



HAL
open science

Dénombrement foetal sur des radiographies de gestation de chienne et de chatte par une intelligence artificielle

Raphaël Coube

► **To cite this version:**

Raphaël Coube. Dénombrement foetal sur des radiographies de gestation de chienne et de chatte par une intelligence artificielle. Médecine vétérinaire et santé animale. 2024. dumas-04804920

HAL Id: dumas-04804920

<https://dumas.ccsd.cnrs.fr/dumas-04804920v1>

Submitted on 26 Nov 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.

DÉNOMBREMENT FŒTAL SUR DES RADIOGRAPHIES DE GESTATION DE CHIENNE ET DE CHATTE PAR UNE INTELLIGENCE ARTIFICIELLE

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*

COUBE Raphaël Jean, Charles

Directeur de thèse : M. Fabrice CONCHOU

JURY

PRESIDENT :

M. Giovanni MOGICATO

Professeur à l'Ecole Nationale Vétérinaire de TOULOUSE

ASSESEURS :

M. Fabrice CONCHOU

Monsieur Laurent-Xavier NOUVEL

Maître de Conférences à l'Ecole Nationale Vétérinaire de TOULOUSE

Professeur 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*
- 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**, *Zootecnie*
- M. **FOUCRAS Gilles**, *Pathologie des ruminants*
- 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*
Mme DÔUET Jean-Yves, *Ophthalmologie vétérinaire et comparée*
M. FERCHIOU Ahmed, *Economie et gestion des entreprises vétérinaires agricoles*
Mme FUSADE-BOYER, *Microbiologie et infectiologie thérapeutiques et résistances*
Mme GRANAT Fariny, *Biologie médicale animalés*
Mme JOURDAN Géraldine, *Anesthésie, analgésie comparée*
Mme JOUSSERAND Nicolas, *Médecine interne des animaux de compagnie*
Mme LAVOUE Rachel, *Médecine Interne*
Mme LE GRAVERAND Quentin, *Alimentation animale*
Mme 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 des animaux de compagnie*
Mme PIERRON Alix, *Pharmacie-Toxicologie*
Mme VERGNE Timothée, *Santé publique vétérinaire, maladies animales réglementées*
Mme WARET-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 GEFRE 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

A monsieur le docteur Giovanni MOGICATO

Professeur de l'École Nationale Vétérinaire de Toulouse,
Anatomie, Imagerie Médicale

Qui m'a fait l'honneur d'accepter de présider le jury de cette thèse

A Monsieur le Docteur Fabrice COUCHOU

Maître de Conférences de l'École Nationale Vétérinaire de Toulouse
Imagerie médicale

Pour avoir accepté de diriger ma thèse, sincères remerciements

A monsieur le Docteur Xavier NOUVEL

Maître de Conférences de l'École Nationale Vétérinaire de Toulouse
pathologie de la reproduction

Qui a très aimablement accepté de faire partie de mon jury de thèse

A madame la docteur Emilie BOISSADY

Docteur vétérinaire

Pour son aide et son accompagnement lors du début de la thèse

A monsieur Benjamin TONI, monsieur Guilhem CODRON, monsieur Awadi BEDJA et
à toute l'équipe PICOXIA

Pour leur aide et leur bienveillance

Sincères amitiés

Table des matières

Table des figures	p5
Table des tableaux	p6
Liste des abréviations	p8
Introduction	p9
PREMIÈRE PARTIE : Aspects physiques des rayons-X et conséquences biologiques	p11
1.1 Rayons X : définition et propriétés	p11
1.2 Mécanisme d'action des rayons X sur l'organisme	p12
1.2.1 Effets directs des rayons X	p12
1.2.2 Effets indirects des rayons X	p12
1.3 Effets néfastes radio-induits	p14
1.3.1 Effets tissulaires ou déterministes	p14
1.3.2 Effets stochastiques	p14
DEUXIÈME PARTIE : Formation de l'image radiographique	p14
2.1 Mécanisme de production des rayons X	p14
2.2 Interactions entre les rayons-X et la matière	p15
2.2.1 Effet photoélectrique	p15
2.2.2 Effet Compton	p16
2.3 Impacts des rayonnements diffusés sur l'image radiographique	p17
2.3.1 Variation de l'intensité des rayonnements diffusés	p17
2.3.2 Absorption des rayonnements diffusés	p17
2.4 Formation de l'image radiographique	p18
TROISIÈME PARTIE : Utilisation de la radiographie dans le suivi de gestation chez la chienne et la chatte	p19
3.1-Réalisation d'une radiographie de gestation	p19
3.1.1 Réalisation d'une radiographie de l'abdomen et ses critères de qualités	p19
::: a) Constantes radiographiques	p19
::: b) Position de l'animal	p19
::: c) Critères de qualité radiographique	p19
3.1.2 Particularité de la radiographie de gestation	p20
3.2-Lecture de la radiographie	p20

3.2.1 Dans l'espèce canine	p20
3.2.2 Dans l'espèce féline	p21
3.3-Avantages et inconvénients	p21
3.3.1-Méthode de diagnostic de gestation	p21
3.3.2-Dénombrement foetal	p21
3.3.3-Détection des dystocies	p22
3.3.4-Mise en évidence de mortalité embryonnaire	p23
QUATRIÈME PARTIE : Intelligence artificielle appliquée à la lecture radiographique vétérinaire	p24
4.1-Définition de l'intelligence artificielle	p24
4.2- Modèle et mise en place d'un réseau neuronal	p24
4.2.1 - Organisation d'un réseau neuronal	p24
a) structure générale d'un réseau neuronal	p24
b) Connexion entre les neurones	p25
4.2.2 - entraînement d'un réseau neuronal	p27
a) Répartition des données	p27
b) Suivi de l'entraînement du réseau	p28
c) Modification des paramètres par rétropropagation	p29
d) Les différentes parties d'un apprentissage	p30
e) Conséquences d'un surapprentissage d'un réseau de neurones	p30
4.3 - Évaluation d'un réseau de reconnaissance d'images	p31
4.3.1 Calcul de l' <i>average precision</i>	p31
a) Le rapport intersection / union	p31
b) Matrice de confusion	p32
c) Rappel et précision	p33
d) Calcul de l' <i>average precision</i>	p34
4.3.2 Interprétation de la fonction précision / rappel	p34
a) Interprétation de l' <i>average precision</i>	p34
b) Choix d'un seuil de positivité	p35
4.4 - Présentation d'un RNC (réseau de neurones convolutifs)	p35
4.4.1 Imitation de la fonction visuelle des mammifères	p35

4.4.2	Présentation de la notion de convolution	p37
4.4.3	Simplification des données grâce à la fonction pooling	p40
4.4.4	Éléments constituant un RNC	p41
4.5-	Historique de l'intelligence artificielle employée en radiologie vétérinaire	p42
4.5.1-	Première occurrence et ses implications	p42
4.5.2-	État des lieux des applications de l'intelligence artificielle en radiologie vétérinaire	p43
4.5.3-	Comparaison entre le niveau d'efficacité de l'intelligence artificielle et celle d'un radiologue	p44
CINQUIÈME PARTIE : Création d'un réseau de dénombrement foetal		p45
5.1	Caractéristiques du modèle	p45
5.1.1	Extractions de l'image des objets	p45
a)	Série de convolutions et voie ascendante	p45
b)	voie descendante avec connexions latérales	p46
c)	Réseau retenu	p48
d)	Pré-entraînement du réseau	p48
5.1.2	Reconnaissance et détection des objets	p49
a)	Coordonnées des boîtes englobantes	p49
b)	Score de centralité et de classification	p50
c)	Filtrage des prédictions des boîtes englobantes	p52
5.1.3	Fonction de coût	p53
a)	Fonction de coût associé à la position des boîtes englobantes	p53
b)	Fonction de coût associé à la centralité des boîtes englobantes	p53
c)	Fonction de coût globale	p54
5.2	Formation de la base de donnée d'entraînement	p54
5.2.1	Caractéristiques des clichés radiographiques fournis pour l'entraînement	p54
5.2.2	Logiciel d'annotation utilisé	p54
5.3	Annotation par keypoints et résultats de l'entraînement	p54
5.3.1	Annotation par keypoint unique	p55
a)	Protocole d'annotation des images	p55
b)	Pool final d'apprentissage	p58

c) Analyse des résultats	p59
5.3.2 Annotation par association de classes	p60
a) Protocole d'annotation des images	p60
b) Pool final d'apprentissage	p61
c) Analyse des résultats	p62
5.3.2 Annotation des crânes	p63
a) Protocole d'annotation des images	p63
b) Protocole de sélection des images	p64
c) Pool final d'apprentissage	p65
d) Analyse des résultats	p65
SIXIEME PARTIE : Discussion et critique	p66
6.1 Pool de radiographies et annotations	p66
6.1.1 Qualité des images radiographiques	p66
6.1.2 Biais d'opérateur	p66
6.2 Performances du modèle	p66
6.3 Perspectives	p67
6.3.1 Amélioration du modèle existant	p67
a) Qualité des annotations	p67
b) Performances du modèle	p67
6.3.2 Création d'un nouveau modèle	p67
Conclusion	p68

Table des figures

Figure 1 : Longueur d'onde et énergie des différents rayonnements électromagnétiques

Figure 2 : Longueur d'onde et énergie des différents rayonnements électromagnétiques

Figure 3 : Effets directs et indirects des rayons X

Figure 3 : Fonctionnement d'un tube radiogène

Figure 5 : Effet photoélectrique

Figure 6 : Effet Compton

Figure 7 : grille anti-diffusante

Figure 8 : Exemple de dénombrement foetal

Figure 9 : Exemple de dystocie, disproportion foeto-maternelle

Figure 10 : Exemple de dystocie, présentation transverse

Figure 11 : Signes de mort foetal

Figure 12 : Organisation générale d'un réseau de neurone

Figure 13 : Fonctions de pré-activation et d'activation d'un neurone

Figure 14 : recherche du minimum de la fonction de coût en fonction du poids par itérations

Figure 15 : Influence du pas sur la convergence du poids vers un minimum

Figure 16 : voie ventrale de la vision dans le cortex

Figure 17 : Organisations entre les cellules simples et complexes

Figure 18 : Exemple de convolution sur une portion de radiographie

Figure 19 : Méthode du zero padding

Figure 20 : Exemple de l'application des fonctions max et everage pooling sur une matrice image

Figure 21 : Organisation générale d'une RNC

Figure 22 : Organisation générale du modèle FCOS

Figure 23 : Voie ascendante et conséquences

Figure 24 : Voie descendante et connexions latérales

Figure 25 : Structure du ResNet-50-FPN

Figure 26 : Boite englobante appliquée à la détection du coeur

Figure 27 : Calcul du score de centralité

Figure 28 : Calcul du score de classification

Figure 29 : Annotation d'un homme par réseau de détection par keypoints

Figure 30 : Annotation d'une radiographie par keypoint unique

Figure 31 : Foetus engagé dans la filière pelvienne

Figure 32 : Exemple de mauvaise qualité du cliché radiographique

Figure 33 : Inadéquation entre les crânes et les rachis

Figures 34 : Répartition des radiographies de gestation

Figure 35 : Multiples annotations du même crâne

Figure 36 : Annotation excédentaire de vertèbres

Figure 37 : Annotation d'une radiographie par keypoint en squelette

Figure 38 : Répartition des radiographies de gestation

Figure 39 : Annotation d'un crâne

Figure 40 : Répartition des radiographies de gestation

Table des tableaux

Tableau 1 : images radiographiques visibles lors de la gestation de la chienne

Tableau 2 : principales fonctions d'activation

Tableau 3 : paramètres d'efficacité d'une intelligence artificielle appliquée à la radiographie

Tableau 4 : Application de l'intelligence artificielle à la radiographie vétérinaire

Tableau 5 : Métriques du modèle par keypoint unique

Tableau 6 : Métriques du modèle par association de classes

Tableau 7 : Métriques du modèle de détection des crânes

Liste des abréviations

ADN : acide désoxyribonucléique

ARN : acide riboNucléique

RNC : réseau de neurones convolutifs

FCOS : fully convolutional one-stage object detection

COCO : common objects in context

CSV : comma-separated values

Introduction

Depuis deux ans, ce que nous appelons couramment "intelligence artificielle" a dépassé ses domaines d'application classiques (imagerie médicale, détection de fraude financières...) pour rentrer dans le quotidien de la population à travers notamment des applications de dialogues pouvant apporter des réponses sur presque tous les sujets.

Il convient dans un premier temps de nous interroger sur cette notion d'intelligence. Celle-ci étant plus pertinente au pluriel, en effet, l'intelligence conceptuelle, manuelle, émotionnelle, collective et tant d'autres constituent chacune une face de cette qualité. On peut cependant trouver un liant entre ces différentes définitions comme étant la capacité d'analyser, de comprendre et de venir à bout d'un problème, et de manière plus générale comme étant la faculté d'agir de façon appropriée selon les situations.

Cette définition se retrouve chez de nombreux auteurs (avec de légères variations) et fait consensus. Comme dans les travaux d'Édouard Claparède (médecin et psychologue suisse) considérant l'intelligence comme une fonction adaptative à une situation nouvelle [1]. Elle est également reprise par Lionel Naccache (neurologue et neurophysiologiste français) qui insiste sur l'importance de la plasticité cérébrale permettant au cerveau de s'adapter et de se remodeler en réponse à de nouvelles expériences et apprentissages [2]. On peut même trouver une approche de l'intelligence très similaire associant analyse et action dans la Grèce antique à travers la *mètis* qui constitue d'après Marcel Detienne et Jean-Pierre Vernant [3] "un ensemble complexe, mais très cohérent, d'attitudes mentales, de comportements intellectuels qui combinent le flair, la sagacité, la prévision, la souplesse d'esprit, la feinte, la débrouillardise, l'attention vigilante, le sens de l'opportunité, des habiletés diverses, une expérience longuement acquise " Ulysse, le héros incarnant cette *mètis* (que nous qualifierions aujourd'hui d'intelligence) a su la mettre à profit tout au long de l'Odyssée. Son action face au Polyphème est particulièrement révélatrice de ce qu'est au regard de notre définition l'intelligence. La capacité d'analyser rapidement et justement une situation : le cyclope ne peut pas être vaincu par la force brute. Et en déduire ainsi un plan d'action adapté : enivrer le monstre pour le rendre vulnérable, lui percer son œil avant de s'enfuir.

Au regard de cette définition, est-ce que le terme d'intelligence artificielle est justifié. La

réponse semble devoir être négative, en effet les systèmes d'IA actuels, même les plus avancés, n'ont aucune compréhension ou conscience. Ils traitent des données et exécutent des tâches basées sur des algorithmes et des modèles prédéfinis. Par exemple, un programme comme ChatGPT génère ses réponses en se basant sur des probabilités calculées à partir d'une base de donnée de texte. Il n'y a pas de compréhension globale de la question demandée. D'autres programmes comme la reconnaissance d'objets dans des images (que nous aborderons à travers cette thèse) sont monotâche et n'ont ainsi pas de définition pas de capacité d'adaptation.

Le terme *artificial intelligence* a été popularisé en 1956 lors de la Conférence de Dartmouth [4] par John McCarthy pour attirer l'attention des universitaires et du public sur ce domaine de recherche, ce qui pose question sur la pertinence de ce dernier.

Nous avons donc vu que qualifier un programme d'intelligent est incorrect. Néanmoins, le terme d'intelligence artificielle étant tellement employé dans la recherche et dans le langage courant qu'il sera réutilisé dans la suite de ce travail tout en gardant en tête les réserves émises précédemment.

Derrière l'intelligence artificielle, on retrouve des qualifications de programme plus précises :

Comme l'apprentissage automatique (*machine learning*) qui permet à un modèle de s'entraîner et d'apprendre de ses erreurs pour obtenir des meilleurs résultats. C'est le cas de ChatGPT dont la prédiction de la suite de mots à donner a été mise en place par l'utilisation d'un large corpus de texte comme base d'entraînement. [5]

Ou l'apprentissage profond (*deep learning*) qui s'appuie sur des réseaux de neurones interconnectés similaires à l'encéphale des mammifères. Où chaque neurone reçoit et émet des informations. [6]

Le premier algorithme d'apprentissage convolutif (fondamental dans la reconnaissance d'objets) est développé en 1980 [7]. De nombreuses améliorations de ce type de programme ont suivi.

L'augmentation des performances des ordinateurs à cette époque a permis d'augmenter la taille des réseaux neuronaux. Cependant, cette première vague d'utilisation des réseaux de neurones convolutifs s'est estompée dans les années 1990 [8].

L'intelligence artificielle a connu un regain d'activité en 2006 grâce à l'invention et à l'utilisation des unités de traitement graphique (GPU) qui ont quadruplé la vitesse d'appren-

tissage [9]. Les recherches dans le domaine sont principalement menées par le secteur privé et de grandes entreprises, comme Google, Microsoft, IBM, ect qui ont largement contribué à cette progression significative.

Du fait de ces avancées, l'intelligence artificielle s'est implantée dans de nombreux domaines et la médecine ne fait pas exception. Dans l'imagerie médicale, les réseaux de neurones convolutifs (spécialisés dans la reconnaissance d'objets) présentent des résultats impressionnants. Par exemple, une étude de 2020 conclu que l'IA pouvait détecter des cancers du sein dans les mammographies avec une précision supérieure à celle des radiologues expérimentés [10]. L'intelligence artificielle à de plus en plus une place prépondérante en radiologie, comme le montre la création d'une revue dédiée de la Radiological Society of North America, *Radiology : Artificial Intelligence*, en janvier 2019.

En médecine vétérinaire, l'application de cette technologie est encore peu présente. Mais certaines entreprises, comme PICOXIA (qui m'a accompagné dans la réalisation de cette thèse) proposent déjà des programmes de lecture radiographique utilisable par les praticiens.

Mon sujet consistant à la création d'un programme permettant de dénombrer les foeti sur une radiographie abdominale de chienne ou de chatte gestante.

PREMIÈRE PARTIE : Aspects physiques des rayons-X et conséquences biologiques

1.1 Rayons X : définition et propriétés

Les rayons X constituent un type de rayonnement électromagnétique constitué de photons, au même titre que la lumière visible ou le rayonnement gamma. Il est caractérisé par une fréquence élevée (de 10^{16} Hz à 10^{20} Hz) et donc une forte quantité d'énergie du fait de la proportionnalité entre l'énergie d'un photon et sa fréquence d'après la relation de Planck-Einstein :

$$E = h.\nu$$

avec E : énergie du photon en Joules, ν la fréquence en Hertz et h la constance de Planck, $6,626.10^{-34}$ J.s

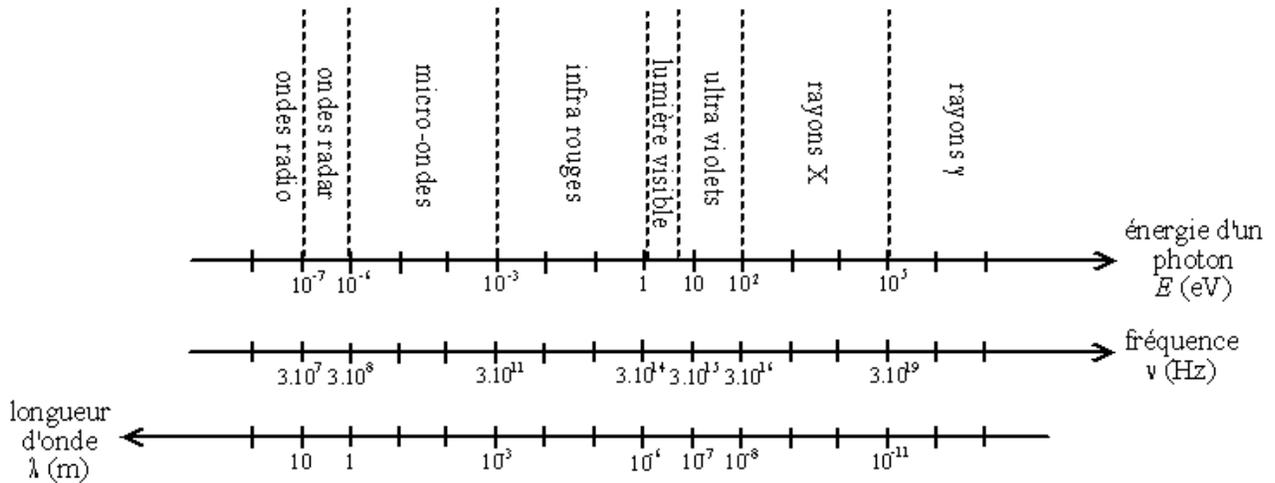


Figure 1 : Longueur d'onde et énergie des différents rayonnements électromagnétiques [1]

Les rayons X se déplacent de manière linéaire à la vitesse de la lumière dans le vide, ils n'ont pas de charge ni de masse.

1.2 Mécanisme d'action des rayons X sur l'organisme

Les rayons X entraînent des dommages directs ou indirects sur les tissus du fait de la grande quantité d'énergie transportée par les photons. Les différents effets sont résumés dans la Figure 2.

1.2.1 Effets directs des rayons X

Les photons chargés en énergie vont directement entraîner des dommages par ionisation des liaisons de certaines macromolécules (ADN, ARN, protéines, enzymes). Cette ionisation peut entraîner une rupture de la liaison ester phosphate dans l'ADN. Cela entraîne des ruptures double brin du matériel génétique au niveau d'un ou plusieurs points suivant l'intensité du rayonnement [11].

1.2.2 Effets indirects des rayons X

Les photons peuvent également réagir avec des molécules d'eau pour produire des radicaux libres : H et OH (électriquement neutre). Ces derniers peuvent par la suite former via des réactions chimiques du peroxyde d'oxygène et un radical d'hydroperoxyde [12].

Les processus chimiques impliqués sont :

- (1) $H_2O \rightarrow H_2O^+ + e^-$: ionisation d'une molécule d'eau par des rayons X
- (2) $H_2O^+ \rightarrow H^+ + OH$: détachement de l'ion hydrogène et formation de OH (radical libre)
- (3) $H_2O + e^- \rightarrow H_2O^-$ liaison entre l'électron et une molécule d'eau
- (4) $H_2O^- \rightarrow H + OH^-$: dissociation et formation de H (radical libre)
- (5) $\left\{ \begin{array}{l} OH + OH \rightarrow H_2O_2 \text{ formation de peroxyde d'oxygène} \\ H + O_2 \rightarrow HO_2 \text{ formation de radical d'hydropéroxyde} \end{array} \right.$

Ces deux molécules vont réagir avec les macromolécules de l'organisme et provoquer une oxydation des lipides et des protéines, ainsi qu'une rupture simple brin et la formation de site abasique au sein de l'ADN et de l'ARN [11].

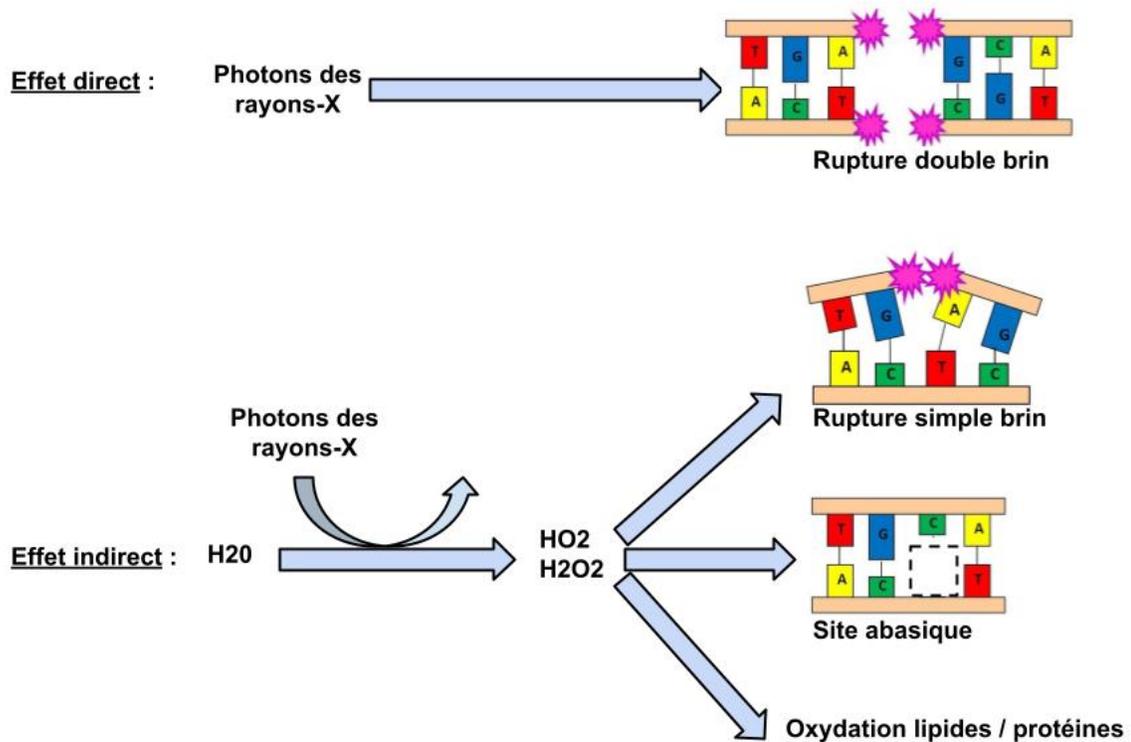


Figure 3 : Effets directs et indirects des rayons X

1.3 Effets néfastes radio induits

On classe généralement les effets indésirables des rayons X en deux catégories, les effets déterministes ou stochastiques

1.3.1 Effets tissulaires ou déterministes

Ce type d'effet indésirable va advenir de manière certaine si la dose de rayon-X reçu dépasse un certain seuil. De plus, la gravité des lésions infligées aux tissus est proportionnelle à l'intensité du rayonnement reçu. On va retrouver des lésions tissulaires précoces comme de l'érythème cutané ou des muqueuses et des lésions tissulaires tardives comme le syndrome hématopoïétique avec une période de latence de 4 à 5 semaines. [13]

1.3.2 Effets stochastiques

Ces effets peuvent se produire de manière aléatoire dès que le corps est exposé à une dose de rayon-X. On retrouve notamment la formation de cancers avec certains organes particulièrement sensible comme la thyroïde chez l'homme [14], ainsi que des effets héréditaires avec des mutations de l'ADN des cellules germinales qui seront transmises aux descendants [15].

DEUXIÈME PARTIE : Formation de l'image radiographique

2.1 Mécanisme de production des rayons X

Au sein de l'appareil de radiographie, les rayons X sont produits par le tube radiogène. Ce dernier est constitué d'une ampoule de verre dans laquelle règne le vide, d'une cathode, d'un disque monté sur un axe et d'une anode.

La cathode est un filament qui, porté à haute température, va produire un nuage d'électron par un effet thermo-ionique. Les électrons qui sont chargés négativement vont se déplacer vers l'anode qui est chargée positivement.

Cela génère un courant électrique qui est exprimé en milliampère (mA). L'intensité de ce courant électrique est une des valeurs que l'on peut configurer pour la réalisation d'un cliché radiographique grâce à la pièce de concentration (ou cupule) qui permet de focaliser les électrons vers l'anode.

Plus la tension entre l'anode et la cathode est élevée, et plus la vitesse des électrons sera importante. Ce différentiel de potentiel exprimé en kilovolt (kV) constitue la deuxième valeur que l'on peut configurer avant la réalisation d'un cliché radiographique.

Il y a enfin une production de rayons-X du fait du freinage des électrons par les atomes de tungstène de l'anode. Néanmoins, le rendement de production des rayons-X est très faible (environ 2%), le reste de l'énergie est dissipée sous forme de chaleur. C'est pour cela qu'un système d'anode tournante à plus de 6000 tours/minute pour dissiper la chaleur est mis en place sur la majorité des appareils de radiographie.

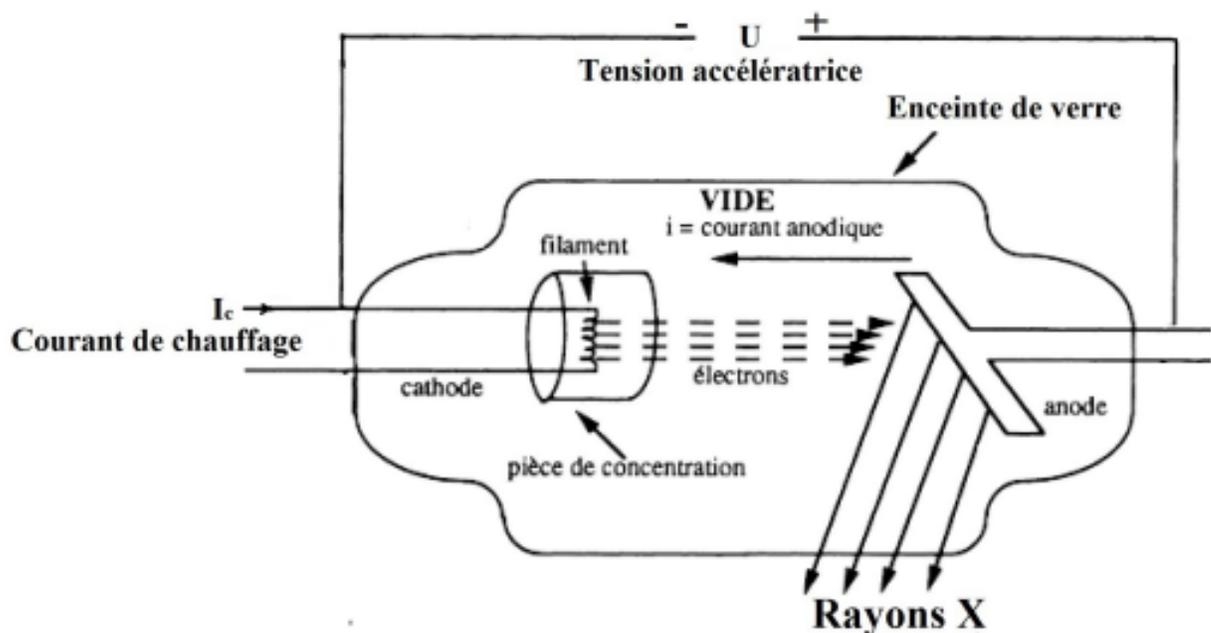


Figure 4 : Fonctionnement d'un tube radiogène [2]

2.2 Interactions entre les rayons-X et la matière

Il existe différents mécanismes d'interactions entre les rayons-X et la matière, l'effet photoélectrique et l'effet Compton

2.2.1 Effet photoélectrique

Cet effet provient de la transmission intégrale de l'énergie du rayon X à un électron de la

couche interne d'un atome. Cet électron est éjecté, devenant ainsi un photo-électron, il est alors remplacé par un électron d'une couche extérieure de l'atome. Le retour de l'atome à son état fondamental est accompagné d'une libération d'énergie sous la forme de la diffusion d'un rayon-X de faible énergie qui sera rapidement absorbé par l'organisme.

Cet effet prédomine pour les rayons-X de faible énergie (inférieur à 70 kV) et permet la formation de l'image radiographique.

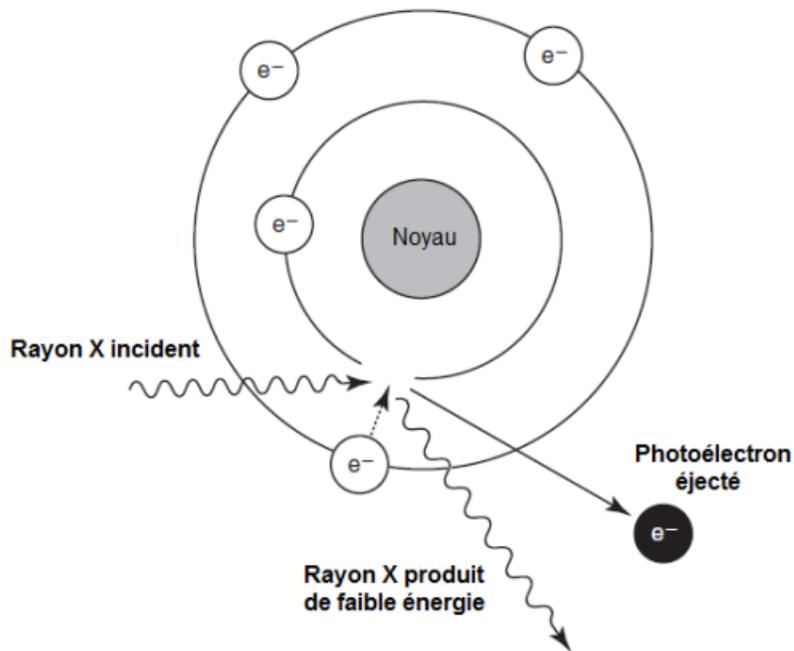


Figure 5 : Effet photoélectrique

2.2.2 Effet Compton

Cet effet provient de la transmission partielle de l'énergie du rayon X à un électron de la couche externe d'un atome. Cet électron est éjecté, devenant ainsi un photo-électron. Il y a alors la diffusion d'un rayon-X qui a une énergie quasiment identique de celle du rayon-X incident dans une direction aléatoire : ce qui constitue un danger pour le personnel. Cet effet prédomine pour les rayons-X de haute énergie (supérieur à 100 kV).

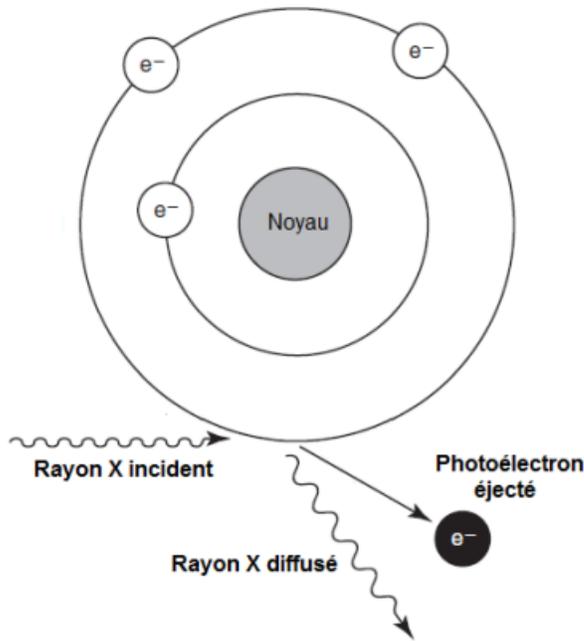


Figure 6 : Effet Compton

2.3 Impacts des rayonnements diffusés sur l'image radiographique

2.3.1 Variation de l'intensité des rayonnements diffusés

Nous avons vu que l'effet Compton était responsable de la grande majorité des rayonnements diffusés. Cet effet sera d'autant plus important que :

- L'énergie des rayons X est élevée
- L'épaisseur de la partie à radiographier est importante
- La taille du champ à radiographier est importante. Ce dernier doit être réduit au maximum grâce à un diaphragme qui absorbe une partie des rayons-X avec une plaque en plomb.

2.3.2 Absorption des rayonnements diffusés

Ces rayons-X parasites vont provoquer une altération de l'image radiographique en formant un voile blanc. Ils doivent donc être supprimés ou réduits au maximum à l'aide d'une grille anti-diffusante.

Le modèle le plus utilisé est une grille à lames focalisées, il est composé de lamelles de plomb parallèles aux rayons-X transmis, ce qui permet leur passage en majorité (environ 60% des rayons). Les rayons diffusés sont quant à eux absorbés car ils ont une trajectoire oblique par rapport aux lamelles de plomb.

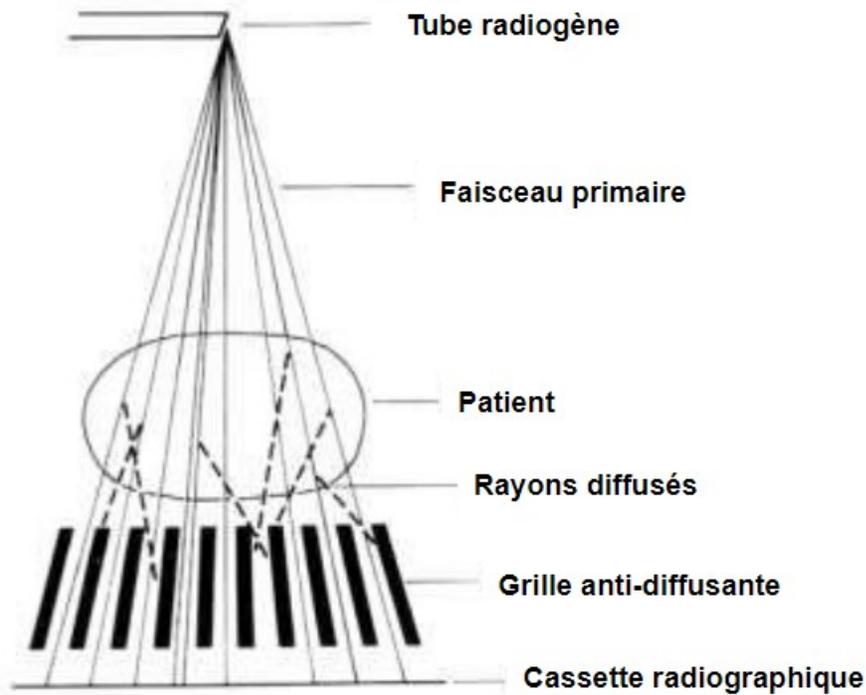


Figure 7 : grille anti-diffusante [3]

Les lamelles de plomb forment une trame sur l'image radiographique par absorption des rayons-X, cela peut gêner l'interprétation du cliché radiographique. C'est pour cela que la grille effectue un mouvement d'oscillation perpendiculaire à l'axe des lamelles, ce qui permet d'enlever la trame suivant le principe de flou cinétique.

2.4 Formation de l'image radiographique

Du fait de l'effet photoélectrique entre les rayons-X et la matière, l'intensité du faisceau incident va diminuer. Les rayons transmis vont alors former l'image de rayonnement de la partie radiographiée. Celle-ci sera par la suite réceptionnée :

- Par une cassette en phosphore, qui sera utilisé dans le cas de la radiographie conventionnelle.
- Par un détecteur numérique spécifique, ce système présente l'avantage de ne pas demander pas de manipulations une fois la radiographie effectuée.

TROISIÈME PARTIE : Utilisation de la radiographie dans le suivi de gestation chez la chienne et la chatte

3.1-Réalisation d'une radiographie de gestation

3.1.1 Réalisation d'une radiographie de l'abdomen et ses critères de qualités

a) Constantes radiographiques

L'abdomen est une région anatomique présentant un faible contraste avec un ensemble d'organes d'opacité tissulaire. Seule la graisse pouvant apporter du contraste. Or le contraste est inversement proportionnel à la tension appliquée durant la réalisation du cliché. Ainsi pour une radiographie de l'abdomen des tensions basses sont utilisées (entre 60 et 80 kV).

Du fait des mouvements respiratoires, le temps de pose reste assez court (< 0.1 s) et se fait à l'expiration.

Enfin, la valeur de l'intensité est proportionnelle à l'épaisseur ou de la largeur de l'abdomen (selon l'angle d'incidence).

b) Position de l'animal

Dans le cas d'une incidence ventro-dorsale, l'animal est positionné sur le dos avec les membres pelviens tirés en arrière. Le faisceau de Rayon-X est quant à lui centré en avant de l'ombilic.

Dans le cas d'une incidence latéro-latérale, l'animal est positionné sur le flanc avec les membres pelviens superposés et en extension en arrière. Le faisceau de Rayon-X est quant à lui centré dans le creux du flanc derrière les dernières côtes.

c) Critères de qualité radiographique

Pour une radiographie en incidence ventro-dorsale, l'ensemble de l'abdomen doit être visible du diaphragme jusqu'aux hanches. L'absence de rotation est contrôlée grâce à la colonne vertébrale qui doit être visible au milieu de la radiographie et avec les deux parties droite et gauche de l'abdomen qui doivent être symétriques.

Pour une radiographie en incidence latéro-latérale, l'ensemble de l'abdomen du diaphragme jusqu'aux hanches doit être visible. Une absence de rotation est contrôlée grâce à la superposition de la base des côtes visibles sur la radiographie.

3.1.2 Particularité de la radiographie de gestation

On réalise deux incidences, la première ventro-dorsale et la deuxième latéro-latérale droite ou gauche, l'intégralité de l'abdomen doit être visible sur les deux clichés.

L'exposition aux rayons X peut provoquer des dommages importants aux foeti lors de l'organogenèse [16] soit de 19 jours à 35 jours après le pic de LH [17] chez le chien. Cela est peu préoccupant car les radiographies de gestation se réalisent 45 jours après le pic de LH chez la chienne, soit après la minéralisation des foeti.

Une mise a jeun de 24h peut être envisagée avant la réalisation du cliché radiographique. En effet, l'accumulation de gaz et de matière fécale dans le colon peut masquer les foeti, notamment quand ces derniers sont encore peu minéralisés [18]. Néanmoins, il est déconseillé de ne pas nourrir une chienne gestante, particulièrement dans le dernier trimestre de gestation. En effet, compte tenu de son état physiologique particulier, elle aura besoin de plus d'énergie, de plus une mise a jeun peut provoquer un état pathologique d'hypoglycémie et d'hypercétonémie [19].

3.2-Lecture de la radiographie

3.2.1-Dans l'espèce canine

Chez la chienne, l'utérus augmente de taille dès trois semaines après ovulation. Il apparaît sous la forme d'une image tubulaire liquidienne située entre le colon et la vessie. Entre 30 et 40 jours, on peut visualiser des dilatations utérines de forme ovoïde. Il est impossible de différencier une gestation d'une atteinte de l'utérine, cela ne permet donc pas un diagnostic de gestation [20]. La minéralisation du squelette commence 35 jours après le pic de LH, mais les os ne sont visibles sur la radiographie que 45 jours après le pic de LH. Le crâne, la colonne vertébrale et les côtes sont les premières parties minéralisées à pouvoir être distinguées, les dents sont les dernières à 63 jours post pic de LH [20]. Le Tableau 1 présente les différentes structures visibles ainsi que les périodes à partir desquelles elles sont visibles.

structures visibles	nombre de jours avant la mise bas
augmentation de taille de l'utérus	33-41
colonne vertébrale	20-22
crâne	20-22
côtes	20-22
Fémur	15-18
Humérus	15-18
Radius	9-13
Tibia	9-13
bassin	9-13
métacarpes et métatarses	2-9
phalanges	2-9
calcaneus	2-9
dents	3-8

Tableau 1 : images radiographiques visibles lors de la gestation de la chienne

3.2.2-Dans l'espèce féline

Chez la chatte, à partir du 32ème jour, l'utérus devient visible sur les radiographies, avec une légère dilatation qu'il est difficile de distinguer des anses intestinales. Aux alentours du 35ème jour, l'utérus est clairement identifiable et présente des renflements qui s'estompent progressivement. Vers le 41ème jour, l'utérus apparaît dilaté et prend une forme tubulaire.

la minéralisation se fait approximativement une semaine plus tôt en comparaison de l'espèce canine. La colonne vertébrale peut être détectée par un examen radiographique entre le 34ème et le 38ème jour. [21]

3.3-Avantages et inconvénients de la radiographie

3.3.1-Méthode de diagnostic de gestation

La radiographie permet un diagnostic de gestation tardif en comparaison avec d'autres méthodes notamment l'examen échographique qui est fiable à 25 jours [18]. L'avantage de la radiographie dans ce diagnostic est une très bonne sensibilité qui est proche de 100% après 45 jours [19], les rares exemples de faux négatifs correspondent généralement à des cas de foeti peu minéralisés en association à une mauvaise technique radiographique (sous exposition) [22].

3.3.2-Dénombrement foetal

La radiographie constitue la méthode la plus fiable pour déterminer le nombre de foeti avec une estimation exacte dans 93% des cas avec une radiographie réalisée après 45 jours

chez la chienne[20]. Il est alors recommandé de compter le nombre de crânes et de rachis en incidence ventro-dorsale puis en latérale et de les comparer en cas de doutes sur le nombre de fœti.

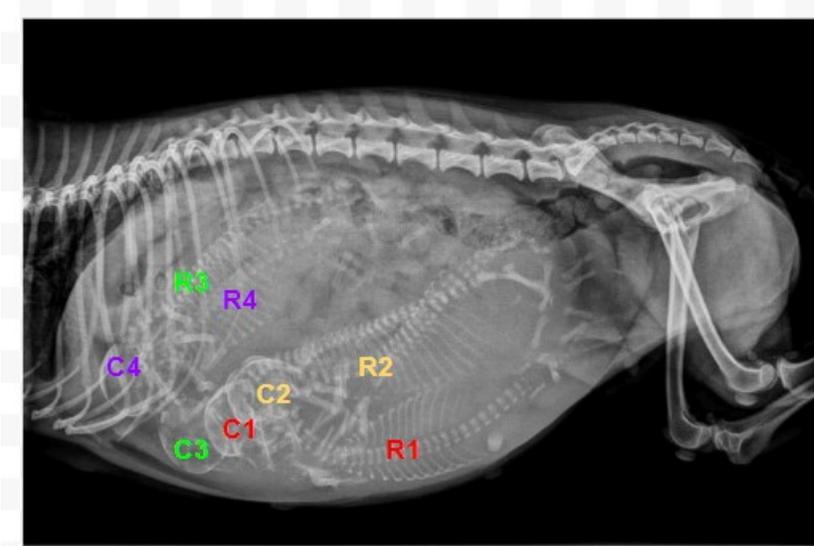


Figure 8 : Exemple de dénombrement fœtal, C : crâne, R : rachis [4]

Cette information permet un bon déroulement de la mise bas. Elle permet à un éleveur de prévoir la taille de la portée et de se préparer en conséquences. Enfin, elle permet d'anticiper un syndrome du chiot unique et ainsi de déclencher la mise bas. [23]

3.3.3-Détection des dystocies

L'examen radiographique présente un intérêt dans la prévention des dystocies, il permet de détecter une malposition fœtale comme une hernie inguinale, une disproportion fœto-maternelle ou une anomalie anatomique du canal pelvien. [20]

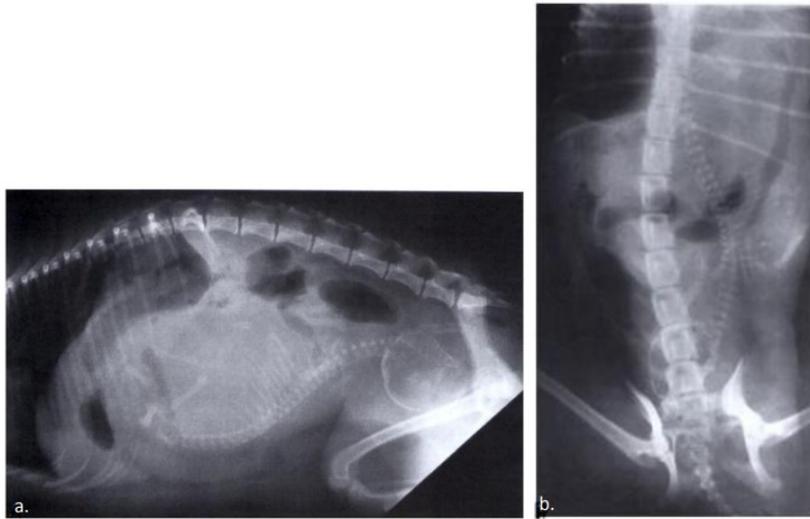


Figure 9 : Exemple de dystocie, disproportion foeto-maternelle [5]

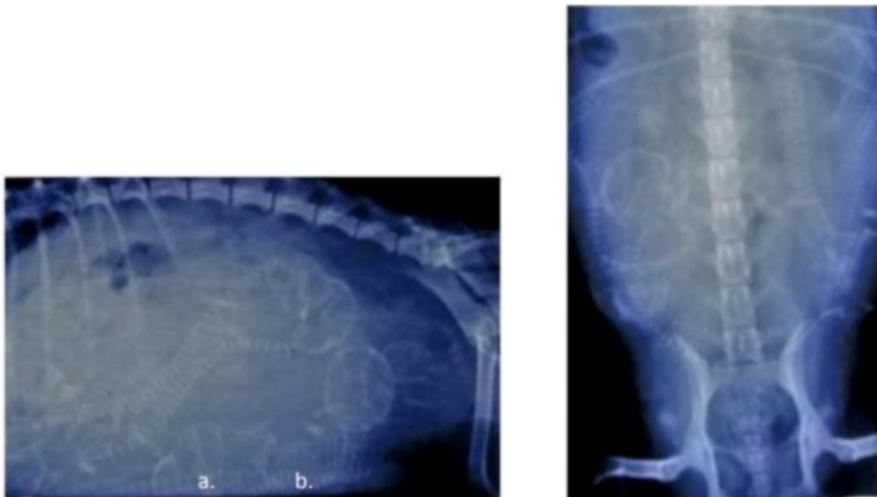
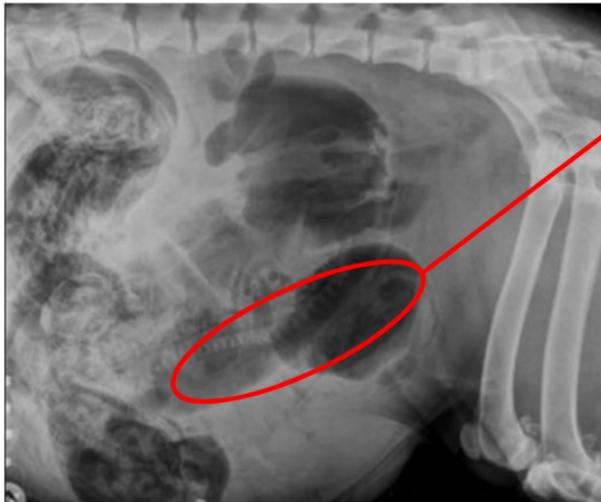


Figure 10 : Exemple de dystocie, présentation transverse [5]

3.3.4-Mise en évidence de mortalité embryonnaire

Enfin, la radiographie permet également de diagnostiquer une mortalité embryonnaire tardive, qui est alors visible 24 à 48 heures après la mort du fœtus. Les signes radiologiques sont alors une déminéralisation osseuse, une opacité gazeuse autour ou sur le foetus traduisant la production de gaz par dégradation métabolique (à distinguer du gaz présent dans les anses intestinales), une superposition des crânes ou un mauvais alignement crâne-rachis qui résultent d'un collapsus crânien. [20]



**Présence de gaz
sur et autour du fœtus**

Figure 11 : Signes de mort foetal [6]

QUATRIÈME PARTIE : Intelligence artificielle appliquée à la lecture radiographique vétérinaire

4.1-Définition de l'intelligence artificielle

Nous avons vu en introduction la genèse du terme "d'intelligence artificielle" et les limites associés.

La définition suivante est plus adaptée au contexte de l'imagerie médicale : "Une machine intelligente est une machine qui est capable d'élaborer des règles (induction), permettant de déduire d'une série d'informations (data), la suite à donner à la série (données sortantes)" [24].

4.2- Modèle et mise en place d'un réseau neuronal

4.2.1 - Organisation d'un réseau neuronal

a) structure générale d'un réseau neuronal

Un réseau de neurones peut être subdivisé en trois parties [25], :

-Une couche "inputs" qui constitue les données fournies au réseau. Ici, il s'agit de l'image radiographique.

-Une couche "output" qui correspond à la ou aux réponses du réseau. On peut retrouver dans ces sorties :

*Une probabilité de la relation entre les pixels d'une ou de plusieurs images et ce qu'elles représentent. Par exemple, pneumothorax : 77%, cardiomégalie : 7% ...

*Un dénombrement associé à sa probabilité. Par exemple, [nombre de foeti, confiance associée] : [5, 76%], [6, 15%] ...

-Enfin, entre la première et la dernière partie, le réseau neuronal est constitué de couches de neurones interconnectées entre elles, on les appelle les couches cachées.

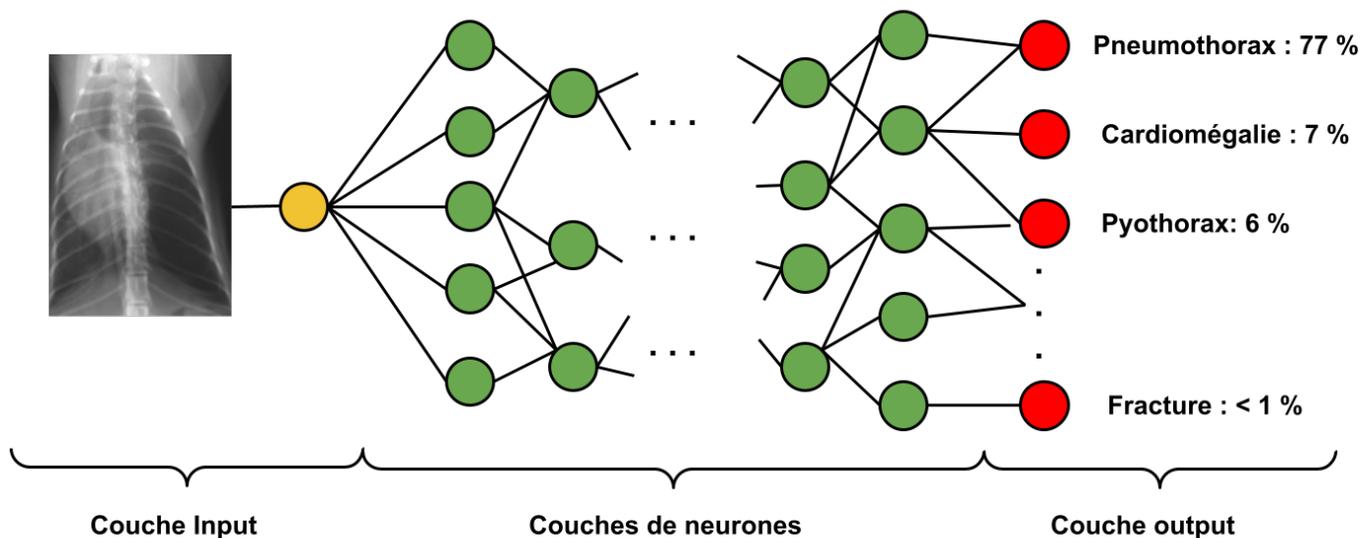


Figure 12 : Organisation générale d'un réseau de neurone

b) Connexion entre les neurones

Chaque neurone est composé de deux fonctions : la pré-activation et l'activation. La première fonction entraînant la deuxième.

La pré-activation est permise par les signaux provenant d'un ou plusieurs neurones N_i avec i entier naturel. Chaque signal est associé à une force appelée poids W_i . La pré-activation correspond à la somme d'un biais noté b et des poids pondérés par un facteur X_i .

L'activation correspond quant à elle une fonction mathématique de la valeur de pré-activation et permet la production d'un signal de sortie. [26]

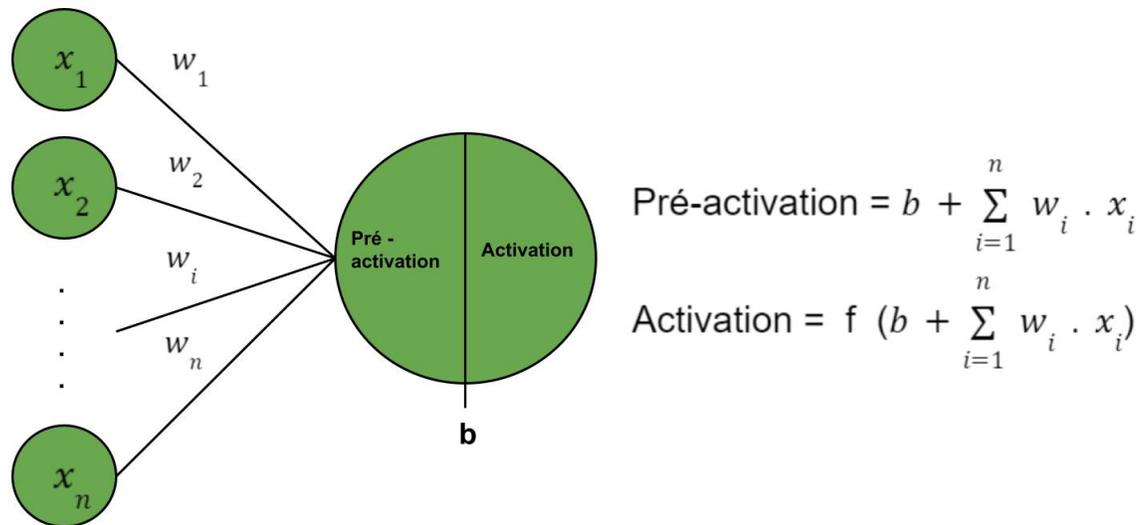


Figure 13 : Fonctions de pré-activation et d'activation d'un neurone

Il existe différentes fonctions d'activation, elles sont utilisées en fonction des différents rôles des neurones. Les fonctions les plus fréquentes sont présentées dans le tableau 2.

Ces fonctions d'activation ont pour point commun d'être non linéaires, c'est-à-dire que $\text{activation}(X) \neq a \times X + b$. En effet, la composition de plusieurs fonctions linéaires est elle-même une fonction linéaire. La non-linéarité des fonctions permet la mise en place d'une démarcation nette entre les couches de neurones, empêchant la simplification de ces dernières.

A contrario, dans le cas d'un réseau de neurones dont les fonctions d'activation seraient linéaires, chaque couche de neurone se comporte de la même façon, rendant impossible l'apprentissage de tâches complexes.

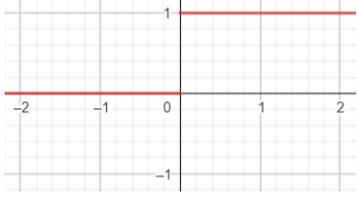
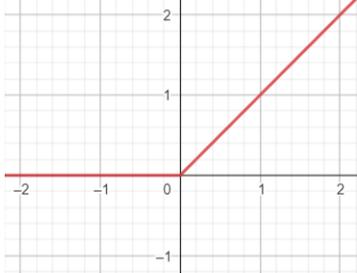
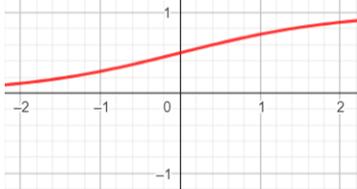
Fonction	Formule f(x)	Graphique/exemple	Propriétés et conséquences
Binaire	$\begin{cases} = 0 & \text{si } x < 0 \\ = x & \text{si } x \geq 0 \end{cases}$		<p>-Ce type de fonction est utilisé pour des algorithmes dont l'<i>output</i> est binaire. Comme par exemple : pneumothorax présent ou absent</p> <p>-De plus, le retour nul dans le cas d'une valeur de pré-activation négative entraîne une non activation de certains neurones et donc un non ajustement d'un certain nombre de poids et de connexions</p>
ReLU	$\begin{cases} = 0 & \text{si } x < 0 \\ = x & \text{si } x \geq 0 \end{cases}$		<p>-ReLU est la fonction la plus utilisée dans les couches cachées. En effet, elle est plus efficace en termes de calcul car le nombre de neurones activés est faible du fait de son retour nul dans le cas d'une valeur de pré-activation négative.</p> <p>-Néanmoins, ce retour nul entraîne une non activation de certains neurones et donc un non ajustement d'un certain nombre de poids et de connexions.</p>
Sigmoïde	$\frac{1}{1+e^{-x}}$		<p>-Les valeurs de la fonction sigmoïde étant comprises dans l'intervalle [0,1], elle est utilisée pour exprimer une probabilité</p>
Softmax	$\frac{e^{x_j}}{\sum_{i=1}^N e^{x_i}}$	$\begin{matrix} 1.8 & & 0.58 \\ 0.9 & \xrightarrow{\text{Softmax}} & 0.23 \\ 0.68 & & 0.19 \end{matrix}$	<p>-Cette fonction permet d'associer à une suite de réels une liste de probabilités dont la somme est égale à 1.</p> <p>-Elle est utilisée dans des modèles dont l'<i>output</i> est un classement associé à une probabilité. .</p>

Tableau 2 : principales fonctions d'activation

4.2.2 - entraînement d'un réseau neuronal

a) Répartition des données

Dans la majorité des cas, la création d'un réseau neuronal conçu pour la lecture radiographique implique le réentraînement d'un réseau déjà existant en vue d'accomplir une nouvelle tâche. En effet, cette méthode nécessite beaucoup moins de données pour entraîner le réseau en comparaison d'un réseau naïf. [27]

L'entraînement d'un réseau nécessite un ensemble de "données témoin", en l'occurrence des radiographies dont le résultat de la lecture est certain et a été confirmé par un ou plusieurs radiologues. Ces données sont divisées en deux parties :

-les données d'entraînement (environ 75% des radiographies disponibles) : elles permettent à l'algorithme d'apprendre la tâche assignée grâce à l'ajustement du poids w dans les réglages neuronaux.

Par exemple, si le but d'un programme est de localiser le cœur sur une radiographie du thorax, les données d'entraînements seraient constituées de radiographies thoraciques où la position du cœur serait délimité par un radiologue.

-Les 25% restants constituent des données de test et leur utilisation sera évoquée dans la partie 4.3 .

b) Suivi de l'entraînement du réseau

L'efficacité du réseau peut être mesurée par un fonction appelée *loss function* ou fonction de coût qui mesure la différence entre les sorties du réseau et les valeurs attendues [28]. De manière générale, une valeur seuil est fixée comme objectif pour le réseau à l'issue de l'entraînement. On retrouve comme fonction de coût :

-L'entropie croisée est la fonction généralement employée pour des algorithmes à classe multiple associé à des probabilités [56]. Comme par exemple, ce chien est-il un beagle, un lévrier, un basset... Plus la valeur de l'entropie croisée est importante, et plus il existe une divergence entre les valeurs de sortie (*output*) et les valeurs attendues. Sa formule est :

$$-\sum_{i=1}^N y_i \times \log(p_i)$$

Avec N étant le nombre de classes

$y_i = 1$ si la classe i est attendue, sinon $y_i = 0$

p_i étant la probabilité associée à la classe i

- L'écart type est la fonction adaptée pour des algorithmes dont l'*output* est une fonction discrète ou continue. Comme par exemple la mesure de la longueur de la vertèbre cervicale n°1. Sa formule est :

$$\sqrt{\frac{1}{n} \sum_{i=1}^N (X_i - Y_i)^2}$$

Avec X_i la valeur attendue ou *gold standard* et Y_i la valeur renvoyée par le réseau.

Dans le cas d'un réseau permettant la reconnaissance et le dénombrement d'objets (utilisé dans le cadre de cette étude avec le dénombrement des fœti), la compréhension de la fonction de coût nécessite dans un premier temps de détailler le fonctionnement de ce modèle. Cette fonction sera ainsi explicitée dans la partie 5.1.3

c) Modification des paramètres par rétropropagation

Lors de l'entraînement d'un réseau, les poids et les biais sont modifiés de proche en proche (de la couche *output* vers la couche *input*) afin de minimiser la fonction de coût.

En pratique, les valeurs du poids du neurone n°j exercé sur le neurone n°i : $W_{i,j}$ et du biais du neurone n°i : b_i sont changées de manière itérative selon les formules suivantes :

$$\begin{cases} W_{i,j} \leftarrow W_{i,j} - \alpha * \frac{\partial \text{fonction de coût}}{\partial W_{i,j}} \\ b_i \leftarrow b_i - \alpha * \frac{\partial \text{fonction de coût}}{\partial b_i} \end{cases}$$

Avec α le pas du réseau qui est fixé

$\frac{\partial \text{fonction de coût}}{\partial W_{i,j}}$ et $\frac{\partial \text{fonction de coût}}{\partial b_i}$ les dérivées partielles de la fonction de coût en fonction du poids du neurone j (avec j variant de $[[1 - n]]$ ou du biais du neurone n°i.

Si cette dérivée partielle est négative, cela signifie que la fonction coût est décroissante en fonction de $W_{i,j}$ ou de b_i . La valeur du poids ou du biais est alors augmentée pour minimiser la fonction de coût.

Le raisonnement est inverse si cette dérivée partielle est positive.

L'illustration suivante illustre ce principe en deux dimensions : la fonction coût est fonction d'un seul poids. Ce qui n'est pas le cas dans la pratique.

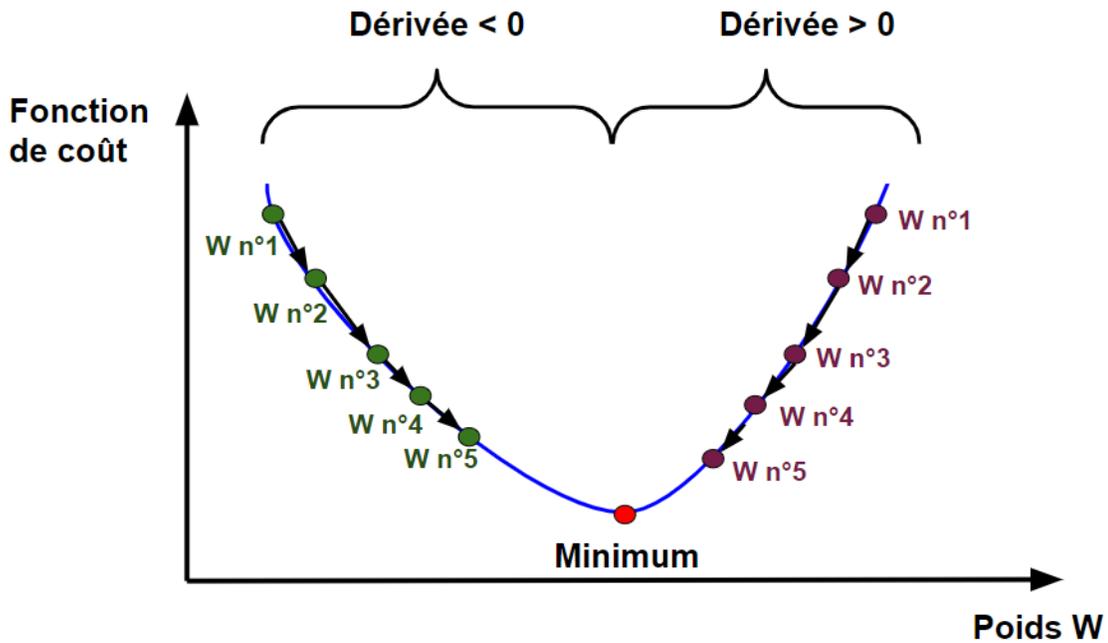


Figure 14 : recherche du minimum de la fonction de coût en fonction du poids par itérations

Le pas du réseau va influencer sur le choix du minimum ainsi que la vitesse de convergence

vers celui-ci.

-Si le pas est faible, la durée de convergence vers un minimum local peut être importante ce qui va prolonger la durée d'entraînement. De plus, une variation trop faible du poids ou du biais empêche le passage de maximum de la fonction de coût, entraînant une absence de convergence vers un autre minimum local.

-Si le pas est trop important, il peut ne pas y avoir de convergence vers un minimum, car les variations des poids et des biais sont trop importants.

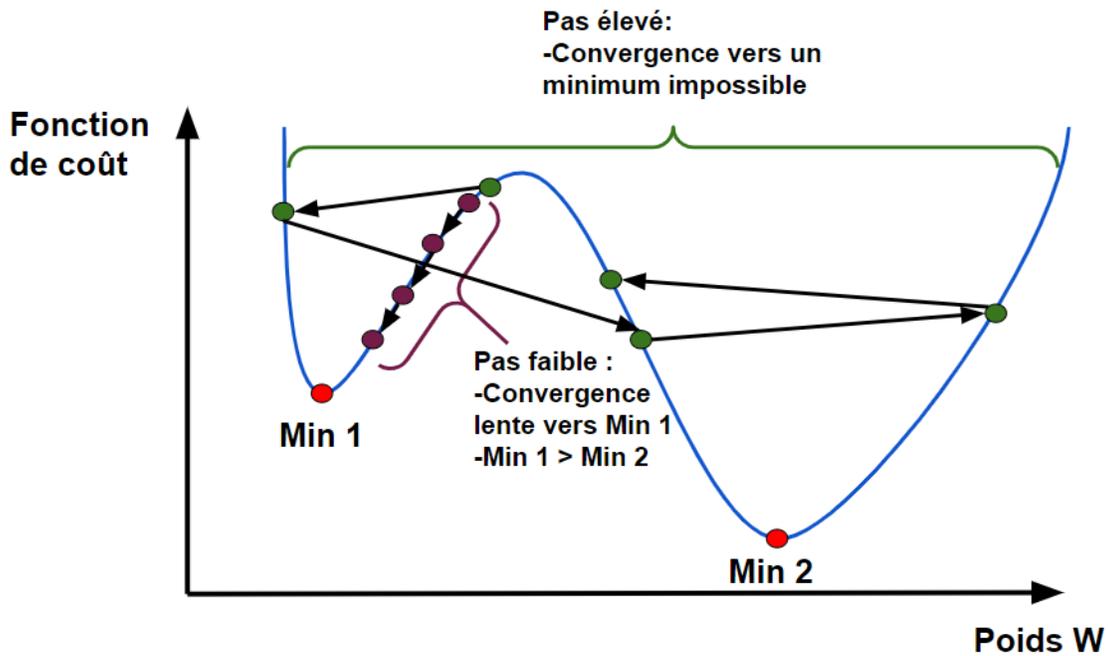


Figure 15 : Influence du pas sur la convergence du poids vers un minimum

d) Les différentes parties d'un apprentissage

L'apprentissage d'une intelligence artificielle est composé d'une succession d'époques. Durant l'une d'entre elles, le réseau utilise une fraction des données d'entraînement (ici des radiographies) afin de minimiser la fonction coût via la variation des poids et des biais du réseau. Cela correspond aux modifications itératives des poids et des biais vues précédemment. Ainsi, si les nouveaux paramètres aboutissent à une diminution de la fonction coût, ils seront retenus pour l'époque suivante [27].

e) Conséquences d'un surapprentissage d'un réseau de neurones

Le surapprentissage intervient dans le cas où la masse de données d'entraînement est trop importante. Le réseau va alors prendre en plus des caractéristiques majeures des interférences inutiles pour fournir sa réponse. Ce phénomène réduit alors la plasticité du modèle [28]. Or dans le cas de la reconnaissance radiographique, celle-ci est importante, car la qualité de l'image radiographique peut considérablement varier entre des radiographies labellisées pour l'entraînement et des radiographies effectuées en pratique clinique ou en urgence.

4.3- Évaluation d'un réseau de reconnaissance d'images

Les données de test représentent quant à elles environ 25% des radiographies disponibles. À la fin de l'entraînement, elles permettent une évaluation de l'intelligence artificielle à travers le calcul du *Average Precision*. Il s'agit d'un paramètre d'efficacité des programmes de reconnaissance d'images et de dénombrement. C'est pourquoi nous nous concentrerons sur cette valeur : elle est adaptée pour évaluer l'algorithme de dénombrement des foeti développé dans le cadre de ce travail.

Il convient de noter que selon le type de programme et de son *output*, d'autres métriques d'évaluations peuvent se révéler plus pertinentes.

4.3.1- Calcul de l'*average Precision*

Sa formule est basée sur les paramètres suivants : la matrice de confusion, le rapport intersection/union, la précision et le rappel du modèle.

a) Le rapport intersection / union

Utilisé pour les reconnaissances d'images, le rapport I/U indique à quel point la position prédite d'un objet se recoupe avec sa position réelle. Dans l'exemple de la figure 16, le modèle cherche à localiser le cœur sur la radiographie.

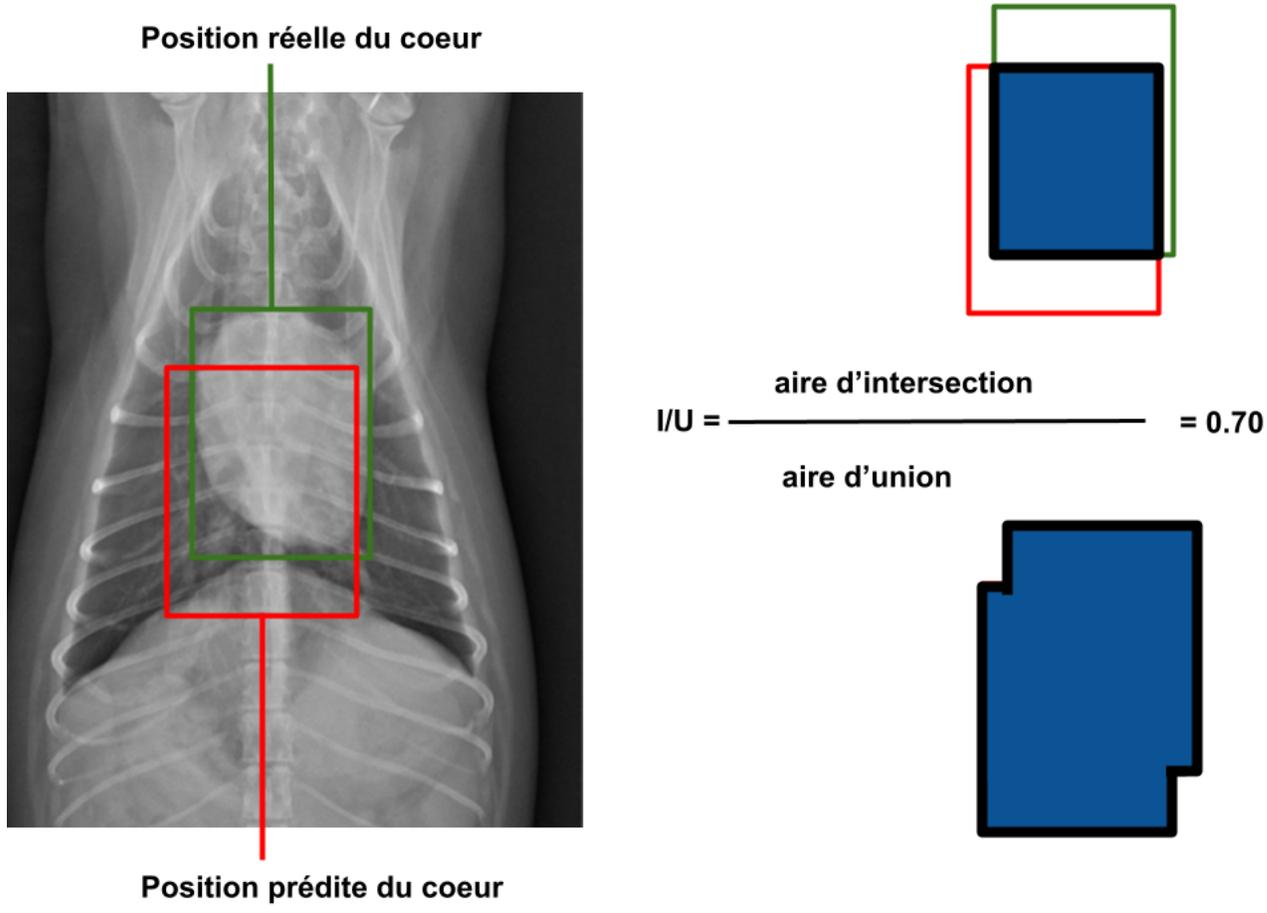


Figure 16 : Rapport intersection / union

b) Matrice de confusion

La matrice de confusion, aussi appelée tableau de contingence, permet d'évaluer la classification d'un modèle, elle est composée des vrais positifs (VP), faux positifs (FP), vrais négatifs (VN) et faux négatifs (FN). Cette matrice est présentée dans le Tableau 3

		Valeur réelle		Total
		Positif	Négatif	
Prédiction	Positif	<i>VP</i>	<i>FP</i>	<i>VP + FP</i>
	Négatif	<i>FN</i>	<i>VN</i>	<i>FN + VN</i>
Total		<i>VP + FN</i>	<i>FP + VN</i>	<i>Ntot</i>

Tableau 3 : matrice de confusion

Les positifs (VP et FP) sont déterminés grâce au rapport intersection / union. Si ce rapport est supérieur à un seuil (choisi par l'opérateur), alors la prédiction du modèle est

considérée comme juste soit un VP. Sinon il s'agit d'un FP. Cette classification est illustrée dans la figure 17 avec une valeur seuil de 0.5.

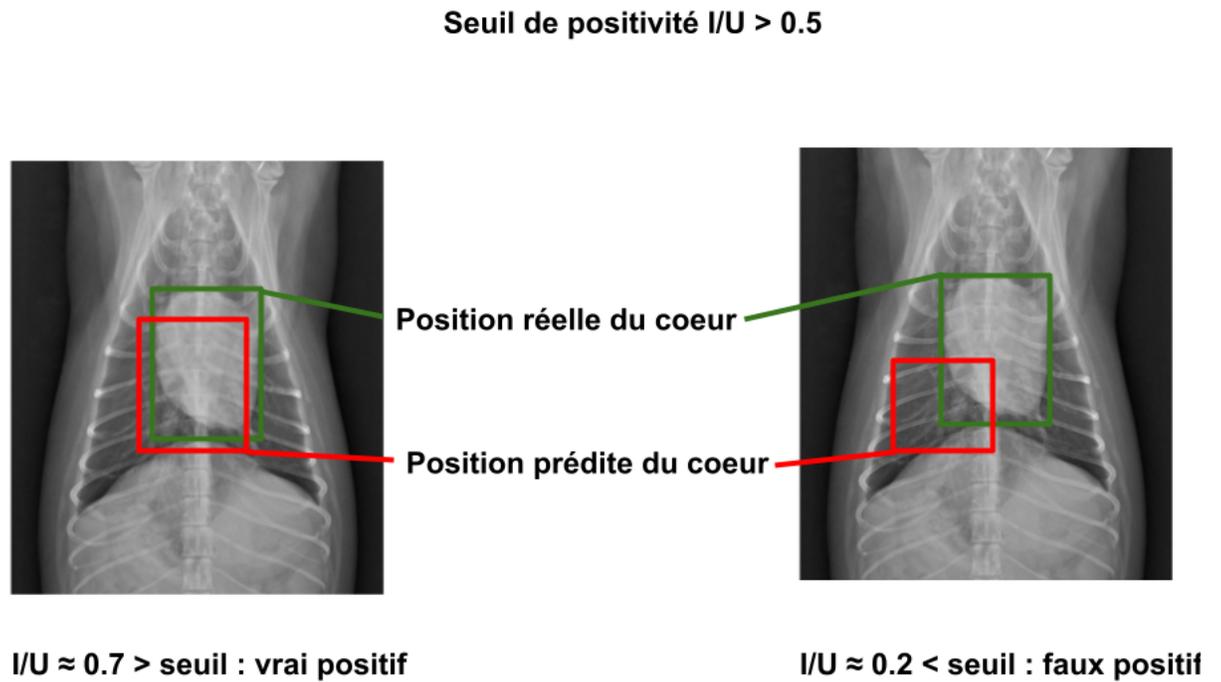


Figure 16 : Utilisation d'une valeur seuil pour déterminer les vrais et faux positifs

c) Rappel et précision

Grace à la matrice de confusion, ces deux paramètres peuvent être calculés de la manière suivante :

Précision (aussi appelé valeur prédictive positive) : $P = \frac{VP}{VP+FP}$ représente la capacité d'un modèle à prédire une occurrence correcte.

Rappel (aussi appelé sensibilité) : $R = \frac{VP}{VP+FN}$ représente la capacité d'un modèle à ne pas oublier une occurrence.

Les deux varient en opposition par rapport fonction du seuil de détection.

En effet, un seuil de positivité élevé entrainera une précision accrue (moins de FP). Ce même seuil va entrainer une baisse du rappel (plus de FN).

Le raisonnement inverse peut être appliqué pour un seuil de positivité bas.

d) Calcul de l'*average Precision*

Enfin, grâce à tous les paramètres, il est possible d'obtenir l'*Average Precision* d'un test, ce dernier correspond à l'aire sous la courbe de la fonction précision = f(rappel) en faisant varier le seuil de positivité de 1 à 0.

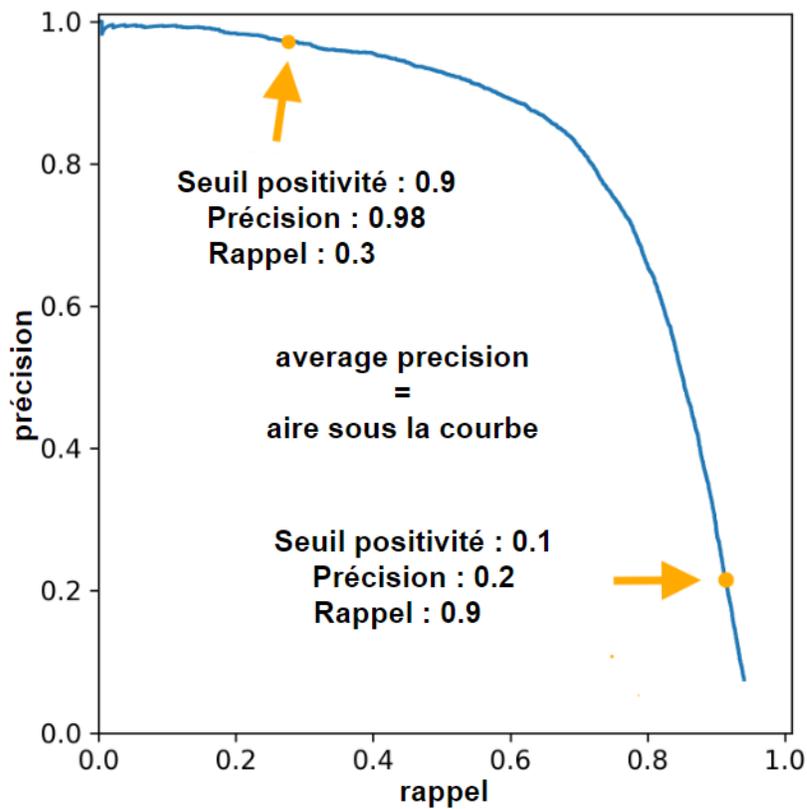


Figure 17 : Courbe précision-rappel

4.3.2- Interprétation de la fonction précision / rappel

a) Interprétation de l'*average Precision*

Plus l'*average précision* est proche de 1 et plus le modèle est considéré comme performant. En effet, il combine dans ce cas un haut niveau de rappel et de précision.

Néanmoins, un modèle est considéré comme performant si l'*average Precision* est supérieure à 0.5. [29]

b) Choix d'un seuil de positivité

Le tracé de la courbe sensibilité = $f(\text{rappel})$ par la variation du seuil de positivité permet de choisir le seuil le plus adapté pour le modèle. Celui-ci est choisi arbitrairement par l'opérateur en fonction de son choix de favoriser la précision ou le rappel.

4.4 - Présentation d'un RNC (réseau de neurones convolutifs)

Il existe différents types de réseaux de neurones, nous verrons ici le RNC qui est le plus utilisé dans le cas d'une analyse de tableaux ou de grilles tels que des images (grilles de pixels).

4.4.1 Imitation de la fonction visuelle des mammifères

Les RNC sont inspirés du mécanisme de reconnaissance visuel des mammifères à trois titres :

-Le premier étant que les RNC, comme tous les réseaux de neurones, sont organisés en couches hiérarchisées comme nous l'avons explicité précédemment. C'est également le cas lors du traitement de la vision par le cortex à travers la voie ventrale de la vision [30]. En effet, les signaux provenant de la rétine sont dans un premier temps traités par le corps géniculé latéral elles sont ensuite projetées de manière séquentielle à travers la voie ventrale de la vision dans le cortex visuel V1, V2, V4 et le gyrus temporal inférieur. Chaque séquence apporte des informations de plus en plus complexes (ligne puis formes).

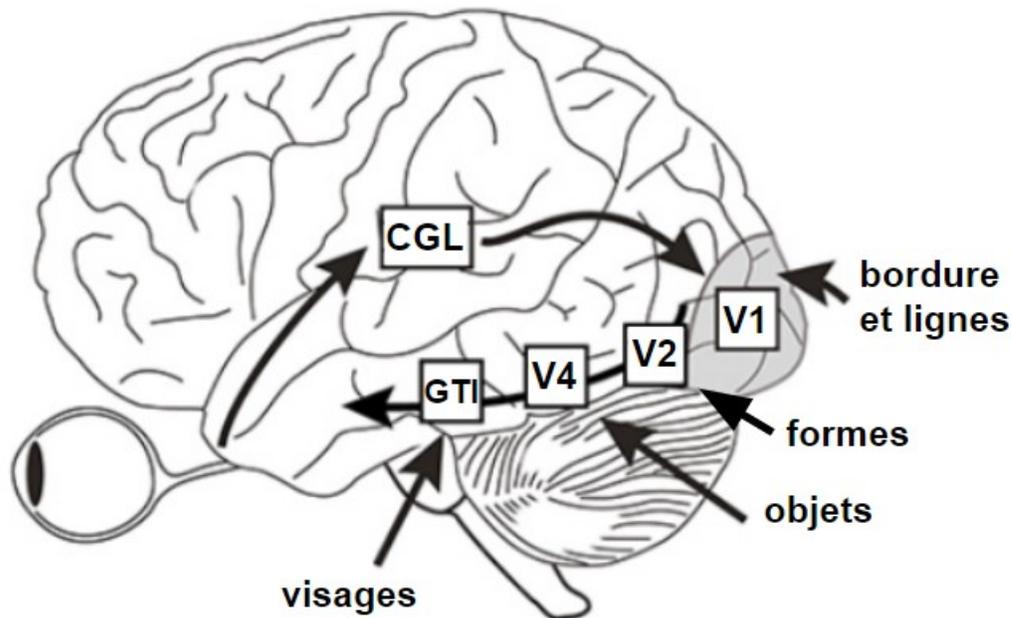


Figure 16 : voie ventrale de la vision dans le cortex [7]

-Le second étant la capacité (appelée *pooling*) du cerveau à agréger et à concentrer des informations reçues, cette caractéristique est également commune avec les RNC et sera détaillée plus tard. Cela est permis grâce à la combinaison de cellules simples et complexes dans le cortex cérébral [31]. Les cellules simples produisent une réponse que si le stimulus est une barre lumineuse d'une orientation donnée et s'il occupe une position précise dans le champ récepteur (à cause d'une zone périphérique inhibitrice). Les cellules complexes quant à elles, combinent les informations transmises par des cellules simples. Elles sont moins sensibles à l'orientation d'un stimulus, et leur activité ne dépend pas de leur position dans le champ visuel.

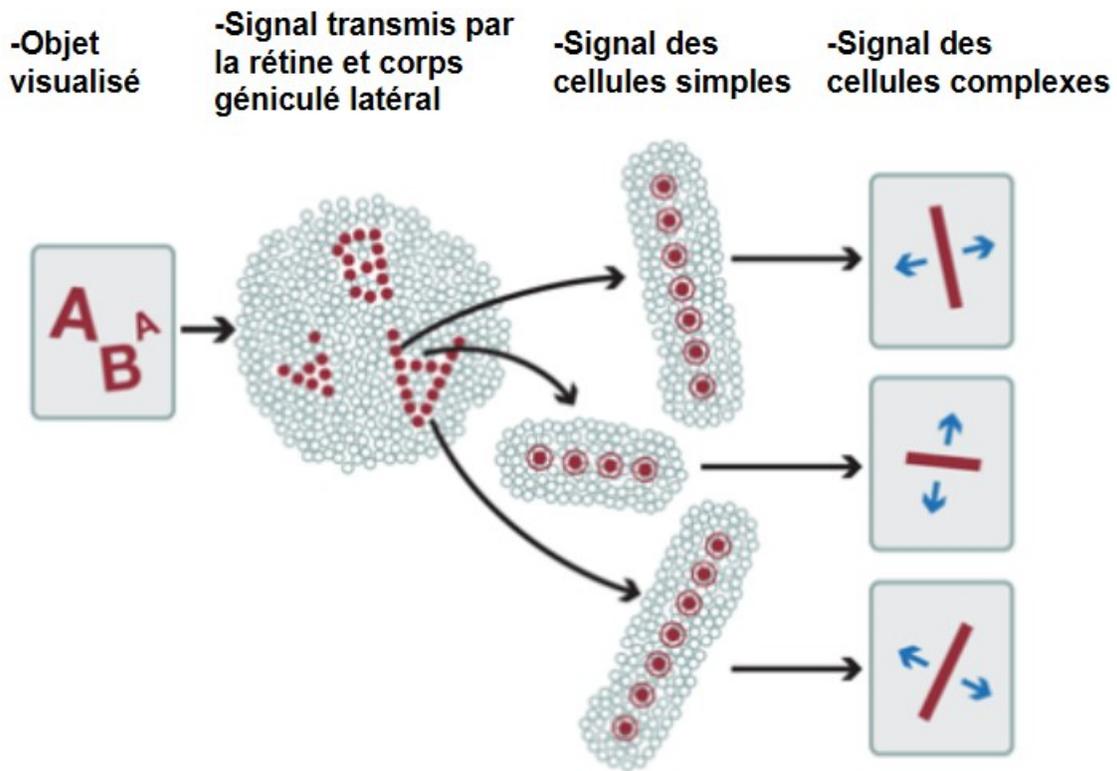


Figure 17 : Organisations entre les cellules simples et complexes [8]

-Enfin, le troisième est la capacité d'apprendre et de s'adapter en fonction de l'expérience soit la plasticité cérébrale. C'est le cas également pour les CNN avec la modification des poids et des biais évoquée précédemment afin de minimiser l'erreur de prédiction. Ce mécanisme étant semblable à la manière dont les connexions neuronales se renforcent ou s'affaiblissent dans le cerveau en réponse aux stimuli.

4.4.2 Présentation de la notion de convolution

Comme leur nom l'indique, les RNC font intervenir des convolutions pour analyser des images.

En mathématiques, le produit de convolution permet la suppression des fluctuations transitoires à travers la formation moyenne glissante (car recalculée de façon continue). Ce produit a comme propriétés d'être bilinéaire, associatif et commutatif.

Entre deux fonctions continues sur le même ensemble réel $E : [a,b]$, le produit de convolution peut être défini de la manière suivante :

$$(f * g)(x) = \int_a^b f(x - t) \cdot g(t) dt$$

Dans le cas de réseau de neurones, les valeurs des fonctions constituent une liste d'entiers L et ne sont pas continues. Dans ce cas, le produit de convolution prend la forme d'une somme :

$$(f * g)(x) = \sum_{x \in L} f(x - t) \cdot g(t)$$

Et dans le cas particulier d'un RNC appliqué à la lecture d'une image I (considérée comme une matrice), la fonction de convolution fait intervenir un noyau bidimensionnel de convolution noté N . Il s'agit d'une matrice bidimensionnelle de taille l (largeur) * h (hauteur) avec $(l, h) \in \mathbb{N}^2$ et $L=H$, elle effectue une moyenne pondérée de l'environnement de chaque pixel. La fonction convolution faisant intervenir deux matrices, la fonction de convolution prends alors la forme d'une double somme :

$$\forall (i, j) \in \mathbb{N}^2, i \leq l \text{ et } j \leq h \quad (I * N)(x) = \sum_{m \leq i} \sum_{n \leq j} I(m, n) * K(i - m, j - n)$$

On peut considérer cette étape de convolution comme l'application d'un filtre dépendant du noyau N . Il y a généralement différents filtres dans chaque réseau de neurones et ils permettent de faire ressortir de l'image des caractéristiques exploitables par le réseau de neurone [28].

Les valeurs de ce filtre sont modifiées par rétropropagation lors de l'entraînement du réseau. Selon le mécanisme exprimé dans la partie 4.2.2 b)

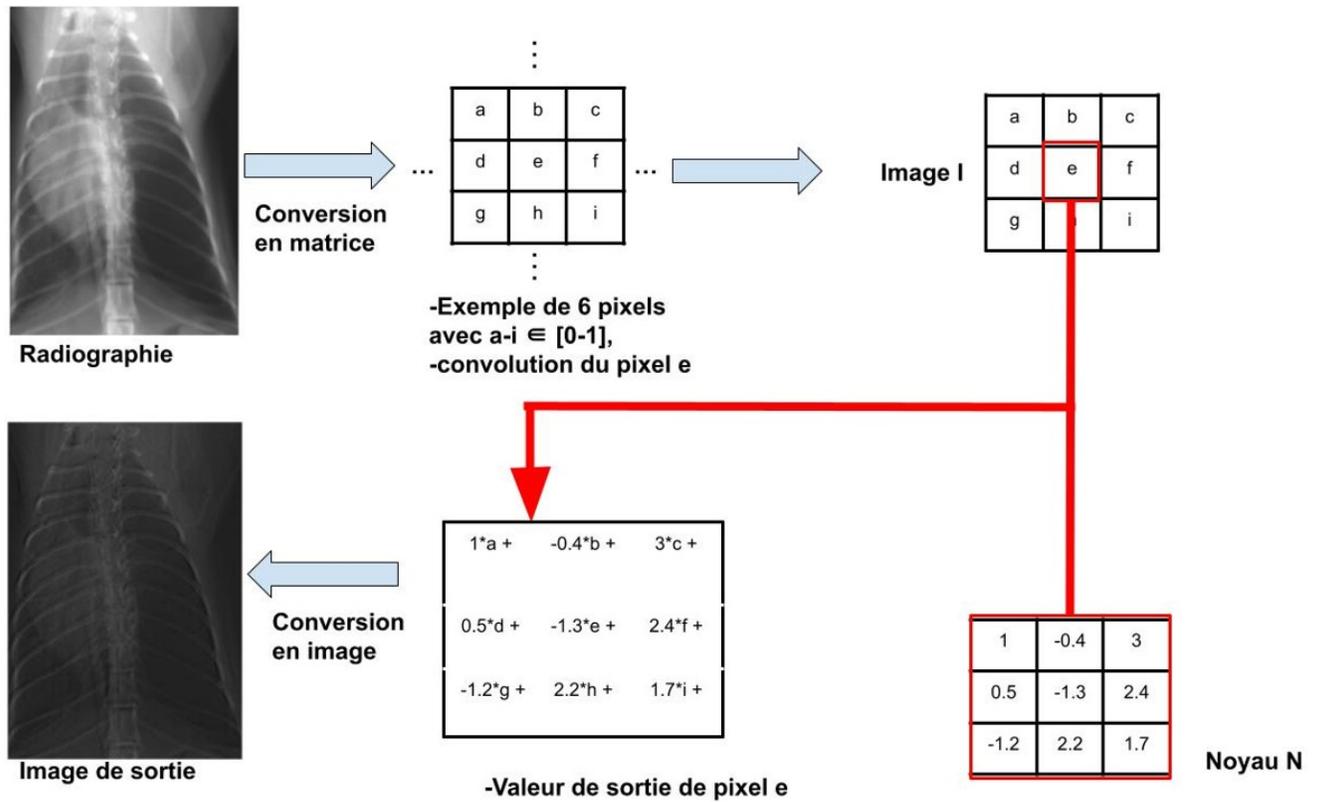


Figure 18 : Exemple de convolution sur un pixel de radiographie

La convolution a pour désavantage de réduire de taille de l'image d'entrée car ses périphéries sont englobées par le noyau. Ce phénomène peut devenir problématique d'autant plus si de multiples convolutions sont réalisées sur la même image.

Une manière de remédier à ce problème est de prolonger les bordures de la matrice initiale par des valeurs nulles. Cette technique s'appelle le "zero padding" [28].

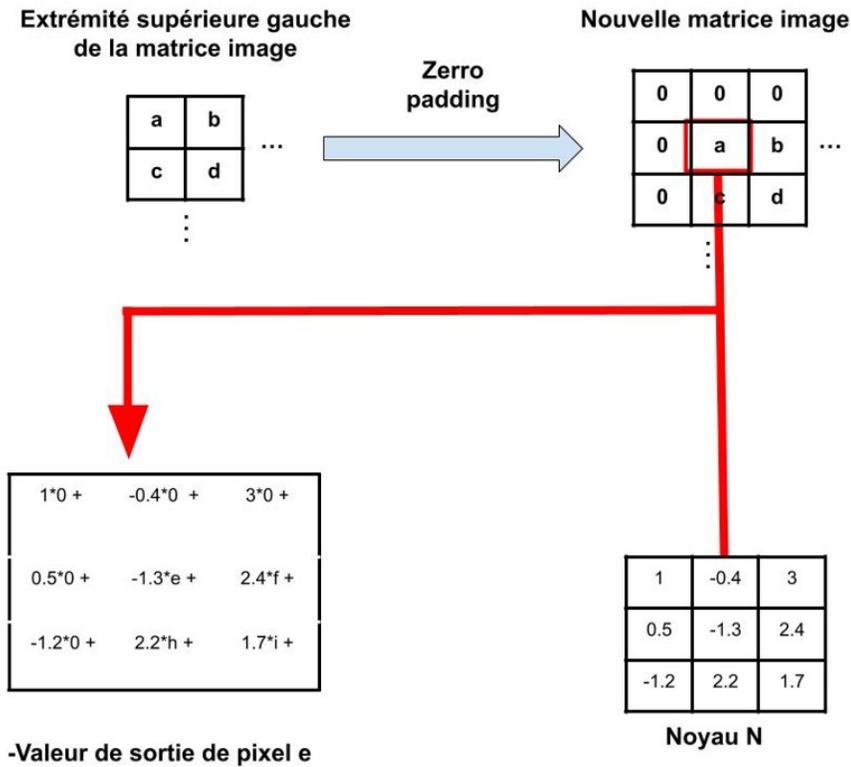


Figure 19 : Méthode du *zero padding*

Les convolutions permettent ainsi, à partir d'une radiographie de créer de nombreuses images de sortie avec des caractéristiques spécifiques

4.4.3 Simplification des données grâce à la fonction *pooling*

L'étape de *pooling* a pour but de réduire la taille des images de convolution et d'en extraire les caractéristiques principales en éliminant localement les légères variations qui peuvent exister [32].

Durant cette étape, une image va être divisé en matrices M de taille 3x3 (dimension usuelles), et chacune de ces matrices (de 3x3 : 9 pixels) sera simplifiée en un pixel. La valeur de ce pixel est fonction de la composition de la matrice, elle peut être déterminée par différentes méthodes [32], les plus communes étant :

-La fonction *max pooling* : le pixel à la valeur la plus forte parmi la de la matrice $F_{max}(M) = \max(x_{i,j})$ avec $(i,j) \in \llbracket 1 - 3 \rrbracket^2$

-La fonction *average pooling* : le pixel est déterminé dans ce cas comme étant la moyenne des valeurs de la matrice $F_{average}(M) = \frac{1}{N} \sum_{i=1, j=1}^3 (x_{i,j})$ avec $(i,j) \in \llbracket 1 - 3 \rrbracket^2$

La fonction *average pooling* a pour désavantage de prendre en compte tous les éléments de la radiographie. Cela peut altérer les caractéristiques majeures de la l'image que la fonction doit prélever. A contrario, la fonction *max pooling* n'a pas ce désavantage du fait de son unique sélection.

Cependant, la fonction *average pooling* a pour avantage le fait que tous les neurones sont activés pour participer à cette moyenne, ils sont tous entraînés par rétro propagation. Ce qui n'est pas le cas de la fonction *max pooling* où le seul neurone entraîné est celui avec le plus fort *output*.

Il convient de noter que la fonction pooling n'est pas toujours présente dans les RNC.

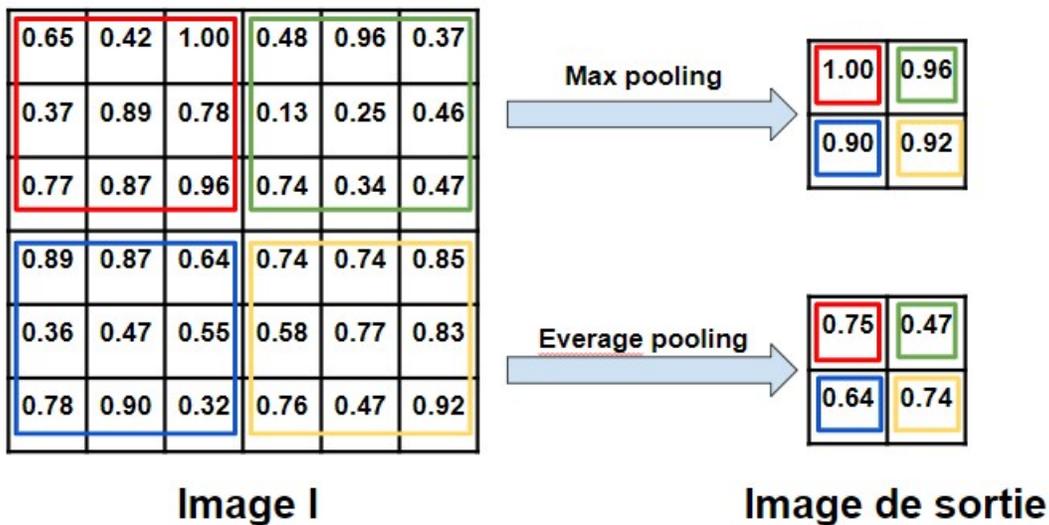


Figure 20 : Exemple de l'application des fonctions *max* et *average pooling* sur une matrice image

4.4.4 Elements constituant un RNC

Maintenant que nous avons abordé des différentes étapes, nous allons présenter l'organisation générale commune à tous les RNC.

-Dans un premier temps, la radiographie va subir un nombre fixé de convolutions produisant de nouvelles images. Celles-ci seront retenues ou non via une fonction ReLU (évoquée dans le Tableau 2). Si l'image est retenue elle sera alors simplifiée par une fonction pooling.

-Ensuite, cette succession d'étapes (1 : convolution - 2 : activation - 3 : pooling) va être répétée un nombre fixé de fois.

-Une fois ces étapes terminées, les informations sont transmises à des couches de neurones qui vont permettre d'analyser les images et de produire l'*outputs* [33].

-L'apprentissage du réseau se fait par rétropropagation.

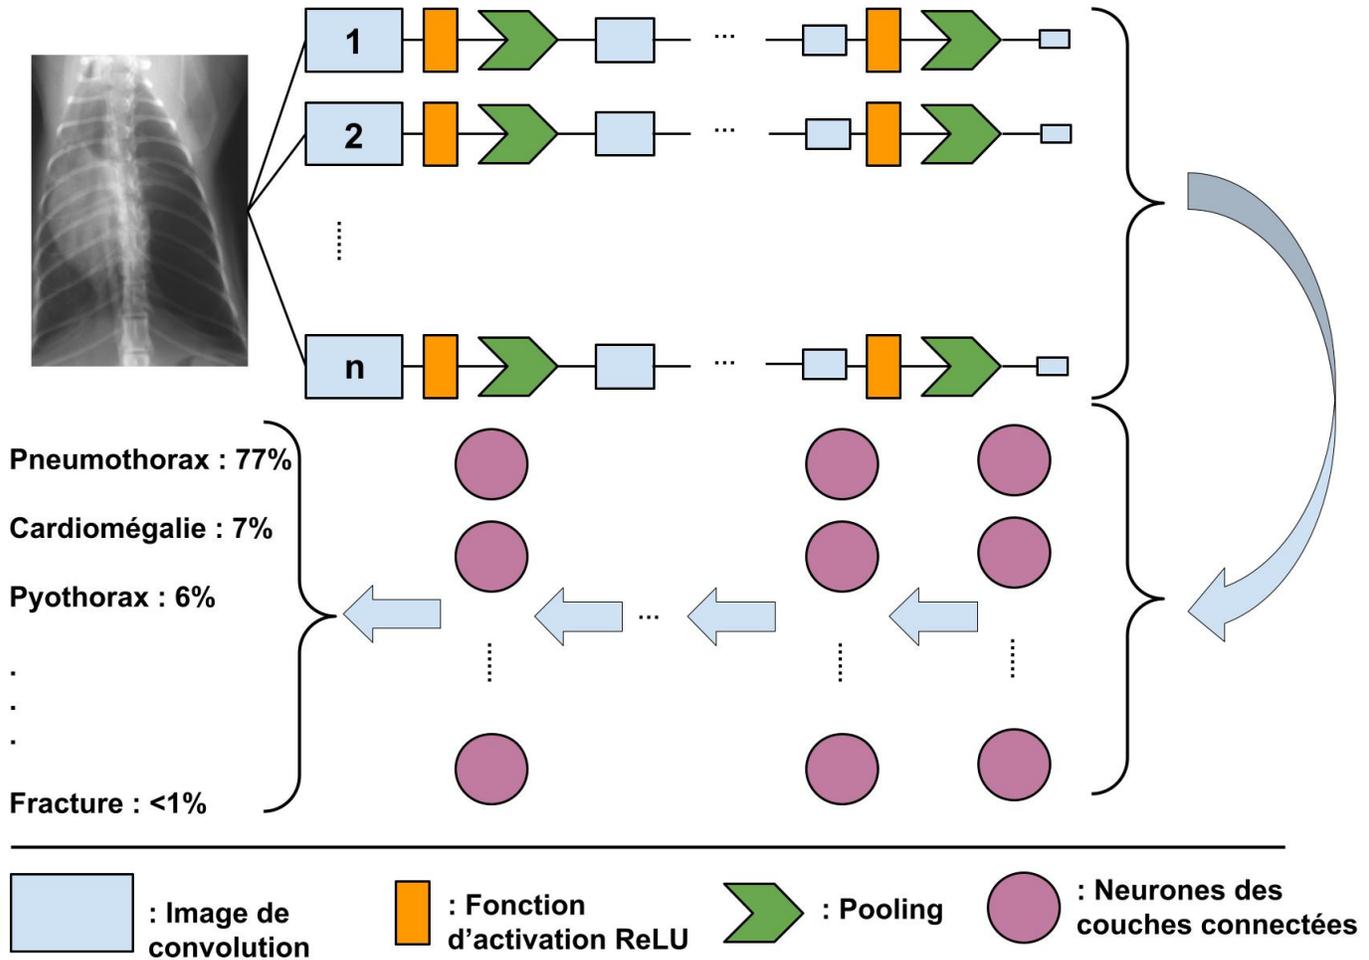


Figure 21 : Organisation générale d'un RNC

4.5- Historique de l'intelligence artificielle employée en radiologie vétérinaire

4.5.1- Première occurrence et ses implications

La première description d'un réseau de neurones appliquée à la radiologie vétérinaire date de 2013. Il consistait à identifier sur une radiographie la présence ou l'absence d'une

articulation coxo-fémorale. Les résultats étaient satisfaisants avec une sensibilité de 86% et une spécificité de 100%. [34]

Cette étude a pour la première fois, mis en évidence que l'intelligence artificielle pouvait également être utilisée en médecine vétérinaire. De plus, ce type de réseau permet l'identification d'une région anatomique. Ce qui constitue la base d'un entraînement de réseau à plus grande échelle en permettant la création d'une dossier de radiographies pour chaque région anatomique sans l'intervention d'un opérateur.

4.5.2- Etat des lieux des applications de l'intelligence artificielle en radiologie vétérinaire

L'utilisation de l'intelligence artificielle dans le domaine de la radiologie vétérinaire est en constante évolution. On peut distinguer deux domaines d'application : le premier étant la reconnaissance d'une région anatomique et le deuxième étant l'identification d'une lésion. La plupart des intelligences artificielles déjà existantes sont résumées dans le tableau 4.

Région anatomique	Application et année de sortie
Appareil musculo squelettique	<p>-2013 : identification de l'articulation coxo-fémorale. [34]</p> <p>-2019 : identification d'os de la phalange de chevaux à partir de données reconstruites numériquement. [35]</p> <p>-2021 : identification et datation de fractures sur des os long de chien. [36]</p> <p>-2021 : deux études sur la détection de la dysplasie des hanches chez le chien. [37] [38]</p>
Thorax	<p>-2020 : Détection d'un élargissement de l'atrium gauche chez le chien. [39]</p> <p>-2020 : Détection de cardiomégalie chez le chien. [40]</p> <p>-2022 : Détection d'un oedeme cardiogénique chez le chien [41]</p> <p>-2022 : Détection d'un épanchement pleural chez le chien [42]</p> <p>-2021 : Détection de la coccidioïdomycose chez le chien [43]</p> <p>-2019 : Détection d'un pattern alvéolaire, bronchique ou interstitiel chez le chien et le chat [44]</p> <p>-2020 : Détection de 15 lésions thoraciques comprenant les opacités pulmonaires, des atteintes de la trachée, du système cardiovasculaire, de la plèvre et la détection des masses pulmonaires chez le chat. [45]</p> <p>-2021 : Détection d'un pattern alvéolaire, bronchique ou interstitiel, d'un mégaoesophage, d'une fracture, d'une hernie, d'un pneumothorax ou pneumomédiastin, et d'emphysème sous cutané chez le chat [46]</p>
Abdomen	<p>-2019 Diagnostic des affections gastro-intestinales (inflammations et obstructions) [47]</p> <p>-2021 : Détection automatique des masses abdominales [48]</p> <p>-2022 : Prédiction de la torsion gastrique chez le chien [49]</p>

Tableau 4 : Application de l'intelligence artificielle à la radiographie vétérinaire

4.5.3- Comparaison entre le niveau d'efficacité de l'intelligence artificielle et celle d'un radiologue

Les études qui ont été réalisées tendent à montrer que actuellement, il existe une équivalence

de niveau entre les intelligences artificielles et l'expertise de radiologues. On observe une légère sur ou sous performance des intelligences artificielles entre les études. Ces dernières se concentrent généralement sur les lésions thoraciques.

Ainsi, une étude réalisée en 2020 [50] a comparé la capacité de détection de 15 lésions thoraciques entre un réseau préalablement entraîné, un groupe de 10 vétérinaires et enfin, un groupe de vétérinaires aidé de l'intelligence artificielle. Les taux d'erreurs étaient alors de 10.7%, 16.8% et 17.2% respectivement. Montrant une légère sur-performance de l'intelligence artificielle.

Néanmoins, une autre étude de 2022 [51] montre quant à elle une légère sous-performance d'un réseau lors de la détection de 5 catégories de lésions thoraciques (parmi les 15 proposés), une sur-performance pour une catégorie de lésion et un niveau d'efficacité équivalent pour la détection des catégories de lésions restantes.

Une autre étude datant de 2021 [52] a montré qu'il existait des niveaux de corrélations très importants lors du calcul de l'indice de buchanan entre un réseau de neurone et un groupe spécialistes en radiologie vétérinaire.

CINQUIÈME PARTIE : Création d'un réseau de dénombrement foetal

5.1 Caractéristiques du modèle

Parmis les différents RNC disponibles, le modèle FCOS (Fully Convolutional One-Stage Object Detection) a été choisi par l'équipe de PICOXIA pour la création d'un programme permettant de dénombrer les foeti sur des radiographies de chienne et de chatte. Proposé par Tian et al. en 2019 [53], ce modèle est actuellement le plus utilisé pour la reconnaissance d'images.

5.1.1 Extractions de l'image des objets

a) Série de convolutions et voie ascendante

L'image analysée va dans un premier temps passer une série de convolutions/pooling appelé *backbone* dans la figure 21.

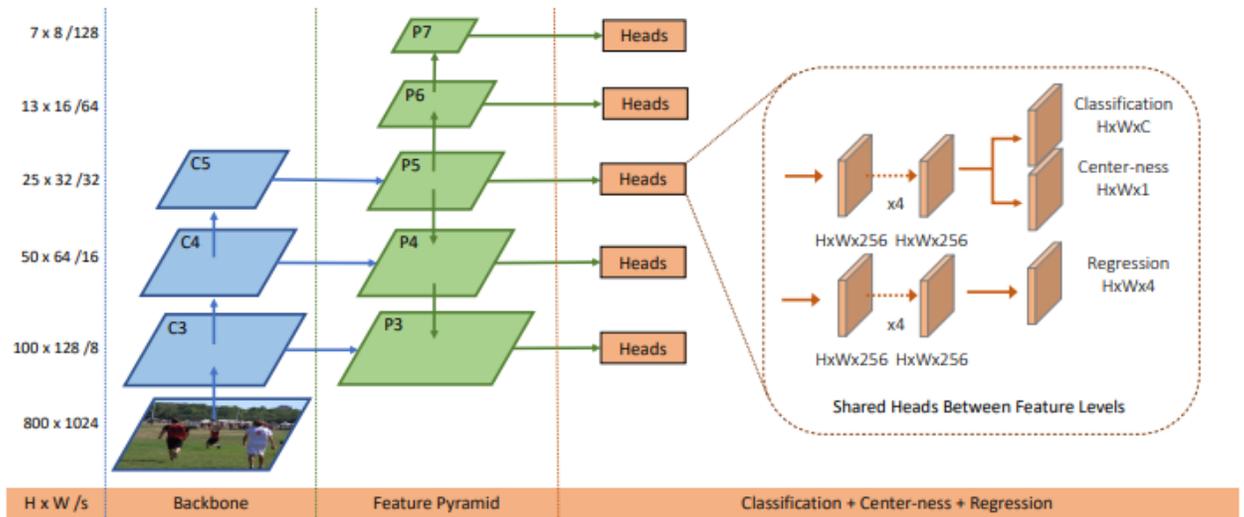


Figure 22 : Organisation générale du modèle FCOS

Avec un nombre de convolutions élevé (C4 ou C5 par exemple) les motifs caractéristiques des objets peuvent être reconnus par le modèle comme expliqué dans la partie 4.3.2, (cela correspond à la "voie ascendante" [42]). Malheureusement, cela ne marche que pour les objets de grande taille car au fil de convolutions, la taille des images diminue rendant difficile la détection des plus petits objets [54]. Ce phénomène est illustré par la figure 23.

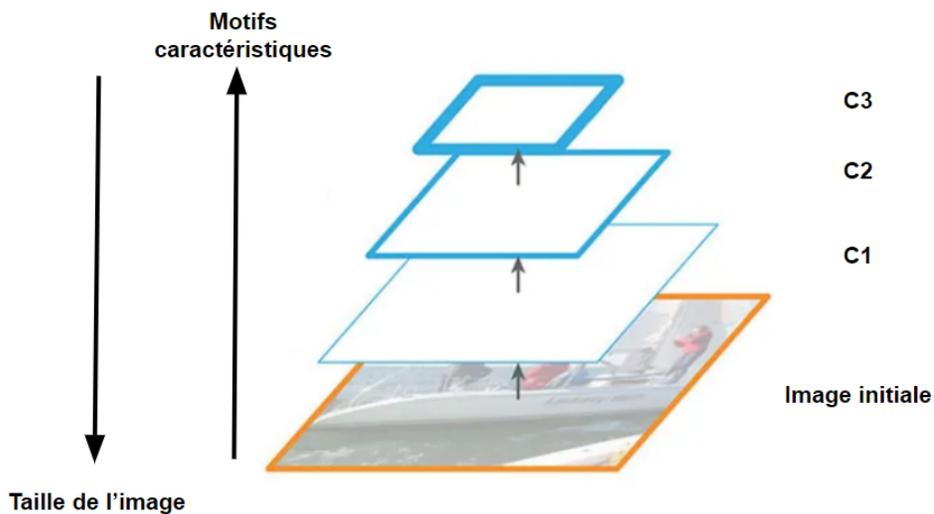


Figure 23 : Voie ascendante et conséquences [9]

b) Voie descendante avec connexion latérales

Pour pallier ce problème, la voie descendante permet de transmettre les motifs caractéristiques

des couches supérieures aux couches inférieures. Cela correspond à la "feature pyramid" de la figure 21.

Dans un premier temps, la couche de convolution la plus élevée du *backbone* ($C(n)$ dans la figure 22) va subir une nouvelle convolution (par un noyau de taille 1×1) pour donner une image $M(n)$, il s'agit de la voie latérale. Puis $M(n)$ va être agrandie et fusionnée avec la convolution (1×1) de $C(n-1)$ pour former $M(n-1)$, et ainsi de suite. Ce qui correspond à la voie descendante.

Enfin, les images $M(x)$ avec $x \in [1 ; n]$ vont subir chacune une convolution 3×3 pour éliminer les artefacts produits lors du processus de fusion. Produisant alors les images de la "feature pyramid" $P(x)$ avec $x \in [1 ; n]$.

Ce mécanisme est illustré dans la figure 23

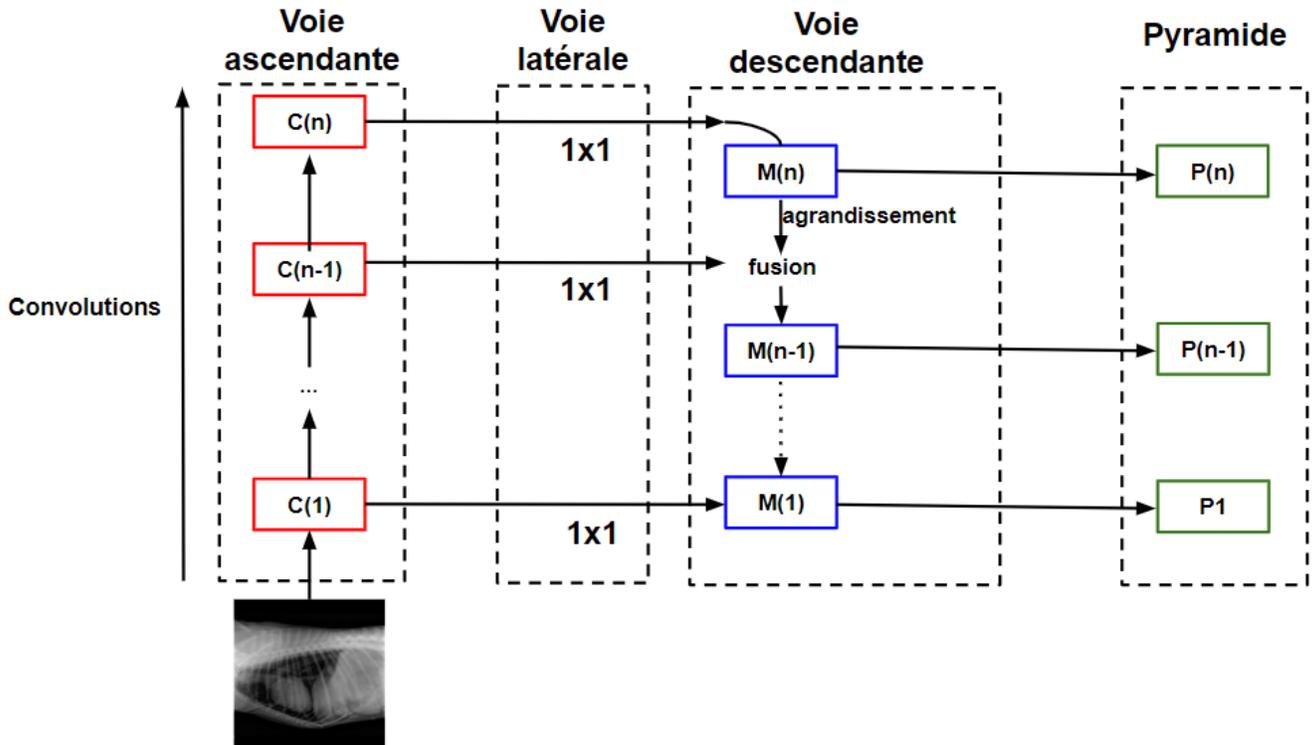


Figure 24 : Voie descendante et connexions latérales

Ce mécanisme permet de fusionner les motifs caractéristiques des images de différentes tailles et ainsi pallier l'échec de la voie ascendante.

Généralement, les nouvelles images permettent les détections suivantes :

- P2 : utilisé pour les petits objets
- P3, P4 : utilisés pour les objets de taille moyenne
- P5 : utilisés pour les objets de grande taille

En combinant toutes les prédictions des différents niveaux, le modèle est capable de détecter les objets de différentes échelles dans une même image.

c) Réseau retenu

Il existe une multitude de combinaisons de voie ascendante et descendante compatibles avec le réseau FCOS avec une variété dans le nombre et le type de convolutions. Nous avons vu le cas général dans les points a) et b).

Dans cette étude, le réseau retenu est le ResNet-50-FPN (couramment utilisé pour la reconnaissance d'image).

Son organisation est présentée dans la figure 25.

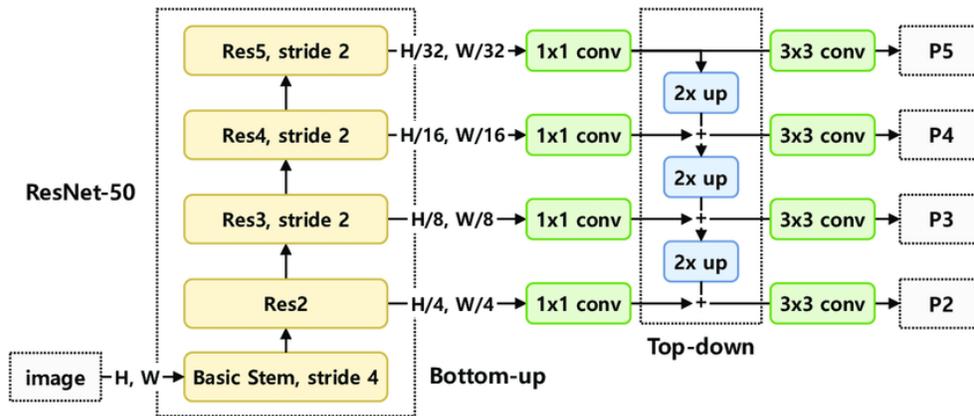


Figure 25 : Structure du ResNet-50-FPN [10]

H : height (hauteur de l'image en pixel)

W : width (largeur de l'image en pixel)

Res x : Image de la convolution x du *backbone*

stride x : max pooling $x \times x$

d) Pré-entraînement du réseau

Lors de son entraînement, les valeurs des matrices de convolutions vont être modifiées par rétropropagation (cf 4.2.2 c)). Cette étape demande beaucoup d'images d'entraînement. Pour réduire ce volume, ces valeurs sont déjà prédéfinies par un pré-entraînement à partir des données COCO (Common Objects in Context). Cet ensemble de données est constitué de 200 000 images annotées pour la détection de plus de 80 classes d'objets (humain, voiture ...). Il permet d'avoir un modèle "préparé" à la reconnaissance d'objets en général.

5.1.2 Reconnaissance et détection des objets

Pour prédire la position des objets (étape appelé head dans la figure 22), les images de la pyramide subissent une série de 4 convolution convolution (3×3), suivie chacune d'une activation ReLU. Trois paramètres sont alors évalués pour chaque pixel de ces images : les coordonnées des boites englobantes, un score de centralité et un score de classification. [53]

a) Coordonnées des boites englobantes

-Pour chaque pixel, une dernière convolution (1x1) permet de donner les dimensions d'un rectangle, comprenant l'objet recherché, par rapport à ce pixel (haut : h, bas : b, gauche : g, droit, d).

-Ainsi pour tout pixel $P_{x,y}$ on :

$$\text{Conv}_{(1*1)}(P_{x,y})=(h_{x,y};b_{x,y};g_{x,y};d_{x,y})$$

-On peut ainsi déterminer les coordonnées de la boite englobante (X_{min} ; X_{max} ; Y_{min} ; Y_{max}) de la manière suivante :

$$X_{min} = x-g$$

$$X_{max} = x+d$$

$$Y_{min} = y-b$$

$$Y_{max} = y+h$$

Ce mécanisme est illustré dans la figure 24. Il convient de noter que dans cet exemple, l'image pas subi de convolution (pour faciliter la compréhension) ce qui n'est pas le cas dans le modèle.

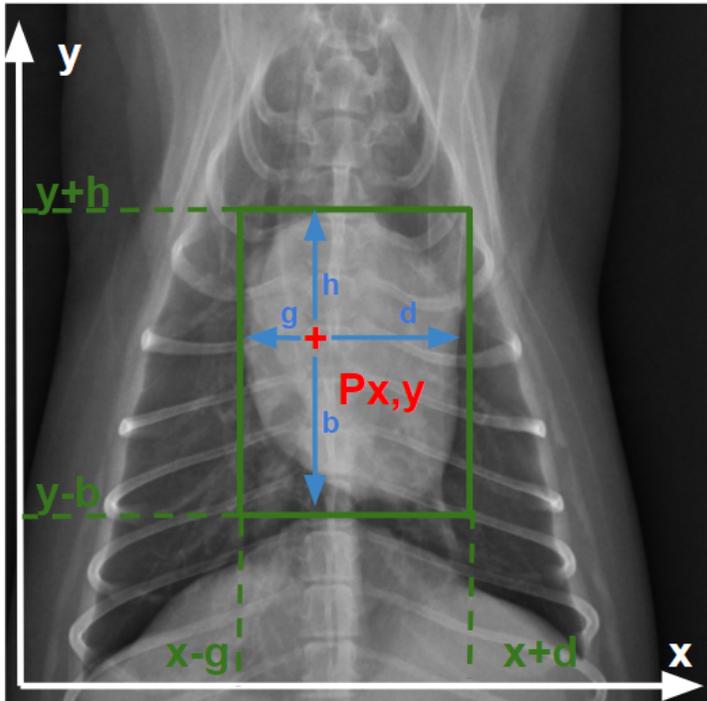


Figure 26 : Boite englobante appliquée à la détection du coeur

b) Score de centralité et de classification

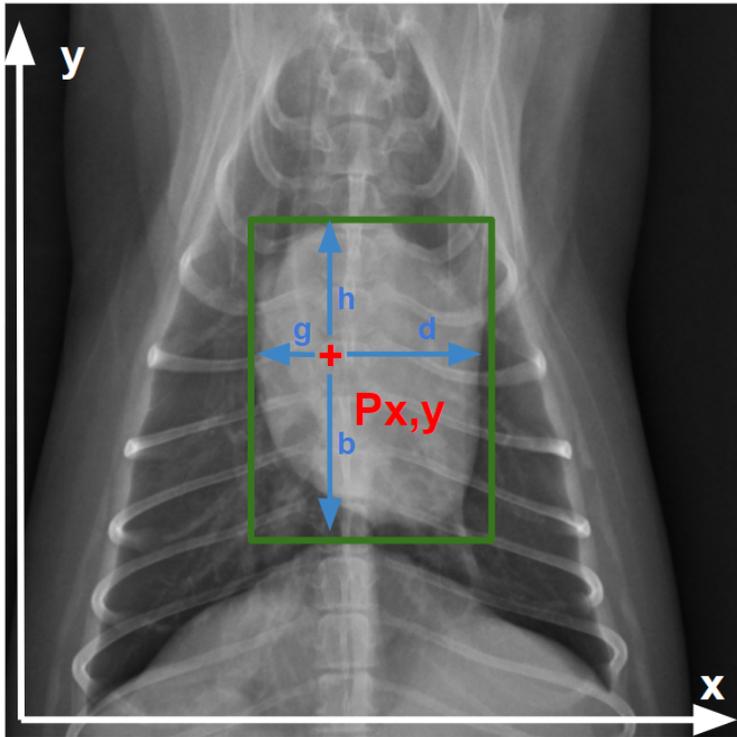
Ces deux scores permettent de prédire si la boite englobante correspond bien à l'objet recherché.

[53]

-Score de centralité :

Ce score vise à donner une indication de la proximité du point au centre de l'objet détecté. Il est compris dans l'intervalle $[0;1]$. Plus ce score est proche de 1, et plus le point est situé au centre de la boite. Il est obtenu en appliquant une dernière convolution (1x1) appliquant la formule suivante :

$$\text{Score de centralité} = \sqrt{\frac{\min(h,b)}{\max(h,b)} * \frac{\min(d,g)}{\max(d,g)}}$$



$d=113$ pixels
 $g= 40$ pixels
 $h= 84$ pixels
 $b=120$ pixels

Score de centralité :

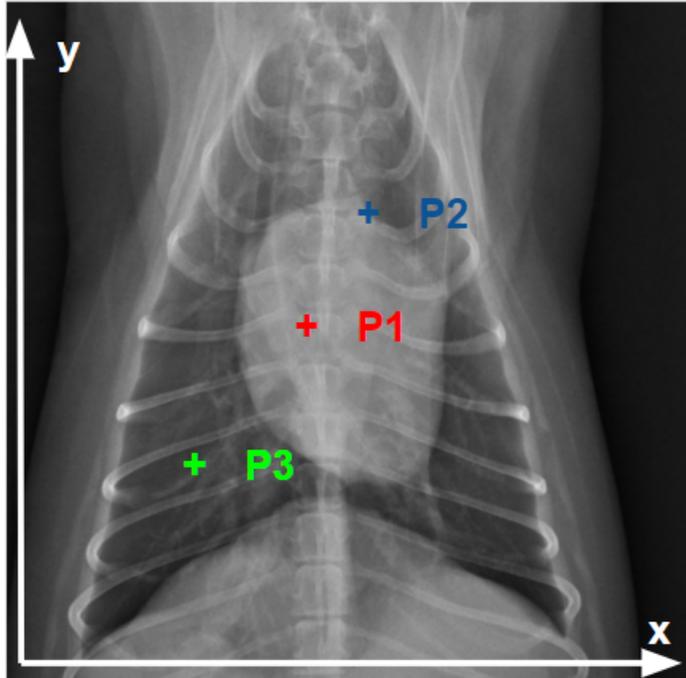
$$\begin{aligned}
 & \sqrt{\frac{\min(h,b)}{\max(h,b)} * \frac{\min(d,g)}{\max(d,g)}} \\
 & = \\
 & \sqrt{\frac{84}{120} * \frac{40}{113}} \\
 & = \\
 & 0.50
 \end{aligned}$$

Figure 27 : Calcul du score de centralité

-Score de classification :

Ce score vise à donner une probabilité pour un pixel d'appartenir à l'objet recherché. Il est compris dans l'intervalle $[0 ;1]$. Plus ce score est proche de 1, et plus le point est susceptible d'appartenir à l'objet. Il est obtenu en appliquant une dernière convolution (1x1) appliquant la fonction sigmoïde (cf tableau 2) :

Score de classification pour un pixel de valeur $x = P(\text{Pixel} \in \text{Objet}) = \frac{1}{1+\exp x}$



Score de classification :

Score(P1) : 0.98

Score(P2) : 0.63

Score(P3) : 0.12

Figure 28 : Exemple de score de classification

c) Filtrage des prédictions des boites englobantes

Les scores calculés lors de la partie b) vont permettre de sélectionner les boites englobantes les plus prometteuses. En effet, si un pixel (formant une boite) est fortement susceptible d'appartenir à la classe de l'objet recherché (score de classification proche de 1) et est au centre de la boite (score de centralité proche de 1), alors la boite englobante est fortement susceptible de contenir l'objet recherché. [53]

On définit ainsi un score total (compris dans l'intervalle [0,1]) comprenant les deux scores :

$$\text{Score total} = \text{Score de classification} * \text{Score de centralité}$$

Les boites englobantes dont la valeur du score total est inférieure à un seuil prédéfini (0.5 dans le cadre de cette étude) sont éliminés :

$$\text{Boite B issue du pixel P} = \begin{cases} \text{retenu si Score final(P)} > \text{seuil} \\ \text{non retenu si Score final(P)} < \text{seuil} \end{cases}$$

Une fois cette première phase réalisée, les boîtes redondantes qui se chevauchent fortement

sont éliminés de la manière suivante :

- Les boîtes sont triées par score de détection décroissant.
- Pour chaque boîte, les boîtes avec une intersection sur union (IoU) supérieure à un seuil (0.5 dans cette étude) sont supprimées.

Les boites restantes constituent les prédictions pour le modèle.

5.1.3 Fonction de coût

Le modèle FCOS utilise plusieurs fonctions de perte pour entraîner le modèle de détection d'objets de manière efficace. La loss function totale pour un modèle FCOS est composée de deux composants [53] :

a) Fonction de coût associé à la position des boites englobantes

La *Bounding Box Regression Loss* ou fonction de coût de régression des boites englobantes permet de mesurer la différence entre les positions réelles des objets définies par l'opérateur et les positions prédites par le modèle. On définit cette fonction de coût C de la manière suivante :

$$C_{regression} = \frac{1}{n} * \sum_{i=1}^n (1 - I/U_i)$$

avec I/U le rapport intersection union explicité dans la partie 4.3.1 a)

et n le nombre de boites englobantes prédites par le modèle

b) fonction de coût associé à la centralité des boites englobantes

La *Centerness loss* ou fonction de coût de centralité des boites englobantes permet de mesurer la distance de la prédiction par rapport au centre de l'objet. L'idée est d'améliorer la précision de la localisation en accordant plus d'importance aux prédictions proches du centre de l'objet. Sa formule fait appel au score de centralité évoqué dans la partie 5.1.2 b)

On a :

$$C_{centerness} = 1 - \text{Score de centralité} = 1 - \sqrt{\frac{\min(g,d)}{\max(g,d)} * \frac{\min(h,b)}{\max(h,b)}}$$

où g,d,h,b sont les distances de la boîte englobante aux bords gauche, droit, supérieur et inférieur respectivement.

c) Fonction de coût globale

La fonction de coût globale, utilisée pour l'optimisation du modèle FCOS est la somme des fonctions évoquées précédemment.

$$C_{total} = C_{regression} + C_{centerness}$$

L'objectif de l'entraînement étant de minimiser cette fonction de coût.

5.2 Formation de la base de données d'entraînement

5.2.1 Caractéristiques des clichés radiographiques fournis pour l'entraînement

Les images radiographiques utilisées dans l'entraînement proviennent des cliniques et cabinets vétérinaires clients de Picoxia.

Dans un premier temps, l'ensemble des images était constitué de 58 clichés pris en incidence ventro-dorsale et 202 en incidence latéro-latérale.

5.2.2 Logiciel d'annotation utilisé

VIA est un logiciel d'accès libre qui permet d'ouvrir un ensemble d'images en format JPEG, de les annoter par des points, des traits ou des formes géométriques. Et enfin, d'exporter ces annotations sous un fichier d'extension csv (comma-separated values). Ce qui permet son ouverture dans un tableur comme Excel. Ce dernier contient un tableau de valeurs des coordonnées (x :y) des différentes annotations.

5.3 Annotation par keypoints et résultats de l'entraînement

La méthode d'annotation par keypoints consiste à identifier des points précis et spécifiques d'intérêt, tels que les coins, les joints, les extrémités. Par l'exemple de la figure 22 Les points sont situés sur le nez, les yeux, les oreilles, les épaules, les coudes, les poignets, les hanches, les genoux et les chevilles. Ces points peuvent être reliés entre eux et forment alors un "squelette" caractéristique de l'image à identifier [40]. Ces keypoints permettent ensuite de définir des zones d'intérêts pour entraîner le modèle. Par exemple dans l'exemple de la figure 22, un disque dont le diamètre est défini comme étant la distance entre les deux oreilles correspond à la tête. Cette surface peut ensuite être exploitée pour entraîner un modèle à reconnaître un homme.



Figure 29 : Annotation d'un homme par réseau de détection par keypoints

Les caractéristiques des points choisis sont :

- L'unicité : ils doivent être uniques et facilement différenciables des autres points.
- L'invariance : le ou les points doivent être visibles sur toutes les images, quelque soit la qualité du cliché ou la rotation de l'objet.
- La répétabilité : la méthode d'annotation doit être autant que possible simple, rapide et peu variable.

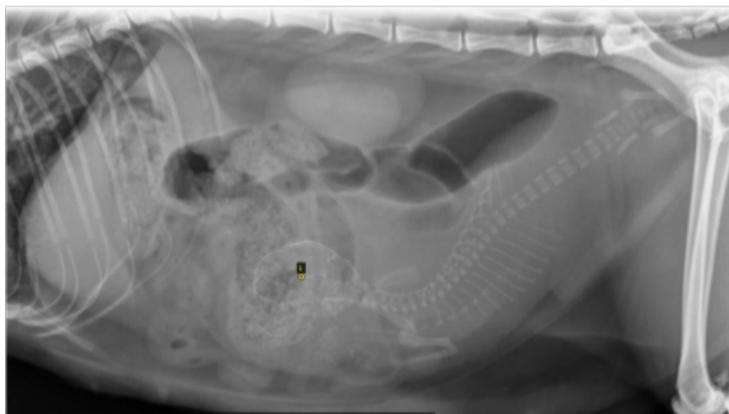
Grâce à ces keypoints des surfaces peuvent être définies pour entraîner le modèle FCOS.

5.3.1 Annotation par keypoint unique

a) Protocole d'annotation des images

Le foetus est marqué par un point au centre de son crâne. De plus, une comparaison du nombre de crânes et de rachis est réalisée pour minimiser le risque de ne pas détecter un foetus. La surface associée pour l'entraînement est un carré de côté 40 pixels centré autour de ce point.

Annotation



Surface d'entraînement

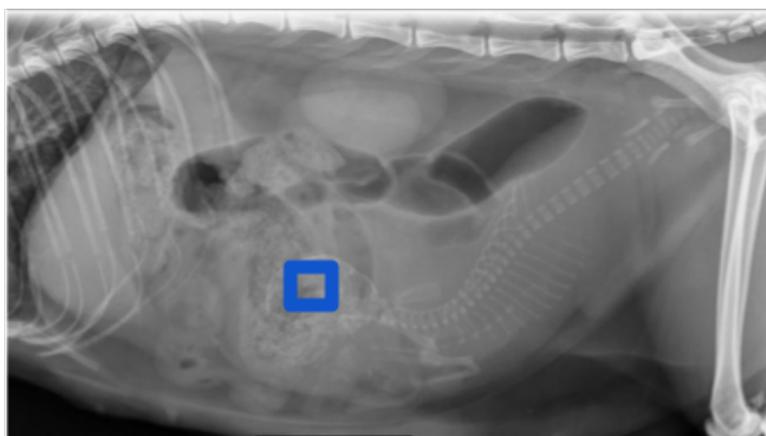


Figure 30 : Annotation d'une radiographie par keypoint unique

Sept images ont été écartés du pool du fait des causes suivantes :

-Crâne engagé dans la filière pelvienne (lors de la mise bas) sur n=2 clichés

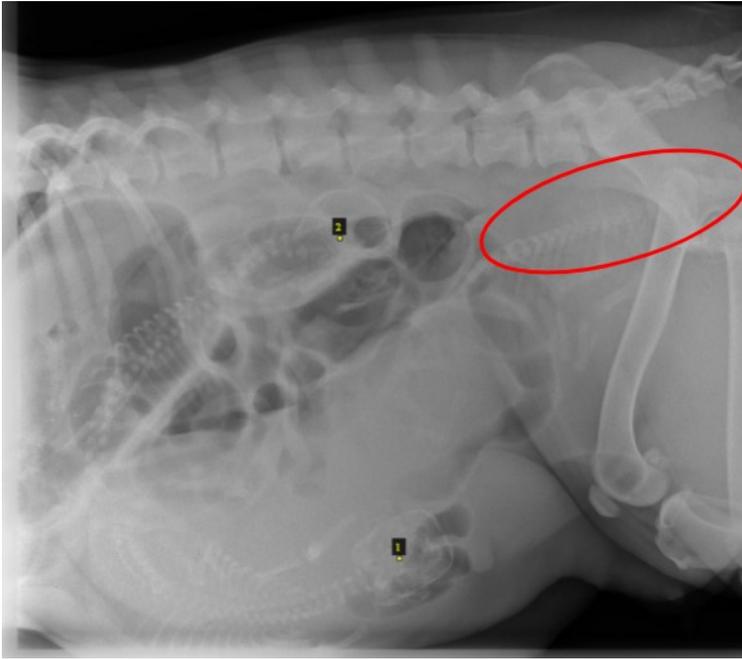


Figure 31 : Foetus engagé dans la filière pelvienne

-Mauvaise qualité de l'image radiographique sur n=3 clichés

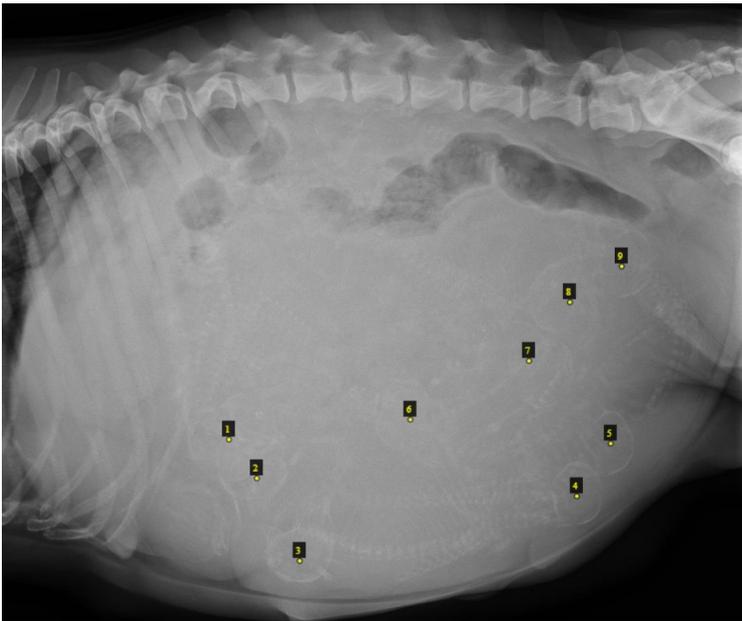


Figure 32 : Exemple de mauvaise qualité du cliché radiographique

-Et enfin, un nombre différents de crânes et de rachis sur le cliché

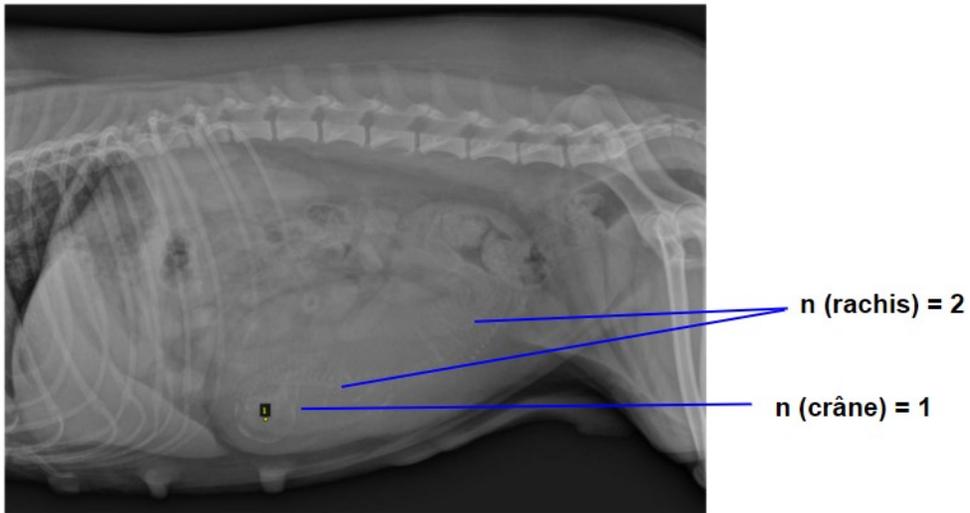


Figure 33 : Inadéquation entre les crânes et les rachis

n=4 clichés

b) Pool final d'apprentissage

Une fois la phase de tri et d'annotation terminée, un pool de n = 251 images a été retenue pour la suite de l'étude.

Les caractéristiques du pool d'image sont résumées dans l'histogramme suivant :

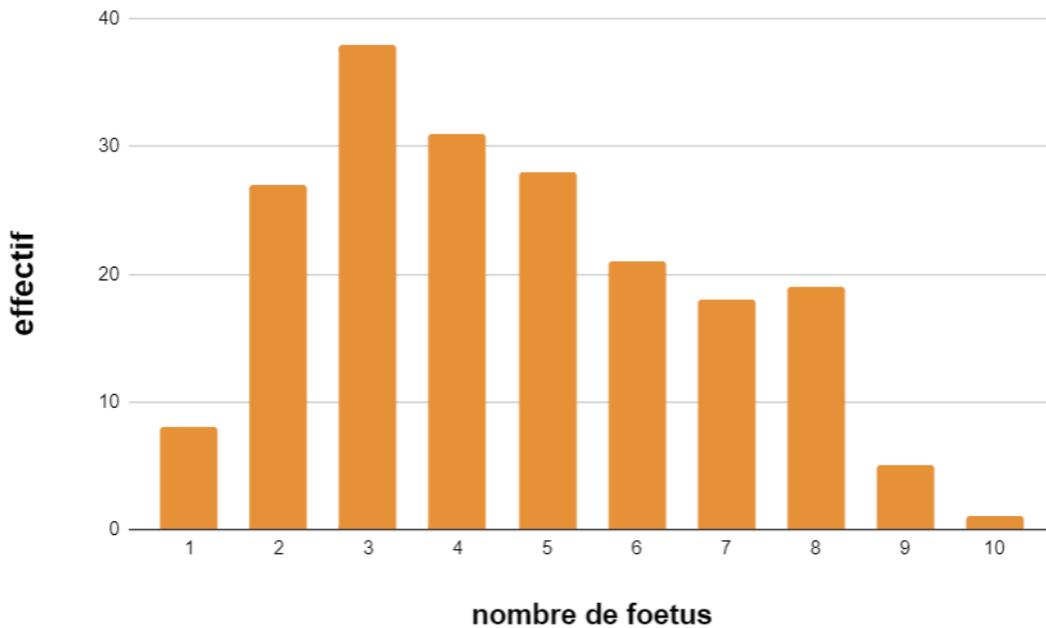


Figure 34 : Répartition des radiographies de gestation

Parmi ces radiographies, 108 ont été utilisées pour entraîner le modèle et 25 pour le tester.

c) Analyse des résultats

Les résultats de cette première méthode n'a pas apporté des résultats satisfaisants. L'average précision étant bien inférieure à la valeur seuil de 0.5 cf 4.3.1 d).

Métrique	Valeur
Précision	0.81
Rappel	0.88
Average precision	0.43

Tableau 5 : Métriques du modèle par keypoint unique

Les principales anomalies rencontrées sont :

-Multiple annotation du même crâne, dans l'exemple de la figure 28 les deux crânes les plus caudaux ont été décomptés deux fois. Les carrés bleus correspondent aux bounding box de l'entraînement et les rouges aux celles prédites par le modèle.

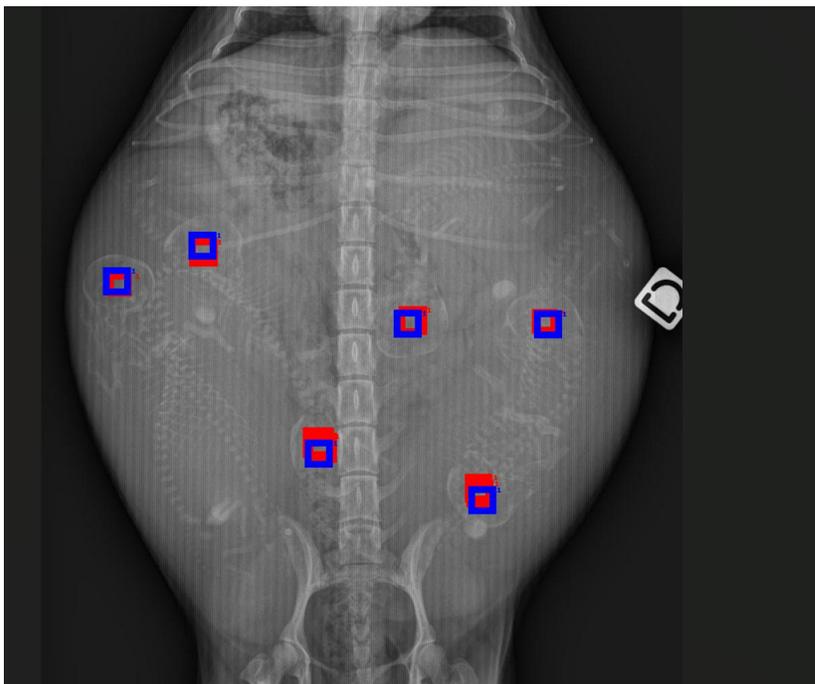


Figure 35 : Multiples annotations du même crâne.

-Confusion entre des zones radio opaques (principalement des vertèbres) et des crânes.

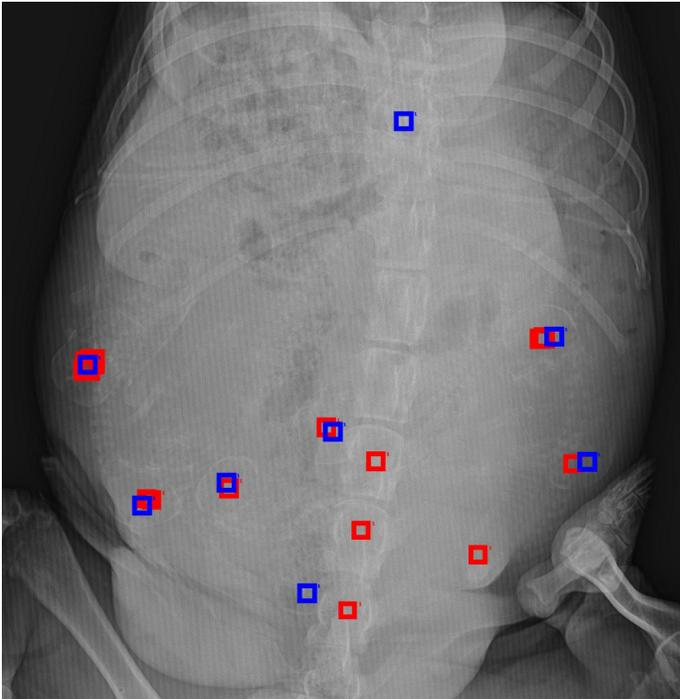


Figure 36 : Annotations excédentaires de vertèbres

5.3.2) Annotation par association de classes.

Compte tenu des mauvais résultats de la méthode précédente, une nouvelle approche a été tentée pour mieux caractériser l'image des foetus

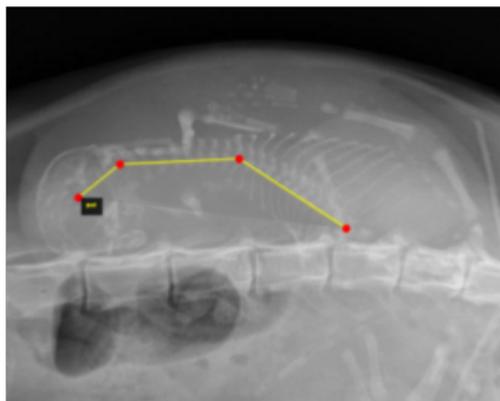
a) Protocole d'annotation des images

Le fœtus est marqué par 4 points formant une ligne brisée. Le premier se situe au centre du crâne, le deuxième au niveau de l'articulation atlanto-occipitale, le troisième au niveau de la première vertèbre thoracique et le quatrième au niveau de la dernière vertèbre thoracique. Le but de cette méthode est d'associer deux motifs caractéristiques du fœtus : le crâne et la cage thoracique.

Grâce à ces annotations, deux surfaces d'entraînement ont été caractérisées :

- Le crâne : carré de côté $2.2 \times$ distance entre les deux premiers points
- Le thorax : rectangle dont la diagonale est formée par les deux derniers points avec une marge de 50 pixels

Annotation



Surface d'entraînement

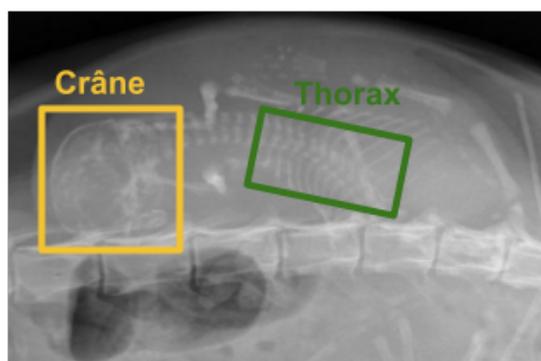


Figure 37 : Annotation d'une radiographie par keypoint en squelette

54 images ont été écartées du pool, principalement du fait de la difficulté d'association des crânes et des cages thoraciques lors de la superposition des fœtus. Ce phénomène était d'autant plus accentué quand la qualité du cliché radiographique était médiocre.

b) Pool final d'apprentissage

Une fois la phase de tri et d'annotation terminée, un pool de $n = 206$ images a été retenue pour la suite de l'étude.

Les caractéristiques du pool d'image sont résumées dans l'histogramme suivant :

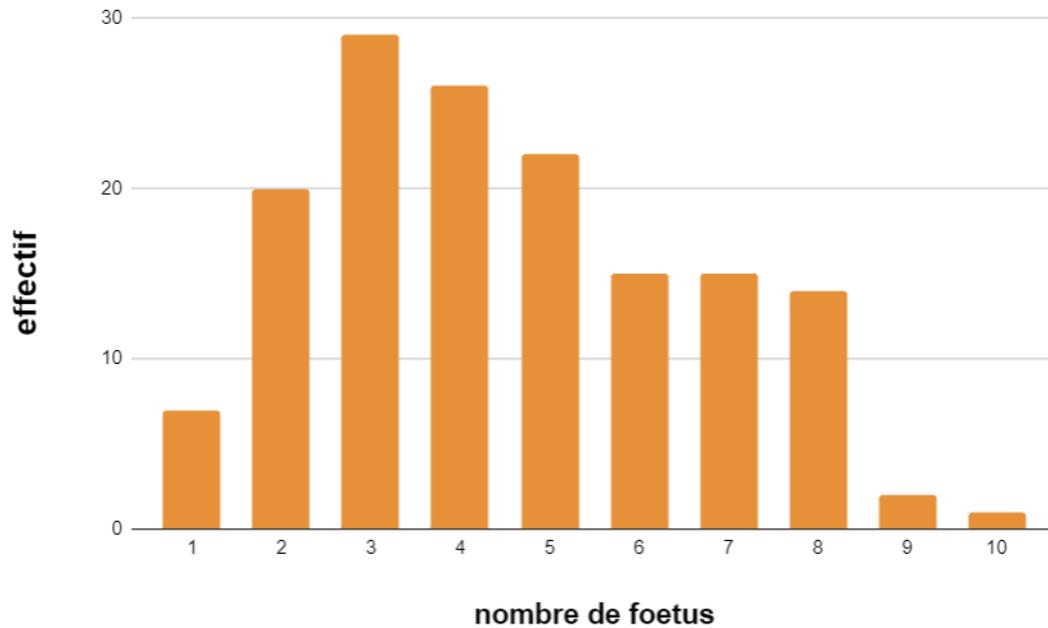


Figure 38 : Répartition des radiographies de gestation

Parmi ces radiographies, 156 ont été utilisées pour entraîner le modèle et 50 pour le tester.

c) Analyse des résultats

Métrique	Valeur crâne	Valeur thorax
Précision	0.88	0.72
Rappel	0.85	0.61
Average precision	0.45	0.38

Tableau 6 : Métriques du modèle par keypoint unique

Les résultats obtenus par cette technique ne sont pas satisfaisants. En effet, le réseau confond facilement les zones osseuses rondes et les bulles de gaz avec des cranes de fœtus. Il n'est pas capable non plus d'identifier les cranes trop recouverts par le bassin ou la colonne vertébrale.

Concernant les cages thoraciques, l'identification est encore plus laborieuse car elles sont généralement plus radio transparente que le crâne (donc moins visibles) et présentent des formes très variables (du fait de la rotation des foeti).

5.3.3- Annotation du crâne

Nous avons vu dans la méthode décrite dans la partie 5.3.2 que la détection des cages thoraciques était très laborieuse pour le modèle. Pour pallier ce handicap seuls les crânes ont été retenus pour identifier les fœti. Mais contrairement à la méthode 5.3.1, toute la surface d'un crâne est sélectionné pour entraîner le modèle.

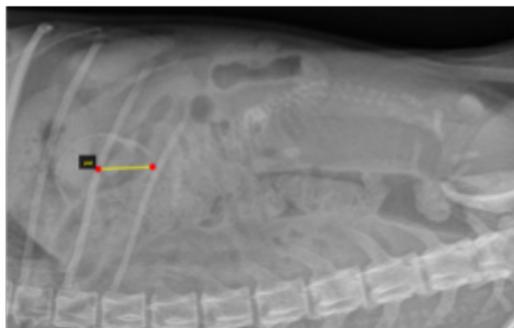
Pour résumer, la méthode est similaire à la partie 5.3.2 mais les cages thoraciques sont exclus.

Plus d'images ont été annotées pour améliorer les performances du modèle par rapport aux versions précédentes.

a) Protocole d'annotation des images

Le crâne est délimité par un carré de côté $2.2 * \text{distance centre du crâne} - \text{base du crâne}$ (similaire à la partie 5.3.2).

Annotation



Surface d'entraînement

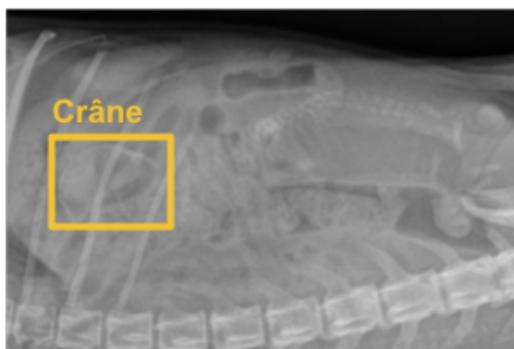


Figure 39 : Annotation d'un crâne

b) Protocole de sélection des images

La première version du programme présentée dans la partie 5.3.2 nous a permis d'effectuer une présélection. Parmi les nouvelles radiographies, celles qui ont été correctement labélisées par cette première version n'ont pas été retenues car elles ne permettent pas au modèle de s'entraîner sur des images plus difficiles, et donc de progresser.

Ainsi, en plus des 206 radios de l'entraînement précédents, un nouveau pool de 498 radios de gestation a été présélectionné afin d'obtenir une masse de donnée d'entraînement suffisante.

Parmi ces nouvelles images, 175 ont été écartées du pool, principalement du fait de la difficulté de distinction des crânes (associé à une qualité radiographique médiocre).

c) Pool final d'apprentissage

Une fois la phase de tri et d'annotation terminée, un pool de $n = 529$ images a été retenue pour la suite de l'étude.

Les caractéristiques du pool d'image sont résumées dans l'histogramme suivant :

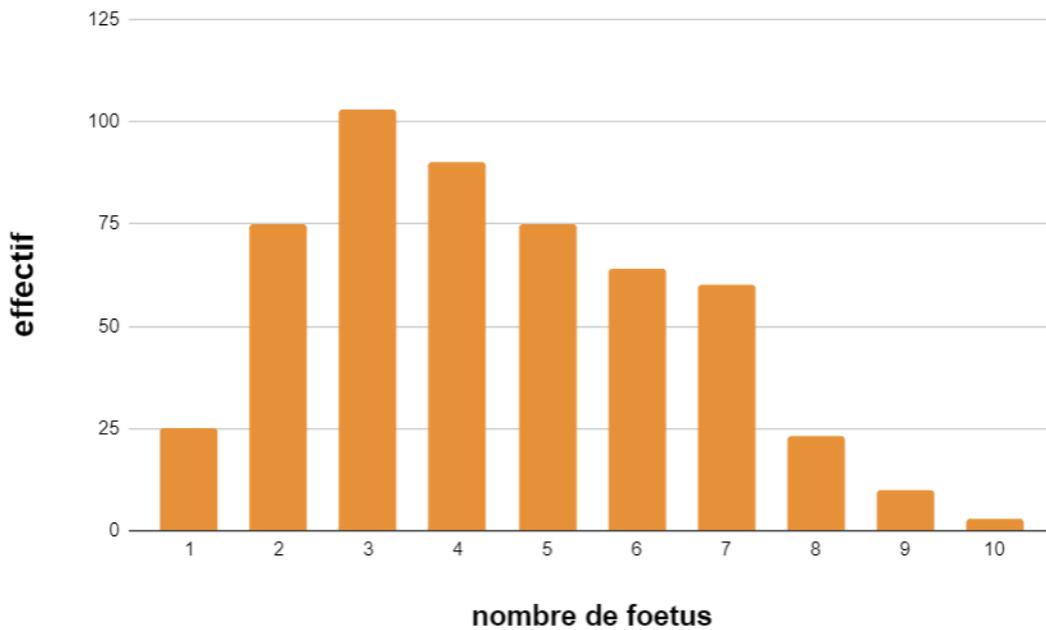


Figure 40 : Répartition des radiographies de gestation

Parmi ces radiographies, 429 ont été utilisées pour entraîner le modèle et 100 pour le tester.

d) Analyse des résultats

Métrique	Valeur
Précision	0.95
Rappel	0.89
Average precision	0.65

Tableau 7 : Métrique du modèle de détection des crânes

Cette fois-ci, grâce à l'augmentation du pool d'apprentissage les résultats du modèle sont satisfaisants (Average précision > 0.5 cf 4.3.1 d). Cependant, ils sont encore insuffisants pour une utilisation commerciale (cf 6.2)

SIXIEME PARTIE : Discussion et critique

6.1- Pool de radiographies et annotations

Dans cette partie , nous discuterons des différents biais (matériels et humains) rencontrés dans l'entraînement du modèle.

6.1.1- Qualité des images radiographiques

Durant cette étude, nous avons utilisé des radiographies provenant de la base de donnée de PICOXIA. Celle-ci étant alimentée par des vétérinaires praticiens.

Cela a eu pour conséquences une très grande variabilité dans la qualité des clichés qui ont été utilisés lors de l'entraînement. Les principaux défauts rencontrés concernent les constantes inadaptées (tension, intensité, temps d'exposition), une rotation de l'abdomen ou une mauvaise préparation de la femelle (colon rempli).

Cela a permis au modèle une certaine plasticité quant à la qualité des images. Ouvrant donc la possibilité de son déploiement chez des vétérinaires praticiens.

Cependant, la mauvaise qualité des radiographies a probablement entraîné des erreurs d'annotations, malgré l'exclusion des clichés les plus problématiques.

6.1.2- Biais d'opérateurs

Durant cette étude, j'ai réalisé les annotations puis un membre de l'équipe de PICOXIA réalisait une relecture.

Notre expérience en la matière étant limitée, il aurait été préférable de faire appel à des vétérinaires plus expérimentés, voire spécialisé en imagerie pour réaliser les annotations.

6.2- Performances du modèle

Durant cette étude, le dernier modèle présentait une average precision de 0.65 (cf 5.3.3) d) cette valeur étant supérieure à 0.5 le programme peut être considéré comme performant.

Cependant, les équipes de PICOXIA considèrent que pour une utilisation commerciale, le rappel (capacité à ne pas oublier de foeti) doit être supérieur à 0.95, or il est de 0.89 pour l'instant.

6.3- Perspectives

6.3.1- Amélioration du modèle existant

a) Qualité des annotations

Comme évoqué dans la partie 6.1.2) il faudrait idéalement confier l'intégralité des annotations des radiographies à un ou un groupe de vétérinaire spécialisé en imagerie médicale.

Cependant, cela peut sembler compliqué d'un point de vue financier et logistique. Une solution intermédiaire pourrait être de laisser une personne peu expérimentée réaliser les annotations et faire effectuer une relecture par un vétérinaire spécialiste.

b) Performances du modèle

Nous avons vu dans la partie 6.2) qu'une valeur de rappel supérieure à 0.95 est nécessaire pour la mise sur le marché du modèle.

La manière la plus simple d'améliorer cette métrique semble être d'augmenter le nombre d'images d'entraînement. En effet, entre la partie 5.3.2 et 5.3.3, la valeur de rappel est passée de 0.85 à 0.89 grâce à l'augmentation du nombre d'images. C'est la solution qui est actuellement retenue par PICOXIA pour la suite de ce projet.

Pour limiter le nombre de nouvelles radiographies d'entraînement, une solution pourrait être de créer artificiellement de nouvelles images considérées comme difficile (donc susceptible de faire grandement progresser le modèle). Cette fabrication de nouvelles images consisterait à superposer l'image d'un fœtus dans des zones de l'abdomen dans lesquels le dénombrement est difficile. Par exemple, superposer le fœtus avec des vertèbres, le colon ou d'autres foeti.

6.3.2- Création d'un nouveau modèle

Comme nous l'avons évoqué dans la partie 3.3.2 quand un radiologue cherche à dénombrer des foeti, il compare le nombre de crânes et de rachis. Le programme de la partie 5.3.2) reprend cette méthodologie.

Cette méthode n'a finalement pas été retenue, car les performances de détection du thorax/colonne vertébrale n'étaient pas satisfaisantes.

Cependant, l'idée initiale permettrait effectivement de limiter les erreurs. Par exemple, si le crâne d'un fœtus n'est pas détectable, la localisation de sa cage thoracique permettrait un dénombrement correct.

Il faudrait dans ce cas augmenter considérablement le nombre d'images d'entraînement (comme exprimé dans la partie 6.3.1) b)) pour obtenir des métriques de détection du thorax similaires à ceux du crâne.

CONCLUSION

L'objectif de cette étude était de créer un programme pouvant dénombrer avec précision des foeti sur des radiographies de chienne ou de chatte.

Le modèle FCOS (Fully convolutional One-stage objet détection) reconnu pour son efficacité dans la reconnaissance d'objets a été retenu. Après une série de convolutions, il prédit les positions les plus probables des objets recherchés sous la forme de rectangles au sein de l'image initiale.

Après plusieurs tentatives infructueuses, dénombrer les crânes pour en déduire le nombre de foeti nous a paru la méthode la plus efficace. C'est ainsi que sur plus de 400 radiographies de gestation, les positions des crânes ont été délimités par un opérateur pour l'entraînement.

Enfin, les performances associées à ce modèle (précision, rappel et *average precision*) ont été calculés en testant le modèle sur 150 radiographies. Celles-ci sont correctes pour une première version mais doivent être améliorés pour une utilisation commerciale en clinique vétérinaire.

Cette évolution doit passer par l'annotation de nouvelles radiographies d'entraînement jusqu'à obtenir l'efficacité souhaité.

L'apparition et la diffusion de ces programmes nous interroge sur la place laissé au vétérinaire dans le diagnostic et les soins apportés à ses patients. Est-ce qu'ils ne vont pas à l'avenir diminuer la valeur du praticien sur le marché ?

J'ai tendance à considérer que ce ne sera pas le cas tant que la majorité des vétérinaires restera polyvalente. Alternant entre la médecine, la chirurgie, l'anesthésie, la radiologie ou encore l'échographie, une diminution de la valeur ajoutée dans un ou plusieurs de ces domaines ne remettra pas en cause la place centrale des praticiens généralistes.

Bibliographie

- [1] CLAPARÈDE, Édouard. L'éducation fonctionnelle. 1931.
- [2] NACCAHE, Lionel. Parlez-vous cerveau ?. Paris : Odile Jacob, 2017.
- [3] DETIENNE, Marcel et VERNANT, Jean-Pierre. Les ruses de l'intelligence : la mètis des Grecs. Paris : Flammarion, 1989.
- [4] AI Magazine. Vol. 27, no 4, 2006.
- [5] ALPAYDIN, Ethem. Introduction to Machine Learning. 3e éd. Cambridge, MA : MIT Press, 2014. (Adaptive Computation and Machine Learning).
- [6] ZEMOURI, Ryad, DEVALLAND, Christine, VALMARY-DEGANO, Séverine et ZERHOUNI, Noureddine. Intelligence artificielle : quel avenir en anatomie pathologique ? Neural network : A future in pathology ? 2019.
- [7] FUKUSHIMA, Kunihiko. Neocognitron : A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. Biological Cybernetics, 1980, vol. 36, no 4.
- [8] THEODORIDIS, Sergios. Neural Networks and Deep Learning. In : Machine Learning : A Bayesian and Optimization Perspective. 2e éd. London : Academic Press, 2020.
- [9] CHELLAPILLA, Kumar, et al. High performance convolutional neural networks for document processing. In : Proceedings of the 10th International Workshop on Frontiers in Handwriting Recognition, 2006.
- [10] MCKINNEY, Scott M., SIENIEK, Marcin, GODBOLE, Vivek, et al. International evaluation of an AI system for breast cancer screening. Nature. 2020, vol. 577. [11] BORREGO-SOTO, Gissela, ORTIZ-LÓPEZ, Rocío et ROJAS-MARTÍNEZ, Augusto. Ionizing radiation-induced DNA injury and damage detection in patients with breast cancer. Journal of Cancer Research and Therapeutics, 2015, vol. 11, no 2.
- [12] WHAITES, Eric et DRAGE, Nicholas. Radiographie et radiologie dentaire. 5e éd. Paris : Elsevier Masson, 2014.
- [13] BUSHBERG, Jerrold T. Exposition aux rayonnements et contamination radioactive. Paris : Lavoisier, 2012.
- [14] HAN, Mi Ah et KIM, Jin Hwa. Diagnostic X-ray exposure and thyroid cancer risk : Systematic review and meta-analysis. Thyroid, 2018, vol. 28, no 2.
- [15] Health Effects of Exposure to Low Levels of Ionizing Radiation : Beir V. Washington,

D.C. : National Academies Press, 1990.

[16] ROOT KUSTRITZ, Margaret V. Pregnancy diagnosis and abnormalities of pregnancy in the dog. *Theriogenology*, 2005, vol. 64, no 4.

[17] PRETZER, Susan D. Canine embryonic and fetal development : A review. *Theriogenology*, 2008, vol. 70, no 3.

[18] BECCAGLIA, M., ALONGE, S., TROVO, C. et LUVONI, G. C. Determination of gestational time and prediction of parturition in dogs and cats : An update. *Reproduction in Domestic Animals*, 2016, vol. 51, no S1.

[19] JOHNSON, C. A. Glucose homeostasis during canine pregnancy : Insulin resistance, ketosis, and hypoglycemia. *Journal of Veterinary Internal Medicine*, 2008, vol. 22, no 3.

[20] THRALL, Donald E. (ed.). *Textbook of Veterinary Diagnostic Radiology*. 6e éd. St. Louis : Elsevier, 2012.

[21] PEY, Pascaline et LÉVY, Xavier. Place de l'imagerie dans la datation de la gestation. *Le Point Vétérinaire*, n° 301, 01/12/2009.

[22] TOAL, Robert L., WALKER, Michael A. et HENRY, George A. A comparison of real-time ultrasound, palpation and radiography in pregnancy detection and litter size determination in the bitch. *Journal of the American Veterinary Medical Association*, 1986, vol. 189, no 1.

[23] TAVEAU, Cyrielle, BONTE, Tancrede et ROSSET, Émilie. Conduite à tenir lors d'un syndrome du chiot unique. *Le Point Vétérinaire*, 2020.

[24] BRUNELLE, F. et BRUNELLE, P. Intelligence artificielle et imagerie médicale : définition, état des lieux et perspectives. *Journal of Radiology*, 2018.

[25] VANCAPPEL, Kévin. *Machine Learning : comprendre ce qu'est un réseau de neurones et en créer un!* [en ligne]. 2019. Disponible sur : <https://example.com> (consulté le 10 septembre 2024).

[26] STATISTICA. *Concepts fondamentaux en statistique : réseaux de neurones*. [en ligne]. Disponible sur : <https://example.com> (consulté le 10 septembre 2024).

[27] HESPEL, Adrien-Maxence, ZHANG, Youshan et BASRAN, Parminder S. Artificial intelligence 101 for veterinary diagnostic imaging. *Veterinary Radiology Ultrasound*, 2020.

[28] YAMASHITA, Rikiya, NISHIO, Mizuho, DO, Richard Kinh Gian et TOGASHI, Kaori. Convolutional neural networks : an overview and application in radiology. *Radiology*,

2018.

[29] AHMED, Nisha Arya. Mean Average Precision (mAP) : A Complete Guide [en ligne]. Kili Technology, 2024. Disponible sur : <https://kili-technology.com/data-labeling/machine-learning/mean-average-precision-map-a-complete-guide> (consulté le 18 août 2024).

[30] CONNOR, Charles E., BRINCAT, Scott L. et PASUPATHY, Anitha. Transformation of shape information in the ventral pathway. *Nature Reviews Neuroscience*, 2007.

[31] LINDSAY, Grace W. Convolutional Neural Networks as a Model of the Visual System : Past, Present, and Future. *Journal of Cognitive Neuroscience*, 2021.

[32] NIRTHIKA, Rajendran, MANIVANNAN, Siyamalan, RAMANAN, Amirthalingam et WANG, Ruixuan. Pooling in convolutional neural networks for medical image analysis : A survey and an empirical study. *Medical Image Analysis*, 2021.

[33] ALZUBAIDI, Laith, ZHANG, Jinglan, HUMAIDI, Amjad J. et al. Review of deep learning : Concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 2021.

[34] MCEVOY, Fintan J. et AMIGO, José M. Using machine learning to classify image features from canine pelvic radiographs : Evaluation of partial least squares discriminant analysis and artificial neural network models. *Veterinary Radiology Ultrasound*, 2019.

[35] VAN HOUTTE, Jeroen, BAZRAFKAN, Shabab, VANDENBERGHE, Filip et al. A deep learning approach to horse bone segmentation from digitally reconstructed radiographs. *Frontiers in Veterinary Science*, 2020.

[36] ERGÜN, Gülnur Begüm et GÜNEY, Selda. Classification of canine maturity and bone fracture time based on X-ray. *Journal of Veterinary Science*, 2020.

[37] MCEVOY, Fintan J., PROSCHOWSKY, Helle F., MÜLLER, Anna V. et al. Deep transfer learning can be used for the detection of hip joints in pelvis radiographs and the classification of their hip dysplasia status. *PLOS ONE*, 2020.

[38] GOMES, Daniel Adorno, ALVES-PIMENTA, Sofia et FILIPE, Vítor M. Predicting canine hip dysplasia in X-ray images using deep learning. *Artificial Intelligence in Veterinary Science*, 2021.

[39] LI, Shen, WANG, Zigui, VISSER, Lance C., WISNER, Erik R. et CHENG, Hao. Pilot study : Application of artificial intelligence for detecting left atrial enlargement on canine thoracic radiographs. *Veterinary Radiology Ultrasound*, 2021.

[40] BURTI, S., OSTI, V. Longhin, ZOTTI, A. et BANZATO, T. Use of deep learning to detect cardiomegaly on thoracic radiographs in dogs. *Veterinary Radiology Ultrasound*, 2021.

[41] KIM, Eunbee, FISCHETTI, Anthony J., SREETHARAN, Pratheev et al. Comparison of artificial intelligence to the veterinary radiologist's diagnosis of canine cardiogenic pulmonary edema. *Veterinary Radiology Ultrasound*, 2022.

[42] MÜLLER, Thiago Rinaldi, SOLANO, Mauricio et TSUNEMI, Mirian Harumi. Accuracy of artificial intelligence software for the detection of confirmed pleural effusion in thoracic radiographs in dogs. *Veterinary Radiology Ultrasound*, 2021.

[43] OTT, Jordan, BRUYETTE, David, ARBUCKLE, Cody et al. Detecting pulmonary coccidioidomycosis with deep convolutional neural networks. *PLOS ONE*, 2020.

[44] ARSOMNGERN, Pattaramanee, NUMCHAROENPINIJ, Nichakorn et al. Computer-Aided Diagnosis for Lung Lesion in Companion Animals from X-ray Images Using Deep Learning Techniques. *Veterinary Radiology Ultrasound*, 2021.

[45] BANZATO, Tommaso, WODZINSKI, Marek, TAUCERI, Federico et al. An AI-Based Algorithm for the Automatic Classification of Thoracic Radiographs in Cats. *Veterinary Radiology Ultrasound*, 2021.

[46] BANZATO, Tommaso, WODZINSKI, Marek, TAUCERI, Federico et al. An AI-Based Algorithm for the Automatic Classification of Thoracic Radiographs in Cats. *Veterinary Radiology Ultrasound*, 2021.

[47] RAMESH, S. et al. AI-assisted diagnostics in gastrointestinal diseases in veterinary patients are growing, with algorithms detecting patterns indicative of obstructions or infections. *Veterinary Medicine Research*, 2019.

[48] KRINIDIS, Stelios et al. AI-based systems have shown promising results in mass detection and segmentation in veterinary abdominal imaging. *Veterinary Medical Imaging*, 2021.

[49] SCHWARTZ, E. et al. AI can enhance early detection of GDV by analyzing abdominal radiographs for key indicators of this life-threatening condition. *Journal of Veterinary Science*, 2022.

[50] BOISSADY, Emilie, DE LA COMBLE, Alois, ZHU, Xiaojuan et HESPEL, Adrien-Maxence. Artificial intelligence evaluating primary thoracic lesions has an overall lower error

rate compared to veterinarians or veterinarians in conjunction with the artificial intelligence. *Veterinary Radiology Ultrasound*, 2021.

[51] HESPEL, Adrien-Maxence et BOISSADY, Emilie. Comparison of error rates between four pretrained DenseNet convolutional neural network models and 13 board-certified veterinary radiologists when evaluating 15 labels of canine thoracic radiographs. *Veterinary Radiology Ultrasound*, 2021.

[52] BOISSADY, Emilie, DE LA COMBLE, Alois, ZHU, Xiajuan, ABBOTT, Jonathan et HESPEL, Adrien-Maxence. Comparison of a deep learning algorithm vs. humans for vertebral heart scale measurements in cats and dogs shows a high degree of agreement among readers. *Veterinary Radiology Ultrasound*, 2021.

[53] TIAN, Zhi, SHEN, Chunhua, CHEN, Hao et HE, Tong. FCOS : Fully Convolutional One-Stage Object Detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2019.

[54] LIN, Tsung-Yi, DOLLAR, Piotr, GIRSHICK, Ross et al. Feature Pyramid Networks for Object Detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2020.

[55] PETRAKIS, Georgios et PARTSINEVELOS, Panagiotis. Keypoint Detection and Description through Deep Learning in Unstructured Environments. *Journal of Artificial Intelligence Research*, 2021.

[56] ALZUBAIDI, Laith, ZHANG, Jinglan, HUMAIDI, Amjad J. et al. Review of deep learning : Concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 2021.

Sources images

[1] RAYONNEMENT ÉLECTROMAGNÉTIQUE [en ligne]. Wikipedia. Disponible sur : <https://fr.wikipedia.org/wiki/Rayonnement>

[2] CPGEMAROC. Paramètres influant sur l'image en radiologie. [en ligne]. 2018. Disponible sur : <http://cpgemaroc.com/cnc/ph2mp/eph2mp2018.pdf>.

[3] PARAMÈTRES INFLUANT L'IMAGE EN RADIOLOGIE [en ligne]. DocPlayer. Disponible sur : <https://docplayer.fr/75876693-Parametres-influant-l-image-en-radiologie.html>.

[4] Pregnancy Ultrasound and X-Ray. Weldrik Animal Hospital. [en ligne]. Disponible sur : <https://www.weldrikanimalhospital.com/>.

[5] RUET-BOIREAU, Laure. Gestion et prévention des dystocies canines et félines. Le

Point Vétérinaire, 2022.

[6] HOLLOWAY, Andrew et MCCONNELL, Fraser, éd. BSAVA Manual of Canine and Feline Radiography and Radiology : A Foundation Manual. BSAVA, 2017.

[7] MSAIL. CNN and Human Visual System [en ligne]. Disponible sur : <https://msail.github.io/post/cnn>

[8] RAJ, Priyanka. PHYSIOLOGY OF VISION. Journal of Optometry, 2021.

[9] LIN, Tsung-Yi, DOLLAR, Piotr, GIRSHICK, Ross et al. Feature Pyramid Networks for Object Detection. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020.

[10] LEE, Inwoong et al. An Efficient Human Instance-Guided Framework for Video Action Recognition. IEEE Transactions on Multimedia, 2022.

Résumé

Dénombrement foetal sur des radiographies de gestation de chienne et de chatte par une intelligence artificielle

Raphaël COUBE

Déjà présente dans l'imagerie médicale appliquée à l'homme, l'intelligence artificielle commence depuis quelques années à se développer dans le même champ de la médecine vétérinaire. Ces outils permettent de limiter les erreurs de diagnostic et de faciliter le travail des praticiens. Dans cet esprit, cette étude a permis de développer un programme de dénombrement foetal sur radiographies.

Pour arriver à ce résultat, sur 529 radiographies de gestation, les positions des crânes des fœti ont été délimités par des rectangles. 429 de ces radiographies ont été utilisées pour entraîner un modèle et les 100 restantes pour le tester. Les performances finales sont prometteuses (avec notamment une précision de 0.95 et un rappel de 0.89) mais insuffisantes pour une utilisation commerciale.

On peut raisonnablement penser qu'un programme performant pourrait voir prochainement jour, notamment en ajoutant des radiographies d'entraînement.

Summary

Fetal counting on pregnancy radiographs of dogs and cats using artificial intelligence

Raphaël COUBE

Already present in medical imaging applied to humans, artificial intelligence has been developing in the field of veterinary medicine for the past few years. These tools help to reduce diagnostic errors and facilitate the work of practitioners. In this spirit, this study aimed to develop a fetal counting program using radiographs.

To achieve this result, the positions of the fetal skulls were outlined with rectangles on 529 pregnancy radiographs. 429 of these radiographs were used to train a model, and the remaining 100 were used to test it. The final performance is promising (with an accuracy of 0.95 and a recall of 0.89) but insufficient for commercial use.

It is reasonable to believe that an efficient program could emerge soon, particularly by adding more training radiographs