

Creative commons : Paternité - Pas d'Utilisation Commerciale -
Pas de Modification 2.0 France (CC BY-NC-ND 2.0)



<http://creativecommons.org/licenses/by-nc-nd/2.0/fr>

UNIVERSITE CLAUDE BERNARD-LYON 1
U.F.R. D'ODONTOLOGIE

Année 2023

Thèse n° 2023 LYO 1D 010

THESE
POUR LE DIPLOME D'ETAT DE DOCTEUR EN CHIRURGIE DENTAIRE
Présentée et soutenue publiquement le 3 avril 2023

Par

Romain BUI
Né le 12 Janvier 1990 à Caen

UTILISATION DE L'INTELLIGENCE ARTIFICIELLE
AFIN DE RÉPLIQUER UN PROCESSUS DÉCISIONNEL :
CAS D'ÉTUDE EN ODONTOLOGIE LÉGALE

JURY

Monsieur le Professeur Jean-Christophe MAURIN	Président
<u>Monsieur le Professeur Maxime DUCRET</u>	Assesseur
Monsieur le Docteur Thibault JACQUES GAGET	Assesseur
<u>Monsieur le Docteur Raphaël RICHERT</u>	Assesseur
<u>Madame la Docteure Cheraz TAFROUNT</u>	Invitée
Madame la Docteure Sophie VEYRE	Assesseure

UNIVERSITE CLAUDE BERNARD LYON 1

Président de l'Université	Frédéric FLEURY
Président du Conseil Académique et de la Commission Recherche	Hamda BEN HADID
Vice-Président du Conseil d'Administration	Didier REVEL
Vice-Présidente de la Commission Formation	Céline BROCHIER
Vice-Président Relations Hospitalo-Universitaires	Jean François MORNEX
Directeur général des services	Pierre ROLLAND

SECTEUR SANTE

Doyen de l'UFR de Médecine Lyon-Est	Gilles RODE
Doyen de l'UFR de Médecine et de Maïeutique Lyon Sud - Charles Mérieux	Philippe PAPAREL
Doyen de l'Institut des Sciences Pharmaceutiques et Biologiques (ISPB)	Claude DUSSART
Doyen de l'UFR d'Odontologie	Jean-Christophe MAURIN
Directeur de l'Institut des Sciences & Techniques de Réadaptation (ISTR)	Jacques LUAUTÉ
Présidente du Comité de Coordination des Études Médicales	Carole BURILLON

SECTEUR SCIENCES ET TECHNOLOGIE

Directrice de l'UFR Biosciences	Kathrin GIESELER
Directeur de l'UFR Faculté des Sciences	Bruno ANDRIOLETTI
Directeur de l'UFR Sciences & Techniques des Activités Physiques et Sportives (STAPS)	Guillaume BODET
Directeur de Polytech Lyon	Emmanuel PERRIN
Directeur de l'Institut Universitaire de Technologie Lyon 1 (IUT)	Michel MASSENZIO
Directeur de l'Institut des Science Financière & Assurances (ISFA)	Nicolas LEBOISNE

30 septembre 2022



FACULTE D'ODONTOLOGIE DE LYON

Doyen : M. Jean-Christophe MAURIN, Professeur des Universités-Praticien hospitalier
Vice-Doyens : Pr. Cyril VILLAT, Professeur des Universités - Praticien hospitalier
Pr. Maxime DUCRET, Professeur des Universités - Praticien hospitalier
Pr. Brigitte GROSGOGEAT, Professeure des Universités - Praticien hospitalier

SOUS-SECTION 56-01 : ODONTOLOGIE PEDIATRIQUE ET ORTHOPEDIE DENTO-FACIALE

Professeurs des Universités-PH : M. Jean-Jacques MORRIER, Mme Béatrice THIVICHON-PRINCE
Maîtres de Conférences-PH : Mme Sarah GEBEILE-CHAUTY, Mme Claire PERNIER
Maître de Conférences Associé : Mme Lienhart Guillemette

SOUS-SECTION 56-02 : PREVENTION – EPIDEMIOLOGIE ECONOMIE DE LA SANTE – ODONTOLOGIE LEGALE

Professeur des Universités-PH : M. Denis BOURGEOIS
Maître de Conférences-PH : M. Bruno COMTE
Maître de Conférences Associé : M. Laurent LAFOREST

SOUS-SECTION 57-01 : CHIRURGIE ORALE – PARODONTOLOGIE – BIOLOGIE ORALE

Professeurs des Universités-PH : M. Jean-Christophe FARGES, Mme Kerstin GRITSCH
Maîtres de Conférences-PH : M. Thomas FORTIN, M. Arnaud LAFON, M. François VIRARD
Maîtres de Conférences Associés : Mme Ina SALIASI, Mme Doriane CHACUN

SOUS-SECTION 58-01 : DENTISTERIE RESTAURATRICE, ENDODONTIE, PROTHESE, FONCTION-DYSFONCTION, IMAGERIE, BIOMATERIAUX

Professeurs des Universités-PH : M. Pierre FARGE, Mme Brigitte GROSGOGEAT, M. Maxime DUCRET
M. Jean-Christophe MAURIN, Mme Catherine MILLET
M. Olivier ROBIN, Mme Sarah MILLOT, M. Cyril VILLAT

Maîtres de Conférences-PH : M. Patrick EXBRAYAT, M. Christophe JEANNIN
Mme Marion LUCCHINI, M. Thierry SELLI
Mme Sophie VEYRE, M. Stéphane VIENNOT

Maître de Conférences Associé M. HAZEM ABOUELLEIL-SAYED

SECTION 87 : SCIENCES BIOLOGIQUES FONDAMENTALES ET CLINIQUES

Maître de Conférences Mme Florence CARROUEL

13 octobre 2022

Table des matières

INTRODUCTION	6
I. ASPECTS LIÉS À L'INTELLIGENCE ARTIFICIELLE.....	8
1. TERMINOLOGIE	8
1.1 <i>Intelligence artificielle</i>	8
1.2 <i>Machine Learning</i>	9
1.3 <i>Deep Learning</i>	10
2. ASPECT SPÉCIFIQUE À L'IMAGERIE.....	12
2.1 <i>Définitions</i>	12
2.2 <i>Approche employée dans l'article</i>	13
II. ARTICLE ORIGINAL	14
1. INTRODUCTION	15
2. MATERIALS AND METHODS	16
2.1. STUDY AND DATABASE	16
2.2. DATA SPLITTING, PRE-PROCESSING, AND AUGMENTATION	16
2.3. LABELING PROCESS	17
2.4. TRAINING OF MASK INFERENCE WITH MASK R-CNN AND U-NET.....	17
2.5. TOPOLOGICAL DATA ANALYSIS WITHOUT DEEP LEARNING (TDA) OR WITH DEEP LEARNING (TDA-DL)	17
2.6. PERFORMANCE ASSESSMENT	18
2.7. STATISTICAL ANALYSIS	18
3. RESULTS	19
3.1. PERFORMANCE AND ERRORS OF MASK INFERENCE.....	19
3.2. PERFORMANCE OF TDA AND TDA-DL	20
3.3. PERFORMANCE OF TDA AND TDA-DL	21
4. DISCUSSION.....	22
5. CONCLUSIONS	23
REFERENCES	24

III. DISCUSSION	27
1. PREMIÈRE INNOVATION : LA SEGMENTATION BI-MASQUE	27
2. SECONDE INNOVATION : COMBINAISON ALGORITHMIQUE	28
3. ENJEUX ÉTHIQUES ET PERSPECTIVES	29
3.1 Enjeux éthiques	29
3.2 Perspectives	30
CONCLUSION	31
BIBLIOGRAPHIE	32

Introduction

L'estimation de l'âge d'un patient est une procédure très courante en médecine légale. Nous nous intéressons dans le contexte de ce travail plus particulièrement à la pratique consistant à estimer si un individu est mineur ou majeur, procédure qui reste de nos jours particulièrement discutée dans la communauté scientifique (1–4). Cette question reste clef notamment dans le contexte de la gestion judiciaire des personnes dénouées de justificatifs d'identité et des demandeurs d'asile. Cette estimation est évidemment sensible à la lumière des enjeux éthique et individuel qu'elle engendre.

En regard de la législation, l'article 43 de la loi n°2016-297 du 16 mars 2016 indique :

« Les examens radiologiques osseux aux fins de détermination de l'âge, en l'absence de documents d'identité valables et lorsque l'âge allégué n'est pas vraisemblable, ne peuvent être réalisés que sur décision de l'autorité judiciaire et après recueil de l'accord de l'intéressé. » (5)

Le consensus scientifique relatif à l'estimation de l'âge (Study Group on Forensic Age Diagnostics : AGFAD) préconise l'utilisation de quatre éléments : un examen clinique, une radiographie de la main, un orthopantomogramme ainsi qu'un scanner de la clavicule (6).

Dans le contexte précédemment décrit, les examens complémentaires radiographiques ne sont, évidemment, pas nécessairement présents. Néanmoins, l'orthopantomogramme étant une pratique d'imagerie classique et régulière en odontologie, il est relativement fréquent de posséder cette information.

Une estimation de l'âge d'un individu en se basant sur le simple orthopantomogramme apparaît de facto comme une approche pertinente dans notre contexte.

Les odontologues médico-légaux utilisent pour se faire l'I3M (dît indice de la troisième molaire). Développé par Cameriere et al. puis validés par de nombreux auteurs (7–10), il consiste en un ratio entre la somme des ouvertures apicales et la hauteur de la 3^{ème} molaire mandibulaire (figure 1), si ledit ratio est inférieur au seuil de 0.08 l'individu est alors classifié comme majeur. Cette approche implique une interprétation manuelle de la radiographie par un odontologue médico-légal. La sollicitation d'une telle procédure est ainsi par définition chronophage, coûteuse, et exposée à des biais humains idiosyncratiques inhérent à l'analyse par l'expert, ce qui soulève le problème de la reproductivité de la conclusion établie (11).




Figure 1 : Exemple d'une annotation pour un calcul de l'I3M : $\frac{A+B}{C}$ (12)

Dans le cadre de cette thèse, le projet consiste à automatiser la procédure de calcul de l'I3M afin d'offrir une aide à la décision permettant d'apprendre cette technique pour les débutants et d'homogénéiser les pratiques pour les spécialistes.

Plus spécifiquement, la solution proposée combine deux algorithmes distincts : l'un permettant d'estimer le contour de la dent, l'autre estimant les points d'inflexion de la forme précédemment estimée pour finalement calculer l'I3M.

Dans la première partie de ce document, afin de mieux apprécier le travail réalisé dans l'article associé, nous rappellerons certains détails relatifs à l'intelligence artificielle et aux éléments algorithmiques. L'article dans sa version originale sera ensuite proposé. Enfin, nous terminerons par une dernière partie de discussions des résultats et sur les perspectives de ce travail.

I. Aspects liés à l'Intelligence Artificielle

1. Terminologie

1.1 Intelligence artificielle

Selon IBM (13) « l'intelligence artificielle exploite les ordinateurs et les machines pour imiter les fonctions de résolution de problèmes et de prise de décision du cerveau humain. ». En somme cette approche permet d'optimiser ou de remplacer les processus décisionnels via l'utilisation de la technologie moderne, cette grande famille regroupe de nombreuses sous-familles, notamment dans le contexte qui nous intéresse le « Machine Learning » et le « Deep Learning » (figure 2).




Figure 2 : Terminologie en lien avec l'intelligence artificielle

Intelligence artificielle : Toute technique permettant de reproduire un comportement humain

Machine Learning : Intelligence Artificielle basée sur l'utilisation d'outil statistique pour permettre l'apprentissage automatisé par les machines

Deep Learning : Algorithme complexe de « machine learning » utilisant des réseaux à couche multiples

(14)

1.2 Machine Learning

Le Machine Learning en français « apprentissage automatique » est une sous-branche de la grande famille de l'intelligence artificielle utilisant des approches algorithmiques à fondamentaux statistiques permettant au logiciel de calibrer sa décision et d'apprendre automatiquement. Quelques exemples d'automatisation en Machine Learning : prédiction météorologique, reconnaissance faciale, publicité ciblée, diagnostics médicaux, identification de fraudes (15–19).

Il est courant de segmenter les algorithmes de Machine Learning en trois paradigmes : Supervisé, Non-Supervisé, et Apprentissage par renforcement (figure 3).




Figure 3 : Les différents paradigmes de Machine Learning
Apprentissage Non supervisé, Apprentissage Supervisé, Apprentissage par renforcement
(20)

L'apprentissage par renforcement concerne une situation où l'environnement est modélisé mais dont la solution au problème n'est pas connue, par exemple la création d'un algorithme capable de jouer seul à un jeu vidéo. L'algorithme agit alors par incréments et ajuste ses critères de décisions en fonction des signaux de renforcements (positifs ou négatifs) reçus par ledit environnement, on parle également d'approche par chaîne de Markov.

Les solutions dites « supervisées » concernent les algorithmes nécessitant une procédure dite de labélisation manuelle en amont de la calibration (entraînement) de ce dernier. L'exemple classique est le développement d'une méthode permettant de détecter un élément donné sur un cliché de photographie (animal, panneau de signalisation, humain etc.), pour ce faire l'algorithme doit s'entraîner en préambule sur une série de photos (souvent très nombreuses), sur lesquelles les éléments à détecter ont d'ores et déjà été indiqués par un humain (étape dite de labélisation). La figure 4 présente un exemple de cliché labélisé qu'on aurait pu donner à un algorithme supervisé dans le cadre de son entraînement.




Figure 4 : Exemple d'une donnée d'entrée pour un algorithme supervisé (21)

Les solutions dites non-supervisées quant à elle ne nécessitent pas de labélisation en amont. L'exemple classique de tels algorithmes est celui des « clusterisation » permettant d'automatiquement créer des sous-groupes (« cluster ») d'individus en fonction de leurs comportements, affinités etc.

1.3 Deep Learning

Le « deep Learning » est une sous-branche du Machine Learning qui s'emploie à utiliser les logiques des algorithmes classiques du Machine Learning et à les intégrer dans une structure de gestion des données appelée « réseau de neurone ».

Le réseau de neurone fait référence à une architecture de « nœuds » s'envoyant mutuellement des informations après avoir transformé l'information reçue (à l'instar du neurone en biologie). Chaque nœud contient une fonction mathématique à l'origine de ladite transformation qui sont souvent de type « convolution » (comparaison entre deux zones, appelée également extraction de « feature »), « pooling » (agrégation), ou

encore une transformation linéaire basique notamment afin de générer un output final de type binaire (figure 5).




Figure 5 : Exemple visuel d'apprentissage de 'features' par un réseau de neurone

Un réseau de neurones à trois couches cachées associées à une couche d'entrée et une couche de sortie est schématisé, ce dernier permet une reconnaissance faciale. Chaque rond blanc correspond à un nœud de calcul encapsulant une série de fonctions mathématiques à optimiser, chaque trait correspond à un poids à optimiser reliant un neurone d'une couche à un neurone de la couche suivante. Des photos de visages sont soumises en entrée à l'algorithme, les sous-couches permettent d'en extraire les caractéristiques cachées ('features') : forme du visage, longueur du nez etc. Finalement la couche finale de sortie donne un résultat binaire sur l'individu détecté sur le visage soumis.

(22)

Il faut donc comprendre le réseau de neurone comme un maillage de fonctions mathématiques élémentaires dont la force réside dans une architecture avec de nombreuses couches (« layers ») permettant un degré de liberté important et donc la résolution de problématiques complexes. On parle de « deep learning » lorsque le nombre de couche du réseau de neurone est important (supérieur à 3 généralement).

2. Aspect spécifique à l'imagerie

2.1 Définitions

Les analyses d'images par Machine Learning se distinguent en quatre catégories selon l'objectif final de l'algorithme (22–26) (figure 6) :

- Classification : une énumération des éléments objectivés
- Localisation : un encadré sur les éléments objectivés
- Segmentation sémantique : une association de chaque pixel à l'un des éléments objectivés
- Segmentation d'instance : identique à la segmentation sémantique mais avec la possibilité de distinguer plusieurs instances d'un même objet.




Figure 6 : Différent type d'analyse d'image par machine learning.

a) Classification : liste des éléments identifiés, b) Localisation d'objets : les éléments identifiés sont localisés par une zone rectangulaire , c) Segmentation sémantique : les éléments identifiés sont localisés précisément pixel par pixel et d) Segmentation d'instances : identique à la segmentation sémantique mais avec la possibilité d'identifier plusieurs instances d'un même élément accolé (cube en l'occurrence)

(21)

2.2 Approche employée dans l'article

L'approche présentée dans l'article comporte deux parties distinctes:

- L'estimation du contour de la dent (également dénommé masque)
- L'estimation des points clefs (bordures des apex, point le plus coronaire et apical de la dent)

L'estimation du contour de la dent passe par l'utilisation d'un algorithme supervisé de deep learning de segmentation. Plus spécifiquement nous avons comparé dans ce travail les algorithmes Mask R-CNN (27) et U-Net (28). Ces deux algorithmes sont tous deux des réseaux de neurones dits convolutifs, c'est-à-dire s'astreignant à extraire les composants (« features ») d'une image, ils diffèrent par des designs d'architecture du réseau et de fonction au sein des nœuds. Mask R-CNN est une référence dans de nombreux domaines d'analyse d'images tandis que U-Net a été développé spécifiquement pour des applications en médecine (28) en intégrant notamment une gestion de la résolution pour éviter une perte de cette dernière entre les différentes couches. Au final, l'objectif de la première partie du travail consiste à développer un algorithme distinguant le contour apical et coronaire de la dent.

La seconde partie de l'algorithme, quant à elle, estime les points clefs permettant in fine de calculer l'I3M. Cette seconde partie prend donc comme seule donnée d'entrée les masques précédemment extraits. Ces algorithmes s'inscrivent dans une branche mathématique dénommée « analyse topologique » dont l'objectif est d'analyser les formes géométriques, d'où la terminologie TDA (topological data analysis) que nous avons utilisée dans la suite de ce travail.

II. Article Original

UTILISATION DE L'INTELLIGENCE ARTIFICIELLE AFIN DE REPLIQUER UN PROCESSUS DECISIONNEL : CAS D'ETUDE EN ODONTOLOGIE LEGALE

RÉSUMÉ

Objectifs : L'utilisation de l'indice de maturité de la troisième molaire mandibulaire (I3M) afin de déterminer l'âge d'un patient est une pratique commune en odontologie légale. L'objectif de cette étude est de calculer automatiquement cet index en combinant un algorithme d'intelligence artificielle avec un algorithme d'analyse topologique. In fine, il s'agit de développer un outil d'aide à la décision.

Méthodes : La base de données contient 456 images de patients issus de la France et de l'Ouganda. Deux algorithmes supervisés d'apprentissage profond (Mask RCNN, U-Net) estimant le contour apical et coronaire des dents ont été comparés sur les radiographies des troisièmes molaires mandibulaires inférieures. Puis, afin de déterminer la hauteur de la dent ainsi que l'ouverture des apex, deux analyses topologiques ont été comparées sur les masques inférés lors de la première étape. Plus spécifiquement, une analyse topologique possédait une composante d'apprentissage profond (TDA-DL), tandis que la seconde n'en possédait pas (TDA).

Résultats : La performance de U-Net fut meilleure que celle de Mask R-CNN avec une précision (ratio moyen de l'intersection sur l'union) de respectivement 91.2% et 83.8%. Les résultats de la combinaison de U-Net avec TDA ou TDA-DL en comparaison avec un expert en odontologie légale furent satisfaisants. L'erreur moyenne $\pm$ l'écart type fut de 0.04 ± 0.03 pour TDA, and 0.06 ± 0.04 pour TDA-DL. Le coefficient de corrélation de Pearson estimé entre l'I3M calculé par l'expert et notre modèle fut de 0.93 pour la combinaison U-Net avec TDA et 0.89 pour la combinaison U-Net avec TDA-DL.

Conclusion : Cette solution combinant une approche d'apprentissage profond avec une analyse topologique offre une précision de prédiction de 95% par rapport à un expert. Ainsi, ce cas d'étude illustre la faisabilité d'une solution automatisée capable de calculer l'I3M afin d'aider les experts ou d'améliorer les autres algorithmes estimant l'âge des patients.

Importance Clinique : Ce cas d'étude montre qu'une approche d'apprentissage profond en combinaison avec une analyse topologique a le potentiel d'offrir une solution d'aide à la décision dans le contexte d'une estimation d'âge d'un patient. Des études supplémentaires sur des bases de données plus larges et plus diversifiées sont néanmoins nécessaires afin de confirmer les performances obtenues et éventuellement envisager des applications cliniques.

Artificial Intelligence as a Decision-Making Tool in Forensic Dentistry: a Pilot Study with I3M

Romain BUI ^{1,2}, Régis IOZZINO ^{1,2}, Raphaël RICHERT ^{1,2}, Pascal ROY ^{3,4}, Loïc BOUSSEL ^{5,6}, Cheraz TAFROUNT ^{1,2}, Maxime DUCRET ^{1,2,7}

- ¹ Pôle d’Odontologie, Hospices Civils de Lyon, 69008 Lyon, France
- ² Université Claude Bernard Lyon 1, Université de Lyon, 69372 Lyon, France
- ³ Hospices Civils de Lyon, Pôle Santé Publique, Service de Biostatistique - Bioinformatique, Lyon, France.
- ⁴ Université de Lyon, Université Lyon 1, CNRS, UMR 5558, Laboratoire de Biométrie et Biologie Évolutive, Équipe Biostatistique-Santé, Villeurbanne, France.
- ⁵ Department of Radiology, Hôpital de la Croix-Rousse, Hospices Civils de Lyon, 69004 Lyon, France
- ⁶ CREATIS, INSA Lyon, Université Claude Bernard Lyon 1, UJM-Saint Etienne, CNRS, Inserm, UMR 5220, U1294, 69100 Villeurbanne, France
- ⁷ Institut de Biologie et Chimie des Protéines, Laboratoire de Biologie Tissulaire et Ingénierie Thérapeutique, UMR 5305 CNRS, Université Claude Bernard Lyon 1, 69367 Lyon, France
- * Correspondence: maxime.ducret@univ-lyon1.fr; Dr Ducret Maxime, Université Claude Bernard Lyon 1, Faculté d’odontologie, Service de Prothèses, 11 Rue Guillaume Paradin, 69008 Lyon

Abstract: Background: Expert determination of the third molar maturity index (I3M) constitutes one of the most common approaches for dental age estimation. This work aimed to investigate the technical feasibility of creating a decision-making tool based on I3M to support expert decision-making. Methods: The dataset consisted of 456 images from France and Uganda. Two deep-learning approaches (Mask R-CNN, U-Net) were compared on mandibular radiographs, leading to a two-part instance segmentation (apical and coronal). Then, two topological data analysis approaches were compared on the inferred mask: one with a deep learning component (TDA-DL), one without (TDA). Results: Regarding mask inference, U-Net had a better accuracy (mean intersection over union metric (mIoU)) 91.2% compared to Mask R-CNN 83.8%. The combination of U-Net with TDA or TDA-DL to compute the I3M score revealed satisfying results in comparison with a dental forensic expert. The mean $\pm$ SD absolute error was 0.04 ± 0.03 for TDA, and 0.06 ± 0.04 for TDA-DL. The Pearson correlation coefficient of the I3M scores between the expert and a U-Net model was 0.93 when combined with TDA and 0.89 with TDA-DL. Conclusion: This pilot study illustrates the feasibility to automate I3M solution combining a deep learning and a topological approach, with a 95% accuracy in comparison with an expert.

Keywords: Artificial intelligence; Age estimation; Dentistry; Deep learning; Machine Learning; Neural Network; Topological Analysis

1. Introduction

Decision-making is a daily process used in all medical fields including dentistry. In forensic medicine, age estimation has become an important challenge as biological markers vary notably from person to person, even in the context of identical chronological age [1]. Therefore, this context constitutes a good pilot study for the development of a decision-making procedure aiming at categorizing one individual’s age. More specifically, one of the most challenging issue involving living patients is to assess whether a person is a minor or not (i.e. under or over 18 years of age) [2]. This question is especially key in the context of unaccompanied asylum seekers without reliable documentation. The protocol of the Study Group on Forensic Age Diagnostics (AGFAD) for age estimation recommends combining a clinical examination (including the oral cavity), a hand radiograph, an orthopantomogram (OPG), and a CT scan of the clavicle medial end (if the skeletal development of the hand and wrist is completed) [3]. Following this

Copyright: © 2023 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

recommendation, several techniques based on OPGs have been proposed to estimate the age of a given individual [4,5]; however, there is currently no scientific consensus regarding the best strategy.

Nearly fifteen years ago, Cameriere *et al.* [6] developed a topological method to estimate whether the chronological age of a given person is below or above 18 years. This approach is based on the relationship between the age and the third molar maturity index (I3M), which takes into account the apex width (a and b respectively for the mesial and distal apex width) and the tooth height (c) by computing the ratio : $(a+b)/c$ [6,7]. A threshold (cut-off) value of $I3M < 0.08$ was identified and used to discriminate between minors and adults. This method has later been applied to several populations and showed to be the most efficient in discriminating between these two categories [8–10].

However, this technique can only be performed by a forensic expert requiring time and cost, which sometimes raise ethical issues especially in the context of unhealthy or legally-implicated minors. Moreover, I3M estimation requires and depends on the experience in dental radiograph interpretation, and therefore represents a potential source of inaccuracy, as illustrated by the I3M inter-intra-class correlation coefficient (ICC) values that are good or excellent, but never perfect [11–13]. This difficulty in dental radiograph analysis is not specific to I3M calculation, and must therefore be carefully managed, especially given the ethical and legal impact of the final decision [14–16]. This dependence on human interpretation strongly highlights the need for an accurate tool able to support and standardize I3M score estimation in order to assist less experienced forensic expert and reduce inaccuracies.

Thus, the aim of the present pilot study was to investigate the technical feasibility of creating a decision-making tool based on I3M index for forensic experts. This study presented an automated approach consisting of a mask inference on OPG followed by a topological analysis with or without a deep learning component. Performance was computed for each task, and the accuracy of their combination was finally investigated in comparison with the forensic expert's I3M estimation. The null hypothesis was therefore: the I3M inferred by the solution is identical to the one estimated by the expert.

2. Materials and Methods

2.1. Study and Database

This study was conducted with accordance of the local ethical committee (HCL-21_440). A retrospective set of 530 OPGs was obtained from a previous French study [8] and thanks to an international collaboration with the Hospital of Mulago (Uganda; ethical validation SBS-216). The image collection was performed in accordance with local and national ethical standards and the Declaration of Helsinki and its later amendments. The present study was conducted and reported following as much as possible the recommendations on artificial intelligence in dentistry [17], more specifically, on the 25 items presented in the article, 23 were followed while two others (clustering and missing data management) were not applicable in our context. The OPGs were first cropped to extract left and right mandibular third molar images downsized to 256x256 pixels, a reasonable resolution for experts to distinguish the dental details and therefore properly assess the I3M score. Each image was analyzed by an I3M expert (CT) to assess the possibility to estimate an I3M score. Among others, radiographs without two apices or without a third mandibular molar were excluded. The final reviewed dataset was composed of 456 images, 57% of the patients were minor for an average age of 17.9 years.

2.2. Data splitting, pre-processing, and augmentation

A model is defined as the combination between a segmentation algorithm (mask R-CNN or U-Net) with one computing the I3M through a topological analysis with or without a deep-learning component. In order to assess the performance of each model, 80% of the database was assigned to the training sample, and the remaining 20% to the testing sample, which was solely used to compute the statistical error once the model was trained.

Before training and testing Mask R-CNN and U-Net (see below), a data pre-processing procedure was applied using the contrast limited adaptive histogram equalization (CLAHE) enhancement approach. This image processing enhances the contrast through a transformation function based on the neighborhood region of each pixel [18]. Data augmentation techniques were also applied using random rotations and flips of the images.

2.3. Labeling process

The use of supervised algorithm implies prior labeling on the training set. The labeling processed, performed by RB, consisted in manually creating a polygon mask (instance segmentation) of the mineralized tissue. One apical and one coronal mask were manually created using the 'labelme' annotation tool under the open MIT license [19].

2.4. Training of mask inference with Mask R-CNN and U-Net

Two deep-learning approaches were used and compared in order to perform the mask inference: Mask R-CNN and U-Net.

Mask R-CNN is a region-based convolutional neural network, its backbone is the Faster-RCNN algorithm with an additional final convolutional branch enabling the prediction of an object mask [20]. Mask R-CNN is an algorithm developed by the Facebook AI Research team and was implemented, in our context, under the open MIT License (matplotlib)[21]. U-Net is a convolutional neural network with a characteristic U-shaped architecture that was specifically developed for biomedical image analysis and has already proven to be successful in analyzing tooth decay on x-ray images [22].

Both U-Net and Mask R-CNN are supervised learning algorithms that require labeled inputs, in our specific context: instance segmentation of the mineralized tissue.

In order to train the network, a batch size of 32 images was chosen for U-Net and 20 for Mask R-CNN. The weight update was performed with a stochastic gradient descent optimizer for both Mask-RCNN and U-Net. A 5-folds cross validation approach was implemented to assess the network robustness and optimize the remaining parameters. The analysis concluded on an optimal convergence after 10 epochs for both Mask-RCNN and U-Net.

2.5. Topological Data Analysis without Deep Learning (TDA) or with Deep Learning (TDA-DL)

Topological Data Analysis (TDA) consists in the application of the mathematic discipline of topology to data extracted from a real system allowing the analysis of geometrical patterns such as shapes [23]. Two specific approaches were compared to compute the I3M figures based on a segmented tooth (mask).

The first step of TDA consisted in the rotation of the image by vertically aligning the barycenters of the two instances segmentations in order to compute the tooth height (parameter c). The second step consisted in applying a gradient approach to find the line equidistant to both instance segmentations. This line represented the root canal center, its ending points was the middle of the apices. The final steps consisted in finding the two extremities of each apex. Simulation of radii centered on various points of the centered line were used to partition each instance segmentation in two parts: one separating the pulp and the dentine, the other separating the tooth and the environment. The extremity of the apex constituted the transition between these two parts. Finally, the a, b, and c parameters were computed: a and b corresponded to the distance between the two extremities of each apex, and c was the distance between the lowest and the highest point on the vertical axis.

The TDA-DL approach consisted in combining a topological data analysis followed by a deep learning approach. The first step was the rotation of the image by vertically aligning the barycenters of the two instances segmentations (apical and coronal) in order to compute the height (parameter c) of the tooth. The segmentations (apical and coronal) were then virtually separated into two sections by a vertical line joining the barycenters. The coronal limit points were defined, on the left and right side of the vertical line, as the lowest points of the coronal segmentation. In order to find the apical limit points, a deep

learning approach was implemented. It consisted in fitting an inverted U-shape line at the center of the apical mask. The U-shape line was mathematically defined by five points: two ending points and three inflexion points. A U-Net convolutional network was trained to infer this apical mask skeleton. The apical limit points were then defined, on the left and right side of the vertical line, as the ending points of the inferred U-shape skeleton. The a and b parameters were then computed as the distance between the coronal and apical ending points on the left side and on the right side, respectively, of the vertical middle line (Figure 1).




Figure 1. Illustration of the Topological Data Analysis (TDA) and Topological Data Analysis associated with Deep Learning (TDA-DL). Topological Analysis to determine the tooth height and apex diameter: (a) instance segmentation, (b) vertical rotation based on the barycenters, (c) root canal middle line based on the gradient analysis (cyan), segmentation of the root canal walls in four parts (pink, green, light blue, yellow) based on the radii analysis (orange) and the vertical line joining the barycenters, (d) measure of the tooth height and apex diameter, (e) root canal ending points (blue, red) obtained by deep learning, (f) measure of the tooth height and apex diameter.

2.6. Performance assessment

In order to assess and understand the segmentation error, every mask inferred by the algorithm was visually checked in comparison to the expert's radiographic graphical analysis to identify errors on the apices or on the crown.

The Intersection over Union metric (IoU) was computed to evaluate the Mask R-CNN and U-Net performance to infer the apical and coronal masks. Given G the ground truth mask and I the inferred mask, the IoU follows: $IoU = |G \cap I| / |G \cup I|$. In our specific context, one could label each pixel as True/False Positive/Negative, the computation of the IoU then becomes: $IoU = TP / (TP + FN + FP)$. IoU was computed for each radiograph on the apical mask, the coronal mask, as well as on the total combined mask. Paired sample bilateral T-Test was computed in order to assess the existence of a statistically significant difference between maskRCNN and U-Net.

In order to properly assess the error related solely to the topological analysis, the algorithm was also applied on ground truth segmentations. The inferred metrics, a, b and c were then compared to the expert's ones.

In order to assess the impact of the error on the final decision, the I3M threshold was set to 0.08: for $I3M < 0.08$, the subject was considered as being ≥ 18 -year-old, for $I3M > 0.08$, the subject was considered as being < 18 -year-old.

2.7. Statistical analysis

In order to analyze the ability of the automated approach to compute I3M, a paired bilateral T-test analysis was performed with a type 1 error of 0.05.

The tested null hypothesis was therefore: the inferred I3M is equivalent to the one computed by the expert.

This approach was used to compare the I3M inferred by the complete automated solution combining the deep learning and the topological approach to the expert's one. It

was also used to compare the I3M inferred by the topological analysis on the ground truth mask to the expert's one in order to isolate the error inherent to the second part of the process.

Analysis of the performance of the different algorithms regarding the final decision was performed using the McNemar's test for nominal data and the null hypothesis was the presence of an agreement.

Pearson correlations were also computed in order to estimate the linear dependency between the expert's I3M and the one computed by the various algorithms.

3. Results

3.1. Performance and errors of mask inference

Paired sample T-test of bilateral difference demonstrated a significative difference between Mask R-CNN and U-Net for the segmented masks (p-value : 3.20E-22), the apical masks (3.71E-22) and the overall masks (6.93E-07). In terms of mean intersection over union, U-Net performed better than Mask R-CNN for the coronal mask (U-Net: 92.9 %; Mask R-CNN: 86.1 %), the apical mask (U-Net: 74.8 %; Mas R-CNN: 62.1 %) as well as the overall mask (U-Net: 91.2 %; Mask R-CNN: 83.8 %) (Table 1).

Table 1. Performance of mask inference (Mask R-CNN or U-Net) on the different segmented part of the tooth.

Segmented Mask	Mask R-CNN mIoU*	U-Net mIoU*	p-value
Coronal	86.1%	92.9%	3.20E-22
Apical	62.1 %	74.8 %	3.71E-22
Overall	83.8 %	91.2 %	6.93E-07

* mIoU: mean intersection over union metric.

Errors analysis of the mask inference confirmed the superiority of U-Net over Mask R-CNN (Figure 2). As a matter of fact, the identification of the root apical part seemed to be more challenging for Mask R-CNN, reducing *de facto* the accuracy in the estimation of a+b (errors # in Figure 2d, 2e, and 2f). It also appeared that Mask R-CNN had difficulties in identifying the crown in its entirety, which could also impact the computation of c (errors * in Figure 2d, 2e, and 2f).




Figure 2. Illustration on three different radiographs (a,b,c) of the segmentation and its associated error with Mask-R CNN (d,e,f) and U-Net (g,h,i). Green: True Positive, Orange: False Positive, Red: False Negative, #: illustration of Mask R-CNN errors on the apices, *: illustration of Mask R-CNN error on the crown.

At this stage, in the training sample, approximately two thirds of the OPGs (57/88) were kept, which corresponded mostly to under-aged subjects (80% of the sample). Indeed, the remaining 31 OPGs presented closed or almost closed apices, which made difficult for U-Net to identify the two different parts of the tooth, and therefore for TDA or TDA-DL to identify the two apices.

3.2. Performance of TDA and TDA-DL

Topological analysis on the ground truth mask revealed similar performance between TDA and TDA-DL. TDA was able to determine a + b with a mean absolute error (MAE) $\pm$ standard deviation (SD) of 12.26 ± 7.21 pixels in comparison with the value of the expert, while the TDA-DL MAE $\pm$ SD was 17.98 ± 9.08 pixels (Figure 3). Similarly for c, the MAE $\pm$ SD was 26.67 ± 9.97 pixels for TDA and 26.21 ± 10.28 pixels for TDA-DL (Figure 4). Paired t-test analysis for TDA (p-value: 7.61×10^{-3}) and TDA-DL (1.40×10^{-10}) on ground truth found p-values < 0.05 , thereby rejecting the null hypothesis of similar mean between the expert and the various combinations.




Figure 3. Performance of Topological Data Analysis (TDA) and Topological Data Analysis associated with Deep Learning (TDA-DL) on ground truth segmentation to determine the I3M numerator (a+b).




Figure 4. Performance of Topological Data Analysis (TDA) and Topological Data Analysis associated with Deep Learning (TDA-DL) on ground truth segmentation to determine the I3M denominator (c).

I3M's similarity is important however the final decision (minor or adult) remain in our context the key part. The McNemar test on agreement between the expert and the algorithm was neither rejected for TDA (p-value: 15.73%) nor for TDA-DL (p-value: 8.33%).

3.3. Performance of TDA and TDA-DL

The combined approach consisted in implementing the best segmentation algorithm followed by the different topological analyses in order to compare their ability to predict the I3M score. The MAE $\pm$ SD was 0.04 ± 0.03 for U-Net combined with TDA and 0.06 ± 0.04 for U-Net combined with TDA-DL in comparison with a dental forensic expert. Both these combinations were able to reproduce 94.7 % (54/57) of the expert decisions.

Paired t-test analysis rejected the null hypothesis of equivalent mean only for U-Net combined with TDA (p-value of 16.36×10^{-2}).

The similarity of performance between U-Net combined with TDA or with TDA-DL was also confirmed by the analysis of the correlation between the I3M score computed by the expert and estimated by the different approaches. As a matter of fact, the Pearson correlation coefficient was of 92.77% (p-value= 6.47×10^{-8}) for U-Net combined with TDA and 89.28% (p-value= 4.96×10^{-8}) for U-Net combined with TDA-DL (Figure 5).




Figure 5. Overall comparison between TDA and TDA-DL with the expert. Performance of the two solutions were analyzed in terms of pixel error (a). Coherence between the two solutions and the expert were analyzed through pearson-correlation (b,c).

Analysis of the final decision based on the I3M score revealed a non-rejection of the McNemar test for any of the combinations considered, with a p-value of 8.33×10^{-2} for all the cases.

4. Discussion

The aim of this study was to evaluate the feasibility of replicating the cognitive mechanism of a forensic expert using an innovative approach consisting in the combination of supervised deep-learning approaches and automated topological algorithms. The results suggested that U-Net was the best approach to infer the mask of the mandibular third molar. They also revealed that the two topological approaches offered similar performance regarding their ability to properly infer a, b, and c, and therefore the I3M score. The developed approach was able to mimic the forensic expertise with a 94.7% accuracy. However, several methodological, technical, and ethical questions must be discussed.

Methodologically, unsupervised machine learning techniques such as deep neural network regressions have been implemented in order to prevent human errors [4,24–27]. These automated methods appear to be particularly attractive as they are fast and less time-consuming since they do not require any prior labeling work. However, these models have been reported to not be mature enough to be implemented, due to their high variance especially regarding the key chronicle age of 18 years [4]. In order to overcome such an issue, the approach of the present study consisted in being based on the I3M score, which has good results regarding the key chronicle age of 18 years [6,7]. The present procedure consisted in using an intermediate segmentation (mask). This innovative approach reduces the dimensionality of the problem by transforming the original image into simple shapes, which become a better input for the topological analysis in order to properly measure a, b, and c. Previous publications in this field have suggested segmentation with a unique mask for the whole tooth [26–28]. However, by definition, such approaches do not encapsulate the presence of two different tissues (mineralized tissue and pulp tissue) at the tooth apex, preventing *de facto* the algorithm ability to compute the apex width (a, b). To resolve this issue, the present study proposed the implementation of a two-mask approach. Such a strategy could easily be adapted to other dental expertise fields requiring measurements or calculus on dental radiographs, for example in order to assess endodontic complexity or to estimate bone loss [29–31].

Regarding the first part of the model, the algorithm produced slightly inferior results compared to previous studies attempting to segment mandibular third molar through Mask-RCNN or U-Net [27,28,32]. This could be explained by the fact that our database included mostly young patients with starting root formation whose segmentations are more complicated due to inconsistent morphologies [27,28]. Moreover, the results are highly influenced by the apical mask, which is likely more complicated to segment due to the wide variety of anatomies and developmental stages encountered. As previously reported [32–34], our results revealed that U-Net was particularly indicated to infer masks on dental radiographs. Moreover, the error analysis revealed that U-Net was also better at identifying the apices of roots. This difficulty during the segmentation to identify entirely the apices of roots have already been observed for molars [35,36], and this point is particularly important for performing future accurate topological analysis.

Regarding the overall performance, U-Net combined with TDA or with TDA-DL displayed a 95% accuracy in comparison with the expert's decision, which is promising for this first pilot study. It is important to note that these results were obtained on a database with an 80% share of underage patients given the necessity to have a large panel of open apices radiograph. Indeed, compared to other similar studies [36,37], the present study presented a relatively low number of OPGs, which might have limited the algorithm ability to learn all possible root configurations, and one could reasonably expect better results with a larger training database.

Graphical analysis between the expert's measurements and the ones produced by the algorithm revealed a systematic overestimation by the latter. These discrepancies can be explained by the fact that the algorithm used the crown most coronal point when estimating the c value, while the expert used a reference point that is more centered on the crown; regarding a and b, the algorithm by design measured the distance between the two most apical points while the expert used points that are slightly more coronal, in other words

the expert estimated a width at the apical constriction while the algorithm estimated it at the apical foramen.

This pilot study also highlighted several limits that must be discussed. Indeed, the present study was performed after a manual cropping of the third molar, which limited its ease of use but also led to better results. A future perspective would be to implement an automated cropping of the mandibular third molars, such an approach appears to be relatively easy according to published studies [24,28]. It is also important to note that major differences could exist between populations, but also between OPG themselves, thereby leading to different root configurations, positions, and radiograph qualities, potentially increasing the errors during the labeling and the I3M computation [38]. Previous studies based on unsupervised approaches have offered very few explicability tools and often times display direct raw results without giving to the user the possibility of evaluating the intermediary step leading *de facto* to Black Box Models. Notwithstanding, it is worth mentioning the Grad-CAM heat map that was proposed to improve the explicability of deep-learning supervised solutions [39]. By reporting the masks and displaying the a, b, and c segments on the radiograph, the procedure proposed herein allows any expert or user to visually validate the mask inference as well as the computation of the score, thereby greatly improving the overall explicability and transparency. A selection bias is also inherent to the expert's filtering process. As a matter of fact, the selection criterion was: radiographic images compatible with the computation of an I3M score. In other words, only teeth with open apices were selected, leading to the creation of a subject sample for which the average age was lower than 18 years. However, further investigations could lead to the production of an algorithm able to identify the tooth stage or closed apex on a given radiograph, and therefore compensate for this bias [24,40]. Furthermore, this pilot study based itself on a single forensic expert and a relatively small database mixing radiographic images from two countries. In this context, the generalization of the proposed approach would require more extensive research on larger, more diverse database, as well as the comparison to a panel of several I3M experts.

Finally, some ethical questions relative to the use of AI-based technologies could be raised [41], especially given the legal impact any mistakes could have. This question is challenging; however, with respect to EU law, most of the time, most of the responsibility is transferred to the user (aka the expert) [42]. It, therefore, requires to be particularly careful upon distributing such a technology. Critically, the aim of this study was to estimate the technical feasibility of developing a tool for educational purpose or to assist experts in uncertain cases, especially when the score averages around 0.08; this study never intended to replace forensic experts. This fully transparent approach offering visual results to the final user is particularly important since AI in dentistry is a fairly recent field of investigation, trust must be gained in order to obtain a sustained and fully accepted system [41–44].

5. Conclusions

This study presented an innovative strategy to compute various factors on OPGs. It was able to segment mandibular third molars in two parts and measure the apex width (a and b), as well as the tooth height (c). The best approach consisted in a U-Net algorithm combined with a topological approach. The addition of a deep learning component to the topological approach did not improve the quality of the decisions made by the algorithm. This study illustrated the technical feasibility of creating a decision-making tool of I3M index for forensic experts with a 95% accuracy and an I3M mean absolute error of 0.04. However, due to the numerous limitations highlighted by this proof-of-concept study, further investigations are required before a fully functional implementation.

Author Contributions: Conceptualization, M.D. and C.T.; methodology, R.B. and P.R.; software, R.B., R.I., R.R. and L.B.; validation, R.B. and P.R.; writing—original draft preparation, R.B. and M.D.; writing—review and editing, R. B. and M.D.; visualization, R.B., R.I., R.R. and L.B.; supervision, M.D. and C.T. All authors have read and agreed to the published version of the manuscript.

Funding: This research received no external funding.

Institutional Review Board Statement: The study was conducted in accordance with the Declaration of Helsinki, with accordance of the local ethical committee (HCL-21_440).

Data Availability Statement: Data is available by contacting the corresponding or first authors.

Acknowledgments: The authors would like to thank Véréna Landel and the Scientific Writing Department from Hospices Civils de Lyon for proofreading the manuscript.

Conflicts of Interest: The authors declare no conflict of interest.

References

- Galić, I.; Mihanović, F.; Giuliadori, A.; Conforti, F.; Cingolani, M.; Cameriere, R. Accuracy of Scoring of the Epiphyses at the Knee Joint (SKJ) for Assessing Legal Adult Age of 18 Years. *Int J Legal Med* **2016**, *130*, 1129–1142, doi:10.1007/s00414-016-1348-x.
- Cunha, E.; Baccino, E.; Martrille, L.; Ramsthaler, F.; Prieto, J.; Schuliar, Y.; Lynnerup, N.; Cattaneo, C. The Problem of Aging Human Remains and Living Individuals: A Review. *Forensic Science International* **2009**, *193*, 1–13, doi:10.1016/j.forsciint.2009.09.008.
- Schmeling, A.; Grundmann, C.; Fuhrmann, A.; Kaatsch, H.-J.; Knell, B.; Ramsthaler, F.; Reisinger, W.; Riepert, T.; Ritz-Timme, S.; Rösing, F.; et al. Updated Recommendations of the Study Group on Forensic Age Diagnostics for Age Estimation in the Living in Criminal Proceedings. *Rechtsmedizin* **2008**, *18*, 451–453.
- Vila-Blanco, N.; Carreira, M.J.; Varas-Quintana, P.; Balsa-Castro, C.; Tomas, I. Deep Neural Networks for Chronological Age Estimation from OPG Images. *IEEE transactions on medical imaging* **2020**, *39*, 2374–2384.
- Kim, S.; Lee, Y.-H.; Noh, Y.-K.; Park, F.C.; Auh, Q.-S. Age-Group Determination of Living Individuals Using First Molar Images Based on Artificial Intelligence. *Sci Rep* **2021**, *11*, 1073, doi:10.1038/s41598-020-80182-8.
- Cameriere, R.; Ferrante, L.; Cingolani, M. Age Estimation in Children by Measurement of Open Apices in Teeth. *International Journal of Legal Medicine* **2006**, *120*, 49–52, doi:10.1007/s00414-005-0047-9.
- Cameriere, R.; Ferrante, L.; De Angelis, D.; Scarpino, F.; Galli, F. The Comparison between Measurement of Open Apices of Third Molars and Demirjian Stages to Test Chronological Age of over 18 Year Olds in Living Subjects. *International Journal of Legal Medicine* **2008**, *122*, 493–497, doi:10.1007/s00414-008-0279-6.
- Tafrount, C.; Galić, I.; Franchi, A.; Fanton, L.; Cameriere, R. Third Molar Maturity Index for Indicating the Legal Adult Age in Southeastern France. *Forensic Science International* **2019**, *294*, 218.e1–218.e6, doi:10.1016/j.forsciint.2018.10.013.
- Hostiuc, S.; Diaconescu, I.; Rusu, M.C.; Negoii, I. Age Estimation Using the Cameriere Methods of Open Apices: A Meta-Analysis. *Healthcare (Switzerland)* **2021**, *9*, 1–14, doi:10.3390/healthcare9020237.
- Angelakopoulos, N.; Galić, I.; Balla, S.B.; Kiş, H.C.; Gómez Jiménez, L.; Zolotenkova, G.; Mohd Yusof, M.Y.P.; Hadzić Selmanagić, A.; Pandey, H.; Palmela Pereira, C.; et al. Comparison of the Third Molar Maturity Index (I3M) between Left and Right Lower Third Molars to Assess the Age of Majority: A Multi-Ethnic Study Sample. *International Journal of Legal Medicine* **2021**, *135*, 2423–2436, doi:10.1007/s00414-021-02656-2.
- Jiménez, L.G.; Palacio, L.A.V.; Luca, S. De; Vasquez, Y.R.; Capellán, M.C.; Cameriere, R. Validation of the Third Molar Maturity Index (I3M): Study of a Dominican Republic Sample. *Journal of Forensic Odonto-Stomatology* **2019**, *37*, 27–33.
- de Miranda, J.C.; de Cássia Silva Azevedo, A.; Rocha, M.; Michel-Crosato, E.; Biazevic, M.G.H. Age Estimation in Brazilian Adults by Kvaal's and Cameriere's Methods. *Brazilian Oral Research* **2020**, *34*, 1–10, doi:10.1590/1807-3107BOR-2020.VOL34.0051.
- Shen, S.; Liu, Z.; Wang, J.; Fan, L.; Ji, F.; Tao, J. Machine Learning Assisted Cameriere Method for Dental Age Estimation. *BMC Oral Health* **2021**, *21*, 1–10, doi:10.1186/s12903-021-01996-0.
- Perschbacher, S. Interpretation of Panoramic Radiographs. *Australian Dental Journal* **2012**, *57*, 40–45, doi:10.1111/j.1834-7819.2011.01655.x.
- Signori, C.; Laske, M.; Mendes, F.M.; Huysmans, M.C.D.N.J.M.; Cenci, M.S.; Opdam, N.J.M. Decision-Making of General Practitioners on Interventions at Restorations Based on Bitewing Radiographs. *Journal of Dentistry* **2018**, *76*, 109–116, doi:10.1016/j.jdent.2018.07.003.
- Gasqui, M.-A.; Pérard, M.; Decup, F.; Monsarrat, P.; Turpin, Y.-L.; Villat, C.; Gueyffier, F.; Maucourt-Boulch, D.; Roche, L.; Grosgeat, B. Place of a New Radiological Index in Predicting Pulp Exposure before Intervention for Deep Carious Lesions. *Oral Radiology* **2022**, *38*, 89–98, doi:10.1007/s11282-021-00530-w.
- Schwendicke, F.; Singh, T.; Lee, J.-H.; Gaudin, R.; Chaurasia, A.; Wiegand, T.; Uribe, S.; Krois, J. Artificial Intelligence in Dental Research: Checklist for Authors, Reviewers, Readers. *Journal of Dentistry* **2021**, *107*, 103610, doi:10.1016/j.jdent.2021.103610.
- Realization of the Contrast Limited Adaptive Histogram Equalization (CLAHE) for Real-Time Image Enhancement | SpringerLink Available online: <https://link.springer.com/article/10.1023/B:VLSI.0000028532.53893.82> (accessed on 24 July 2022).

19. Russell, B.C.; Torralba, A.; Murphy, K.P.; Freeman, W.T. LabelMe: A Database and Web-Based Tool for Image Annotation. *Int J Comput Vis* **2008**, *77*, 157–173, doi:10.1007/s11263-007-0090-8. 435
20. He, K.; Gkioxari, G.; Dollar, P.; Girshick, R. Mask R-CNN. In Proceedings of the 2017 IEEE International Conference on Computer Vision (ICCV); IEEE, October 2017; pp. 2980–2988. 437
21. Waleed Abdulla Mask R-CNN for Object Detection and Instance Segmentation on Keras and TensorFlow 2017. 439
22. Ronneberger, O.; Fischer, P.; Brox, T. U-Net: Convolutional Networks for Biomedical Image Segmentation. In: 2015; pp. 234–241. 440
23. Topological Data Analysis. *Inverse Problems* **2011**, *27*, 120201, doi:10.1088/0266-5611/27/12/120201. 442
24. Banar, N.; Bertels, J.; Laurent, F.; Boedi, R.M.; De Tobel, J.; Thevissen, P.; Vandermeulen, D. Towards Fully Automated Third Molar Development Staging in Panoramic Radiographs. *International Journal of Legal Medicine* **2020**, *134*, 1831–1841, doi:10.1007/s00414-020-02283-3. 443
25. Galibourg, A.; Cussat-Blanc, S.; Dumoncel, J.; Telmon, N.; Monsarrat, P.; Maret, D. Comparison of Different Machine Learning Approaches to Predict Dental Age Using Demirjian's Staging Approach. *International Journal of Legal Medicine* **2021**, *135*, 665–675, doi:10.1007/s00414-020-02489-5. 444
26. Vranckx, M.; Van Gerven, A.; Willems, H.; Vandemeulebroucke, A.; Ferreira Leite, A.; Politis, C.; Jacobs, R. Artificial Intelligence (AI)-Driven Molar Angulation Measurements to Predict Third Molar Eruption on Panoramic Radiographs. *International Journal of Environmental Research and Public Health* **2020**, *17*, 3716, doi:10.3390/ijerph17103716. 445
27. Leite, A.F.; Gerven, A. Van; Willems, H.; Beznik, T.; Lahoud, P.; Gaêta-Araujo, H.; Vranckx, M.; Jacobs, R. Artificial Intelligence-Driven Novel Tool for Tooth Detection and Segmentation on Panoramic Radiographs. *Clinical oral investigations* **2021**, *25*, 2257–2267, doi:10.1007/s00784-020-03544-6. 446
28. Vinayahalingam, S.; Xi, T.; Bergé, S.; Maal, T.; de Jong, G. Automated Detection of Third Molars and Mandibular Nerve by Deep Learning. *Scientific Reports* **2019**, *9*, 1–7, doi:10.1038/s41598-019-45487-3. 447
29. Hartmann, R.C.; Fensterseifer, M.; Peters, O.A.; de Figueiredo, J.A.P.; Gomes, M.S.; Rossi-Fedele, G. Methods for Measurement of Root Canal Curvature: A Systematic and Critical Review. *International Endodontic Journal* **2019**, *52*, 169–180, doi:10.1111/iej.12996. 448
30. Kim, J.; Lee, H.S.; Song, I.S.; Jung, K.H. DeNTNet: Deep Neural Transfer Network for the Detection of Periodontal Bone Loss Using Panoramic Dental Radiographs. *Scientific Reports* **2019**, *9*, 1–9, doi:10.1038/s41598-019-53758-2. 449
31. Chang, H.J.; Lee, S.J.; Yong, T.H.; Shin, N.Y.; Jang, B.G.; Kim, J.E.; Huh, K.H.; Lee, S.S.; Heo, M.S.; Choi, S.C.; et al. Deep Learning Hybrid Method to Automatically Diagnose Periodontal Bone Loss and Stage Periodontitis. *Scientific Reports* **2020**, *10*, 1–8, doi:10.1038/s41598-020-64509-z. 450
32. Koch, T.L.; Perslev, M.; Igel, C.; Brandt, S.S. Accurate Segmentation of Dental Panoramic Radiographs with U-NETS. *Proceedings - International Symposium on Biomedical Imaging* **2019**, 2019-April, 15–19, doi:10.1109/ISBI.2019.8759563. 451
33. Ronneberger, O.; Fischer, P.; Brox, T. Dental X-Ray Image Segmentation Using a U-Shaped Deep Convolutional Network. *International Symposium on Biomedical Imaging* **2015**, 1–13. 452
34. Li, Y.; Wang, S.; Wang, J.; Zeng, G.; Liu, W.; Zhang, Q.; Jin, Q.; Wang, Y. *GT U-Net: A U-Net Like Group Transformer Network for Tooth Root Segmentation*; Springer International Publishing, 2021; Vol. 12966 LNCS; ISBN 9783030875886. 453
35. Lee, J.H.; Han, S.S.; Kim, Y.H.; Lee, C.; Kim, I. Application of a Fully Deep Convolutional Neural Network to the Automation of Tooth Segmentation on Panoramic Radiographs. *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology* **2020**, *00*, 1–8, doi:10.1016/j.oooo.2019.11.007. 454
36. Vinayahalingam, S.; Goey, R. shan; Kempers, S.; Schoep, J.; Cherici, T.; Moin, D.A.; Hanisch, M. Automated Chart Filing on Panoramic Radiographs Using Deep Learning. *Journal of Dentistry* **2021**, *115*, 103864, doi:10.1016/j.jdent.2021.103864. 455
37. Cui, W.; Zeng, L.; Chong, B.; Zhang, Q. Toothpix: Pixel-Level Tooth Segmentation in Panoramic X-Ray Images Based on Generative Adversarial Networks. *2021 IEEE 18th International Symposium on Biomedical Imaging (ISBI)* **2021**, doi:10.1109/ISBI48211.2021.9433807. 456
38. Eliasova, H.; Dostalova, T.; Prochazka, A.; Sediva, E.; Horacek, M.; Urbanova, P.; Hlinakova, P. Comparison of 2D OPG Image versus Orthopantomogram from 3D CBCT from the Forensic Point of View. *Legal Medicine* **2021**, *48*, 101802, doi:10.1016/j.legalmed.2020.101802. 457
39. Vila-Blanco, N.; Carreira, M.J.; Varas-Quintana, P.; Balsa-Castro, C.; Tomas, I. Deep Neural Networks for Chronological Age Estimation from OPG Images. *IEEE Transactions on Medical Imaging* **2020**, 1–1, doi:10.1109/tmi.2020.2968765. 458
40. De Tobel, J.; Radesh, P.; Vandermeulen, D.; Thevissen, P.W. An Automated Technique to Stage Lower Third Molar Development on Panoramic Radiographs for Age Estimation: A Pilot Study. *Journal of Forensic Odonto-Stomatology* **2017**, *35*, 42–54. 459
41. Mörch, C.M.; Atsu, S.; Cai, W.; Li, X.; Madathil, S.A.; Liu, X.; Mai, V.; Tamimi, F.; Dilhac, M.A.; Ducret, M. Artificial Intelligence and Ethics in Dentistry: A Scoping Review. *Journal of Dental Research* **2021**, doi:10.1177/00220345211013808. 460
42. Cohen, I.G.; Evgeniou, T.; Gerke, S.; Minssen, T. The European Artificial Intelligence Strategy: Implications and Challenges for Digital Health. *The Lancet Digital Health* **2020**, *2*, e376–e379, doi:10.1016/S2589-7500(20)30112-6. 461
43. Ducret, M.; Mörch, C.-M.; Karteva, T.; Fisher, J.; Schwendicke, F. Artificial Intelligence for Sustainable Oral Healthcare. *Journal of Dentistry* **2022**, *127*, 104344, doi:10.1016/j.jdent.2022.104344. 462
44. Ducret, M.; Mörch, C. Focus on Artificial Intelligence Ethics in Dentistry. *Journal of Dental Sciences* **2022**, doi:10.1016/j.jds.2022.12.003. 463

Disclaimer/Publisher's Note: The statements, opinions and data contained in all publications are solely those of the individual author(s) and contributor(s) and not of MDPI and/or the editor(s). MDPI and/or the editor(s) disclaim responsibility for any injury to people or property resulting from any ideas, methods, instructions or products referred to in the content.

III. Discussion

Afin de permettre une réplique du processus décisionnel d'un expert, l'article présente une approche innovante à deux égards : son approche de segmentation bi-masque ainsi que sa combinaison algorithmique.

1. Première innovation : la segmentation bi-masque

La segmentation d'organes dentaires par intelligence artificielle a été abordée à de multiples reprises dans la littérature avec d'excellents résultats (29–32). Néanmoins les approches consistaient systématiquement en une unique segmentation de chaque dent (figure 7).




Figure 7 : Segmentation Proposée par Leite et al. Proposant un masque unique pour estimer le contour de la dent. (33)

Il est aisé d'observer qu'une telle segmentation omet d'identifier le parenchyme pulpaire empêchant de facto toute possibilité de réalisation de mesures en lien avec cet élément, notamment, l'ouverture apicale.

La solution proposée par notre article (figure 8) fût de segmenter les tissus dentaires radio-opaque contigus. Nous obtenons alors non pas un mais deux masques de segmentation.




Figure 8 : Segmentation Proposée par notre article

En bleu la portion apicale des tissus durs dentaire, et en rouge la portion coronaire. Une telle distinction permet d'inférer le parenchyme pulpaire se situant entre la portion apicale et coronaire.

Cette nouvelle approche permet ainsi d'avoir en négatif le détail de l'anatomie pulpaire, et d'effectuer dans un second temps les mesures.

2. Seconde Innovation : combinaison algorithmique

Les algorithmes d'intelligence artificielle appliqués à la segmentation voire aux calculs de certaines métriques (y compris l'âge) de l'organe dentaire ont été nombreux (29,32–36). La première génération de ces algorithmes fût celle des approches par réseaux de neurones reconnus pour leur stabilité. Néanmoins, ces premières propositions n'ont pas su offrir un niveau de précision suffisant, notamment en ce qui concerne l'estimation de l'âge et plus particulièrement la discrimination majeur / mineur (37). Notons, de surcroît, que de telles propositions amènent fréquemment à des solutions de type « black box » c'est-à-dire offrant un résultat brut (majeur/mineur) sans pour autant offrir d'explicabilité dudit résultat. Ce type de solution peut donc difficilement être une aide à la décision puisqu'elle impose sans détails un résultat.

Notre approche, grâce à la combinaison de deux algorithmes, permet d'améliorer les deux faiblesses exposées plus hauts. Le premier algorithme, un réseau de neurone, permet de segmenter la dent, le second correspond à une approche topologique prenant comme donnée d'entrée la simple segmentation. L'analyse topologique correspond à l'étude des formes et de la géométrie afin d'en extraire des informations. L'utilisation de la segmentation comme donnée d'entrée représente une réduction drastique de la dimensionalité du problème permettant de s'assurer d'une bien meilleure performance du second algorithme. Ainsi la combinaison des deux algorithmes permet d'améliorer la précision des résultats. En outre, le second algorithme,

puisque topologique permet d'offrir un résultat visuel permettant une explicabilité et un positionnement en tant qu'aide à la décision.




Figure 9 : Exemple du résultat de la combinaison des deux algorithmes illustrant l'explicabilité du modèle proposé. La ligne rouge au niveau des apex et celle en bleu verticale correspondent aux mesures utilisées pour le calcul de l'I3M, tandis que les autres lignes permettent d'apprécier le contour des éléments dentaires inférés par l'algorithme.

3. Enjeux éthiques et perspectives

3.1 Enjeux éthiques

Ce projet, de par l'application d'algorithmes, qui plus est dans un contexte médico-légal à impacts individuels important, est forcément lié à des questions éthiques dites d' « AI Ethics » dans le cadre spécifique de l'intelligence artificielle (38).

Les algorithmes de « deep-learning » sont par définition auto-apprenant et en perpétuelle évolution. Ainsi, nul ne peut prédire l'impact de l'apprentissage sur les futures prédictions. Ces caractéristiques de non prévisibilité et faible stabilité propre au deep-learning complexifient grandement la réglementation (39). Est-il possible dans le contexte de ce système imprévisible d'engager la responsabilité du développeur sur les conséquences de la prise de décision ?

Dans le cas d'une aide à la décision, telle que développée dans l'article, au niveau européen, la responsabilité éthique et légale engagée reste celle de l'utilisateur final, qu'il soit expert ou non (40,41).

La solution proposée est un cas d'étude illustrant la capacité d'un système à répliquer un processus décisionnel complexe. Il conviendra dans un second temps d'optimiser ledit système grâce à une base de données de plus grande ampleur et offrant une plus grande diversité. Cette étape permettra à terme de s'assurer d'obtenir un outil stable, fiable et généralisable à l'ensemble des situations cliniques afin de pouvoir déployer plus largement la solution (38,41,42).

3.2 Perspectives

La capacité de segmenter la partie apicale et coronaire de la dent, d'en inférer le trajet central pulpaire ainsi que la capacité à réaliser une mesure graphique finale sont autant d'outils qui peuvent trouver écho dans d'autres applications en odontologie (43,44) : estimation pré-opératoire de la difficulté du traitement endodontique d'une dent, identification précise des lésions radiographiques, positionnement idéal d'un implant, planification de chirurgie complexe etc.

L'approche novatrice consistant à combiner deux algorithmes dont un permettant une analyse topologique possède également le potentiel d'améliorer la performance des réseaux de neurones d'ores et déjà proposés dans la recherche sur les différents domaines de l'odontologie (45): odontologie conservatrice (46), endodontie (47,48), parodontologie (49), chirurgie (50), implantologie (51).

Évidemment, les innovations proposées dans l'article ne sont pas uniquement applicables au domaine de l'odontologie. L'utilisation de l'intelligence artificielle et plus particulièrement du « deep-learning » dans le domaine de la santé en générale (26) permet un diagnostic plus rapide, une réduction des erreurs médicales, et éventuellement la possibilité pour les patients de réaliser eux-mêmes certaines analyses (52–54). L'application de structure algorithmique similaire à celle proposée dans l'article peut permettre d'améliorer les solutions existantes voire d'en développer de nouvelles.

Conclusion

Ce travail de thèse propose une solution innovante dans le domaine de l'odontologie légale. L'utilisation d'un algorithme pour réduire la dimensionalité du problème et d'un second d'analyse topologique afin d'estimer des points clefs sur l'image, constitue une approche novatrice à un problème complexe d'analyse d'imagerie médicale. Cette preuve de concept ne saurait évidemment ne soustraire à l'expertise d'un spécialiste, mais elle pourrait en revanche, être une aide à la décision régulière pour ce dernier. Les résultats obtenus dans le contexte de cette preuve de concept sont encourageants et démontre le potentiel de telles approches.

Bibliographie

1. Cunha E, Baccino E, Martrille L, Ramsthaler F, Prieto J, Schuliar Y, et al. The problem of aging human remains and living individuals: A review. *Forensic Science International*. 2009 Dec;193(1–3):1–13.
2. Jia L, Zhang W, Chen X. Common methods of biological age estimation. *Clin Interv Aging*. 2017 May 11;12:759–72.
3. Schmeling A, Geserick G, Reisinger W, Olze A. Age estimation. *Forensic Science International*. 2007 Jan 17;165(2):178–81.
4. Schmeling A, Dettmeyer R, Rudolf E, Vieth V, Geserick G. Forensic Age Estimation. *Dtsch Arztebl Int*. 2016 Jan;113(4):44–50.
5. LOI n° 2016-297 du 14 mars 2016 relative à la protection de l'enfant (1). 2016-297 Mar 14, 2016.
6. Schmeling A, Grundmann C, Fuhrmann A, Kaatsch HJ, Knell B, Ramsthaler F, et al. Updated recommendations of the Study Group on Forensic Age Diagnostics for age estimation in the living in criminal proceedings. *Rechtsmedizin*. 2008 Jan 1;18:451–3.
7. Cameriere R, Ferrante L, De Angelis D, Scarpino F, Galli F. The comparison between measurement of open apices of third molars and Demirjian stages to test chronological age of over 18 year olds in living subjects. *Int J Legal Med*. 2008 Nov;122(6):493–7.
8. Cameriere R, Ferrante L, Cingolani M. Age estimation in children by measurement of open apices in teeth. *Int J Legal Med*. 2006 Jan;120(1):49–52.
9. Angelakopoulos N, Galić I, Balla SB, Kiş HC, Gómez Jiménez L, Zolotenkova G, et al. Comparison of the third molar maturity index (I3M) between left and right lower third molars to assess the age of majority: a multi-ethnic study sample. *Int J Legal Med*. 2021 Nov;135(6):2423–36.
10. Albernaz Neves J, Antunes-Ferreira N, Machado V, Botelho J, Proença L, Quintas A, et al. Validation of the Third Molar Maturation Index (I3M) to assess the legal adult age in the Portuguese population. *Sci Rep*. 2020 Oct 28;10(1):18466.
11. Diamant-Berger O. Détermination médico-légale de l'âge du sujet jeune. :4.
12. Neves JA, Antunes-Ferreira N, Machado V, Botelho J, Proença L, Quintas A, et al. Validation of the Third Molar Maturation Index (I 3M) to assess the legal adult age in the Portuguese population. *Scientific reports*. 2020;10(1):1–10.
13. What is Artificial Intelligence (AI)? [Internet]. 2022 [cited 2022 Nov 18]. Available from: <https://www.ibm.com/cloud/learn/what-is-artificial-intelligence>
14. Artificial Intelligence (AI) [Internet]. DataRobot AI Cloud. [cited 2022 Nov 18]. Available from: <https://www.datarobot.com/wiki/artificial-intelligence/>
15. Libbrecht MW, Noble WS. Machine learning applications in genetics and genomics. *Nat Rev Genet*. 2015 Jun;16(6):321–32.
16. Kourou K, Exarchos TP, Exarchos KP, Karamouzis MV, Fotiadis DI. Machine learning applications in cancer prognosis and prediction. *Computational and Structural Biotechnology Journal*. 2015 Jan 1;13:8–17.
17. Awoyemi JO, Adetunmbi AO, Oluwadare SA. Credit card fraud detection using machine learning techniques: A comparative analysis. In: 2017 International Conference on Computing Networking and Informatics (ICCNI). 2017. p. 1–9.
18. Perlich C, Dalessandro B, Raeder T, Stitelman O, Provost F. Machine learning for targeted display advertising: transfer learning in action. *Mach Learn*. 2014 Apr 1;95(1):103–27.
19. Chen J, Jenkins WK. Facial recognition with PCA and machine learning methods. In: 2017 IEEE 60th International Midwest Symposium on Circuits and Systems (MWSCAS). 2017. p. 973–6.
20. Lorberfeld A. Machine Learning Algorithms In Layman's Terms, Part 1 [Internet]. Medium. 2019 [cited 2022 Nov 18]. Available from: <https://towardsdatascience.com/machine-learning-algorithms-in-laymans-terms-part-1-d0368d769a7b>

21. Rosebrock A. Mask R-CNN with OpenCV [Internet]. PyImageSearch. 2018 [cited 2022 Nov 18]. Available from: <https://pyimagesearch.com/2018/11/19/mask-r-cnn-with-opencv/>
22. Convolutional neural networks — Neurocomputing [Internet]. [cited 2022 Nov 18]. Available from: <https://julien-vitay.net/lecturenotes-neurocomputing/3-deeplearning/3-CNN.html>
23. Casado-García Á, Domínguez C, García-Domínguez M, Heras J, Inés A, Mata E, et al. CLoDSA: a tool for augmentation in classification, localization, detection, semantic segmentation and instance segmentation tasks. *BMC Bioinformatics*. 2019 Jun 13;20(1):323.
24. Chen LC, Hermans A, Papandreou G, Schroff F, Wang P, Adam H. MaskLab: Instance Segmentation by Refining Object Detection with Semantic and Direction Features. In: 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition [Internet]. Salt Lake City, UT: IEEE; 2018 [cited 2023 Jan 19]. p. 4013–22. Available from: <https://ieeexplore.ieee.org/document/8578520/>
25. Li F, Zhang H, xu H, Liu S, Zhang L, Ni LM, et al. Mask DINO: Towards A Unified Transformer-based Framework for Object Detection and Segmentation [Internet]. arXiv; 2022 [cited 2023 Jan 19]. Available from: <http://arxiv.org/abs/2206.02777>
26. Mazurowski MA, Buda M, Saha A, Bashir MR. Deep learning in radiology: An overview of the concepts and a survey of the state of the art with focus on MRI. *Journal of Magnetic Resonance Imaging*. 2019;49(4):939–54.
27. He K, Gkioxari G, Dollar P, Girshick R. Mask R-CNN. In: 2017 IEEE International Conference on Computer Vision (ICCV) [Internet]. Venice: IEEE; 2017 [cited 2022 Jul 18]. p. 2980–8. Available from: <http://ieeexplore.ieee.org/document/8237584/>
28. Ronneberger O, Fischer P, Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. In: Navab N, Hornegger J, Wells WM, Frangi AF, editors. *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015* [Internet]. Cham: Springer International Publishing; 2015 [cited 2022 Jul 18]. p. 234–41. (Lecture Notes in Computer Science; vol. 9351). Available from: http://link.springer.com/10.1007/978-3-319-24574-4_28
29. Leite AF, Van Gerven A, Willems H, Beznik T, Lahoud P, Gaêta-Araujo H, et al. Artificial intelligence-driven novel tool for tooth detection and segmentation on panoramic radiographs. *Clinical oral investigations*. 2021;25(4):2257–67.
30. Hung K, Montalvao C, Tanaka R, Kawai T, Bornstein MM. The use and performance of artificial intelligence applications in dental and maxillofacial radiology: A systematic review. *Dentomaxillofacial Radiology*. 2020 Jan;49(1):20190107.
31. Abdalla-Aslan R, Yeshua T, Kabla D, Leichter I, Nadler C. An artificial intelligence system using machine-learning for automatic detection and classification of dental restorations in panoramic radiography. *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology*. 2020 Nov 1;130(5):593–602.
32. Shan T, Tay FR, Gu L. Application of Artificial Intelligence in Dentistry. *J Dent Res*. 2021 Mar 1;100(3):232–44.
33. Vranckx M, Van Gerven A, Willems H, Vandemeulebroucke A, Ferreira Leite A, Politis C, et al. Artificial intelligence (AI)-driven molar angulation measurements to predict third molar eruption on panoramic radiographs. *International Journal of Environmental Research and Public Health*. 2020;17(10):3716.
34. Kim S, Lee YH, Noh YK, Park FC, Auh QS. Age-group determination of living individuals using first molar images based on artificial intelligence. *Sci Rep*. 2021 Dec;11(1):1073.
35. Khanagar SB, Al-ehaideb A, Maganur PC, Vishwanathaiah S, Patil S, Baeshen HA, et al. Developments, application, and performance of artificial intelligence in dentistry – A systematic review. *Journal of Dental Sciences*. 2021 Jan 1;16(1):508–22.
36. Schwendicke F, Samek W, Krois J. Artificial Intelligence in Dentistry: Chances and Challenges. *J Dent Res*. 2020 Jul 1;99(7):769–74.

37. Vila-Blanco N, Carreira MJ, Varas-Quintana P, Balsa-Castro C, Tomas I. Deep neural networks for chronological age estimation from OPG images. *IEEE transactions on medical imaging*. 2020;39(7):2374–84.
38. Mörch CM, Atsu S, Cai W, Li X, Madathil SA, Liu X, et al. Artificial Intelligence and Ethics in Dentistry: A Scoping Review. *J Dent Res*. 2021 Dec;100(13):1452–60.
39. King BF. Artificial Intelligence and Radiology: What Will the Future Hold? *Journal of the American College of Radiology*. 2018 Mar 1;15(3):501–3.
40. Pesapane F, Volonté C, Codari M, Sardanelli F. Artificial intelligence as a medical device in radiology: ethical and regulatory issues in Europe and the United States. *Insights Imaging*. 2018 Oct 1;9(5):745–53.
41. Cohen IG, Evgeniou T, Gerke S, Minssen T. The European artificial intelligence strategy: implications and challenges for digital health. *The Lancet Digital Health*. 2020 Jul;2(7):e376–9.
42. Ducret M, Mörch CM, Karteva T, Fisher J, Schwendicke F. Artificial intelligence for sustainable oral healthcare. *Journal of Dentistry*. 2022 Dec 1;127:104344.
43. Brickley MR, Shepherd JP, Armstrong RA. Neural networks: a new technique for development of decision support systems in dentistry. *Journal of Dentistry*. 1998 May;26(4):305–9.
44. Park WJ, Park JB. History and application of artificial neural networks in dentistry. *Eur J Dent*. 2018 Oct;12(04):594–601.
45. Schwendicke F, Golla T, Dreher M, Krois J. Convolutional neural networks for dental image diagnostics: A scoping review. *Journal of Dentistry*. 2019 Dec 1;91:103226.
46. Prados-Privado M, García Villalón J, Martínez-Martínez CH, Ivorra C, Prados-Frutos JC. Dental Caries Diagnosis and Detection Using Neural Networks: A Systematic Review. *Journal of Clinical Medicine*. 2020 Nov;9(11):3579.
47. Aminoshariae A, Kulild J, Nagendrababu V. Artificial Intelligence in Endodontics: Current Applications and Future Directions. *Journal of Endodontics*. 2021 Sep 1;47(9):1352–7.
48. Hartmann RC, Fensterseifer M, Peters OA, de Figueiredo JAP, Gomes MS, Rossi-Fedele G. Methods for measurement of root canal curvature: a systematic and critical review. *Int Endod J*. 2019 Feb;52(2):169–80.
49. Lee JH, Kim D hyung, Jeong SN, Choi SH. Diagnosis and prediction of periodontally compromised teeth using a deep learning-based convolutional neural network algorithm. *J Periodontal Implant Sci*. 2018 Apr 30;48(2):114–23.
50. Jung SK, Kim TW. New approach for the diagnosis of extractions with neural network machine learning. *American Journal of Orthodontics and Dentofacial Orthopedics*. 2016 Jan 1;149(1):127–33.
51. Sukegawa S, Yoshii K, Hara T, Yamashita K, Nakano K, Yamamoto N, et al. Deep Neural Networks for Dental Implant System Classification. *Biomolecules*. 2020 Jul;10(7):984.
52. Topol EJ. High-performance medicine: the convergence of human and artificial intelligence. *Nat Med*. 2019 Jan;25(1):44–56.
53. He J, Baxter SL, Xu J, Xu J, Zhou X, Zhang K. The practical implementation of artificial intelligence technologies in medicine. *Nat Med*. 2019 Jan;25(1):30–6.
54. Fourcade A, Khonsari RH. Deep learning in medical image analysis: A third eye for doctors. *Journal of Stomatology, Oral and Maxillofacial Surgery*. 2019 Sep 1;120(4):279–88.

BUI Romain - UTILISATION DE L'INTELLIGENCE ARTIFICIELLE AFIN DE RÉPLIQUER UN PROCESSUS DÉCISIONNEL : CAS D'ÉTUDE EN ODONTOLOGIE LÉGALE

Résumé :

L'utilisation de l'indice de maturité de la troisième molaire mandibulaire (I3M) afin de déterminer l'âge d'un patient est une pratique commune en odontologie légale. L'objectif de cette étude est de calculer automatiquement cet index en combinant un algorithme d'intelligence artificielle avec un algorithme d'analyse topologique. In fine, il s'agit de développer un outil d'aide à la décision.

La solution développée combinant une approche d'apprentissage profond avec une analyse topologique offre une précision de prédiction de 95% par rapport à un expert. Ainsi, ce cas d'étude illustre la faisabilité d'une solution automatisée capable de calculer l'I3M afin d'aider les experts ou d'améliorer les autres algorithmes estimant l'âge des patients.

Ce cas d'étude montre qu'une approche d'apprentissage profond en combinaison avec une analyse topologique a le potentiel d'offrir une solution d'aide à la décision dans le contexte d'une estimation d'âge d'un patient. Des études supplémentaires sur des bases de données plus larges et plus diversifiées sont néanmoins nécessaires afin de confirmer les performances obtenues et éventuellement envisager des applications cliniques.

Mots-clés : Intelligence Artificielle, Estimation de l'âge, Deep Learning, Machine Learning, Apprentissage profond, Réseau de neurones, analyse topologique.

Jury :

Président :

Monsieur le Professeur Jean-Christophe MAURIN

Assesseurs :

Monsieur le Professeur Maxime DUCRET

Monsieur le Docteur Thibault JACQUES GAGET

Monsieur le Docteur Raphaël RICHERT

Madame la Docteure Sophie VEYRE

Membre invité :

Madame la Docteure Cheraz TAFROUNT

Adresse de l'auteur :

BUI Romain
28 cours Vitton
69006 Lyon