



Faculté de médecine

Année 2022/2023

N°

## Thèse

Pour le

### DOCTORAT EN MEDECINE

Diplôme d'État

par

**Aurélié LECANU**

Née le 23 avril 1994 à Paris (75)

---

#### TITRE

Intérêt de l'échographie couplée à l'intelligence artificielle pour la détection et la caractérisation des lésions hépatiques bénignes et malignes : une étude exploratoire

---

Présentée et soutenue publiquement le 17 Novembre 2023 devant un jury composé de :

Président du Jury : Professeur Thierry LECOMTE, Hépatogastro-entérologie, Faculté de Médecine – Tours

Membres du Jury :

Docteur Romain CHAUTARD, Hépatogastro-entérologie, CCA, Faculté de Médecine – Tours

Docteur Anaïs JAILLAIS, Hépatogastro-entérologie, PH, CHU – Tours

Docteur Jérôme ROUMY, Biophysique et médecine nucléaire, MCU-PH, Faculté de Médecine – Tours

**Directrice de thèse : Professeure Laure ELKRIEF, Hépatogastro-entérologie, Faculté de Médecine- Tours**

UNIVERSITE DE TOURS  
**FACULTE DE MEDECINE DE TOURS**

**DOYEN**

**Pr Patrice DIOT**

**VICE-DOYEN**

Pr Henri MARRET

**ASSESEURS**

Pr Denis ANGOULVANT, *P dagogie*

Pr Mathias BUCHLER, *Relations internationales*

Pr Theodora BEJAN-ANGOULVANT, *Moyens – relations avec l'Universit *

Pr Clarisse DIBAO-DINA, *M decine g n rale*

Pr Fran ois MAILLOT, *Formation M dicale Continue*

Pr Patrick VOUREH, *Recherche*

**RESPONSABLE ADMINISTRATIVE**

Mme Carole ACCOLAS

\*\*\*\*\*

**DOYENS HONORAIRES**

Pr Emile ARON (†) – 1962-1966

*Directeur de l'Ecole de M decine - 1947-1962*

Pr Georges DESBUQUOIS (†) – 1966-1972

Pr Andr  GOUAZE (†) – 1972-1994

Pr Jean-Claude ROLLAND – 1994-2004

Pr Dominique PERROTIN – 2004-2014

**PROFESSEURS EMERITES**

Pr Daniel ALISON

Pr Gilles BODY

Pr Philippe COLOMBAT

Pr Etienne DANQUECHIN-DORVAL

Pr Luc FAVARD

Pr Bernard FOUQUET

Pr Yves GRUEL

Pr G rard LORETTE

Pr Lo c VAILLANT

**PROFESSEURS HONORAIRES**

P. ANTHONIOZ – P. ARBEILLE – A. AUDURIER – A. AUTRET – C. BARTHELEMY – J.L. BAULIEU – C. BERGER – JC. BESNARD – P. BEUTTER – C. BONNARD – P. BONNET – P. BOUGNOUX – P. BURDIN – L. CASTELLANI – J. CHANDENIER – A. CHANTEPIE – B. CHARBONNIER – P. CHOUTET – T. CONSTANS – C. COUET – L. DE LA LANDE DE CALAN – P. DUMONT – J.P. FAUCHIER – F. FETISSOF – J. FUSCIARDI – P. GAILLARD – G. GINIES – D. GOGA – A. GOUDEAU – J.L. GUILMOT – O. HAILLOT – N. HUTEN – M. JAN – J.P. LAMAGNERE – F. LAMISSE – Y. LANSON – O. LE FLOCH – Y. LEBRANCHU – E. LECA – P. LECOMTE – AM. LEHR-DRYLEWICZ – E. LEMARIE – G. LEROY – M. MARCHAND – C. MAURAGE – C. MERCIER – J. MOLINE – C. MORAIN – J.P. MUH – J. MURAT – H. NIVET – D. PERROTIN – L. POURCELOT – R. QUENTIN – P. RAYNAUD – D. RICHARD-LENOBLE – A. ROBIER – J.C. ROLLAND – P. ROSSET – D. ROYERE – A. SAINDELLE – E. SALIBA – J.J. SANTINI – D. SAUVAGE – D. SIRINELLI – J. WEILL

## PROFESSEURS DES UNIVERSITES - PRATICIENS HOSPITALIERS

---

ANDRES Christian.....	Biochimie et biologie moléculaire
ANGOULVANT Denis .....	Cardiologie
APETOH Lionel.....	Immunologie
AUPART Michel.....	Chirurgie thoracique et cardiovasculaire
BABUTY Dominique .....	Cardiologie
BACLE Guillaume.....	Chirurgie orthopédique et traumatologique
BAKHOS David.....	Oto-rhino-laryngologie
BALLON Nicolas.....	Psychiatrie ; addictologie
BARBIER François.....	Médecine intensive et réanimation
BARILLOT Isabelle .....	Cancérologie ; radiothérapie
BARON Christophe .....	Immunologie
BEJAN-ANGOULVANT Théodora .....	Pharmacologie clinique
BERHOUEZ Julien .....	Chirurgie orthopédique et traumatologique
BERNARD Anne .....	Cardiologie
BERNARD Louis .....	Maladies infectieuses et maladies tropicales
BLANCHARD-LAUMONNIER Emmanuelle .....	Biologie cellulaire
BLASCO Hélène.....	Biochimie et biologie moléculaire
BONNET-BRILHAULT Frédérique .....	Physiologie
BOURGUIGNON Thierry .....	Chirurgie thoracique et cardiovasculaire
BRILHAULT Jean.....	Chirurgie orthopédique et traumatologique
BRUNEREAU Laurent.....	Radiologie et imagerie médicale
BRUYERE Franck.....	Urologie
BUCHLER Matthias.....	Néphrologie
CAILLE Agnès .....	Biostat., informatique médical et technologies de communication
CALAIS Gilles.....	Cancérologie, radiothérapie
CAMUS Vincent.....	Psychiatrie d'adultes
CORCIA Philippe.....	Neurologie
COTTIER Jean-Philippe .....	Radiologie et imagerie médicale
DEQUIN Pierre-François.....	Thérapeutique
DESMIDT Thomas .....	Psychiatrie
DESOUBEUX Guillaume.....	Parasitologie et mycologie
DESTRIEUX Christophe .....	Anatomie
DI GUISTO Caroline .....	Gynécologie obstétrique
DIOT Patrice.....	Pneumologie
DU BOUEXIC de PINIEUX Gonzague .....	Anatomie & cytologie pathologiques
DUCLUZEAU Pierre-Henri.....	Endocrinologie, diabétologie, et nutrition
EHRMANN Stephan .....	Médecine intensive – réanimation
EL HAGE Wissam.....	Psychiatrie adultes
ELKRIEF Laure.....	Hépatologie – gastroentérologie
ESPITALIER Fabien.....	Anesthésiologie et réanimation, médecine d'urgence
FAUCHIER Laurent .....	Cardiologie
FOUGERE Bertrand .....	Gériatrie
FRANCOIS Patrick.....	Neurochirurgie
FROMONT-HANKARD Gaëlle .....	Anatomie & cytologie pathologiques
GATAULT Philippe.....	Néphrologie
GAUDY-GRAFFIN Catherine.....	Bactériologie-virologie, hygiène hospitalière
GOUPILLE Philippe .....	Rhumatologie
GUERIF Fabrice .....	Biologie et médecine du développement et de la reproduction
GUILLOIN Antoine.....	Médecine intensive – réanimation
GUILLOIN-GRAMMATICO Leslie.....	Epidémiologie, économie de la santé et prévention
GUYETANT Serge .....	Anatomie et cytologie pathologiques
GYAN Emmanuel.....	Hématologie, transfusion
HALIMI Jean-Michel.....	Thérapeutique
HANKARD Régis.....	Pédiatrie
HERAULT Olivier .....	Hématologie, transfusion
HERBRETEAU Denis .....	Radiologie et imagerie médicale
HOURIOUX Christophe.....	Biologie cellulaire
IVANES Fabrice .....	Physiologie
LABARTHE François .....	Pédiatrie
LAFFON Marc .....	Anesthésiologie et réanimation chirurgicale, médecine d'urgence
LARDY Hubert.....	Chirurgie infantile
LARIBI Saïd.....	Médecine d'urgence
LARTIGUE Marie-Frédérique .....	Bactériologie-virologie
LAURE Boris.....	Chirurgie maxillo-faciale et stomatologie
LECOMTE Thierry.....	Gastroentérologie, hépatologie

LEGRAS Antoine.....	Chirurgie thoracique
LESCANNE Emmanuel.....	Oto-rhino-laryngologie
LEVESQUE Éric.....	Anesthésiologie et réanimation chirurgicale, médecine d'urgence
LINASSIER Claude .....	Cancérologie, radiothérapie
MACHET Laurent .....	Dermato-vénérologie
MAILLOT François .....	Médecine interne
MARCHAND-ADAM Sylvain .....	Pneumologie
MARRET Henri .....	Gynécologie-obstétrique
MARUANI Annabel.....	Dermatologie-vénérologie
MEREGHETTI Laurent.....	Bactériologie-virologie ; hygiène hospitalière
MITANCHEZ Delphine .....	Pédiatrie
MOREL Baptiste .....	Radiologie pédiatrique
MORINIERE Sylvain.....	Oto-rhino-laryngologie
MOUSSATA Driffa .....	Gastro-entérologie
MULLEMAN Denis.....	Rhumatologie
ODENT Thierry.....	Chirurgie infantile
OUAISSI Mehdi .....	Chirurgie digestive
OULDAMER Lobna.....	Gynécologie-obstétrique
PAINTAUD Gilles .....	Pharmacologie fondamentale, pharmacologie clinique
PATAT Frédéric .....	Biophysique et médecine nucléaire
PERROTIN Franck .....	Gynécologie-obstétrique
PISELLA Pierre-Jean.....	Ophtalmologie
PLANTIER Laurent.....	Physiologie
REMERAND Francis .....	Anesthésiologie et réanimation, médecine d'urgence
ROINGEARD Philippe.....	Biologie cellulaire
RUSCH Emmanuel.....	Epidémiologie, économie de la santé et prévention
SAINT-MARTIN Pauline.....	Médecine légale et droit de la santé
SALAME Ephrem.....	Chirurgie digestive
SAMIMI Mahtab .....	Dermatologie-vénérologie
SANTIAGO-RIBEIRO Maria .....	Biophysique et médecine nucléaire
SAUTENET-BIGOT Bénédicte .....	Thérapeutique
THOMAS-CASTELNAU Pierre .....	Pédiatrie
TOUTAIN Annick.....	Génétique
VELUT Stéphane.....	Anatomie
VOURC'H Patrick.....	Biochimie et biologie moléculaire
WATIER Hervé .....	Immunologie
ZEMMOURA Ilyess .....	Neurochirurgie

## **PROFESSEUR DES UNIVERSITES DE MEDECINE GENERALE**

---

DIBAO-DINA Clarisse  
LEBEAU Jean-Pierre

## **PROFESSEURS ASSOCIES**

---

MALLET Donatien .....

## **PROFESSEUR CERTIFIE DU 2<sup>ND</sup> DEGRE**

---

MC CARTHY Catherine.....

## **MAITRES DE CONFERENCES DES UNIVERSITES - PRATICIENS HOSPITALIERS**

---

AUDEMARD-VERGER Alexandra .....	Médecine interne
BISSON Arnaud .....	Cardiologie (CHRO)
BRUNAUT Paul .....	Psychiatrie d'adultes, addictologie
CARVAJAL-ALLEGRIA Guillermo .....	Rhumatologie (au 01/10/2021)
CLEMENTY Nicolas .....	Cardiologie
DOMELIER Anne-Sophie .....	Bactériologie-virologie, hygiène hospitalière
DUFOUR Diane .....	Biophysique et médecine nucléaire
FOUQUET-BERGEMER Anne-Marie.....	Anatomie et cytologie pathologiques
GARGOT Thomas .....	Pédopsychiatrie
GOUILLEUX Valérie.....	Immunologie
HOARAU Cyrille .....	Immunologie
KERVARREC Thibault.....	Anatomie et cytologie pathologiques
LE GUELLEC Chantal.....	Pharmacologie fondamentale, pharmacologie clinique
LEDUCQ Sophie .....	Dermatologie
LEFORT Bruno .....	Pédiatrie
LEJEUNE Julien .....	Hématologie, transfusion
LEMAIGNEN Adrien .....	Maladies infectieuses
MACHET Marie-Christine .....	Anatomie et cytologie pathologiques
MOUMNEH Thomas .....	Médecine d'urgence
PARE Arnaud.....	Chirurgie maxillo-faciale et stomatologie
PIVER Éric.....	Biochimie et biologie moléculaire
ROUMY Jérôme .....	Biophysique et médecine nucléaire
STANDLEY-MIQUELESTORENA Elodie .....	Anatomie et cytologie pathologiques
STEFIC Karl.....	Bactériologie
TERNANT David.....	Pharmacologie fondamentale, pharmacologie clinique
VAYNE Caroline .....	Hématologie, transfusion
VUILLAUME-WINTER Marie-Laure.....	Génétique

## **MAITRES DE CONFERENCES DES UNIVERSITES**

---

AGUILLON-HERNANDEZ Nadia.....	Neurosciences
NICOGLU Antonine .....	Philosophie – histoire des sciences et des techniques
PATIENT Romuald.....	Biologie cellulaire
RENOUX-JACQUET Cécile .....	Médecine Générale

## **MAITRES DE CONFERENCES ASSOCIES**

---

AUMARECHAL Alain .....	Médecine Générale
BARBEAU Ludivine.....	Médecine Générale
CHAMANT Christelle .....	Médecine Générale
ETTORI Isabelle .....	Médecine Générale
MOLINA Valérie .....	Médecine Générale
PAUTRAT Maxime .....	Médecine Générale
PHILIPPE Laurence.....	Médecine Générale
RUIZ Christophe.....	Médecine Générale
SAMKO Boris.....	Médecine Générale

## CHERCHEURS INSERM - CNRS - INRAE

---

BECKER Jérôme.....	Chargé de Recherche Inserm – UMR Inserm 1253
BOUAKAZ Ayache .....	Directeur de Recherche Inserm – UMR Inserm 1253
BOUTIN Hervé.....	Directeur de Recherche Inserm – UMR Inserm 1253
BRIARD Benoit.....	Chargé de Recherche Inserm – UMR Inserm 1100
CHALON Sylvie.....	Directrice de Recherche Inserm – UMR Inserm 1253
DE ROCQUIGNY Hugues .....	Chargé de Recherche Inserm – UMR Inserm 1259
ESCOFFRE Jean-Michel.....	Chargé de Recherche Inserm – UMR Inserm 1253
GILOT Philippe.....	Chargé de Recherche Inrae – UMR Inrae 1282
GOMOT Marie.....	Chargée de Recherche Inserm – UMR Inserm 1253
GOUILLEUX Fabrice .....	Directeur de Recherche CNRS – EA 7501 - ERL CNRS 7001
GUEGUINOU Maxime.....	Chargé de Recherche Inserm – UMR Inserm 1069
HEUZE-VOURCH Nathalie.....	Directrice de Recherche Inserm – UMR Inserm 1100
KORKMAZ Brice.....	Chargé de Recherche Inserm – UMR Inserm 1100
LATINUS Marianne.....	Chargée de Recherche Inserm – UMR Inserm 1253
LAUMONNIER Frédéric .....	Directeur de Recherche Inserm - UMR Inserm 1253
LE MERRER Julie .....	Directrice de Recherche CNRS – UMR Inserm 1253
MAMMANO Fabrizio.....	Directeur de Recherche Inserm – UMR Inserm 1259
MEUNIER Jean-Christophe .....	Chargé de Recherche Inserm – UMR Inserm 1259
PAGET Christophe.....	Directeur de Recherche Inserm – UMR Inserm 1100
RAOUL William .....	Chargé de Recherche Inserm – UMR Inserm 1069
SECHER Thomas.....	Chargé de Recherche Inserm – UMR Inserm 1100
SI TAHAR Mustapha.....	Directeur de Recherche Inserm – UMR Inserm 1100
SUREAU Camille .....	Directrice de Recherche émérite CNRS – UMR Inserm 1259
TANTI Arnaud .....	Chargé de Recherche Inserm - UMR Inserm 1253
WARDAK Claire.....	Chargée de Recherche Inserm – UMR Inserm 1253

## CHARGES D'ENSEIGNEMENT

---

### *Pour l'éthique médicale*

BIRMELE Béatrice.....Praticien Hospitalier

### *Pour la médecine manuelle et l'ostéopathie médicale*

LAMANDE Marc.....Praticien Hospitalier

### *Pour l'orthophonie*

BATAILLE Magalie.....Orthophoniste

CLOUTOUR Nathalie.....Orthophoniste

CORBINEAU Mathilde.....Orthophoniste

EL AKIKI Carole.....Orthophoniste

HARIVEL OUALLI Ingrid.....Orthophoniste

IMBERT Mélanie.....Orthophoniste

SIZARET Eva.....Orthophoniste

### *Pour l'orthoptie*

BOULNOIS Sandrine.....Orthoptiste

# SERMENT D'HIPPOCRATE

En présence des enseignants et enseignantes  
de cette Faculté,  
de mes chers condisciples  
et selon la tradition d'Hippocrate,  
je promets et je jure d'être fidèle aux lois de l'honneur  
et de la probité dans l'exercice de la Médecine.

Je donnerai mes soins gratuits aux indigents,  
et n'exigerai jamais un salaire au-dessus de mon travail.

Admis(e) dans l'intérieur des maisons, mes yeux  
ne verront pas ce qui s'y passe, ma langue taira  
les secrets qui me seront confiés et mon état ne servira pas  
à corrompre les mœurs ni à favoriser le crime.

Respectueux(euse) et reconnaissant(e) envers mes Maîtres,  
je rendrai à leurs enfants  
l'instruction que j'ai reçue de leurs parents.

Que les hommes et les femmes m'accordent leur estime  
si je suis fidèle à mes promesses.  
Que je sois couvert(e) d'opprobre  
et méprisé(e) de mes confrères et consœurs  
si j'y manque.

## REMERCIEMENTS

### **Au président du jury,**

À Monsieur le **Professeur Thierry LECOMTE**, je vous remercie d'avoir accepté de présider ce jury. Je tenais à vous remercier pour votre enseignement tout au long de ma formation et m'avoir permis de réaliser la FST d'oncologie. Soyez assuré de mon profond respect et de ma reconnaissance.

### **À ma directrice de thèse,**

À Madame la **Professeure Laure ELKRIEF**, merci d'avoir accepté (et ce dès le début de mon internat) de m'encadrer pour cette thèse avec bienveillance. Merci pour tes relectures précises et tes conseils avisés. J'admire le médecin que tu es. Merci de m'avoir appris à questionner les diagnostics et à être rigoureuse. Tu peux être sûre que je ne prescrirai jamais des IPP à l'aveugle. Merci également pour ton humour et nos références parisiennes communes.

### **Aux membres du jury,**

À Monsieur le **Docteur Jérôme ROUMY**, je vous remercie d'avoir accepté de faire parti de mon jury de thèse. Veuillez trouver dans ce travail, l'expression de mon profond respect.

À Monsieur le **Docteur Romain CHAUTARD**, que dire ... Je te remercie d'avoir accepté de faire parti de ce jury (le rallye de toute ma promotion est enfin fini). Merci pour ton compagnonnage dès mon premier semestre d'internat, t'avoir à mes côtés a grandement participer à ma formation. J'admire ta pertinence et ton dévouement aux patients et tâcherai de m'inspirer de toi dans ma pratique future. Merci d'être devenu un ami cher en dehors de l'hôpital. On a bien rigolé pendant cet internat dis ! Kele kush kush

À Madame le **Docteur Anaïs JAILLAIS**, je te remercie d'avoir accepté de faire partie de ce jury. Ta rencontre dès mon début d'internat a été déterminante dans la vision du médecin que je voulais devenir. Je garde en souvenir tes visites en hépato où je ne comprenais pas tout mais où tu prenais le temps de m'expliquer. Merci également pour ton humour, ton sens du style (poches de marques gardées...) et les verres bus en dehors de l'hôpital.

### **Aux personnes m'ayant aidé pour cette thèse,**

**Merci à Michael VION** pour ta disponibilité, ta rapidité de réponse à mes mails et ta sympathie. C'était un plaisir de travailler avec toi.

**Merci à Mehdi YEDROUDJ** pour le temps passé à m'expliquer ce qu'est le Deep Learning.  
**Merci à Paul-Armand DUJARDIN** pour votre aide lors du recueil de données.

**Aux personnes ayant contribué à ma formation,**

**À toute l'équipe médicale du CHRU de Tours**, en particulier au Pr MOUSSATA, Dr d'ALTEROCHE, Dr NICOLAS, Dr PICON, Dr CAULET, Dr ANON et Dr BARBIEUX. Votre bonne humeur et bienveillance m'ont permis d'apprendre sereinement et de m'épanouir tout au long de mon internat.

**Merci à Clarisse et Anna** pour avoir été mon duo de chefs de cliniques adorées. Votre gentillesse et votre écoute m'ont fait commencer mon internat de la meilleure des façons.

**Merci à Thomas** mon mentor d'endoscopie, tu peux être sûr que tes techniques seront transmises aux générations futures.

**Merci à Benoit** pour ta bonne humeur et pour les CPRE calées à droite à gauche.

**À toute l'équipe d'oncologie médicale du CHU de Tours**, je vous remercie tous pour votre enseignement. Un merci particulier au Dr NARCISO pour son énergie, au Dr STACOFFE pour sa voix, au Dr TOURNET-DOUARD pour toutes nos RCP dig ensemble, au Dr CANCEL pour sa gentillesse et au Dr VEGAS.

**À toute l'équipe de radiothérapie du CHU de Tours**, je garde un excellent souvenir de ce semestre passé à vos côtés. Merci tout particulier à Astrid, Sofia, Laurie et Sarah pour votre dynamisme et amitié.

**À toute l'équipe d'oncologie digestive de l'HEGP à Paris**, ces 6 mois d'inter-CHU ont été très formateurs. Les rires partagés et la bonne humeur ambiante ont contribué à faire de cet inter CHU un semestre mémorable. Merci au Pr TAIEB d'avoir accepté ma venue, au Pr ZAANAN pour son savoir immense, au Dr GALLOIS pour sa jovialité et excellence et au Dr LAHLOU pour toutes ses anecdotes partagées. Merci également aux Dr PALLE et Dr HAFLIGER pour leur sympathie et leurs rires.

**Merci également à toutes les équipes que j'ai croisé durant mon internat et avec qui j'ai passé de très bons moments**, secrétaires (Natacha et Virginie), infirmier(e)s (Joana, Florine, Maeva, Elizabeth, Charlotte, Anne So, Justine, Ophélie, Léa, Rachel, Lise), aides-soignantes (Coralie), diététiciennes (Marie-Pierre), psychologues et j'en passe.

**À ma famille,**

**Merci à mes parents** qui m'ont élevé dans tant d'amour, de soif de connaissances et de rire. Vous m'avez donné toutes les clés pour réussir, je vous en suis éternellement reconnaissante.

Mama, mon modèle (hormis pour ton goût étonnant de casquettes), j'espère réussir à être une médecin aussi bienveillante, souriante et brillante que toi. Merci pour ta douceur, ton rire unique et nos moments à deux.

Baba, mon sosie de tête ronde, j'espère réussir à être une médecin aussi passionnée et passionnante que tu l'es. Merci pour ta force, ton humour (dont je m'inspire quelquefois), ton hyperactivité et ta présence toujours à mes côtés.

**Merci à mes incroyables et tant aimées sœurs,**

Julie, mon mi ange mi démon. Merci pour tes blagues douteuses, ton amour pour les bons plans, ta façon de danser débordante et surtout ton soutien indéfectible.

Margaux, ma tempête. Merci d'être si intrépide et la meilleure prof de plongée, ton talent de cuisinière (pâtissière surtout), ces heures de massage forcées et d'être toujours là pour moi.

**Merci à ma Mamie Véro**, pour tous nos souvenirs inoubliables et heureux ensemble que ce soit à Carnac ou avenue Felix Faure, merci pour ta tendresse, tes habits que j'aime tant avoir et d'avoir toujours un coca et un riz uncle ben's si je débarque chez toi.

**Merci à mon Dadou**, pour m'avoir transmis ton taux de décibels, pour nos vacances houlgataises éternelles, pour tes sauces maisons inimitables et d'être là pour nous tous.

**Merci à ma Stef** d'être ma tante adorée, ta folie n'a d'égal que l'amour que je te porte.

**Merci à Yann** pour sa passion Roger et ses couscous inégalables.

**Merci à mes 3 cousins, frères de cœur, Alexis, Clément et Maël.** Avoir grandi à vos côtés, en tant que nus pieds, a été un privilège.

**Merci à mon tonton Lolo et à Marta**, de m'avoir fait sentir superstar à chaque fois que j'allais à Budapest, pour les photos de partout et bien sûr pour le Buzz Quiz.

Une pensée pour mes beaux-parents **Mélanie et Bruno** pour m'avoir accueilli dans leur famille de la plus belle des façons. Hâte de tous nos futurs moments ensemble.

**Merci à Vladimir, Cléopée et Cécile** d'être un trio de belles sœurs/beau frère aussi marrants qu'attachants.

**Merci à Jeanne, Cyprien, Charles, Rose, Clotilde, Ysé** d'être aussi drôles et créatifs. Votre chanson résonne souvent dans mon cœur.

**À ma Mamie Pontoise**, mon papillon à une étoile, tu me manques terriblement chaque jour  
**À mon Papi Georges**, dont j'entends encore la voix et son accent hongrois, tu me manques

**À mes ami(e)s, si fidèles**

**Merci à ma PP, Amicie, Anna, Julie et Marie.** Quasi 25 ans que ça dure ....

Mimi, merci de m'avoir toujours encouragé et cru en moi. Merci pour la femme forte que tu es.

Nanou, merci pour ton goût du vin (qu'on partage) et les câlins dont tu es la spécialiste.

Marie, merci tes bons plans make up et ton amour pour les anniversaires démesurés.

Sol, merci pour ces innombrables après midi à danser chanter et être des Glécins, pour tes bons plans (Bobbies), tes Gin Fizz et nos moments. Je sais que tu resteras mon soleil toute ma vie.

**Merci à Mélanie**, ma gwi since André citroën (vive l'athlé) et pour encore de longues années.

**Merci à mes girls de la seconde 5, Amandine, Axelle, Mélina, Manon et Fleur**

Amande, merci pour nos moments partagés à toutes les étapes de ma vie. Telle la lumière d'un phare, tu es un de mes repères dans la nuit.

Mon axe, ta blondeur n'a d'égal que la joie que tu procures autour de toi. Merci de rester toujours auprès de moi.

Poussin, merci pour ta joie de vivre, Manon, pour ta curiosité et ma Fleur pour ta passion.

**Merci à mes zoulettes de l'amour, Elsa, Fanny, Laura, Margot, Romane, Shana**

Ma vie est tellement plus pimentée depuis que je vous ai à mes côtés !

Ma Fann, sœur de cœur, merci pour tes goûts de cinéma d'auteur, ta descente inégalable, ton niveau d'anglais (fanidico), Alex Pettyfer et d'être mon aide au quotidien.

Ma Marg, ma quasi écoloc, merci pour tes talents de masseuse, pour ton rire franc, pour la plongée et chaque moment passé ensemble.

Ma Roro, mon ensorceleuse, merci de me suivre même dans des courses à Barcelone, de m'avoir fait découvrir les endives, de toutes ces aventures pianaises et d'être si précieuse dans ma vie.

Ma Shan, mon shanatov, merci d'éclairer ma vie de tes milles lumières. Merci pour tes mots d'amour, nos folies ensemble jusqu'au bout de la nuit (un max de planches) et d'être aussi forte.

Ma Zaz, mon double tourangeau et bien plus. Merci pour cette amitié éternelle et indispensable. Je tiens à remercier l'interne qui a choisi uro à Amiens sans lui ma vie à Tours n'aurait jamais été la même. Merci pour ces 2 années de coloc, de m'avoir cuisiné des plats délicieux (même sans viande), de t'être adaptée à mon sens du rangement, de toutes les fringues prêtées, de toutes nos chorégraphies, de tous ces fous rires et de m'avoir supporté pendant toutes ces années.

### **À mes frères d'amour, Aimene, Ari, Ben, Maxime, Tim, Yoann et la PEJ**

Mon Aimene, merci d'être mon co-colopathe préféré. Hâte de continuer à enflammer ensemble le dance floor pour de nombreuses années à venir.

Mon Ari, merci d'être un ami si unique. Merci pour tes phrases pleines de sens, ton humour décapant et ton sens du lever tôt.

Mon Ben, merci pour ce voyage inoubliable en Norvège et nos discussions sur la vie.

Mon Maxou, mon chouki. Merci d'avoir été un de mes piliers tourangeaux. Merci pour ta bomba, ton sens de l'amitié, nos diners délices et ta bonne humeur.

Mon Tim merci pour ton talent de musicien et d'organisateur d'évènements inoubliables.

Mon Yo, merci pour ta présence rassurante, tes petits tatouages et d'être là.

La PEJ merci pour ton flow et ton soutien en D4.

**Merci à Alex, Gabi (meilleur collabo), Léo, Vincent et Yohan** d'être les meilleurs co-zoulettes

**Merci à la CGT**, tous les moments passés avec vous, de Pantin à la Bern sont merveilleux et j'ai hâte d'en vivre des centaines encore.

**Merci aux amis de mon Jean** qui sont devenus les miens : Constant, Hortense, Lise, Lucie, Moté, Ophélie, Paola, Quentin, Samy.

**Merci aux Cormier**, famille miroir. La Corse reste inoubliable pour moi.

### **A mes co internes et ami(e)s tourangeaux, la famille**

Merci à la meilleure promotion qui soit, j'ai nommé, le King et les Queens, Cyprien, Diane et Léa. Sans vous, mon internat n'aurait pas eu la même saveur.

**Merci Léa**, ma lélé, pour être devenue si essentielle à ma vie. Merci de m'avoir fait aimer ta bothorelite certains matins, ta folie dès le midi, le chocolat noir le soir et la disco à tout heure. Hâte de continuer à twerker sur des murs à 80 ans.

**Merci Cyp cyp** mon binôme, pour ton soutien pendant notre 1<sup>er</sup> semestre, merci pour tes blagues, tes diagnostics précis et notre amitié, qui je l'espère perdurera longtemps.

**Merci à Draulette et Ludo**, le S. Hâte de vous retrouver à Paris.

**Merci à Juliette, Sophie et Enora** ma triloc de l'amour

Merci Jul de m'avoir fait découvrir SCH. Ce week end marseillais était un régal, hâte des futurs. Merci Soph pour ta joie communicative.

**Merci à ma Laurène**, notre semestre en radiothérapie a été 6 mois de rires éclatants, de chansons en tout genre et de vidéos divertissantes. Merci d'être depuis une amie très chère. Hâte de continuer à débriefer de nos vies pendant de longues années.

**Merci à Sarah** pour ton rire communicatif, nos déjeuners d'astreinte et ta motivation.

**Merci à Alice** pour tes pas de danse enflammés et les bons moments passés ensemble.

**Merci à Astrid** de m'avoir prouvé que la radiothérapie c'est pas que des épидurites. Merci pour ce week end nantais et nos combos pétillant/ film et blabla, j'espère qu'on continuera à en faire.

**Merci à tous ceux que j'ai rencontré à Tours** : Charp, Naomi, Pauline, Caroline, Hugo, Salem, Lucile, Ourielle, Paul, Léandre. C'est en partie grâce à vous que j'ai adoré cette ville.

**Merci à tous ceux dont j'ai croisé la route en stage**, Adrien, Alexandra, Anéa (team jaune forever), Camille, Céline (LL), Chloé M, Chloé S, Claire, Coralie F, Coralie P, Corentin, Manon, Marine, Mathieu, Nicolas, Olympe, Pauline, Vitto, Yazid votre compagnie a toujours été que du plaisir.

**Last but not least, merci Jean**

4 lignes ne suffiraient pas pour te décrire.

Hâte de continuer à conjuguer tous nos rêves pour les vivre un par un ensemble toute ma vie.

**Intérêt de l'échographie couplée à l'intelligence  
artificielle pour la détection et la caractérisation des  
lésions hépatiques bénignes et malignes : une étude  
exploratoire**

## RÉSUMÉ

L'échographie hépatique est un examen d'imagerie fréquent que ce soit dans le cadre de suivi de pathologies ou en 1<sup>ère</sup> intention face à une situation clinique évoquant une pathologie abdominale ou biliaire. Les lésions hépatiques sont fréquentes avec des taux de découverte fortuite lors d'une échographie allant jusqu'à 30%. Le développement de modèles utilisant l'intelligence artificielle (IA) est un terrain prometteur en médecine. Le but de cette étude était de créer un outil grâce au Deep Learning qui détecte et caractérise simultanément les lésions focales hépatiques lors d'une échographie hépatique.

Nous avons d'abord créé puis entraîné notre modèle avec la base de données QWLUS (conçue par Qwanteus startup spécialisée en IA), une base de données d'images échographiques hépatiques issues d'internet et rassemblées via un logiciel d'exploration de site web (web crawler). Cette base de données était composée de 790 images échographiques bidimensionnelles du foie, correspondant à 1672 lésions focales hépatiques réparties en six catégories (adénome, hémangiome, hyperplasie nodulaire focale, kystes, métastases, carcinome hépatocellulaire CHC). 630 images ont été utilisées pour entraîner le modèle et 160 pour le tester. Il a ensuite été testé sur un nouvel ensemble de données d'images issues de 61 patients sélectionnés au CHU de Tours.

Nous avons testé plusieurs réseaux de Deep Learning connus et obtenu les meilleurs résultats avec YOLO LT, une version modifiée de YOLO développée par Qwanteus, que nous avons intégré dans notre outil de détection appelé DETECT. YOLO est basé sur des réseaux de neurones artificiels et conçu pour une détection rapide en temps réel des objets dans des images. Nous avons obtenu une VPP (valeur prédictive positive) de 57,9% et une sensibilité de 86,8% avec la base de données QWLUS. Les taux de sensibilité / spécificité / VPP / exactitude de détection pour les lésions focales du foie pour la base issue du CHU de Tours étaient respectivement de 66% / 90% / 85% / 79%. Les meilleurs résultats de caractérisation ont été obtenus avec les adénomes, les kystes et les CHC.

Notre modèle couplant Deep Learning et échographie hépatique a montré de bons résultats en tant qu'outil de détection et doit améliorer ses performances pour la caractérisation. Ses résultats prometteurs encouragent la recherche dans ce domaine afin d'obtenir dans un futur proche un outil permettant une détection et caractérisation des lésions hépatiques fiable et utile en pratique clinique.

## **ABSTRACT**

*Aim* : The aim of this study was to create a model that simultaneously detects and characterizes focal liver lesion using deep learning and ultrasound images (US).

*Patients and methods* : we first create and train our model with QWLUS database, a database created by Qwanteus, a startup specialized in Artificial Intelligence, of US liver images captured via a web crawler. This database was composed of 790 two-dimensional ultrasound images of the liver, corresponding of 1672 focal liver lesions divided into six categories (adenoma, hemangioma, focal nodular hyperplasia, cysts, metastasis, hepatocellular carcinoma HCC). 630 images were used to train the model and 160 to test it.

It was then tested on a new data set of images from 61 patients selected among the database of the University Hospital of Tours.

*Results* : We tested 3 different Deep Learning networks (Faster R-CNN, YOLO and YOLO LT) and obtained best results with YOLO LT, a modified version of YOLO developed by Qwanteus. YOLO is a Deep Learning framework based on artificial neural networks and designed for rapid, real-time detection of objects in images. We obtained a PPV (positive predictive value) of 57,9% and recall of 86,8% with the QWLUS database. The detection sensitivity / specificity / PPV / diagnostic accuracy rates for focal liver lesion with the validation database were 66% / 90% / 85% / 79% respectively. The best results for characterization were obtained with Adenoma, cysts and HCC.

*Conclusion* : The developed Deep Learning program Detect, based on routine ultrasound images, showed good results as a tool detection and need further improvement for characterization performance. Deep Learning algorithm and model may allow proper detection and characterization of Focal Liver Lesions in the future.

## Table des matières

<b>REMERCIEMENTS</b> .....	<b>8</b>
<b>TITRE</b> .....	<b>14</b>
<b>RÉSUMÉ</b> .....	<b>15</b>
<b>ABSTRACT</b> .....	<b>16</b>
<b>INDEX DES ABRÉVIATIONS</b> .....	<b>18</b>
<b>I. ÉTAT DES CONNAISSANCES</b> .....	<b>19</b>
<i>A. Généralités sur l'échographie</i> .....	<i>19</i>
1. Bases physiques .....	19
2. Modalités pratiques .....	20
3. Échographie hépatique .....	21
<i>B. Intelligence artificielle (IA)</i> .....	<i>22</i>
1. Régression, classification et détection d'objet .....	23
2. Machine Learning et Deep Learning .....	25
<i>C. Place de l'intelligence artificielle dans l'imagerie hépatique</i> .....	<i>28</i>
<b>II. OBJECTIFS DU TRAVAIL</b> .....	<b>33</b>
<b>III. ARTICLE ORIGINAL</b> .....	<b>34</b>
1. Introduction .....	34
2. Patients and methods.....	35
2.1. Database preparation .....	35
2.2. Annotation process.....	36
2.3. Object detection networks .....	36
2.4. Validation database.....	36
2.5. Statistical Analysis.....	38
3. Results.....	38
3.1. QWLUS database .....	38
3.2. Validation database .....	41
4. Discussion .....	43
5. References.....	46
6. Appendix .....	49

## **INDEX DES ABRÉVIATIONS**

AI: Artificial Intelligence

ANN: Artificial Neural Network

CNN: Convolutional Neural Network

CT: Computed Tomography

DBN: Deep Belief Network

DL: Deep Learning

FCN: Fully Convolutional Network

FNH: Focal Nodular Hyperplasia

GLCM : Grey Level Co-Occurrence Matrix Based Statistical Texture

GLRLM: Gray Level Run Length Matrix

HCC: Hepatocellular carcinoma

ML: Machine Learning

MRI: Magnetic Resonance Imaging

RFC: Random Forest

US: Ultrasound

SVM: Support Vector Machine

## I. État des connaissances

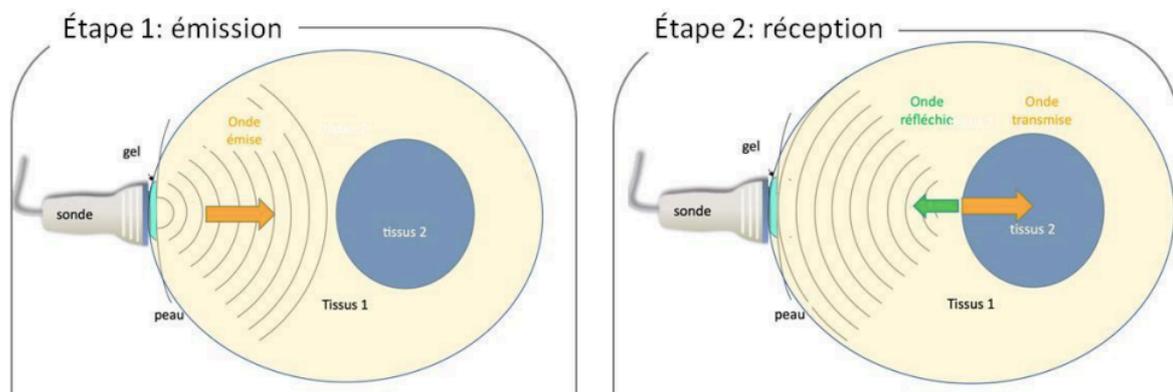
### A. Généralités sur l'échographie

Dans la pathologie abdominale et notamment la pathologie hépato biliaire, l'échographie est dans la plupart des situations cliniques l'examen morphologique de première ligne <sup>1</sup>.

#### 1) Bases physiques

L'échographie utilise des ondes sonores pour pénétrer le corps et générer une image. Une onde sonore est une onde mécanique qui correspond à une vibration du milieu dans laquelle l'onde se propage. Les ondes ultrasonores ont une fréquence élevée et sont inaudibles pour l'oreille humaine. C'est l'élasticité du milieu qui assure la propagation de l'onde et la vitesse de propagation (célérité) dépend de la nature du milieu. De  $300 \text{ m.s}^{-1}$  dans l'air elle passe à  $1500 \text{ m.s}^{-1}$  en milieu aqueux (ordre de grandeur de la vitesse de propagation dans l'organisme humain). Les ondes sonores ne peuvent pas se transmettre dans le vide. Les tissus présentent une résistance au passage des ultrasons, qui dépend des tissus traversés, de leur élasticité et de leur densité. A l'arrivée des ondes ultrasonores à une interface entre 2 tissus, une partie de l'onde incidente est transmise, l'autre est réfléchi. Les énergies transmises et réfléchies (caractérisées par l'amplitude du signal observé) dépendent de la nature des deux tissus.

**Figure 1.** Émission et réception des ondes sonores lors de l'échographie <sup>2</sup>



La caractéristique physique qui génère le contraste dans l'image est l'échogénicité soit la capacité de renvoyer une partie du faisceau ultrasonore vers le transducteur (= la sonde) <sup>3</sup>.

Ainsi si le tissu 2 est :

- un os ; alors tout le signal est réfléchi, l'os apparaît en hyper signal = blanc. L'onde transmise est quasiment nulle, ce qui explique pourquoi on ne peut pas obtenir d'images échographiques de régions protégées par des os
- un liquide ; alors tout le signal est transmis et cette région apparaît en hyposignal = noir

En échographie, les ondes ultrasonores sont produites de façon pulsée (par intervalles) par un transducteur piézoélectrique qui sert aussi de récepteur des ultrasons.

En effet, la sonde d'échographie est composée d'une céramique piézoélectrique qui en tant qu'émetteur est soumise à des impulsions électriques à l'origine des ultrasons et en tant que récepteur agit comme transducteur ultrasonore avec l'onde ultrasonore. L'action de l'onde ultrasonore sur le transducteur induit une impulsion électrique qui donnera naissance à l'image échographique. La sonde émet l'onde ultrasonore et reçoit l'onde réfléchie.

On utilise en échographie des sondes avec des ondes sonores de 2 à 15 Mégahertz, en fonction de l'application<sup>3</sup>.

## 2) Modalités pratiques

L'échographie est réalisée par voie transcutanée, en déplaçant la sonde de l'échographe sur la peau et peut être réalisé par un radiologue ou tout professionnel formé avec un diplôme universitaire d'échographie. Les appareils d'échographie récents se sont améliorés, démocratisés et diversifiés. Le développement exponentiel de la puissance des processeurs a permis d'abandonner le traitement d'images par des cartes vidéo spécifiques onéreuses au profit d'un traitement logiciel, avec une division par quatre du prix d'un appareil de bonne qualité <sup>4</sup>. Ce développement des logiciels permet également une miniaturisation du matériel, devenu portable. La diminution du coût des sondes permet aujourd'hui de s'équiper plus facilement d'au moins deux sondes, une superficielle et une profonde, particulièrement adaptées à l'exploration abdominale. On estimait déjà en 2001 que 50% des gastroentérologues étaient équipées d'un matériel d'échographie <sup>5</sup>.

L'échographie a de nombreux avantages notamment de par son coût modéré, son innocuité (pas de radiation) et sa facilité d'accès<sup>1</sup>. Elle a toutefois des inconvénients. En effet, on parle d'un acte « opérateur-dépendant » étant donné que la qualité de l'image et les mesures effectuées dépendent de la position de la sonde appliquée par le radiologue<sup>6</sup>.

Par ailleurs, un autre inconvénient consiste en la présence d'un « grain » et d'artefacts, on parle d'échotexture. Les images échographiques peuvent donner l'impression d'être composée de « grains » et cela peut entraîner une visibilité réduite. On peut influencer l'échotexture de l'image via le mode d'imagerie choisie et les réglages choisis<sup>6</sup>.

### 3) Échographie hépatique

L'échographie hépatique standard est à la fois un examen d'imagerie de 1<sup>ère</sup> intention face à une douleur abdominale, des perturbations du bilan hépatique ou des symptômes digestifs frustrés et un examen d'imagerie de suivi pour les hépatopathies chroniques comme la cirrhose ou dans le cadre de la surveillance d'un cancer<sup>1</sup>.

Par ailleurs, ces dernières années ont vu de nombreuses évolutions technologiques modifier la pratique de l'échographie hépatique que ce soit pour mieux visualiser les vaisseaux (doppler), mieux caractériser les lésions hépatiques (échographie de contraste), la mesure de la dureté hépatique sur une zone définie (élastographie ultrasonore) ou encore en radiologie interventionnelle (fusion temps réel imagerie ultrasonore- scanner-IRM) faisant de l'échographie un examen d'imagerie de premier plan<sup>1</sup>.

En pratique, la détection fortuite de lésions focales hépatiques lorsque l'échographie est réalisée en routine face à des perturbations du bilan hépatique ou des symptômes digestifs frustrés constitue une circonstance fréquente, jusqu'à 10 à 30% des explorations selon les études<sup>7 8</sup>.

Les tumeurs hépatiques détectées de façon fortuite en l'absence de cirrhose ou de cancer sont très majoritairement bénignes et tout particulièrement suspectées comme telles si elles sont solitaires, de petite taille (< 2 cm) et chez le sujet jeune. Il peut s'agir principalement de kystes hépatiques (≈ 5% de la population générale), d'hémangiomes (0,5-5%) ou, plus rarement, de tumeurs hépatocytaires bénignes qui présentent une forte prédisposition féminine et se subdivisent en hyperplasie nodulaire focale (< 0,2-1%) et en adénome (< 0,01-0,1%)<sup>9</sup>.

Certains sous-types d'adénomes ont pour particularité de présenter un risque évolutif qui les expose à une possibilité de complications (hémorragie) ou de transformation maligne<sup>10</sup>.

Dans le cadre de la surveillance de cancer ou du suivi de certaines hépatopathies chroniques, les échographies hépatiques sont répétées régulièrement. La sensibilité de l'échographie hépatique pour le dépistage du CHC en cas d'hépatopathie chronique dépend surtout de la taille, avec une sensibilité de moins de 50% pour les tumeurs < 1 cm <sup>11</sup>. Il est recommandé de réaliser une échographie hépatique tous les 6 mois afin de dépister le carcinome hépatocellulaire en cas d'hépatopathie chronique <sup>12</sup>.

L'échographie hépatique a une sensibilité voisine de 85% et spécificité de 95% pour la détection de métastases hépatiques. Les dernières recommandations du groupe d'étude français publiées dans le TNCD (Thésaurus National de Cancérologie Digestive) en 2022 encouragent la réalisation d'une échographie abdominale tous les 3 mois pendant 3 ans puis tous les 6 mois pendant 2 ans <sup>13</sup>.

Au vu du nombre de cancer colique en France chaque année (43 000 nouveaux cas en 2018 <sup>14</sup>) et de patients atteints d'hépatopathie chronique (on recense entre 1500 et 2500 cas de cirrhose par million d'habitants en France), on comprend bien la fréquence élevée d'échographies hépatiques réalisées chaque année en France. À titre d'exemple, en 2016, 3 412 287 échographies de l'appareil digestif ont ainsi été réalisées <sup>15</sup>.

## **B. Intelligence artificielle (IA)**

L'IA est un domaine de recherche qui regroupe toutes les techniques qui visent à reproduire, via des systèmes artificiels, les capacités cognitives humaines et plus généralement les comportements « intelligents » et la possibilité de résoudre des problèmes complexes <sup>16</sup>.

Le Machine Learning est un domaine de l'IA qui consiste à programmer une machine pour que celle-ci apprenne à réaliser des tâches en étudiant des exemples de ces dernières. Le Machine Learning consiste ainsi à laisser l'ordinateur apprendre quel calcul effectuer, plutôt que de lui donner ce calcul (c'est-à-dire le programmer de façon explicite).

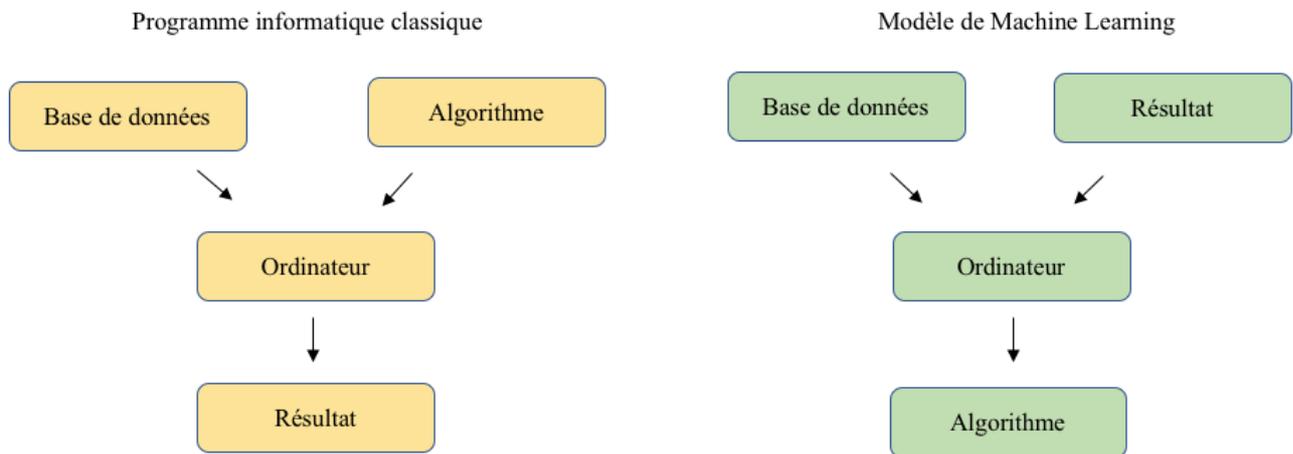
On utilise des méthodes d'apprentissage pour donner la capacité à l'ordinateur d'apprendre.

Il en existe 3 principales : l'apprentissage supervisé (Supervised Learning), l'apprentissage non supervisé (Unsupervised Learning) et l'apprentissage par renforcement (Reinforcement Learning)

Nous nous concentrerons uniquement sur l'apprentissage supervisé, car il s'agit de la méthode la plus utilisée en Machine Learning.

L'apprentissage supervisé consiste à fournir à une machine beaucoup d'exemples qu'elle doit étudier pour apprendre à résoudre un problème <sup>17</sup>.

**Figure 2.** Différences entre un programme informatique classique et un modèle de Machine Learning



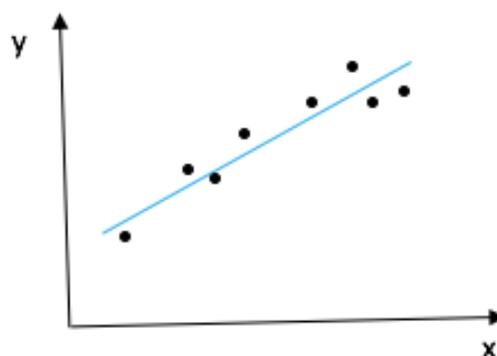
1) Régression, classification et détection d'objet

On peut développer des modèles pour résoudre plusieurs types de problèmes, principalement des problèmes de régression, des problèmes de classification ou des problèmes de détection d'objet.

Dans les problèmes de régression, on cherche à prédire la valeur d'une variable continue, c'est-à-dire une observation (*variable*) qui peut prendre une infinité de valeurs.

Par exemple, prédire la quantité d'essence consommée ( $y$ ) selon la distance parcourue ( $x$ )

**Figure 3.** Régression

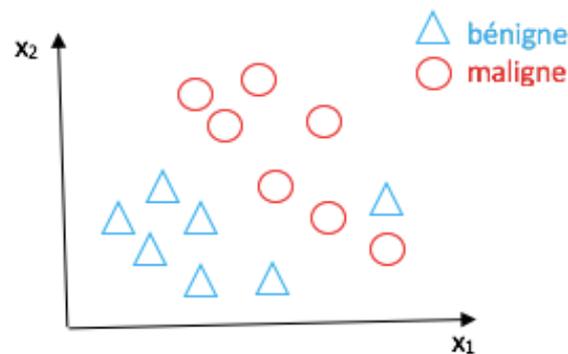


Dans un problème de classification, on cherche à classer un objet dans différentes classes, c'est-à-dire que l'on cherche à prédire la valeur d'une variable discontinue (qui ne prend qu'un nombre fini de valeurs).

Par exemple, on peut vouloir prédire si une tumeur est maligne ( $y=1$ ) ou bénigne ( $y=0$ ) selon l'âge du patient ( $x_1$ ) et la taille de la tumeur ( $x_2$ ).

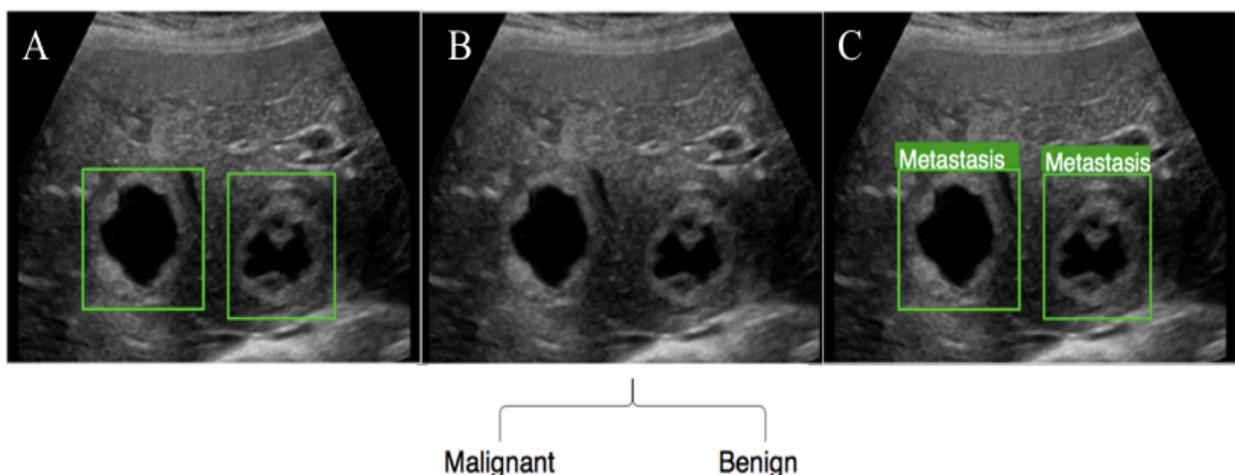
La classification d'images est une sous-famille qui consiste à classer une image dans une catégorie distincte. On représente souvent les classes par des symboles en cas de problème de classification.

**Figure 4. Classification**



La détection d'objet réunit 2 tâches en une seule, à savoir la classification d'une image et sa localisation. Ainsi non seulement on demande à notre système d'IA de catégoriser l'objet visualisée sur une image mais on lui demande aussi de savoir situer cet objet au sein de l'image. Le terme « détection » n'est ainsi par parfaitement adapté car il faut bien comprendre qu'en parlant de détection d'objet on inclue la localisation de l'objet et sa classification au sein de l'image.

**Figure 5.** A. Exemple de localisation d'image B. Exemple de classification d'image  
C. Exemple de détection d'objet (soit localisation + classification)



## 2) Machine Learning et Deep Learning

Le système classique de Machine Learning (ML) est ainsi fait de 2 blocs :

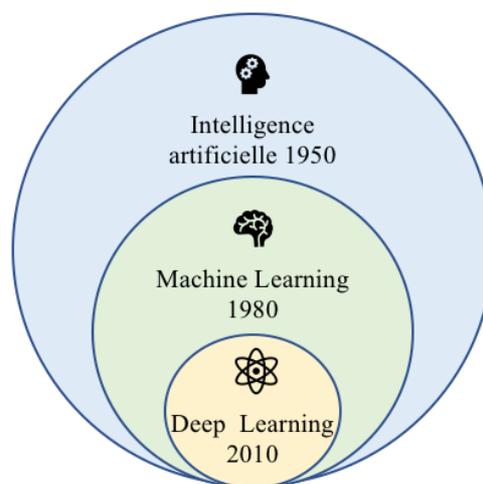
- un programme (feature extraction) conçu pour extraire les données utiles à partir des données brutes. Ce programme est conçu par un expert dans le domaine concerné
- il est suivi par un programme (classification) conçu pour apprendre à partir des caractéristiques extraites, la fonction mathématique la plus adaptée à l'objectif recherché (la cible)

Le Machine Learning est un outil puissant, dans la mesure où il peut créer ses propres modèles à partir de données, même non qualifiées. Mais les systèmes de Machine Learning ont toutefois leurs limites. Concevoir un « feature extractor » performant et adapté est très difficile. De plus la dépendance du machine learning aux données d'entrée entraîne un problème de biais. En effet si les exemples fournis sont biaisés, cette partialité sera reproduite par le programme. Aussi automatique soit-il, le machine learning est un système qui demeure dépendant de son concepteur.

Par ailleurs, pour être pertinent ce procédé requiert une grande quantité de données, celles-ci étant d'autant plus disponibles actuellement, notamment avec le big data. Ce volume augmenté de données induit une augmentation du temps nécessaire à l'apprentissage.

C'est pour surmonter ces limites qu'un système plus puissant a été conçu dans les années 2010 : le Deep Learning, ou apprentissage profond en français <sup>18</sup>.

**Figure 6.** Évolution au sein de l'Intelligence Artificielle

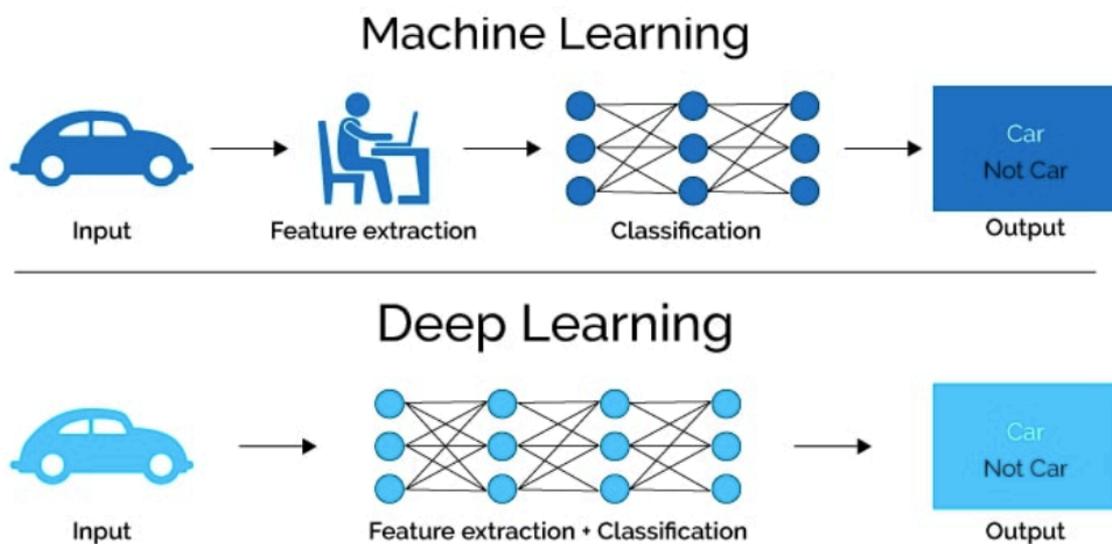


Le Deep Learning est une sous classe au sein du Machine Learning qui combine l'approche traditionnelle en 2 blocs (feature extraction puis classification) en 1 seul bloc qui réunit les deux tâches. Cet unique bloc est représenté par un réseau de neurones artificiels.

Un modèle de Deep Learning peut résoudre des problèmes plus complexes et utiliser de plus grande quantité de données que les modèles traditionnels de Machine Learning.

Le développement de la puissance des ordinateurs ainsi que l'avènement des big datas a permis l'essor du Deep Learning.

**Figure 7.** Schémas classiques de Machine Learning et Deep Learning



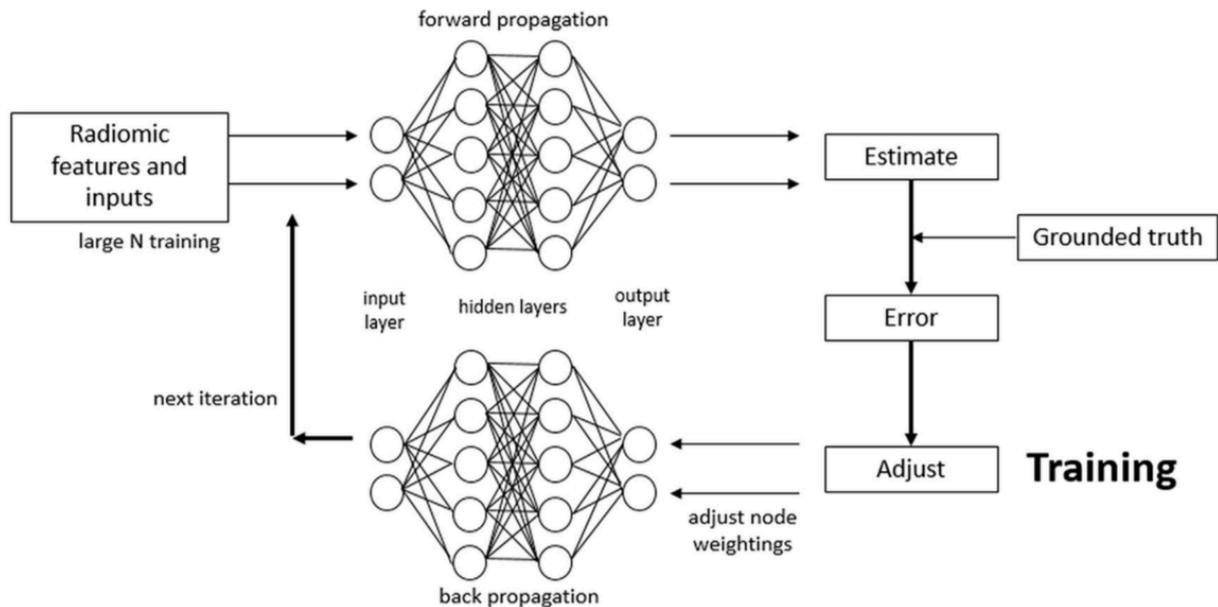
Comme dit précédemment, un système de Deep Learning est composé d'un réseau de neurones artificiels qui assure la double tâche de « feature extraction » et de « classification ».

Un réseau de neurones artificiel (ANN pour Artificial Neural Network) est constitué d'une dizaine jusqu'à plusieurs millions de neurones configurés en plusieurs couches superposées (layers)<sup>19</sup>. Chaque couche possède une entrée et un résultat de sortie. L'entrée de la couche  $n+1$  est le résultat de la sortie de la couche  $n$ , où s'applique une combinaison linéaire, composée de différents coefficients, permettant de propager l'information selon des seuils et des poids distincts. Plus le poids est élevé, plus il contribue de façon significative au résultat de sortie, à la manière des potentiels d'action au sein des synapses du cerveau humain.

En effet, le réseau de neurones artificiels vise à maximiser les réponses correctes par rapport à une référence (ground truth) en ajustant les pondérations sur chaque neurone en fonction de l'erreur calculé lors de la propagation vers l'avant<sup>20</sup>.

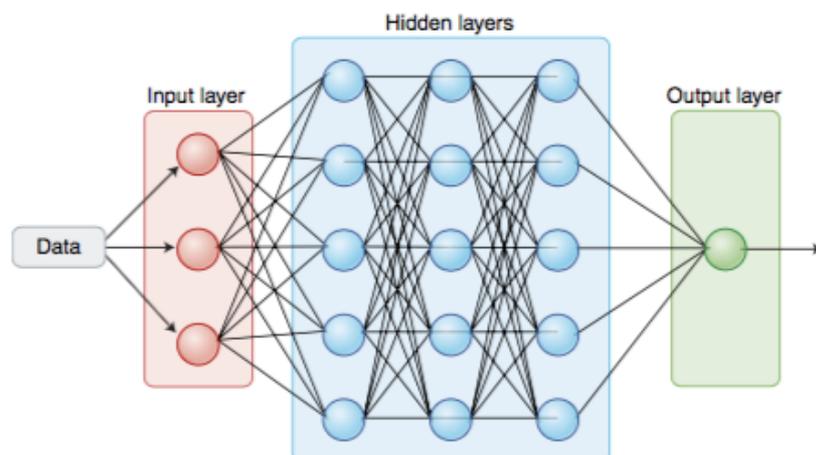
Les différences entre les sorties des neurones et les sorties désirées forment ces erreurs qui sont ensuite corrigées via la rétropropagation (back propagation) <sup>21</sup>. La rétropropagation du gradient de l'erreur est un algorithme d'optimisation permettant d'ajuster les paramètres d'un réseau de neurones multicouches en mettant à jour les poids de chaque neurone de la dernière couche vers la première.

**Figure 8.** Modèle de Deep Learning extrait d'un article de Curie e al, 2019 <sup>20</sup>



En pratique, si les données en sortie d'un nœud vont au-delà du seuil spécifié, ce neurone est activé et envoie ses données aux neurones de la couche suivante. Ce mécanisme est mis en œuvre jusqu'à la dernière couche qui affichera le résultat de sortie final, sous la forme d'une probabilité.

**Figure 9.** Un réseau neuronal de Deep Learning simplifié



Il existe plusieurs types de réseaux de neurones artificiel en fonction des données étudiées. Par exemple, quand on traite d'images on utilise le plus souvent un réseau neuronal convolutif <sup>22</sup>.

À chaque nouveau passage (nouveau calcul), l'algorithme mathématique converge vers une réponse plus correcte, c'est à dire avec une erreur qui tend à diminuer. C'est la phase d'apprentissage de notre modèle.

Un réseau de neurones performant aura besoin d'une quantité de données plus importantes et annotées de façon fiable pour s'entraîner en comparaison à des modèles de prédiction statistiques moins complexes ( Machine Learning traditionnelle).

Après la phase d'entraînement de notre modèle vient la phase de test. En général on utilise un 1<sup>er</sup> dataset pour l'entraînement puis un 2<sup>nd</sup> pour tester les performances de notre modèle. Ce sont les résultats de cette 2<sup>e</sup> phase qui sont en général publiés dans les études scientifiques.

Un 3<sup>e</sup> dataset est souvent utilisé ensuite pour évaluer l'efficacité et valider l'utilisation du modèle créé (base de données ou cohorte de validation).

### **C. Place de l'intelligence artificielle dans l'imagerie hépatique**

Depuis les années 2010 et les progrès de l'IA, on note de plus en plus d'application de l'Intelligence Artificielle à la médecine y compris en hépato-gastro-entérologie <sup>23</sup>.

Avec les avancées du Deep Learning en termes de classification, détection et de segmentation des images, de nombreux chercheurs et compagnies ont commencé à développer des systèmes de computer- aided diagnostic utilisant le Machine Learning en radiologie <sup>24</sup>.

Le tableau ci-dessous regroupe les principales études utilisant de l'IA en imagerie hépatique ces dernières années (Table 1).

**Table 1. Artificial Intelligence and liver imaging**

First Author	Diseases/ lesions	Year	Diagnostic	AI classifier	No of images/cases in training set (positive/negative)	No of images/cases in test set (positive/negative)	Accuracy %	Sensitivity %	Specificity %	AUC
Acharya e al <sup>25</sup>	Fatty liver disease FLD	2016	Ultrasound	ANN	50 normal / 50 fatty liver disease FLD		98	100	96	
Biswas e al <sup>26</sup>	Fatty liver disease	2017	Ultrasound		63 patients ( 27 normal / 36 abnormal)					
Chen e al <sup>27</sup>	HBV-associated fibrosis	2017	Real-time tissue elastography	SVM / RF	257	256	91,3	72,9	99,2	0,83
Wang e al <sup>28</sup>	HBV-associated fibrosis	2019	Shear wave elastography	CNN	1330 from 266 patients	660 from 132 patients		90,4	98,3	0,98
Gatos e al <sup>29</sup>	Chronic liver disease	2017	Shear wave elastography	SVM	126 (56/70) from 126 patients		87,3	93,5	81,2	
Zhang e al <sup>30</sup>	Liver fibrosis	2012	Ultrasound	ANN	179 patients	60 patients	88,3	95	85	
Meng e al <sup>31</sup>	Liver fibrosis	2017	Ultrasound	FCN	79 normal/ 89 early-stage fibrosis/ III late-stage fibrosis		93,9	88,6	97,1	
Yasaka e al <sup>32</sup>	Liver fibrosis	2018	CT	CNN	396 portal phase images	100 images				0,74-0,73

First Author	Diseases/ lesions	Year	Diagnostic	AI classifier	No of images/cases in training set (positive/negative)	No of images/cases in test set (positive/negative)	Accuracy %	Sensitivity %	Specificity %	AUC
Choi e al <sup>33</sup>	Liver fibrosis	2018	CT		7461 patients	891 patients	79,4			0,94-0,97
Lee e al <sup>34</sup>	Liver fibrosis	2020	Ultrasound	CNN	13 608 images (3446 patients)	300 images (266 patients)	83,5			0,90
Li e al <sup>35</sup>	Liver fibrosis	2020	CT	ResNet	278 patients	69 patients				0,90-0,97
Budai e al <sup>36</sup>	Liver fibrosis	2020	CT	SVM	32 patients					0,90
Yin e al <sup>37</sup>	Liver fibrosis	2021	CT	Grad-cam	252 patients					0,88-0,92
Hectors e al <sup>38</sup>	Liver fibrosis	2021	MRI	ImageNet VGG16	178 patients	54 patients				0,77-0,91
Xie e al <sup>39</sup>	Liver fibrosis	2022	Ultrasound	CNN with GoogLeNet	780 patients					0,95
Strotzer e al <sup>40</sup>	Liver fibrosis	2022	MRI	U-shaped CNN	90 patients	22 patients				0,752
Liu e al <sup>41</sup>	Liver cirrhosis	2017	Ultrasound	CNN	47 cirrhosis/ 44 normal		86,9			
Nowak e al <sup>42</sup>	Liver cirrhosis	2021	MRI	ResNet 50 CNN	713 patients	70% for train, 30% for validation/test				0,96

First Author	Diseases/ lesions	Year	Diagnostic	AI classifier	No of images/cases in training set (positive/negative)	No of images/cases in test set (positive/negative)	Accuracy %	Sensitivity %	Specificity %	AUC
Virmani e al <sup>43</sup>	HCC	2013	Ultrasound	SVM	15 normal/ 16 cirrhotic/ 25 HCC		88,8	90		
Balasubramanian e al <sup>44</sup>	Focal Liver Lesions	2007	Ultrasound	GLCM	160 ultrasound		90			
Wu e al <sup>45</sup>	Focal liver lesions (FFL)	2014	Contrast-enhanced ultrasound	DBN	6 HCC / 10 hemangioma/ 4 liver abcesses / 3 metastases / 3 localized fat sparings		86,36	83,3	87,5	
Kalyan e al <sup>46</sup>	Focal liver lesion	2014	Ultrasound	ANN + GLRLM	60 images	40 images	92,5	95	90	
Hwang e al <sup>47</sup>	Focal liver lesions	2015	Ultrasound	ANN	115 patients		96			
Hassan e al <sup>48</sup>	Focal liver lesions (FFL)	2017	Ultrasound	Sparse autoencoder	44 cyst/ 18 hemangioma/ 30 HCC/ 16 normal		97,2	98	95,70	
Yasaka e al <sup>49</sup>	Focal liver lesions (FFL)	2018	CT- scan	CNN	55 536 images		100	84		0,92
Guo e al <sup>50</sup>	Liver lesions	2018	Contrast-enhanced ultrasound	Multiple kernel learning	93 lesions ( 47 malignant cancers vs 46 benign tumors)		90,41 +/- 5,80 %	93,56 +/- 5,90%	86,89 +/- 9,38%	
Schmauch e al <sup>51</sup>	Focal liver lesions (FFL)	2019	Ultrasound	CNN	245 patients	122 patients				0,935

First Author	Diseases/ lesions	Year	Diagnostic	AI classifier	No of images/cases in training set (positive/negative)	No of images/cases in test set (positive/negative)	Accuracy %	Sensitivity %	Specificity %	AUC
Mostafiz e al <sup>52</sup>	Liver Lesions	2020	US	CNN	298 ultrasound		98,4			
Zhen e al <sup>53</sup>	Liver tumors	2020	Dynamic contrast-enhanced MRI	CNN	1210 patients ( 31 608 images)	201 patients (6 816 images)		91,9	94,1	0,95
Cao e al <sup>54</sup>	Focal Liver Lesions	2020	Dynamic contrast enhanced CT	CNN	410 images	107 images	81,3%			0,92

## II. Objectifs du travail

En tant que médecin, qu'on soit généraliste, radiologue ou hépato-gastro-entérologue, faire face à un patient présentant une lésion hépatique est une situation fréquente.

La caractérisation fiable d'une lésion hépatique répond à différents objectifs selon les situations. La caractérisation de tumeurs hépatiques de découverte fortuite vise à identifier la minorité d'entre elles qui sont associées à un risque évolutif afin d'éviter qu'elles n'évoluent sans traitement ni surveillance tout en évitant d'exposer la majorité d'entre elles qui sont sans risque évolutif à un excès d'examens qui génèrent, outre des coûts, des irradiations inutiles et de l'anxiété lors de l'attente des résultats pour les patients.

Par ailleurs, une détection et caractérisation de lésion hépatique fiable lors d'une échographie hépatique de suivi dans le cadre du dépistage de carcinome hépatocellulaire dans les hépatopathies chroniques, et lors de la surveillance de cancer colique est nécessaire.

L'intelligence artificielle est au cœur de l'innovation technologique de ces 20 dernières années et la médecine en est un sujet fort. L'imagerie médicale, principalement parce qu'elle génère une quantité massive de données déjà dématérialisées (numérisées dans les systèmes d'archivage) et que les modèles de Machine Learning / Deep Learning sont particulièrement performants sur l'image est une des spécialités les plus concernées par les avancées de l'Intelligence Artificielle.

Quelques études basées sur l'apprentissage profond (Deep Learning) ont été développées en utilisant l'échographie de contraste, le scanner et l'IRM pour caractériser des lésions hépatiques focales <sup>45,49,53</sup>. Concernant l'échographie hépatique standard, on peut citer l'étude de Hassan et al qui trouvaient à partir de 110 images échographiques incluant des kystes, des hémangiomes, des carcinomes hépatocellulaires et des foies sains, une sensibilité et spécificité d'environ 97% mais il n'était question que de classification et non de double tâche (détection + classification) <sup>48</sup>.

Ainsi l'objectif de ce travail est de rechercher et développer un outil d'imagerie innovant à l'aide de l'Intelligence Artificielle, utile en pratique clinique, qui assurerait la double tâche de détecter une lésion hépatique puis de la caractériser de façon fiable.

### **III. Article original**

## **Detection and characterization of Focal Liver Lesions on ultrasound images with the Qwanteus DETECT Deep Learning program : an exploratory study**

### **1. Introduction**

For decades, ultrasound image has been extensively applied in the detection and classification of different diseases including liver diseases. Its high safety, high efficiency and cost explains this attractivity<sup>1</sup>. However, ultrasound image has several limitations. It requires years of experience and training to be an excellent radiologist. Moreover, in modern medicine, the number of imaging examinations is steadily increasing, along with the complexity of interpretation and demands on providers for access to healthcare data, collaborative decision making, and quality accountability measures<sup>55</sup>. In this context, the Computer Aided Diagnosis can be a powerful tool to assist radiologists. It can assist physicians to make more accurate and reproductive imaging diagnosis leading to reduce the risk of mistakes and physician's workload<sup>56</sup>. Liver diseases can be classified in two parts : diffuse disease and focal liver lesions<sup>57</sup>. In focal liver lesions, we can distinguish benign and malignant lesions. Liver lesions are frequent and in daily practice, the accidental detection of focal liver lesions when US is performed constitutes a frequent circumstance, up to 10 to 30% of explorations depending on the studies<sup>7 8</sup>. Although they are less common than benign, surveillance of malignant focal liver lesions (namely hepatocellular carcinoma HCC and metastasis) represent a common indication for liver ultrasound. Current guidelines recommend to perform liver ultrasound every 6 months for patients with chronic liver disease to detect eventual HCC and regular abdominal ultrasound for 5 years after resection of colon cancer<sup>12,13</sup>.

Considering the number and diversity of the focal liver lesions and thus of treatment and follow up, the proper classification of focal liver lesions is an unmet need in clinical practice.

Several Deep-Learning-based models have been developed using contrast-enhanced ultrasound, CT scan and MRI to characterize focal liver lesions<sup>45,49,53</sup>. Using ultrasound images, Hassan et al. found from 110 US images including cysts, hemangiomas, hepatocellular carcinoma and healthy liver a sensitivity and specificity accuracy around 97% for the classification of thus lesions<sup>48</sup>. This study only focused on the classification of the lesions and not in the double action of detection and classification.

Considering these data, the development of new Deep Learning models able to detect focal liver lesions and then properly characterize them remains an unmet need. Combining the latest advances in artificial intelligence and ultrasound to perform detection and characterization with only one examination could be useful in daily practice. We therefore performed a study aiming at developing a new model to evaluate the detection rate and then in a second time the characterization of focal liver lesions on ultrasound images with the help of a Deep Learning-based Artificial Intelligence program.

## **2. Patients and methods**

We conducted this work in collaboration with a startup specialized in Artificial Intelligence and specially Machine Learning (Qwanteus), which purpose was to develop an early liver cancer detection tool using an innovative ultrasound imaging solution.

### **2.1. Database preparation**

In order to successfully train a Deep Learning model with a lot of data, we downloaded images from internet using a web crawler (Appendix Table 1), specifically dedicated to liver diseases. Once downloaded, the images were grouped into categories, corresponding to liver medical conditions categories. Each category included several cases.

The categories were: amebic abscess, benign cysts, fatty liver, focal nodular hyperplasia, hemangiomas, normal liver, hepatitis, hepatocellular carcinoma, hydatid cysts, liver cirrhosis, liver trauma, lymphoma, metastases, adenoma and miscellaneous liver.

We could thus generate a database, named Qwanteus Liver database (QWL database, Appendix Figure 1) including a total of 5400 images collected over the internet of different sizes and modalities (CT, US, contrast-enhanced US, Doppler US) and categorized into 15 categories.

For the aim of the present study, we selected among the QWL database, the images fulfilling the following criteria: (i) only ultrasound, (ii) no contrast-enhanced ultrasound imaging nor Doppler ultrasound imaging, and (iii) no extremely noisy images. Then, we focused on the 6 most frequent tumors affecting the liver, namely adenoma, hemangioma, focal nodular hyperplasia (FNH), cysts, metastasis and hepatocellular carcinoma (HCC). The resulting database referred as QWLUS database, dedicated to the present study and used to train and select the best model, was composed of 790 images sorted into six categories.

## 2.2.Annotation process

We used Bounding Boxes, which is one of the most widely-used annotation methods (Appendix Table 1). Images were annotated using the Computer Vision Annotation Tool (CVAT) which is an open-source annotation tool developed by Intel researchers. All image were resized to 480 x 480 pixels (Appendix Figure 2).

Each type of focal liver lesion had a specific color of Bounding Boxes as follow: red for adenoma, pink for hemangioma, dark orange for FNH, light orange for cyst, light green for metastasis and dark green for HCC.

## 2.3.Object detection networks

We used and tested three different type of object detection networks : Faster R-CNN (Appendix Figure 3) , YOLO (Appendix Figure 4) (Appendix Table 1) and YOLO LT.

YOLO LT is a modified version of the last version of YOLO specifically developed by Qwanteus for liver tumor detection. Among the most important modifications, two additional layers were implemented and then added to YOLO to overcome the issues of variation in tumor's size. The stride of the first additional layer was set to 64 for detecting large tumors, while the stride of the second layer was set to 4 for detecting small tumors. Since some categories were much better represented than others, the use of focal loss was integrated in YOLO LT to address this problem of class imbalance. We empirically determined that the best activation function was the Hardwish function (Appendix Table 1). YOLO LT was the most relevant algorithm to our task.

We used Pytorch for YOLO and Python language (Appendix Table 1). The experiments were conducted on two NVIDIA graphics cards type RTX 3090 and RTX 2080Ti (Appendix Table 1).

## 2.4.Validation database

We retrospectively collected images from patients in the medical database of the University Hospital of Tours. The retrospective study was reviewed and approved by our local institutional review board ( N°2021\_007) .

Eligible patients were 18 years old with available ultrasound imaging of the liver acquired by vector probe. We selected images of the previously selected focal liver lesions namely adenoma, hemangioma, focal nodular hyperplasia (FNH), cysts, metastasis, hepatocellular

carcinoma (HCC) as well as patients with healthy liver. Patients with more than one focal liver lesion could be included if we could select images with no more than 2 lesions. In all patients, a diagnostic confirmation of focal liver lesions using the gold standard method (either imaging, or histology, depending on the cases) was available (Table 1). Ultrasound images with annotation, pictogram, arrow or other symbol added were excluded, as well as zoomed images. The images were collected by a gastroenterology resident and an experienced radiologist from the bank of image of the institution (the picture archiving and communication system PACS). Basic information about the patients was obtained from the hospital information system, including gender and age.

The image annotation was performed using the CVAT application by a clinical research engineer expert in image analyses, using the information provided by the clinicians (identification of the patient, date of the ultrasound, number of the image or time of the examination). For each selected image, an anonymized raw image and an image annotated with the specialist comment were provided to Qwanteus.

**Table 1.** Criteria used for diagnosis of focal liver lesions <sup>58</sup>

Focal Liver Lesion	Gold standard diagnosis
Adenoma	<b>Magnetic Resonance Imaging</b> with contrast injection : criteria depending on the sub-type Or <b>histology</b> after resection
Hemangioma	<b>Ultrasound</b> is sufficient with image of hyperechoic homogenous nodule, with well-defined margins and posterior acoustic enhancement.
Focal nodular hyperplasia	<b>Magnetic Resonance Imaging:</b> homogeneous lesion except for specific hypointense central scar on T1 and hyperintense central scar on T2
Cyst	<b>Ultrasound:</b> unilocular space filled with fluids, thin walls and posterior acoustic enhancement
Metastasis	<b>Histology</b> or triple-phase <b>Computed Tomography scan:</b> hypodense before injection and then heterogeneous contrast enhancement predominant in periphery in a patient with known primary tumor Specific characteristics depends on the primary tumor
Hepatocellular carcinoma	<b>Computed Tomography scan</b> with enhancement during arterial phase and then a wash out during portal phase (wash in-wash out)

## 2.5. Statistical Analyses

The diagnostic performances of our model were evaluated using Sensitivity, Specificity, positive predictive value (see below). The diagnostic accuracy corresponded to the proportion of well-classified patients. The formulas used are listed below.

As a reminder TP = true positive, TN = true negative, FP = false positive and FN = false negative

- Sensitivity =  $\frac{TP}{TP+FN}$
- Specificity =  $\frac{TN}{TN+FP}$
- Positive predictive value =  $\frac{TP}{TP+FP}$
- Diagnostic Accuracy =  $\frac{TP+TN}{TP+FP+FN+TN}$

For detection, we evaluated the ability of our model to correctly detect the lesion in the image, meaning putting a rectangle annotation correctly around the lesion in the image. If the model placed the rectangle in a area of the image free from any lesion, it was considered as non detection of the focal liver lesion.

For the characterization of focal liver lesions, the performance of the model was evaluated for each focal liver lesion, as compared to the rest of the dataset. As an example, if we evaluated the performance of the model for the diagnosis of adenoma, all the other liver lesions were considered as a whole group of images with “no adenomas”. When the model detected the lesion, it outputted a score from 0 to 1 for each category of focal liver lesion. This score can be interpreted as the probability of presence of such lesion in the image.

## 3. Results

### 3.1. QWLUS database

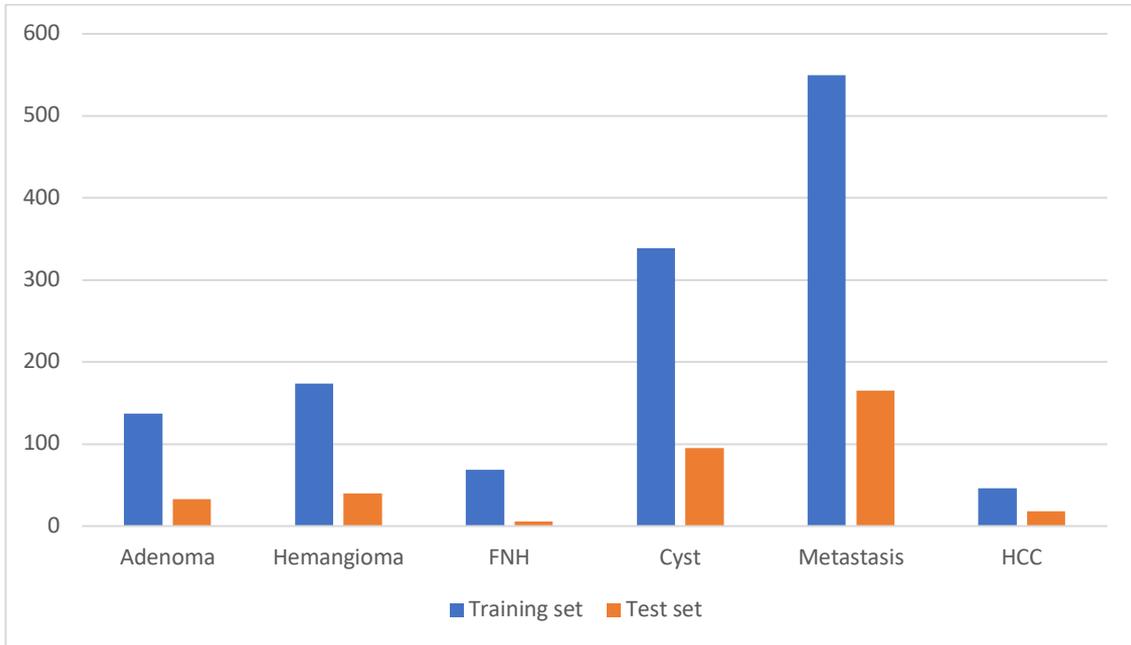
1672 focal liver lesions were selected and annotated in the QWLUS database (images collected from internet) including 170 adenomas, 214 hemangiomas, 75 focal nodular hyperplasia (FNH), 434 cysts, 715 metastasis and 64 hepatocellular carcinomas (HCC).

This database was then divided into two sets : a training set of 630 images (and 1315 annotations), and 160 images (and 357 annotations) for the test set (Figure 1).

**Figure 1.** Distribution of the focal liver lesions in the QWLUS database

Training set n = 1315 focal liver lesions annotations (630 images)

Test set n = 357 focal liver lesions annotations (160 images)



We trained and tested three different type of object detection networks with the images from QWLUS database : Faster R-CNN, YOLO and YOLO LT. The Table 2 indicates the results of the test set for each network. The same training and test sets were used for both networks.

We obtained the best results with YOLO LT in term of Sensitivity (86,8% versus 58,4% and 77,4% with Faster R-CNN and YOLO, respectively) and positive predictive value (57,9% versus 28,4% and 34,9% with Faster R-CNN and YOLO, respectively). This lead us to choose to integrate YOLO-LT to the Computed Aided Diagnostic model developed by Qwanteus called DETECT. The inference time was 12 ms, this is equal to 83 frames per second.

The results obtained for the characterization of each lesion using DETECT in the QWLUS database are shown in Table 3. The best results were obtained for the following local liver lesions : cyst, adenoma and FNH. The worst results were obtained for metastasis and HCC.

**Table 2.** Results of the test set from QWLUS database with Faster R-CNN / YOLO and YOLO LT algorithm for tumor detection

n = 357 focal liver lesions annotations (160 images)

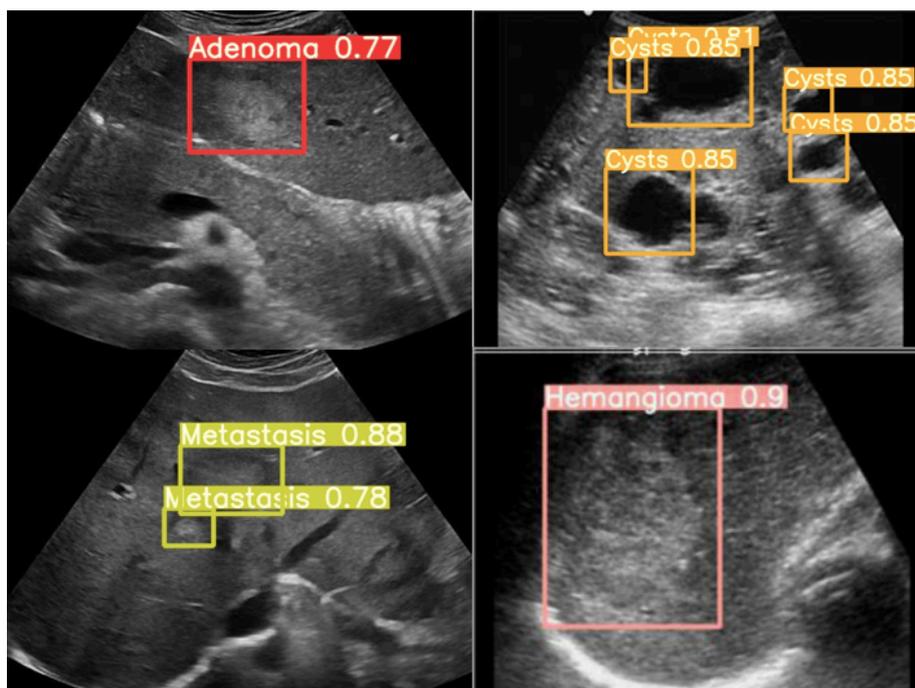
	Sensitivity	PPV
	%	%
Faster R-CNN	58,4	28,9
YOLO	77,4	34,9
YOLO LT	86,8	57,9

**Table 3.** Results of the test set from QWLUS database for characterization with YOLO LT algorithm in each class

n = 357 focal liver lesions annotations (160 images)

YOLO LT	Sensitivity	Specificity	PPV	Diagnostic Accuracy
	%	%	%	%
Adenoma	45	98,7	75	94,7
Hemangioma	42	97,4	63	92,4
FNH	50	99,3	50	98,6
Cysts	61	91,7	67	84,9
Metastasis	46	83,5	63	69,3
HCC	22	99	66	96,3

**Figure 2.** Examples of object detection of focal liver lesion with QWLUS database



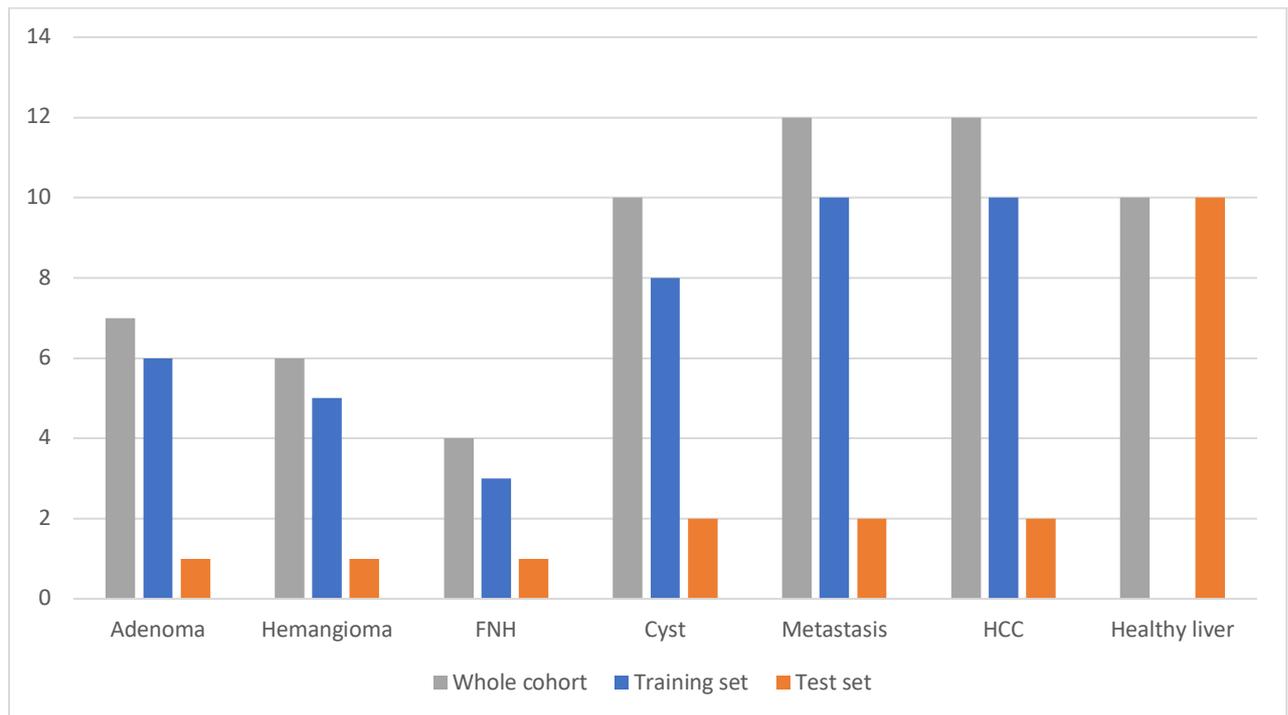
### 3.2. Validation database

61 patients, from the University Hospital of Tours, were included in the validation database. The repartition of the lesions is reported in Figure 3. 27 women and 34 men were included in this database. The median age was 60 years (range 20-80 years).

Because of the diversity of the validation database with atypical images, the engineer of Qwanteus decided to divide the validation database into two sets in order to “re”-train the model with new atypical images. For this purpose, 42 patients were used for training and 19 patients for the test set.

Among the 19 patients we had 10 patients with healthy liver and 9 focal liver lesions including one adenoma, one hemangioma, one FNH, two cysts, two metastasis and two HCC.

**Figure 3.** Repartition of the type of focal liver lesions in the validation database (whole cohort n = 61, training set n = 42, and test set n = 19)



We finally obtained a sensitivity of 66%, specificity of 90%, a PPV of 85% and a diagnostic accuracy of 78,9% with our model DETECT (Table 4).

Six out of 9 focal liver lesions were properly detected.

**Table 4.** Results of the test set for tumor detection with Qwanteus Model called DETECT and validation database from the University Hospital of Tours

n = 19 patients

DETECT by	Sensitivity	Specificity	PPV	Diagnostic Accuracy
QWANTEUS	%	%	%	%
All	66	90	85	78,9

The results obtained for the characterization of each lesions using DETECT in the validation database are shown in Table 5. The best results were obtained for the characterization of adenoma, cyst and HCC.

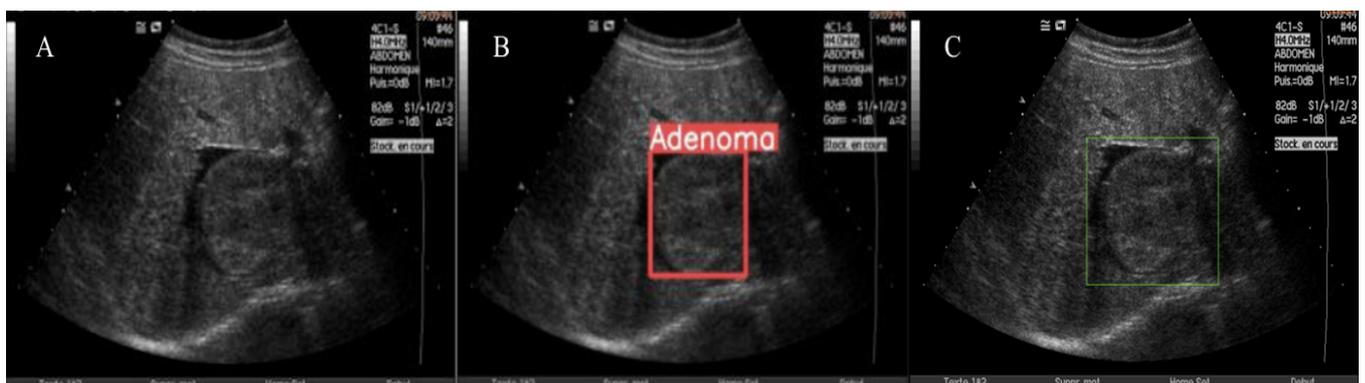
**Table 5.** Results of the test set for tumor characterization with Qwanteus Model called DETECT and validation database from the University Hospital of Tours

n = 19 patients

DETECT by	Sensitivity	Specificity	PPV	Diagnostic Accuracy
QWANTEUS	%	%	%	%
Adenoma	100	94,4	50	94,7
Hemangioma	0	94	0	89,4
FNH	0	100	0	94,7
Cysts	100	88,2	50	89,4
Metastasis	0	100	0	89,4
HCC	50	94,1	50	89,4

**Figure 4.** Example of object detection with DETECT in the validation database

A. The raw and anonymized image given to Qwanteus ; B. Same image annotated given to Qwanteus ; C. Same image with the result given by DETECT



#### 4. Discussion

This study is one of the first to assess the performance of a deep-learning based model from ultrasound images. Although this was an exploratory data, based on a limited number of cases, we obtained promising results.

The first major finding of this study is that we obtained good performances for the detection of focal liver lesions. The performance of the DETECT algorithm was excellent when tested in the QWLUS database, including images selected from the web. In this setting, the sensitivity was almost 90%. In the validation database, including US images selected from patients from our center, the sensitivity and the positive predictive value were 66% and 85%, respectively. The less good results can be explained by the diversity of the validation database with atypical images.

In routine clinical practice, the interest of such Computer Aided Diagnosis model that can correctly detect a focal liver lesion on an ultrasound image is to reinforce the clinician diagnosis and allow the diagnosis of unseen lesion. Having the best detection rate of focal liver lesion is particularly useful in the surveillance of malignant focal liver lesion. Indeed, an early detection of HCC is associated with a significant increase of the proportion of tumors diagnosed at a curable stage and overall survival<sup>59</sup>. In cases of liver metastasis, the early detection may allow surgical treatment according to the sizes and the number of liver lesions<sup>60</sup>. The sensibility of ultrasound to detect HCC inferior to 10 mm is quite low with a diagnosis of HCC possible in a third of the cases<sup>61</sup>. Similarly, the sensitivity to detect liver metastasis decreases with the size < 10 mm, the iso-echogenicity of the lesion or the localization (a peripheric or subcapsular or hepatic dome)<sup>13</sup>. They are some limitation to detection of focal liver lesion with ultrasound. With the increase number of patients worldwide suffering from obesity and metabolic syndrome, fatty infiltration of the liver is projected to increase significantly in multiple world regions by 2030<sup>62</sup>. Focal or diffuse liver infiltration impact the image of the ultrasound by increasing the echogenicity, decreasing image quality owing to signal attenuation and thus leading to difficult interpretation of the ultrasound <sup>63</sup>. The impact and help of AI model in particular situations of difficult focal liver lesion detection such as liver steatosis could be important <sup>64</sup>. Further studies will be needed to assess the ability of our model to detect focal liver lesion in patients with steatotic liver disease. The inference time for detection with our model was 12 ms. Having a performant and fast Detection Computer Aided Diagnosis model on ultrasound can decrease the time of an examination in a era of modern medicine where the number of imaging examinations is steadily increasing, along with the complexity of interpretation.

The second major finding is that the DETECT model showed good results in characterization of focal liver lesions in the QWLUS database particularly in adenoma with a PPV of 75% and cysts with a PPV of 67%. Inferior results were obtained for HCC with a sensitivity of 22%. The Deep Learning technique using Stacked Sparse Auto-encoders (SSAE) with ultrasound images, developed by Hassan et al, obtained highest results in characterization with accuracy, sensitivity and specificity above 90% for cyst, hemangioma and HCC<sup>48</sup>. This difference might be explained by the architecture of the Deep Learning algorithm itself. The architecture used by Hassan et al (Stacked Sparse Auto-encoders SSAE) can extract the high-level feature representations of input images, given the ability of the model to better diagnose the lesions from the patient images.

When tested in the validation database, the performance of the DETECT model was lower, for all the focal liver lesions tested. However, since the tests were performed in only 19 patients, including 10 healthy liver, it is impossible to draw any conclusion. Further studies, including a large number of images will be needed to clarify the value of the DETECT model for the characterization of focal liver lesions.

Another important finding is that in the present study, we showed the feasibility of using ultrasound images from the Web to develop Deep Learning models. This approach has never been proposed so far with ultrasound images<sup>44-48,51,52</sup>, and thus included a limited number of cases – 367 in the larger study<sup>51</sup>. The use of a web crawler permitted us to create a large database. Indeed, the number of cases included in the training set is crucial to improve the performance of a Deep Learning based model<sup>21</sup>. Using this original approach, our database, including 1672 focal liver lesions, is the largest to date. On another hand, the fact that images were collected randomly via a web crawler had some disadvantages. We did not have the possibility to assess the quality of the images in the QWLUS database. The images captured from the web came from different origins including different setting and machines. It is important to keep in mind that our results were obtained from selected images. Our study presented results on a limited sample of patients, not representative of the general population. We will need to have prospective study in real life to validate our Deep Learning model. Furthermore, we trained and tested our model with frozen ultrasound images whereas ultrasound is a dynamic examination. The clinician scans the liver with the ultrasound probe with several angles and positions which allow several views of the same image and facilitate the characterization of the lesion. We thus will need to train future Deep Learning models with videos of ultrasound in order to have the dynamic aspect of this examination.

In conclusion, this study shows that the Deep Learning model DETECT, based on routine ultrasound images, showed good results for the detection of focal liver lesions. Further improvement is needed to improve its performance for the characterization of focal liver lesions. The results of this study confirms the potential of Artificial Intelligence to improve the accuracy of ultrasounds for the diagnosis of focal liver lesions.

## 5. References

1. Aubé, C. Nouvelles perspectives de l'échographie en pathologie hépatique. 8.
2. Poirier-Quinot, M. L'Imagerie Médicale, quand la physique rencontre la médecine. *Rev. 3EI* (2019).
3. Lemort, M. Principes de base échographie. (2022).
4. Aygalenq, P. Douleurs abdominales explorées par échographie au décours de la consultation ou la naissance de l'échoscopie. (2017).
5. SNFGE. *Le Livre Blanc de l'Hépto-Gastroentérologie*. (2001).
6. Lucidarme, O. *Échographie abdominale*. (Elsevier Masson, 2017).
7. Kaltenbach, T. E.-M. *et al.* Prevalence of benign focal liver lesions: ultrasound investigation of 45,319 hospital patients. *Abdom. Radiol.* **41**, 25–32 (2016).
8. Dietrich, C. F. Fortuitously discovered liver lesions. *World J. Gastroenterol.* **19**, 3173 (2013).
9. AFEF. Recommandations pour le diagnostic et le suivi non-invasif des maladies chroniques du foie. (2020).
10. Barbier, L. *et al.* Natural history of liver adenomatosis: A long-term observational study. *J. Hepatol.* **71**, 1184–1192 (2019).
11. Tasu, J.-P. & Vialle, R. Diagnostic du carcinome hépatocellulaire : apport de l'imagerie. *EMC - Hépatologie* **6**, 1–11 (2011).
12. Blanc, J. F. *et al.* Hepatocellular carcinoma: French Intergroup Clinical Practice Guidelines for diagnosis, treatment and follow-up (SNFGE, FFCD, GERCOR, UNICANCER, SFCD, SFED, SFRO, AFEF, SIAD, SFR/FRI). *Clin. Res. Hepatol. Gastroenterol.* **45**, 101590 (2021).
13. Lecomte T, Tougeron D, Chautard R, Bressand D, André T, Bibeau F, Blanc B, Cohen R, Jacques J, Lagasse JP, Laurent-Puig P, Lepage C, Lucidarme O, Martin-Babau J, Panis Y, Portales F, Taieb J, Aparicio T, Bouché O. Non-metastatic colon cancer-French Intergroup Clinical Practice Guidelines for diagnosis, treatments and follow-up (TNCD, SNFGE, FFCD, GERCOR, UNICANCER, SFCD, SFED, SFRO, ACHBT, SFP, AFEF, SFR). *Digestive and Liver Disease* (2023).
14. Defossez, G. *Estimations nationales de l'incidence et de la mortalité par cancer en France métropolitaine entre 1990 et 2018: étude à partir des registres des cancers du réseau Francim, résultats préliminaires synthèse*. (Santé publique France, 2019).
15. Cour des Comptes. L'imagerie médicale. Communication à la commission des affaires sociales du Sénat. (2016).
16. Russell, S. J., Norvig, P. & Davis, E. *Artificial intelligence: a modern approach*. (Prentice Hall, 2010).
17. Jiang, T., Gradus, J. L. & Rosellini, A. J. Supervised Machine Learning: A Brief Primer. *Behav. Ther.* **51**, 675–687 (2020).
18. LeCun, Y., Bengio, Y. & Hinton, G. Deep learning. *Nature* **521**, 436–444 (2015).
19. Tang, A. *et al.* Canadian Association of Radiologists White Paper on Artificial Intelligence in Radiology. *Can. Assoc. Radiol. J.* **69**, 120–135 (2018).
20. Currie, G., Hawk, K. E., Rohren, E., Vial, A. & Klein, R. Machine Learning and Deep Learning in Medical Imaging: Intelligent Imaging. *J. Med. Imaging Radiat. Sci.* **50**, 477–487 (2019).
21. Alzubaidi, L. *et al.* Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *J. Big Data* **8**, 53 (2021).
22. Dhillon, A. & Verma, G. K. Convolutional neural network: a review of models, methodologies and applications to object detection. *Prog. Artif. Intell.* **9**, 85–112 (2020).
23. Le Berre, C. *et al.* Application of Artificial Intelligence to Gastroenterology and Hepatology. *Gastroenterology* **158**, 76-94.e2 (2020).

24. Doi, K. Computer-aided diagnosis in medical imaging: Historical review, current status and future potential. *Comput. Med. Imaging Graph.* **31**, 198–211 (2007).
25. Acharya, U. R. *et al.* An integrated index for identification of fatty liver disease using radon transform and discrete cosine transform features in ultrasound images. *Inf. Fusion* **31**, 43–53 (2016).
26. Biswas, M. *et al.* Syntosis: A liver ultrasound tissue characterization and risk stratification in optimized deep learning paradigm. *Comput. Methods Programs Biomed.* **155**, 165–177 (2018).
27. Chen, Y. *et al.* Machine-learning-based classification of real-time tissue elastography for hepatic fibrosis in patients with chronic hepatitis B. *Comput. Biol. Med.* **89**, 18–23 (2017).
28. Wang, K. *et al.* Deep learning Radiomics of shear wave elastography significantly improved diagnostic performance for assessing liver fibrosis in chronic hepatitis B: a prospective multicentre study. *Gut* **68**, 729–741 (2019).
29. Gatos, I. *et al.* A Machine-Learning Algorithm Toward Color Analysis for Chronic Liver Disease Classification, Employing Ultrasound Shear Wave Elastography. *Ultrasound Med. Biol.* **43**, 1797–1810 (2017).
30. Zhang, L. *et al.* Artificial neural network aided non-invasive grading evaluation of hepatic fibrosis by duplex ultrasonography. *BMC Med. Inform. Decis. Mak.* **12**, 55 (2012).
31. Meng, D. *et al.* Liver fibrosis classification based on transfer learning and FCNet for ultrasound images. *IEEE Access* 1–1 (2017) doi:10.1109/ACCESS.2017.2689058.
32. Yasaka, K., Akai, H., Kunimatsu, A., Abe, O. & Kiryu, S. Deep learning for staging liver fibrosis on CT: a pilot study. *Eur. Radiol.* **28**, 4578–4585 (2018).
33. Choi, K. J. *et al.* Development and Validation of a Deep Learning System for Staging Liver Fibrosis by Using Contrast Agent-enhanced CT Images in the Liver. *Radiology* **289**, 688–697 (2018).
34. Lee, J. H. *et al.* Deep learning with ultrasonography: automated classification of liver fibrosis using a deep convolutional neural network. *Eur. Radiol.* **30**, 1264–1273 (2020).
35. Li, Q. *et al.* Deep residual nets model for staging liver fibrosis on plain CT images. *Int. J. Comput. Assist. Radiol. Surg.* **15**, 1399–1406 (2020).
36. Budai, B. K. *et al.* Three-dimensional CT texture analysis of anatomic liver segments can differentiate between low-grade and high-grade fibrosis. *BMC Med. Imaging* **20**, 108 (2020).
37. Yin, Y. *et al.* Liver fibrosis staging by deep learning: a visual-based explanation of diagnostic decisions of the model. *Eur. Radiol.* **31**, 9620–9627 (2021).
38. Hectors, S. J. *et al.* Fully automated prediction of liver fibrosis using deep learning analysis of gadoxetic acid-enhanced MRI. *Eur. Radiol.* **31**, 3805–3814 (2021).
39. Xie, Y. *et al.* Artificial Intelligence-Based Feature Analysis of Ultrasound Images of Liver Fibrosis. *Comput. Intell. Neurosci.* **2022**, 1–9 (2022).
40. Strotzer, Q. D. *et al.* Application of A U-Net for Map-like Segmentation and Classification of Discontinuous Fibrosis Distribution in Gd-EOB-DTPA-Enhanced Liver MRI. *Diagnostics* **12**, 1938 (2022).
41. Liu, X., Song, J., Wang, S., Zhao, J. & Chen, Y. Learning to Diagnose Cirrhosis with Liver Capsule Guided Ultrasound Image Classification. *Sensors* **17**, 149 (2017).
42. Nowak, S. *et al.* Detection of liver cirrhosis in standard T2-weighted MRI using deep transfer learning. *Eur. Radiol.* **31**, 8807–8815 (2021).
43. Virmani, J., Kumar, V., Kalra, N. & Khandelwal, N. SVM-Based Characterization of Liver Ultrasound Images Using Wavelet Packet Texture Descriptors. *J. Digit. Imaging* **26**, 530–543 (2013).
44. Balasubramanian, D., Srinivasan, P. & Gurupatham, R. Automatic Classification of Focal Lesions in Ultrasound Liver Images using Principal Component Analysis and Neural Networks. in *2007 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society* 2134–2137 (IEEE, 2007). doi:10.1109/IEMBS.2007.4352744.

45. Wu, K., Chen, X. & Ding, M. Deep learning based classification of focal liver lesions with contrast-enhanced ultrasound. *Optik* **125**, 4057–4063 (2014).
46. Kalyan, K., Jakhia, B., Lele, R. D., Joshi, M. & Chowdhary, A. Artificial Neural Network Application in the Diagnosis of Disease Conditions with Liver Ultrasound Images. *Adv. Bioinforma.* **2014**, 1–14 (2014).
47. Hwang, Y. N., Lee, J. H., Kim, G. Y., Jiang, Y. Y. & Kim, S. M. Classification of focal liver lesions on ultrasound images by extracting hybrid textural features and using an artificial neural network. *Biomed. Mater. Eng.* **26**, S1599–S1611 (2015).
48. Hassan, T. M., Elmogy, M. & Sallam, E.-S. Diagnosis of Focal Liver Diseases Based on Deep Learning Technique for Ultrasound Images. *Arab. J. Sci. Eng.* **42**, 3127–3140 (2017).
49. Yasaka, K., Akai, H., Abe, O. & Kiryu, S. Deep Learning with Convolutional Neural Network for Differentiation of Liver Masses at Dynamic Contrast-enhanced CT: A Preliminary Study. *Radiology* **286**, 887–896 (2018).
50. Guo, L.-H. *et al.* A two-stage multi-view learning framework based computer-aided diagnosis of liver tumors with contrast enhanced ultrasound images. *Clin. Hemorheol. Microcirc.* **69**, 343–354 (2018).
51. Schmauch, B. *et al.* Diagnosis of focal liver lesions from ultrasound using deep learning. *Diagn. Interv. Imaging* **100**, 227–233 (2019).
52. Mostafiz, R., Rahman, M., Islam, A. & Belkasim, S. Focal Liver Lesion Detection in Ultrasound Image Using Deep Feature Fusions and Super Resolution. *Mach. Learn. Knowl. Extr.* **2**, 172–191 (2020).
53. Zhen, S. *et al.* Deep Learning for Accurate Diagnosis of Liver Tumor Based on Magnetic Resonance Imaging and Clinical Data. *Front. Oncol.* **10**, 680 (2020).
54. Cao, S.-E. *et al.* Multiphase convolutional dense network for the classification of focal liver lesions on dynamic contrast-enhanced computed tomography. *World J. Gastroenterol.* **26**, 3660–3672 (2020).
55. Reiner, B. I. & Krupinski, E. The Insidious Problem of Fatigue in Medical Imaging Practice. *J. Digit. Imaging* **25**, 3–6 (2012).
56. Topol, E. J. High-performance medicine: the convergence of human and artificial intelligence. *Nat. Med.* **25**, 44–56 (2019).
57. M.Hassan, T., Elmogy, M. & Sallam, E. Medical Image Segmentation for Liver Diseases: A Survey. *Int. J. Comput. Appl.* **118**, 38–44 (2015).
58. EASL Clinical Practice Guidelines on the management of benign liver tumours. *J. Hepatol.* **65**, 386–398 (2016).
59. Singal, A. G. *et al.* HCC surveillance improves early detection, curative treatment receipt, and survival in patients with cirrhosis: A meta-analysis. *J. Hepatol.* **77**, 128–139 (2022).
60. Phelip, J. M. *et al.* Metastatic colorectal cancer (mCRC): French intergroup clinical practice guidelines for diagnosis, treatments and follow-up (SNFGE, FFCD, GERCOR, UNICANCER, SFCD, SFED, SFRO, SFR). *Dig. Liver Dis.* **51**, 1357–1363 (2019).
61. Trinchet, J.-C. *et al.* Ultrasonographic surveillance of hepatocellular carcinoma in cirrhosis: A randomized trial comparing 3- and 6-month periodicities. *Hepatology* **54**, 1987–1997 (2011).
62. Teng, M. L. *et al.* Global incidence and prevalence of nonalcoholic fatty liver disease. *Clin. Mol. Hepatol.* **29**, S32–S42 (2023).
63. Van Vledder, M. G. The Effect of Steatosis on Echogenicity of Colorectal Liver Metastases on Intraoperative Ultrasonography. *Arch. Surg.* **145**, 661 (2010).
64. Wu, S. *et al.* Impact of variations in fatty liver on sonographic detection of focal hepatic lesions originally identified by CT. *Ultrasonography* **35**, 39–46 (2016).
65. Lutz, M. *Learning Python*. (O'Reilly Media, 2009).
66. Redmon, J., Divvala, S., Girshick, R. & Farhadi, A. You Only Look Once: Unified, Real-Time Object Detection. (2015) doi:10.48550/ARXIV.1506.02640.

## 6. Appendix

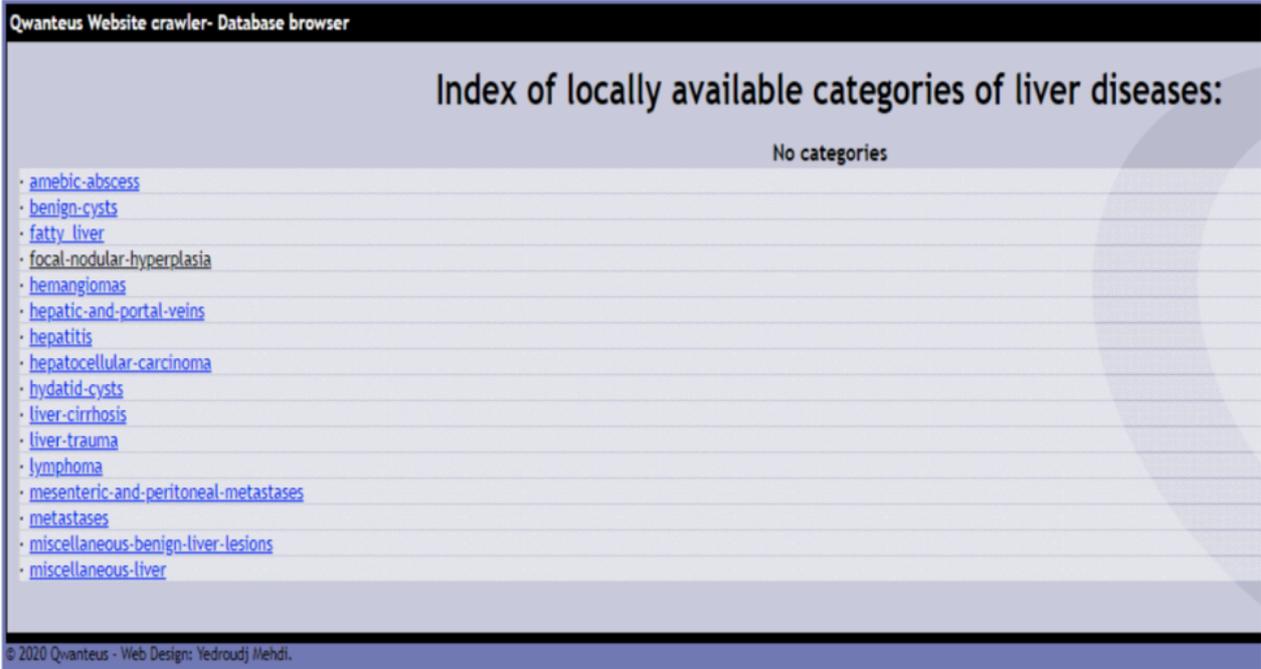
**Appendix Table 1**

<p><b>Web crawler</b></p>	<p>In order to successfully train a Deep Learning model, a large amount of input data is required. This is one of the limits for the practical applications of deep models in medical image analysis, as the available medical image data sets, if any, are generally limited. One possible solution to collect a lot of images over the internet is a web image crawler.</p> <p>A web crawler is a web-based tool that collects and indexes group of web images available on the internet.</p> <p>In our case we determined the main liver lesions. Then, for each lesion, we launched a crawler that scans a large number of indexed web pages for a specific query and then downloads the images corresponding to the query along with their clinical reports.</p> <p>Once downloaded, the images are grouped into categories. Each category represents a specific liver disease and contains several cases that contains the images.</p> <p>Each image is accompanied by a small description that will be used for the annotation.</p>
<p><b>Annotation process</b></p>	<p>Image annotation is defined as the process of classifying or labelling an image using a descriptive text, annotation tools or both, thus enabling machines to understand and interpret visual data. These labels are the expected outputs that a model should learn to predict on its own.</p> <p>A label is assigned to each existing object in the image. In our case of object detection, each label is composed of coordinates that define the object's boundaries and a class that describes the object's type.</p>
<p><b>Bounding Boxes</b></p>	<p>It's an imaginary rectangle that serves as a point of reference for object detection and creates a collision box for that object in projects on image processing.</p> <p>In case of object detection, each label is composed of coordinates that define the object's boundaries and a class that describes the object's type.</p>
	<p>Object detection combines two tasks into one, namely the localization of an image and its classification.</p> <p>First of all it's important to precise that in deep learning, object detection frameworks are mainly divided into two categories.</p>

<b>Object detection networks</b>	<p>Frameworks of first categories follow traditional object detection pipeline which consists in :</p> <ol style="list-style-type: none"> <li>1. generating region proposals refereed as region of interest (ROI)</li> <li>2. classifying every ROI into an object category</li> </ol> <p>This category is called two-stage object detection frameworks. Faster R-CNN is part of this category.</p> <p>The second category handle the object detection task as a regression/classification problem. Only a unified frame is needed to perform both localization and classification. It's refereed as one-stage object detection. YOLO and YOLO LT are both one-stage object detection method.</p>
<b>Pytorch</b>	<p>Pytorch is an open-source machine learning library based on the Torch library, used for natural language processing and computer vision applications, primarily developed by Facebook's AI Research lab.</p>
<b>Python</b>	<p>Created in the early 1990s , Python is one of the most widely used open-source programming languages used by computer scientists <sup>65</sup>.</p> <p>It is an interpreted language that allows developers to focus on their actions. As a result, Python code development is much faster compared to other languages. Since then, Python has become the language of data science, machine learning and big data.</p>
<b>NVIDIA graphics card</b>	<p>A graphics card is a computer expansion card that generates a feed of graphics output to a display device such as a monitor. Most graphics cards are not limited to simple display output and can be used for additional processing.</p> <p>NVIDIA is an American multinational technology company based in Santa Clara, California.</p>
<b>Hardwish function</b>	<p>It's one type of activation function. In AI, the activation function is a mathematical function applied to a signal of the output of an artificial neuron. The term "activation function" comes from the biological equivalent "activation potential", a stimulation threshold which, once reached, results in a response from the neuron.</p> <p>The Hardwish activation function permits to introduce a non-linearity into networks. Thus, neural networks take advantage of the many stacked convolutional layers.</p>
<b>Inference time</b>	<p>The time required to perform a detection and subsequently write the output to the disk.</p>
<b>Training set</b>	<p>It's a data set of examples used to train the different models. This data is analysed again and again in a repetitive fashion until output is generated that matches the reference label.</p>

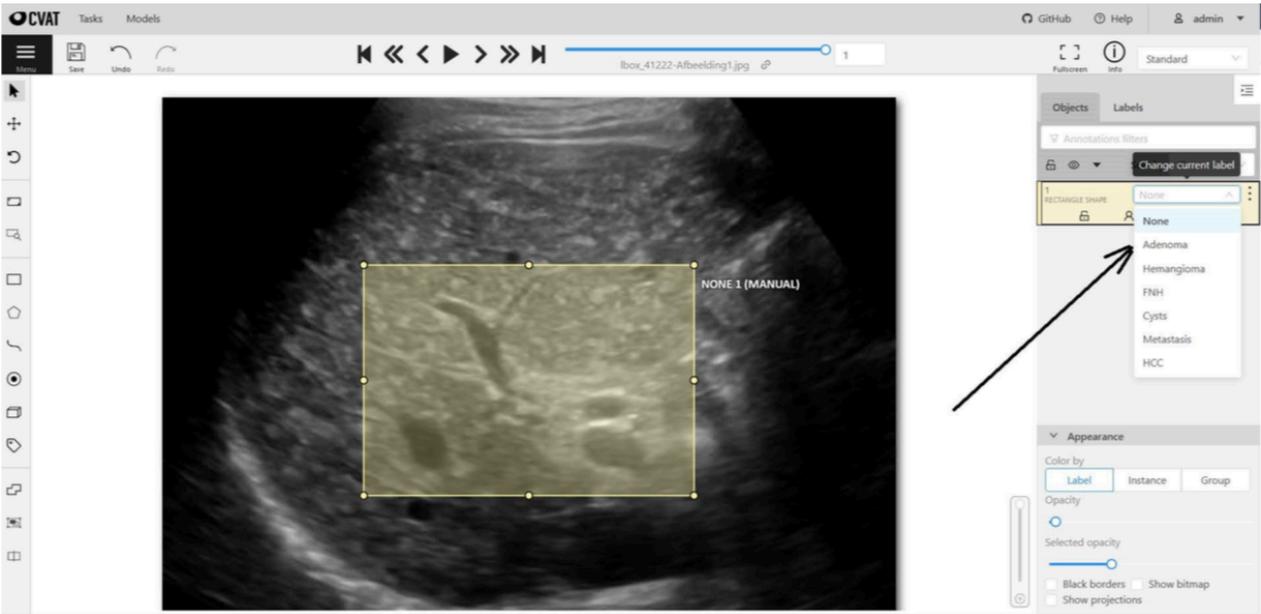
<p><b>Test set</b></p>	<p>It's a data set of examples used to evaluate and compare the different trained models in order to select the one that performs best.</p>
------------------------	---

**Appendix Figure 1.** Structure of Qwanteus database for liver conditions



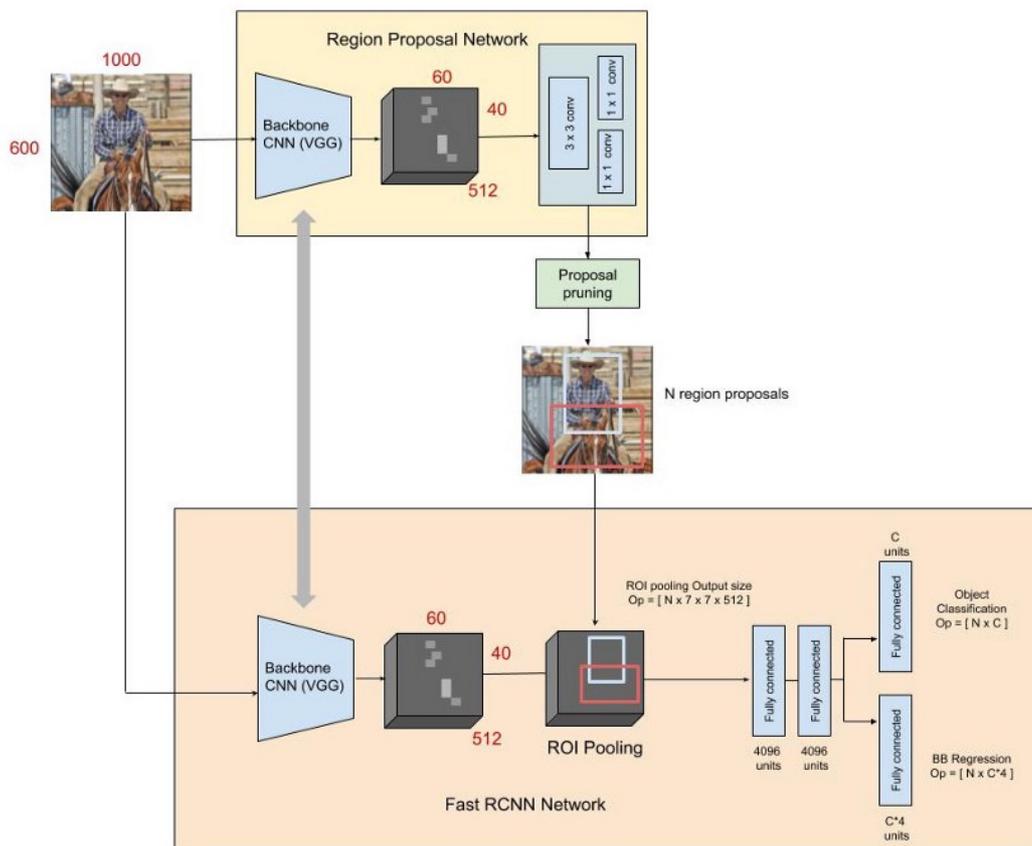
**Appendix Figure 2.** Computer Vision Annotation Tool Interface

It is an open-source annotation tool developed by Inter researchers. It's a web application that requires no installation and offers the possibility to work in collaboration with several users on the same annotation project.



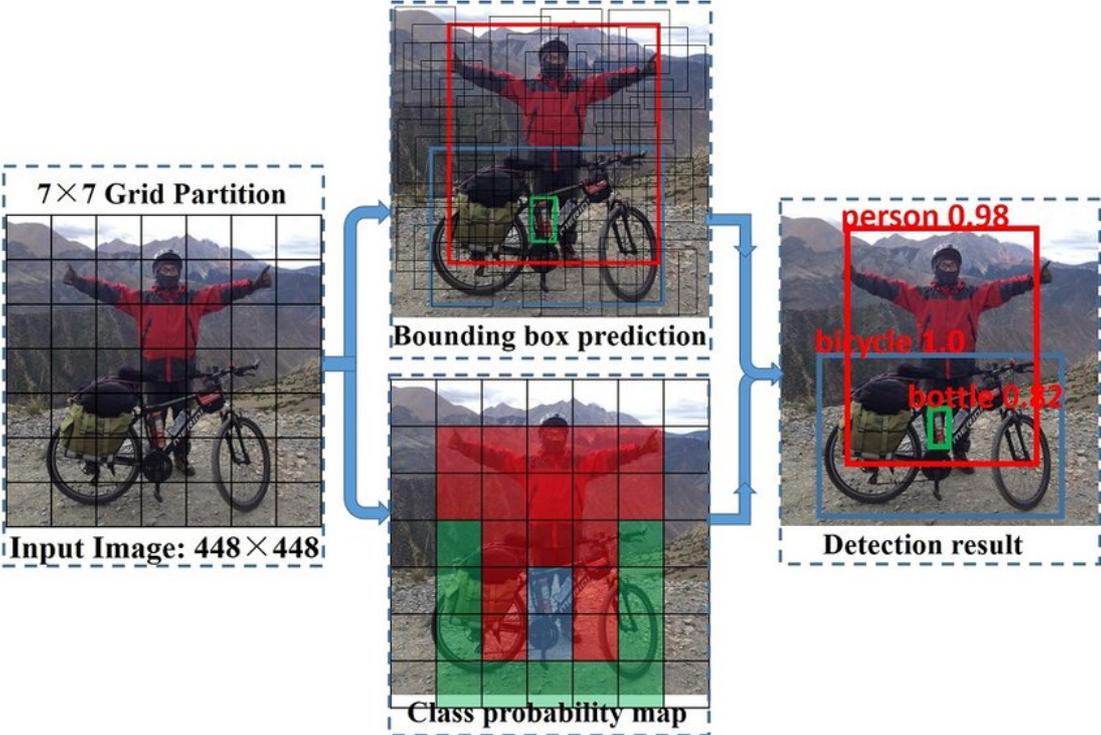
**Appendix Figure 3.** The architecture of the Faster R-CNN algorithm

It was first released in 2015. It consists of a region proposal network (RPN) to generate “bounding boxes” or possible object locations in the image. The RPN network is composed of a backbone network, whose role is to extract features, followed by several convolutions layers for regression in order to generate the coordinates of the possible objects (N region proposals). The same extracted features, plus the N region proposals are fed to another network which is composed of a Region Of Interest pool whose role is to reshape arbitrarily sized inputs into a fixed-length output, and two fully connected layers, one for classification and the other for regression whose role is to make the coordinates of the object bounding box more precise.



**Appendix Figure 4.** The SxS grid cells of the YOLO algorithm

The models of YOLO family has started with Joseph Redmon in 2015 <sup>66</sup>. It applies a single neural network for both localization and classification. YOLO divides the input image into an SxS grid. Then, for each grid cell, YOLO predicts the coordinates and the class of the objects whose their centre fall in that grid.



**Vu, le Directeur de Thèse**

A handwritten signature in black ink, appearing to read "Edouard". The signature is written in a cursive style with a large initial 'E' and a long, sweeping tail.

**Vu, le Doyen  
De la Faculté de Médecine de  
Tours Tours, le**

**LECANU Aurélie**

56 pages – 6 tableaux – 17 figures

**Résumé :** L'échographie hépatique est un examen d'imagerie fréquent que ce soit dans le cadre de suivi de pathologies ou en 1<sup>ère</sup> intention face à une situation clinique évoquant une pathologie abdominale ou biliaire. Les lésions hépatiques sont fréquentes avec des taux de découverte fortuite lors d'une échographie allant jusqu'à 30%. Le développement de modèles utilisant l'intelligence artificielle (IA) est un terrain prometteur en médecine. Le but de cette étude était de créer un outil grâce au Deep Learning qui détecte et caractérise simultanément les lésions focales hépatiques lors d'une échographie hépatique.

Nous avons d'abord créé puis entraîné notre modèle avec la base de données QWLUS (conçue par Qwanteus startup spécialisée en IA), une base de données d'images échographiques hépatiques issues d'internet et rassemblées via un logiciel d'exploration de site web (web crawler). Cette base de données était composée de 790 images échographiques bidimensionnelles du foie, correspondant à 1672 lésions focales hépatiques réparties en six catégories (adénome, hémangiome, hyperplasie nodulaire focale, kystes, métastases, carcinome hépatocellulaire CHC). 630 images ont été utilisées pour entraîner le modèle et 160 pour le tester. Il a ensuite été testé sur un nouvel ensemble de données d'images issues de 61 patients sélectionnés au CHU de Tours.

Nous avons testé plusieurs réseaux de Deep Learning connus et obtenu les meilleurs résultats avec YOLO LT, une version modifiée de YOLO développée par Qwanteus, que nous avons intégré dans notre outil de détection appelé DETECT. YOLO est basé sur des réseaux de neurones artificiels et conçu pour une détection rapide en temps réel des objets dans des images. Nous avons obtenu une VPP (valeur prédictive positive) de 57,9% et une sensibilité de 86,8% avec la base de données QWLUS. Les taux de sensibilité / spécificité / VPP / exactitude de détection pour les lésions focales du foie pour la base issue du CHU de Tours étaient respectivement de 66% / 90% / 85% / 79%. Les meilleurs résultats de caractérisation ont été obtenus avec les adénomes, les kystes et les CHC.

Notre modèle couplant Deep Learning et échographie hépatique a montré de bons résultats en tant qu'outil de détection et doit améliorer ses performances pour la caractérisation. Ses résultats prometteurs encouragent la recherche dans ce domaine afin d'obtenir dans un futur proche un outil permettant une détection et caractérisation des lésions hépatiques fiable et utile en pratique clinique.

**Mots clés :** échographie hépatique ; intelligence artificielle ; lésions focales hépatiques ; outil de détection ; outil de caractérisation

**Jury :**

Président du Jury : Professeur Thierry LECOMTE

Directrice de thèse : Professeure Laure ELKRIEF  
Membres du Jury : Docteur Romain CHAUTARD  
Docteur Anaïs JAILLAIS  
Docteur Jérôme ROUMY

Date de soutenance : 17 novembre 2023