



UNIVERSITÉ DE LILLE
UFR3S – DEPARTEMENT ODONTOLOGIE

[Année de soutenance : 2026]

N°:

THÈSE POUR LE
DIPLÔME D'ÉTAT DE DOCTEUR EN CHIRURGIE DENTAIRE

Présentée et soutenue publiquement le 22/05/2026

Par Louis LESPINASSE

IMPACT DE L'INTELLIGENCE ARTIFICIELLE SUR L'OPTIMISATION
DU WORKFLOW EN ORTHODONTIE

JURY

Président :

Professeur DELFOSSE Caroline

Assesseurs :

Docteur FOUMOU-MORETTI Nathalie

Docteur COUTEL Xavier

Docteur VANDOMME Jérôme



Président de l'Université :	Pr. R. BORDET
Directrice Générale des Services de l'Université :	A.V. CHIRIS FABRE
Doyen UFR3S :	Pr. D. LACROIX
Directrice des Services d'Appui UFR3S :	A. PACAUD
Vice doyen département facultaire UFR3S-Odontologie :	Pr. C. DELFOSSE
Responsable des Services :	L. KORAÏCHI
Responsable de la Scolarité :	V MAURIAUCOURT

PERSONNEL ENSEIGNANT DE LA FACULTE

PROFESSEURS DES UNIVERSITES

K. AGOSSA	Parodontologie
P. BOITELLE	Prothèses
T. COLARD	Fonction-Dysfonction, Imagerie, Biomatériaux
C. DELFOSSE	Vice doyen du département UFR3S-Odontologie Odontologie Pédiatrique Responsable du département d'Orthopédie dento-faciale
M. DEHURTEVENT	Co-responsable du département de Prothèses
B LOUVET	Chirurgie orale (Professeur des universités associé)
T. MARQUILLIER	Odontologie Pédiatrique
L ROBBERECHT	Responsable du département de Dentisterie Restauratrice Endodontie

MAITRES DE CONFERENCES DES UNIVERSITES

A. BLAIZOT	Prévention, Epidémiologie, Economie de la Santé, Odontologie Légale
F. BOSCHIN	Parodontologie
F CATHALA	Prévention, Epidémiologie, Economie de la Santé, Odontologie Légale (maître de conférences des Universités associé)
C. CATTEAU	Responsable du département de Prévention, Epidémiologie, Economie de la Santé, Odontologie Légale.
X. COUTEL	Biologie Orale
A. de BROUCKER	Fonction-Dysfonction, Imagerie, Biomatériaux
C. DENIS	Co-responsable du département de Prothèses
F. DESCAMP	Prothèses
M. DUBAR	Responsable du département de Parodontologie
A. GAMBIEZ	Dentisterie Restauratrice Endodontie
F. GRAUX	Prothèses
M. LINEZ	Dentisterie Restauratrice Endodontie
G. MAYER	Prothèses
L. NAWROCKI	Responsable du département de Chirurgie Orale Chef du Service d'Odontologie A. Caumartin - CHU Lille
C. OLEJNIK	Responsable du département de Biologie Orale
P OLEKSIK	Dentisterie Restauratrice Endodontie (maître de conférences des Universités associé)
H PERSOON	Dentisterie Restauratrice Endodontie (maître de conférences des Universités associé)
C PRUVOST	Prévention, Epidémiologie, Economie de la Santé, Odontologie Légale (maître de conférences des Universités associé)
P. ROCHER	Fonction-Dysfonction, Imagerie, Biomatériaux
M. SAVIGNAT	Responsable du département de Fonction Dysfonction, Imagerie, Biomatériaux
T. TRENTESAUX	Responsable du département d'Odontologie Pédiatrique
J. VANDOMME	Prothèses

R. WAKAM KOUAM Prothèses

PRATICIEN HOSPITALIER et UNIVERSITAIRE

M BEDEZ

Biologie Orale

Réglementation de présentation du mémoire de Thèse

Par délibération en date du 29 octobre 1998, le Conseil de la Faculté de Chirurgie Dentaire de l'Université de Lille a décidé que les opinions émises dans le contenu et les dédicaces des mémoires soutenus devant jury doivent être considérées comme propres à leurs auteurs, et qu'ainsi aucune approbation ni improbation ne leur est donnée.

TABLE DES ABRÉVIATIONS

AGI	:	Artificial General Intelligence
ANI	:	Artificial Narrow Intelligence
ANN	:	Artificial Neural Network
ASI	:	Artificial Super Intelligence
BNN	:	Bayesian Neural Network
BPNN	:	Backpropagation Neural Network
CAO/FAO	:	Conception Assistée par Ordinateur/ Fabrication Assistée par Ordinateur
CBCT	:	Cone Beam Computed Tomography
CFAO	:	Conception et Fabrication Assistées par Ordinateur
CNN	:	Convolutional Neural Network
CS1-CS6	:	Cervical Stage 1 à 6
CVM	:	Cervical Vertebral Maturation
DL	:	Deep Learning (apprentissage profond)
FNN	:	Feedforward Neural Network
HWM	:	Hand-Wrist Maturation
IA	:	Intelligence Artificielle
ML	:	Machine Learning
MTA	:	Multi-Treatment Plan Approach
OTM	:	Orthodontic Tooth Movements
ReLU	:	Rectified Linear Unit
RGPD	:	Règlement Général sur la Protection des Données
RIP	:	Réductions Interproximales
RNC	:	Réseaux Neuronaux Convolutionnels
RNA	:	Réseaux Neuronaux Artificiels
RNR	:	Réseaux Neuronaux Récurrents
SVM	:	Support Vector Machine
VADS	:	Voies Aéro-Digestives Supérieures
3D	:	3 Dimensions

TABLE DES MATIÈRES

INTRODUCTION.....	1
1 L'INTELLIGENCE ARTIFICIELLE (IA) DANS LE MONDE DE LA SANTE ET DE L'ORTHODONTIE.....	3
1.1 Introduction à l'intelligence artificielle.....	3
1.1.1 Définition.....	3
1.1.2 Fonctionnement et mécanismes de l'intelligence artificielle.....	4
1.2 Historique et évolution de l'intelligence artificielle : des origines à nos jours (figure 5)	18
1.3 Application de l'intelligence artificielle dans la santé	21
1.3.1 Imagerie médicale	21
1.3.2 Dermatologie	21
1.3.3 Neurologie	22
1.3.4 Ophtalmologie.....	22
1.3.5 Oncologie	22
1.3.6 Pharmacologie.....	22
1.4 L'intelligence artificielle en odontologie.....	23
1.4.1 Odontologie	23
1.4.2 Orthopédie dento-faciale	23
2 L'INTELLIGENCE ARTIFICIELLE AU SEIN DU WORKFLOW ORTHODONTIQUE	24
2.1 Concept du workflow.....	24
2.2 Première consultation	26
2.3 Diagnostic	27
2.3.1 Tri des photos	27
2.3.2 Besoin en traitement.....	28
2.3.3 Caractéristiques occlusales	29

2.3.4	Détection de points anatomiques.....	30
2.3.5	Évaluation de la maturation vertébrale cervicale (CVM)	32
2.3.6	Voies aéro-digestives supérieures (VADS)	34
2.3.7	Comptes rendus médicaux	34
2.3.8	Gestion de matériel.....	34
2.4	Planification du traitement.....	35
2.4.1	Planification générale	35
2.4.2	Besoin en extraction	37
2.4.3	Traitement ortho-chirurgical	37
2.5	Délivrance du traitement.....	39
2.5.1	Collage indirect digital.....	39
2.5.2	Aligneurs.....	40
2.5.3	Contention	42
2.6	Suivi du traitement.....	43
3	DEFIS, ENJEUX ET PERSPECTIVES DE L'INTÉGRATION DE L'IA EN ORTHODONTIE.....	46
3.1	Défis techniques et cliniques	46
3.1.1	Fiabilité des algorithmes et qualité des données	46
3.1.2	Limitations actuelles de l'IA dans la prise de décision clinique ...	47
3.1.3	Intégration dans les logiciels et équipements existants	48
3.2	Enjeux éthiques et juridiques	48
3.2.1	Confidentialité des données et cybersécurité	48
3.2.2	Responsabilité médico-légale en cas d'erreur	49
3.2.3	Equité d'accès et biais algorithmiques.....	49
3.3	Acceptabilité humaine et changements organisationnels	50
3.3.1	Résistance au changement chez les praticiens	50
3.3.2	Réactions des patients face à l'utilisation	51

3.3.3	Redéfinition des rôles dans l'équipe orthodontique	51
3.3.4	Enjeux philosophiques et idéologiques	52
3.4	Enjeux économiques et industriels	53
3.4.1	Coût d'implémentation de l'IA en cabinet	53
3.4.2	Monopole technologique et dépendance aux fournisseurs	54
3.4.3	Influence de l'industrie sur les protocoles cliniques	54
3.4.4	Impact environnemental	54
3.5	Perspectives d'évolution et pistes de solutions	55
3.5.1	Vers une IA éthique, transparente et co-construite	55
3.5.2	Formation des professionnels à l'IA	56
3.5.3	Vers une orthodontie « augmentée »	57
CONCLUSION		59
TABLES DES FIGURES		60
TABLES DES TABLEAUX		61
BIBLIOGRAPHIE		62
WEBOGRAPHIE		70

INTRODUCTION

L'orthodontie, discipline dédiée à la correction des anomalies dento-faciales, a connu de nombreuses évolutions technologiques au fil des décennies. Parmi elles, **l'intelligence artificielle (IA)** connaît actuellement un **intérêt croissant** [1]. Son émergence dans le domaine médical, plus particulièrement en orthodontie, ouvre de **nouvelles perspectives** qui révolutionnent la manière dont les traitements sont **planifiés, suivis et réalisés**. Le concept **d'optimisation du workflow orthodontique via l'IA** s'inscrit dans une démarche visant à améliorer **l'efficacité, la précision et la personnalisation** des soins orthodontiques tout en réduisant les coûts et les délais associés à chaque étape du traitement.

Traditionnellement, le processus orthodontique repose sur des **examens cliniques et des analyses manuelles**, qu'il s'agisse de **radiographies, de photos ou de modèles 3D**. Toutefois, ces pratiques, bien que fondées sur des principes éprouvés, sont parfois **lentes et sujettes à des erreurs humaines**. L'introduction de l'IA dans ce domaine permet de surmonter certaines de ces limitations en automatisant des tâches complexes et en fournissant des **outils d'aide à la décision** plus performants. En utilisant des algorithmes **d'apprentissage automatique** et de **traitement d'image**, l'IA offre des possibilités de diagnostics plus rapides et plus précis, ainsi qu'une **personnalisation accrue des traitements**.

Ainsi, cette thèse se propose d'explorer les différents moyens par lesquels l'IA peut optimiser le workflow orthodontique. L'objectif est de démontrer comment ces technologies peuvent améliorer non seulement la **qualité des soins**, mais aussi **l'organisation du travail** au sein des cabinets orthodontiques. À travers cette étude, nous analyserons les **applications actuelles et futures de l'IA** dans la pratique orthodontique, en mettant l'accent sur **l'optimisation des étapes de diagnostic, de planification et de suivi du traitement**,

tout en prenant en compte les **défis techniques, éthiques et humains** associés à cette transformation numérique.

1 L'INTELLIGENCE ARTIFICIELLE (IA) DANS LE MONDE DE LA SANTE ET DE L'ORTHODONTIE

1.1 Introduction à l'intelligence artificielle

1.1.1 Définition

1.1.1.1 L'intelligence artificielle

L'intelligence artificielle (IA) est communément définie comme « *une capacité d'un système à interpréter correctement des données externes, d'apprendre de ces dernières, et d'utiliser ces apprentissages pour réaliser certains objectifs avec une adaptation flexible* » [2]. C'est un **sous-domaine de l'informatique** qui fait référence à la capacité d'une machine à **imiter les fonctions cognitives** de l'intelligence humaine [3].

Selon le groupe d'experts sur l'IA de l'OCDE (Organisation de Coopération et Développement Economiques), « *un système d'intelligence artificielle (ou système d'IA) est un système automatisé qui, pour un ensemble donné d'objectifs définis par l'homme, est en mesure d'établir des prévisions, de formuler des recommandations, ou de prendre des décisions influant sur des environnements réels ou virtuels* » [4].

Ainsi, le monde de l'IA peut être divisé en 3 catégories distinctes :

- **l'intelligence artificielle restreinte (ANI : Artificial Narrow Intelligence)** ;
- **l'intelligence artificielle générale (AGI : Artificial General Intelligence)** ;
- **la super intelligence artificielle (ASI : Artificial Super Intelligence)[5]**.

1.1.1.2 L'intelligence artificielle restreinte

L'intelligence artificielle restreinte (ANI : Artificial Narrow Intelligence), aussi appelée **l'IA faible** ou **étroite**, se concentre principalement sur des **tâches spécifiques**, avec un champ de capacités restreintes. Ceci étant dit, ces systèmes fonctionnent donc uniquement selon les **limites prédéfinies** pour lesquelles ils ont été programmés. On peut citer par exemple des **assistants vocaux** comme **Siri® (Apple)** ou **Alexa® (Amazon)**, ils peuvent répondre à des questions simples, jouer de la musique, mais ne peuvent accomplir d'autres

tâches en dehors de leur programmation. Cette IA n'est donc **pas consciente, sensible** ou **motivée par des émotions** comme les humains [6]. Il s'agit de l'état de la majorité des systèmes actuels.

1.1.1.3 L'intelligence artificielle générale

L'**intelligence artificielle générale** (AGI : *Artificial General Intelligence*) représente la capacité d'une machine à réaliser **les mêmes tâches intellectuelles** qu'un être humain. Elle est définie comme « *une machine ayant la possibilité de comprendre ou apprendre toutes sortes de tâches intellectuelles qu'un humain pourrait faire comme synthétiser pléthore d'apprentissages cognitifs, hiérarchiser, mémoriser, résoudre, anticiper des problèmes complexes, de développer des concepts et de faire preuve de créativité* » [4]. Bien que des concepts et recherches existent sur l'IA générale, aucun système aujourd'hui ne possède encore cette **capacité de polyvalence** [7].

1.1.1.4 La super intelligence artificielle

La **super intelligence artificielle** (ASI : *Artificial Super Intelligence*) est purement **théorique**, voire **hypothétique**, et relève actuellement de la **science-fiction**. Ce serait donc une technologie qui pourrait **égaler** voire **dépasser** l'esprit humain dans tous les domaines **possibles** et **imaginables**. Non seulement ces technologies IA seraient capables d'exécuter des tâches mais aussi de ressentir des **émotions**, voire **nouer des relations sociales** similaires à celles d'êtres humains. Fondamentalement, la super intelligence artificielle serait également capable **d'accroître son intelligence de manière exponentielle** au fil du temps. Cette technologie reste **purement spéculative**, et est loin de voir le jour [8].

1.1.2 Fonctionnement et mécanismes de l'intelligence artificielle

Afin de mieux comprendre les apports potentiels de l'intelligence artificielle dans le domaine de la santé et de l'orthodontie, il est essentiel de s'intéresser à ses mécanismes fondamentaux. Cette section présente les **principes de fonctionnement de l'IA**, en mettant l'accent sur les concepts clés tels que le « *machine learning* » (apprentissage automatique), le « *deep learning* » (apprentissage profond), et les algorithmes qui en constituent la base (figure 1).




Figure 1: intelligence artificielle, machine learning et deep learning [4]

1.1.2.1 Machine learning

Le *machine learning* (ML), ou **apprentissage automatique** conceptualisé par **Arthur Samuel en 1952**, est une branche de l'IA dont sont équipés les ordinateurs, leur octroyant la capacité d'analyser les données de manière proactive. Si l'IA était une personne, le *machine learning* serait le cerveau de celle-ci [9]. Il s'appuie sur un **algorithme** qui adapte lui-même le système à partir des retours faits par l'humain qui lui indique ses erreurs selon des **données structurées** (catégorisées ou labelisées par un observateur) [4]. Si précédemment nous avons classé l'IA comme « restreinte » ou « générale » selon sa capacité de résolution de problèmes, d'une perspective dite « algorithmique », il faut distinguer le ML de « l'intelligence artificielle symbolique ». La base de l'**IA symbolique** est de concevoir des algorithmes dont le fonctionnement est compréhensible par l'humain. Elle repose sur des systèmes experts, organisant les connaissances sous forme de règles explicites. Cette approche reste utile lorsque les problèmes sont simples, bien définis, ou lorsqu'une explication claire est nécessaire, mais elle montre ses limites dès que les situations deviennent trop complexes ou nécessitent une grande puissance de calcul. C'est exactement le cas dans le secteur de la santé, où les problèmes

sont souvent **complexes**, mal compris et impliquent de multiples variables explicatives, ce qui rend la construction d'un modèle basé sur des règles extrêmement **difficile**, voire totalement **impossible** [10]. Véritable **colonne vertébrale** de l'IA, la naissance du ML résulte de la confluence de plusieurs disciplines, dont les **statistiques**, les **théories probabilistes**, les **théories d'approximation** et des **algorithmes complexes**. En dentisterie et dans la sphère médicale, c'est l'application de l'IA la **plus communément** employée [11]. Les relations entre les variables intrinsèques peuvent être déduites sur la base d'expériences d'apprentissages, *comme un détective reconstituerait une enquête à partir d'éléments connus. Toujours dans cet exemple, le niveau d'un détective repose sur l'accumulation des connaissances de base ainsi que sur celles acquises avec l'expérience.* Ce dernier sera alors apte à participer à des enquêtes seulement après avoir reçu un **entraînement adapté** et passer des **examens**. De la même manière, les algorithmes de ML reçoivent beaucoup de données avec des **réponses connues**, et la formule d'opération résultante peut être construite de manière à **résoudre des problèmes spécifiques**. Ce processus est appelé « **phase d'apprentissage** ». Le ML agit de façon automatique et souvent opaque, contrairement aux fonctions linéaires classiques dont le fonctionnement reste directement observable. Après la phase **d'entraînement**, l'algorithme est testé avec des ensembles de données externes pendant la phase dite de « **validation** », les résultats découlant de cette phase permettant d'objectiver **l'efficacité et la précision** du modèle en question.

Les algorithmes les **plus courants** de ML sont :

- les **réseaux neuronaux artificiels (RNA)** (*ANN : Artificial Neural Network*) ;
- les **arbres de décision** (*DT : decision tree*) ;
- les **bayésiens naïfs** (*Naive Bayesian Classifier*) ;
- les **machines à vecteur de support** (*SVM : support vector machine*) ;
- les **random forests** ;
- les **algorithmes d'Expectation-Maximization**

En se basant sur les diverses techniques d'apprentissage, le ML peut être divisé en **4** catégories (figure 2) :

1. **supervisé ;**
2. **non supervisé ;**
3. **semi-supervisé ;**
4. **l'apprentissage renforcé ;**




Figure 2: classification du machine learning [12]

1.1.2.1.1 Machine learning supervisé

Le **ML supervisé** consiste à utiliser un jeu de données dont les valeurs finales sont **connues** (des **données étiquetées**), et la précision de ces modèles est progressivement optimisée via un « *feedback* » (**retour d'informations**) lié à l'écart entre la prédiction et la vérité observée de ces données étiquetées. Par exemple, en gastro-entérologie, pour construire un modèle servant à classer le **cancer gastrique** par rapport à des **tissus sains**, les résultats des diagnostics contenus dans les ensembles de données internes **doivent être étiquetés**. Le ML supervisé a pour objectif de résoudre 2 tâches principales :

- 1) **la classification**, comme l'analyse rapide de radios thoraciques ;

2) la **régression**, comme la prédiction du risque de récurrence des patients atteints de cancer en fonction de données cliniques. Ces 2 tâches reposent sur l'exploration de règles potentielles entre les variables. Parmi les algorithmes de ML les plus couramment employés, on retrouve :

- la **régression logistique** (*LR : logistic regression*) ;
- les **réseaux de neurones à rétropropagation** (*BPNNs : backpropagation neural network*) ;
- l'algorithme du « **k-voisin le plus proche** » (*FKNN : fuzzy-k nearest neighbour*).

1.1.2.1.2 Machine learning non supervisé

Le **ML non supervisé** fait référence à un ensemble de données d'apprentissages **non** étiquetées. Contrairement à l'apprentissage supervisé, cette approche est utilisée pour analyser des **données non organisées** ou **non structurées**, afin d'en **extraire des motifs cachés** ou des **structures sous-jacentes**. Le **clustering** (*regroupement*) est l'illustration de ce ML non supervisé et peut aider à découvrir des modèles et des groupes innés basés sur des données d'exploration. Prenons l'exemple du **séquençage de nouvelle génération**, où des centaines de milliers de niveaux d'expression des gènes sont répertoriés. Ces gènes seront regroupés en fonction des **similitudes d'expression** et ce processus **ne nécessite pas** de données préétiquetées. De plus, le ML non supervisé peut être utilisé pour grouper et étiqueter des jeux de données pour de futurs algorithmes supervisés [9].

1.1.2.1.3 Machine learning semi-supervisé

Le **machine learning semi-supervisé** agit comme un **assistant** dans la reconnaissance de schémas complexes. Il s'appuie à la fois sur des méthodes **supervisées** et non **supervisées**, ce qui permet d'exploiter à la fois des données **étiquetées** et **non étiquetées**, en combinant les avantages des deux approches. La **composante non supervisée** permet donc de **réduire** le besoin en étiquetage manuel, souvent coûteux en temps et en ressources humaines. De son côté, la **composante supervisée** garantit une certaine **précision** et une **cohérence** des prédictions dans les résultats obtenus. En orthodontie, cela

pourrait s'avérer utile pour l'analyse automatique de grandes bases de téléradiographies. Parmi les méthodes couramment utilisées en apprentissage semi-supervisé, on retrouve :

- le **self-training** (*apprentissage autonome*)
- le **transductive learning** (*apprentissage transductif*)
- les **SVM transductifs** (*transductive support vector machine*) [9].

1.1.2.1.4 Apprentissage renforcé

L'**apprentissage renforcé** ressemble au **processus psychologique de l'acquisition des comportements**, à la manière d'un **dressage animalier**. Aucune donnée prédéfinie n'est requise. Les algorithmes sont petit à petit alimentés par des signaux dans chaque couche et reçoivent des « **récompenses** » ou des « **sanctions** » directement après évaluation des erreurs entre les **valeurs vraies** et les **valeurs de sortie**. L'efficacité des algorithmes peut être **ajustée** durant l'apprentissage, et la règle d'or de ce type d'apprentissage est de **maximiser les récompenses** et **minimiser les sanctions**. La manière d'obtenir un **équilibre optimal** et une **allocation fiable** reste le plus grand challenge pour les chercheurs. De nos jours, les ordinateurs sont capables de résoudre de manière indépendante des problèmes complexes basés sur l'apprentissage renforcé, comme le robot **AlphaGo** [9].

1.1.2.2 Deep learning

Le *deep learning* (ou « **apprentissage profond** ») est une **forme spécifique et plus évoluée** du machine learning car il utilise des **données non structurées**. Contrairement au machine learning qui utilise un algorithme « *a priori* », dans le deep learning, *ce sont les données qui guident le fonctionnement de l'algorithme*. C'est un système **d'apprentissage autonome** qui, à partir des **données discriminantes analysées et des erreurs observées**, ajuste en permanence son **modèle mathématique**. S'inspirant du cerveau humain, le deep learning repose sur un « **réseau de neurones** » dit **artificiel**, composé de plusieurs couches [4].

1.1.2.2.1 Les réseaux neuronaux artificiels

Le concept des **réseaux neuronaux artificiels** (RNA) a vu le jour pour la première fois en 1943. Depuis, leur développement est en constante évolution. En 1980, leurs progrès fulgurants ont contribué à une **révolution moderne**. Le design des RNA s'appuie sur celui des **réseaux neuronaux du cerveau humain**. Un RNA est (premièrement) composé de plusieurs **neurones** au travers duquel passe le flux de données (donc le signal) pour être traité. Les neurones des différentes couches ont leurs propres **tâches** à résoudre, ce qui peut être comparé à une **chaîne de production**. La décomposition de ces tâches pour l'analyse des données permet la capacité de trouver **la solution optimale le plus rapidement possible** (figure 3).




Figure 3: schéma de divers réseaux neuronaux ; chronologie de développement [9]

La structure d'un RNA peut être divisée en **3 parties** (figure 4) :

- 1) Les couches **d'entrée** (*input layers*). Celles-ci sont responsables de recevoir les signaux de certains ensembles de données et servent « d'yeux » au réseau voyant l'environnement externe.

- 2) Les couches **cachées** (*hidden layers*). Elles sont prépondérantes et dépendent des associations entre les données d'entrée et de sortie. Les données brutes provenant des couches d'entrées seront traitées par les neurones. Le nombre de couches cachées est toujours supérieur ou égal à 1. Les missions des RNA peuvent être subtilement décomposées et réparties sur plusieurs couches. Les modèles multicouches permettent l'efficacité du traitement des données. Les neurones dans ces couches ont plusieurs connexions en série basées sur des séquences prédéfinies plutôt que des connexions dite « parallèles ».
- 3) Les couches de **sortie** (*output layers*) prennent la décision finale et émettent le résultat.




Figure 4: illustration de réseau neuronal d'un cerveau humain [13]

Les termes communs décrivant le mieux les formes ainsi que les capacités des réseaux neuronaux sont listées ci-dessous (tableau 1):

- la **profondeur** (*depth*) désigne l'efficacité du réseau de par son nombre de couches. Un RNA simple est monocouche, avec une couche d'entrée, une seule couche cachée et une couche de sortie. Ce type est limité à des problèmes binaires basés sur un seul facteur, il a ainsi une capacité très limitée. Augmenter la profondeur du RNA peut drastiquement augmenter leur capacité à ajuster des caractéristiques complexes. Certains chercheurs commencent à développer des RNA multicouches. En 2016, une étude a reporté la création d'un RNA de plus de **1000 couches** [14]. En contrepartie, un trop grand nombre de couches peut entraîner une instabilité de tout le système et une perte des capacités d'apprentissage.

Chaque couche a une mission bien définie si le volume de l'ensemble des données ainsi que la profondeur sont déterminés ;

- l'**ampleur** (*width*) comparable aux nombres de travailleurs dans une chaîne de production. Des travailleurs adéquats amélioreront la qualité des traitements des tâches, là où une redondance de réalisation de ces dernières pourraient conduire à des effets négatifs. Un RNA de large ampleur augmente l'accès à différentes composantes des données, là où une ampleur plus réduite conduit à une efficacité moindre pour extraire les données ainsi qu'une surchauffe du système ;
- la **taille** (*size*) décrit la résultante de la profondeur et de l'ampleur, c'est un indicateur important quand il s'agit d'évaluer la capacité d'un RNA ;
- la **structure** représente l'agencement des couches et des neurones ;
- la **capacité** quant à elle, se définit comme ce que le modèle a appris de la réalité grâce aux données et comment il les utilise pour accomplir des tâches.

Tableau 1 :termes décrivant les RNA [9]

Term of ANN	Specific meaning
Size	Number of neurons in the whole model
Width	Number of neurons in the one layer
Depth	Number of layers
Framework	Arrangement methods of layers and neurons
Capability	The reflection contents of reality by the specific model

De plus, les RNA peuvent être divisés en 2 grandes catégories basées sur la **direction du flux des divers signaux** entre les couches cachées (tableau 2).

- **Réseaux à propagation avant** (*feedforward neural network, FNN*). Le flux de données est unidirectionnel, des couches d'entrée vers les couches de sortie, sans rétroaction ni connexion entre neurones de la même couche. En termes de système d'apprentissage, le FNN est adapté pour la **reprogrammation** et peut résoudre des problèmes non-linéaires comme par exemple la relation entre des valeurs dentaires (overjet,

overbite) ; ou crânio-faciales et le besoin de traitement. C'est un problème non linéaire car les relations entre ces valeurs et les décisions sont complexes et interdépendantes. Un petit changement d'angle mandibulaire peut être anodin pour un patient, mais déterminant pour un autre, en fonction d'autres paramètres (croissance, occlusion, etc.).

- **Réseaux à rétroaction** (*feedback neural network*). Dans ces réseaux, un neurone peut transmettre ses données de sortie aux autres neurones dans la même couche ou des couches supérieures. Les algorithmes seront simultanément ajustés par les signaux émis par les neurones, basés sur un ensemble de données préalablement acquis. Le calibrage répété contribue à l'excellente capacité et précision du réseau. Un réseau neuronal à rétroaction est typiquement utilisé pour **l'analyse d'image**, **diagnostic** et la **prédiction des résultats** comme prédire l'évolution future d'un paramètre céphalométrique comme l'ANB avec des données collectées à différents moments pour estimer la probabilité d'une malocclusion à venir, le besoin d'orthopédie...

Category	Feedforward neural network	Feedback neural network
Signal direction	Unidirectional	Unidirectional/bidirectional
Operation time	Short	Long
Feedback by output signal	No	Yes
Structural complexity	Simple	Complicated
Memory time	Short-term or none	Long-term
Applied ranges in medicine	Wide	Limited
Application	Perceptron network, back propagation network, radial basis function network	Recurrent neural network, Hopfield network, Boltzmann machine

Tableau 2 : comparaison entre réseau neuronal "avant" et "arrière" [9]

Les principes du traitement des données dans les neurones peuvent être définis comme des **fonctions d'activation**, et ressemblent aux principes du « tout-ou-rien » des neurones du cerveau. Ces fonctions sont de 3 types :

- **ReLU** (Rectified Linear Unit) ;
- **Sigmoïde** ;
- **Tanh** (Fonction tangente hyperbolique).

Les fonctions linéaires sont exclues des fonctions d'activation car plusieurs superpositions de fonctions linéaires peuvent être regroupées en une seule fonction. Plusieurs études ont démontré que la capacité de cartographie non-linéaire des RNA compense justement les limites des analyses linéaires. De plus, chaque neurone peut transmettre simultanément son signal à plusieurs neurones de la couche suivante (un vers plusieurs) ce qui garantit l'efficacité d'apprentissage du réseau. Une couche de neurone peut en même temps, envoyer des signaux à plus d'un neurone. Aussi, il est important de noter que le flux de signaux n'est pas réparti également à chaque neurone dans la prochaine couche. Cette inégalité fait en sorte que le réseau puisse s'adapter à l'environnement externe. Avant le calcul des fonctions d'activation, les données seront ajustées par des « **facteurs de poids** », chacun d'entre eux ayant une relation spécifique avec un neurone en particulier. Les facteurs de poids servent de régulateurs pour le flux de données. De plus grands facteurs de poids ont une plus grande influence sur les résultats de sortie. À l'inverse, attribuer un facteur de poids égal à 0 peut annuler les fonctions du neurone correspondant. Il existe de nombreuses catégories de réseaux neuronaux artificiels (RNA) qui sont utilisés en médecine classique et clinique. Chaque réseau contient des algorithmes qui présentent chacun leurs avantages et inconvénients par rapport aux autres. La compréhension de ces derniers permet de les assigner à la situation adéquate. Ci-après, une brève introduction des méthodes des RNA les plus communément utilisés.

1.1.2.2.1.1 Les réseaux neuronaux convolutionnels

Les **réseaux neuronaux convolutionnels (RNC)** (*CNN : Convolutional Neural Networks*) sont les réseaux neuronaux **les plus populaires** de nos jours en raison de leurs **couches convolutionnelles** et de leurs couches de « *pooling* » (**regroupement**). La **convolution** et le **regroupement** sont des notions complexes en informatique. Brièvement, les **couches convolutionnelles** peuvent **extraire des caractéristiques** depuis une base de données parce que les neurones de cette couche sont responsables de **collecter** et **d'analyser** l'information présente dans des zones spécifiques. Ces neurones peuvent être comparés à celles du **cortex visuel** par exemple qui filtre les informations de l'environnement externe. Les données sont ensuite envoyées aux **couches de**

regroupement après convolution, où les caractéristiques des données sont **filtrées** et **compressées**. Les couches de regroupement permettent de **réduire le bruit de fond**, *au prix d'une perte partielle de données*. Après, les données seront traitées dans les **réseaux neuronaux classiques** [9]. Ces couches en question permettent donc à tous les neurones d'être interconnectés. Ce type de réseaux est très performant pour le traitement d'image [5].

Prenons l'exemple d'une photo prise avec un smartphone :

- la **première couche** de neurones identifiera la **luminosité** des pixels ;
- la **seconde** se chargera d'étudier les **liens entre ces luminosités** ;
- la **troisième** déterminera les **contours** ;
- la **quatrième** rendra possible l'identification des structures spécifiques (les yeux, les oreilles, etc.) ;
- puis **d'autres algorithmes** qui nous permettront de déterminer si un animal est présent sur l'image.

Le principe général des RNC, dans cet exemple, est que **chaque neurone de chaque couche intermédiaire** est exposé seulement à une **parcelle particulière** : une petite partie de l'image. Ces couches entremêlées serviront à traiter **l'entièreté de l'image** [5].

Le nombre de couches des RNC est relativement **variable**. La **précision** et la **performance** sont toutefois **restreintes** dans les réseaux dont les **structures** sont **superficielles**. La majorité des RNC reste des réseaux dits « **profonds** ». Ils sont appliqués dans de nombreux domaines tels que la **classification d'images**, la **reconnaissance d'éléments** et la **compréhension du langage naturel**. Ces applications nécessitent un apprentissage provenant de **beaucoup de données** ainsi que de la **capacité à généraliser des résultats**. Par ailleurs, la reconnaissance précise d'images médicales est la principale difficulté des RNC, qui peut être contournée en réalisant des RNC « **faits mains** » ou **non supervisés**.

1.1.2.2.1.2 Les « back-propagation neural network »

Le **réseau neuronal à rétropropagation** (*Backpropagation Neural Network*, BPNN) est un type spécifique de **réseau de neurones à propagation avant**

(*feedforward Neural Network*, FNN). Il est composé de plusieurs couches (entrée, cachées, sortie) dans lesquelles les données circulent de manière unidirectionnelle, **sans rétroaction interne** entre les neurones. L'apprentissage dans un BPNN se fait en deux étapes principales : la **propagation avant**, où les données sont transmises des couches d'entrée jusqu'à la sortie ; puis la **rétropropagation de l'erreur**, qui n'est pas une rétroaction du réseau, mais un **algorithme d'apprentissage supervisé**. Cette rétropropagation ajuste les **poids synaptiques** en calculant l'erreur entre la **sortie produite par le modèle** et la **sortie attendue**, puis en redistribuant cette erreur en sens inverse à travers les couches du réseau, afin de corriger les poids de manière optimale. Grâce à sa capacité à apprendre des **relations complexes entre les variables**, sans nécessiter une modélisation mathématique explicite, **le BPNN est largement utilisé en médecine**, notamment pour le **diagnostic**, la **reconnaissance de motifs** et la **prédiction de résultats cliniques**, y compris en orthodontie.

1.1.2.2.1.3 Les réseaux neuronaux bayésiens

La phase d'entraînement d'un réseau neuronal artificiel (ANN) nécessite une certaine quantité de données, et de petits ensembles de données d'entraînement ont tendance à nuire à l'efficacité et à la praticabilité de la plupart des ANN. Cependant, une taille d'échantillon suffisante n'est pas toujours disponible. **Les réseaux neuronaux bayésiens (BNN)** (*Bayesian Neural Network*) ont été conçus pour de telles situations. Les BNN sont basés sur des facteurs de poids qui décrivent des **plages probabilistes** soumises à une **distribution de Gauss** au lieu d'être des constantes. Les paramètres optimisés par **rétropropagation** sont les **moyennes** et les **variances** des facteurs de poids, et peuvent augmenter la confiance de chaque élément de données, renforçant ainsi la robustesse de l'ensemble de données. Récemment, les BNN ont montré un **grand potentiel** dans l'analyse des caractéristiques des images et la construction de modèles de maladies.

1.1.2.2.1.4 Les réseaux de neurones récurrents

Dans les réseaux neuronaux classiques, les données d'entrée sont généralement considérées comme **indépendantes et identiquement distribuées**, ce qui signifie que **l'ordre ou la séquence des données n'a pas d'influence** sur le

traitement ou la sortie. Cependant, dans certains contextes, notamment en imagerie médicale, cette hypothèse ne tient pas. Par exemple, une série d'images issues d'un scanner (CT) représente différentes coupes successives d'une même région anatomique. **L'ordre des images est essentiel** pour reconstituer avec précision la forme, la taille ou l'évolution d'une lésion. Traiter ces images comme des données indépendantes reviendrait à ignorer la structure temporelle ou spatiale sous-jacente, et donc à perdre une information précieuse. Les **réseaux neuronaux récurrents (RNR)** ont été conçus pour surmonter cette limitation. Contrairement aux réseaux classiques, les RNR intègrent une **rétroaction interne** : la sortie d'une couche cachée à un instant donné dépend non seulement des entrées actuelles, mais aussi de l'état précédent du réseau. En d'autres termes, le réseau dispose d'une **mémoire de court terme**, ce qui lui permet de modéliser des **dépendances séquentielles** dans les données. Cette architecture est particulièrement adaptée à l'analyse de séries temporelles, de séquences d'images, ou de données longitudinales, et a donc trouvé de nombreuses applications en médecine et en orthodontie [9].

1.2 Historique et évolution de l'intelligence artificielle : des origines à nos jours (figure 5)


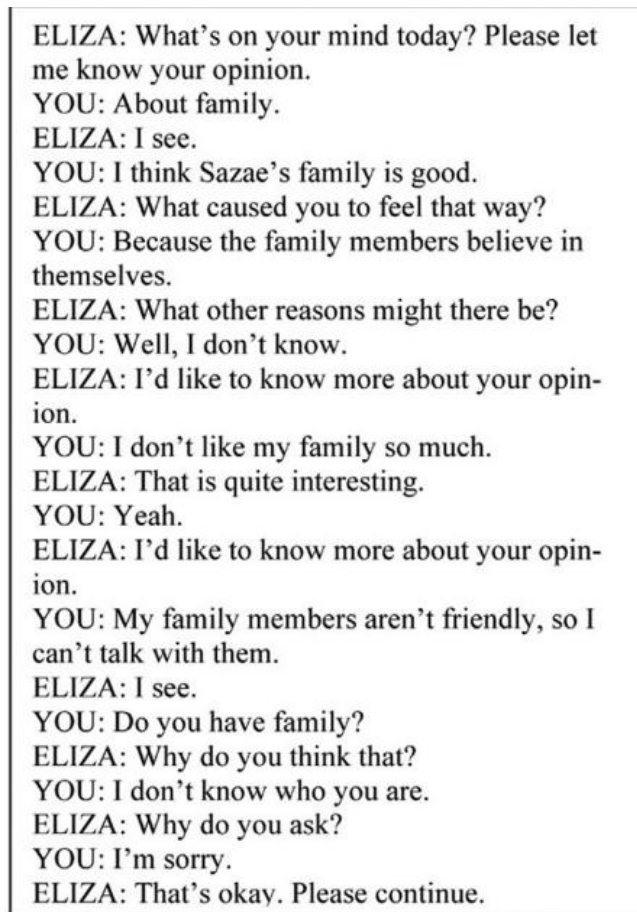


Figure 5: histoire de l'intelligence artificielle [15]

L'**intelligence artificielle** trouve ses origines dans les travaux fondateurs d'**Alan Turing**, notamment dans son article de 1950 "*Computing Machinery and Intelligence*" [16]. Il y introduit le célèbre **test de Turing**, aussi appelé *jeu de l'imitation*, dans lequel une machine est considérée comme « pensante » si un humain **ne parvient pas** à la distinguer d'un autre humain au cours d'un échange de questions-réponses (figure 6).



ELIZA: What's on your mind today? Please let me know your opinion.
YOU: About family.
ELIZA: I see.
YOU: I think Sazae's family is good.
ELIZA: What caused you to feel that way?
YOU: Because the family members believe in themselves.
ELIZA: What other reasons might there be?
YOU: Well, I don't know.
ELIZA: I'd like to know more about your opinion.
YOU: I don't like my family so much.
ELIZA: That is quite interesting.
YOU: Yeah.
ELIZA: I'd like to know more about your opinion.
YOU: My family members aren't friendly, so I can't talk with them.
ELIZA: I see.
YOU: Do you have family?
ELIZA: Why do you think that?
YOU: I don't know who you are.
ELIZA: Why do you ask?
YOU: I'm sorry.
ELIZA: That's okay. Please continue.

Figure 6: exemple d'un test de Turing [17]

Le terme "**intelligence artificielle**" (IA) a été formellement proposé en **1956** par **John McCarthy**, lors de la **conférence de Dartmouth**, événement considéré comme l'acte de naissance officiel du domaine [11]. Néanmoins, les travaux précurseurs remontent à **1943** avec **McCulloch** et **Pitts**, qui proposèrent un modèle mathématique de neurone artificiel.

Après 20 ans d'engouement (**1950-1970**), les **limites techniques** des ordinateurs et des algorithmes entraînent un ralentissement brutal du financement. Ce premier "**hiver de l'IA**" est marqué, notamment au **Royaume-**

Uni, par le **rapport Lighthill (1973)** qui critiquait sévèrement les résultats obtenus. Aux **États-Unis**, les **amendements Mansfield (1969 et 1973)** restreignaient les financements militaires aux seules recherches à applications directes, excluant ainsi l'IA jugée peu utile à court terme.

Au début des **années 1980**, l'intérêt renaît avec l'apparition des **systèmes experts**, promus notamment par le Japon à travers le programme « *Fifth Generation* ». Cette période voit également les bases du **machine learning** moderne se consolider, notamment avec la généralisation de **l'algorithme de rétropropagation** pour l'entraînement des réseaux de neurones. Malgré cet essor, les attentes économiques sont largement déçues, menant à un **second hiver** de l'IA à la fin des années **1980**.

À partir des années **1990**, **l'amélioration des capacités de calcul** permet à l'IA de réaliser certains de ses objectifs historiques. Un tournant symbolique est atteint en **1996**, lorsque l'ordinateur **Deep Blue**, développé par **IBM**, bat le champion du monde d'échecs **Garry Kasparov** (figure 7).



Figure 7: Garry Kasparov vs Deep Blue, 10 février 1996 [18]

Dès les années **2000**, les applications de l'IA s'étendent à des domaines variés tels que la **reconnaissance vocale**, la **robotique**, ou encore la **médecine**. Le véritable changement de paradigme a lieu au début des **années 2010**, avec l'essor du **deep learning**, facilité par deux facteurs clés : la disponibilité de

masses de données (**big data**) et la puissance croissante des **processeurs graphiques**.

Des architectures telles que les **réseaux convolutifs (RNC)** ou les **réseaux récurrents (RNR)**, développées théoriquement dans la précédente partie, trouvent alors une application massive. En **2017**, une nouvelle étape est franchie avec **AlphaGo**, une IA développée par **DeepMind**, qui bat le champion du monde de **Go**, un jeu considéré comme bien plus complexe que les échecs [2].

1.3 Application de l'intelligence artificielle dans la santé

Dans le domaine de la **santé**, l'IA a permis des avancées considérables, notamment en matière de **diagnostic médical**, de **prédiction des maladies**, de **gestion des soins** et même de **personnalisation des traitements**. Les systèmes d'IA analysent des masses de données médicales (imagerie, antécédents médicaux...) plus connues sous le nom de « big data ». Le concept de ces **masses de données** a gagné en popularité dans le domaine de la santé sur ces dernières années [19]. **L'augmentation des pools de données** ainsi que leur **complexité**, associées à la **puissance des super-ordinateurs** ont permis l'exploitation de ces dernières afin d'optimiser la santé en général. Voici donc plusieurs exemples non exhaustifs de l'application de l'intelligence artificielle dans le domaine de la santé :

1.3.1 Imagerie médicale

Dans une revue de littérature exhaustive, Saba *et al.* [13] ont analysé 150 articles relevant de l'apport du *deep learning* dans l'imagerie médicale. On y retrouve des modèles de DL servant d'outil diagnostic pour des pathologies hépatiques telles que la stéatose hépatique métabolique, de cancer de la prostate ou encore des RNC dans la reconnaissance des tissus récupérables après lésions causées par un accident vasculaire cérébral ischémique aigu.

1.3.2 Dermatologie

Esteva *et al.* [20] ont développé un réseau neuronal convolutionnel afin de mettre en évidence des cancers de la peau. Il a été entraîné à distinguer diverses maladies en se basant sur un large pool d'images (129 450 couvrant 2 032

maladies différentes). Ce dernier a été testé sur 2 cas critiques à classification binaire : carcinome kératinocytaire vs kératoses bénignes et mélanome malin vs nævi bénins. Dans les 2 cas, le RNC a obtenu une performance comparable à celle de 21 dermatologues certifiés (sur des images cliniquement validées par biopsie).

1.3.3 Neurologie

Lee *et al.* [21] ont étudié des cas d'AVC dans lesquels l'intelligence artificielle a été utilisée afin d'établir des diagnostics précis ainsi que des pronostics tels que les thrombolyse ou la prédiction des séquelles neurologiques.

1.3.4 Ophtalmologie

En ophtalmologie, des systèmes basés sur le *machine learning* ont été employés afin de diagnostiquer des glaucomes pouvant aboutir dans le pire des cas à une perte irréversible de la vue, des dégénérescences maculaires liées à l'âge, des rétinopathies diabétiques etc. Ces applications ont été détaillées dans la revue de littérature publiée par Hogarty *et al.* [22].

1.3.5 Oncologie

Bibault *et al.* [23], dans leur revue de littérature, ont développé les différentes technologies d'IA appliquée à la radiothérapie, couvrant la collecte et la gestion des données cliniques, thérapeutiques, en termes d'imagerie et de biologie moléculaire en radiothérapie, pour construire un modèle prédictif efficace mais aussi de système d'aide de prise à la décision.

1.3.6 Pharmacologie

Singh *et al.* [12] soulignent aussi l'intérêt de l'intelligence artificielle, au niveau de la recherche pharmacologique. L'incrémentation de cette dernière dans les méthodes de développement des médicaments a permis de surmonter les principales difficultés (temps, coût, efficacité) rencontrées jusqu'à présent. De plus, l'IA a joué un rôle crucial dans le criblage des médicaments prédisant la toxicité, la bio activité, les propriétés physico-chimiques...

1.4 L'intelligence artificielle en odontologie

1.4.1 Odontologie

En dentisterie, l'IA commence à démontrer son potentiel. Par exemple, un RNC utilisé par You *et al.* [24] en vue de détecter la plaque dentaire pour en améliorer son contrôle. Le modèle IA a montré des résultats cliniquement comparables à ceux d'un praticien spécialisé en odontologie pédiatrique. Par ailleurs, Poedjiastoeti *et al.* [25] ont étudié l'application d'un RNC, en faisant diagnostiquer sur des orthopantomogrammes des lésions orales, notamment des améloblastomes et des tumeurs kératokystiques odontogènes. 83% des diagnostics furent précis et l'efficacité de ce réseau par rapport aux 5 chirurgiens oraux et maxillo-faciaux n'était pas statistiquement différents, en témoignent les aires sous courbes, les sensibilités et spécificités.

1.4.2 Orthopédie dento-faciale

L'orthopédie dento-faciale est impactée par l'avènement de ces nouvelles technologies comme le montrent plusieurs études [5,26–30]. Ces dernières peuvent intervenir tout au long du workflow orthodontique que l'on se proposera de développer dans la partie suivante.

2 L'INTELLIGENCE ARTIFICIELLE AU SEIN DU WORKFLOW ORTHODONTIQUE

À l'ère du numérique, un ensemble de quatre innovations majeures [31] est venu transformer en profondeur la pratique de l'orthodontie :

- les **progrès de l'imagerie** ;
- l'avènement des **empreintes 3D** ;
- le développement des procédés de fabrication des appareils orthodontiques (**CFAO : « Conception et Fabrication Assistées par Ordinateur »**) ;
- l'essor de **l'intelligence artificielle**, en témoigne l'augmentation exponentielle du nombre d'études portant sur le sujet au cours de ces 3 dernières années [28].

Dans ce contexte, la notion de **flux de travail (workflow)** s'impose comme un élément clé dans l'ensemble des procédures orthodontiques, qu'elles soient cliniques, techniques, organisationnelles ou même liées à la production de savoir scientifique. Comme l'a souligné W. Edwards Deming : *« Si vous ne pouvez pas décrire ce que vous faites comme un processus, alors vous ne savez pas ce que vous faites. »* Cette citation met en évidence l'importance fondamentale d'une structuration rigoureuse des tâches dans toute démarche professionnelle complexe [32].

2.1 Concept du workflow

Historiquement, la genèse du **workflow** peut être reliée aux travaux de Frederick Taylor et Henry Gantt, pionniers de l'organisation scientifique du travail, bien que le terme *workflow* n'ait pas encore été formalisé à leur époque. Une des premières mentions explicites du mot n'apparaît qu'en 1921 dans une revue d'ingénierie ferroviaire. Ce n'est cependant qu'après la Seconde Guerre mondiale que les travaux de W. Edwards Deming et Joseph M. Juran ont profondément modifié les paradigmes de gestion de la qualité. Leurs contributions ont permis l'émergence de méthodologies telles que le **Total Quality Management** et le **Six Sigma**, fondées sur l'analyse quantitative des performances et la standardisation des processus [32].

Il convient de distinguer quelques notions clés :

- le **workflow** désigne la séquence ordonnée de tâches nécessaires à la réalisation d'un objectif donné ;
- le **processus** correspond à une structure plus large, englobant non seulement les tâches mais aussi les données, les outils et le cadre de leur exécution ;
- la **checklist**, enfin, est une forme simplifiée du workflow : suffisante pour une tâche donnée mais incomplète dans un contexte complexe comme l'orthodontie, notamment car elle ne permet pas le suivi rétroactif des étapes précédentes.

À titre d'exemple, la fabrication d'un plateau de collage indirect peut débuter par un **workflow** relativement simple (sélection du type de collage et initiation de la conception). En revanche, le **processus** complet impliquera également le choix de la prescription orthodontique, la sélection du fabricant des brackets, du logiciel de planification, du matériau d'impression 3D et de l'imprimante elle-même (autant d'éléments qui interagissent de manière dynamique pour garantir un résultat optimal) [32]. Wilmes *et al.* [33], dans la même idée, ont d'ores et déjà conceptualisé des workflows dans l'utilisation d'ancrage osseux au niveau du palais antérieur à des fins d'expansion en orthodontie/orthopédie.

Classiquement, il existe **5 grandes étapes** dans le **workflow orthodontique**, certains auteurs en décrivent parfois 4 [31] (figure 8) :



Figure 8: workflow orthodontique classique [34]

Patient/ Diagnostic/ Planification du traitement/ Délivrance du traitement/ Suivi.

Dans cette thèse, nous allons considérer la section « patient » comme la « 1^{ère} consultation », ce qui va nous donner le plan suivant : **1^{ère} consultation → diagnostic → planification du traitement → délivrance du traitement → suivi du traitement.**

2.2 Première consultation

La **première consultation** représente une étape déterminante du parcours orthodontique. C'est à ce moment précis que se joue en grande partie la qualité de la relation praticien-patient, mais aussi l'acceptation du traitement. Aujourd'hui, les patients sont connectés, informés et influencés par les technologies mobiles : ils attendent des services modernes, accessibles et digitalisés dès le premier contact avec le praticien. L'orthodontie numérique vise précisément à tirer parti de ces innovations technologiques, en particulier celles favorisant la **personnalisation du traitement** et **l'optimisation de l'expérience patient**.

Les données issues de la littérature montrent une préférence marquée pour les outils numériques, quel que soit l'âge des patients, notamment grâce :

- **aux empreintes numériques** désormais considérées comme le nouveau *gold standard* [35], plutôt que les empreintes classiques [36], même si leur précision est comparable[37] ;
- **aux aligneurs transparents personnalisés** préférés aux appareils fixes traditionnels [38,39] ;
- **à la communication numérique avec leur praticien**, permettant de réduire les déplacements jugés inutiles pour les rendez-vous [40].

Katyal et Vaid ont mené en 2020 une étude pilote [41] évaluant une plateforme de **téléconsultation orthodontique** semi-personnalisée, intégrant une **IA** d'aide au diagnostic. Sur plus de 350 consultations, les bénéfices suivants ont été observés :

- taux d'acceptation du traitement plus élevé ;
- réduction du temps clinique et administratif ;
- meilleure compréhension du traitement par le patient ;

- préparation plus efficace de l'équipe soignante ;
- tri optimisé des cas non éligibles ;
- diminution potentielle des délais de prise en charge.

Au-delà de l'aspect technologique, l'enjeu est également **éthique et médico-légal** : une communication initiale claire contribue à réduire l'insatisfaction et à préserver la confiance [42]. L'IA contribue ici à renforcer la qualité de l'échange patient-praticien, tout en posant les bases d'un **workflow orthodontique** plus fluide, structuré et prédictif.

2.3 Diagnostic

Le **diagnostic orthodontique** repose sur le recueil et l'analyse de plusieurs éléments : **l'anamnèse** (recueilli en général à la première consultation), **l'examen clinique** et les **examens complémentaires** repris par les photographies (exo- et endo-buccales), les radiographies (orthopantomogramme et téléradiographie de profil à minima), ainsi que les modèles d'étude (empreinte 3D ou physico-chimiques). Ces étapes peuvent s'avérer chronophages et sujettes à des erreurs humaines. Afin de répondre à ces problématiques, l'IA apparaît comme un outil prometteur dans l'automatisation des tâches, l'amélioration de la précision des données et la réduction de la variabilité inter-praticiens dans les interprétations de ces dernières.

2.3.1 Tri des photos

Les **photographies cliniques** exo et endo-buccales (figure 9) permettent de documenter l'état initial du patient et de formuler les premières hypothèses diagnostiques [43]. Ryu *et al.* [44] ont évalué l'application des **réseaux de neurones convolutifs (RNC)** pour le classement automatisé de photographies orthodontiques. Leur modèle, composé d'un RNC léger à quatre couches de convolution pour les photos faciales et d'une seule couche pour les images intra-orales (activation ReLU), a été entraîné sur 1 396 photos faciales et 2 152 photos intra-orales, avec un ensemble de validation de 400 faciales et 500 images endo-buccales) respectivement. Les résultats ont montré un taux de précision global de **98 %**, avec des performances maximales (**100 %**) pour les profils faciaux latéraux et les vues endo-buccales maxillaires et mandibulaires. En comparaison

avec une étude antérieure de Li *et al.* [45], cette recherche présente plusieurs avantages méthodologiques : augmentation du jeu de données initiales, standardisation des photographies et intégration d'une plus grande variété de situations cliniques (appareillage, ancrages osseux...). En résumé, l'application du **deep learning** au tri des photographies orthodontiques constitue une avancée concrète vers la **numérisation complète du workflow** facilitant la gestion des dossiers numériques, réduisant les erreurs, et optimisant le temps clinique.




Figure 9: photos cliniques classiques (illustration personnelle).

2.3.2 Besoin en traitement

L'évaluation du besoin en traitement constitue une étape fondamentale du **diagnostic orthodontique**. Elle permet de déterminer la sévérité de la malocclusion, d'établir les priorités thérapeutiques, et d'orienter le plan de traitement. L'**Index of Orthodontic Treatment Need (IOTN)** ou *indice de besoin en traitement orthodontique*, décrit 31 rubriques, dont 24 concernent directement l'analyse des positions dentaires [46].

Dans une étude menée en 2021, Talaat *et al.* [47] ont évalué la validité d'un outil d'intelligence artificielle (RNC) capable de détecter les principales anomalies occlusales (encombrement, diastèmes, surplomb augmenté, occlusion inversée, infra et supraclusion) à partir de photographies cliniques standardisées. Les résultats ont montré une forte concordance entre les évaluations de l'IA et celles de praticiens expérimentés.

Ces résultats suggèrent que de tels systèmes peuvent être intégrés dès l'amont du diagnostic, en tant qu'outils de **pré-tri** ou de **priorisation des cas**, contribuant à optimiser le temps clinique et à renforcer la pertinence du **workflow orthodontique**.

2.3.3 Caractéristiques occlusales

L'IA est désormais capable d'évaluer automatiquement des **caractéristiques occlusales** à partir d'images ou de modèles numériques.

En Chine, Nan *et al.* [48] ont utilisé une approche multimodale combinant des **téléradiographies et photographies de profil** pour entraîner leur RNC à déterminer les classes squelettiques I, II et III, confirmées par l'indice de WITS (similaire à l'AoBo) chez des enfants de 11 ans en moyenne. Le modèle a atteint une précision de **90,33 %** pour les téléradiographies et **83,39 %** pour les photos, soulignant la polyvalence des supports exploitables.

Comme cité précédemment, Talaat *et al.* [47] ont obtenu une précision de **99 %** dans la détection automatique des principales anomalies occlusales endo-buccales (encombrement, surplomb, infraclusion, etc.) à partir de photographies cliniques standardisées, confirmant la fiabilité de l'IA dans un contexte purement visuel.

D'autres équipes ont élargi le champ d'application. Ali *et al.* [49] ont appliqué un RNA pour prédire automatiquement les **dimensions mésio-distales** des dents permanentes à partir de photographies intra-orales. Le modèle, entraîné sur une population irakienne, a montré une corrélation élevée ($r = 0,91$) entre les dimensions prédites et les mesures réelles. Cette méthode permet, par exemple, lors de la consultation d'un enfant en denture mixte (8-10 ans), d'anticiper la taille des futures dents permanentes à partir des dimensions des dents déjà présentes en bouche. L'intérêt clinique réside notamment dans l'évaluation précoce de l'espace disponible, utile en orthodontie interceptive et dans la planification du traitement.

Enfin, Budiman *et al.* [50] en Indonésie, ont développé un RNA capable de prédire la **forme de l'arcade dentaire** (parabolique, carrée ou ogivale) à partir de

moulages numérisés en 2D, avec une précision de **76,3 %**. Ce type d'analyse présente un intérêt clinique particulier dans le cadre de la **stabilité post-traitement**, où la forme de l'arcade joue un rôle déterminant [51].

En somme, l'IA appliquée à l'analyse des caractéristiques occlusales permet de fiabiliser le diagnostic, d'anticiper les besoins cliniques et de standardiser l'évaluation initiale, tout en s'adaptant à divers types de données cliniques (photos, radiographies, modèles).

2.3.4 Détection de points anatomiques

L'IA, plus particulièrement les RNC, permet aujourd'hui une détection automatique et précise des **points anatomiques** sur divers types de supports :

2.3.4.1 Téléradiographie de profil

King *et al.* [52] ont développé le modèle **CephaX**, basé sur un RNC dérivé de **YOLOv3**, atteignant une précision de **86,1 %** pour une erreur inférieure à **2 mm**, et **94,9 %** à **3 mm**, surpassant les modèles antérieurs en réduisant l'erreur moyenne de **0,9 mm** et en améliorant la régularité des mesures (écart-type réduit de 1,20 à 0,93 mm).

Yao *et al.* [53] ont atteint un **taux de détection** (SDR : successful detection rate) de **97,3 %** pour 37 points céphalométriques en seulement **3** secondes.

Yu *et al.* [54] ont utilisé un RNC pour classer la **morphologie squelettique** avec une précision de **90 %** (figure 10).




Figure 10: exemple de tracé automatisé d'une téléradiographie de profil [55]

2.3.4.2 Téléradiographie de face

Gil *et al.* [56] ont appliqué un RNC en cascade pour identifier 16 repères sur des téléradiographies de face, atteignant un taux de précision de **83,3 %**. Cette performance est particulièrement notable dans la mesure où l'analyse des clichés de face est souvent fastidieuse en raison de la superposition des structures.

2.3.4.3 Imagerie 3D

Dot *et al.* [57] ont rapporté un taux de détection de **90,4 %** avec une erreur moyenne de **1,0 mm** pour **33 points** (21 squelettiques, 12 dentaires).

Kim *et al.* [58] ont utilisé la technique de « **projection d'intensité maximale** » (**Maximum Intensity Projection, MIP**) pour extraire la téléradiographie de profil à partir de l'examen 3D avec un taux de détection atteignant **87,13%** à **2 mm** d'erreur.

Dans un second travail, la même équipe de recherche [59] a tenté d'extraire la téléradiographie de face à partir du **CBCT** affichant un taux de détection de **60,88 %** à **2 mm**, révélant les défis techniques laborieux sur ce type de projection.

2.3.4.4 Empreintes numériques et photographies

Croquet *et al.* [60] ont évalué la détection automatique de points anatomiques au niveau du palais sur des **empreintes numériques** : 2 points bilatéraux canins (gauche/droite) et molaire (gauche/droite) + 3 repères médians : inter-molaire (MM), niveau inter-canin (MC), papille incisive (IP). Ils ont observé une précision de **68 %** à **93 %** selon le point (IP : 93 %, MM : 68 %) dans une marge d'erreur de **2 mm**.

Rao *et al.* [61] grâce à un algorithme de **machine learning**, ont identifié des points faciaux sur des **photographies exo-buccales 2D** avec **97,7%** des points détectés dans une erreur inférieure à **5mm**, avec une vitesse d'exécution de **0,00023 ms**.

2.3.5 Évaluation de la maturation vertébrale cervicale (CVM)

La détermination du moment optimal d'intervention en orthodontie dépend en grande partie de l'identification du **pic de croissance pubertaire**, particulièrement dans les cas de **dysmorphoses squelettiques**. La méthode de référence est l'**analyse des os du poignet (Hand-Wrist Maturation – HWM)** initiée par Lamparski. Cependant, elle implique une irradiation supplémentaire. Pour limiter ces contraintes, la méthode **CVM (Cervical Vertebral Maturation)**, introduite par Baccetti *et al.* [62], s'est progressivement imposée. Elle repose sur l'analyse des modifications morphologiques des vertèbres cervicales C2 à C4 visibles sur la **téléradiographie de profil**, sans recours à des clichés supplémentaires. Plusieurs études ont confirmé une corrélation significative entre les stades de maturation déterminés par la méthode de Baccetti et ceux obtenus avec la HWM, validant ainsi la CVM comme une alternative fiable et moins invasive [63].

L'IA renforce encore cette approche en automatisant la classification des stades de croissance avec une grande précision. Seo *et al.* [64] ont utilisé six modèles de **deep learning** capables de classer les stades de maturation CVM en moins de **0,1 seconde/ image**, avec une précision supérieure à **90 %**. Grâce à l'outil **Grad-CAM**, ils ont pu vérifier que les modèles focalisaient bien sur les vertèbres

cervicales, augmentant ainsi la confiance clinique dans leur interprétation (figure 11).

Khazaei *et al.* [65] ont entraîné un RNC sur un large ensemble de données (1846 images pour l'entraînement, 449 pour le test) et ont évalué deux scénarios de classification :

- **scénario à 3 classes** : pré-pic (CS1–CS2), pic (CS3–CS4), post-pic (CS5–CS6) → 82 % de précision ;
- **scénario à 2 classes** : croissance active (CS1–CS3) vs post-croissance (CS4–CS6) → 93 % de précision.

Ces résultats démontrent que l'IA, en particulier via les RNC, permet une **évaluation rapide, reproductible et fiable de la maturation squelettique**, comparable aux méthodes classiques.




Figure 11: illustration du Grad-CAM sur divers stades de maturations cervicales. Le rouge représente une grande attention, le bleu une petite [66].

2.3.6 Voies aéro-digestives supérieures (VADS)

En orthodontie, l'**aspect fonctionnel** revêt une importance particulière, notamment dans le cadre de troubles tels que **le syndrome d'apnées-hypopnées obstructives du sommeil (SAHOS)** ou **l'hypertrophie des amygdales**. Ces pathologies sont souvent associées à des anomalies crânio-faciales comme une **étroitesse maxillaire** ou un **rétrognathisme mandibulaire**. Une corrélation significative a également été rapportée entre une **résistance nasale élevée** (difficulté au passage de l'air) et certaines caractéristiques occlusales : surplomb augmenté, béance antérieure et encombrement maxillaire [67].

Dans ce contexte, des approches fondées sur l'intelligence artificielle ont été développées pour évaluer l'obstruction des **voies aériennes supérieures**. Jeong *et al.* [68] ont conçu un RNC capable de détecter ces obstructions, obtenant un score F1 de **0,88**. Ce score combine la **précision** (capacité à éviter les faux positifs) et le **rappel** (capacité à détecter tous les cas positifs) ; un score proche de 1 indiquant une excellente performance.

D'autres études [69,70] ont confirmé ces résultats en appliquant des méthodes d'IA à l'analyse de **CBCT** pour l'évaluation des voies aériennes supérieures, offrant ainsi des outils automatisés fiables pour le diagnostic fonctionnel.

2.3.7 Comptes rendus médicaux

Il existe des aides pour la prise de notes et l'édition automatisée de comptes rendus médicaux telle que l'entreprise française (Nabla®) par exemple [71].

2.3.8 Gestion de matériel

Certaines entreprises (comme ClinicPilot® par exemple) ont mis au point des logiciels permettant la gestion des stocks de matériel, la comparabilité des prix, la traçabilité et d'autres éléments paracliniques, une sorte de « secrétariat » assisté par IA [72].

2.4 Planification du traitement

La **planification du traitement orthodontique** débute par l'élaboration d'une stratégie thérapeutique globale, étape déterminante du **workflow clinique**. Elle vise à définir la solution la plus appropriée en fonction du **diagnostic**, des **attentes du patient** et des **contraintes anatomiques et fonctionnelles**. L'IA intervient de plus en plus comme un outil d'aide à la décision, optimisant la précision et l'efficacité de cette phase critique.

2.4.1 Planification générale

Prasad *et al.* [73] ont proposé quatre modèles de planification fondés sur **l'apprentissage automatique**, intégrant 33 variables cliniques initiales et 11 variables résultantes : classe squelettique (Classe I, II, III), nécessité d'extractions (oui/non), et type de traitement (orthopédie/ compensation/ chirurgie). Leurs modèles ont atteint une précision moyenne de **84 %**, certains culminant à 93 %, démontrant ainsi la capacité des algorithmes à reproduire les décisions cliniques d'experts.

Dans une autre étude, El-Dawlatly *et al.* [74] ont exploré la prise en charge d'une problématique fréquente : la **supraclusion (deep bite)**, définie comme un recouvrement vertical excessif des incisives mandibulaires par les incisives maxillaires. De par la variabilité inter-individuelle des dimensions dentaires, un recouvrement est considéré comme physiologique lorsque 30 % ou 1/3 de la couronne clinique des incisives mandibulaires sont recouvertes [75]. Leur modèle prédictif, basé sur l'IA, proposait diverses stratégies thérapeutiques (ingression antérieure, égression postérieure, nivellement de la courbe de Spee, etc. [76]) avec un taux d'accord de **94,4 %** par rapport aux décisions cliniques réelles, confirmant la pertinence de ces outils dans des situations spécifiques. Ces approches pourraient ainsi accompagner le clinicien dans son processus décisionnel.

D'autres chercheurs ont mis l'accent sur des aspects moins techniques, mais tout aussi essentiels à la planification, comme **l'expérience patient**. Xu *et al.* [77] ont ainsi développé un RNA pour anticiper la douleur, l'anxiété et l'impact sur la qualité de vie lors d'un traitement par aligneurs (*Invisalign*®). Les taux de

prédiction atteignaient respectivement **87,7 %**, **93,4 %** et **92,4 %**, avec des aires sous la courbe allant jusqu'à **0,99**. Le nombre d'attaches linguales et de boutons a été identifié comme facteur majeur de gêne, permettant au praticien d'adapter ses choix en amont.

Du côté de la planification esthétique, Xing *et al.* [78] ont conçu un modèle de machine learning permettant de prédire la **position finale des lèvres** en fonction des mouvements dentaires planifiés, notamment l'avancée ou le recul des incisives. Un outil clinique dérivé de ce modèle permet aujourd'hui d'évaluer l'impact esthétique du traitement dès la phase de planification.

La précision du **diagnostic initial** joue également un rôle central. Leite *et al.* [79] ont utilisé des RNC pour **détecter** et **segmenter automatiquement les dents** sur des **radiographies panoramiques**, avec une précision de **99,6 %**, tout en réduisant le temps de travail de **67 %** par rapport à la segmentation manuelle. Ces informations sont cruciales pour identifier les malpositions, les dents incluses ou absentes, et affiner les décisions thérapeutiques.

Dans le même registre, Alqathni *et al.* [80] ont développé un RNC spécialisé dans la segmentation des dents appareillées sur des **images CBCT**, surmontant les artefacts métalliques générés par les brackets. Leur modèle a obtenu une précision de **99,9 %**, avec un temps de traitement moyen de **13,7 secondes**, démontrant une efficacité compatible avec la pratique clinique.

Enfin, la **surveillance des mouvements radiculaires**, souvent difficile à objectiver en temps réel, a été abordée par Hu *et al.* [81] via un modèle **d'apprentissage profond**. Leur approche innovante consistait à superposer la modélisation des couronnes (issue de **scans intra-oraux** répétés) avec une segmentation des racines à partir d'un seul CBCT initial, créant ainsi des "racines virtuelles". Les écarts entre positions finales réelles et simulées étaient inférieurs à **0,3 mm**, ouvrant la voie à un contrôle précis des mouvements dentaires dans le respect de leur environnement parodontal en limitant les irradiations multiples.

En résumé, l'intégration de l'IA dans la planification ne se limite pas à une optimisation technique : elle améliore la précision orthodontique, favorise la

personnalisation thérapeutique, anticipe l'expérience et améliore la prédictibilité des résultats.

2.4.2 Besoin en extraction

Les **extractions orthodontiques** peuvent être prescrites dans différents contextes : créer de l'espace, corriger une **malocclusion**, améliorer le **profil**, préparer une **chirurgie**, etc. Cette décision, souvent délicate, repose sur plusieurs paramètres : imagerie radiographique, analyse esthétique, croissance... L'IA apparaît ici comme un support précieux, capable d'analyser ces données complexes et d'identifier des **patterns prédictifs**.

Deux études récentes illustrent le potentiel de ces approches. En 2018, Del Real *et al.* [82] ont comparé plusieurs modèles **d'apprentissage automatique** pour évaluer la nécessité d'extractions dentaires. En combinant des données issues de **modèles numériques** et de **radiographies**, ils ont obtenu une précision allant jusqu'à **93,9 %** dans la distinction entre traitements avec ou sans extraction en général, démontrant la capacité des algorithmes à intégrer une multiplicité de variables et à reproduire, voire surpasser, les décisions cliniques humaines.

Plus récemment, en 2023, Leavitt *et al.* [83] ont élargi la problématique en s'intéressant à la **détermination du schéma d'extraction le plus approprié**. Leur modèle de machine learning a atteint une précision élevée pour les schémas les plus fréquents : extraction des premières prémolaires maxillaires et mandibulaires (**81,63 %**), ou des seules premières prémolaires maxillaires (**72,22 %**). Toutefois, les performances chutaient en dessous de **50 %** pour des configurations plus atypiques ou rares, soulignant les limites actuelles de ces technologies lorsque les bases d'apprentissage manquent de diversité. Si l'IA montre déjà un potentiel élevé dans la décision d'extractions orthodontiques, son efficacité dépend encore largement de la représentativité et de la richesse des données utilisées pour son entraînement.

2.4.3 Traitement ortho-chirurgical

Planifier et exécuter un **traitement ortho-chirurgical**, lors de **dysmorphoses squelettiques** ou lorsque les simples compensations dentoalvéolaires sont insuffisantes pour atteindre les objectifs fixés, nécessite une **coordination**

pluridisciplinaire fine entre orthodontistes et chirurgiens. Là aussi, des études ont investigué l'apport de l'IA :

Patcas *et al.* [84] ont évalué l'impact de la chirurgie orthognathique sur **l'attractivité perçue** et **l'âge apparent** d'une population suisse, à l'aide d'un RNC. Selon leurs résultats, **66,4 %** des patients ont présenté une amélioration de l'apparence générale, avec un rajeunissement moyen estimé à **0,93 an**. L'attractivité faciale a augmenté chez **74,7 %** des patients, avec un gain moyen de **+1,22** points sur l'échelle utilisée. Les effets étaient particulièrement marqués après les chirurgies modifiant le profil facial, notamment les **avancées mandibulaires**. Ce type d'évaluation, objectivée par l'IA, permet de réduire la subjectivité inhérente aux critères esthétiques, et s'avère utile tant pour la **planification** que pour la **communication avec le patient**.

Sur le plan **diagnostic**, Chaiprasittikul *et al.* [85] ont utilisé des RNC et des RNA pour déterminer la nécessité d'une chirurgie orthognathique. Leurs modèles ont atteint un taux d'accord de **96,3 %** avec l'avis de spécialistes expérimentés, confirmant le potentiel de l'IA comme outil d'aide à la décision thérapeutique.

Sur le plan **thérapeutique**, Cheng *et al.* [86] ont développé le **VSP Transformer**, un outil basé sur le **deep learning**, capable d'automatiser la planification chirurgicale à partir de données céphalométriques 3D. Le système prédisait les déplacements osseux nécessaires avec une erreur absolue moyenne de **1,3 mm**, jugée cliniquement acceptable. Outre sa précision, il se distingue par une bonne **interprétabilité** et un potentiel élevé d'intégration clinique, permettant à la fois un gain de temps et une amélioration de la qualité des soins comme de la formation des praticiens.

Enfin, Tanikawa et Yamashiro [87] ont développé un modèle **de deep learning** capable de prédire la **morphologie faciale tridimensionnelle post-traitement** (orthodontique ou chirurgical). Leur étude, portant sur 137 patients, a révélé que le système atteignait un taux de succès de **54 %** (erreur < 1 mm) pour les cas chirurgicaux, et de **98 %** pour les cas orthodontiques avec extractions. Pour une marge d'erreur inférieure à 2 mm, le taux de réussite était de **100 %**, ce qui est largement acceptable en pratique clinique. Contrairement aux logiciels

commerciaux traditionnels, souvent basés sur l'hypothèse simpliste d'une correspondance linéaire entre mouvements osseux et tissus mous, l'IA propose une modélisation plus réaliste, intégrant des **relations non linéaires complexes**, et offre ainsi une véritable valeur ajoutée dans la **prédiction des résultats esthétiques**.

2.5 Délivrance du traitement

Comme mentionné précédemment (cf. section 2.1), l'émergence des **technologies numériques**, en particulier les systèmes **CAO/FAO (Conception et Fabrication Assistées par Ordinateur, en anglais CAD/CAM)**, a profondément transformé la planification et la réalisation des traitements orthodontiques.

Introduits initialement en dentisterie prothétique dès 1985 avec le système **CEREC** (Dentsply Sirona, Charlotte, NC, USA), ces outils permettaient la conception assistée par ordinateur de couronnes unitaires, puis de restaurations plus complexes telles que les bridges. En orthodontie, leur application a débuté en 1998 avec le développement des **aligneurs transparents** par la société Invisalign®, marquant une rupture technologique majeure. Parallèlement, la personnalisation des bases de brackets (système **Incognito®**, Bad Essen, Allemagne) et l'automatisation du pliage des fils orthodontiques à l'aide de robots (Orametrix, Richardson, Texas, USA, dès 1999) ont illustré l'entrée progressive de la spécialité dans l'ère numérique [34].

Ces innovations ont ouvert la voie à l'intégration de l'intelligence artificielle dans la **phase active du traitement orthodontique**. Aujourd'hui, l'IA intervient de manière croissante dans la **délivrance du traitement**, en optimisant la conception des dispositifs, en assurant un **suivi clinique individualisé** et en facilitant les **ajustements thérapeutiques en temps réel**.

2.5.1 Collage indirect digital

Hoang *et al.* [88] ont évalué le logiciel **Medit Splints v1.1** pour la conception automatisée de gouttières de **collage indirect lingual**, imprimées en 3D. Deux types de gouttières ont été comparées : groupées (couvrant plusieurs dents) et individuelles. Sur 22 patients, la **précision linéaire moyenne variait entre 0,07**

et **0,012 mm**, jugée **cliniquement acceptable**. Les gouttières groupées se sont révélées **plus précises** que les unitaires. L'IA a donc permis de standardiser le positionnement virtuel des brackets et de générer automatiquement les gouttières, améliorant la reproductibilité du processus. Toutefois, le **contrôle du torque** est resté la principale source d'imprécision, avec des écarts souvent supérieurs à **2°**, nécessitant des ajustements cliniques.

2.5.2 Aligneurs

L'introduction des **aligneurs transparents** a profondément modifié le **workflow clinique**, notamment grâce à l'intégration de l'IA à chaque étape du processus, de la simulation du sourire jusqu'au suivi thérapeutique. En 2019, Invisalign® rapportait plus de **7 millions de cas traités**, tous répertoriés par leurs algorithmes [89].

2.5.2.1 Smile View : la simulation comme outil d'engagement

La fonctionnalité **Smile View** (Invisalign®) (figure 12) génère une simulation instantanée du sourire post-traitement à partir d'une simple photo. Basée sur des algorithmes de **deep learning**, elle détecte automatiquement les **points anatomiques faciaux**, **classe les images**, et propose une **prévisualisation réaliste du sourire**, en moins **d'une minute**. Cet outil de **préconsultation à distance**, réduisant les freins initiaux des patients, permettrait de faciliter la première consultation avec le praticien. Selon Adel *et al.* [90], cinq paramètres quantitatifs générés par l'IA sont considérés comme fiables : **hauteur du philtrum**, **hauteur des commissures labiales**, **la largeur du sourire**, **le corridor buccal** et **l'indice du sourire**. La **largeur intercanine maxillaire** reste peu prédictive. Qualitativement, seule la **ligne labiale** corrélait avec les résultats finaux, qui montraient globalement une amélioration par rapport à la simulation initiale. Au-delà de son intérêt clinique, cet outil s'inscrit également dans une logique de **marketing**, favorisant la **communication** et valorisant **l'offre thérapeutique** en proposant au patient cette visualisation anticipée du sourire aux premiers échanges.




Figure 12: illustration du SmileView [91]

2.5.2.2 ClinCheck et planification automatisée du traitement

Le logiciel **ClinCheck** (figure 13) permet à l'orthodontiste de visualiser et d'ajuster virtuellement chaque étape du mouvement dentaire, à partir d'un set-up numérique automatisé. Invisalign® a également introduit le **Multi-Treatment Plan Approach (MTA)** dans son programme **Invisalign Go**, générant automatiquement plusieurs plans de traitement possibles (nombre d'aligneurs, réductions interproximales (RIP), ajout de taquets, etc.). Le praticien peut alors sélectionner ou modifier la version la plus adaptée, bénéficiant ainsi d'une personnalisation assistée et d'une réduction de temps de planification.




Figure 13: Clincheck Invisalign® [92]

2.5.2.3 Efficacité clinique et communication

Les aligneurs intégrant l'IA présentent des avantages cliniques. Alam *et al.* [93] ont comparé l'efficacité des **mouvements orthodontiques (Orthodontic Tooth Movements= OTM)** entre aligneurs Invisalign® et appareils fixes conventionnels. Leurs résultats montrent une **efficacité comparable**, avec une **réduction de la durée de traitement** en faveur des aligneurs. Cependant, ils soulignent un manque de standardisation des méthodes de mesure, ce qui rend les comparaisons parfois délicates.

Enfin, ces outils (ex. **Outcome Simulator**) améliorent la **communication patient-praticien**. Les simulations visuelles, l'évolution virtuelle du traitement et les prévisions de résultat contribuent à **améliorer l'adhésion du patient**, et **l'observance** au long cours [89].

2.5.3 Contention

La phase de **contention** constitue l'étape finale du traitement orthodontique. Le dictionnaire d'Orthognathodontie de la **Société Française d'Orthopédie Dento-Faciale (SFODF)** la définit comme « *l'ensemble des moyens mis en œuvre pour maintenir les résultats obtenus après un traitement orthodontique, en stabilisant les dents dans leur nouvelle position le temps que les structures de soutien (os, gencives, fibres parodontales) s'adaptent* » [94].

On distingue :

- **les contentions fixes**, par fils collés en face linguale ou palatine ;
- **les contentions amovibles**, comme les gouttières thermoformées ou les plaques de Hawley ;
- **une combinaison des deux** selon les cas.

Historiquement réalisées manuellement (thermoformage au fauteuil/ laboratoire, fil collé per-opératoire), ces étapes sont aujourd'hui transformées par l'impression **3D**, la **segmentation dentaire assistée IA**, et l'évolution des **biomatériaux**. L'IA permet notamment une **segmentation automatique des**

dents à partir de modèles 3D, facilitant la conception numérique de dispositifs parfaitement adaptés, puis leur fabrication par CAO/FAO de grande précision.

Sur le plan clinique, des comparaisons entre contentions numériques et conventionnelles montrent **l'absence de différences significatives** après 6 mois tant en termes de **stabilité** (indice d'irrégularité de Little, largeur et longueur d'arcades), qu'en **taux d'échec** ou de **satisfaction des patients** [95], nos traitements s'inscrivant sur le long terme, ces mêmes comparaisons seraient souhaitables à 2 ;5 voire 10 ans post-contention.

2.6 Suivi du traitement

En orthodontie, la durée moyenne d'un traitement est estimée à environ **2 ans**, avec des variations allant de **14 et 33 mois** [96], une période durant laquelle la **coopération du patient**, la **surveillance clinique** et le **respect des protocoles** sont essentiels. Cette durée prolongée peut impacter la qualité de vie liée à la santé bucco-dentaire, notamment chez les adultes, ainsi que la **compliance** du patient. De plus, les traitements excessivement longs augmentent le risque de **complications iatrogènes**, telles que la résorption radiculaire ou les déminéralisations liées à la plaque [97].

Dans ce contexte, **l'optimisation du temps de traitement** et du **suivi clinique** devient un enjeu central. En 2019, Sharif *et al.* [98] ont montré que 87 % des patients se déclaraient prêts à utiliser une **application mobile** pour les accompagner pendant leur traitement orthodontique, bien que la connaissance de l'existence de telles solutions restait faible. Six ans plus tard, des outils comme **DentalMonitoring®** (DM) sont devenus une réalité clinique[99].

Développée par une entreprise française, **DentalMonitoring®** est une application de **télédentisterie** intégrant un algorithme IA fondé sur une large base de données cliniques. Son objectif est de permettre un **suivi semi-automatisé à distance**, en réduisant la fréquence des consultations physiques tout en maintenant un contrôle rigoureux.

Son fonctionnement est le suivant :

1. Le patient utilise une **ScanBox** (figure14) et un écarteur pour capturer des images standardisées de sa cavité buccale via son smartphone.
2. Ces images sont transmises à une plateforme sécurisée où elles sont **analysées par un algorithme d'IA** capable de détecter automatiquement de nombreux événements cliniques : décollement de brackets, détachement de fils ou d'attaches, inflammation gingivale, hygiène orale insuffisante, mauvaise adaptation des aligneurs, éruption dentaire, etc.
3. Le praticien reçoit des alertes automatisées et peut configurer la surveillance de mouvements dentaires spécifiques, envoyer des instructions au patient ou planifier un rendez-vous si nécessaire.

Ce système permet donc de **réduire les visites en présentiel** sans compromettre la qualité du suivi. Dans leur revue systématique de 2023, Sangalli *et al.* [100] ont montré que l'intégration de DM permettait de **réduire significativement le nombre de consultations physiques**, tout en améliorant **l'adaptation des aligneurs**. En revanche, aucune différence n'a été observée concernant la **durée totale du traitement** ni le **nombre de rendez-vous d'urgence**.

Ces outils présentent également des **avantages organisationnels** notables : espacer les consultations sans prolonger le traitement fait **gagner du temps** au praticien comme au patient, tout en limitant les risques liés au contexte postpandémique. Toutefois, espacer les rendez-vous comporte aussi des risques si aucun système de détection n'est en place, notamment pour les urgences orthodontiques non identifiées.

L'intégration de l'IA dans le suivi orthodontique permet un **changement de paradigme** : d'un modèle passif et ponctuel à un **modèle dynamique, connecté et prédictif**, améliorant la réactivité et la précision du suivi thérapeutique. L'implémentation de ces technologies suppose néanmoins une **maîtrise technique de la part du patient**, ainsi qu'une réflexion **éthique et réglementaire**, notamment concernant la **confidentialité des données de santé** (RGPD), qui sera abordée en partie 3.



Figure 14: ScanBox de DentalMonitoring [101]

3 DEFIS, ENJEUX ET PERSPECTIVES DE L'INTÉGRATION DE L'IA EN ORTHODONTIE

Si les bénéfices de l'intelligence artificielle dans le workflow orthodontique sont de plus en plus démontrés, son intégration effective dans la pratique clinique soulève encore de nombreuses interrogations. Qu'elles soient d'ordre technique, éthique, organisationnel ou économique, ces problématiques méritent une analyse approfondie pour anticiper les freins potentiels et envisager une mise en œuvre responsable et durable à l'avenir.

3.1 Défis techniques et cliniques

3.1.1 Fiabilité des algorithmes et qualité des données

L'intégration de l'IA en orthodontie demeure limitée par la **qualité** et la **diversité insuffisantes des jeux de données** disponibles. Ces bases, souvent de taille réduite et peu représentatives, manquent de variété en termes **d'âge**, de **types de malocclusions**, **d'origine ethnique**, **d'équipements d'imagerie** ce qui entrave la capacité des modèles à **généraliser leurs prédictions**. La **standardisation** des variables, des unités de mesure, des protocoles d'acquisition, mais aussi des indicateurs d'évaluation (*accuracy*, *F1-score*, *Dice coefficient*), apparaît indispensable pour assurer la **comparabilité** des résultats et éviter que certaines limites ne soient masquées [102]. L'exemple des modèles prédictifs appliqués aux voies aériennes illustre ce problème, avec une forte baisse de performance lorsqu'ils sont confrontés à des bases publiques.

Un autre facteur critique est la **qualité de l'annotation des données**. La performance des modèles dépend fortement d'un étiquetage précis réalisé par des experts cliniques. Or, les erreurs ou la subjectivité dans la définition du « gold standard » compromettent la fiabilité des algorithmes. Trop souvent la référence clinique est établie sur l'avis d'un seul expert, ce qui rend nécessaire la construction de référentiels établis **consensus**.

Le **surapprentissage (overfitting)** demeure un défi majeur : certains modèles s'ajustent trop étroitement aux données d'entraînement et perdent leur capacité à prédire correctement sur de nouveaux cas [103]. Ce phénomène est accentué par la taille limitée et l'hétérogénéité des données. Pourtant, les stratégies de

contrôle telles que la **validation croisée**, la **régularisation** ou l'**augmentation des données** restent encore sous-utilisées dans la littérature [79].

Enfin, malgré les progrès, l'IA n'atteint toujours pas la **précision des cliniciens expérimentés** notamment pour la **détection de points anatomiques**, soulignant l'importance d'une **validation clinique rigoureuse**. La question des **marges d'erreur** constitue un point critique dans l'évaluation de la fiabilité des systèmes IA. On retrouve dans des études citées précédemment, des précisions de 95 % sur une erreur à 3 mm sur des repères céphalométriques, or cela peut modifier drastiquement le diagnostic squelettique final et influencer les thérapeutiques attenantes. De même, un écart de 5 mm dans la détection de points faciaux sur des photographies peut compromettre l'analyse morphologique. La qualification de telles marges comme « cliniquement acceptables » reste alors **discutable** en l'absence de **contextualisation**. Par ailleurs, la majorité des études existantes sont exploratoires, issues de contextes géographiques restreints et manquent souvent de **rigueur méthodologique**. Des recherches multicentriques, des études interventionnelles et des revues systématiques robustes sont indispensables pour établir la fiabilité réelle et l'**utilité clinique** des outils d'IA en orthodontie.

3.1.2 Limitations actuelles de l'IA dans la prise de décision clinique

Malgré des avancées notables, l'IA demeure limitée lorsqu'il s'agit d'intégrer la **complexité des situations orthodontiques réelles**. Les modèles actuels peinent à traduire en tâches computationnelles la richesse des **paramètres cliniques**, en particulier les cas nécessitant une **vision globale du patient** et un **plan de traitement complet**. Cette difficulté s'explique en grande partie par la **représentativité insuffisante des bases de données** : souvent centrées sur des cas simples, elles manquent de diversité et échouent à couvrir les subtilités rencontrées en pratique quotidienne, or c'est précisément sur les patients sortant du cadre des « cas simples » que l'on se pose des questions, auxquelles nous aimerions que l'intelligence artificielle apporte un début de réponses.

L'IA ne peut assumer seule la **responsabilité décisionnelle**. Le **jugement clinique** reste indispensable pour interpréter les spécificités de chaque patient,

pondérer les alternatives thérapeutiques et prévenir le **biais d'automatisation** [102]. En l'état, les systèmes doivent être considérés comme des **outils d'assistance**, capables d'accélérer certaines étapes diagnostiques mais incapables de formuler de manière autonome un **diagnostic complet** ou une **stratégie thérapeutique**. La perspective réaliste est donc celle d'une **intégration progressive**, où la fiabilité et la validation des algorithmes s'accompagnent du maintien du rôle central du praticien.

3.1.3 Intégration dans les logiciels et équipements existants

La **compatibilité avec les outils déjà en usage** en orthodontie constitue une barrière importante à l'adoption de l'IA. Les logiciels de planification ou d'imagerie ne sont pas toujours conçus pour accueillir des **modules intelligents**, ce qui limite leur intégration fluide dans les **workflows cliniques**. Le développement de solutions à la fois **cliniquement pertinentes** et **techniquement robustes** suppose donc une collaboration étroite entre **orthodontistes** et **ingénieurs** afin de garantir la pertinence clinique autant que la faisabilité technique [102].

L'intégration de l'IA exige également des **infrastructures numériques adaptées**. Le rythme rapide d'évolution des approches de deep learning et des algorithmes de pointe impose des logiciels **évolutifs**, capables de rester compatibles avec des innovations fréquentes. Sans cette **flexibilité technique**, les outils risquent de devenir obsolètes avant même d'être pleinement adoptés, freinant ainsi la diffusion de l'IA dans la pratique orthodontique.

3.2 Enjeux éthiques et juridiques

3.2.1 Confidentialité des données et cybersécurité

Le **partage**, l'**échange** et le **stockage des données de santé** constituent un frein majeur à l'entraînement efficace des modèles d'IA. En orthodontie, les cas disponibles sont souvent trop peu nombreux ou trop homogènes pour permettre une **généralisation robuste**. A cela s'ajoutent les contraintes **éthiques** et **réglementaires**, comme le **Règlement Général sur la Protection des Données (RGPD)**, qui rendent difficile la centralisation des dossiers patients à grande échelle dû à l'hétérogénéité des comités d'éthique ainsi que les différences d'application de leurs règles selon les territoires du monde.

Pour contourner ces obstacles, des approches émergent. **L'apprentissage fédéré (*federated learning*)** permet à plusieurs centres de santé de collaborer à l'entraînement d'un modèle commun, **sans transférer directement leurs données** [104]. En parallèle, la technologie **blockchain** assure une **sécurisation**, une **traçabilité** et une **immutabilité** des informations, tout en respectant leur caractère confidentiel [105].

Combinées, ces deux approches pourraient révolutionner l'exploitation des données en orthodontie, en ouvrant la voie à des **bases d'entraînement mondiales, massives, diversifiées et sécurisées**, sans compromis sur la vie privée [106].

3.2.2 Responsabilité médico-légale en cas d'erreur

À mesure que l'utilisation des systèmes d'IA dans le diagnostic et la planification thérapeutique orthodontique s'intensifie, la question de la **responsabilité médico-légale** en cas d'erreur devient centrale. L'intégration de ces outils dans la **prise de décision médicale** soulève des problématiques juridiques complexes : en cas de dommage subi par le patient, la responsabilité ne saurait incomber uniquement au **praticien**, mais pourrait également concerner le **développeur de l'IA**, le **fournisseur**, l'**établissement de santé** ou encore l'**autorité de régulation** ayant approuvé l'outil. Cette pluralité d'acteurs rend nécessaire une **évolution du droit de la faute médicale** et la création de mécanismes de régulation spécifiques. Pour assurer une adoption sûre et éthique, il est indispensable de définir un cadre juridique clair qui garantisse la protection du patient, encourage l'innovation technologique et répartisse équitablement la responsabilité entre les différents intervenants [107].

3.2.3 Équité d'accès et biais algorithmiques

L'**équité d'accès aux soins** et la prévention des **biais algorithmiques** constituent un enjeu majeur dans l'intégration de l'IA en orthodontie. Lorsqu'un modèle est entraîné sur des **données non représentatives**, il risque de produire des recommandations biaisées, renforçant ainsi des **inégalités de prise en charge**. La **transparence** des corpus d'apprentissage et la possibilité de soumettre les processus décisionnels de l'IA à un **examen critique** et à une

relecture par les pairs apparaissent comme des conditions essentielles à une **justice algorithmique** [108].

Par ailleurs, l'IA fonde ses prédictions sur des approches **statistiques et probabilistes**, qui tendent à réduire la **complexité biologique** à des relations mesurables, mais souvent **intriquées** et difficilement modélisables. Cette simplification peut générer des **biais implicites**, surtout si les critères retenus ne reflètent pas la **diversité clinique réelle** [109].

Assurer la **représentativité des données** et instaurer des mécanismes de **transparence** constituent ainsi une exigence indispensable pour garantir une utilisation équitable de l'IA en orthodontie.

3.3 Acceptabilité humaine et changements organisationnels

3.3.1 Résistance au changement chez les praticiens

La **Crainte d'une déshumanisation** de la relation soignant-soigné et la **perte de contrôle clinique** peuvent expliquer la résistance des praticiens à l'adoption de l'intelligence artificielle: l'IA ne peut reproduire **l'intuition**, le **ressenti** ou la **compréhension fine des besoins individuels** du patient, éléments qui demeurent au cœur de **l'expertise orthodontique** [4].

À cela s'ajoute un **déficit de formation spécifique** : si l'intégration de l'IA dans les cursus paraît nécessaire, elle ne doit pas se faire au détriment des **bases cliniques fondées sur les preuves**. Le risque d'une adoption motivée par **l'effet de mode**, doublé de la **fatigue technologique** liée à **l'obsolescence rapide** des outils numériques, accentue les réticences [34]. Ces inquiétudes traduisent une interrogation plus large sur la **valeur réelle des "vérités statistiques"** produites par l'IA, souvent perçues comme insuffisantes pour se substituer au **raisonnement clinique** [109].

Enfin, il est à noter que **l'acceptation** de l'IA semble globalement plus élevée chez les orthodontistes et leurs équipes que chez les patients, ce qui reflète une dynamique d'appropriation contrastée [41].

3.3.2 Réactions des patients face à l'utilisation

Les réactions des **patients** face à l'intégration de l'IA en orthodontie oscillent entre **intérêt** et **méfiance**. Si certains voient dans ces outils un moyen d'améliorer l'**efficacité** et de faciliter l'**accès aux soins**, beaucoup expriment des **craintes** liées à la **perte de contact humain** et au risque de **déshumanisation** de la relation thérapeutique.

La téléconsultation assistée par l'IA illustre parfaitement cette notion. Bien qu'efficace sur le plan organisationnel, elle peut limiter l'accès à certaines dimensions relationnelles essentielles, notamment la **communication non verbale** et l'**appréciation fine du profil psychologique du patient**. Or, ces éléments participent à l'alliance thérapeutique et à l'observance, dont l'impact réel sur la qualité globale du traitement ne peut être évalué qu'à distance, plusieurs années après sa finalisation.

La **demande de transparence** reste forte : les patients souhaitent comprendre clairement le rôle joué par l'IA dans le diagnostic ou la planification, et s'assurer qu'elle demeure un **support au jugement clinique** plutôt qu'un substitut. SmileView® en est le parfait exemple, plus perçu comme un outil de communication que diagnostique, cela peut générer un décalage entre la simulation proposée et les résultats cliniques obtenus mettant en exergue les relations complexe de l'innovation technologique/ marketing avec la perception patient.

Par ailleurs, l'**âge** influence également le degré d'acceptabilité : les patients âgés de 18 à 55 ans se montrent globalement plus enclins à adopter des solutions numériques comme les consultations "*Virtual-First*", tandis que ceux de **plus de 55 ans** apparaissent plus réticents. Cette observation souligne l'importance de prendre en compte les **spécificités générationnelles** dans le déploiement de ces technologies [41]

3.3.3 Redéfinition des rôles dans l'équipe orthodontique

L'introduction de l'IA en orthodontie entraîne une **redéfinition progressive des rôles** au sein de l'**équipe soignante**. Certaines **tâches cognitives**, autrefois exclusivement assurées par l'orthodontiste, peuvent désormais être partiellement

automatisées ou **déléguées**, modifiant **l'organisation du travail** et le **périmètre d'action** des assistants. L'enjeu n'est pas une **substitution de l'humain** par la machine, mais l'émergence d'un **modèle collaboratif** où l'IA agit comme **partenaire de l'expertise clinique**. Cette évolution impose une **reconfiguration des compétences** : les orthodontistes de demain devront être capables d'opérer dans un **environnement technologique automatisé**, tout en préservant ce qui demeure irréductiblement **humain** (la communication avec le patient, le discernement clinique, l'éthique et la prise de décision complexe) [108]. L'intégration précoce de ces dimensions dans la **formation initiale** apparaît déterminante pour permettre aux praticiens de tirer parti des atouts de l'IA **sans en devenir dépendants**, et pour transformer l'outil numérique en **levier organisationnel** plutôt qu'en menace pour la profession.

3.3.4 Enjeux philosophiques et idéologiques

Au-delà des considérations **techniques, juridiques** ou **économiques**, l'intégration de l'IA dans le domaine de la santé (et en orthodontie) soulève également des **enjeux philosophiques et culturels** souvent sous-estimés. L'IA n'est pas qu'un simple outil : elle véhicule des conceptions de **l'humain** et du **soin** qui méritent d'être interrogées.

Certains auteurs, comme **Jean-Philippe Philibert** [109], relient le développement de l'IA à l'**idéologie transhumaniste**, qui postule que l'humain aurait atteint les limites de ses capacités physiques, intellectuelles ou biologiques. L'IA devient alors une **technologie de dépassement**, au même titre que les prothèses connectées, les substances dites *cognitives* ou l'ingénierie génétique. Ce courant ambitionne une **hybridation homme-machine**, effaçant les frontières biologiques et redéfinissant la condition humaine. Bien que parfois perçus comme extrêmes, ces discours influencent certaines orientations **politiques, économiques** et **scientifiques** contemporaines.

Dans cette perspective, l'IA acquiert un **statut prescriptif**, voire normatif. Comme le souligne le philosophe **Éric Sadin**, elle peut s'imposer comme une **autorité de vérité**, réduisant l'espace du **jugement humain**. Son pouvoir injonctif (*ce que l'algorithme recommande, on le suit*) peut conduire à une **forme d'aliénation décisionnelle**, où la rationalité humaine est déléguée à la machine.

En santé, cela se traduit par une **technologisation croissante du soin**, où les décisions cliniques sont influencées, voire déterminées par des logiques algorithmiques.

L'extension du rôle de l'IA s'inscrit dans une redéfinition de la **santé** elle-même. Depuis que l'**Organisation Mondiale de la Santé (OMS)** a élargi sa définition la concevant comme un **état de bien-être physique, mental et social complet** et non plus comme la seule absence de maladie [110], la frontière entre médical et non médical s'est déplacée. Cette définition légitime l'usage de technologies visant un bien-être généralisé, y compris dans des domaines qui relevaient autrefois de la sphère privée. Les **capteurs connectés**, les plateformes d'IA et applications de suivi deviennent ainsi de **nouveaux acteurs du soin**, parfois au détriment du rôle traditionnel du praticien.

En orthodontie, ces enjeux ne sont pas neutres. L'introduction massive **d'outils IA** dans le diagnostic, la planification et le suivi du traitement transforme la relation au patient, la nature des décisions cliniques, et le **statut du praticien**. Cette transition doit impérativement s'accompagner d'une **réflexion critique sur ses fondements idéologiques**, afin d'éviter une adoption aveugle ou dictée uniquement par les logiques de marché.

3.4 Enjeux économiques et industriels

3.4.1 Coût d'implémentation de l'IA en cabinet

L'implémentation de l'IA en cabinet orthodontique représente un **investissement financier conséquent**, incluant l'**achat de logiciels spécialisés**, l'**acquisition** ou la **mise à niveau du matériel informatique**, ainsi que les **coûts récurrents de maintenance** et de mises à jour [111]. Ce poids économique constitue un frein à l'**accessibilité** de ces technologies, aussi bien pour certains praticiens que pour une partie des patients. Cependant, l'analyse coûts-bénéfices ne peut se limiter à la dépense initiale. L'**automatisation de tâches chronophages**, telles que l'**indexation** et la **classification manuelle des images radiologiques et cliniques**, offre un **retour sur investissement fonctionnel** tangible. Plusieurs études montrent que l'IA permet d'atteindre une **précision élevée** et une **amélioration significative de l'efficacité temporelle** par rapport aux méthodes

manuelles, réduisant ainsi la **charge de travail de l'orthodontiste** et optimisant **l'organisation des soins** [102]. À long terme, ce gain de temps clinique peut se traduire par une **économie en ressources humaines** et une **meilleure rentabilité** de l'activité, positionnant l'IA non seulement comme un **coût d'implémentation**, mais aussi comme un **levier d'efficacité économique**.

3.4.2 Monopole technologique et dépendance aux fournisseurs

L'intégration de l'IA en orthodontie s'accompagne de risques liés à la **domination de grandes plateformes propriétaires**, qui imposent leurs **standards techniques** et **commerciaux**. Cette situation favorise une **dépendance des praticiens** à des systèmes fermés, limitant leur **marge de manœuvre** et générant des **coûts supplémentaires**. Le **manque d'interopérabilité** entre systèmes accentue ce problème : les **données** et **outils** ne circulent pas facilement d'une plateforme à l'autre, ce qui freine **l'efficacité clinique** et complique **l'adoption à grande échelle**.

3.4.3 Influence de l'industrie sur les protocoles cliniques

L'**influence croissante de l'industrie** dans le développement et la diffusion des solutions d'IA en orthodontie comporte le risque d'une **standardisation excessive des pratiques cliniques**. Les **protocoles thérapeutiques** pourraient être orientés par des **logiques de marché** plutôt que par une véritable **pertinence médicale**, avec des outils incitant les praticiens à suivre des **schémas prédéfinis** optimisés pour la **rentabilité** ou la **diffusion commerciale**. Une telle orientation pourrait réduire la **diversité des approches thérapeutiques**, gommer les **spécificités propres à chaque patient** et limiter **l'autonomie décisionnelle** du clinicien.

3.4.4 Impact environnemental

Au-delà des considérations cliniques et économiques, l'essor de l'intelligence artificielle soulève également un **enjeu environnemental**. Les centres de données, indispensables à l'entraînement et à l'utilisation des modèles d'IA, représentent une part non négligeable de la consommation électrique mondiale : en 2024, ils ont consommé environ **415 TWh, soit $\approx 1,5\%$ de l'électricité**

mondiale, et cette demande a augmenté régulièrement au fil des dernières années [112].

Pour assurer cette performance énergétique, les centres de données requièrent des **ressources matérielles importantes**, dont la fabrication et l'exploitation des serveurs et processeurs, qui contribuent aux émissions de gaz à effet de serre ainsi qu'à l'épuisement des ressources naturelles [113].

Par ailleurs, ces installations consomment également des **quantités significatives d'eau**, utilisées pour le refroidissement des infrastructures et indirectement via la production d'électricité, ce qui peut devenir critique dans les régions sujettes au stress hydrique [114]. Afin de visualiser, des grands centres de données peuvent consommer jusqu'à 19 millions de litres par jour, ce qui est équivalent à la consommation d'eau par une ville peuplée par 10 000 à 50 000 habitants [115].

L'intégration croissante d'outils d'IA dans des secteurs comme la santé implique ainsi non seulement une réflexion clinique, éthique et économique, mais aussi une analyse de leur **impact écologique global dans une perspective de développement durable des pratiques numériques**

3.5 Perspectives d'évolution et pistes de solutions

3.5.1 Vers une IA éthique, transparente et co-construite

L'un des principaux freins à l'adoption de l'IA en orthodontie réside dans son **opacité** : les modèles de deep learning, souvent perçus comme des « *boîtes noires* », délivrent des prédictions sans permettre au clinicien de comprendre sur quels critères elles reposent. Cette **absence d'explicabilité** nourrit la **méfiance**, complique la **validation clinique** et empêche de **justifier une décision médicale** en cas d'erreur. Le développement de l'**IA explicable (Explainable AI ou XAI)** constitue une réponse prometteuse : des méthodes comme **Grad-CAM** ou **DeConvNet** permettent de produire des **cartes de saillance** indiquant les zones de l'image ayant influencé la prédiction du modèle, renforçant ainsi la **confiance des praticiens** et favorisant une **prise de décision partagée et éthique** [116].

Au-delà de la transparence algorithmique, l'**accessibilité** et la **standardisation** des données sont essentielles. L'initiative de Liao *et al.* [66] qui ont rendu publics leurs jeux de données afin de faciliter la comparaison entre modèles, illustre l'intérêt de **stratégies de mutualisation**, dans le respect des exigences de **confidentialité**. En parallèle, l'**hétérogénéité méthodologiques** des études publiées (tailles d'échantillons, protocoles, métriques d'évaluation) freine la **reproductibilité scientifique**. Pour y remédier, Norgeot *et al.* [117] ont proposé la **checklist MI-CLAIM**, visant à uniformiser la méthodologie et la transparence des travaux d'IA clinique, garantissant ainsi une recherche plus **fiable** et **reproductible**.

Enfin, la construction d'**IA médicales responsables** suppose une **collaboration interdisciplinaire** étroite entre **cliniciens**, **ingénieurs** et **juristes**, afin d'assurer à la fois **pertinence clinique**, **robustesse technique** et **acceptabilité éthique**. À terme, la mise en place d'**instances de régulation professionnelle**, analogues à un « *Algorithm Board of Orthodontics* », pourrait offrir un cadre d'**évaluation indépendant** et **standardisé** des systèmes, consolidant leur intégration dans la pratique orthodontique [108].

3.5.2 Formation des professionnels à l'IA

L'intégration de l'IA dans la pratique orthodontique impose une adaptation profonde des **dispositifs pédagogiques**. L'IA peut constituer un **outil formateur précieux**, notamment pour les **jeunes praticiens** en début de carrière : en proposant des **plans de traitement alternatifs** et en permettant la **comparaison de différentes approches**, elle favorise l'acquisition rapide d'un **raisonnement clinique structuré**, tout en restant **complémentaire à l'expérience humaine** et sans prétendre la remplacer [102]. En parallèle, la **formation continue** des orthodontistes est indispensable pour leur permettre de comprendre la **logique** et les **limites** des systèmes d'IA, en particulier dans la **construction** et la **validation des jeux de données**, qui doivent être conçus et annotés par des **cliniciens expérimentés** [73]. De plus, même s'il existe des pairs qualifiés dans leurs domaines orthodontiques, à l'heure actuelle, il n'y a pas encore de praticiens pouvant se revendiquer comme **expert en orthodontie et en IA**, tant

la rencontre de ces deux domaines est récente. **L'intégration progressive de compétences numériques et technologiques**, dès la formation initiale puis tout au long de la carrière, constitue donc une condition essentielle pour créer de nouvelles **opportunités professionnelles**, où **l'expertise humaine** conserve sa **valeur centrale** malgré **l'automatisation croissante** [108].

3.5.3 Vers une orthodontie « augmentée »

Les perspectives offertes par l'IA en orthodontie dépassent le seul objectif d'alignement dentaire. De nouveaux champs d'application émergent, tels que **l'indexation automatisée des images**, **l'identification des caractéristiques occlusales** ou encore la **création de patients virtuels**, autant d'innovations qui illustrent la **progression de l'IA** dans la discipline [102].

Certaines étapes, comme **l'analyse des modèles d'étude** (encore largement manuelle et sujette à une variabilité inter-opérateurs) apparaissent particulièrement adaptées à une **automatisation future**. Des travaux préliminaires ont montré que l'IA pouvait déjà évaluer les **dimensions mésio-distales** des dents et prédire **la forme des arcades**, mais soulignent la nécessité de recherches supplémentaires pour développer des modèles plus **complets** et **fiables** [49,50].

Dans le même esprit, **l'évaluation des voies aériennes**, déterminante en orthodontie en raison de son influence sur la **croissance crânio-faciale** et la genèse de certaines **malocclusions**, bénéficie désormais de méthodes d'IA permettant une **analyse plus rapide** que les techniques traditionnelles, même si la **généralisabilité** des modèles reste encore limitée.

Ces avancées traduisent l'émergence d'un modèle **d'orthodontie « augmentée »**, où l'IA assiste le clinicien en améliorant la **précision**, **l'objectivité** et la **reproductibilité** des diagnostics, sans se substituer à son **expertise**. L'accumulation de travaux sur **l'imagerie 3D** et le développement **d'outils prédictifs** appliqués aux **schémas de croissance faciale** ou aux **indices de traitement orthodontique** laissent entrevoir une **standardisation progressive des diagnostics**, susceptible d'orienter les **pratiques cliniques**, mais aussi

d'alimenter les **politiques de santé publique** et **l'allocation rationnelle des ressources**.

Dans cette perspective, l'exploitation du deep learning pourrait, à terme, contribuer à l'avènement d'une orthodontie « **4P** » (**personnalisée, préventive, prédictive et participative**) où la technologie soutiendrait la **décision médicale** et enrichirait la **relation thérapeutique** [4].

CONCLUSION

L'**intelligence artificielle (IA)** s'impose désormais comme un vecteur majeur de transformation en orthodontie. En s'intégrant progressivement à chaque étape du **workflow orthodontique** (du **diagnostic** initial à la **planification thérapeutique**, de la **délivrance** à la **phase de suivi**), elle contribue à automatiser des tâches chronophages, à fiabiliser les analyses et à enrichir la personnalisation des traitements. Les bénéfices attendus, qu'il s'agisse de **gain de temps clinique**, de **réduction de la variabilité inter-praticiens** ou d'**amélioration de l'expérience patient**, traduisent le potentiel de ces technologies à redéfinir les standards de la spécialité.

Toutefois, cette intégration ne peut être envisagée sans une prise en compte rigoureuse des **défis techniques** (qualité et diversité des données, explicabilité des modèles), des **enjeux éthiques et juridiques** (confidentialité, responsabilité, équité d'accès), et des **transformations organisationnelles** qu'elle induit. L'IA ne saurait se substituer au **jugement clinique humain** : elle doit demeurer un **outil d'assistance**, venant soutenir l'expertise orthodontique plutôt que la remplacer.

Les **perspectives** ouvertes par ces innovations laissent entrevoir l'émergence d'une orthodontie « **augmentée** », plus **prédictive, préventive, personnalisée** et **participative**. Pour que cette évolution soit durable et bénéfique, elle doit s'accompagner d'une **formation adaptée des professionnels**, d'une **collaboration interdisciplinaire** étroite et de **cadres de régulation clairs** garantissant à la fois la protection des patients et la fiabilité des systèmes.

En définitive, l'intégration de l'intelligence artificielle en orthodontie ne constitue pas une simple modernisation technologique : elle représente un **changement de paradigme**, où la valeur ajoutée réside autant dans l'optimisation des procédures que dans la redéfinition du rôle du praticien et de sa relation au patient. C'est à cette condition que l'IA pourra s'affirmer non comme une menace, mais comme une **opportunité stratégique** pour l'avenir de la discipline.

TABLES DES FIGURES

Figure 1: intelligence artificielle, machine learning et deep learning [4]	5
Figure 2: classification du machine learning [12].....	7
Figure 3: schéma de divers réseaux neuronaux ; chronologie de développement [9]	10
Figure 4: illustration de réseau neuronal d'un cerveau humain [13].....	11
Figure 5: histoire de l'intelligence artificielle [15]	18
Figure 6: exemple d'un test de Turing [17]	19
Figure 7: Garry Kasparov vs Deep Blue, 10 février 1996 [18].....	20
Figure 8: workflow orthodontique classique [34]	25
Figure 9: photos cliniques classiques (illustration personnelle).....	28
Figure 10: exemple de tracé automatisé d'une téléradiographie de profil [56] .	31
Figure 11: illustration du Grad-CAM sur divers stades de maturations cervicales. Le rouge représente une grande attention, le bleu une petite [67].....	33
Figure 12: illustration du SmileView [92]	41
Figure 13: Clincheck Invisalign® [93].....	41
Figure 14: ScanBox de DentalMonitoring [102].....	45

TABLES DES TABLEAUX

Tableau 1 :termes décrivant les RNA [9]	12
Tableau 2 : comparaison entre réseau neuronal "avant" et "arrière" [9]	13

BIBLIOGRAPHIE

1. Muthukrishnan N, Maleki F, Ovens K, Reinhold C, Forghani B, Forghani R. Brief History of Artificial Intelligence. *Neuroimaging Clin N Am*. 2020;30(4):393-9.
2. Bouletreau P, Makaremi M, Ibrahim B, Louvrier A, Sigaux N. Artificial Intelligence: applications in orthognathic surgery. *J Stomatol Oral Maxillofac Surg*. 2019;120(4):347-54.
3. Liu J, Zhang C, Shan Z. Application of artificial intelligence in orthodontics: current state and future perspectives. *Healthcare (Basel)*. 2023;11(20):2760.
4. Foucart JM, Gillibert L, Chavanne A, Ripoche X. Le deep learning en orthodontie : vers une relation patient-praticien repensée. *Rev Orthopédie Dento-Faciale*. 2021;55(1):73-87.
5. Fawaz P, Sayegh PE, Vannet BV. What is the current state of artificial intelligence applications in dentistry and orthodontics? *J Stomatol Oral Maxillofac Surg*. 2023;124(5):101524.
6. Page J, Bain M, Mukhlis F. The risks of low level narrow artificial intelligence. In: *Proc IEEE Int Conf on Intell Saf Robot*. 2018. p. 1-6.
7. Goertzel B. Artificial general intelligence: concept, state of the art, and future prospects. *J Artif Gen Intell*. 2014;5(1) :1-48.
8. Yampolskiy RV. Artificial superintelligence: a futuristic approach. CRC Press; 2015. 216 p.
9. Cao B, Zhang KC, Wei B, Chen L. Status quo and future prospects of artificial neural network from the perspective of gastroenterologists. *World J Gastroenterol*. 2021;27(21):2681-709.
10. Faber J, Faber C, Faber P. Artificial intelligence in orthodontics. *APOS Trends Orthod*. 2019;9(4):201-5.
11. Sharma MS, Jadhav V, Bhuskute KP, Reche A. Artificial intelligence: an innovative approach in orthodontics: a narrative review. *J Clin Diagn Res*. 2023;17(12):7-11.
12. Singh S, Kaur N, Gehlot A. Application of artificial intelligence in drug design: a review. *Comput Biol Med*. 2024;179:108810.
13. Saba L, Biswas M, Kuppili V, Cuadrado Godia E, Suri HS, Edla DR, et al. The present and future of deep learning in radiology. *Eur J Radiol*. 2019;114:14-24.
14. He K, Zhang X, Ren S, Sun J. Identity mappings in deep residual networks. In: Leibe B, Matas J, Sebe N, Welling M, éditeurs. *Computer Vision – ECCV 2016*. Cham: Springer; 2016. p. 630-45.

16. Castelfranchi C. Alan Turing's « Computing machinery and intelligence ». *Topoi*. 2013;32(2):293-9.
17. Goda Y, Yamada M, Matsukawa H, Hata K, Yasunami S. Conversation with a Chatbot before an online EFL group discussion and the effects on critical thinking. *J Inf Syst Educ*. 2014;13(1):1-7.
19. Allareddy V, Rengasamy Venugopalan S, Nalliah RP, Caplin JL, Lee MK, Allareddy V. Orthodontics in the era of big data analytics. *Orthod Craniofac Res*. 2019;22(Suppl 1):8-13.
20. Esteva A, Kuprel B, Novoa RA, Ko J, Swetter SM, Blau HM, et al. Dermatologist-level classification of skin cancer with deep neural networks. *Nature*. 2017;542(7639):115-8.
21. Lee EJ, Kim YH, Kim N, Kang DW. Deep into the brain: artificial intelligence in stroke imaging. *J Stroke*. 2017;19(3):277-85.
22. Hogarty DT, Mackey DA, Hewitt AW. Current state and future prospects of artificial intelligence in ophthalmology: a review. *Clin Exp Ophthalmol*. 2019;47(1):128-39.
23. Bibault JE, Burgun A, Giraud P. Intelligence artificielle appliquée à la radiothérapie. *Cancer/Radiother*. 2017;21(3):239-43.
24. You W, Hao A, Li S, Wang Y, Xia B. Deep learning-based dental plaque detection on primary teeth: a comparison with clinical assessments. *BMC Oral Health*. 2020;20(1):141.
25. Poedjiastoeti W, Suebnukarn S. Application of convolutional neural network in the diagnosis of jaw tumors. *Healthc Inform Res*. 2018;24(3):236-41.
26. Albalawi F, Alamoud KA. Trends and application of artificial intelligence technology in orthodontic diagnosis and treatment planning: a review. *Appl Sci*. 2022;12(22):22:11864.
27. Monill-González A, Rovira-Calatayud L, d'Oliveira NG, Ustrell-Torrent JM. Artificial intelligence in orthodontics: Where are we now? A scoping review. *Orthod Craniofac Res*. 2021;24(Suppl 2):6-15
28. Nordblom NF, Büttner M, Schwendicke F. Artificial intelligence in orthodontics: critical review. *J Dent Res*. 2024;103(6):577-84.
29. Dipalma G, Inchingolo AD, Inchingolo AM, Piras F, Carpentiere V, Garofoli G, et al. Artificial intelligence and its clinical applications in orthodontics: a systematic review. *Diagnostics (Basel)*. 2023;13(24):3677.
30. Akdeniz BS, Tosun ME. A review of the use of artificial intelligence in orthodontics. *J Exp Clin Med*. 2021;38:157-62.

31. Makaremi M, Brondeau F de, Lacaule C, N'Kaoua B. Le workflow numérique au service de l'apprentissage clinique du praticien. *Orthod Fr.* 2020;91(1):93-9.
32. Vaid NR, Adel SM. Contemporary orthodontic workflows: a panacea for efficiency ? *Semin Orthod.* 2023;29(1):1-3.
33. Wilmes B, Drescher D. CAD-CAM workflows for palatal TAD anchored appliances. *Semin Orthod.* 2023;29(1):51-9.
34. Cattaneo PM, Cornelis MA. Digital workflows in orthodontic postgraduate training. *Semin Orthod.* 2023;29(1):4-10.
35. Rossini G, Parrini S, Castroflorio T, Deregibus A, Debernardi CL. Diagnostic accuracy and measurement sensitivity of digital models for orthodontic purposes: a systematic review. *Am J Orthod Dentofacial Orthop.* 2016;149(2):161-70.
36. Burzynski JA, Firestone AR, Beck FM, Fields HW, Deguchi T. Comparison of digital intraoral scanners and alginate impressions: time and patient satisfaction. *Am J Orthod Dentofacial Orthop.* 2018;153(4):534-41.
37. Grünheid T, McCarthy SD, Larson BE. Clinical use of a direct chairside oral scanner: an assessment of accuracy, time, and patient acceptance. *Am J Orthod Dentofacial Orthop.* 2014;146(5):673-82.
38. Alansari RA, Faydhi DA, Ashour BS, Alsaggaf DH, Shuman MT, Ghoneim SH, et al. Adult perceptions of different orthodontic appliances. *Patient Prefer Adherence.* 2019;13:2119-28.
39. Alansari RA. Youth Perception of different orthodontic appliances. *Patient Prefer Adherence.* 2020;14:1011-9.
40. Hansa I, Katyal V, Semaan SJ, Coyne R, Vaid NR. Artificial intelligence driven remote monitoring of orthodontic patients: clinical applicability and rationale. *Semin Orthod.* 2021;27(2):138-56.
41. Katyal V, Vaid N. Virtual-First: a virtual workflow for new patient consultation, engagement and education in orthodontics. *Semin Orthod.* 2023;29(1):109-15.
42. Mellor AC, Milgrom P. Dentists' attitudes toward frustrating patient visits: relationship to satisfaction and malpractice complaints. *Community Dent Oral Epidemiol.* 1995;23(1):15-9.
43. Sandler J, Dwyer J, Kokich V, McKeown F, Murray A, McLaughlin R, et al. Quality of clinical photographs taken by orthodontists, professional photographers, and orthodontic auxiliaries. *Am J Orthod Dentofacial Orthop.* 2009;135(5):657-62.

44. Ryu J, Lee YS, Mo SP, Lim K, Jung SK, Kim TW. Application of deep learning artificial intelligence technique to the classification of clinical orthodontic photos. *BMC Oral Health*. 2022;22(1):454.
45. Li S, Guo Z, Lin J, Ying S. Artificial intelligence for classifying and archiving orthodontic images. *Biomed Res Int*. 2022;2022(1):1473977.
46. Brook PH, Shaw WC. The development of an index of orthodontic treatment priority. *Eur J Orthod*. 1989;11(3):309-20.
47. Talaat S, Kaboudan A, Talaat W, Kusnoto B, Sanchez F, Elnagar MH, et al. The validity of an artificial intelligence application for assessment of orthodontic treatment need from clinical images. *Semin Orthod*. 2021;27(2):164-71.
48. Nan L, Tang M, Liang B, Mo S, Kang N, Song S, et al. Automated sagittal skeletal classification of children based on deep learning. *Diagnostics (Basel)*. 2023;13(10):1719.
49. Ali SM, Saloom HF, Tawfeeq MA. Artificial neural network for prediction of unerupted premolars and canines. *Int Med J*. 2021 ;28(Suppl 1):74-79.
50. Budiman J. Use of artificial neuron network to predict dental arch form. *Pesqui Bras Odontopediatria Clin Integr*. 2018;18(1):1-6.
51. Bishara SE, Ortho D, Jakobsen JR, Treder J, Nowak A. Arch width changes from 6 weeks to 45 years of age. *Am J Orthod Dentofacial Orthop*. 1997;111(4):401-9.
52. King CH, Wang YL, Lin WY, Tsai CL. Automatic cephalometric landmark detection on X-ray images using object detection. In: *Proc IEEE Int Symp Biomed Imaging* . 2022 .p. 1-4.
53. Yao J, Zeng W, He T, Zhou S, Zhang Y, Guo J, et al. Automatic localization of cephalometric landmarks based on convolutional neural network. *Am J Orthod Dentofacial Orthop*. 2022;161(3):e250-9.
54. Yu HJ, Cho SR, Kim MJ, Kim WH, Kim JW, Choi J. Automated skeletal classification with lateral cephalometry based on artificial intelligence. *J Dent Res*. 2020;99(3):249-56.
56. Gil SM, Kim I, Cho JH, Hong M, Kim M, Kim SJ, et al. Accuracy of auto-identification of the posteroanterior cephalometric landmarks using cascade convolution neural network algorithm and cephalometric images of different quality from nationwide multiple centers. *Am J Orthod Dentofacial Orthop*. 2022;161(4):e361-71.
57. Dot G, Schouman T, Chang S, Rafflenbeul F, Kerbrat A, Rouch P, et al. Automatic three-dimensional cephalometric landmarking via deep learning. *J Dent Res*. 2022;101(11):1380-7.

58. Kim MJ, Liu Y, Oh SH, Ahn HW, Kim SH, Nelson G. Automatic cephalometric landmark identification system based on the multi-stage convolutional neural networks with CBCT images. *Sensors (Basel)*. 2021;21(2):505.
59. Kim MJ, Liu Y, Oh SH, Ahn HW, Kim SH, Nelson G. Evaluation of a multi-stage convolutional neural network-based fully automated landmark identification system using cone-beam computed tomographysynthesized posteroanterior cephalometric images. *Korean J Orthod*. 2021;51(2):77-85.
60. Croquet B, Matthews H, Mertens J, Fan Y, Nauwelaers N, Mahdi S, et al. Automated landmarking for palatal shape analysis using geometric deep learning. *Orthod Craniofac Res*. 2021;24(Suppl 2):144-52.
61. Rao GKL, Srinivasa AC, Iskandar YHP, Mokhtar N. Identification and analysis of photometric points on 2D facial images: a machine learning approach in orthodontics. *Health Technol*. 2019;9(5):715-24.
62. Baccetti T, Franchi L, McNamara JA. An improved version of the cervical vertebral maturation method for the assessment of mandibular growth. *Angle Orthod*. 2002;72(4):316-23.
63. Ferrillo M, Curci C, Roccuzzo A, Migliario M, Invernizzi M, de Sire A. Reliability of cervical vertebral maturation compared to hand-wrist for skeletal maturation assessment in growing subjects: a systematic review. *J Back Musculoskelet Rehabil*. 2021;34(6):925-36.
64. Seo H, Hwang J, Jeong T, Shin J. Comparison of deep learning models for cervical vertebral maturation stage classification on lateral cephalometric radiographs. *J Clin Med*. 2021;10(16):3591.
65. Khazaei M, Mollabashi V, Khotanlou H, Farhadian M. Automatic determination of pubertal growth spurts based on the cervical vertebral maturation staging using deep convolutional neural networks. *J World Fed Orthod*. 2023;12(2):56-63.
66. Liao N, Dai J, Tang Y, Zhong Q, Mo S. iCVM: An interpretable deep learning model for CVM assessment under label uncertainty. *IEEE J Biomed Health Inform*. 2022;26(8):4325-34.
67. Lopatiene K, Babarskas A. Malocclusion and upper airway obstruction. *Medicina (Kaunas)*. 2002;38(3):277-83.
68. Jeong Y, Nang Y, Zhao Z. Automated evaluation of upper airway obstruction based on deep learning. *BioMed Res Int*. 2023;2023:8231425.
69. Dong W, Chen Y, Li A, Mei X, Yang Y. Automatic detection of adenoid hypertrophy on cone-beam computed tomography based on deep learning. *Am J Orthod Dentofacial Orthop*. 2023;163(4):553-560.e3.

70. Shujaat S, Jazil O, Willems H, Van Gerven A, Shaheen E, Politis C, et al. Automatic segmentation of the pharyngeal airway space with convolutional neural network. *J Dent*. 2021;111:103705.
73. Prasad J, Mallikarjunaiah DR, Shetty A, Gandedkar N, Chikkamuniswamy AB, Shivashankar PC. Machine learning predictive model as clinical decision support system in orthodontic treatment planning. *Dent J*. 2022;11(1):1.
74. El-Dawlatly MM, Abdelmaksoud AR, Amer OM, El-Dakrouy AE, Mostafa YA. Evaluation of the efficiency of computerized algorithms to formulate a decision support system for deepbite treatment planning. *Am J Orthod Dentofacial Orthop*. 2021;159(4):512-21.
75. Ceylan I, Eröz UB. The effects of overbite on the maxillary and mandibular morphology. *Angle Orthod*. 2001;71(2):110-5.
76. M El-Dawlatly M, M Salah Fayed M, Mohamed Heider A, A Mostafa Y. Deep bite: A treatment planning decision support scheme. *Dent Oral Craniofacial Res*. 2015;1(3):81-89
77. Xu L, Mei L, Lu R, Li Y, Li H, Li Y. Predicting patient experience of Invisalign treatment: An analysis using artificial neural network. *Korean J Orthod*. 2022;52(4):268-77.
78. Xing L, Zhang X, Guo Y, Bai D, Xu H. XGBoost-aided prediction of lip prominence based on hard-tissue measurements and demographic characteristics in an Asian population. *Am J Orthod Dentofacial Orthop*. 2023;164(3):357-67.
79. Leite AF, Gerven AV, Willems H, Beznik T, Lahoud P, Gaêta-Araujo H, et al. Artificial intelligence-driven novel tool for tooth detection and segmentation on panoramic radiographs. *Clin Oral Investig*. 2021;25(4):2257-67.
80. Alqahtani KA, Jacobs R, Smolders A, Van Gerven A, Willems H, Shujaat S, et al. Deep convolutional neural network-based automated segmentation and classification of teeth with orthodontic brackets on cone-beam computed-tomographic images: a validation study. *Eur J Orthod*. 2023;45(2):169-74.
81. Hu X, Zhao Y, Yang C. Evaluation of root position during orthodontic treatment via multiple intraoral scans with automated registration technology. *Am J Orthod Dentofacial Orthop*. 2023;164(2):285-92.
82. Real AD, Real OD, Sardina S, Oyonarte R. Use of automated artificial intelligence to predict the need for orthodontic extractions. *Korean J Orthod*. 2022;52(2):102-11.
83. Leavitt L, Volovic J, Steinhauer L, Mason T, Eckert G, Dean JA, et al. Can we predict orthodontic extraction patterns by using machine learning? *Orthod Craniofac Res*. 2023;26(4):552-9.

84. Patcas R, Bernini DAJ, Volokitin A, Agustsson E, Rothe R, Timofte R. Applying artificial intelligence to assess the impact of orthognathic treatment on facial attractiveness and estimated age. *Int J Oral Maxillofac Surg*. 2019;48(1):77-83.
85. Chaiprasittikul N, Thanathornwong B, Pornprasertsuk-Damrongsri S, Raocharernporn S, Maponthong S, Manopatanakul S. Application of a Multi-Layer Perceptron in Preoperative Screening for Orthognathic Surgery. *Healthc Inform Res*. 2023;29(1):16-22.
86. Cheng M, Zhang X, Wang J, Yang Y, Li M, Zhao H, et al. Prediction of orthognathic surgery plan from 3D cephalometric analysis via deep learning. *BMC Oral Health*. 2023;23(1):161.
87. Tanikawa C, Yamashiro T. Development of novel artificial intelligence systems to predict facial morphology after orthognathic surgery and orthodontic treatment in Japanese patients. *Sci Rep*. 2021;11(1):15853.
88. Hoang V, Vuong TQT, Nguyen PH, Pham NH, Hoang KL, Hoang TTT, et al. AI-assisted design of 3D-printed lingual iindirect bonding trays: a comparative evaluation of bracket transfer accuracy. *J Clin Med*. 2025;14(12):4303.
89. Chazalon JF. L'intelligence artificielle et Invisalign : mythes et réalités. *Rev Orthop Dento-Faciale*. 2019;53(4):373-83.
90. Adel SM, Bichu YM, Pandian SM, Sabouni W, Shah C, Vaid N. Clinical audit of an artificial intelligence (AI) empowered smile simulation system: a prospective clinical trial. *Sci Rep*. 2024;14(1):19385.
93. Alam MK, Awawdeh M, Alhazmi N, Abalkhail KA, Iyer K, Abutayyem H, et al. A systematic review of interventions: does Invisalign move teeth as effectively as orthodontic fixed appliances? *Scientifica*. 2024;2024:4268902.
94. SFODF. La contention en orthodontie: recommandations de bonne pratique. *Orthod Fr*. 2023;94(Suppl 1):1-61.
95. Gera A, Pullisaar H, Cattaneo PM, Gera S, Vandevska-Radunovic V, Cornelis MA. Stability, survival, and patient satisfaction with CAD/CAM versus conventional multistranded fixed retainers in orthodontic patients: a 6-month follow-up of a two-centre randomized controlled clinical trial. *Eur J Orthod*. 2023;45(1):58-67.
96. Tsihlaki A, Chin SY, Pandis N, Fleming PS. How long does treatment with fixed orthodontic appliances last? A systematic review. *Am J Orthod Dentofacial Orthop*. 2016;149(3):308-18.
97. Mohammed H, Morsi A, Wafaie K, Daniel BK, Farella M. Patients' perspectives of the long-term impact of orthodontic treatment: a qualitative study. *Angle Orthod*. 2025;95(2):205-11.

98. Sharif MO, Siddiqui NR, Hodges SJ. Patient awareness of orthodontic mobile phone apps. *J Orthod.* 2019;46(1):51-5.
99. Caruso S, Caruso S, Pellegrino M, Skafi R, Nota A, Tecco S. A Knowledge-based algorithm for automatic monitoring of orthodontic treatment: the Dental Monitoring system: two cases. *Sensors.* 2021;21(5):1856.
100. Sangalli L, Savoldi F, Dalessandri D, Bonetti S, Gu M, Signoroni A, et al. Effects of remote digital monitoring on oral hygiene of orthodontic patients: a prospective study. *BMC Oral Health.* 2021;21(1):435.
102. Gracea RS, Winderickx N, Vanheers M, Hendrickx J, Preda F, Shujaat S, et al. Artificial intelligence for orthodontic diagnosis and treatment planning: A scoping review. *J Dent.* 2025;152:105442.
103. Bao C, Pu Y, Zhang Y. Fractional-order deep backpropagation neural network. *Comput Intell Neurosci.* 2018;2018:7361628.
104. Wolff J, Matschinske J, Baumgart D, Pytlik A, Keck A, Natarajan A, et al. Federated machine learning for a facilitated implementation of Artificial Intelligence in healthcare: a proof-of-concept study for the prediction of coronary artery calcification scores. *J Integr Bioinforma.* 2022;19(4).
105. Attaran M. Blockchain technology in healthcare: Challenges and opportunities. *Int J Healthc Manag.* 2022;15(1):70-83.
106. Allareddy V, Rampa S, Venugopalan SR, Elnagar MH, Lee MK, Oubaidin M, et al. Blockchain technology and federated machine learning for collaborative initiatives in orthodontics and craniofacial health. *Orthod Craniofac Res.* 2023;26(Suppl 1):118-23.
107. Dot G, Gajny L, Ducret M. Les enjeux de l'intelligence artificielle en odontologie. *Med/Sci (Paris).* 2024;40(1):79-84.
108. Vaid NR. Artificial Intelligence (AI) driven orthodontic care: a quest toward utopia? *Semin Orthod.* 2021;27(2):57-61.
109. Philibert A. L'intelligence artificielle, avenir de l'intelligence ou intelligence de l'avenir ? *Orthod Fr.* 2020;91(1):139-44.
111. Strunga M, Urban R, Surovková J, Thurzo A. Artificial intelligence systems assisting in the assessment of the course and retention of orthodontic treatment. *Healthcare (Basel).* 2023;11(5):683.
116. Singh A, Sengupta S, Lakshminarayanan V. Explainable deep learning models in medical image analysis. *J Imaging.* 2020;6(6).
117. Norgeot B, Quer G, Beaulieu-Jones BK, Torkamani A, Dias R, Gianfrancesco M, et al. Minimum information about clinical artificial intelligence modeling: the MI-CLAIM checklist. *Nat Med.* 2020;26(9):1320-4.

WEBOGRAPHIE

15. Histoire de l'intelligence artificielle : création & évolution de l'IA [Internet]. WiziShop ; [cité 28 juill 2025]. Disponible sur : <https://www.wizishop.fr/blog/histoire-intelligence-artificielle>
18. Il y a 25 ans : Deep Blue battait Kasparov [Internet]. ChessBase ; 2021 [cité 20 août 2025] Disponible sur : <https://fr.chessbase.com/post/il-y-a-25-ans-deep-blue-battait-kasparov>

55. Landmarks and tracing done by AI driven fully automated software “WebCeph”™. [Internet] ResearchGate ; [cité 8 sept 2025]. Disponible sur : https://www.researchgate.net/figure/Landmarks-and-tracing-done-by-AI-driven-fully-automated-software-WebCeph_fig2_360059594
71. Nabla · L’assistant médical qui vous libère du temps [Internet]. [cité 1 août 2025]. Disponible sur : <https://www.nabla.com/fr>
72. Témoignages des associés - ClinicPilot [Internet]. Tella ; [cité 17 févr 2026]. Disponible sur : <https://www.tella.tv/video/cmg6qf3pq00080bkyd4fy11xt/view>
91. Smile view simulator [Internet]. Google. [cité 12 août 2025]. Disponible sur: <https://www.google.com/search?q=smile+view+simulator>
92. ClinCheck Pro - Invisalign - Discover new possibilities [Internet]. Invisalign ; [cité 9 sept 2025]. Disponible sur : <http://www.invisalign-g6.com/fr-XB/clincheckpro.aspx>
101. Pour les patients [Internet]. DentalMonitoring ; [cité 9 sept 2025]. Disponible sur : <https://dentalmonitoring.com/fr/pour-les-patients/>
110. Constitution de l’Organisation mondiale de la santé [Internet]. Organisation mondiale de la santé ; [cité 2025 sept 2]. Disponible sur : <https://apps.who.int/gb/bd/PDF/bd47/FR/constitution-fr.pdf>
112. Energy demand from AI [Internet]. International Energy Agency; [cité 2026 févr 18]. Disponible sur: <https://www.iea.org/reports/energy-and-ai/energy-demand-from-ai>
113. Centre de données [Internet]. Wikipédia ; 2026 [cité 2026 févr 18]. Disponible sur : https://fr.wikipedia.org/w/index.php?title=Centre_de_donn%C3%A9es&oldid=233269056
114. Énergie, environnement, IA : Les data centers en sept questions [Internet] Vie-publique.fr ; 2026 [cité 18 févr 2026]. Disponible sur: <https://www.vie-publique.fr/questions-reponses/297730-energie-environnement-ia-les-data-centers-en-sept-questions>
115. Data centers and water consumption [Internet]. Environmental and Energy Study Institute; 2023 [cité 2026 févr 18]. Disponible sur: <https://www.eesi.org/papers/view/data-centers-and-water-consumption>

Thèse d'exercice : Chir. Dent. : Lille : Année 2026
IMPACT DE L'INTELLIGENCE ARTIFICIELLE SUR L'OPTIMISATION DU WORKFLOW EN ORTHODONTIE / Louis LESPINASSE. - p. 88 : ill. 14 ; réf. 117. <u>Domaines</u> : ORTHOPÉDIE DENTO-FACIALE Mots clés Libres : Orthodontie – Intelligence Artificielle – Workflow – Diagnostic orthodontique – Aide à la décision clinique – Deep Learning Résumé de la thèse en français L'intelligence artificielle (IA) s'intègre progressivement en orthodontie, discipline reposant sur un flux de travail structuré et l'analyse de données cliniques. Ce travail analyse son impact sur l'optimisation du workflow, de la première consultation au suivi. En phase diagnostique, l'IA automatise le tri des images, la céphalométrie et l'analyse occlusale, améliorant précision et reproductibilité. Elle intervient également dans la planification thérapeutique via des modèles prédictifs d'aide à la décision. En phase de délivrance, elle participe à la standardisation des procédures et à la personnalisation des dispositifs. Le suivi est transformé par le monitoring à distance et la détection automatisée d'événements cliniques. Cependant, des limites persistent : qualité des données, biais algorithmiques et manque de validation externe. L'IA ne peut reproduire le raisonnement clinique global du praticien. Son intégration soulève aussi des enjeux éthiques, juridiques et organisationnels. Ainsi, l'IA constitue un outil d'assistance prometteur, à intégrer dans un cadre rigoureux centré sur le jugement clinique. <u>JURY</u> : Président : Mme le professeur Caroline Delfosse Assesseurs : Mme le Docteur Nathalie Fournou-Moretti M le Docteur Jérôme Vandomme, M le Docteur Xavier Coutel