



جامعة ميدأوشن

كلية الإدارة

ماجستير الادارة الصحية

نظام دعم القرار التشخيصي القائم على الذكاء الاصطناعي في الأشعة البانورامية لأطباء الأسنان: دراسة
تطبيقية لتحسين دقة التشخيص وجودة القرار الطبي

**AI-Based Diagnostic Decision Support System for Panoramic Radiography
in Dentistry: An Applied Study to Improve Diagnostic Accuracy and Clinical
Decision Quality**

إعداد الطالب/

محمد عبد الرزاق هوساوى

الرقم الجامعي/

251003347

إشراف/

د. الفیصل عبد الحمید محمد حسن

2025





سُرُشَکَر و قَفَر

المستخلص

تهدف هذه الدراسة إلى تطوير وتقييم نظام دعم القرار التشخيصي القائم على الذكاء الاصطناعي لتحسين دقة تفسير الأشعة البانورامية في طب الأسنان وتعزيز جودة القرار الطبي. تواجه ممارسة طب الأسنان تحديات متزايدة في تفسير الأشعة البانورامية بدقة عالية، حيث تشير الدراسات إلى أن معدل الأخطاء التشخيصية يتراوح بين 15-25% نتيجة عوامل متعددة منها التعب البشري وضغط الوقت والتعقيد المتزايد للحالات المرضية.

اتبعت الدراسة المنهج المختلط الذي يجمع بين المنهج الكمي لقياس دقة النظام وكفاءته، والمنهج النوعي لفهم تجربة المستخدمين، والمنهج التطبيقي لتطوير واختبار النظام عملياً. تم تصميم الدراسة وفقاً للتصميم التجريبي المقارن مع مجموعة تجريبية تستخدم النظام المطور ومجموعة ضابطة تستخدم الطرق التقليدية. يتكون النظام المقترح من أربعة مكونات أساسية: خوارزميات التعلم الآلي المتقدمة القائمة على الشبكات العصبية التحويلية، قاعدة بيانات شاملة من 10,000-15,000 صورة أشعة بانورامية مصنفة من قبل خبراء، واجهة مستخدم تفاعلية مصممة وفقاً لمبادئ سهولة الاستخدام الطبي، ونظام أتمتة تعاوني يحقق التوازن بين القدرات التقنية والخبرة البشرية.

تتضمن متغيرات الدراسة المتغير المستقل المتمثل في نظام دعم القرار التشخيصي، والمتغيرات التابعة الشاملة لمؤشرات الأداء التشخيصي (الدقة، الحساسية، النوعية، القيم التنبؤية)، ومتغيرات الكفاءة (الوقت المطلوب للتشخيص، عدد الحالات المعالجة، معدل الأخطاء، مستوى الثقة في القرار)، ومتغيرات الرضا والقبول (مستوى رضا الأطباء، سهولة الاستخدام، المنفعة المدركة، النية للاستخدام المستقبلي). كما تشمل الدراسة متغيرات وسيطة مثل مستوى خبرة الطبيب ونوع الحالة المرضية وجودة الصورة الإشعاعية.

من المتوقع أن تساهم نتائج هذه الدراسة في تحسين دقة التشخيص الإشعاعي في طب الأسنان، تقليل الأخطاء التشخيصية، توفير الوقت اللازم للتحليل، وزيادة كفاءة العمل السريري. كما ستقدم الدراسة إطاراً نظرياً وتطبيقياً قابلاً للتكرار في مجالات طبية أخرى، وستساهم في تطوير المعرفة العلمية في مجال تطبيقات الذكاء الاصطناعي الطبي. تتميز الدراسة بنهجها التعاوني بين الذكاء الاصطناعي والذكاء البشري، مما يضمن احتفاظ الطبيب بدوره المحوري في اتخاذ القرار النهائي بينما يوفر النظام دعماً تحليلياً متقدماً لتعزيز دقة التشخيص وجودة الرعاية الصحية المقدمة للمرضى.

الكلمات المفتاحية: نظام دعم القرار التشخيصي، الذكاء الاصطناعي، الأشعة البانورامية، طب الأسنان، التعلم الآلي، التشخيص الطبي، جودة الرعاية الصحية.

المحتويات

1.....	مقدمة الدراسة.....
6.....	أولاً: مشكلة الدراسة.....
7.....	ثانياً: أهمية الدراسة.....
9.....	ثالثاً: أهداف الدراسة.....
10.....	رابعاً: تساؤلات أو فرضيات الدراسة.....
11.....	خامساً: الفرضيات:.....
11.....	سادساً: المتغيرات.....
28.....	سابعاً: حدود الدراسة.....
29.....	ثامناً: منهجية البحث.....
32.....	تاسعاً: هيكل الدراسة.....
36.....	المراجع الأولية.....

مقدمة الدراسة

يشهد العالم اليوم ثورة تكنولوجية حقيقية في مجال الرعاية الصحية، حيث تتسارع وتيرة تطبيق التقنيات الذكية والذكاء الاصطناعي في مختلف التخصصات الطبية. وفي هذا السياق، يبرز مجال طب الأسنان كأحد أهم المجالات التي تستفيد من هذا التطور التقني، خاصة في مجال التشخيص الإشعاعي الذي يعتبر حجر الأساس في تقديم الرعاية السنية المتميزة. إن التشخيص الدقيق والسريع يمثل القاعدة الأساسية لأي علاج ناجح، ومن هنا تأتي أهمية تطوير أنظمة تقنية متقدمة تدعم الأطباء في اتخاذ قرارات تشخيصية سليمة ومدروسة.

تعتبر الأشعة البانورامية للأسنان من أهم الأدوات التشخيصية المستخدمة في طب الأسنان الحديث، حيث توفر صورة شاملة للفكين والأسنان والهياكل المجاورة في صورة واحدة. هذه التقنية الإشعاعية، التي تطورت بشكل كبير منذ اختراعها في منتصف القرن العشرين، تمكن أطباء الأسنان من تشخيص مجموعة واسعة من الحالات المرضية شاملة التسوس العميق، أمراض اللثة المتقدمة، الكيسات والأورام، التشوهات الخلقية، ومشاكل مفصل الفك الصدغي. إلا أن تفسير هذه الأشعة يتطلب خبرة واسعة ووقتاً كافياً، كما أنه عرضة للأخطاء البشرية نتيجة عوامل متعددة منها التعب، ضغط الوقت، وتعقيد الحالات المرضية.

في هذا الإطار، تشير الدراسات العلمية الحديثة إلى أن معدل الأخطاء في تفسير الأشعة الطبية عموماً يتراوح بين 3% إلى 5% في الحالات العادية، وقد يصل إلى 30% في الحالات المعقدة أو في بيئات العمل عالية الضغط. هذه الإحصائيات تسلط الضوء على الحاجة الملحة لتطوير أدوات تقنية تدعم الأطباء في عملية التشخيص وتقلل من احتمالية الخطأ البشري. من جانب آخر، فإن الوقت المطلوب لتحليل الأشعة البانورامية

بدقة يتراوح بين 5 إلى 15 دقيقة للحالة الواحدة، وهو ما يشكل تحدياً في العيادات المزدحمة حيث يتعامل الطبيب مع عشرات الحالات يومياً.

لقد شهد مجال الذكاء الاصطناعي تطوراً مذهلاً خلال العقد الماضي، خاصة في مجال التعلم العميق ومعالجة الصور، مما فتح آفاقاً جديدة أمام تطبيقاته في المجال الطبي. تقنيات الشبكات العصبية الاصطناعية، وبالتحديد الشبكات العصبية التحويلية، أثبتت قدرتها الفائقة على تحليل الصور الطبية بدقة تضاهي أو تفوق أحياناً دقة الخبراء البشريين. هذا التطور التقني يوفر فرصة ذهبية لتطوير أنظمة دعم القرار التشخيصي التي تجمع بين قوة الحوسبة الذكية وخبرة الأطباء البشرية، مما يحقق نتائج تشخيصية متميزة تخدم المرضى وتحسن من جودة الرعاية الصحية.

إن مفهوم أنظمة دعم القرار السريري ليس جديداً في المجال الطبي، حيث بدأت المحاولات الأولى لتطوير هذه الأنظمة في السبعينيات من القرن الماضي. إلا أن التطورات التقنية الحديثة، وخاصة في مجال التعلم الآلي والذكاء الاصطناعي، أعطت دفعة قوية لهذه الأنظمة وجعلتها أكثر دقة وفاعلية. أنظمة دعم القرار السريري المعاصرة تتميز بقدرتها على معالجة كميات هائلة من البيانات الطبية، تحليل الأنماط المعقدة، والتعلم المستمر من الخبرات السابقة، مما يجعلها أدوات قوية لتعزيز قدرات الأطباء التشخيصية.

في مجال طب الأسنان تحديداً، بدأت تطبيقات الذكاء الاصطناعي تظهر بوضوح في السنوات الأخيرة، حيث تم تطوير أنظمة لتشخيص التسوس، كشف أمراض اللثة، تحليل الصور الإشعاعية، وحتى التخطيط للعلاجات المختلفة. هذه التطبيقات أثبتت جدواها العملية وأظهرت نتائج مبشرة في تحسين دقة التشخيص وكفاءة العمل السريري. إلا أن معظم هذه الأنظمة ما زالت في مراحل التطوير أو التطبيق المحدود، ولم تصل بعد إلى مرحلة التطبيق الواسع في الممارسة السريرية اليومية.

تتميز الأشعة البانورامية بخصائص فريدة تجعلها مجالاً مثالياً لتطبيق تقنيات الذكاء الاصطناعي. فهي توفر صورة موحدة وشاملة تغطي منطقة واسعة من الوجه والفكين، مما يسمح بتحليل شامل للهياكل التشريحية المختلفة في إطار واحد. كما أن هذه الأشعة تتبع بروتوكولات تصوير موحدة نسبياً، مما يسهل من عملية تطوير خوارزميات الذكاء الاصطناعي وتدريبها بفاعلية. إضافة إلى ذلك، فإن حجم البيانات المتاحة من الأشعة البانورامية كبير نسبياً مقارنة بأنواع أخرى من الأشعة المتخصصة، مما يوفر قاعدة بيانات غنية لتدريب النماذج الذكية.

من ناحية أخرى، فإن التحديات التي تواجه تفسير الأشعة البانورامية متنوعة ومعقدة. فهذه الأشعة تتطلب من الطبيب تحليل هياكل تشريحية متعددة ومتداخلة، البحث عن علامات مرضية دقيقة قد تكون خفية، وتمييز بين التغيرات الطبيعية والمرضية. كما أن جودة الصورة قد تتأثر بعوامل متعددة مثل حركة المريض، إعدادات الجهاز، أو خصائص المريض الفيزيائية. هذه التعقيدات تجعل من تطوير نظام ذكي فعال تحدياً تقنياً وعلمياً كبيراً، إلا أنها في الوقت نفسه تبرر الحاجة الملحة لمثل هذا النظام.

إن التطور المتسارع في تقنيات معالجة الصور الرقمية والتعلم العميق يوفر إمكانيات هائلة لتطوير أنظمة تشخيصية متقدمة. الشبكات العصبية التحويلية، على سبيل المثال، أثبتت قدرتها الاستثنائية على تحليل التفاصيل الدقيقة في الصور الطبية، كشف الأنماط المعقدة، والتمييز بين الحالات الطبيعية والمرضية بدقة عالية. تقنيات مثل Transfer Learning تسمح بالاستفادة من النماذج المدربة مسبقاً وتكييفها للتطبيقات الطبية المتخصصة، مما يقلل من الوقت والموارد المطلوبة للتطوير. كما أن تقنيات Data Augmentation تمكن من زيادة حجم البيانات التدريبية وتحسين قدرة النماذج على التعامل مع الحالات المتنوعة.

في السياق الإقليمي والمحلي، تواجه أنظمة الرعاية الصحية تحديات متزايدة في تقديم خدمات عالية الجودة مع الموارد المحدودة. الطلب المتزايد على خدمات طب الأسنان، النقص في عدد الأطباء المتخصصين في بعض المناطق، والحاجة لتحسين كفاءة العمل السريري، كلها عوامل تجعل من تطوير أدوات تقنية مساعدة ضرورة حتمية وليس مجرد ترف تقني. إن نظام دعم القرار التشخيصي المقترح يمكن أن يساهم في مواجهة هذه التحديات من خلال تحسين دقة التشخيص، تسريع عملية اتخاذ القرار، ودعم الأطباء في الحالات المعقدة.

لقد أظهرت الدراسات العلمية الحديثة نتائج مشجعة في تطبيق الذكاء الاصطناعي على تحليل الأشعة الطبية المختلفة. في مجال الأشعة البانورامية للأسنان تحديداً، حققت بعض الأنظمة المطورة دقة تشخيصية تتراوح بين 85% إلى 95% في كشف التسوس وأمراض اللثة، وهي نتائج تضاهي أو تفوق أداء الأطباء في بعض الحالات. إلا أن معظم هذه الدراسات أجريت في بيئات بحثية محكومة، ولم تختبر بعد في ظروف الممارسة السريرية الحقيقية حيث تتنوع جودة الصور والحالات المرضية بشكل أكبر.

إن تطوير نظام دعم القرار التشخيصي الفعال يتطلب نهجاً متعدد التخصصات يجمع بين خبرات الأطباء المتخصصين، خبراء الذكاء الاصطناعي، مهندسي البرمجيات، وخبراء تجربة المستخدم. هذا التعاون المتكامل ضروري لضمان أن النظام المطور لا يكون متقدماً تقنياً فحسب، بل يكون أيضاً عملياً وقابلاً للاستخدام في البيئة السريرية الحقيقية. كما أن فهم احتياجات المستخدمين النهائيين وتحدياتهم اليومية أمر بالغ الأهمية لضمان تبني النظام واستخدامه بفاعلية.

من الناحية التقنية، يتطلب تطوير مثل هذا النظام التغلب على تحديات متعددة شاملة جمع وتنظيم كميات كبيرة من البيانات عالية الجودة، تطوير خوارزميات قادرة على التعامل مع تنوع وتعقيد الصور الإشعاعية، ضمان سرعة الأداء والموثوقية في البيئة السريرية، وتوفير واجهة مستخدم بديهية وسهلة الاستخدام. كما أن

دمج النظام مع أنظمة إدارة المعلومات الطبية الموجودة يعتبر تحدياً إضافياً يتطلب تخطيطاً دقيقاً وتنفيذاً محكماً.

إن الهدف من هذه الدراسة ليس تطوير نظام يحل محل الطبيب البشري، بل تطوير أداة ذكية تدعم الطبيب وتعزز من قدراته التشخيصية. هذا النهج التعاوني بين الذكاء الاصطناعي والذكاء البشري يمثل الاتجاه الحديث في تطبيقات الذكاء الاصطناعي الطبي، حيث تكمل التقنية نقاط القوة البشرية وتعوض نقاط الضعف، مما يحقق نتائج أفضل من استخدام أي منهما منفرداً. الطبيب يحتفظ بدوره المحوري في اتخاذ القرار النهائي، بينما يوفر النظام الذكي معلومات إضافية ودعماً تحليلياً يساعد في اتخاذ قرارات أكثر دقة ووثوقية.

كما تسعى هذه الدراسة إلى تحقيق التوازن بين التقدم التقني والاعتبارات الأخلاقية والقانونية المرتبطة بتطبيق الذكاء الاصطناعي في المجال الطبي. حماية خصوصية المرضى، ضمان شفافية القرارات التشخيصية، وتوفير آليات للمساءلة والتحقق من صحة النتائج، كلها اعتبارات مهمة يجب أخذها في الحسبان عند تطوير وتطبيق مثل هذه الأنظمة. إن بناء الثقة بين الأطباء والمرضى في التقنيات الجديدة أمر أساسي لنجاح أي تطبيق تقني في المجال الطبي.

من ناحية أخرى، تهدف الدراسة إلى فهم العوامل التي تؤثر على قبول الأطباء للتقنيات الجديدة واستعدادهم لدمجها في ممارستهم اليومية. التدريب والتعليم المناسب، توفير الدعم التقني، وإثبات الفائدة العملية الواضحة، كلها عوامل حاسمة في نجاح تطبيق أي نظام تقني جديد في البيئة الطبية. كما أن فهم التحديات والمخاوف التي قد تواجه الأطباء عند استخدام مثل هذه الأنظمة يساعد في تطوير حلول مناسبة وبرامج تدريبية فعالة.

إن النتائج المتوقعة من هذه الدراسة لا تقتصر على تطوير نظام تقني متقدم فحسب، بل تمتد لتشمل إسهامات علمية ومعرفية متنوعة. على الصعيد التقني، ستساهم الدراسة في تطوير خوارزميات جديدة ومحسنة لتحليل

الأشعة البانورامية، وستقدم إطاراً تطبيقياً يمكن تكراره في مجالات طبية أخرى. على الصعيد السريري، ستوفر الدراسة بيانات قيمة حول فاعلية أنظمة دعم القرار في تحسين الأداء التشخيصي وكفاءة العمل السريري. وعلى الصعيد الاجتماعي، ستساهم في تحسين جودة الرعاية الصحية وتطوير نماذج جديدة لتقديم الخدمات الطبية. إن هذه الدراسة تأتي في وقت مناسب حيث تشهد منطقتنا نهضة علمية وتقنية واضحة، واهتماماً متزايداً بتطبيق التقنيات الحديثة في مختلف المجالات. الاستثمار في أبحاث الذكاء الاصطناعي الطبي ليس فقط استثماراً في التقنية، بل استثمار في المستقبل الصحي للمجتمع وفي بناء قدرات علمية وتقنية محلية قادرة على المنافسة عالمياً. كما أن تطوير حلول تقنية مبتكرة في المجال الطبي يمكن أن يساهم في تعزيز الاقتصاد المعرفي وخلق فرص عمل جديدة في القطاعات التقنية المتقدمة.

في الختام، تمثل هذه الدراسة محاولة علمية جادة لاستكشاف إمكانيات تطبيق الذكاء الاصطناعي في مجال حيوي ومهم كطب الأسنان، وتسعى لتقديم إسهام علمي وعملي يخدم المجتمع الطبي والمرضى على حد سواء. إن التحدي الذي تواجهه هذه الدراسة كبير، لكن الإمكانيات والفرص المتاحة أكبر، والنتائج المتوقعة تبشر بمستقبل واعد لتطبيقات الذكاء الاصطناعي في تحسين جودة الرعاية الصحية وتطوير أدوات تشخيصية متقدمة تخدم البشرية.

أولاً: مشكلة الدراسة

تواجه ممارسة طب الأسنان تحديات متزايدة في تفسير الأشعة البانورامية بدقة عالية، حيث تعتبر هذه الأشعة أداة تشخيصية أساسية تتطلب خبرة واسعة ووقتاً كبيراً للتحليل الدقيق. تشير الدراسات إلى أن معدل الأخطاء في التشخيص الإشعاعي للأسنان يتراوح بين 15-25% نتيجة لعوامل متعددة منها التعب البشري، ضغط الوقت، والتعقيد المتزايد للحالات المرضية.

تتجلى المشكلة الأساسية في عدة أبعاد رئيسية:

البعد التشخيصي: صعوبة تحديد الآفات الصغيرة والمبكرة في الأشعة البانورامية، خاصة في حالات التسوس بين الأسنان، أمراض اللثة المتقدمة، والتشوهات العظمية الدقيقة. هذا الأمر يؤدي إلى تأخير التشخيص أو عدم دقته، مما يؤثر سلباً على خطة العلاج ونتائجها.

البعد الزمني: الوقت المطلوب لتحليل الأشعة البانورامية يتراوح بين 5-15 دقيقة للحالة الواحدة، مما يشكل عبئاً على الأطباء ويقلل من كفاءة العمل في العيادات المزدحمة. هذا الضغط الزمني قد يؤثر على جودة التشخيص ودقة القرار الطبي.

البعد التعليمي: نقص في برامج التدريب المتخصصة لتطوير مهارات قراءة الأشعة البانورامية، خاصة للأطباء الجدد والمقيمين، مما يزيد من فجوة الخبرة بين الأطباء المختلفين.

البعد التكنولوجي: عدم وجود أنظمة ذكية متطورة تدعم الأطباء في اتخاذ القرارات التشخيصية بناءً على تحليل الأشعة البانورامية، رغم التقدم الهائل في تقنيات الذكاء الاصطناعي والتعلم الآلي.

تتفاقم هذه المشكلة في البيئة المحلية والإقليمية حيث يواجه أطباء الأسنان ضغطاً متزايداً لتقديم خدمات عالية الجودة بوقت أقل وتكلفة أقل، مما يجعل الحاجة ملحة لتطوير حلول تقنية مبتكرة تدعم عملية التشخيص وتحسن من دقة القرار الطبي.

ثانياً: أهمية الدراسة

تكتسب هذه الدراسة أهمية بالغة من عدة جوانب متكاملة تسهم في تطوير مجال طب الأسنان وتحسين جودة الرعاية الصحية:

الأهمية العلمية والأكاديمية: تساهم الدراسة في إثراء المعرفة العلمية من خلال تطوير نموذج متقدم يدمج بين تقنيات الذكاء الاصطناعي وعلم طب الأسنان. تقدم الدراسة إطاراً نظرياً وتطبيقياً جديداً يمكن أن يكون مرجعاً للباحثين والأكاديميين في مجالات متعددة شملت علوم الحاسوب، الذكاء الاصطناعي، وطب الأسنان. كما تفتح آفاقاً جديدة للبحث في مجال التشخيص الطبي المدعوم بالذكاء الاصطناعي.

الأهمية التطبيقية والمهنية: تقدم الدراسة حلاً عملياً لتحسين أداء أطباء الأسنان في التشخيص الإشعاعي، مما يؤدي إلى تحسين جودة الخدمة المقدمة للمرضى. النظام المقترح يمكن أن يساعد في تقليل الأخطاء التشخيصية وتوفير الوقت، مما يزيد من كفاءة العمل في العيادات والمستشفيات.

الأهمية الاقتصادية: يمكن للنظام المقترح أن يساهم في تقليل التكاليف الطبية من خلال التشخيص المبكر والدقيق، مما يقلل من الحاجة للعلاجات المعقدة والمكلفة. كما يمكن أن يقلل من تكاليف إعادة التشخيص والعلاجات الإضافية الناتجة عن الأخطاء التشخيصية.

الأهمية الاجتماعية والصحية: تساهم الدراسة في تحسين جودة الرعاية الصحية للمجتمع من خلال تقديم تشخيص أكثر دقة وسرعة، مما يؤدي إلى علاج أفضل ونتائج صحية محسنة للمرضى. كما تساهم في تقليل القلق والتوتر لدى المرضى من خلال تقديم تشخيص أكثر وضوحاً وثقة.

الأهمية التقنية والابتكارية: تساهم الدراسة في تطوير التقنيات الحديثة في مجال الذكاء الاصطناعي وتطبيقها في المجال الطبي، مما يعزز من موقع المؤسسة والدولة في مجال الابتكار التكنولوجي. كما تقدم نموذجاً يمكن تطبيقه في مجالات طبية أخرى.

ثالثاً: أهداف الدراسة

الهدف الرئيسي: تطوير وتقييم نظام دعم القرار التشخيصي القائم على الذكاء الاصطناعي لتحسين دقة تفسير الأشعة البانورامية في طب الأسنان وتعزيز جودة القرار الطبي.

الأهداف الفرعية:

1-الأهداف التقنية:

- تصميم وتطوير خوارزميات التعلم الآلي المتخصصة في تحليل الأشعة البانورامية للأسنان
- إنشاء قاعدة بيانات شاملة للأشعة البانورامية مع التصنيفات التشخيصية المرجعية
- تطوير واجهة مستخدم تفاعلية وسهلة الاستخدام للأطباء
- تحسين دقة النظام في التعرف على الآفات والتشوهات المختلفة

2-الأهداف التطبيقية:

- قياس تأثير النظام على دقة التشخيص مقارنة بالطرق التقليدية
- تقييم مدى تحسن كفاءة الأطباء في استخدام النظام
- قياس مستوى رضا الأطباء عن النظام المطور
- تحليل تأثير النظام على الوقت المطلوب للتشخيص

3-الأهداف المعرفية:

- استكشاف أفضل الممارسات في تطبيق الذكاء الاصطناعي في التشخيص الطبي

- تحليل العوامل المؤثرة على قبول الأطباء للتقنيات الجديدة
- تطوير إطار نظري لتقييم أنظمة دعم القرار الطبي
- إنتاج توصيات لتحسين تطبيق الذكاء الاصطناعي في طب الأسنان

رابعاً: تساؤلات أو فرضيات الدراسة

التساؤل الرئيسي: إلى أي مدى يمكن لنظام دعم القرار التشخيصي القائم على الذكاء الاصطناعي أن يحسن من دقة تفسير الأشعة البانورامية وجودة القرار الطبي لدى أطباء الأسنان؟

التساؤلات الفرعية:

1-التساؤلات التقنية:

- ما هي أفضل خوارزميات التعلم الآلي المناسبة لتحليل الأشعة البانورامية؟
- كيف يمكن تحسين دقة التعرف على الآفات المختلفة في الأشعة البانورامية؟
- ما هي المتطلبات التقنية اللازمة لتطوير نظام فعال؟
- كيف يمكن ضمان موثوقية وأمان النظام المطور؟

2- التساؤلات التطبيقية:

- ما مدى تأثير النظام على دقة التشخيص مقارنة بالطرق التقليدية؟
- كيف يؤثر النظام على الوقت المطلوب للتشخيص؟
- ما مستوى رضا الأطباء عن استخدام النظام؟

- ما هي العوامل التي تؤثر على قبول الأطباء للنظام؟

خامسا: الفرضيات:

الفرضية الأساسية: يحسن نظام دعم القرار التشخيصي القائم على الذكاء الاصطناعي بشكل معنوي من دقة تفسير الأشعة البانورامية وجودة القرار الطبي لدى أطباء الأسنان.

الفرضيات الفرعية:

- توجد فروق ذات دلالة إحصائية في دقة التشخيص بين استخدام النظام والطرق التقليدية لصالح النظام
- يقلل النظام المطور من الوقت المطلوب للتشخيص بنسبة لا تقل عن 30%
- يحقق النظام مستوى رضا عالي (أكثر من 80%) من قبل الأطباء المستخدمين
- تتحسن ثقة الأطباء في قراراتهم التشخيصية عند استخدام النظام

سادسا: المتغيرات

1-المتغير المستقل: نظام دعم القرار التشخيصي القائم على الذكاء الاصطناعي

يمثل نظام دعم القرار التشخيصي القائم على الذكاء الاصطناعي المتغير المستقل المحوري في هذه الدراسة، والذي يُعرف بأنه نظام حاسوبي ذكي متكامل يستخدم تقنيات الذكاء الاصطناعي والتعلم الآلي لتحليل الأشعة البانورامية للأسنان وتقديم توصيات تشخيصية مدعومة بالأدلة للأطباء المختصين. هذا النظام لا يهدف إلى استبدال الخبرة البشرية، بل يعمل كمساعد ذكي يعزز من قدرات الطبيب التشخيصية ويوفر رأياً ثانياً موضوعياً ومتسقاً في عملية اتخاذ القرار السريري. وفقاً لدراسة Schwendicke وزملاؤه (2023)، فإن أنظمة دعم القرار الطبي الحديثة تتميز بقدرتها على معالجة كميات هائلة من البيانات البصرية، استخراج الأنماط المعقدة

غير المرئية للعين البشرية، وتقديم تحليل سريع ومتسق لا يتأثر بعوامل التعب أو الضغط النفسي التي قد تؤثر على الأداء البشري.

يتكون هذا النظام من أربعة مكونات أساسية متداخلة ومتراصة تعمل بتناغم لتحقيق الهدف المنشود من تحسين دقة التشخيص وكفاءة العمل السريري. هذه المكونات الأربعة - خوارزميات التعلم الآلي، قاعدة البيانات التدريبية، واجهة المستخدم، ومستوى الأتمتة - تشكل منظومة متكاملة حيث يؤثر كل مكون على أداء وفاعلية المكونات الأخرى. التصميم المتوازن والتكامل السليم بين هذه المكونات يحدد في النهاية مدى نجاح النظام في تحقيق أهدافه العلمية والعملية في البيئة السريرية الحقيقية.

خوارزميات التعلم الآلي المستخدمة

تشكل خوارزميات التعلم الآلي القلب النابض للنظام والمحرك الأساسي لقدراته التشخيصية، حيث تمثل مجموعة من الخوارزميات الرياضية والحاسوبية المتطورة التي تمكن النظام من التعلم من البيانات التدريبية واستخراج الأنماط المعقدة من الصور الإشعاعية. في سياق تحليل الأشعة البانورامية، تعتمد الدراسة بشكل أساسي على الشبكات العصبية التحويلية (Convolutional Neural Networks - CNNs) والتي تعتبر الأكثر فاعلية في مهام معالجة وتحليل الصور الطبية. هذه الشبكات تتميز بقدرتها على استخراج الخصائص البصرية المتدرجة من الصور، بدءاً من الحواف والخطوط البسيطة في الطبقات الأولى، وصولاً إلى الأنماط المعقدة والهياكل التشريحية في الطبقات العميقة.

تستخدم الدراسة معمارية ResNet (Residual Networks) المحسنة كأساس للشبكة العصبية، والتي تتميز بقدرتها على التعامل مع الشبكات العميقة جداً دون التعرض لمشكلة تدهور التدرج (Vanishing Gradient Problem). وفقاً لدراسة Chen وزملائه (2023)، فإن معمارية ResNet-50 و ResNet-

101حققت نتائج متميزة في تحليل الأشعة البانورامية بدقة تجاوزت 90% في كشف التسوس والآفات العظمية. بالإضافة إلى ذلك، يتم دمج تقنية **Transfer Learning** للاستفادة من النماذج المدربة مسبقاً على مجموعات بيانات ضخمة مثل ImageNet ، مما يقلل من الوقت والموارد المطلوبة للتدريب ويحسن من دقة النموذج النهائي.

كما يتضمن النظام خوارزميات **معالجة الصور المتقدمة** مثل تقنيات تحسين التباين، إزالة الضوضاء، وتصحيح التشوهات الهندسية التي قد تحدث أثناء عملية التصوير. تقنيات مثل **Histogram Equalization** و **Gaussian Filtering** تستخدم لتحسين جودة الصورة قبل إدخالها للشبكة العصبية. دراسة Ezhov وزملاؤه (2023) تؤكد على أن معالجة الصور المسبقة تحسن من دقة التشخيص بنسبة 10-15% خاصة في الصور منخفضة الجودة أو التي تحتوي على تشوهات تقنية.

يشمل النظام أيضاً خوارزميات **التجميع والتصنيف المتعدد (Ensemble Learning)** التي تجمع بين نتائج عدة نماذج مختلفة لتحسين الدقة الإجمالية وتقليل احتمالية الخطأ. هذا النهج، المعروف باسم **Ensemble Methods**، يستخدم تقنيات مثل Voting ، Bagging ، و Boosting لدمج قرارات متعددة في قرار نهائي أكثر موثوقية. وفقاً لدراسة Hung وزملاؤه (2023)، فإن استخدام نماذج التجميع يمكن أن يحسن من دقة التشخيص بنسبة 5-8% مقارنة باستخدام نموذج واحد منفرد، كما يوفر مقياساً لثقة النظام في قراراته من خلال قياس مستوى الاتفاق بين النماذج المختلفة.

قاعدة البيانات التدريبية

تمثل قاعدة البيانات التدريبية العنصر الحيوي الذي يحدد جودة وفاعلية النظام، حيث أن جودة البيانات المستخدمة في التدريب تؤثر بشكل مباشر على دقة وموثوقية النظام النهائي. تتكون قاعدة البيانات من مجموعة

شاملة ومتنوعة من صور الأشعة البانورامية عالية الجودة، مصنفة ومعتمدة من قبل أطباء أسنان متخصصين في التشخيص الإشعاعي. يبلغ الحجم المستهدف لقاعدة البيانات 10,000-15,000 صورة موزعة على فئات تشخيصية مختلفة تشمل الحالات الطبيعية، التسوس بدرجاته المختلفة، أمراض اللثة، الكيسات والأورام، التشوهات الخلقية، ومشاكل مفصل الفك الصدغي.

تتميز قاعدة البيانات بالتنوع الديموغرافي والجغرافي، حيث تضم صوراً من مؤسسات طبية متعددة وتغطي فئات عمرية مختلفة من الأطفال إلى كبار السن، مع تمثيل متوازن للذكور والإناث. هذا التنوع ضروري لضمان قدرة النظام على التعامل مع الاختلافات التشرحية الطبيعية بين المرضى المختلفين وتجنب التحيز في الأداء تجاه فئات معينة. دراسة Bianchi وزملاؤه (2023) تؤكد على أن التنوع في البيانات التدريبية يحسن من قابلية التعميم للنظام ويقلل من مخاطر الإفراط في التخصص (Overfitting) التي تؤدي إلى ضعف الأداء على البيانات الجديدة غير المرئية سابقاً.

يتم **تصنيف البيانات** وفقاً لبروتوكول صارم يتضمن مراجعة مزدوجة من قبل طبيبين مستقلين، مع آلية لحل الخلافات من خلال طبيب ثالث أكثر خبرة في حالة عدم الاتفاق. كل صورة تحصل على تصنيف متعدد المستويات يشمل التشخيص الرئيسي، موقع الآفة، شدة الحالة، ومستوى الثقة في التشخيص. هذا النظام المتدرج للتصنيف يمكن النظام من التعلم ليس فقط على تحديد وجود المرض، بل أيضاً على تقدير شدته وتحديد موقعه بدقة. وفقاً لدراسة Kim وزملاؤه (2023)، فإن جودة التصنيف والاتفاق بين المقيمين (Inter-rater Agreement) يجب أن يحقق معامل كابتا لا يقل عن 0.8 لضمان موثوقية البيانات التدريبية.

تشمل قاعدة البيانات أيضاً **البيانات الوصفية (Metadata)** المرتبطة بكل صورة، مثل معلومات جهاز التصوير، الإعدادات التقنية المستخدمة، عمر المريض، جنسه، والتاريخ الطبي ذي الصلة. هذه المعلومات

الإضافية تساعد النظام على فهم السياق الطبي للصورة وتحسين دقة التشخيص. كما يتم تطبيق تقنيات تكبير البيانات (Data Augmentation) لزيادة التنوع في مجموعة التدريب من خلال تطبيق تحويلات مختلفة على الصور الأصلية مثل الدوران، التكبير، تغيير التباين، وإضافة ضوضاء خفيفة. دراسة Vinayahalingam وزملاؤه (2023) تشير إلى أن تقنيات تكبير البيانات يمكن أن تحسن من أداء النموذج بنسبة 15-20% خاصة عندما تكون البيانات الأصلية محدودة.

واجهة المستخدم

تمثل واجهة المستخدم الجسر الذي يربط بين القوة التقنية للنظام وسهولة الاستخدام العملي في البيئة السريرية، حيث تحدد مدى قدرة الأطباء على الاستفادة الكاملة من إمكانيات النظام بكفاءة وسهولة. تم تصميم الواجهة وفقاً لمبادئ التصميم المتمحور حول المستخدم (User-Centered Design) وإرشادات سهولة الاستخدام الطبي، مع التركيز على البساطة، الوضوح، والتدفق المنطقي للعمليات. الواجهة مقسمة إلى عدة مناطق وظيفية متكاملة: منطقة عرض الصورة الرئيسية، لوحة النتائج والتوصيات، أدوات التحكم والتنقل، ومنطقة المعلومات التكميلية والإعدادات.

منطقة عرض الصورة تحتل الجزء الأكبر من الشاشة وتوفر إمكانيات متقدمة للتفاعل مع الصورة مثل التكبير، التحريك، تعديل السطوع والتباين، والقياس. يتم تمييز المناطق المشبوهة التي حددها النظام بألوان مختلفة حسب نوع الآفة ومستوى الثقة في التشخيص، مع إمكانية إظهار أو إخفاء هذه التمييزات حسب رغبة الطبيب. دراسة Nguyen وزملاؤه (2023) تؤكد على أن التمييز البصري الواضح للمناطق المشبوهة يحسن من دقة الطبيب في اكتشاف الآفات بنسبة 20-30%، خاصة الآفات الصغيرة أو الخفية التي قد تمر دون ملاحظة في الفحص التقليدي.

لوحة النتائج والتوصيات تعرض تحليل النظام بطريقة منظمة ومفهومة، تبدأ بالتشخيص الأكثر احتمالاً متبوعاً بالتشخيصات البديلة مرتبة حسب درجة الاحتمال. كل تشخيص يُصاحب بمستوى الثقة في القرار، الأدلة البصرية المدعمة، والتوصيات للخطوات التالية. يتم عرض هذه المعلومات باستخدام نظام بصري متدرج يجمع بين النصوص، الأيقونات، والألوان لتسهيل الفهم السريع. كما تتضمن اللوحة روابط للمراجع العلمية والحالات المشابهة في قاعدة البيانات لمساعدة الطبيب في اتخاذ قرار مدروس.

تشمل **أدوات التحكم والتنقل** مجموعة من الوظائف المساعدة مثل حفظ التشخيص، إضافة ملاحظات خاصة، مقارنة الصورة الحالية مع صور سابقة للمريض نفسه، وتصدير التقرير بصيغ مختلفة. كما توفر الواجهة إمكانية تخصيص الإعدادات حسب تفضيلات كل طبيب، مثل ألوان التمييز، مستوى التفاصيل في التقارير، ولغة العرض. وفقاً لدراسة Panda وزملاؤه (2023)، فإن قابلية التخصيص في واجهة المستخدم تزيد من مستوى رضا المستخدمين بنسبة 25-35% وتقلل من زمن التعلم المطلوب لإتقان استخدام النظام.

التفاعل التكيفي يمثل ميزة متقدمة في الواجهة، حيث يتعلم النظام من سلوك وتفضيلات كل مستخدم ويكيف عرض المعلومات وترتيب الوظائف وفقاً لاحتياجاته الخاصة. على سبيل المثال، إذا كان الطبيب يركز بشكل أساسي على تشخيص التسوس، فسيعطي النظام أولوية أكبر لعرض المعلومات المتعلقة بهذا النوع من التشخيص. هذا التفاعل التكيفي يحسن من كفاءة الاستخدام ويقلل من الحمل المعرفي على المستخدم، مما يساعده على التركيز على الجوانب الطبية بدلاً من التعامل مع تعقيدات التقنية.

مستوى الأتمتة في التشخيص

يمثل **مستوى الأتمتة في التشخيص** البُعد الذي يحدد درجة الاستقلالية التي يتمتع بها النظام في عملية التحليل واتخاذ القرار، وهو متغير متدرج يتراوح من الأتمتة الجزئية التي تقتصر على توفير معلومات مساعدة، إلى

الأمثلة الكاملة التي تقدم تشخيصاً نهائياً. في سياق هذه الدراسة، تم تصميم النظام ليعمل وفقاً لنموذج الأمثلة التعاونية (Collaborative Automation) التي تحقق التوازن المثالي بين القدرات التقنية للذكاء الاصطناعي والخبرة السريرية للطبيب البشري. هذا النموذج يضمن أن النظام يعمل كمساعد ذكي وليس كبديل للطبيب، مما يحافظ على المسؤولية الطبية والقانونية في يد الطبيب المختص.

المستوى الأول من الأمثلة يشمل التحليل الأولي والفرز التلقائي للصور، حيث يقوم النظام بتحليل كل صورة تلقائياً فور تحميلها ويصنفها حسب مستوى الأولوية للمراجعة. الصور التي لا تظهر أي علامات مرضية واضحة يتم تصنيفها كحالات ذات أولوية منخفضة، بينما الصور التي تحتوي على آفات محتملة أو علامات مثيرة للقلق يتم تمييزها كحالات ذات أولوية عالية تتطلب مراجعة فورية. هذا النظام يساعد الأطباء في إدارة عبء العمل بكفاءة أكبر، خاصة في البيئات المزدحمة حيث يتعامل الطبيب مع عشرات الصور يومياً. دراسة Thurzo وزملاؤه (2023) تشير إلى أن نظام الفرز التلقائي يمكن أن يحسن من كفاءة تدفق العمل بنسبة 40-50% ويقلل من احتمالية تأخير تشخيص الحالات الطارئة.

المستوى الثاني من الأمثلة يتضمن التحليل التفصيلي وتحديد المناطق المشبوهة بدقة عالية، حيث يستخدم النظام خوارزميات التعلم العميق لفحص كل منطقة من الصورة وتحديد المناطق التي تظهر خصائص غير طبيعية. هذا التحليل يشمل قياس كثافة الأنسجة، تحليل الأنماط النسيجية، وكشف التغيرات الشكلية في الهياكل التشريحية. النظام يقوم بتمييز هذه المناطق بصرياً على الصورة ويقدم تفسيراً للأسباب التي جعلته يعتبرها مشبوهة، مما يساعد الطبيب في فهم منطق النظام وتقييم صحة التحليل. وفقاً لدراسة Wang وزملاؤه (2023)، فإن دقة تحديد المناطق المشبوهة تصل إلى 92-95% في معظم أنواع الآفات الشائعة، مما يجعل هذه الوظيفة ذات قيمة كبيرة في التطبيق العملي.

المستوى الثالث من الأتمتة يشمل توليد التشخيصات المحتملة والتوصيات العلاجية بناءً على تحليل شامل لجميع النتائج المستخرجة من الصورة. النظام يقارن النتائج مع قاعدة معرفة واسعة من الحالات المشابهة ويقدم قائمة مرتبة بالتشخيصات الأكثر احتمالاً، مصحوبة بمستوى الثقة في كل تشخيص والأدلة المدعمة له. كما يقدم النظام توصيات للفحوصات الإضافية التي قد تكون مطلوبة، التوقيت المناسب للمتابعة، ومستوى الإلحاح المطلوب للتدخل العلاجي. هذا المستوى من الأتمتة يوفر للطبيب رؤية شاملة ومنظمة للحالة، مما يساعده في اتخاذ قرارات مدروسة وشاملة.

آليات التحكم في مستوى الأتمتة تسمح للطبيب بتخصيص درجة الأتمتة حسب احتياجاته وتفضيلاته الشخصية. يمكن للطبيب اختيار مستوى الأتمتة المناسب لكل نوع من الحالات، بحيث يمكن الاعتماد على أتمتة أعلى في الحالات الروتينية البسيطة، واستخدام أتمتة أقل في الحالات المعقدة التي تتطلب تقييماً بشرياً أكثر تفصيلاً. دراسة Zaorska وزملاؤه (2023) تؤكد على أن مرونة التحكم في مستوى الأتمتة تزيد من مستوى راحة الأطباء مع النظام وتقلل من مقاومتهم لتبني التقنية الجديدة، حيث يشعرون بأنهم يحتفظون بالسيطرة على عملية التشخيص النهائية.

2- المتغيرات التابعة:

متغيرات الأداء التشخيصي

تشكل متغيرات الأداء التشخيصي العمود الفقري لتقييم فاعلية نظام دعم القرار التشخيصي المقترح، حيث تقدم مؤشرات كمية دقيقة لقياس قدرة النظام على تحديد الحالات المرضية بشكل صحيح. يعتبر مفهوم دقة التشخيص (**Diagnostic Accuracy**) المؤشر الأساسي والأكثر شمولية في هذا السياق، والذي يُعرف بأنه النسبة المئوية للحالات التي تم تشخيصها بشكل صحيح من إجمالي الحالات المدروسة، ويُحسب رياضياً

وفقاً للمعادلة: (النتائج الإيجابية الصحيحة + النتائج السلبية الصحيحة) ÷ إجمالي عدد الحالات × 100.
تشير دراسة Chen وزملاؤه (2023) إلى أن دقة التشخيص في أنظمة الذكاء الاصطناعي للأشعة البانورامية تتراوح بين 85% إلى 95% حسب نوع الحالة المرضية والخوارزمية المستخدمة.

وترتبط دقة التشخيص ارتباطاً وثيقاً بمفهوم الحساسية (Sensitivity) ، والذي يُعرف أيضاً بمعدل الإيجابية الصحيحة، وهو مقياس لقدرة النظام على تحديد الحالات المرضية الموجودة فعلياً دون إغفالها. تُحسب الحساسية من خلال قسمة عدد النتائج الإيجابية الصحيحة على مجموع النتائج الإيجابية الصحيحة والنتائج السلبية الخاطئة، وتتراوح قيمتها بين 0 و 1، حيث تشير القيمة الأعلى إلى قدرة أفضل على كشف المرض. وفقاً لدراسة Bianchi وزملاؤه (2023)، فإن الحساسية العالية ضرورية جداً في التطبيقات الطبية حيث أن عدم اكتشاف المرض (False Negative) قد يؤدي إلى تأخير العلاج وتفاقم الحالة المرضية، خاصة في حالات الأورام والكيسات التي تتطلب تدخلاً مبكراً.

في المقابل، يأتي مفهوم النوعية (Specificity) ليكمل الصورة التشخيصية، حيث يقيس قدرة النظام على تحديد الحالات السليمة بشكل صحيح وعدم تصنيفها خطأ كحالات مرضية. تُحسب النوعية بقسمة عدد النتائج السلبية الصحيحة على مجموع النتائج السلبية الصحيحة والنتائج الإيجابية الخاطئة، وتعتبر مقياساً مهماً لتجنب التشخيص المفرط والعلاجات غير الضرورية. تؤكد دراسة Ezhov وزملاؤه (2023) على أن التوازن بين الحساسية والنوعية أمر بالغ الأهمية في أنظمة التشخيص الطبي، حيث أن النوعية المنخفضة تؤدي إلى زيادة النتائج الإيجابية الخاطئة مما يسبب قلقاً غير مبرر للمرضى وتكاليف إضافية للنظام الصحي.

ويرتبط بهذين المفهومين متغيران إضافيان في غاية الأهمية هما القيمة التنبؤية الإيجابية (Positive Predictive Value) والقيمة التنبؤية السلبية (Negative Predictive Value). تُعرف القيمة التنبؤية

الإيجابية بأنها احتمالية أن يكون المريض مصاباً فعلاً بالمرض عندما تشير نتيجة الفحص إلى وجود المرض، وتُحسب بقسمة النتائج الإيجابية الصحيحة على مجموع النتائج الإيجابية الصحيحة والخاطئة. هذا المقياس مهم جداً من الناحية العملية لأنه يجيب على السؤال الذي يطرحه الطبيب والمريض: "إذا كانت نتيجة الفحص إيجابية، ما هي احتمالية وجود المرض فعلاً؟" وفقاً لدراسة Fukuda وزملاؤه (2023)، فإن القيمة التنبؤية الإيجابية تتأثر بشكل كبير بانتشار المرض في المجتمع المدروس، حيث تنخفض في حالة الأمراض النادرة حتى لو كانت دقة الاختبار عالية.

أما القيمة التنبؤية السلبية فتتمثل احتمالية عدم إصابة المريض بالمرض عندما تشير نتيجة الفحص إلى عدم وجود المرض، وتُحسب بقسمة النتائج السلبية الصحيحة على مجموع النتائج السلبية الصحيحة والخاطئة. هذا المقياس يجيب على السؤال: "إذا كانت نتيجة الفحص سلبية، ما هي احتمالية عدم وجود المرض؟" تشير دراسة Geetha وزملاؤه (2023) إلى أن القيمة التنبؤية السلبية العالية تعطي الطبيب والمريض ثقة أكبر في استبعاد المرض عند الحصول على نتيجة سلبية، مما يقلل من الحاجة لفحوصات إضافية ويخفف من القلق النفسي للمريض.

متغيرات الكفاءة

تشكل متغيرات الكفاءة جانباً حاسماً في تقييم الجدوى العملية لنظام دعم القرار التشخيصي، حيث تقيس مدى تحسين الأداء التشغيلي والإنتاجية السريرية. يعتبر الوقت المطلوب للتشخيص المتغير الأكثر وضوحاً وقابلية للقياس في هذه الفئة، ويُعرف بأنه المدة الزمنية اللازمة للطبيب لتحليل صورة الأشعة البانورامية والوصول إلى تشخيص أولي أو نهائي. هذا المتغير يقاس بالدقائق أو الثواني، ويشمل الوقت من بداية عرض الصورة على الطبيب حتى تسجيل التشخيص النهائي. تشير دراسة Hung وزملاؤه (2023) إلى أن الوقت المتوسط لتحليل

الأشعة البانورامية يتراوح بين 5 إلى 15 دقيقة حسب تعقيد الحالة وخبرة الطبيب، وأن استخدام أنظمة الذكاء الاصطناعي يمكن أن يقلل هذا الوقت بنسبة 30% إلى 50%.

ويرتبط الوقت المطلوب للتشخيص مباشرة بمتغير **عدد الحالات المعالجة في الساعة**، والذي يقيس الإنتاجية السريرية للطبيب ويُحسب بقسمة عدد الحالات التي تم تشخيصها على عدد ساعات العمل الفعلية. هذا المقياس مهم جداً في بيئة العمل السريري حيث يواجه الأطباء ضغطاً متزايداً لمعالجة عدد أكبر من المرضى في وقت أقل. دراسة Jeon وزملاؤه (2023) تبين أن تحسين الكفاءة الزمنية لا يعني بالضرورة التضحية بالجودة، بل يمكن تحقيق الاثنين معاً من خلال الاستخدام الذكي للتقنيات المساعدة، حيث أن النظام الذكي يمكنه تسليط الضوء على المناطق المشبوهة مما يوجه انتباه الطبيب بشكل أكثر فاعلية.

يشكل **معدل الأخطاء التشخيصية** متغيراً حاسماً في قياس جودة الأداء، ويُعرف بأنه النسبة المئوية للحالات التي تم تشخيصها بشكل خاطئ من إجمالي الحالات المشخصة. هذا المعدل يشمل نوعين من الأخطاء: الأخطاء الإيجابية الخاطئة (تشخيص المرض في حالة عدم وجوده) والأخطاء السلبية الخاطئة (عدم تشخيص المرض رغم وجوده). وفقاً لدراسة Kim وزملاؤه (2023)، فإن معدل الأخطاء التشخيصية في قراءة الأشعة البانورامية يتراوح بين 10% إلى 25% حسب نوع الحالة وخبرة الطبيب، وأن استخدام أنظمة دعم القرار يمكن أن يقلل هذا المعدل بشكل ملحوظ من خلال توفير رأي ثانٍ إلكتروني ولفت انتباه الطبيب للمناطق المشبوهة. أما **مستوى الثقة في القرار** فيمثل متغيراً نوعياً مهماً يقيس درجة اليقين التي يشعر بها الطبيب تجاه تشخيصه. هذا المتغير عادة ما يُقاس باستخدام مقاييس ليكرت أو مقاييس رقمية تتراوح من 1 إلى 10، حيث تشير القيم الأعلى إلى ثقة أكبر في التشخيص. تؤكد دراسة Lee وزملاؤه (2023) على أن مستوى الثقة في القرار يؤثر بشكل مباشر على جودة الرعاية الطبية، حيث أن الأطباء الذين يشعرون بثقة أكبر في تشخيصهم يتخذون

قرارات علاجية أكثر حسماً وفاعلية، بينما الثقة المنخفضة قد تؤدي إلى طلب فحوصات إضافية غير ضرورية أو تأخير في بدء العلاج.

متغيرات الرضا والقبول

تمثل متغيرات الرضا والقبول جانباً بالغ الأهمية في نجاح تطبيق أي نظام تقني جديد في البيئة الطبية، حيث أن القبول من قبل المستخدمين النهائيين شرط أساسي لضمان الاستخدام الفعال والمستمر للنظام. يشكل **مستوى رضا الأطباء** المتغير المحوري في هذه الفئة، ويُعرف بأنه درجة الإشباع والارتياح التي يشعر بها الطبيب عند استخدام النظام لأداء مهامه التشخيصية. هذا المتغير متعدد الأبعاد ويشمل الرضا عن دقة النظام، سرعة الأداء، سهولة الاستخدام، والفائدة المحققة في الممارسة اليومية. دراسة Moran وزملاؤه (2023) تشير إلى أن مستوى رضا الأطباء يتأثر بعوامل متعددة منها توقعاتهم المسبقة، مستوى التدريب المتلقى، والدعم التقني المتاح، وأن النظم التي تحقق مستوى رضا عالي (أكثر من 80%) تحظى بمعدلات تبني واستخدام أعلى بكثير من النظم ذات الرضا المنخفض.

ويرتبط مستوى الرضا بشكل وثيق بمتغير **سهولة الاستخدام (Ease of Use)** ، والذي يقيس مدى بساطة وبديهية التفاعل مع النظام من وجهة نظر المستخدم. هذا المفهوم، المستمد من نظرية قبول التكنولوجيا (Technology Acceptance Model)، يشمل عدة أبعاد منها وضوح واجهة المستخدم، منطقية تسلسل العمليات، سرعة الاستجابة، وقلة عدد الخطوات المطلوبة لإنجاز المهمة. تؤكد دراسة Nguyen وزملاؤه (2023) على أن سهولة الاستخدام تعتبر عاملاً حاسماً في قبول الأطباء للتقنيات الجديدة، خاصة في البيئات السريرية المزدحمة حيث لا يتوفر وقت كافٍ لتعلم أنظمة معقدة، وأن النظم التي تتطلب تدريباً مكثفاً أو تستغرق وقتاً طويلاً للتشغيل تواجه مقاومة كبيرة من المستخدمين.

كما يلعب متغير **المنفعة المدركة (Perceived Usefulness)** دوراً محورياً في تحديد مستوى قبول النظام، ويُعرف بأنه درجة اعتقاد المستخدم بأن استخدام النظام سيحسن من أدائه المهني ويحقق له فوائد ملموسة. هذا المتغير يقيس التقييم الذاتي للطبيب لفائدة النظام في تحسين دقة التشخيص، توفير الوقت، زيادة الثقة في القرارات، وتحسين جودة الرعاية المقدمة للمرضى. وفقاً لدراسة Panda وزملاؤه (2023)، فإن المنفعة المدركة تتأثر بشكل كبير بالتجربة الفعلية للاستخدام والنتائج المحققة، حيث أن الأطباء الذين يلاحظون تحسناً واضحاً في أدائهم عند استخدام النظام يطورون تقييماً إيجابياً أكثر للمنفعة مقارنة بأولئك الذين لا يلاحظون فرقاً واضحاً.

ويكمل الصورة متغير **النية لاستخدام النظام مستقبلاً (Intention to Use)** ، والذي يقيس استعداد الطبيب ورغبته في الاستمرار في استخدام النظام في المستقبل والتوصية به للزملاء. هذا المتغير يعتبر مؤشراً مهماً للنجاح طويل المدى للنظام واستدامة تطبيقه، حيث أنه يعكس الرضا الإجمالي والثقة في قيمة النظام. دراسة Schwendicke وزملاؤه (2023) تبين أن النية للاستخدام المستقبلي تتأثر بمزيج من العوامل الشخصية (مثل الاتجاه نحو التكنولوجيا) والعوامل التنظيمية (مثل الدعم الإداري والتدريب) والعوامل التقنية (مثل موثوقية النظام وجودة الأداء)، وأن النظم التي تحقق نية استخدام عالية تتمتع بمعدلات تبني أسرع وانتشار أوسع في المجتمع الطبي.

المتغيرات الوسيطة

تلعب المتغيرات الوسيطة دوراً بالغ الأهمية في فهم العلاقات المعقدة بين المتغير المستقل (نظام دعم القرار) والمتغيرات التابعة (مؤشرات الأداء)، حيث تساعد في تفسير كيف ولماذا يختلف تأثير النظام من طبيب لآخر ومن حالة لأخرى. يعتبر **مستوى خبرة الطبيب** أحد أهم المتغيرات الوسيطة، ويُعرف بأنه مقدار المعرفة

والمهارات التراكمية التي اكتسبها الطبيب من خلال سنوات الممارسة والتدريب في مجال تشخيص الأشعة البانورامية. هذا المتغير يُقاس عادة بعدد سنوات الخبرة، عدد الحالات المشخصة سابقاً، الشهادات التخصصية الحاصل عليها، والدورات التدريبية المتعلقة بالتصوير الطبي. تشير دراسة Thurzo وزملاؤه (2023) إلى أن مستوى خبرة الطبيب يؤثر بشكل كبير على طريقة استفادته من نظام دعم القرار، حيث أن الأطباء الأكثر خبرة قد يستخدمون النظام بشكل مختلف عن الأطباء الأقل خبرة، وقد تختلف نظرتهم لأهمية التوصيات المقدمة من النظام.

ويرتبط بهذا المتغير بشكل وثيق **التدريب على استخدام النظام**، والذي يشمل نوع وكمية وجودة التدريب الذي تلقاه الطبيب قبل وأثناء استخدام النظام. هذا المتغير متعدد الأبعاد ويشمل مدة التدريب، نوع الأنشطة التدريبية (نظري، عملي، تفاعلي)، جودة المواد التدريبية، وخبرة المدربين. دراسة Vinayahalingam وزملاؤه (2023) تؤكد على أن جودة وشمولية التدريب تؤثر بشكل مباشر على قدرة الطبيب على الاستفادة الكاملة من إمكانيات النظام وتجنب الأخطاء الناتجة عن سوء الفهم أو الاستخدام الخاطئ، وأن البرامج التدريبية المصممة بعناية يمكن أن تقلل بشكل كبير من منحنى التعلم وتحسن من الأداء الأولي للمستخدمين الجدد.

كما يشكل **نوع الحالة المرضية** متغيراً بسيطاً مهماً يؤثر على فاعلية النظام ودقة أدائه. هذا المتغير يشمل تصنيف الحالات حسب نوع المرض (تسوس، أمراض لثة، كيسات، أورام، تشوهات خلقية)، شدة الحالة (مبكرة، متوسطة، متقدمة)، ومدى وضوح العلامات المرضية في الصورة. تبين دراسة Wang وزملاؤه (2023) أن أداء أنظمة الذكاء الاصطناعي يختلف بشكل كبير حسب نوع الحالة المرضية، حيث تحقق نتائج ممتازة في كشف بعض أنواع التسوس والآفات الواضحة، بينما قد تواجه تحديات أكبر في الحالات المعقدة أو الآفات النادرة التي لم يتم تدريب النظام عليها بشكل كافٍ.

وأخيراً، تلعب **جودة الصورة الإشعاعية** دوراً حاسماً كمتغير وسيط يؤثر على كل من الأداء البشري والآلي في التشخيص. هذا المتغير يشمل عدة أبعاد منها وضوح الصورة، التباين، الدقة (Resolution) ، مستوى الضوضاء، ووجود تشوهات أو قطع أثرية. جودة الصورة تتأثر بعوامل تقنية مثل إعدادات جهاز الأشعة، حالة المريض أثناء التصوير، وصيانة المعدات. دراسة Zaorska وزملاؤه (2023) تشير إلى أن أنظمة الذكاء الاصطناعي حساسة جداً لجودة الصورة، وأن الصور منخفضة الجودة قد تؤثر سلباً على دقة النظام أكثر مما تؤثر على الطبيب البشري، مما يجعل من ضمان جودة الصورة عاملاً حاسماً في نجاح تطبيق هذه الأنظمة عملياً.

المتغيرات الضابطة

تهدف المتغيرات الضابطة إلى التحكم في العوامل الخارجية التي قد تؤثر على نتائج الدراسة، مما يضمن أن التأثيرات المرصودة تُعزى فعلاً إلى المتغير المستقل وليس لعوامل أخرى. يعتبر **العمر والجنس للمريض** من أهم المتغيرات الضابطة في الدراسات الطبية، حيث أن هذين العاملين يؤثران على انتشار أنواع معينة من الأمراض وخصائص الصور الإشعاعية. العمر يؤثر على كثافة العظام، وضوح المعالم التشريحية، وانتشار أمراض معينة مثل فقدان الأسنان أو أمراض اللثة المتقدمة. الجنس أيضاً له تأثير على بعض الخصائص التشريحية وانتشار أمراض معينة. وفقاً لدراسة الخطيب (2022)، فإن التحكم في هذين المتغيرين ضروري لضمان التوزيع المتوازن للعينة وتجنب التحيز في النتائج، خاصة أن بعض أنظمة الذكاء الاصطناعي قد تُظهر أداءً مختلفاً حسب الفئة العمرية أو الجنس نتيجة للاختلافات في التدريب أو خصائص البيانات.

ويشكل **نوع جهاز الأشعة المستخدم** متغيراً ضابطاً تقنياً مهماً، حيث أن مختلف أجهزة الأشعة البانورامية تنتج صوراً بخصائص متفاوتة من حيث الدقة، التباين، ومستوى الضوضاء. هذا المتغير يشمل الشركة المصنعة،

الموديل، عمر الجهاز، ومستوى التقنية المستخدمة (تتأثرية أو رقمية). التحكم في هذا المتغير يمكن أن يتم من خلال استخدام نفس نوع الجهاز لجميع الحالات، أو من خلال التصنيف والتحليل المنفصل للنتائج حسب نوع الجهاز. دراسة أحمد (2023) تؤكد على أن توحيد نوع الجهاز المستخدم أو على الأقل التحكم الإحصائي في هذا المتغير ضروري لضمان صحة المقارنات وموثوقية النتائج، خاصة أن أنظمة الذكاء الاصطناعي قد تحتاج لمعايرة خاصة لكل نوع من أجهزة الأشعة.

كما تلعب الإعدادات التقنية للصورة دوراً مهماً كمتغير ضابط، وتشمل هذه الإعدادات قوة الأشعة (kV) ، شدة التيار (mA) ، زمن التعرض، وإعدادات المعالجة الرقمية للصورة. هذه الإعدادات تؤثر بشكل مباشر على جودة الصورة ووضوح التفاصيل، وبالتالي على قدرة كل من الطبيب والنظام الذكي على تحديد الآفات المرضية. التحكم في هذا المتغير يتطلب توحيد البروتوكولات المستخدمة لكل فئة من المرضى أو تسجيل الإعدادات المستخدمة لكل حالة لأخذها في الاعتبار أثناء التحليل. وفقاً لدراسة سليمان (2023)، فإن تسجيل ومراقبة الإعدادات التقنية يساعد في فهم أي اختلافات في الأداء وتفسيرها بشكل علمي سليم.

وأخيراً، يعتبر الوقت من اليوم لإجراء التشخيص متغيراً ضابطاً مهماً يؤثر على الأداء البشري بشكل خاص، حيث تشير الدراسات إلى أن دقة التشخيص الطبي تتأثر بحالة التعب والإرهاق التي قد يعاني منها الطبيب خلال ساعات العمل المختلفة. هذا المتغير يشمل عدة أبعاد منها الوقت من بداية نوبة العمل، العدد التراكمي للحالات المشخصة في نفس اليوم، وفترة اليوم (صباح، ظهيرة، مساء). البحوث في مجال الطب النفسي التطبيقي تبين أن الأداء المعرفي والقدرة على التركيز تتدهور تدريجياً مع طول فترة العمل المستمر، وأن هذا التدهور يكون أكثر وضوحاً في المهام التي تتطلب دقة بصرية عالية مثل قراءة الأشعة.

دراسة العتيبي (2022) تشير إلى أن معدل الأخطاء التشخيصية يزيد بنسبة 15% إلى 25% في الساعات الأخيرة من نوبة العمل مقارنة بالساعات الأولى، وأن هذا التأثير يكون أقل وضوحاً عند استخدام أنظمة دعم القرار التي توفر رأياً ثانياً مستقلاً عن حالة التعب البشري. التحكم في هذا المتغير يمكن أن يتم من خلال توزيع الحالات بشكل متوازن عبر فترات العمل المختلفة، أو من خلال تسجيل وقت التشخيص وأخذه في الاعتبار كمتغير في التحليل الإحصائي. هذا التحكم ضروري لضمان أن تحسن الأداء المرصود عند استخدام النظام لا يُعزى لعوامل زمنية بل للنظام نفسه.

التفاعلات بين المتغيرات

إن فهم التفاعلات المعقدة بين المتغيرات المختلفة يعتبر أمراً بالغ الأهمية للوصول إلى فهم شامل لكيفية عمل نظام دعم القرار في البيئة السريرية الحقيقية. التفاعل بين مستوى خبرة الطبيب ونوع الحالة المرضية يمثل أحد أهم أنماط التفاعل، حيث أن الأطباء الأكثر خبرة قد يستفيدون من النظام بطريقة مختلفة عن الأطباء الأقل خبرة، خاصة في الحالات المعقدة أو النادرة. وفقاً لدراسة محمد (2023)، فإن الأطباء المبتدئين قد يعتمدون بشكل أكبر على توصيات النظام في جميع الحالات، بينما الأطباء الخبراء قد يستخدمون النظام بشكل انتقائي أكثر، مستفيدين منه بشكل خاص في الحالات التي تقع خارج منطقة خبرتهم المعتادة.

كما أن التفاعل بين جودة الصورة الإشعاعية ودقة النظام التشخيصية يظهر نمطاً معقداً، حيث أن تدهور جودة الصورة قد يؤثر على النظام الذكي والطبيب البشري بطرق مختلفة. الأنظمة الذكية قد تكون أكثر حساسية لأنواع معينة من تشوهات الصورة (مثل الضوضاء الرقمية)، بينما قد تكون أقل تأثراً بأنواع أخرى (مثل التشوهات الناتجة عن حركة المريض الطفيفة). هذا التفاعل يتطلب دراسة دقيقة لفهم متى يكون النظام مفيداً أكثر ومتى قد نقل فائدته.

التفاعل بين التدريب على استخدام النظام وسهولة الاستخدام يمثل عاملاً حاسماً في تحديد مستوى رضا المستخدمين ونيتهم لاستخدام النظام مستقبلاً. النظم التي تتميز بسهولة استخدام عالية قد تحتاج لتدريب أقل لتحقيق مستوى رضا مقبول، بينما النظم الأكثر تعقيداً قد تتطلب تدريباً مكثفاً ولكن قد تحقق مستويات أداء أعلى بعد إتقان استخدامها. فهم هذا التفاعل مهم لتصميم برامج تدريبية مناسبة وتطوير واجهات مستخدم محسنة.

سابعاً: حدود الدراسة

1- الحدود الموضوعية: تقتصر الدراسة على تطوير نظام دعم القرار التشخيصي للأشعة البانورامية في طب الأسنان، دون التطرق لأنواع أخرى من الأشعة مثل الأشعة المقطعية أو أشعة الأسنان الفردية. كما تركز على التشخيص الأولي ولا تشمل التخطيط العلاجي أو المتابعة.

2- الحدود المكانية: ستطبق الدراسة في عيادات ومستشفيات الأسنان المختارة في المنطقة، مع التركيز على المؤسسات التي تستخدم أنظمة الأشعة الرقمية. قد تشمل الدراسة 3-5 مؤسسات طبية مختلفة لضمان تنوع البيانات.

3- الحدود الزمانية: ستمتد الدراسة لفترة 18-24 شهراً، تشمل 6 أشهر لتطوير النظام، 6 أشهر لجمع البيانات والتدريب، و6-12 شهراً للاختبار والتقييم.

4- الحدود البشرية: تستهدف الدراسة أطباء الأسنان العامين والمتخصصين في طب الأسنان، مع التركيز على الأطباء الذين لديهم خبرة لا تقل عن عامين في قراءة الأشعة البانورامية.

5-الحدود التقنية: تقتصر الدراسة على استخدام تقنيات التعلم الآلي والتعلم العميق المتاحة حالياً، مع التركيز على الخوارزميات المثبتة علمياً وعملياً. كما تتطلب الدراسة توفر بيانات كافية وعالية الجودة للتدريب.

ثامنا: منهجية البحث

1-منهج الدراسة: تتبع الدراسة المنهج المختلط (Mixed Methods Approach) الذي يجمع بين:

- **المنهج الكمي**: لقياس دقة النظام وكفاءته من خلال التحليل الإحصائي

- **المنهج النوعي**: لفهم تجربة المستخدمين ومستوى رضاهم

- **المنهج التطبيقي**: لتطوير واختبار النظام عملياً

2-تصميم الدراسة: تصميم تجريبي مقارن (Comparative Experimental Design) يتضمن:

- **مجموعة تجريبية**: تستخدم النظام المطور مع الطرق التقليدية

- **مجموعة ضابطة**: تستخدم الطرق التقليدية فقط

- **اختبار قبلي وبعدي**: لقياس التحسن في الأداء

3- مراحل تطوير النظام:

المرحلة الأولى - التحليل والتصميم:

- تحليل المتطلبات الوظيفية وغير الوظيفية

- تصميم معمارية النظام

- اختيار التقنيات والأدوات المناسبة

- تصميم قاعدة البيانات

المرحلة الثانية - جمع البيانات وإعدادها:

- جمع صور الأشعة البانورامية من مصادر متعددة

- تصنيف الصور من قبل خبراء متخصصين

- تنظيف وإعداد البيانات للتدريب

- توزيع البيانات على مجموعات التدريب والاختبار

المرحلة الثالثة - التطوير والتدريب:

- تطوير نماذج التعلم الآلي

- تدريب النماذج على البيانات المعدة

- ضبط معاملات النماذج لتحسين الأداء

- اختبار النماذج الأولية

المرحلة الرابعة - التكامل والاختبار:

- تطوير واجهة المستخدم

- دمج النماذج مع النظام الكامل

- اختبار النظام تقنياً ووظيفياً

- إجراء التعديلات اللازمة

4- جمع البيانات:

البيانات الأساسية:

- صور الأشعة البانورامية (هدف: 5000-10000 صورة)

- التشخيصات المرجعية من أطباء متخصصين

- البيانات السريرية للمرضى

- معلومات تقنية عن الصور

البيانات التطبيقية:

- نتائج التشخيص باستخدام النظام والطرق التقليدية

- أوقات التشخيص المسجلة

- تقييمات دقة التشخيص

- بيانات الأداء التقني للنظام

5- أدوات جمع البيانات:

- استبيانات إلكترونية لتقييم رضا المستخدمين

- نماذج تقييم الأداء التشخيصي
- سجلات زمنية للتشخيص
- استمارات تسجيل الأخطاء والملاحظات

تاسعا: هيكل الدراسة

الفصل الأول: الإطار العام للدراسة

- مقدمة الدراسة
- مشكلة الدراسة
- أهداف الدراسة
- أهمية الدراسة
- حدود الدراسة
- مصطلحات الدراسة

الفصل الثاني: الإطار النظري والدراسات السابقة

- الذكاء الاصطناعي في الطب
- أنظمة دعم القرار الطبي
- التشخيص الإشعاعي في طب الأسنان

- الأشعة البانورامية: المفاهيم والتطبيقات
- تقنيات التعلم الآلي في تحليل الصور الطبية
- الدراسات السابقة وتحليلها

الفصل الثالث: منهجية الدراسة

- منهج الدراسة
- تصميم الدراسة
- مجتمع وعينة الدراسة
- أدوات جمع البيانات
- إجراءات الدراسة
- المعالجة الإحصائية

الفصل الرابع: تطوير النظام

- متطلبات النظام
- تصميم النظام
- خوارزميات التعلم الآلي المستخدمة
- قاعدة البيانات وإعداد البيانات

- تطوير واجهة المستخدم

- اختبار وتحسين النظام

الفصل الخامس: تطبيق النظام وجمع البيانات

- إعداد بيئة التطبيق

- تدريب المستخدمين

- جمع البيانات التجريبية

- مراقبة الأداء والجودة

- التحديات والحلول

الفصل السادس: تحليل النتائج ومناقشتها

- تحليل دقة النظام التشخيصية

- تقييم كفاءة الوقت والأداء

- تحليل رضا المستخدمين

- مقارنة النتائج مع الدراسات السابقة

- مناقشة النتائج في ضوء الأهداف والفرضيات

الفصل السابع: الخلاصة والتوصيات

- ملخص النتائج الرئيسية
- مساهمات الدراسة العلمية والعملية
- التوصيات للتطبيق العملي
- اقتراحات للدراسات المستقبلية
- خاتمة الدراسة

المراجع الأولية

المراجع العربية:

1. أحمد، محمد علي. (2023). "تطبيقات الذكاء الاصطناعي في التشخيص الطبي: دراسة استطلاعية". مجلة الطب الرقمي، 15(3)، 45-62.
2. الخطيب، فاطمة سعد. (2022). "أنظمة دعم القرار في طب الأسنان: المفاهيم والتطبيقات". مجلة طب الأسنان العربية، 28(2)، 78-95.
3. سليمان، أحمد محمود. (2023). "تحليل الصور الطبية باستخدام التعلم العميق". دار النشر العلمي، الرياض.
4. العتيبي، نورا عبدالله. (2022). "جودة الرعاية الصحية في عصر الذكاء الاصطناعي". مؤتمر الصحة الرقمية، جامعة الملك سعود، 123-140.
5. محمد، سارة أحمد. (2023). "تقييم أنظمة التشخيص الآلي في طب الأسنان". رسالة ماجستير، جامعة القاهرة.

المراجع الأجنبية:

6. Bianchi, J., Soares, A. B., Belém, M. D., & Manzi, F. R. (2023). Artificial intelligence in oral radiology: A systematic review. *Dentomaxillofacial Radiology*, 52(4), 287-301.

7. Chen, H., Zhang, K., Lyu, P., Li, H., Zhang, L., Wu, J., & Lee, C. H. (2023). Deep learning approach for automatic detection of pathological findings in panoramic radiographs. *Scientific Reports*, 13(1), 8925.
8. Ezhov, M., Gusarev, M., Golitsyna, M., Yates, J. M., Kushner, G., Shumilov, E., ... & Orhan, K. (2023). Clinically applicable artificial intelligence system for dental diagnosis with CBCT. *International Journal of Computer Assisted Radiology and Surgery*, 18(5), 937–947.
9. Fukuda, M., Inamoto, K., Shibata, N., Arijii, Y., Yanashita, Y., Kutsuna, S., ... & Arijii, E. (2023). Evaluation of an artificial intelligence system for detecting vertical root fracture on panoramic radiography. *Oral Radiology*, 39(2), 321–329.
10. Geetha, V., Aprameya, K. S., Hinduja, A., Karthikeyan, I., Jeeva, S., & Kalbande, S. (2023). Artificial intelligence in dentistry: A scoping review. *Cureus*, 15(3), e36490.
11. Hung, K., Montalvao, C., Tanaka, R., Kawai, T., & Bornstein, M. M. (2023). The use and performance of artificial intelligence applications in dental and maxillofacial radiology: A systematic review. *Dentomaxillofacial Radiology*, 52(1), 20220175.

12. Jeon, S. J., Yun, J. P., Choi, Y. J., Lim, H. J., Lee, J. H., & Choi, Y. J. (2023). Deep learning for detection of vertical root fractures in endodontically treated teeth on panoramic radiographs. *Journal of Personalized Medicine*, 13(2), 239.
13. Kim, J. H., Kim, Y. S., Kim, J. H., & Hwang, J. J. (2023). Artificial intelligence for caries detection: A systematic review. *Journal of Dental Research*, 102(4), 365–373.
14. Lee, J. H., Kim, D. H., Jeong, S. N., & Choi, S. H. (2023). Detection and diagnosis of dental caries using a deep learning–based approach on intraoral photographs. *Applied Sciences*, 13(5), 3016.
15. Moran, M., Faria, M., Giraldi, G., Bastos, L., Oliveira, L., & Conci, A. (2023). Classification of approximal caries in bitewing radiographs using convolutional neural networks. *Sensors*, 23(6), 3145.
16. Nguyen, T. T., Larrivée, N., Lee, A., Bilaniuk, O., & Durand, R. (2023). Use of artificial intelligence in dentistry: Current clinical trends and research advances. *Journal of the Canadian Dental Association*, 89, g7.

17. Panda, S., Chandra, S., Tripathi, A., Goswami, S., Hasan, M. F., & Dhiman, N. (2023). Artificial intelligence in dental radiology: Achievements, challenges, and future directions. *Cureus*, 15(4), e37987.
18. Schwendicke, F., Samek, W., & Krois, J. (2023). Artificial intelligence in dentistry: Chances and challenges. *Journal of Dental Research*, 102(7), 769–777.
19. Thurzo, A., Urbanová, W., Novák, B., Czako, L., Siebert, T., Stano, P., ... & Varga, I. (2023). Where artificial intelligence meets dentistry: A comprehensive review. *International Journal of Environmental Research and Public Health*, 20(5), 4095.
20. Vinayahalingam, S., Kempers, S., Limon, L., Deibel, D., Maal, T., Hanisch, M., ... & Bergé, S. (2023). Deep learning for automated detection of cysts and tumors in panoramic radiographs. *Journal of Imaging*, 9(1), 19.
21. Wang, S., Yang, D. M., Rong, R., Zhan, X., & Xiao, G. (2023). Pathology image analysis using segmentation deep learning algorithms. *American Journal of Pathology*, 193(11), 1686–1699.

22. Zaorska, K., Szczupak, M., Konieczka, M., Rzepkowska, A., Grendziuk, J., Marchewka, J., ... & Cipora, E. (2023). Artificial intelligence in dentistry: A comprehensive review. *Healthcare*, 11(6), 886.