec θ l'ensemble de tous ses paramètres (poids et biais). On définit y_i , la valeur cible attendue en output pour ce modèle, et \hat{y}_i la sortie du modèle, pour l'échantillon i . Une fonction de perte L correspondant à l'erreur quadratique moyenne, peut alors être définie ainsi :

$$L(D, m_{\theta}) = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2$$

Dans le cas d'une classification à classe multiple associée à des probabilités, l'output est une valeur discrète et la fonction de perte L la plus utilisée est l'entropie croisée [30]. D est notre ensemble de données composé de n échantillons d'entraînement et m_{θ} est notre modèle, avec θ l'ensemble de tous ses paramètres (poids et biais), la fonction de perte L correspondant à la fonction d'entropie croisée, peut être définie comme ceci :

$$L(D, m_{\theta}) = -\frac{1}{n} \sum_{i=1}^n \sum_{j=1}^C \hat{y}_{i,j} \log(p_{i,j})$$

- p_i étant la probabilité selon le réseau que l'échantillon i (par exemple l'image radiographique) appartienne à la classe j (par exemple une radiographie de cardiomégalie)
- $\hat{y}_{i,j}$ étant la réalité concernant l'appartenance de l'échantillon i à la classe j. Ainsi $\hat{y}_{i,j} = 1$ si la classe j est attendue pour l'échantillon i, $\hat{y}_{i,j} = 0$ sinon.
- C étant le nombre de classes différentes

b) Descente du gradient

Lors de la phase de rétropropagation, les paramètres θ du réseau (poids et biais) sont en général modifiés selon la descente du gradient. C'est un algorithme itératif de minimisation de la fonction de perte du modèle.

Soit η correspondant au taux d'apprentissage, et $\frac{\partial L}{\partial \theta}$ étant la dérivée partielle de la fonction de perte L en fonction des paramètres θ . L'algorithme correspond à la formule suivante :

$$\theta \leftarrow \theta - \eta \cdot \frac{\partial L(\theta)}{\partial \theta}$$

Soit pour les paramètres de poids $\omega_{i,j}$ (le poids exercé par le neurone j sur le neurone i) et de biais b_i associé au neurone i :

$$\omega_{i,j} \leftarrow \omega_{i,j} - \eta \cdot \frac{\partial L(\omega_{i,j})}{\partial \omega_{i,j}}$$

$$b_i \leftarrow b_i - \eta \cdot \frac{\partial L(b_i)}{\partial b_i}$$

On remarque que plus le taux d'apprentissage est élevé, plus la variation des paramètres à chaque epoch va être conséquente.

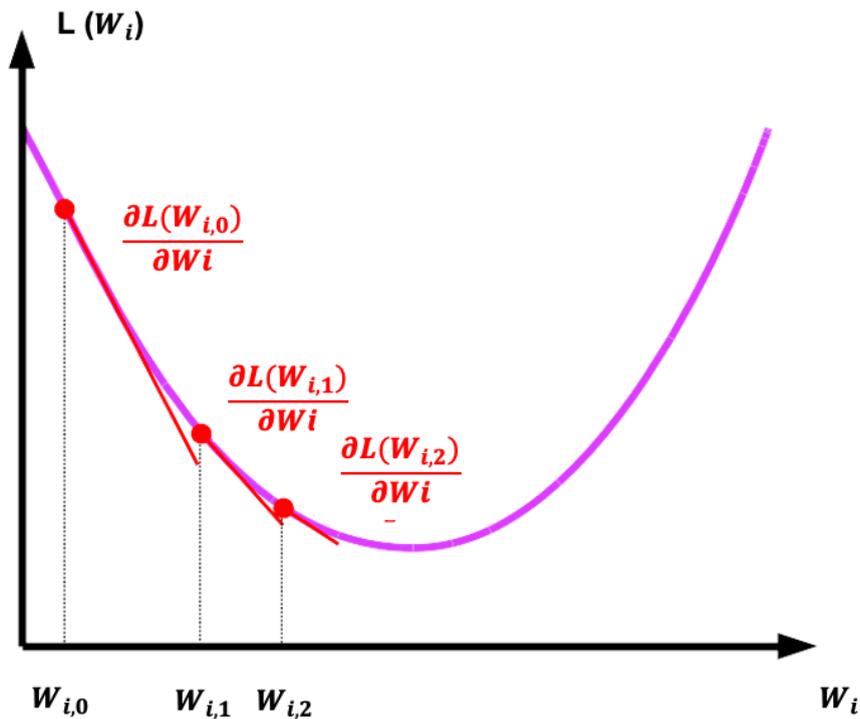


Figure 19 : recherche du minimum de la fonction de perte en fonction du poids selon l'algorithme du gradient stochastique

Rq : $W_{i,j}$ correspond ici au poids d'un neurone i dans une connexion à l'epoch j , par souci de simplification. Cette figure illustre le problème pour une fonction unidimensionnelle, ce qui n'est pas le cas en pratique

L'exemple ci-dessus permet de visualiser la méthode de descente du gradient. Cependant, les fonctions de perte sont des fonctions à plusieurs variables, qui peuvent avoir des minimums locaux. Il faut ainsi bien adapter le taux d'apprentissage pour ne pas converger vers un minimum local ne permettant pas l'optimisation de l'IA.

De plus, calculer l'algorithme pour tout le jeu de données d'entraînement peut prendre beaucoup de temps. Des alternatives existent :

- La méthode de descente du gradient stochastique applique l'algorithme de descente du gradient à un unique échantillon choisi aléatoirement à chaque epoch.
- La méthode de descente du gradient par mini-lot (mini-batch) applique l'algorithme à des mini-lots d'échantillons à chaque epoch.

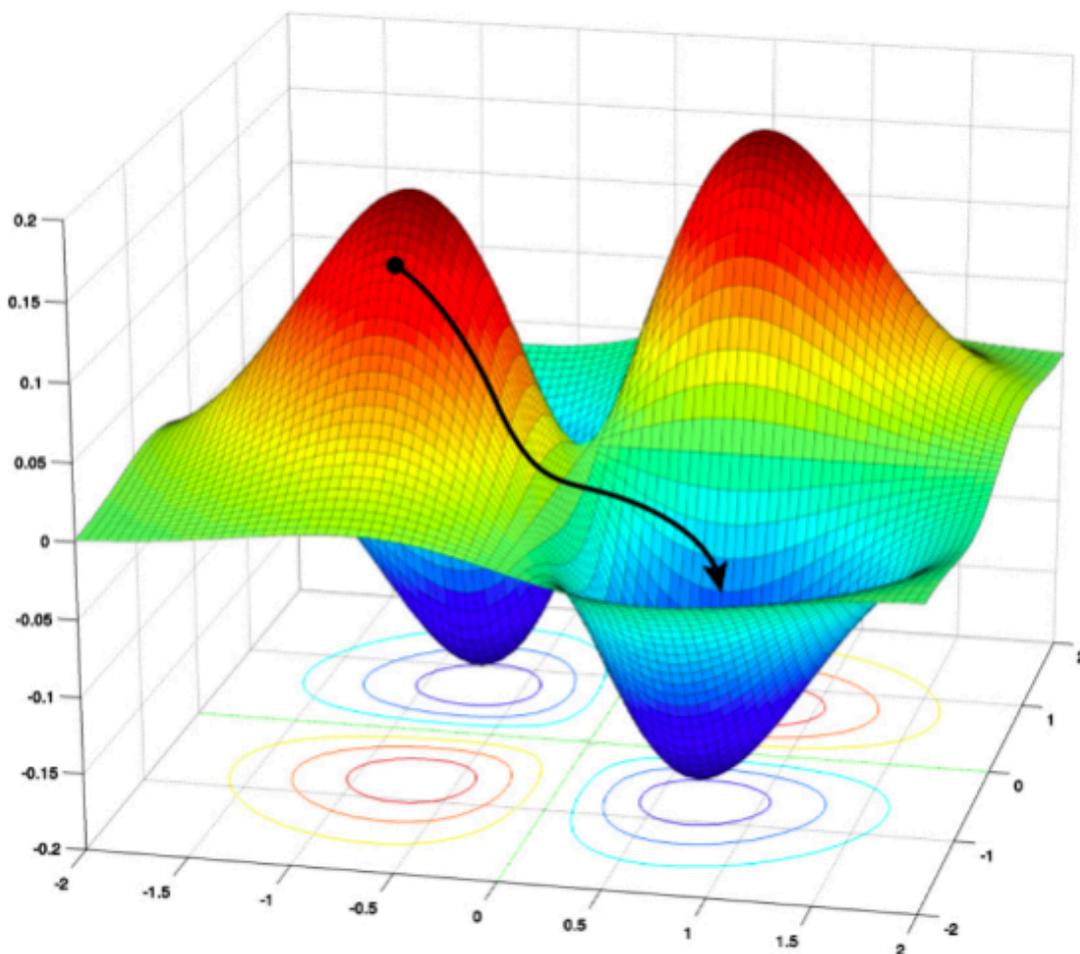


Figure 20 : représentation de la descente du gradient pour une fonction de perte à plusieurs variables [31]

c) Optimisation du modèle

Afin d'optimiser le modèle, différents algorithmes permettent d'affiner le taux d'apprentissage à chaque epoch. On retrouve comme optimiseur :

- Le momentum, un optimiseur qui permet que la variable (les poids ou les biais par exemple) pour laquelle le gradient varie le plus soit changé plus rapidement, tandis qu'une variable pour laquelle le gradient ne change pas ne subisse que de faibles variations.

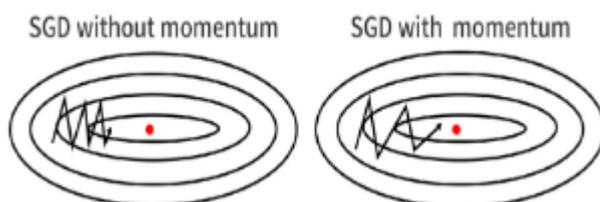


Figure 21 : représentation de la descente du gradient stochastique avec et sans l'optimiseur "momentum" [32]

- Adagrad est un optimiseur qui applique un facteur multiplicateur différent pour chaque variable au taux d'apprentissage. Cela a pour but d'entraîner une atténuation de la variabilité des paramètres qui sont trop vite mis à jour, et une augmentation de la variabilité des paramètres qui ne changent pas beaucoup. Cependant, la somme des gradients au carré est présente au dénominateur du facteur multiplicateur, ce qui peut entraîner une diminution drastique des taux d'apprentissage si celle-ci augmente rapidement, et donc entraîner l'arrêt de l'apprentissage du système. Des alternatives, telles que l'optimiseur Adam, existent aujourd'hui pour parer à ce problème potentiel.

3.2.3 Application à la lecture radiographique (exemples etc)

3.2.3.1 Composition et fonctionnement d'un réseau neuronal convolutif (RNC)

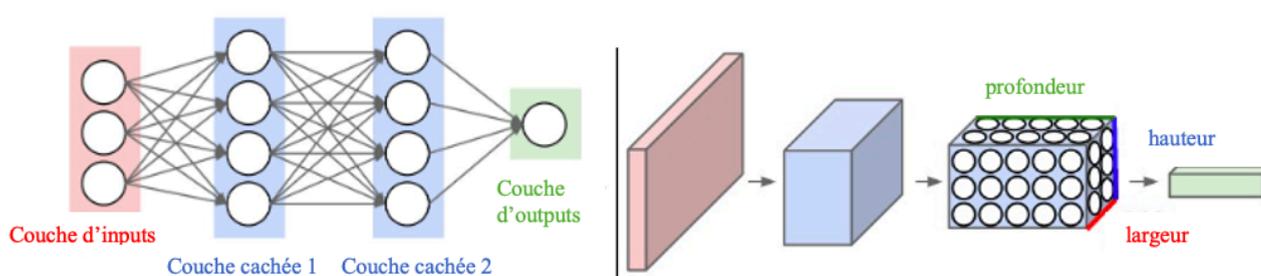
a) Architecture en couches de 3 dimensions du RNC

Dans le cas d'un algorithme de lecture radiographique, la couche d'inputs correspond à l'ensemble des pixels de l'image radiographique, et la couche d'outputs à l'ensemble des hypothèses formulées par le réseau neuronal, chacune d'elle étant associée à un pourcentage. Dans notre cas de lecture radiographique, l'output est donc un ensemble de probabilités associées aux pathologies traitées par le réseau (95% de probabilité de cardiomégalie, 5% de Pneumothorax... par exemple). Afin de

comprendre la mise au point d'un algorithme d'apprentissage profond dans ce contexte, il convient d'introduire la notion de réseau de neurones convolutif, très utilisé dans la reconnaissance d'images.

L'architecture d'un réseau de neurones convolutif est très similaire à l'architecture d'un réseau de neurones classiques, détaillée précédemment : on y retrouve les notions de couches de neurones, de poids, de biais, d'inputs, d'outputs, de fonction de perte, etc. Comme vu précédemment, l'input d'un tel réseau de neurones est l'ensemble des pixels de l'image étudiée. L'ensemble de données CIFAR-10 est une collections d'images couramment utilisée pour former de tels algorithmes, le format de ces images étant 32x32x3 (32 de hauteur, 32 de largeur, 3 couleurs par pixel : rouge, vert, bleu), donc un neurone unique de la première couche de neurones cachées, s'il est entièrement connecté, a 3072 poids associés aux connexions qu'il reçoit. Si le format de ces images peut encore être adapté à un réseau de neurones classiques, on se rend compte que le traitement de plus grandes images va vite entraîner le traitement d'un très grand nombre de paramètres et donc nécessiter une très grande puissance de calculs.

L'architecture d'un RNC est donc adaptée à la nature des inputs. Les couches d'un tel réseau sont des volumes de neurones en 3 dimensions. Les neurones de chaque couche vont ainsi être connectés à une petite partie de la couche précédente, au lieu d'une interconnexion complète.



Gauche : Organisation d'un réseau de neurones classique. Droite : un RNC organise ses neurones en 3 dimensions (largeur, hauteur et profondeur) comme visualisé sur l'une des couches cachées. Dans cet exemple, la couche d'input rouge contient l'image. Sa hauteur et sa largeur sont donc les dimensions de l'image et sa profondeur est de 3 (les canaux rouge, vert et bleu associés à chaque pixels).

Figure 22 : Organisation de couches du RNC en 3 dimensions adaptées au traitement d'images [29]

b) Types de couches au sein d'un RNC

Les types de couches de neurones principales au sein d'un RNC sont les suivantes :

- La couche d'inputs contient les valeurs associées aux trois canaux (rouge, vert et bleu) pour chaque pixel de l'image comme vu précédemment
- Les couches de convolution appliquent des filtres au sens photographique du terme à l'image.
- Les couches ReLU permettent d'accélérer l'apprentissage du RNC en se concentrant sur certains neurones par inactivation des autres (cf. figure 15), et permettent d'introduire la non-linéarité au modèle
- Les couches de pooling vont entraîner un sous-échantillonnage, c'est-à-dire réduire le nombre de pixels de l'image qu'ils reçoivent en entrée
- La couche dite entièrement connectée qui va prendre en compte toutes les valeurs de la couche précédente afin d'indiquer l'output désiré : les différentes pathologies envisagées avec le pourcentage de certitude correspondant à chacune d'elle par exemple

Nous allons nous intéresser plus en détails aux couches de convolutions et de pooling, propres aux réseaux de neurones convolutifs. En plus de l'image d'entrée, le fonctionnement d'une couche de convolution nécessite un filtre (également appelé noyau) qui est une matrice plus petite que l'image d'entrée. Ce noyau va alors parcourir l'image et effectuer un produit scalaire avec chaque portion de l'image de même taille, produisant un output en 2 dimensions (Cf. Figure 21).

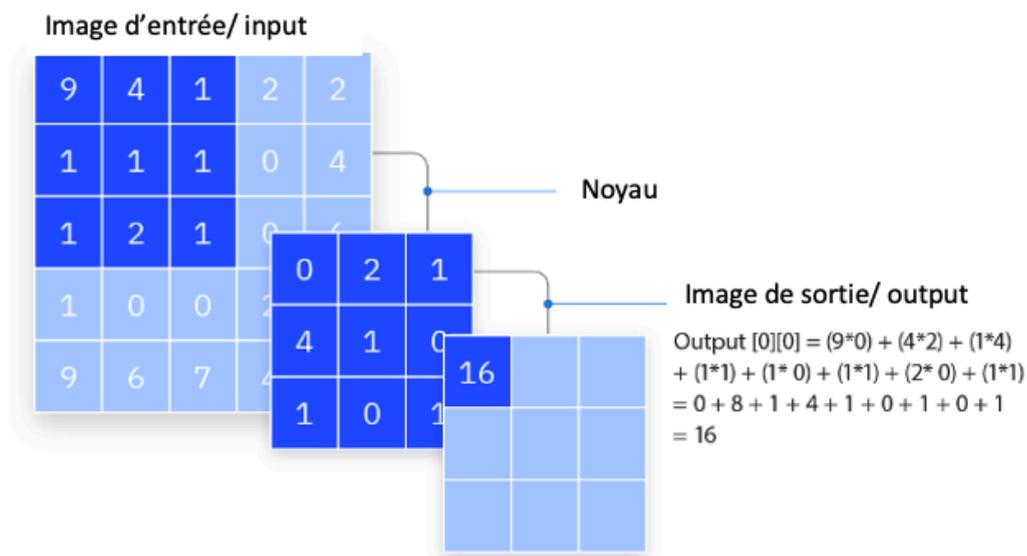


Figure 23 : fonctionnement d'une couche de convolution [33]. On notera qu'ici le cas d'une image bidimensionnelle est considérée, le fonctionnement est le même pour une image colorée, le noyau et l'image d'entrée seront alors aussi en 3 dimensions afin de prendre en compte les 3 canaux de pixels. L'output de la couche sera lui en 2 dimensions.

L'intérêt de la couche de convolution est que le noyau va être mis à jour par rétropropagation durant les phases d'entraînement de l'algorithme, et ainsi s'adapter aux images considérées. On remarque ainsi l'intérêt d'avoir des radiographies standardisées dans notre cas (cadrage et d'orientation), afin de développer des couches de convolutions adaptées à notre objectif.

L'output de la couche de convolution est donc d'un format inférieur à l'image d'entrée. Pour parer à cette réduction de la taille de l'image d'entrée, la méthode du zero-padding peut-être utilisée. Cela consiste à ajouter des valeurs nulles au-delà des bordures de l'image.

Durant l'entraînement, des filtres adaptés à la reconnaissance d'un élément visuel tel qu'un élément d'une couleur particulière, ou un pattern particulier, vont se développer. Dans un RNC, plusieurs couches de convolutions vont chacune permettre l'obtention de matrice en 2 dimensions. Celles-ci vont être stockées afin d'être prises en compte dans l'output du RNC.

La couche de pooling est un autre type de couche de neurones important et propre aux RNC. Comme nous l'avons vu, ces couches permettent de réduire la taille de l'image d'entrée. Au-delà de diminuer la puissance de calcul nécessaire, cela a notamment pour conséquence de parer au surapprentissage. Le surapprentissage se produit lorsque l'analyse de l'IA est trop adaptée au jeu de données d'entraînement, ce qui se fait au détriment de l'efficacité générale. Le average-pooling est une méthode, souvent utilisée, qui consiste à donner à chaque pixel de l'image de sortie la moyenne des valeurs de pixels voisins. Cependant, le max-pooling, plus efficace en pratique, est aujourd'hui plus répandu. Cette méthode consiste à conférer à chaque pixel la valeur maximale parmi celles de pixels voisins.

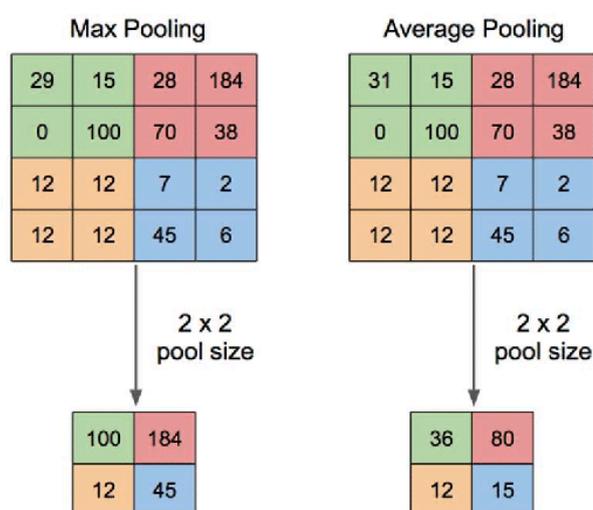


Figure 24 : Illustration du max-pooling et du average-pooling [34]

c) Analogie avec le cerveau humain

Les RNC sont souvent comparés au système visuel des primates, à juste titre. En premier lieu, l'analogie peut être faite d'un point de vue "comportemental". En effet, une étude de 2016 a montré que les RNC étaient capables d'une reconnaissance et d'une catégorisation de formes sensibles à des variations infimes, proches de la perception humaine. Les conclusions de l'étude allaient même jusqu'à établir la capacité de certains réseaux à se représenter correctement les formes dans l'espace [35]. Il convient toutefois de noter que les humains et les RNC font en général des erreurs de reconnaissance sur des images différentes, les RNC étant par exemple plus affectés par une qualité d'image dégradée (par du bruit numérique par exemple). [36]

Une correspondance au niveau structurel entre les réseaux de neurones convolutifs et le système visuel des primates peut également être établie. En effet, les interconnexions entre les neurones, ainsi que la transmission du signal de couche en couche rappelle le fonctionnement des voies neuronales. En outre, la comparaison reste pertinente lorsque l'on s'intéresse aux deux structures de plus près. Bien que l'information visuelle soit captée par les yeux, l'interprétation de ce qui a été vu est faite dans le cortex visuel primaire. Une étude menée par Hubel et Wiesel dans les années 1950 y a révélé la présence de deux types de cellules répondant aux stimuli visuels [37]. Les cellules simples, ou cellules S, s'activent pour reconnaître des formes simples, telles qu'une ligne droite, selon un angle spécifique et dans une région spécifique. Les cellules complexes, ou cellules C, ont des champs récepteurs plus larges et ne sont pas sensibles à la position de la forme reconnue dans leur champ visuel. Elles agissent comme une fonction non linéaire de plusieurs cellules S.

Au sein d'un RNC, de la même manière que les cellules S, les couches de convolution appliquent leur filtre localement, permettant la reconnaissance de formes simples, et de la même manière que les cellules C, les couches de pooling agissent à l'échelle de l'image entière, appliquant des mécanismes de translation et de rotation [38].

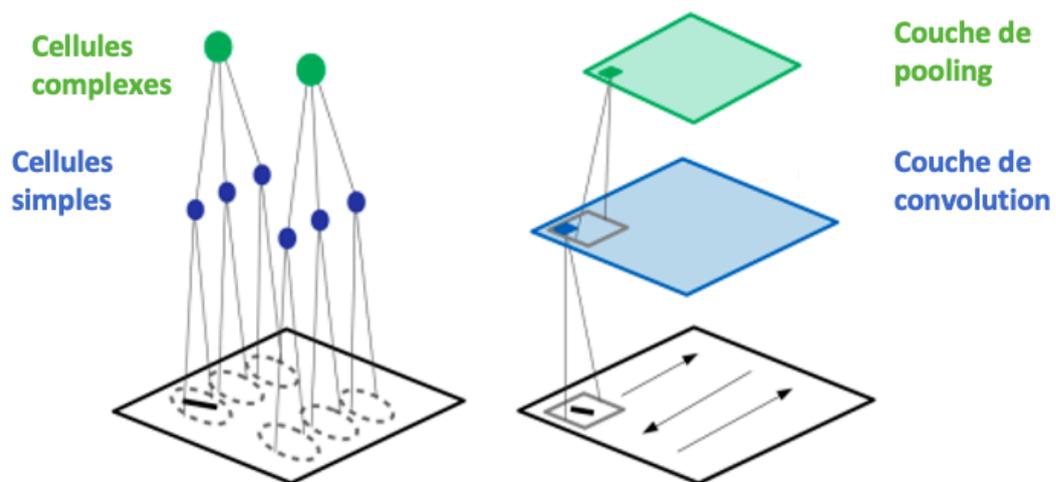


Figure 25 : Analogie entre le fonctionnement des cellules du complexe visuel primaire et un RNC [39]

3.2.3.2 Aperçu d'applications de RNC en imagerie médicale

En 1993, le premier RNC dédié à l'analyse d'images médicales est entraîné à détecter des nodules pulmonaires sur des radiographies thoraciques. [40] Cependant, le tournant dans l'utilisation du deep learning à cette fin est daté de 2012, lorsque les réseaux neuronaux ont surpassé les méthodes classiques de vision par ordinateur. Le "ImageNet Large Scale Visual Recognition Challenge" (ILSVRC) était un concours d'algorithmes de traitement d'images sur la base de données conséquentes d'ImageNet, très représentatif des progrès accomplis à cette période. Le graphe ci-dessous met en lumière l'amélioration des réseaux neuronaux dans les tâches de classification de ce concours depuis 2012.

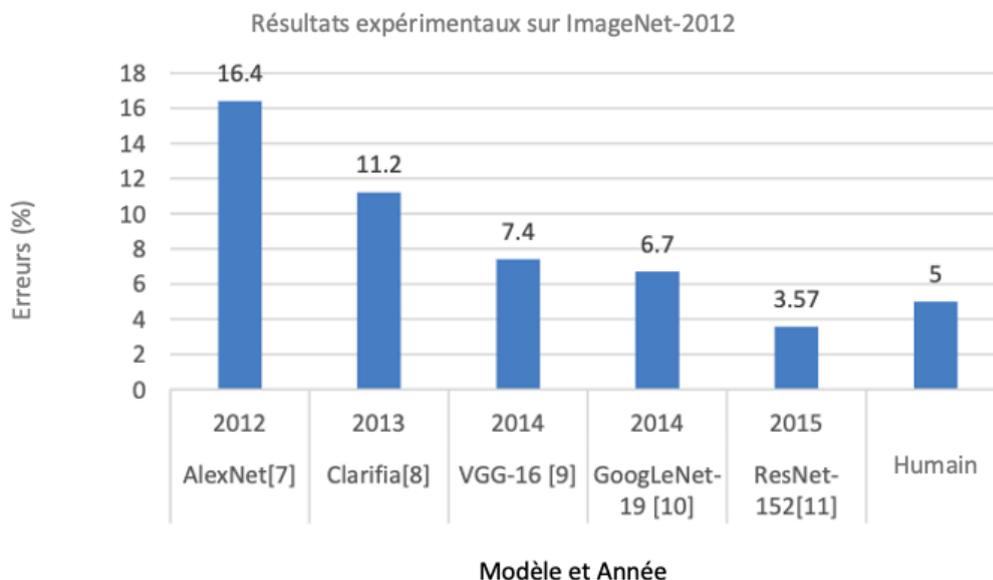


Figure 25 : Précision de différents modèles de deep learning au challenge ImageNet [41]

Les applications de l'apprentissage profond en imagerie médicale sont désormais trop nombreuses pour en faire une liste exhaustive. Les tâches accomplies par les RNC ne se limitent pas à la classification de pathologies et incluent aussi le débruitage, ou l'augmentation de contraste par exemple [42].

Voici quelques exemples d'études de cas ou d'applications de RNC dans différents champs de l'imagerie médicale :

- Un RNC a été entraîné afin de débruiter des images scanographiques, permettant ainsi de diminuer l'irradiation reçue par les patients en prenant des images à doses faibles [43].

- La segmentation d'images est une étape cruciale dans le diagnostic d'images par IRM. Cette étape consiste à la délimitation de l'image obtenue en différents tissus ou régions d'intérêt, et étant donné la quantité importante de données produites par un IRM, il est souvent impossible d'effectuer cette tâche manuellement dans un temps raisonnable. Pereira et al. ont présenté en 2016 une méthode de segmentation des tumeurs du cerveau à l'aide d'un RNC dans des images IRM [44].
- Gulshan et al. ont développé un algorithme d'apprentissage profond permettant d'identifier une rétinopathie diabétique à partir d'images de rétines [45].

3.3 Evaluation des performances d'un réseau neuronal de reconnaissance d'images [46]

Plusieurs paramètres permettent l'évaluation du réseau de neurones suite à l'entraînement. Dans les problèmes de classification, la matrice de confusion, ou tableau de contingence, permet d'avoir une représentation visuelle des performances du réseau ainsi que des informations sur le type d'erreur commise. Elle permet de confronter les prédictions du modèle à la réalité. Dans cette partie, ce que l'on désignera sous le terme de prédictions positives représente la classification d'une image dans une catégorie dans le contexte de la reconnaissance d'images. Ainsi, une radiographie d'occlusion digestive correspond ainsi à une prédiction positive dans notre cas, contrairement à une radiographie sans occlusion digestive. On remarquera que dans le cas de notre algorithme, l'output n'est pas binaire (occlusion digestive ou non) mais associée à une probabilité. Une prédiction positive est ainsi définie selon un seuil de probabilité, 0,5 par exemple, qui est souvent le choix par défaut.

		Prédictions	
		Positif	Négatif
Réalité	Positif	Vrai Positif	Faux Négatif
	Négatif	Faux Positif	Vrai Négatif

Figure 26 : Tableau de contingence. Ce tableau introduit les notions utilisées par la suite : un vrai positif est une classification correcte, un vrai négatif correspond à une image qui n'a pas été classée à raison (radiographie sans occlusion digestive qui n'a pas été classée dans la catégorie occlusion digestive), un faux positif correspond à une classification erronée (radiographie sans occlusion digestive classée comme radiographie d'occlusion par exemple), et un faux négatif correspond à un échantillon non classifié alors qu'il aurait dû l'être (radiographie d'occlusion non classée dans la catégorie d'occlusion digestive).

Ce tableau permet de définir trois paramètres communément utilisés dans l'évaluation des réseaux neuronaux :

- L'Accuracy représente une mesure directe de la capacité de l'algorithme à réaliser la tâche attendue. Soit VP le nombre de vrais positifs, VN le nombre de vrais négatifs, FP le nombre de faux positifs et FN le nombre de faux négatifs, on définit l'accuracy selon la formule suivante :

$$Accuracy = \frac{VP + VN}{VP + VN + FP + FN}$$

- La précision indique la justesse des précisions positives de l'algorithme, autrement dit dans le cas de la reconnaissance d'images, elle représente la proportion d'images classées dans une certaine catégorie qui y appartient réellement. On peut rapprocher ce paramètre de la spécificité d'un test diagnostique en médecine par exemple.

$$Précision = \frac{VP}{VP + FP}$$

- Le rappel, ou *recall* en anglais, désigne la capacité à détecter les données positives parmi l'ensemble des données positives. Dans le cas de la classification d'une radiographie comme porteuse d'une pathologie ou non,

elle représente ainsi le nombre de radiographies pathologiques détectées parmi l'ensemble des radiographies pathologiques. On peut rapprocher ce paramètre de la sensibilité d'un test diagnostique en médecine.

$$Rappel = \frac{VP}{VP + FN}$$

Afin d'avoir une représentation plus globale de l'efficacité du modèle, le score F1 peut être défini comme étant la moyenne harmonique de la précision et du rappel. Un autre paramètre utilisé à cette fin est l'aire sous la courbe précision-rappel (AUPRC).

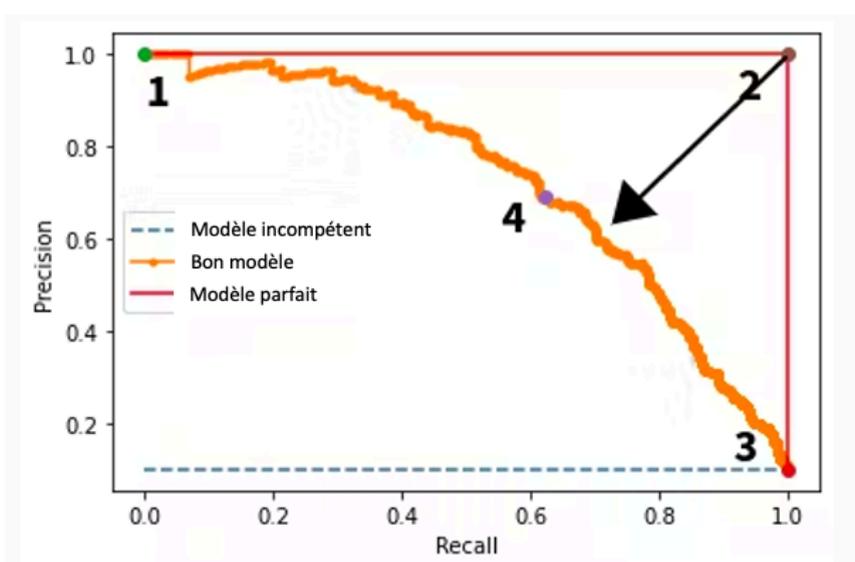


Figure 27 : Courbe Précision-Rappel

La courbe Précision-Rappel représente la capacité du modèle à être précis dans ses prédictions positives (c'est-à-dire à minimiser le nombre de faux positifs) tout en détectant efficacement les positifs réels (c'est-à-dire en minimisant le nombre de faux négatifs). Plus le modèle est efficace, plus la courbe s'approche du coin supérieur droit. Autrement dit, plus le modèle est efficace, plus l'aire sous la courbe précision-rappel (l'AUPRC) est proche de 1.

QUATRIÈME PARTIE : Exécution de l'apprentissage de réseau appliqué au diagnostic d'occlusion digestive chez le lapin

4.1 Caractéristiques du modèle utilisé [47]

Le modèle utilisé afin de mettre au point l'algorithme dédié au diagnostic d'occlusion digestive chez le lapin a été le "efficient_net_b2", développé par Pytorch en 2020. Ce réseau, de la famille des EfficientNet est un réseau convolutif adapté aux problèmes de classification.

La spécificité de cette famille de réseau réside dans la manière dont est fait le "scaling" des réseaux convolutifs. Cet anglicisme décrit la manière dont on va faire évoluer les réseaux afin de répondre à nos objectifs. En général, le développement d'un réseau de neurones convolutif va être mené avec un budget limité, puis va être mis à l'échelle (scale-up) afin d'être adapté au traitement de plus grandes bases de données. On peut agir sur trois dimensions pour procéder à cette mise à l'échelle : la profondeur du réseau, sa largeur ou la résolution de l'image. Il est commun de mener le processus sur l'une de ces trois dimensions, mais la particularité de la famille EfficientNet est que le "scaling" est fait uniformément sur les trois dimensions à l'aide d'un coefficient composé.

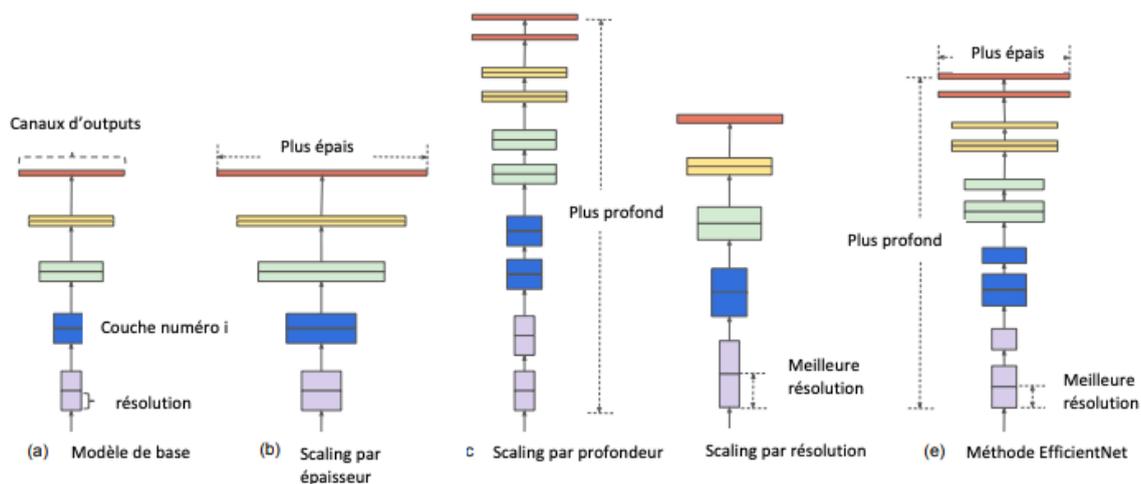


Figure 28 : Méthodes de scaling [47]

Cette méthode a permis la mise au point de réseaux très performants, notamment testé sur la base de données ImageNet évoqué plus tôt, avec une

accuracy de 84,3% pour le réseau EfficientNet-B7, tout en étant 8,4 fois plus petit et 6,1 fois plus rapide que l'ancien réseau de neurones convolutif le plus performant.

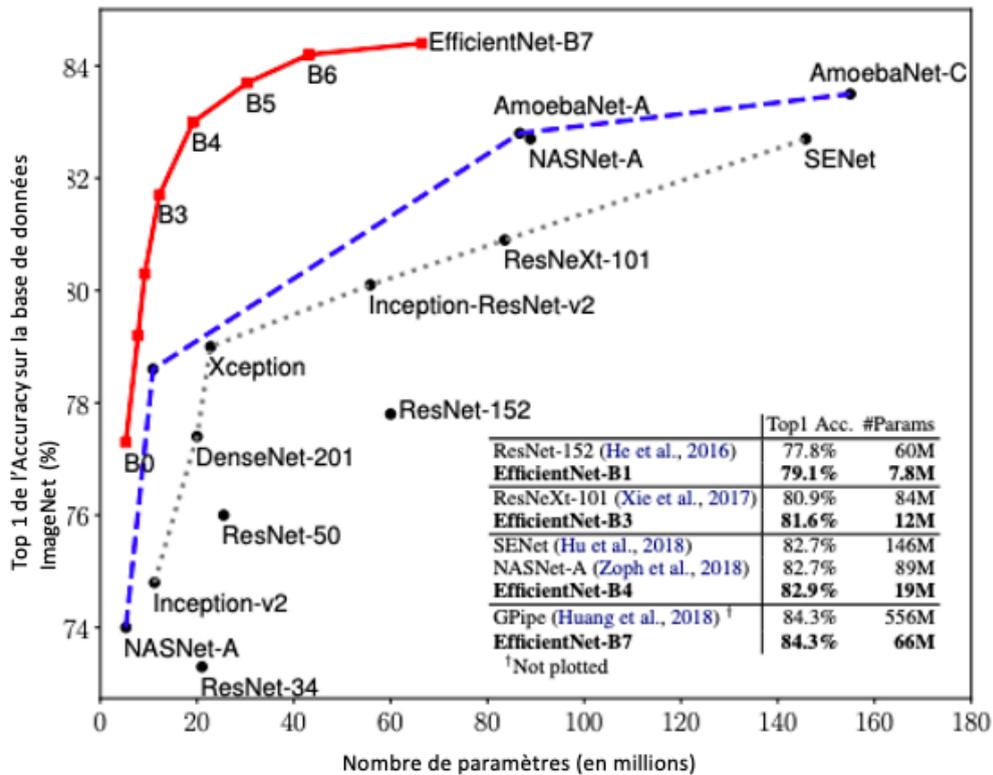


Figure 29 : Accuracy de modèles sur la base de données ImageNet en fonction de leur taille [47]

Pour comprendre les décisions prises par un réseau neuronal convolutif, les “Class Activation Map” (CAM) sont utilisées. Ces dernières permettent de souligner les régions de l'image qui vont influencer les prédictions du modèle, et ainsi d'évaluer la pertinence de ce dernier à classer une image.

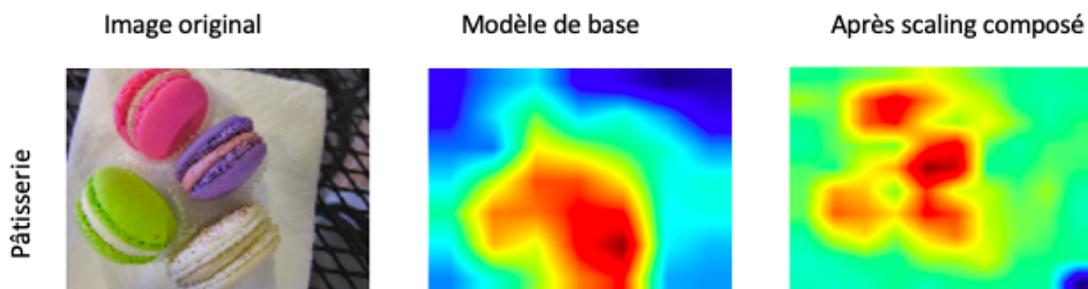


Figure 30 : CAM du modèle EfficientNet après la méthode de scaling composé. Le modèle permet à l'algorithmme de se concentrer sur des régions plus pertinentes contenant les détails des objets considérés.

4.2 Annotation binaire des radiographies

4.2.1 Base de données initiale

Les radiographies abdominales de lapin utilisées pour l'entraînement sont issues des cliniques et cabinets vétérinaires clients de Picoxia. J'ai annoté 775 radiographies, 332 d'entre elles étaient prises en incidence ventro-dorsale, et 443 en incidence latérale.

4.2.2 Méthode d'annotation

La méthode d'annotation a consisté à classer les radiographies en 3 catégories : "radiographie d'occlusion digestive", "radiographie douteuse", et "radiographie sans occlusion digestive". Les radiographies dites douteuses étaient ensuite exclues de l'entraînement, l'algorithme ayant besoin de certitude.

Dans un premier temps, le réseau a été entraîné avec les images originales et les labels que je leur avais associés. Dans un second temps, le réseau a été entraîné avec les mêmes radiographies, recadrées et orientées selon les conventions radiologiques.

4.2.3 Critères d'annotation

Les critères d'annotation utilisés ont été détaillés précédemment et proviennent essentiellement de l'étude réalisée en 2019 par Debenham et al. [16], et discutés avec mon directeur de thèse Fabrice CONCHOU.

Dans un premier temps, la nature de l'ingesta et la taille de l'estomac étaient considérées. Ce second critère est évalué par comparaison entre l'extension caudale de l'organe et l'extension caudale de L2, et en considérant l'existence ou non d'un contact direct entre la paroi gastrique et l'abdomen ventral. Ces paramètres étant spécifiques, ils permettent d'orienter fortement le diagnostic vers l'occlusion, et sont renforcés par la dilatation des anses digestives de l'intestin grêle et l'absence de gaz dans le cæcum. En cas de doute, lorsque les critères ne convergent pas vers la même hypothèse, la somme de la longueur et de la largeur gastrique comparée à la longueur L1-articulation coxo-fémorale est considérée. Lorsqu'un critère très spécifique (concernant la nature de l'ingesta ou l'extension caudale de l'estomac)

n'est pas associée à ce critère fortement sensible, la radiographie était considérée comme douteuse.

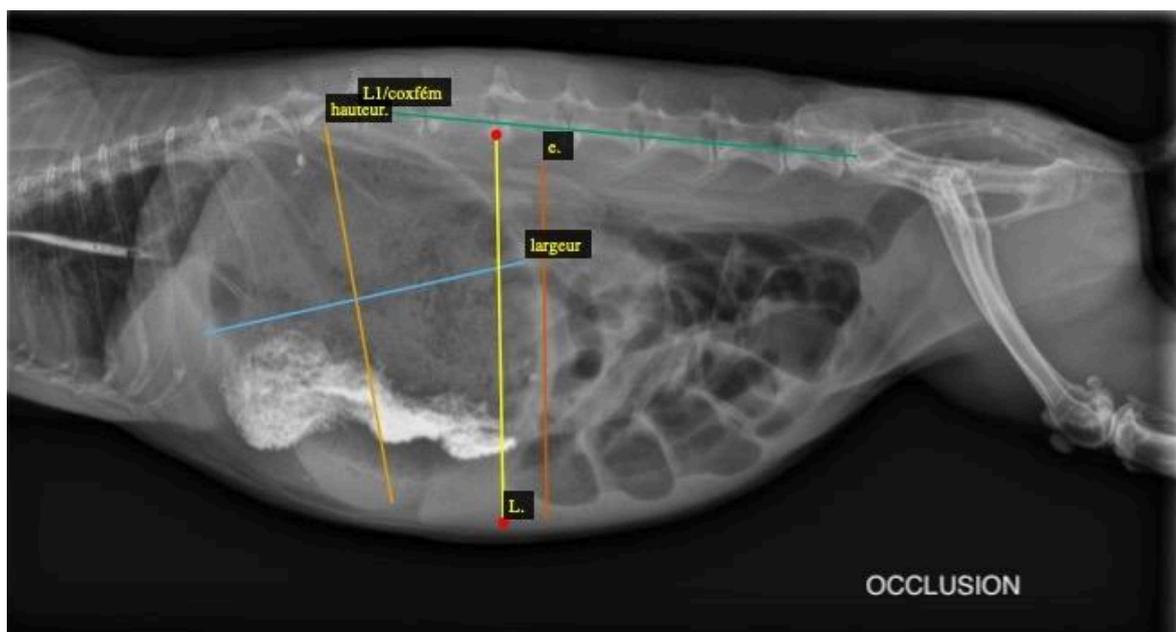


Figure 31 : Exemple de radiographie annotée afin d'établir ou non le diagnostic d'occlusion

J'ai effectué les mesures avec le logiciel Gimp (les mesures sont obtenues en nombre de pixels).

4.2.4 Pool final d'apprentissage

Au total, 34 des images ont été écartées du pool, le diagnostic étant incertain. Parmi les 741 radiographies ainsi utilisées, 80% ont été utilisées pour entraîner le modèle, soit 593, et 20% pour le tester, soit 148.

4.3 Evaluation de l'algorithme mis en place et analyse des résultats

4.3.1 Evaluation de l'algorithme mis en place avec les radiographies non recadrées

Le meilleur réseau entraîné de l'algorithme avec des images non recadrées a été obtenu au bout du 36^{ème} cycle d'apprentissage.

Métrique	Valeur
Accuracy	0.937
Précision	0.967
Rappel	0.906
AUPRC	0.963
Score F1	0.935

Figure 32 : Métriques d'évaluation du meilleur réseau entraîné avec des images non recadrées

Le réseau peut être considéré comme performant puisque l'AUPRC est supérieur à 0,50. Cependant, cela n'est pas suffisant pour envisager une utilisation commerciale, les exigences du laboratoire étant alors de 0,87 pour l'AUPRC (condition remplie) mais de 0,95 pour le rappel. En effet, l'objectif est de minimiser le nombre de faux négatifs, puisque c'est le cas qui poserait le plus de problèmes : l'affection étant grave, une sous-estimation du nombre de cas pourrait avoir des conséquences délétères sans prise en charge d'individus malades.

4.3.2 Evaluation de l'algorithme mis en place avec les radiographies recadrées

Le meilleur réseau entraîné de l'algorithme avec des images non recadrées a été obtenu au bout du 31^{ème} cycle d'apprentissage.

Métrique	Valeur
Accuracy	0.968
Précision	0.969
Rappel	0.969
AUPRC	0.978
Score F1	0.969

Figure 33 : Métriques d'évaluation du meilleur réseau entraîné avec des images recadrées

Le réseau peut être considéré comme performant puisque l'AUPRC est supérieur à 0,50. De plus, les valeurs des métriques permettent d'envisager une utilisation

commerciale, l'AUPRC étant supérieur à 0,87 et le rappel à 0,95. Cependant, il convient d'évaluer le modèle avec d'autres données que celle du pool d'apprentissage.

4.3.3 Comparaison des deux réseaux obtenus

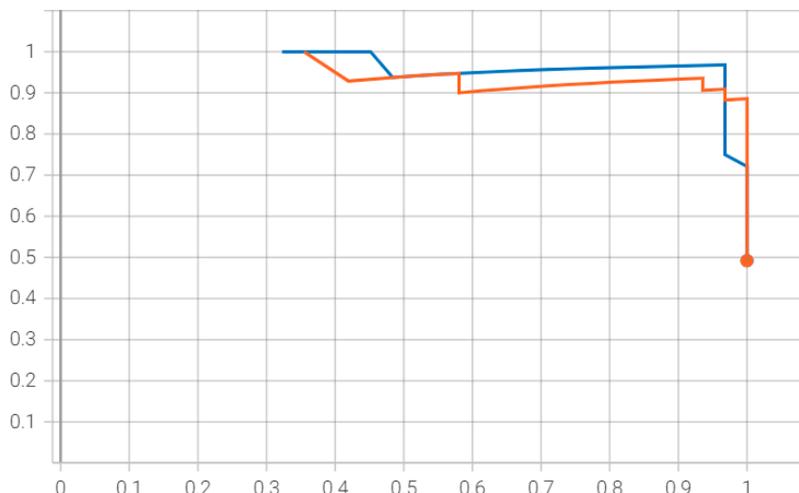


Figure 34 : Courbes précision-rappel pour les deux algorithmes mis au point. Le réseau entraîné avec les images non recadrées est en orange. Le réseau entraîné avec les images recadrées est en bleu.

Le recadrage des images a permis une nette amélioration du réseau entraîné, ce qui est évident lorsqu'on considère le fonctionnement des réseaux de neurones de convolution. En effet l'application de filtres via les couches de convolution peut ainsi être adaptée au mieux à l'objectif avec des images standardisées (cf 3.2.3.1.b.).

4.4 Discussion et limites

L'une des principales limites de l'étude est liée à l'expérience de l'opérateur. Bien que j'ai établie au préalable avec Fabrice CONCHOU les critères d'annotation de l'occlusion digestive, mon expérience en lecture radiographique reste limitée et une annotation par des vétérinaires spécialistes en imagerie aurait été préférable. De plus, l'évaluation du modèle sur la même base de données que celle d'entraînement ne permet pas d'estimer la qualité effective de l'algorithme, et un risque de surapprentissage par exemple n'est pas exclu (cf 3.2.3.1.b.).

Une autre limite de l'étude concerne la qualité des clichés radiographiques. En effet, la base de données est un ensemble de radiographies prises par des vétérinaires praticiens et issus de cabinets clients de Picoxia, ce qui entraîne une

grande variabilité sur la qualité des clichés, que ce soit concernant le positionnement de l'animal, les constantes d'exposition, le cadrage des clichés, etc. Les images considérées comme les plus difficiles à analyser, due à une mauvaise qualité du cliché radiographique ont ainsi été exclues du pool d'apprentissage, et cette variabilité reste nécessaire pour envisager une accessibilité de l'algorithme aux vétérinaires praticiens, qui n'ont pas forcément le temps, le matériel ou les moyens de contention nécessaires pour effectuer des radiographies de bonne qualité. Cependant des erreurs d'annotation ont pu être entraînées par la mauvaise qualité de certains clichés.

Afin d'améliorer le modèle, en plus de faire appel à des spécialistes pour les annotations, il pourrait être intéressant de constituer un pool plus conséquent de radiographies, puis d'évaluer le réseau en dehors de sa base de données d'entraînement.

CONCLUSION

L'objectif de cette thèse était la mise au point d'un algorithme dédié au diagnostic radiographique de l'occlusion digestive chez le lapin.

Ainsi, 775 radiographies, provenant de cabinets vétérinaires clients de PicoxIA, ont été étiquetées en trois catégories : les radiographies de patients en occlusion digestive, les radiographies dont le diagnostic n'était pas certain (dites douteuses), et les radiographies de patients sans occlusion digestive.

Le modèle "efficient_net_b2" a été retenu, sa méthode innovante de mise à l'échelle du réseau lui ayant permis d'atteindre des performances remarquables concernant les problèmes de classification.

L'entraînement d'un réseau de neurones convolutif a été effectué en premier lieu sur les radiographies non recadrées, à l'exception des radiographies douteuses. Les métriques d'évaluation de ce modèle (précision, rappel et AUPRC) ne permettaient pas d'envisager une utilisation commerciale. Il a alors été décidé de recadrer les radiographies afin d'obtenir une base de données plus standardisée.

Le second réseau de neurones convolutif, entraîné avec des radiographies recadrées, était plus performant que le premier, et son évaluation permettait d'envisager une utilisation commerciale. La prochaine étape sera de constater son efficacité en dehors de la base de données d'entraînement, afin de s'assurer de son utilité en pratique.

Le développement de tels outils diagnostiques, intégrant l'intelligence artificielle, entraîne une évolution du rôle du vétérinaire. Comme cette thèse le montre, l'expertise du vétérinaire reste précieuse puisqu'elle peut concourir à l'élaboration de tels algorithmes.

Au-delà de ces nouvelles perspectives au sein de la profession, le nombre croissant d'aides au diagnostic du praticien permet d'accorder une plus grande place à la gestion personnalisée de l'animal et du propriétaire. Le temps gagné par un algorithme de lecture radiographique peut ainsi être utilisé pour réfléchir à la prise en charge thérapeutique et aux discours les plus adaptés, en prenant en compte les attentes du propriétaire, les potentielles contraintes financières, et le bien-être du patient, et donc de valoriser la nature humaine du vétérinaire.

Références bibliographiques

- [1] KAUL, Vivek, ENSLIN, Sarah et GROSS, Seth A., 2020. History of artificial intelligence in medicine. *Gastrointestinal Endoscopy*. 1 octobre 2020. Vol. 92, n° 4, pp. 807-812. DOI [10.1016/j.gie.2020.06.040](https://doi.org/10.1016/j.gie.2020.06.040).
- [2] INTELLIGENCE : Définition de INTELLIGENCE, Centre National de Ressources Textuelles et Lexicales [sans date] [en ligne]. Disponible à l'adresse : <https://www.cnrtl.fr/definition/intelligence> [Consulté le 22 août 2024].
- [3] WEISS, Sholom, KULIKOWSKI, Casimir A. et SAFIR, Aran, 1978. Glaucoma consultation by computer. *Computers in Biology and Medicine*. 1 janvier 1978. Vol. 8, n° 1, pp. 25-40. DOI [10.1016/0010-4825\(78\)90011-2](https://doi.org/10.1016/0010-4825(78)90011-2).
- [4] FERRUCCI, David, LEVAS, Anthony, BAGCHI, Sugato, GONDEK, David et MUELLER, Erik T., 2013. Watson: Beyond Jeopardy! *Artificial Intelligence*. 1 juin 2013. Vol. 199-200, pp. 93-105. DOI [10.1016/j.artint.2012.06.009](https://doi.org/10.1016/j.artint.2012.06.009).
- [5] MONEGAIN, Bernie. IBM Watson pinpoints rare form of leukemia after doctors misdiagnosed patient. *Healthcare IT News* [en ligne]. 8 août 2016. Disponible à l'adresse : <https://www.healthcareitnews.com/news/ibm-watson-pinpoints-rare-form-leukemia-after-doctors-misdiagnosed-patient> [Consulté le 22 août 2024].
- [6] LUXTON, David D., 2019. Should Watson Be Consulted for a Second Opinion? *AMA Journal of Ethics*. 1 février 2019. Vol. 21, n° 2, pp. 131-137. DOI [10.1001/amajethics.2019.131](https://doi.org/10.1001/amajethics.2019.131).
- [7] RAJPURKAR, Pranav et al., 2018. Deep learning for chest radiograph diagnosis: A retrospective comparison of the CheXNeXt algorithm to practicing radiologists. *PLOS Medicine*. 20 novembre 2018. Vol. 15, n° 11, pp. e1002686. DOI [10.1371/journal.pmed.1002686](https://doi.org/10.1371/journal.pmed.1002686).
- [8] BUSHBERG, Jerrold T. et al. 2012, The Essential Physics of Medical Imaging. Third edition. Philadelphia : Wolters Kluwer Health / Lippincott Williams & Wilkins, 2012. ISBN : 978- 0-7817-8057-5.
- [9] CEA, Commissariat à l'énergie atomique et aux énergies alternatives, 2015, L'homme et les rayonnements [en ligne]. Disponible sur : <https://www.cea.fr/comprendre/Pages/radioactivite/homme-rayonnements.aspx?Type>

- [17] OGLESBEE, Barbara L. et LORD, Brigitte, 2020. Gastrointestinal Diseases of Rabbits. *Ferrets, Rabbits, and Rodents*. 2020. pp. 174. DOI [10.1016/B978-0-323-48435-0.00014-9](https://doi.org/10.1016/B978-0-323-48435-0.00014-9).
- [18] HARCOURT-BROWN, F. M., 2013. Gastric dilation and intestinal obstruction. In: *BSAVA Manual of Rabbit Surgery, Dentistry and Imaging*. Eds F. Harcourt-Brown and J. Chitty. British Small Animal Veterinary Association, Gloucester, UK. pp 172-189, ISBN: 978-1-905-31941-1, Disponible sur doi:10.22233/9781910443163.14
- [19] SCHUHMANN, B. et COPE, I., 2014. Medical treatment of 145 cases of gastric dilatation in rabbits. *Veterinary Record*. novembre 2014. Vol. 175, n° 19, pp. 484-484. DOI [10.1136/vr.102491](https://doi.org/10.1136/vr.102491).
- [20] HARCOURT-BROWN, F. M. et HARCOURT-BROWN, S.F., 2012. Clinical value of blood glucose measurement in pet rabbits. *Veterinary Record/ The Veterinary Record* [en ligne]. 1 juin 2012. Vol. 170, n° 26, pp. 674. DOI [10.1136/vr.100321](https://doi.org/10.1136/vr.100321).
- [21] BÖTTCHER, Anja et MÜLLER, Kerstin, 2024. Radiological and laboratory prognostic parameters for gastric dilation in rabbits (*Oryctolagus cuniculus*). *Veterinary Record*. 2024. Vol. 194, n° 5, pp. e3827. DOI [10.1002/vetr.3827](https://doi.org/10.1002/vetr.3827).
- [22] AIHLEG, 2019, A definition of Artificial Intelligence : main capabilities and scientific disciplines. Disponible depuis l'adresse <https://digital-strategy.ec.europa.eu/en/library/definition-artificial-intelligence-main-capabilities-and-scientific-disciplines> [Consulté le 19 août 2024].
- [23] HERNANDEZ, Annalisa M., BILBROUGH, Graham E. A., DENICOLA, Dennis B., MYRICK, Celine, EDWARDS, Suzanne, HAMMOND, Jeremy M., MYERS, Alex N., HESELTINE, Johanna C., RUSSELL, Karen, GIRALDI, Marco et NABITY, Mary B., 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*. janvier 2019. Vol. 33, n° 1, pp. 167-177. DOI [10.1111/jvim.15341](https://doi.org/10.1111/jvim.15341).
- [24] Apprentissage profond (deep learning). *CNIL* [en ligne]. [sans date] [consulté le 28 août 2024]. Disponible sur : <https://www.cnil.fr/fr/definition/apprentissage-profond-deep-learning>
- [25] VANCAPPEL, Kévin. Machine Learning : comprendre ce qu'est un réseau de neurones et en créer un ! *Business & Decision* [en ligne]. 10 Novembre 2020

[consulté le 28 août 2024]. Disponible sur :
<https://fr.blog.businessdecision.com/tutoriel-machine-learning-comprendre-ce-quest-un-reseau-de-neurones-et-en-creer-un/>

[26] SZANDAŁA, Tomasz, 2021. Review and Comparison of Commonly Used Activation Functions for Deep Neural Networks. In : BHOI, Akash Kumar, MALLICK, Pradeep Kumar, LIU, Chuan-Ming et BALAS, Valentina E. (éd.), *Bio-inspired Neurocomputing* [en ligne]. Singapore : Springer Singapore. pp. 203-224. Studies in Computational Intelligence. ISBN 9789811554940. [Consulté le 28 août 2024].

[27] What is the "dead ReLU" problem and, why is it an issue in Neural Network training ? *AIML.com* [en ligne]. 22 juillet 2024 [consulté le 28 août 2024]. Disponible sur :
<https://aiml.com/what-is-dying-relu-or-dead-relu-and-why-is-this-a-problem-in-neural-network-training/>

[28] MAURICE, Bastien. Fonction d'activation - Deeply Learning. *Deeply Learning* [en ligne]. 26 Septembre 2018 [consulté le 28 août 2024]. Disponible sur :
<https://deeplylearning.fr/cours-theoriques-deep-learning/fonction-dactivation/>

[29] Fei-Fei, Li et al. 2024, Convolutional Neural Networks for Visual Recognition, Stanford

[30] TORRES-VELÁZQUEZ, Maribel, CHEN, Wei-Jie, LI, Xue et MCMILLAN, Alan B., 2021. Application and Construction of Deep Learning Networks in Medical Imaging. *IEEE transactions on radiation and plasma medical sciences*. mars 2021. Vol. 5, n° 2, pp. 137-159. DOI [10.1109/trpms.2020.3030611](https://doi.org/10.1109/trpms.2020.3030611).

[31] ANANTHASWAMY, Anil, 2022. Researchers Build AI That Builds AI. *Quanta Magazine* [en ligne]. 25 janvier 2022. Disponible à l'adresse :
<https://www.quantamagazine.org/researchers-build-ai-that-builds-ai-20220125/>
[Consulté le 30 août 2024].

[32] DU, Juan, 2019. The Frontier of SGD and Its Variants in Machine Learning. *Journal of Physics: Conference Series*. 1 mai 2019. Vol. 1229, pp. 012046. DOI [10.1088/1742-6596/1229/1/012046](https://doi.org/10.1088/1742-6596/1229/1/012046).

[33] What are convolutional neural networks ? IBM [en ligne]. [sans date] [consulté le 3 Septembre 2024] Disponible sur :
<https://www.ibm.com/topics/convolutional-neural-networks>

- [34] YANI, Muhamad, S, M.T. Budhi Irawan, Si. et S.T., M.T. Casi Setiningsih, 2019. Application of Transfer Learning Using Convolutional Neural Network Method for Early Detection of Terry's Nail. *Journal of Physics: Conference Series*. mai 2019. Vol. 1201, n° 1, pp. 012052. DOI [10.1088/1742-6596/1201/1/012052](https://doi.org/10.1088/1742-6596/1201/1/012052).
- [35] KUBILIUS, Jonas, BRACCI, Stefania et OP DE BEECK, Hans P., 2016. Deep Neural Networks as a Computational Model for Human Shape Sensitivity. *PLoS Computational Biology*. 28 avril 2016. Vol. 12, n° 4, pp. e1004896. DOI [10.1371/journal.pcbi.1004896](https://doi.org/10.1371/journal.pcbi.1004896).
- [36] CELEGHIN, Alessia, BORRIERO, Alessio, ORSENIGO, Davide, DIANO, Matteo, MÉNDEZ GUERRERO, Carlos Andrés, PEROTTI, Alan, PETRI, Giovanni et TAMIETTO, Marco, 2023. Convolutional neural networks for vision neuroscience: significance, developments, and outstanding issues. *Frontiers in Computational Neuroscience*. 6 juillet 2023. Vol. 17, pp. 1153572. DOI [10.3389/fncom.2023.1153572](https://doi.org/10.3389/fncom.2023.1153572).
- [37] WURTZ, Robert H, 2009. Recounting the impact of Hubel and Wiesel. *The Journal of Physiology*. 15 juin 2009. Vol. 587, n° Pt 12, pp. 2817-2823. DOI [10.1113/jphysiol.2009.170209](https://doi.org/10.1113/jphysiol.2009.170209).
- [38] OKTAR, Yigit, ULUCAN, Diclehan, ULUCAN, Oguzhan et TURKAN, Mehmet, 2019. *Convolutional Neural Networks: A Binocular Vision Perspective*. DOI 10.48550/arXiv.1912.10201
- [39] LINDSAY, Grace W., 2021. Convolutional Neural Networks as a Model of the Visual System: Past, Present, and Future. *Journal of Cognitive Neuroscience*. 1 septembre 2021. Vol. 33, n° 10, pp. 2017-2031. DOI [10.1162/jocn_a_01544](https://doi.org/10.1162/jocn_a_01544).
- [40] Lo, Shih-Chung & Chan, Heang-Ping & Lin, Jyh-Shyan & Li, Huai & Freedman, Matthew & Mun, Seong. (1995). Artificial convolution neural network for medical image pattern recognition. *Neural Networks*. 8. 1201-1214. DOI [10.1016/0893-6080\(95\)00061-5](https://doi.org/10.1016/0893-6080(95)00061-5).
- [41] ALOM, Zahangir, TAHA, Tarek M, YAKOPCIC, Chris, WESTBERG, Stefan, SIDIKE, Paheding et NASRIN, Mst Shamima, 2018. The History Began from AlexNet: A Comprehensive Survey on Deep Learning Approaches. DOI 10.48550/arXiv.1803.01164

- [42] RAHMAN, Tawsifur, KHANDAKAR, Amith, QIBLAWEY, Yazan, TAHIR, Anas, KIRANYAZ, Serkan, ABUL KASHEM, Saad Bin, ISLAM, Mohammad Tariqul, AL MAADEED, Somaya, ZUGHAIER, Susu M., KHAN, Muhammad Salman et CHOWDHURY, Muhammad E.H., 2021. Exploring the effect of image enhancement techniques on COVID-19 detection using chest X-ray images. *Computers in Biology and Medicine*. mai 2021. Vol. 132, pp. 104319. DOI [10.1016/j.compbimed.2021.104319](https://doi.org/10.1016/j.compbimed.2021.104319).
- [43] LI, Meng, HSU, William, XIE, Xiaodong, CONG, Jason et GAO, Wen, 2020. SACNN: Self-Attention Convolutional Neural Network for Low-Dose CT Denoising With Self-Supervised Perceptual Loss Network. *IEEE transactions on medical imaging*. juillet 2020. Vol. 39, n° 7, pp. 2289-2301. DOI [10.1109/TMI.2020.2968472](https://doi.org/10.1109/TMI.2020.2968472).
- [44] PEREIRA, Sergio, PINTO, Adriano, ALVES, Victor et SILVA, Carlos A., 2016. Brain Tumor Segmentation Using Convolutional Neural Networks in MRI Images. *IEEE transactions on medical imaging*. mai 2016. Vol. 35, n° 5, pp. 1240-1251. DOI [10.1109/TMI.2016.2538465](https://doi.org/10.1109/TMI.2016.2538465).
- [45] GULSHAN, Varun, PENG, Lily, CORAM, Marc, STUMPE, Martin C., WU, Derek, NARAYANASWAMY, Arunachalam, VENUGOPALAN, Subhashini, WIDNER, Kasumi, MADAMS, Tom, CUADROS, Jorge, KIM, Ramasamy, RAMAN, Rajiv, NELSON, Philip C., MEGA, Jessica L. et WEBSTER, Dale R., 2016. Development and Validation of a Deep Learning Algorithm for Detection of Diabetic Retinopathy in Retinal Fundus Photographs. *JAMA*. 13 décembre 2016. Vol. 316, n° 22, pp. 2402-2410. DOI [10.1001/jama.2016.17216](https://doi.org/10.1001/jama.2016.17216).
- [46] Accuracy vs. Precision vs. Recall in Machine Learning: What is the Difference?, [sans date]. [en ligne]. Disponible à l'adresse : <https://encord.com/blog/classification-metrics-accuracy-precision-recall/> [Consulté le 10 septembre 2024].
- [47] TAN, Mingxing et LE, Quoc V., 2019. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. International Conference on Machine Learning, 2019 DOI [10.48550/arXiv.1905.11946](https://doi.org/10.48550/arXiv.1905.11946)

Validate metric	DataLoader 0
val/accuracy	0.9682539701461792
val/auprc	0.9775874614715576
val/f1score_0	0.96875
val/loss_epoch	0.22964145243167877
val/npv	0.9677419066429138
val/precision_0	0.96875
val/ppv	0.9677419066429138
val/recall_0	0.96875

ANNEXE 1 : Ensemble des métriques d'évaluation du réseau entraîné avec les images recadrées

Validate metric	DataLoader 0
val/accuracy	0.9365079402923584
val/auprc	0.9632867574691772
val/f1score_0	0.9354838132858276
val/loss_epoch	0.3248501420021057
val/npv	0.9090909361839294
val/precision_0	0.9666666388511658
val/ppv	0.9090909361839294
val/recall_0	0.90625

ANNEXE 2 : Ensemble des métriques d'évaluation du réseau entraîné avec les images non recadrées

Mise au point d'un algorithme de Deep Learning dédié au diagnostic radiographique de l'occlusion digestive chez le lapin

PIEDRA Benjamin

L'occlusion intestinale correspond à une diminution de la taille de la lumière intestinale, qu'elle qu'en soit la cause. Il est particulièrement intéressant de pouvoir diagnostiquer rapidement les occlusions digestives chez le lapin puisque ce sont des affections aiguës qui engagent le pronostic vital de l'animal. La radiographie est un examen particulièrement évocateur, bien que le seul moyen de confirmer le diagnostic soit l'évaluation post-mortem et la chirurgie. L'objectif de cette thèse est de développer un algorithme d'apprentissage profond dédié au diagnostic radiographique de l'occlusion digestive chez le lapin, en collaboration avec PicoxIA.

741 radiographies de lapin, étiquetées de façon binaire (présence d'une occlusion digestive ou non), ont permis d'entraîner un réseau de neurones convolutif. Les radiographies ont toutes été recadrées afin de standardiser la base de données, et de permettre un meilleur apprentissage du réseau. Le réseau finalement obtenu a présenté des performances satisfaisantes, permettant d'envisager une utilisation commerciale, avec une AUPRC de 0.963, et un rappel de 0.969.

Mots-clés : Imagerie diagnostic - Radiographie - Intelligence Artificielle - Occlusion intestinale - Lapins

Development of a deep-learning algorithm dedicated to the radiographic diagnosis of intestinal obstruction in rabbits

PIEDRA Benjamin

Intestinal obstruction occurs when the lumen of the intestines is being reduced by any cause. Concerning intestinal obstructions in rabbits, having a quick diagnosis is very valuable since they are acute and life-threatening. Radiographs are very helpful even if the only way to confirm the diagnosis is post-mortem examination or surgery. The objective of this study is to develop a deep-learning algorithm dedicated to the radiographic diagnosis of the intestinal obstruction in rabbits, in collaboration with PicoxIA.

741 radiographs of rabbits, labeled in a binary way (presence of an obstruction or not), were used to train a convolutional neural network. All radiographs have been reframed to standardize the database and obtain better performances from the network. Eventually, the last network trained was showing satisfying metrics like an AUPRC of 0.963 and a recall of 0.969, which permits to consider a commercial use.

Mots-clés : Diagnostic imaging - Radiography - Artificial intelligence - Intestinal obstruction - Rabbits