



جامعة ميدأوشن

كلية الإدارة

قسم إدارة الأعمال - ماجستير إدارة الأعمال

العلاقة بين التوسع في استخدام تقنيات الذكاء الاصطناعي
وكفاءة قرارات الموافقات الطبية المسبقة

دراسة حالة طويلة تطبيقية في شركة بوبا العربية للتأمين التعاوني
بالمملكة العربية السعودية

بحث تطبيقي مقدم استكمالاً لمتطلبات الحصول على درجة ماجستير إدارة
الأعمال

إعداد الطالب: محمد عبدالرحمن حسين عيسى

الرقم الأكاديمي: 253000097

إشراف:

العام الجامعي: 2026

بيان حقوق الطباعة

أُعد هذا البحث لأغراض أكاديمية ضمن متطلبات برنامج ماجستير إدارة الأعمال بجامعة ميدأوشن، وتعود حقوق الطباعة والإيداع الأكاديمي للجامعة وفق لوائحها المعتمدة. أما البيانات التشغيلية المستخدمة فتظل خاضعة لحقوق الجهة المالكة وسياساتها الخاصة بالسرية والاستخدام المصرح به.

يلتزم الباحث بالأمانة العلمية ودقة التوثيق، وبحماية سرية المعلومات المهنية؛ لذلك اعتمدت الدراسة على مؤشرات تشغيلية مجمعة فقط، من دون إدراج أي بيانات شخصية أو معلومات تعريفية تخص الأعضاء المؤمن لهم أو مقدمي الخدمة.

المستخلص

هدفت هذه الدراسة إلى فحص العلاقة بين التوسع التدريجي في استخدام تقنيات الذكاء الاصطناعي والأتمتة وبين كفاءة عمليات الموافقات الطبية المسبقة في شركة بوبا العربية للتأمين التعاوني. وتمثلت المشكلة البحثية في أن ارتفاع المعالجة الآلية لا يساوي بالضرورة ارتفاع استخدام الذكاء الاصطناعي، كما أن التحسن في السرعة قد يخفي ضغوطاً على المسار اليدوي أو تغييراً في جودة القرار. واعتمدت الدراسة تصميم دراسة حالة طولية تطبيقية يستند إلى مؤشرات تشغيلية مجمعة تغطي الفترة من يناير 2022 حتى 29 يوليو 2026. وتمثل مجتمع الدراسة التشغيلي في طلبات الموافقات المسبقة الممثلة بهذه المؤشرات، من دون استخدام بيانات تعريفية على مستوى الأعضاء أو مقدمي الخدمة.

استخدم التحليل الإحصاء الوصفي ونسب التغير والمقارنة الزمنية، إضافة إلى مقارنة متناظرة بين يناير-يوليو 2025 والفترة نفسها من 2026. كما استُخدم اختبار t للعينات المترابطة واختبار Wilcoxon للتحقق من الفروق الشهرية. وأظهرت النتائج ارتفاع الحجم السنوي من 14 مليون طلب في 2022 إلى 20 مليوناً في 2025 (+42.9%)، بالتزامن مع ارتفاع حصة المعالجة الآلية من 56.1% إلى قرابة 68%. وظل زمن الاستجابة الكلي قريباً من 93% خلال السنوات الكاملة، في حين انخفض أداء المسار اليدوي من 85.4% في 2022 إلى 82.6% في 2025. وبقي معدل إعادة العمل في نطاق 1.4%-1.5% خلال السنوات الكاملة.

وفي المقارنة المتناظرة ارتفع حجم الطلبات في يناير-يوليو 2026 بنسبة 13.8% عن الفترة نفسها من 2025، بينما انخفض زمن الاستجابة المرجح بالحجم من 94.08% إلى 92.82%. وكانت الفروق الشهرية دالة إحصائياً للحجم ($p=0.018$) ولزمن الاستجابة ($p=0.003$)، وأكد اختبار Wilcoxon الاتجاه نفسه. وتخلص الدراسة إلى وجود ارتباط واضح بين التوسع التقني والقدرة على استيعاب النمو، مع بقاء أثره على جودة القرار أقل حسماً بسبب ثبات إعادة العمل، واتساع فجوة المسار اليدوي، وعدم توفر مؤشر تاريخي مستقل يفصل قرارات الذكاء الاصطناعي عن الأتمتة القائمة على القواعد.

الكلمات المفتاحية: الذكاء الاصطناعي، الموافقات الطبية المسبقة، التأمين الصحي، الأتمتة، زمن الاستجابة، إعادة العمل، بوبا العربية.

الشكر والتقدير

أتقدم بالشكر والتقدير لجامعة ميدأوشن وللمشرف الأكاديمي وأعضاء الهيئة التعليمية على ما قدموه من توجيه منهجي خلال إعداد هذا البحث. كما أشكر الزملاء الذين أسهموا في توضيح التعريفات التشغيلية ومراجعة سياق البيانات المستخدمة. وأقدر للجهة المهنية إتاحة المؤشرات المجمعة اللازمة للدراسة في الحدود المسموح بها، مع الالتزام التام بسرية البيانات وعدم استخدامها خارج الغرض الأكاديمي.

فهرس المحتويات

الصفحة	العنوان
1	الفصل الأول: الإطار العام للدراسة
1	1.1 المقدمة
1	1.2 مشكلة الدراسة
2	1.3 أسئلة الدراسة
2	1.4 أهداف الدراسة
2	1.5 أهمية الدراسة
2	1.6 فرضيات الدراسة
3	1.7 التعريفات التشغيلية
3	1.8 النظرية العلمية المتبعة لإعداد البحث
3	1.9 حدود الدراسة
5	الفصل الثاني: مراجعة الأدبيات والإطار النظري
5	2.1 مفهوم الذكاء الاصطناعي والأتمتة في دعم القرار
5	2.2 المتغير المستقل: التوسع في استخدام الذكاء الاصطناعي والأتمتة
5	2.3 المتغير التابع: كفاءة قرارات الموافقات الطبية المسبقة
5	2.4 الذكاء الاصطناعي في الرعاية الصحية والتأمين الصحي
6	2.5 الذكاء الاصطناعي في الموافقات الطبية المسبقة
6	2.6 الحوكمة والمراجعة البشرية
6	2.7 النظرية العلمية المتبعة
7	2.8 النموذج المفاهيمي
8	2.9 الدراسات السابقة: مقارنة تحليلية
8	2.10 الفجوة البحثية
9	الفصل الثالث: منهجية الدراسة
9	3.1 مقدمة المنهجية
9	3.2 تصميم الدراسة
9	3.3 مجتمع الدراسة ووحدة التحليل
9	3.4 خصائص العينة وتحديد حجمها
9	3.5 الفترات التحليلية
10	3.6 مصادر البيانات وإجراءات جمعها
10	3.7 المتغيرات وأساليب القياس

الصفحة	العنوان
10	3.8 أساليب التحليل الإحصائي
11	3.9 جودة البيانات والمتغيرات المركبة
11	3.10 محددات الدراسة
11	3.11 الاعتبارات الأخلاقية وسرية البيانات
12	الفصل الرابع: الدراسة التطبيقية وتحليل البيانات والنتائج
12	4.1 مقدمة الدراسة التطبيقية
12	4.2 وصف البيانات والاتجاه السنوي
12	4.3 حجم الطلبات والمعالجة الآلية
13	4.4 أداء زمن الاستجابة
13	4.5 عدم الحاجة إلى موافقة مسبقة والرفض وإعادة العمل
13	4.6 مقارنة يناير-يوليو 2025 و2026
14	4.7 اختبار الفروق بين الفترتين
14	4.8 ملخص الفرضيات
15	4.9 النتائج الرئيسية
15	4.10 محددات تفسير النتائج
16	الفصل الخامس: المناقشة والاستنتاجات والتوصيات
16	5.1 مقدمة المناقشة
16	5.2 مناقشة النتائج في ضوء الدراسات السابقة
16	5.3 الاستنتاجات
17	5.4 الإجابة عن سؤال الدراسة
17	5.5 الآثار الإدارية والاستراتيجية
18	5.6 التوصيات التنفيذية
19	5.7 إطار مقترح لتقييم تجربة التوسع في التنويع
19	5.8 خارطة طريق للتوسع المسؤول
20	5.9 مقترحات للبحوث المستقبلية
21	المراجع
23	الملاحق
24	Abstract

قائمة الجداول

الصفحة	عنوان الجدول
3	الجدول 1-1: التعريفات التشغيلية للمتغيرات
8	الجدول 1-2: مقارنة تحليلية للدراسات السابقة
9	الجدول 1-3: الفترات التحليلية
10	الجدول 2-3: المتغيرات ومصادرها
11	الجدول 3-3: المتغيرات المركبة واستراتيجية الحد منها
12	الجدول 1-4: مؤشرات لوحة العمليات 2022-2026
13	الجدول 2-4: الفجوة بين زمن الاستجابة الكلي واليدوي
13	الجدول 3-4: مقارنة يناير-يوليو 2025 و2026
14	الجدول 4-4: اختبارات الفروق الشهرية والتحقق غير المعلمي
14	الجدول 5-4: ملخص اختبار الفرضيات
18	الجدول 1-5: التوصيات التنفيذية
19	الجدول 2-5: إطار قياس تجربة التوسع في التنويع
19	الجدول 3-5: خارطة طريق للتوسع المسؤول

قائمة الأشكال

الصفحة	عنوان الشكل
7	الشكل 1-2: النموذج المفاهيمي للدراسة

قائمة المصطلحات

المصطلح	التعريف
الموافقة الطبية المسبقة (Pre-Authorization)	عملية مراجعة تسبق تقديم بعض الخدمات للتحقق من التغطية والضرورة الطبية وشروط الوثيقة.
إعادة العمل/تغيير القرار (Rework)	تغير القرار بعد صدوره نتيجة معلومات جديدة أو مراجعة لاحقة أو تصحيح.
حصة المعالجة الآلية (Automated Volume)	نسبة الطلبات التي عولجت آلياً، وتشمل تطبيقات الذكاء الاصطناعي والأتمتة القائمة على القواعد.
زمن الاستجابة للمسار اليدوي (Manual RT)	نسبة الالتزام بزمن الاستجابة في الطلبات التي تتطلب معالجة بشرية.
التعرض لتوسع الذكاء الاصطناعي (AI Exposure)	مرحلة زمنية تبدأ في مارس 2023 وتتوسع تدريجياً، ولا تعني أن كل معالجة آلية ناتجة عن الذكاء الاصطناعي.
الإنسان داخل الحلقة (Human-in-the-loop)	نموذج تشغيل يبقى فيه التدخل أو الإشراف البشري جزءاً من القرار أو من مراجعته.

قائمة الاختصارات

الاختصار	المعنى
AI	Artificial Intelligence - الذكاء الاصطناعي
PA	Pre-Authorization - الموافقة الطبية المسبقة
RT	Response Time - زمن/التزام الاستجابة
NPR	No Prior Authorization Required - لا يحتاج إلى موافقة مسبقة
PBM	Pharmacy Benefit Management - إدارة منافع الصيدلة
FTE	Full-Time Equivalent - مكافئ الدوام الكامل
SLA	Service Level Agreement - اتفاقية مستوى الخدمة
LLM	Large Language Model - نموذج لغوي كبير

الفصل الأول
الإطار العام للدراسة

1.1 المقدمة

لم يعد التحول الرقمي في القطاع الصحي مقتصرًا على التطبيقات السريرية؛ فقد انتقل بصورة واضحة إلى العمليات الإدارية التي تؤثر في سرعة الوصول إلى الخدمة وكفاءة استخدام الموارد. ومن أكثر هذه العمليات حساسية عملية الموافقة الطبية المسبقة، لأنها تقع عند نقطة التقاء التغطية التأمينية والضرورة الطبية وسياسات الوثيقة والوقت التشغيلي. لذلك فإن تحسين هذه العملية لا يرتبط بخفض زمن المعالجة فحسب، بل يرتبط أيضاً باتساق القرار، وإمكانية تفسيره، وقدرة المؤسسة على التعامل مع الزيادة في حجم الطلبات من دون التأثير في سلامة القرار.

أتاحت تقنيات الذكاء الاصطناعي والأتمتة فرصاً جديدة لإعادة تصميم الأعمال المتكررة. ففي بيئات التأمين الصحي يمكن استخدام الخوارزميات في تصنيف الطلبات، واستخراج المعلومات، والتحقق من اكتمال المستندات، ومطابقة بعض الشروط، واقتراح القرار أو إصداره في حالات محددة. ومع ذلك، فإن التوسع في هذه الأدوات يفرض تمييزاً مهماً بين الأتمتة القائمة على قواعد ثابتة وبين الذكاء الاصطناعي الذي يعتمد على البيانات والنماذج في الاستدلال أو التنبؤ؛ لأن الجمع بينهما في مؤشر واحد قد يؤدي إلى تقدير أثر التقنية بصورة غير دقيقة.

وفي المملكة العربية السعودية يتزامن هذا التحول مع توسع البنية الرقمية للتأمين الصحي. فقد أعلن مجلس الضمان الصحي في استراتيجيته 2025-2027 عن توجه نحو منظومة تقودها البيانات والتقنيات الذكية، مع تعزيز استخدام الذكاء الاصطناعي وجودة البيانات والجوكة والكفاءة التشغيلية. كما أعلن المجلس في 2023 وصول منصة نفيس إلى 100 مليون معاملة تأمينية، وهو ما يعكس حجم الاعتماد المتزايد على التبادل الرقمي بين أطراف المنظومة الصحية (مجلس الضمان الصحي، 2023؛ 2025).

ضمن هذا السياق بدأت بوبا العربية في مارس 2023 تطبيق أدوات للذكاء الاصطناعي تدريجياً في عدد من الخدمات المتكررة، ثم اتسع نطاق الاستخدام في مراحل لاحقة. وتوفر المؤشرات الداخلية المجمعة للفترة 2022-29 يوليو 2026 فرصة مناسبة لدراسة العلاقة بين هذا التوسع وبين مؤشرات الكفاءة التشغيلية، مع ضرورة مراعاة أن بعض المعالجة الآلية تعود إلى قواعد أتمتة تقليدية وليست إلى الذكاء الاصطناعي وحده (بوبا العربية، 2026). ومن هنا جاءت الدراسة الحالية لتقديم قراءة تطبيقية متوازنة لا تفترض مسبقاً أن ارتفاع الأتمتة يعني تحسناً تلقائياً في جودة القرار.

1.2 مشكلة الدراسة

تمثل المشكلة البحثية في صعوبة تقدير العلاقة الفعلية بين التوسع في استخدام الذكاء الاصطناعي وبين كفاءة الموافقات الطبية المسبقة عند الاعتماد على مؤشرات تشغيلية مجمعة. فزيادة نسبة المعالجة الآلية قد تكون نتيجة لنمو استخدام نماذج الذكاء الاصطناعي، أو لتوسيع قواعد الأتمتة التقليدية، أو لتغير مزيج الخدمات والعقود؛ ومن ثم لا يمكن التعامل مع مؤشر المعالجة الآلية باعتباره قياساً خالصاً للذكاء الاصطناعي.

وتشير القراءة الأولية للوحة العمليات إلى أن حجم الطلبات السنوي ارتفع من 14 مليون طلب في 2022 إلى 20 مليون طلب في 2025، بالتزامن مع ارتفاع حصة المعالجة الآلية من 56.1% إلى قرابة 68%. وفي الفترة نفسها ظل مؤشر زمن الاستجابة الكلي قريباً من 93%، بينما تراجع أداء المسار اليدوي وبقي معدل إعادة العمل دون تحسن مستمر واضح. هذه المؤشرات تفتح احتماليين متوازيين: الأول أن التوسع التقني ساعد على استيعاب النمو، والثاني أن جزءاً من التعقيد والضغط التشغيلي انتقل إلى الحالات التي بقيت في المسار البشري.

لذلك لا تبحث الدراسة عن إثبات سببية مباشرة لا تسمح بها البيانات، وإنما تفحص نمط الارتباط بين التوسع في الذكاء الاصطناعي والأتمتة وبين مجموعة متوازنة من مؤشرات الكفاءة. كما تراعي التغيرات التشغيلية المصاحبة، ومنها نمو الحجم، وتغير بعض قواعد عدم الحاجة إلى موافقة مسبقة، واختلاف مزيج الطلبات. ويسمح هذا المنظور بإصدار حكم أكثر تحفظاً وقابلية للدفاع الأكاديمي من الحكم المبني على نسبة الأتمتة وحدها.

السؤال الرئيس: ما العلاقة بين التوسع التدريجي في استخدام تقنيات الذكاء الاصطناعي والأتمتة وبين كفاءة عمليات الموافقات الطبية المسبقة في بوبا العربية خلال الفترة 2022-2026؟

1.3 تساؤلات الدراسة

1. كيف تغير حجم الطلبات وحصة المعالجة الآلية بعد بدء تطبيق الذكاء الاصطناعي في مارس 2023؟
2. إلى أي مدى حافظ مؤشر زمن الاستجابة الكلي على استقراره مع نمو حجم الطلبات؟
3. كيف تغير أداء المسار اليدوي، ونسبة عدم الحاجة إلى موافقة مسبقة، والرفض، وإعادة العمل خلال فترة الدراسة؟

4. هل توجد فروق ذات دلالة إحصائية بين حجم الطلبات وزمن الاستجابة في يناير-يوليو 2025 والفترة المناظرة من 2026؟
5. ما الاعتبارات التشغيلية والحوكمة التي ينبغي مراعاتها قبل توسيع استخدام الذكاء الاصطناعي إلى خدمات أكثر تعقيداً مثل التنويم؟

1.4 أهداف الدراسة

1. تحليل اتجاهات حجم الطلبات وحصة المعالجة الآلية قبل بدء تطبيق الذكاء الاصطناعي في مارس 2023 وبعده.
2. تقييم استقرار زمن الاستجابة الكلي وتغير أداء المسار اليدوي في ظل نمو حجم الطلبات.
3. تحليل اتجاهات عدم الحاجة إلى موافقة مسبقة والرفض وإعادة العمل وتفسيرها في ضوء التغيرات التشغيلية.
4. إجراء مقارنة زمنية متناظرة بين يناير-يوليو 2025 ويناير-يوليو 2026 لاختبار الفروق في الحجم وزمن الاستجابة.
5. صياغة إطار للقياس والحوكمة يساعد الإدارة على التوسع المسؤول في استخدام الذكاء الاصطناعي في الموافقات الطبية.

1.5 أهمية الدراسة

1.5.1 الأهمية العلمية

تتبع الأهمية العلمية من تناول الدراسة لتطبيق إداري غير سريري للذكاء الاصطناعي داخل قطاع التأمين الصحي، وهو مجال ما تزال الأدلة التطبيقية فيه أقل عدداً مقارنة بالتطبيقات التشخيصية والعلاجية. كما أن الدراسة لا تعتمد على اتجاهات الموظفين وحدها، بل تستند إلى مؤشرات تشغيلية ممتدة عبر عدة سنوات، بما يسمح بفهم التغير في القدرة الاستيعابية والأداء الزمني وجودة القرار بصورة أكثر ارتباطاً بالواقع التشغيلي.

وتضيف الدراسة حالة تطبيقية من البيئة السعودية، كما تفصيل منهجياً بين الذكاء الاصطناعي والأتمتة القائمة على القواعد، وتتعامل مع الكفاءة باعتبارها مفهوماً متعدد الأبعاد لا يختزل في معدل الأتمتة. وتساعد هذه المعالجة في توسيع النقاش الأكاديمي من سؤال «كم عدد الحالات التي تمت أتمتتها؟» إلى سؤال أكثر عمقاً يتعلق بما إذا كان التوسع قد صاحبه قدرة أفضل على استيعاب الطلبات مع الحفاظ على جودة القرار.

1.5.2 الأهمية العملية

توفر الدراسة للإدارة إطاراً يمكن استخدامه عند تقييم التوسع في أدوات الذكاء الاصطناعي، لأنها تجمع بين مؤشرات الحجم وزمن الاستجابة وإعادة العمل والمسار اليدوي بدلاً من الاعتماد على مؤشر منفرد. كما تساعد على تحديد إشارات الإنذار المبكر، مثل اتساع فجوة الأداء بين المسارين الآلي واليدوي أو ارتفاع تغيير القرار بعد صدوره.

وتكتسب النتائج المتوقعة أهمية خاصة عند الانتقال من الخدمات البسيطة والمتكررة إلى خدمات أعلى تعقيداً. فالتوسع في التنويم، على سبيل المثال، يحتاج إلى عتبات واضحة للتصعيد والمراجعة البشرية، ومؤشرات جودة مستقلة، وفصل دقيق بين القرار المباشر والتوصية الآلية. وبذلك يمكن للدراسة أن تدعم قراراً إدارياً يوازن بين الكفاءة والسرعة من جهة، والسلامة والحوكمة من جهة أخرى.

1.6 فرضيات الدراسة

تنطلق الفرضيات من طبيعة البيانات المتاحة ومن تعريف الكفاءة بصورة متعددة الأبعاد. ولأن الدراسة لا تمتلك متغيراً مستقلاً نقيماً يقيس حجم قرارات الذكاء الاصطناعي وحدها، فإن صياغة الفرضيات تركز على التوسع في الذكاء الاصطناعي والأتمتة بوصفه تدخلاً تشغيلياً تدريجياً، مع تجنب الادعاء السببي المباشر.

الفرضية الرئيسة: يرتبط التوسع التدريجي في استخدام تقنيات الذكاء الاصطناعي والأتمتة بتحسين القدرة التشغيلية لعمليات الموافقات الطبية المسبقة، مع بقاء جودة القرار والضغط على المسار اليدوي عاملين حاسمين في تقييم الكفاءة الكلية.

- H1a: ترتفع حصة المعالجة الآلية بعد بدء تطبيق الذكاء الاصطناعي في مارس 2023.

- H1b: يرتبط التوسع في الأتمتة بالمحافظة على استقرار مؤشر زمن الاستجابة الكلي رغم نمو حجم الطلبات خلال السنوات الكاملة.
- H1c: لا يصاحب التوسع في الأتمتة تدهور جوهري ومستمر في معدل إعادة العمل خلال السنوات الكاملة.
- H1d: توجد فروق ذات دلالة إحصائية بين الحجم الشهري للطلبات في يناير-يوليو 2025 والفترة المناظرة من 2026.
- H1e: توجد فروق ذات دلالة إحصائية بين مؤشر زمن الاستجابة الشهري في يناير-يوليو 2025 والفترة المناظرة من 2026.

1.7 التعريفات التشغيلية للمتغيرات

الجدول 1-1: التعريفات التشغيلية للمتغيرات

المتغير/المؤشر	التعريف التشغيلي
التوسع في الذكاء الاصطناعي والأتمتة	مرحلة زمنية تبدأ في مارس 2023 وتتوسع تدريجياً. وتستخدم حصة المعالجة الآلية مؤشراً مسانداً، لا قياساً خالصاً للذكاء الاصطناعي.
حصة المعالجة الآلية	نسبة الطلبات التي عولجت آلياً، وتشمل تطبيقات الذكاء الاصطناعي والأتمتة القائمة على القواعد.
زمن الاستجابة الكلي (Total RT)	نسبة الالتزام بزمن الاستجابة المحدد لجميع الطلبات.
زمن الاستجابة اليدوي (Manual RT)	نسبة الالتزام بزمن الاستجابة في الطلبات التي تتطلب معالجة بشرية.
عدم الحاجة إلى موافقة مسبقة (NPR)	حالة لا تتطلب موافقة مسبقة وفق قواعد النظام؛ ولا تعد قرار رفض.
الرفض (Rejection/Volume Waste)	نسبة الطلبات المرفوضة كما تظهر في لوحة العمليات، مع تفسيرها بحسب السياق التشغيلي.
إعادة العمل (Rework)	حالة يتغير قرارها بعد القرار الأول نتيجة مراجعة لاحقة أو معلومات جديدة أو تصحيح.
الكفاءة التشغيلية	مفهوم مركب يجمع القدرة على استيعاب الحجم، والالتزام الزمني، واستقرار القرار وجودته؛ ولا يقاس بمؤشر منفرد.

المصدر: إعداد الباحث استناداً إلى تعريفات لوحة العمليات والإطار التحليلي للدراسة.

1.8 النظرية العلمية والنموذج النظري للدراسة

يعتمد البحث على المنظور الاجتماعي-التقني بوصفه الإطار النظري الرئيس. ويفترض هذا المنظور أن أداء النظام لا ينتج عن التقنية منفردة، وإنما عن تفاعلها مع تصميم العمل والأفراد والقواعد والحوكمة. وقد أوضح (Bostrom and Heinen 1977) أن نجاح نظم المعلومات يرتبط بمواءمة المكونات التقنية والاجتماعية داخل المنظمة. وتظهر أهمية هذا المنظور في الدراسة الحالية لأن نقل الحالات البسيطة إلى المسار الآلي قد يغير طبيعة العمل المتبقي لدى المراجعين البشر، فيبدو أداء المسار اليدوي أقل رغم أن السبب قد يكون زيادة تعقيد مزيج الحالات لا ضعف الكفاءة الفردية.

ويستخدم البحث منظور القدرات الديناميكية بصورة مساندة. فوفق (Teece et al. 1997)، لا تتحول التقنية إلى ميزة مؤسسية بمجرد امتلاكها؛ بل تتولد القيمة عندما تستطيع المنظمة استشعار

فرص الاستخدام، وتخصيص الموارد، ثم إعادة تشكيل العمليات مع تغير البيئة. ومن ثم فإن التوسع الناجح في الذكاء الاصطناعي داخل الموافقات الطبية يقتضي قياس الأداء، والتعلم من حالات إعادة العمل والاعتراض، وتعديل عتبات التصعيد والنطاق والموارد بدلاً من التعامل مع الأتمتة كهدف مستقل. يتيح الجمع بين المنظورين تفسير نتائج الدراسة بصورة أكثر توازناً؛ فارتفاع حصة المعالجة الآلية قد يحسن القدرة الاستيعابية، لكن أثره النهائي على الكفاءة يعتمد على جودة البيانات، ووضوح قواعد القرار، وتكامل النظام مع سير العمل، ومهارة المستخدمين، ومستوى الإشراف البشري، وحجم وتعقيد الحالات.

الشكل 1-1: النموذج النظري للعلاقة بين التوسع التقني وكفاءة الموافقات الطبية

المتغير المستقل	آليات وعوامل وسيطة	المتغير التابع
التوسع في استخدام الذكاء الاصطناعي والأتمتة	جودة البيانات والتكامل التدريب والحوكمة التصعيد والمراجعة البشرية حجم وتعقيد الطلبات	كفاءة الموافقات الطبية القدرة الاستيعابية زمن الاستجابة استقرار القرار وإعادة العمل

المصدر: إعداد الباحث استناداً إلى المنظور الاجتماعي-التقني ومنظور القدرات الديناميكية والدراسات السابقة.

1.9 حدود الدراسة ومحدداتها

- الحدود الموضوعية: تركز الدراسة على العلاقة بين التوسع في الذكاء الاصطناعي والأتمتة وبين كفاءة عمليات الموافقات الطبية المسبقة، ولا تتناول جميع تطبيقات الذكاء الاصطناعي في الشركة.
- الحدود المكانية: قسم الموافقات الطبية في شركة بوبا العربية للتأمين التعاوني بالمملكة العربية السعودية.
- الحدود الزمنية: المؤشرات التشغيلية من يناير 2022 حتى 29 يوليو 2026.
- الحدود المنهجية: تعتمد الدراسة على مؤشرات تشغيلية مجمعة، ولا يتوفر في النسخة الحالية ملف معاملات خام أو مؤشر مستقل يفصل جميع قرارات الذكاء الاصطناعي عن الأتمتة القائمة على القواعد؛ لذلك تستخدم الدراسة لغة الارتباط ولا تدعي إثبات السببية.
- حدود السرية: لا تتضمن الدراسة بيانات تعريفية على مستوى العضو أو مقدم الخدمة، ولا تعرض صوراً داخلية للوحة العمليات.
- محددات التفسير: قد تؤثر تغيرات العقود، والموارد البشرية، ومزيج الخدمات، وقواعد NPR، والموسمية، والأعطال التقنية في بعض المؤشرات خلال فترة الدراسة.

1.10 خلاصة الفصل

حدد الفصل الأول المشكلة البحثية وأهداف الدراسة وأسئلتها وفرضياتها وحدودها، ويُن أن تقييم أثر التوسع التقني يحتاج إلى أكثر من متابعة نسبة المعالجة الآلية. كما وضع المنظور الاجتماعي-التقني ومنظور القدرات الديناميكية أساساً تفسيريًا يربط التقنية بتصميم العمل والحوكمة والتعلم المؤسسي. وينتقل الفصل الثاني إلى مراجعة الأدبيات بصورة أعمق، وتحديد المتغيرين المستقل والتابع، ومناقشة الدراسات السابقة والفجوة التي تستهدفها الدراسة الحالية.

الفصل الثاني
مراجعة الأدبيات والإطار النظري

2.1 مقدمة الفصل

يهدف هذا الفصل إلى بناء الأساس النظري الذي يفسر العلاقة بين التوسع في استخدام الذكاء الاصطناعي وبين كفاءة عمليات الموافقات الطبية المسبقة. ويبدأ بتوضيح الفرق بين الذكاء الاصطناعي والأتمتة القائمة على القواعد، ثم يعرض طبيعة عملية الموافقة المسبقة بوصفها عملية قرار إداري-طبي متعددة الخطوات. بعد ذلك يحدد المتغير المستقل والمتغير التابع ومؤشرات قياسهما، قبل الانتقال إلى الأدبيات المتعلقة بالذكاء الاصطناعي في الرعاية الصحية والتأمين الصحي والموافقات المسبقة.

ولا تقتصر المراجعة على عرض فوائد التقنية، بل تشمل أيضاً مخاطر الاعتماد المفرط على الخوارزميات، وقابلية التفسير، والتحيز، والحاجة إلى المراجعة البشرية. ويختتم الفصل بمقارنة تحليلية للدراسات السابقة وتحديد أوجه الاتفاق والاختلاف والفجوة البحثية، بحيث تكون العلاقة بين الأدبيات وتصميم الدراسة الحالية واضحة وقابلة للتتبع.

2.2 مفهوم الذكاء الاصطناعي والأتمتة في دعم القرار

يشير الذكاء الاصطناعي في السياق الإداري إلى نظم تستخدم البيانات والخوارزميات لتنفيذ مهام تتطلب عادةً تصنيفاً أو استدلالاً أو تنبؤاً أو اقتراح قرار. أما الأتمتة التقليدية فتعتمد على قواعد وشروط مبرمجة مسبقاً، بحيث تكون العلاقة بين المدخل والنتيجة محددة سلفاً. وفي التطبيق العملي قد يعمل النوعان داخل المسار نفسه؛ لذلك فإن التمييز بينهما ليس مسألة لغوية، بل مسألة قياس تؤثر مباشرة في تفسير النتائج.

تزداد أهمية هذا التمييز في أنظمة الموافقات الطبية، فمطابقة حد مالي محدد أو شرط وثيقة واضح مثال على أتمتة قائمة على قاعدة، بينما تصنيف مستندات غير منظمة أو تقدير احتمال تأخر الطلب أو تقديم توصية اعتماداً على نمط تعلم من البيانات أقرب إلى تطبيقات الذكاء الاصطناعي. ويؤدي دمج المخرجات المختلفة تحت مسمى «المعالجة الآلية» إلى خطر نسبة أثر القواعد التقليدية إلى الذكاء الاصطناعي، ولذلك تستخدم الدراسة حصة المعالجة الآلية مؤشراً مسانداً ولا تعاملها كمتغير نقى.

وتشير أدبيات الرعاية الصحية إلى أن قيمة الذكاء الاصطناعي لا تعتمد على الأداء التقني فقط، بل على جودة البيانات، وملاءمة المهمة، وطريقة دمج النظام في سير العمل، وقدرة المستخدم على فهم المخرجات والتدخل عند الحاجة (Jiang et al., 2017; Davenport & Kalakota, 2019). وهذه الفكرة تعد أساساً مهماً عند الانتقال من تطبيقات دعم القرار إلى قرارات قد تؤثر في توقيت حصول المريض على خدمة صحية.

2.3 طبيعة عملية الموافقة الطبية المسبقة

الموافقة الطبية المسبقة هي عملية تسبق تقديم بعض الخدمات للتحقق من أهلية العضو، والتغطية، وشروط الوثيقة، وملاءمة الخدمة، وتوافر المعلومات السريرية، إصدار القرار، ثم المراجعة اللاحقة أو الاعتراض عند الحاجة. ويختلف الدور الممكن للذكاء الاصطناعي من حلقة إلى أخرى؛ فقد يكون مناسباً للاستخراج والتصنيف في مرحلة الاستقبال، بينما تتطلب القرارات المعقدة أو عالية الخطورة مستوى أكبر من الإشراف البشري.

من منظور العمليات، يمكن تقسيم المسار إلى خمس حلقات مترابطة: استقبال الطلب وتصنيفه، التحقق من التغطية والقواعد، مراجعة المعلومات السريرية، إصدار القرار، ثم المراجعة اللاحقة أو الاعتراض عند الحاجة. ويختلف الدور الممكن للذكاء الاصطناعي من حلقة إلى أخرى؛ فقد يكون مناسباً للاستخراج والتصنيف في مرحلة الاستقبال، بينما تتطلب القرارات المعقدة أو عالية الخطورة مستوى أكبر من الإشراف البشري.

تمثل الموافقة الطبية المسبقة عبئاً إدارياً ملموساً على مقدمي الخدمة والدافعين، وقد يمتد أثرها إلى توقيت الحصول على الرعاية. وفي مسح متعدد الأطراف شمل 1005 مرضى و1010 من العاملين لدى مقدمي الخدمة و115 من العاملين لدى دافعين خاصين، وجد Sahni et al. (2024) اختلافاً بين الأطراف في تقدير حجم العبء، كما أفاد 65% من ممثلي الدافعين بأن مؤسساتهم تخطط لإدخال الذكاء الاصطناعي في العملية خلال ثلاث إلى خمس سنوات. وتبرز هذه النتيجة أن تقييم التقنية ينبغي أن يجمع بين تخفيف العبء، وجودة القرار، وجاهزية البنية التشغيلية والحوكمة.

2.4 المتغير المستقل: التوسع في استخدام الذكاء الاصطناعي والأتمتة

يمثل المتغير المستقل التفسيري في الدراسة التوسع التدريجي في استخدام الذكاء الاصطناعي والأتمتة داخل مسار الموافقات الطبية. ويُعرّف زمنياً بدء تطبيق أدوات الذكاء الاصطناعي في مارس 2023 ثم اتساع نطاقها في السنوات اللاحقة. ونظراً إلى أن لوحة العمليات لا تفصل في كل الفترات بين المعالجة القائمة على الذكاء الاصطناعي وبين القواعد التقليدية، تستخدم الدراسة المرحلة الزمنية وحصّة المعالجة الآلية كمؤشرين على مستوى التعرض للتوسع التقني.

وتفرض هذه الصياغة قدرّاً من التحفظ المنهجي. فارتفاع حصّة المعالجة الآلية لا يثبت بمفرده أن الذكاء الاصطناعي هو سبب التغير في مؤشرات الأداء، لكنه يتيح تحليل ما إذا كان التوسع في المسار الآلي قد تزامن مع استيعاب نمو أكبر أو تغير في زمن الاستجابة أو إعادة العمل. وتساعد المقارنة الزمنية قبل وبعد مارس 2023 والمقارنة المتناظرة بين 2025 و2026 في وصف الاتجاه، بينما يبقى الاستدلال السببي خارج حدود البيانات المتاحة.

2.5 المتغير التابع: كفاءة قرارات الموافقات الطبية المسبقة

لا تُعرّف الكفاءة في هذه الدراسة باعتبارها السرعة وحدها. فالقرار الذي يصدر بسرعة ثم يحتاج إلى تعديل متكرر لا يمثل كفاءة مستدامة، كما أن ارتفاع الأتمتة مع تدهور المسار اليدوي قد يخفي انتقال الحالات الأكثر تعقيداً إلى المراجعين البشر. لذلك يُبنى المتغير التابع على أربعة أبعاد مترابطة: القدرة الاستيعابية، والأداء الزمني، واستقرار القرار، وسلامة المسار التشغيلي.

تقاس القدرة الاستيعابية بحجم الطلبات وحصّة المعالجة الآلية، بينما يقاس الأداء الزمني بمؤشر زمن الاستجابة الكلي واليدوي. ويستخدم معدل إعادة العمل مؤشراً على استقرار القرار، في حين تساعد نسب عدم الحاجة إلى موافقة مسبقة والرفض على تفسير كيفية تغير مسار القرارات. ويسمح هذا البناء المتعدد الأبعاد بالتمييز بين التوسع التشغيلي الحقيقي وبين مجرد نقل العمل من قناة إلى أخرى.

2.6 الذكاء الاصطناعي في الرعاية الصحية والتأمين الصحي

تُظهر الأدبيات الصحية أن أفضل استخدام للذكاء الاصطناعي لا يقوم على استبدال المختص، بل على توزيع المهام بين الإنسان والنظام وفق طبيعة القرار. وقد أشار (Topol (2019 إلى قيمة التكامل بين قدرات الإنسان والحوسبة، بينما أوضح (Davenport and Kalakota (2019 أن التطبيقات الإدارية تمثل أحد المسارات المهمة لاستخدام الذكاء الاصطناعي في الصحة. وتدعم هذه الرؤية فكرة توجيه الأتمتة نحو المهام ذات الحجم المرتفع والقواعد الواضحة، مع الاحتفاظ بمراجعة بشرية للحالات الغامضة أو عالية الخطورة.

كما تؤكد أدبيات التعلم العميق أن الأداء المرتفع في بيئة اختبار لا يضمن النجاح التشغيلي ما لم يتحقق التكامل مع سير العمل وتتم مراقبة الأخطاء والانحرافات على أرض الواقع (Esteva et al., 2019). وفي السياق التأميني تصبح هذه النقطة أكثر أهمية لأن قرار التغطية يجمع بين بيانات سريرية وسياسات وثيقة وقيود تعاقدية، وقد يؤدي الخطأ إلى تأخير الخدمة أو رفضها أو زيادة العمل التصحيحي.

وفي السعودية، يوفر توجه مجلس الضمان الصحي نحو البيانات والذكاء الاصطناعي والحوكمة سياقاً مؤسسياً داعماً للتحويل الرقمي (مجلس الضمان الصحي، 2025). غير أن الانتقال من التوجه الاستراتيجي إلى قيمة تشغيلية يتطلب مؤشرات تفصل بين السرعة والجودة، وهذا ما تركز عليه الدراسة الحالية.

2.7 الذكاء الاصطناعي في الموافقات الطبية المسبقة

تشير الدراسات المباشرة في مجال الموافقات المسبقة إلى وجود فرصة حقيقية لتحسين الكفاءة، لكنها لا تقدم دليلاً موثقاً على أن الأتمتة الكاملة هي الحل الأفضل. فقد استخدم Choudhury (2021) and Perumalla التحليلات التنبؤية للتنبؤ المبكر بمسار الرعاية بعد الخروج بهدف تقليل التأخير المرتبط بالموافقة، وأظهرت الدراسة إمكانية استخدام التعلم الآلي للتدخل قبل وصول العملية إلى نقطة الانتظار. وتفيد هذه النتيجة بأن قيمة الذكاء الاصطناعي قد تتحقق من خلال التنبؤ وإدارة سير العمل، لا من خلال إصدار قرار نهائي فقط.

وقدم (Lenert et al. (2023 تصوراً يميز بين الأتمتة القائمة على قواعد ثابتة وبين نهج يعتمد على الذكاء الاصطناعي لمحاكاة تقدير الخبراء. وركزت المقالة على البيانات المعيارية، وقابلية

التفسير، والتحقق المستقل، والمراجعة البشرية. وبرغم طبيعتها المفاهيمية، فإن أهميتها للدراسة الحالية تكمن في وضعها إطاراً واضحاً لنظام موافقات متمركز حول الإنسان، بدلاً من افتراض أن القرار الآلي الكامل يمثل المرحلة الأكثر تقدماً بالضرورة.

وفي 2024، ناقش Mello and Rose استخدام أدوات الذكاء الاصطناعي في قرارات التغطية الصحية، مع التركيز على مخاطر الغموض والاعتماد غير المنضبط على المخرجات الخوارزمية. ويؤكد هذا المنظور أن جودة القرار لا يمكن استنتاجها من السرعة وحدها؛ لذلك تتعامل الدراسة الحالية مع إعادة العمل، والتصعيد، وإمكان المراجعة البشرية بوصفها مؤشرات موازية للأداء الزمني.

وتظهر الأدلة الأحدث توسعاً فعلياً في تطبيقات السوق. فقد وثق (Kunze et al. (2025 انتشار منتجات توليدية في الأعمال الصحية، ومنها منصات للموافقات المسبقة، مع الإشارة إلى قيود تتعلق بالرقابة التنظيمية والاحياز والتكامل والثقة في المخرجات. كما رأى Keng et al. (2025 أن الأتمتة والذكاء الاصطناعي يمكن أن يخففا العبء الإداري في prior authorization والتوثيق وقياس الجودة، بشرط أن يعاد تصميم سير العمل بدلاً من إضافة طبقة تقنية فوق عملية معقدة بالفعل.

وفي 2026 أصبح النقاش أكثر ارتباطاً بحوكمة مراجعة الاستخدام لدى شركات التأمين. فقد أوضح (Mello et al. (2026 أن الذكاء الاصطناعي قد يرفع الكفاءة، لكنه قد يضخم عيوب العملية إذا غابت الشفافية وفهم المستخدم وآليات الرقابة. كما ناقش (Raza et al. (2026 مخاطر استخدام الخوارزميات في مراجعة الموافقات ضمن Medicare Advantage، ولا سيما الرفض واسع النطاق ونقص الشفافية. ويعزز ذلك فرضية الدراسة الحالية بأن التوسع المسؤول يحتاج إلى قياس مستقل للجودة وإبقاء الحكم البشري في الحالات التي لا تحتل قراراً آلياً غير قابل للمراجعة.

2.8 الحوكمة والمراجعة البشرية

تعد الحوكمة جزءاً من الكفاءة وليست قيداً خارجياً عليها. فالنظام الذي يوفر قراراً أسرع لكنه لا يسمح بتفسيره أو الاعتراض عليه قد يرفع مؤشرات السرعة على المدى القصير بينما يزيد مخاطر التصحيح والشكاوى وعدم الثقة. ولهذا تضع منظمة الصحة العالمية مبادئ تشمل حماية الاستقلال البشري، والسلامة، والشفافية وقابلية التفسير، والمساءلة، والإنصاف، والاستدامة عند استخدام الذكاء الاصطناعي في الصحة (World Health Organization, 2021; 2023).

وتترجم هذه المبادئ عملياً إلى مجموعة ضوابط داخل الموافقات الطبية: توثيق مصدر البيانات والقواعد وإصدارات النموذج، وإتاحة مسار اعتراض واضح، ومراقبة الأداء حسب نوع الخدمة والخطورة، وقياس الخطأ وتغيير القرار والتصعيد، وتحديد المسؤولية النهائية، واستخدام مراجعة بشرية أعلى في الحالات المعقدة أو عالية الخطورة. وبعد تطبيق هذه الضوابط ضرورياً قبل الانتقال من التوصية إلى القرار المباشر في خدمات مثل التنويم.

- الفصل بين قرار الذكاء الاصطناعي المباشر، وتوصية الذكاء الاصطناعي، والأتمتة القائمة على القواعد، والمعالجة اليدوية في القياس والتدقيق.
- استخدام عتبات تصعيد واضحة للحالات ناقصة المعلومات أو عالية الخطورة أو غير المعتادة.
- تدقيق عينات من الموافقات والرفض وNPR الآلية ومراجعة أسباب الاختلاف بين النظام والمراجع البشري.
- مراقبة Rework والاعتراضات وأخطاء السياسة أو الضرورة الطبية حسب نوع الخدمة وإصدار النموذج.
- تحديث تدريب المستخدمين ومسؤولياتهم كلما تغير نطاق النظام أو طريقة اتخاذ القرار.

2.9 الإطار النظري للدراسة

2.9.1 المنظور الاجتماعي-التقني

يفسر المنظور الاجتماعي-التقني الأداء باعتباره نتيجة للتفاعل بين النظام التقني والنظام الاجتماعي داخل المنظمة. وبناءً عليه، فإن أثر الذكاء الاصطناعي على الموافقات الطبية لا يمكن تقييمه بمعزل عن تصميم العمل، وتوزيع الحالات، وعدد الموظفين، ومستوى التدريب، وقواعد التصعيد. فإذا انتقلت الطلبات السهلة إلى المسار الآلي، فإن متوسط تعقيد الحالات اليدوية يرتفع، وقد ينخفض أداء المسار اليدوي حتى مع تحسن القدرة الكلية. هذه العلاقة تفسر أهمية تحليل Total

Manual RT و RT معاً بدلاً من استخدام المؤشر الكلي وحده (Bostrom & Heinen, 1977).

2.9.2 منظور القدرات الديناميكية

يركز منظور القدرات الديناميكية على قدرة المؤسسة على إعادة تشكيل مواردها وعملياتها استجابة للتغير. وفي هذه الدراسة يظهر ذلك في الانتقال التدريجي من خدمات بسيطة إلى نطاق أوسع، وفي الحاجة إلى التعلم من الأخطاء وإعادة العمل قبل الانتقال إلى خدمات أكثر تعقيداً. ومن ثم لا تقاس القدرة المؤسسية بنسبة الأتمتة وحدها، بل بقدرة المنظمة على اختيار الاستخدام المناسب، وقياس الأثر، ثم تعديل النطاق والحوكمة والموارد عند ظهور إشارات جديدة (Teece et al., 1997).

2.9.3 تكامل النظريتين في الدراسة الحالية

يستخدم البحث المنظور الاجتماعي-التقني لتفسير كيفية تغير الأداء داخل سير العمل، ويستخدم القدرات الديناميكية لتفسير قدرة المنظمة على تطوير استخدام الذكاء الاصطناعي على مراحل. ويؤدي الجمع بينهما إلى توقع رئيس: قد يرفع التوسع التقني القدرة الاستيعابية، لكن استدامة الأثر تعتمد على جودة التكامل، والتعلم من التغيرات، وإعادة توزيع الموارد، وإبقاء الإنسان داخل الحلقة في الحالات التي تتطلب حكماً أكثر تعقيداً.

2.10 الدراسات السابقة

تم اختيار الدراسات السابقة وفق صلتها بأحد ثلاثة محاور: الذكاء الاصطناعي في الموافقات المسبقة، العبء الإداري والأتمتة، وحوكمة قرارات التغطية. ويبين العرض التالي موضوع كل دراسة وطريقتها وأهم نتيجة يستفيد منها البحث الحالي.

Choudhury & Perumalla (2021): دراسة تطبيقية استخدمت تحليلات تنبؤية وبيانات 1600 حالة للتنبؤ المبكر بمسار الرعاية بعد الخروج. أظهرت إمكانية استخدام التعلم الآلي لتقليل التأخير الناتج عن الموافقة عبر التدخل المبكر في سير العمل. تدعم قياس أثر AI على الزمن والقدرة التشغيلية، وتوضح أن القيمة قد تكون في إدارة المسار لا في القرار المباشر فقط.

Lenert et al. (2023): مقالة مفاهيمية قارنت بين الأتمتة القائمة على قواعد ونهج ذكاء اصطناعي متمركز حول الإنسان في الموافقات المسبقة. ركزت على البيانات المعيارية وقابلية التفسير والتحقق المستقل والمراجعة البشرية. توفر أساساً نظرياً للفصل بين الأتمتة التقليدية والذكاء الاصطناعي ولتصميم الحوكمة البشرية.

Sahni et al. (2024): مسح شمل 1005 مرضى و1010 من العاملين لدى مقدمي الخدمة و115 من العاملين لدى دافعين خاصين. أظهر عبئاً مرتفعاً وتبايناً في الإدراك؛ وذكر 65% من ممثلي الدافعين نية إدخال AI خلال 3-5 سنوات. يدعم أهمية الجمع بين الكفاءة التشغيلية والثقة والبنية التحتية والحوكمة.

Mello & Rose (2024): تحليل سياساتي وقانوني لاستخدام AI في قرارات التغطية الصحية. حذر من الغموض والاعتماد المفرط على الخوارزميات، وأكد ضرورة الحكم البشري ومراعاة ظروف الفرد. يدعم استخدام Rework والتدقيق والتفسير كمؤشرات جودة موازية للسرعة.

Kunze et al. (2025): مراجعة للتطبيقات التجارية للذكاء الاصطناعي التوليدي في سير العمل الصحي. حددت prior authorization ضمن التطبيقات الناشئة، مع مخاطر تنظيمية وإنحياز وتكامل وثقة. توضح أن الانتقال إلى التشغيل يتطلب جاهزية تنظيمية وتقنية وليس نموذجاً جيداً فقط.

Keng et al. (2025): مقالة تحليلية حول استراتيجيات الأتمتة والذكاء الاصطناعي لخفض العبء الإداري. اعتبرت الموافقة المسبقة من المجالات المرشحة للتحسين عبر إعادة تصميم العمليات واستخدام أدوات معلوماتية. تدعم تفسير الذكاء الاصطناعي كأداة لإعادة تصميم العملية، لا كقرار تقني معزول.

Mello et al. (2026): تحليل متخصص في استخدام AI داخل health insurance utilization review. يبين فرص الكفاءة مقابل مخاطر automation

bias والغموض وضعف الحوكمة المؤسسية. يرتبط مباشرة بسؤال الدراسة حول التوسع المسؤول والحاجة إلى مؤشرات جودة وحوكمة.

Raza et al. (2026): مقالة Perspective حول استخدام AI في prior authorization داخل Medicare Advantage. ناقشت مخاطر الرفض واسع النطاق ونقص الشفافية والعبء الناتج عن الاعتراضات. تدعم إبقاء المراجعة البشرية ووضوح أسباب القرار ضمن معايير التوسع.

الجدول 1-2: مقارنة تحليلية للدراسات السابقة

الدراسة	التركيز/المنهج	أهم ما يفيد الدراسة الحالية
Choudhury & Perumalla (2021)	دراسة تطبيقية استخدمت تحليلات تنبؤية وبيانات 1600 حالة للتنبؤ المبكر بمسار الرعاية بعد الخروج.	تدعم قياس أثر التقنية على الزمن والقدرة التشغيلية، وتوضح أن القيمة قد تتحقق من إدارة المسار لا من القرار المباشر فقط.
Lenert et al. (2023)	مقالة مفاهيمية قارنت بين الأتمتة القائمة على قواعد ونهج ذكاء اصطناعي متمركز حول الإنسان في الموافقات المسبقة.	توفر أساساً للفصل بين الأتمتة التقليدية والذكاء الاصطناعي ولتصميم المراجعة البشرية والحوكمة.
Sahni et al. (2024)	مسح شمل 1005 مرضى و1010 من العاملين لدى مقدمي الخدمة و115 من العاملين لدى دافعين خاصين.	يبين حجم العبء الإداري ويزيد أهمية الثقة والبنية التحتية والحوكمة عند تبني الذكاء الاصطناعي.
Vatsal et al. (2024)	اختبار تقني لاستخدام GPT-4 في الإجابة عن أسئلة قائمة على إرشادات الموافقة المسبقة باستخدام سجلات منزوعة الهوية.	يقدم دليلاً تطبيقياً على دعم التحقق من المعايير، مع أداء غير كامل يبرر استمرار التحقق البشري.
Mello & Rose (2024)	تحليل سياساتي وقانوني لاستخدام الذكاء الاصطناعي في قرارات التغطية الصحية.	يدعم استخدام إعادة العمل والتدقيق والتفسير كمؤشرات جودة موازية للسرعة.
Kunze et al. (2025)	مراجعة للتطبيقات التجارية للذكاء الاصطناعي التوليدي في سير العمل الصحي.	توضح أن منصات الموافقات من التطبيقات الناشئة وأن نجاحها يتطلب جاهزية تنظيمية وتقنية.
Keng et al. (2025)	مقالة تحليلية عن الأتمتة والذكاء الاصطناعي لتقليل العبء الإداري.	تدعم إعادة تصميم العملية بدلاً من إضافة طبقة تقنية فوق سير عمل غير محسن.
Mello et al. (2026)	تحليل متخصص في استخدام الذكاء الاصطناعي في مراجعة الاستخدام لدى التأمين الصحي.	يرتبط مباشرة بالتوسع المسؤول والحاجة إلى الشفافية ومؤشرات الجودة والحوكمة.
Raza et al. (2026)	مقالة Perspective عن استخدام الذكاء الاصطناعي في مراجعة الموافقات ضمن Medicare Advantage.	تدعم إبقاء المراجعة البشرية ووضوح أسباب القرار ضمن معايير التوسع.

المصدر: إعداد الباحث استناداً إلى الدراسات المشار إليها في الجدول.

2.11 مناقشة الدراسات السابقة وأوجه الاتفاق والاختلاف

تتفق الدراسات السابقة على ثلاث نقاط رئيسية. أولاً، prior authorization عملية ذات عبء تشغيلي يجعلها مرشحة للأتمتة والتحسين المعلوماتي. ثانياً، تستطيع تقنيات الذكاء الاصطناعي دعم التصنيف والتنبؤ والمراجعة وتسريع بعض الخطوات، لكن فائدتها تعتمد على جودة البيانات

والتكامل مع سير العمل. ثالثاً، لا تكفي السرعة وحدها لتقييم النجاح؛ إذ تبرز الحاجة إلى الشفافية وقابلية التفسير والمراجعة البشرية ومراقبة الأخطاء.

تختلف الدراسات في نوع الدليل الذي تقدمه. فقد اعتمد Choudhury and Perumalla (2021) على بيانات حالات وتطبيق تنبؤي، بينما قدم Lenert et al. (2023) إطاراً مفاهيمياً، واستخدم Sahni et al. (2024) مسحاً واسعاً لأصحاب المصلحة. وأضاف Vatsal et al. (2024) اختباراً تقنياً مباشراً لقدرة نموذج لغوي كبير على الإجابة عن أسئلة قائمة على إرشادات الموافقة المسبقة. أما Mello and Rose (2024) والدراسات المنشورة في 2026 فركزت بصورة أكبر على المخاطر القانونية والحوكمة، في حين تناولت دراسات 2025 انتشار التطبيقات وإمكانات تخفيف العبء الإداري. وهذا التنوع يبرر الحاجة إلى دراسة تشغيلية طويلة تربط التوسع التقني بمؤشرات الأداء الفعلية.

تختلف الدراسة الحالية عن معظم هذه الأعمال في أنها لا تختبر نموذجاً واحداً ولا تعتمد على آراء المستخدمين بوصفها المصدر الرئيس، بل تستخدم مؤشرات تشغيلية مجمعة ممتدة من 2022 إلى يوليو 2026 داخل شركة تأمين صحي. كما تميز صراحةً بين AI والأتمتة التقليدية، وتربط الكفاءة بالقدرة الاستيعابية وزمن الاستجابة الكلي واليدوي وإعادة العمل، وهو ما يسمح بتكوين صورة تشغيلية لا توفرها الدراسات التي تركز على قبول التقنية أو الأداء التقني للنموذج فقط.

2.12 الفجوة البحثية وما تضيفه الدراسة الحالية

رغم تسارع الأدبيات العالمية حول الذكاء الاصطناعي في prior authorization، ما تزال هناك فجوة في الدراسات التي تستخدم بيانات تشغيلية طويلة من شركة تأمين صحي في البيئة السعودية. كما أن جزءاً كبيراً من الأدبيات الحالية إما تصوري أو يركز على جوانب قانونية وأخلاقية أو على تجربة تقنية محددة، بينما تقل الدراسات التي تربط التوسع التقني بمؤشرات أداء تشغيلية متعددة عبر فترة زمنية طويلة.

وتتمثل الفجوة الثانية في الخلط بين AI والأتمتة. فبعض التحليلات تشير إلى «الأتمتة» باعتبارها مرادفاً للذكاء الاصطناعي، بينما قد تكون أجزاء كبيرة من العمل قائمة على قواعد ثابتة. الدراسة الحالية تتعامل مع هذه المشكلة صراحةً، فتستخدم حصة المعالجة الآلية كمؤشر داعم وتوضح أن عدم توفر AI Flag تاريخي مستقل يحد من الاستدلال السببي.

أما الإضافة الثالثة فهي الجمع بين منظور القدرة الاستيعابية ومنظور جودة القرار. فبدلاً من اعتبار ارتفاع الأتمتة أو استقرار RT دليلاً كافياً، تراقب الدراسة أيضاً أداء المسار اليدوي وRework وNPR والرفض. وتسمح هذه المقارنة بتحديد ما إذا كان التوسع قد صاحبه ضغوط خفية على الحالات الأكثر تعقيداً، وهو سؤال إداري مهم قبل توسيع التقنية إلى التنويم أو خدمات أعلى خطورة.

2.13 خلاصة الفصل

أوضحت مراجعة الأدبيات أن الذكاء الاصطناعي يمكن أن يسهم في تخفيف العبء وتسريع بعض مراحل prior authorization، إلا أن النتائج تعتمد على جودة البيانات والتكامل مع سير العمل والحوكمة والمراجعة البشرية. كما دعمت الأدبيات استخدام المنظور الاجتماعي-التقني والقدرات الديناميكية لتفسير العلاقة بين التقنية والأداء التنظيمي. ويؤسس ذلك للجزء التطبيقي من البحث الذي سيختبر الاتجاهات الفعلية في مؤشرات الحجم وزمن الاستجابة وإعادة العمل داخل بوابا العربية مع مراعاة حدود الاستدلال السببي.

الفصل الثالث

منهجية الدراسة

3.1 مقدمة المنهجية

يعرض هذا الفصل تصميم الدراسة، ووحدة التحليل، ومصادر البيانات، وإجراءات جمعها ومراجعتها، والمتغيرات وأساليب القياس، وطريقة التحليل الإحصائي، إضافة إلى اعتبارات الجودة والسرية. وقد اختير التصميم بما يتوافق مع طبيعة البيانات المتاحة؛ فهي مؤشرات تشغيلية مجمعة وليست معاملات فردية خامة.

3.2 تصميم الدراسة

اعتمد البحث تصميم دراسة حالة طويلة تطبيقية تجمع بين التحليل الوصفي والمقارنة الزمنية. وشمل التحليل الاتجاهات السنوية قبل بدء تطبيق الذكاء الاصطناعي وبعده، ثم مقارنة متناظرة بين شهور يناير-يوليو 2025 والشهور نفسها من 2026. ولا تُعرض العلاقة بوصفها سببية؛ لأن البيانات لا تعزل حجم قرارات الذكاء الاصطناعي عن الأتمتة القائمة على القواعد، ولأن الفترة شهدت تغيرات تشغيلية متزامنة.

3.3 مجتمع الدراسة ووحدة التحليل

يتمثل مجتمع الدراسة التشغيلي في طلبات الموافقات الطبية المسبقة الممثلة في لوحة عمليات الموافقات خلال الفترة من يناير 2022 حتى 29 يوليو 2026. وبسبب استخدام بيانات مجمعة، فإن وحدة التحليل الفعلية هي المؤشرات السنوية والشهرية، وليس الطلب الفردي أو العضو المؤمن له أو الموظف. ويحافظ هذا المستوى من التجميع على السرية، لكنه يحد من القدرة على ضبط الاختلافات بين الخدمات والحالات.

3.4 خصائص العينة وتحديد حجمها

لا تعتمد الدراسة على عينة بشرية أو عينة احتمالية من الأعضاء، بل تستخدم الحصر الشامل للمؤشرات المجمعة المتاحة للفترة المحددة. لذلك لا تنطبق معادلات تحديد حجم العينة البشرية على التحليل النهائي. أما المقارنة الإحصائية فتستند إلى سبعة أزواج شهرية متطابقة زمنياً، وهو عدد محدود يقتضي تفسير النتائج بوصفها دليلاً زمنياً استكشافياً لا تقديراً قابلاً للتعميم على معاملات فردية.

3.5 الفترات التحليلية

الجدول 3-1: الفترات التحليلية

المرحلة	الفترة	الوصف
خط الأساس	يناير 2022 - فبراير 2023	قبل تطبيق AI؛ مع وجود أتمتة تقليدية.
البداية	مارس - ديسمبر 2023	تطبيق محدود على PT وMRI وCT والأدوية.

المرحلة	الفترة	الوصف
التوسع	2024 - يوليو 2026	توسع تدريجي في النطاق والقرارات.

3.6 مصادر البيانات وإجراءات جمعها

المصدر الرئيس للبيانات هو لوحة عمليات الموافقات الطبية الداخلية للفترة من 2022 حتى 29 يوليو 2026. واقتصر الاستخدام الأكاديمي على القيم المجمعة، من دون صور للوحة أو بيانات على مستوى العضو أو مقدم الخدمة. وشملت إجراءات المراجعة تثبيت تاريخ الاستخراج، والتحقق من تعريفات المؤشرات، وفصل السنوات الكاملة عن سنة 2026 الجزئية، وإجراء المقارنة المتناظرة بين يناير ويوليو، واستبعاد مؤشر القيمة المالية للهدر لعدم موثوقيته، وتسجيل التغير الذي طرأ على قواعد عدم الحاجة إلى موافقة مسبقة في يناير 2026 بوصفه عاملاً مربكاً (بوبا العربية، 2026).

3.7 المتغيرات وأساليب القياس

الجدول 2-3: المتغيرات ومصادرها

المتغير	نوعه في التحليل	مصدره
حجم الطلبات (Request Volume)	مؤشر قدرة استيعابية	Dashboard
حصة المعالجة الآلية (Automated Share)	مؤشر توسع الأتمتة؛ ليس آلياً خالصاً	Dashboard
زمن الاستجابة الكلي (Total RT)	مؤشر كفاءة زمنية	Dashboard
زمن الاستجابة اليدوي (Manual RT)	مؤشر ضغط وتعقيد المسار اليدوي	Dashboard
عدم الحاجة إلى موافقة مسبقة (NPR)	مؤشر مسار/سياسة	Dashboard
الرفض (Rejection)	مؤشر نتيجة تشغيلية	Dashboard
إعادة العمل (Rework)	مؤشر جودة واتساق قرار	Dashboard

3.8 أساليب التحليل الإحصائي

- استخدام الإحصاء الوصفي لعرض الاتجاهات السنوية ونسب التغير.
- مقارنة الفترة يناير-يوليو 2025 بالفترة المناظرة من 2026.
- حساب زمن الاستجابة المرجح بالحجم بقسمة مجموع (حجم الشهر × مؤشر زمن الاستجابة للشهر) على مجموع الحجم.
- استخدام اختبار t للعينات المترابطة على القيم الشهرية للحجم وزمن الاستجابة بين 2025 و2026.
- إجراء اختبار Wilcoxon Signed-Rank بوصفه تحققاً غير معلمي بسبب صغر عدد الأزواج (n=7).
- تفسير النتائج في ضوء المتغيرات المركبة وعدم استخدام لغة السببية.

أُجريت الحسابات الإحصائية باستخدام Python ومكتبة SciPy، واعتمد مستوى دلالة 0.05. واستُخدم اختبار العينات المترابطة للمقارنة بين القيم الشهرية في الفترتين، كما استُخدم اختبار Wilcoxon للتحقق من ثبات النتيجة في ظل صغر عدد الأزواج. ولا تمنح هذه الاختبارات تفسيراً سببياً للفرق؛ لأنها لا تعالج وحدها الموسمية أو تغير العقود والموارد ومزيج الحالات.

3.9 جودة البيانات والمتغيرات المربكة

قد تتغير مؤشرات الأداء لأسباب لا ترتبط مباشرة بالذكاء الاصطناعي، مثل نمو عدد المؤمن لهم، وإضافة عقود جديدة، وتغير قواعد عدم الحاجة إلى موافقة مسبقة، وعدد الموظفين، وموسمية الطلبات، والأعطال التقنية، واختلاف أنواع الخدمات. ولتقليل أثر هذه العوامل، فُصلت السنوات الكاملة عن 2026 الجزئية، واستخدمت مقارنة زمنية متناظرة، وسجل تغيير يناير 2026 بوصفه عاملاً مربكاً يحتاج إلى مراعاة عند تفسير النتائج.

الجدول 3-3: المتغيرات المربكة واستراتيجية الحد منها

العامل المربك	الأثر المحتمل	المعالجة
نمو الحجم	ضغط RT وارتفاع العمل اليدوي	استخدام النسب والمقارنة المتناظرة.
تغير العقود	تغير مزيج الطلبات	يذكر كقيد؛ يضاف كمتغير عند توفر بيانات شهرية.
تغير NPR في يناير 2026	تحويل حالات للمسار اليدوي	تفسير 2026 بصورة منفصلة.
عدد الموظفين	تأثير مباشر على الإنتاجية	إضافة FTE في التحليل المستقبلي.
تعقيد الحالات	خفض RT اليدوي	تصنيف الخدمة والخطورة عند توفر بيانات مستوى الطلب.
أعطال النظام	انخفاض مؤقت	وسم فترات الحوادث مستقبلاً.

3.10 محددات الدراسة

تتفق محددات التحليل مع الحدود الواردة في القسم 1.9. وأبرزها عدم توفر مؤشر مستقل يحدد جميع قرارات الذكاء الاصطناعي، وعدم توفر ملف معاملات خام أو سلسلة شهرية مكتملة لعدد مكافئات الدوام الكامل والعقود وتعقيد الخدمات. كما أن بيانات 2026 جزئية حتى 29 يوليو وتتضمن تغييراً في قواعد عدم الحاجة إلى موافقة مسبقة. لذلك تركز الدراسة على الارتباطات التشغيلية ولا تنسب السببية مباشرة إلى الذكاء الاصطناعي.

3.11 الاعتبارات الأخلاقية وسرية البيانات

اقتصر البحث على بيانات تشغيلية مجمعة لا تتضمن معلومات تعريفية أو بيانات صحية على مستوى الفرد. ولم تُدرج صور اللوحة الداخلية أو أسماء مقدمي الخدمة أو تفاصيل العقود. كما أن أي استخدام خارجي للنتائج أو مشاركة إضافية للبيانات يظل خاضعاً لموافقة الجهة المالكة وللوائح الجامعة ذات الصلة بالسرية والأمانة العلمية.

الفصل الرابع

الدراسة التطبيقية: تحليل البيانات والنتائج

4.1 مقدمة الدراسة التطبيقية

يعرض هذا الفصل النتائج التطبيقية ابتداءً من الاتجاه السنوي للحجم وحصّة المعالجة الآلية، ثم ينتقل إلى زمن الاستجابة ومؤشرات عدم الحاجة إلى موافقة مسبقة والرفض وإعادة العمل، وينتهي بالمقارنة الشهرية المتناظرة والاختبارات الإحصائية. ويُفصل في العرض بين ما تثبته الأرقام وصفيًا وما يمكن اختبارُه إحصائيًا، مع إبقاء العوامل المربكة حاضرة في التفسير.

4.2 وصف البيانات والاتجاه السنوي

الجدول 1-4: مؤشرات لوحة العمليات 2022-2026

السنة	الحجم	حصّة المعالجة الآلية	الحصّة اليدوية	زمن الاستجابة الكلي	زمن الاستجابة اليدوي	عدم الحاجة لموافقة	الرفض	إعادة العمل
2022	14M	56.1%	43.9%	92.7%	85.4%	9.7%	16.8%	1.5%
2023	16M	58.4%	41.6%	93.3%	86.2%	9.4%	18.7%	1.4%
2024	18M	61.5%	38.5%	93.3%	84.9%	8.7%	18.2%	1.4%
2025	20M	68%≈	32%≈	93.4%	82.6%	7.2%	18.5%	1.5%
*2026	12M	64%≈	36%≈	92.8%	81.2%	8.1%	17.5%	1.1%

المصدر: إعداد الباحث استناداً إلى لوحة عمليات الموافقات الطبية الداخلية (بوبا العربية، 2026).

* بيانات 2026 جزئية حتى 29 يوليو ولا تقارن مباشرة بسنة كاملة.

4.3 حجم الطلبات والمعالجة الآلية

ارتفع حجم الطلبات من 14 مليوناً في 2022 إلى 20 مليون طلب في 2025، بزيادة إجمالية قدرها 42.9%. وخلال الفترة نفسها ارتفعت حصّة المعالجة الآلية من 56.1% إلى قرابة 68%. ويعني ذلك، بصورة تقريبية، أن الحجم المعالج آلياً ارتفع من نحو 7.9 ملايين إلى قرابة 13.6 مليون طلب، بينما بقي الحجم اليدوي قريباً من مستواه السابق. وتدعم هذه النتيجة الفرضية H1a وصفيًا، كما توضح أن معظم النمو الإضافي استوعبه المسار الآلي. ومع ذلك لا يمكن نسبة الزيادة كاملة إلى الذكاء الاصطناعي؛ لأن مؤشر المعالجة الآلية يتضمن أيضاً أتمّة قائمة على قواعد ثابتة.

4.4 أداء زمن الاستجابة

ظل مؤشر الالتزام بزمن الاستجابة الكلي بين 92.7% و 93.4% خلال السنوات الكاملة 2022-2025 على الرغم من نمو الحجم بنسبة 42.9%، وهو ما يدعم الفرضية H1b وصفيًا. في المقابل تحسن أداء المسار اليدوي إلى 86.2% في 2023 ثم انخفض إلى 84.9% في 2024 و 82.6% في 2025، ووصل إلى 81.2% في بيانات 2026 الجزئية. ويحتمل أن يعكس هذا الاتجاه اجتماع عاملين: انتقال نسبة أكبر من الحالات البسيطة إلى الأتمتة، وارتفاع الضغط أو التعقيد في الحالات المتبقية للمراجعة البشرية.

الجدول 4-2: الفجوة بين زمن الاستجابة الكلي واليدوي

السنة	زمن الاستجابة الكلي	زمن الاستجابة اليدوي	الفجوة
2022	92.7%	85.4%	7.3 نقطة
2023	93.3%	86.2%	7.1 نقطة
2024	93.3%	84.9%	8.4 نقطة
2025	93.4%	82.6%	10.8 نقطة
*2026	92.8%	81.2%	11.6 نقطة

المصدر: حسابات الباحث استناداً إلى مؤشرات لوحة العمليات (بوبا العربية، 2026).

4.5 عدم الحاجة إلى موافقة مسبقة والرفض وإعادة العمل

انخفضت نسبة الطلبات المصنفة على أنها لا تحتاج إلى موافقة مسبقة من 9.7% في 2022 إلى 7.2% في 2025، ثم بلغت 8.1% حتى يوليو 2026. ولا يحمل هذا الانخفاض دلالة جودة مستقلة، لأن المؤشر يتأثر بتغير السياسة وحدود الخدمات والعقود. وبعد التغيير التشغيلي في يناير 2026، الذي أعاد بعض الحالات الآلية الأعلى قيمة إلى المسار اليدوي، عاملاً مبركاً مباشراً. أما الرفض فتراوح بين 16.8% و 18.7% في السنوات الكاملة دون اتجاه ثابت، بينما بقي معدل إعادة العمل بين 1.4% و 1.5% خلال 2022-2025. وبذلك تدعم البيانات الفرضية H1c من زاوية عدم ظهور تدهور مستمر، لكنها لا تثبت تحسن دقة القرار.

4.6 مقارنة يناير-يوليو 2025 و 2026

الجدول 4-3: مقارنة يناير-يوليو 2025 و 2026

الشهر	حجم 2025	حجم 2026	زمن الاستجابة 2025	زمن الاستجابة 2026
يناير	1.636M	1.855M	95.3%	93.1%
فبراير	1.500M	1.687M	94.8%	93.3%
مارس	1.250M	1.527M	94.2%	93.7%
أبريل	1.518M	1.963M	94.3%	93.3%
مايو	1.727M	1.687M	93.4%	93.1%

الشهر	حجم 2025	حجم 2026	زمن الاستجابة 2025	زمن الاستجابة 2026
يونيو	1.474M	1.855M	92.8%	91.4%
يوليو	1.734M	1.760M	93.8%	92.0%

المصدر: إعداد الباحث من القيم الشهرية المجمعة في لوحة العمليات (بوبا العربية، 2026).

بلغ إجمالي الحجم 10.839 مليون طلب في يناير-يوليو 2025 مقابل 12.334 مليون طلب في الفترة نفسها من 2026، أي بزيادة قدرها 13.8%. وفي الوقت ذاته انخفض مؤشر زمن الاستجابة المرجح بالحجم من 94.08% إلى 92.82%، بفارق 1.26 نقطة مئوية. وتوضح المقارنة أن النظام استمر في استيعاب حجم أكبر، إلا أن ذلك تزامن مع ضغط واضح على الأداء الزمني خلال 2026.

4.7 اختبار الفروق بين الفترتين

الجدول 4-4: اختبارات الفروق الشهرية والتحقق غير المعلمي

المتغير	متوسط 2025	متوسط 2026	t (df=6)	قيمة p (اختبار t)	Wilcoxon W	قيمة p (Wilcoxon)	النتيجة
الحجم الشهري (مليون)	1.548	1.762	3.211	0.018	2.0	0.047	2026 أعلى؛ فرق دال
زمن الاستجابة الشهري	94.09%	92.84%	-4.799	0.003	0.0	0.016	2026 أقل؛ فرق دال

المصدر: حسابات الباحث باستخدام القيم الشهرية المجمعة واختبارات العينات المترابطة.

أظهر اختبار العينات المترابطة فروقاً ذات دلالة إحصائية في الحجم الشهري ($p=0.018$) وفي زمن الاستجابة ($p=0.003$). ونظراً إلى أن المقارنة تعتمد على سبعة أزواج شهرية فقط، استخدم اختبار Wilcoxon كتحقق غير معلمي إضافي؛ وظلت الفروق دالة عند مستوى 0.05 للحجم ($p=0.047$) ولزمن الاستجابة ($p=0.016$). وتؤكد هذه الاختبارات وجود اختلاف بين الفترتين، لكنها لا تحدد سببه، لأن 2026 شهدت تغيرات في قواعد عدم الحاجة إلى موافقة مسبقة والعقود ومزيج الحالات والموارد.

4.8 ملخص الفرضيات

الجدول 4-5: ملخص اختبار الفرضيات

الفرضية	النتيجة	الحكم
H1a: ارتفاع حصة المعالجة الآلية	56.1% في 2022 إلى نحو 68% في 2025	مدعومة وصفيًا
H1b: استقرار زمن الاستجابة الكلي رغم النمو	92.7-93.4% في السنوات الكاملة	مدعومة وصفيًا حتى 2025
H1c: عدم تدهور إعادة العمل بصورة مستمرة	1.4-1.5% في السنوات الكاملة	مدعومة جزئيًا؛ استقرار لا تحسن

الفرضية	النتيجة	الحكم
H1d: فرق في الحجم يناير-يوليو	p=0.018	مدعومة
H1e: فرق في زمن الاستجابة يناير-يوليو	p=0.003	مدعومة

المصدر: إعداد الباحث في ضوء نتائج التحليل الوصفي والإحصائي.

4.9 النتائج الرئيسية

- ارتفع حجم الطلبات بنسبة 42.9% بين 2022 و2025، بالتزامن مع زيادة حصة المعالجة الآلية بنحو 12 نقطة مئوية.
- حافظ مؤشر زمن الاستجابة الكلي على مستوى قريب من 93% خلال السنوات الكاملة رغم نمو الحجم.
- اتسعت الفجوة بين الأداء الكلي وأداء المسار اليدوي، بما يشير إلى ضغط أو تعقيد أعلى في الحالات التي بقيت للمراجعة البشرية.
- ظل معدل إعادة العمل مستقراً تقريباً في السنوات الكاملة؛ وهو أمر يحد من مخاطر التدهور، لكنه لا يكفي لإثبات تحسن جودة القرار.
- في يناير-يوليو 2026 ارتفع الحجم 13.8%، في حين انخفض مؤشر زمن الاستجابة المرجح بالحجم 1.26 نقطة مئوية مقارنة بالفترة المناظرة من 2025.
- أكد اختبارا العينات المترابطة وWilcoxon وجود فروق بين الفترتين في الحجم وزمن الاستجابة، مع بقاء تفسير السبب محدوداً بالبيانات المتاحة.

4.10 محددات تفسير النتائج

- عدم توفر مؤشر مستقل يفصل قرارات الذكاء الاصطناعي عن الأتمتة التقليدية.
- الاعتماد على مؤشرات مجمعة من لوحة العمليات بدلاً من معاملات خام على مستوى الطلب.
- احتمال تأثير النتائج بتغير العقود والسياسات والموارد ومزيج الحالات.
- كون بيانات 2026 جزئية حتى 29 يوليو وتتضمن تغيراً تشغيلياً في يناير.
- اعتماد المقارنة الإحصائية على سبعة أزواج شهرية فقط، من دون نموذج يعالج الموسمية والارتباط الزمني بصورة كاملة.

الفصل الخامس

المناقشة والاستنتاجات والتوصيات

5.1 مقدمة المناقشة

يربط هذا الفصل النتائج التشغيلية بالإطار النظري والدراسات السابقة، ثم يستخلص ما تعنيه النتائج إدارياً واستراتيجياً. ويقوم النقاش على مبدأ أساسي: ارتفاع الأتمتة ليس هدفاً مستقلاً، بل ينبغي تقييمه مع سرعة الخدمة وجودة القرار واستدامة المسار اليدوي.

5.2 مناقشة النتائج في ضوء الدراسات السابقة

أبرز ما يظهر في النتائج هو أن النظام التشغيلي استوعب زيادة كبيرة في حجم الطلبات خلال 2022-2025 من دون تراجع موازٍ في مؤشر زمن الاستجابة الكلي. وتتفق هذه الصورة مع الأدبيات التي ترى أن الأتمتة والذكاء الاصطناعي يمكن أن يخففا العبء الإداري عندما يُدمجان بصورة صحيحة في سير العمل (Davenport & Kalakota, 2019; Keng et al., 2025). وفي الحالة محل الدراسة، لم تكن الفائدة في خفض الحجم اليدوي إلى الصفر، بل في منع نموه بالمعدل نفسه الذي نما به إجمالي الطلبات.

في المقابل، لم يظهر معدل إعادة العمل تحسناً واضحاً خلال السنوات الكاملة، ولذلك لا يمكن استخدام ارتفاع حصة المعالجة الآلية كدليل مستقل على تحسن جودة القرار. ويتسق هذا التحفظ مع الأدبيات التي تناولت استخدام الخوارزميات في مراجعات التغطية، حيث ترتبط سرعة القرار بمخاطر محتملة إذا غابت الشفافية أو ضعفت المراجعة البشرية ومسارات الاعتراض (Mello & Rose, 2024; Mello et al., 2026; Raza et al., 2026).

أما انخفاض أداء المسار اليدوي واتساع الفجوة مع الأداء الكلي فيدعم تفسيراً اجتماعياً-تقنياً منطقياً: كلما انتقلت الحالات الأبسط إلى المعالجة الآلية، بقي للمراجعين مزيج أكبر من الحالات الاستثنائية أو المعقدة. وعليه، قد يصبح من غير العادل مقارنة إنتاجية المسار اليدوي بعد التوسع التقني بمستواه السابق من دون ضبط درجة التعقيد والموارد. وهذا يربط قرار الأتمتة مباشرة بتخطيط القوى العاملة واتفاقيات مستوى الخدمة.

وتضيف بيانات 2026 إشارة مهمة إلى أن القدرة على التوسع ليست بلا حدود. فزيادة الحجم 13.8% تزامنت مع انخفاض ذي دلالة في زمن الاستجابة مقارنة بالفترة المناظرة من 2025. ولا تسمح البيانات بإرجاع هذا التراجع إلى الذكاء الاصطناعي وحده، لكنه يمثل سبباً عملياً لتجنب التوسع السريع في خدمات أكثر تعقيداً - مثل التنويم - قبل وضع عتبات للتصعيد، ومراقبة يومية للجودة، وخطة موارد واضحة.

5.3 الاستنتاجات

- ارتبط بدء AI والتوسع اللاحق بارتفاع مستمر في حصة المعالجة الآلية.
- استوعب المسار الآلي الجزء الأكبر من نمو الحجم بين 2022 و2025.

- استقرار RT الكلي يمثل دليلاً تشغيلياً على قابلية التوسع، لا دليلاً سببياً منفرداً.
- تراجع RT اليدوي يمثل مخاطرة تشغيلية ويستدعي قياس تعقيد الحالات والموارد.
- استقرار Rework يعني عدم ظهور تدهور واسع، لكنه لا يثبت تحسن الدقة.
- NPR مؤشر مسار وسياسة وليس مؤشراً مباشراً للجودة.
- يلزم فصل AI عن Rule-based automation في القياس المستقبلي.

5.4 الإجابة عن سؤال الدراسة

تجيب النتائج عن السؤال الرئيس بوجود علاقة إيجابية بين التوسع التدريجي في الذكاء الاصطناعي والأتمتة وبين القدرة التشغيلية للموافقات الطبية المسبقة؛ فقد نما الحجم بقوة مع زيادة المعالجة الآلية وبقاء الأداء الكلي مستقرًا نسبيًا حتى 2025. غير أن أثر هذا التوسع على جودة القرار لم يظهر بالوضوح نفسه، كما برز ضغط متزايد في المسار اليدوي وفي زمن الاستجابة خلال 2026. لذلك فإن الاستنتاج الأدق هو أن التقنية دعمت قابلية التوسع، لكنها تحتاج إلى قياس مستقل لقرارات الذكاء الاصطناعي وربطها بالجودة والحوكمة والموارد قبل الانتقال إلى خدمات أعلى خطورة.

5.5 الآثار الإدارية والاستراتيجية

إدارياً، ينبغي التعامل مع الذكاء الاصطناعي بوصفه تغييراً في نموذج تشغيل الموافقات، لا مشروعاً تقنياً منفصلاً. فكلما توسعت المعالجة الآلية تغيرت طبيعة العمل المتبقي للمراجعين من معالجة الحالات المتكررة إلى إدارة الاستثناءات والتدقيق والتفسير والتصعيد. وبناءً عليه، يجب أن تتغير مؤشرات الأداء والتدريب وتخطيط الموارد بالتوازي مع تغير مزيج العمل.

استراتيجياً، يوفر التوسع المنضبط فرصة لاستيعاب نمو الأعمال من دون زيادة خطية مماثلة في الجهد اليدوي، لكن هذه الفائدة تبقى مشروطة بجودة البيانات والحوكمة وقابلية تفسير القرار. ومن منظور القدرات الديناميكية، لا تتمثل الميزة في رفع نسبة الأتمتة بحد ذاتها، بل في قدرة المؤسسة على اختيار الحالات المناسبة، وقياس النتائج، والتعلم من الأخطاء، وإعادة ضبط النطاق والقواعد باستمرار.

5.6 التوصيات التنفيذية

الجدول 1-5: التوصيات التنفيذية

التوصية	الإجراء
إنشاء مؤشر يحدد مسار القرار على مستوى الطلب	التمييز بين القرار المباشر بالذكاء الاصطناعي، وتوصية الذكاء الاصطناعي، والأتمتة القائمة على القواعد، والمعالجة اليدوية.
لوحة جودة مستقلة	عرض زمن الاستجابة وإعادة العمل وتغير القرار حسب مسار القرار ونوع الخدمة وإصدار النموذج.
حوكمة التنويم	بدء AI كتوصية فقط للحالات عالية الخطورة وعدم السماح بالقرار المباشر إلا بعد تحقق معايير الأمان.
تدقيق بشري عشوائي	تدقيق عينة ثابتة من الموافقات والرفض وطلبات عدم الحاجة إلى موافقة التي صدرت ألياً.
ضبط المسار اليدوي	قياس تعقيد الحالات وربط الموارد واتفاقيات مستوى الخدمة بالمزيج الجديد للحالات.
تحليل أسباب إعادة العمل	فصل خطأ النظام عن نقص المعلومات وتغير السياسة والتدخل الطبي أو البشري.
حماية البيانات	تقليل البيانات، ضبط الصلاحيات، توثيق الإصدارات، ومراقبة الانحياز.

5.7 إطار مقترح لتقييم تجربة التوسع في التنويم

الجدول 5-2: إطار قياس تجربة التوسع في التنويم

المؤشر	قبل التجربة	أثناء التجربة	عتبة التصعيد
متوسط زمن القرار	خط أساس 4 أسابيع	أسبوعي وشهري	تدهور < 10%
زمن الاستجابة	خط أساس	إجمالي/بدوي/ذكاء اصطناعي	انخفاض < 2 نقطة
إعادة العمل	خط أساس	حسب سبب التغيير	ارتفاع < 0.5 نقطة
الإحالة البشرية	غير مطبق	النسبة والسبب	نقص معلومات/خطورة
خطأ سريري/سياسة	خط أساس	تدقيق عينة	أي نمط متكرر
رضا الموظفين	قبل	منتصف/نهاية	متوسط > 3.5/5

ينبغي التعامل مع عتبات التجربة بوصفها مؤشرات تستدعي المراجعة والتصعيد، لا بوصفها بديلاً عن الحكم الطبي أو التعاقد. وفي المرحلة الأولى يفضل إبقاء حالات التنويم عالية الخطورة وقرارات الرفض تحت مراجعة بشرية إلزامية، مع تسجيل سبب تعديل أي توصية صادرة عن النظام حتى تتحول الاختلافات إلى مدخلات قابلة للتعلم والتحسين.

5.8 خارطة طريق للتوسع المسؤول

الجدول 5-3: خارطة طريق للتوسع المسؤول

المرحلة	المدة	الأعمال الرئيسية	قرار الانتقال
التهيئة	قبل الإطلاق	تعريف المؤشرات، اختبار البيانات، التدريب	اكتمال الجاهزية والحوكمة
الوضع الصامت	أسبوعان	يقدم النظام توصية من دون تنفيذ مباشر	توافق مقبول مع القرار البشري
التوصية المدعومة	4 أسابيع	الموظف يعتمد أو يعدل مع توثيق السبب	إعادة العمل ضمن العتبة
قرار محدود	4 أسابيع	قرار مباشر للحالات منخفضة الخطورة	عدم ظهور نمط أخطاء
التقييم	نهاية التجربة	مقارنة قبل/بعد وتحليل أسباب الاختلاف	توسع/تعديل/إيقاف

5.9 مقترحات للبحوث المستقبلية

- تحليل بيانات على مستوى الطلب باستخدام سلسلة زمنية متقطعة أو انحدار مقطع عند توفر تاريخ دقيق لمراحل التطبيق.
- إضافة عدد مكافئات الدوام الكامل، والعقود، ونوع الخدمة، ومستوى الخطورة كمتغيرات ضابطة.
- قياس حجم الحالات التي عالجها الذكاء الاصطناعي بصورة مستقلة بدلاً من استخدام حصة المعالجة الآلية كمؤشر تقريبي.
- قياس تجربة المستفيد ومقدم الخدمة إلى جانب المؤشرات التشغيلية الداخلية.
- تقييم قابلية تفسير النموذج والانحياز والعدالة، وإجراء تحليل تكلفة-منفعة بعد تحسين جودة البيانات المالية.

المراجع

المراجع العربية والمؤسسية السعودية

بوبا العربية. (2026). لوحة عمليات الموافقات الطبية: مؤشرات تشغيلية مجمعة للفترة 2022-29 يوليو 2026 [مصدر داخلي غير منشور].

مجلس الضمان الصحي. (2023، 14 مارس). احتفاء مجلس الضمان الصحي بإنجاز منصة نفيس 100 مليون معاملة تأمينية. تم الاسترجاع في 21 أغسطس 2026 من

<https://www.chi.gov.sa/en/MediaCenter/News/Pages/News-3-14-2023.aspx>

مجلس الضمان الصحي. (2025، 20 يوليو). مجلس الضمان الصحي يطلق استراتيجيته 2025-2027. تم الاسترجاع في 21 أغسطس 2026 من <https://chi.gov.sa/en/MediaCenter/News/Pages/2025-7-20.aspx>

المراجع الأجنبية

- Bostrom, R. P., & Heinen, J. S. (1977). MIS problems and failures: A socio-technical perspective. Part I: The causes. *MIS Quarterly*, 1(3), 17-32.
- Choudhury, A., & Perumalla, S. (2021). Using machine learning to minimize delays caused by prior authorization: A brief report. *Cogent Engineering*, 8(1), 1944961. <https://doi.org/10.1080/23311916.2021.1944961>
- Davenport, T. H., & Kalakota, R. (2019). The potential for artificial intelligence in healthcare. *Future Healthcare Journal*, 6(2), 94-98. <https://doi.org/10.7861/futurehosp.6-2-94>
- Esteva, A., Robicquet, A., Ramsundar, B., Kuleshov, V., DePristo, M., Chou, K., Cui, C., Corrado, G., Thrun, S., & Dean, J. (2019). A guide to deep learning in healthcare. *Nature Medicine*, 25, 24-29. <https://doi.org/10.1038/s41591-018-0316-z>
- Jiang, F., Jiang, Y., Zhi, H., Dong, Y., Li, H., Ma, S., Wang, Y., Dong, Q., Shen, H., & Wang, Y. (2017). Artificial intelligence in healthcare: Past, present and future. *Stroke and Vascular Neurology*, 2(4), 230-243. <https://doi.org/10.1136/svn-2017-000101>
- Keng, C., DiGiorgio, A., Ehrenfeld, J. M., Spear, J., & Miller, B. J. (2025). Unburdening patients and clinicians through automation and artificial intelligence: Informatics strategies for reducing administrative burden. *Journal of Medical Systems*, 49, 128. <https://doi.org/10.1007/s10916-025-02265-1>
- Kunze, K. N., Bepple, J., Bedi, A., Ramkumar, P. N., & Pean, C. A. (2025). Commercial products using generative artificial intelligence include ambient scribes, automated documentation and scheduling, revenue cycle management, patient engagement and education, and prior authorization platforms. *Arthroscopy*, 41(11), 4950-4955. <https://doi.org/10.1016/j.arthro.2025.05.021>
- Lenert, L. A., Lane, S., & Wehbe, R. (2023). Could an artificial intelligence approach to prior authorization be more human? *Journal of the American Medical Informatics Association*, 30(5), 989-994. <https://doi.org/10.1093/jamia/ocad016>

- Mello, M. M., & Rose, S. (2024). Denial-Artificial intelligence tools and health insurance coverage decisions. *JAMA Health Forum*, 5(3), e240622. <https://doi.org/10.1001/jamahealthforum.2024.0622>
- Mello, M. M., Trotsyuk, A. A., Mahamadou, A. J. D., & Char, D. (2026). The AI arms race in health insurance utilization review: Promises of efficiency and risks of supercharged flaws. *Health Affairs*, 45(1), 6-13. <https://doi.org/10.1377/hlthaff.2025.00897>
- Raza, S., Gerke, S., Silcox, C., Hendricks-Sturup, R., & Shachar, C. (2026). Medicare advantage becoming a disadvantage with use of artificial intelligence in prior authorization review. *npj Digital Medicine*, 9, 208. <https://doi.org/10.1038/s41746-026-02387-x>
- Sahni, N. R., Istvan, B., Stafford, C., & Cutler, D. (2024). Perceptions of prior authorization burden and solutions. *Health Affairs Scholar*, 2(9), qxae096. <https://doi.org/10.1093/haschl/qxae096>
- Teece, D. J., Pisano, G., & Shuen, A. (1997). Dynamic capabilities and strategic management. *Strategic Management Journal*, 18(7), 509-533.
- Topol, E. J. (2019). High-performance medicine: The convergence of human and artificial intelligence. *Nature Medicine*, 25, 44-56. <https://doi.org/10.1038/s41591-018-0300-7>
- Vatsal, S., Singh, A., & Tafreshi, S. (2024). Can GPT improve the state of prior authorization via guideline based automated question answering? In *AI for Health Equity and Fairness: Leveraging AI to Address Social Determinants of Health* (pp. 147-158). Springer. https://doi.org/10.1007/978-3-031-63592-2_12
- World Health Organization. (2021). Ethics and governance of artificial intelligence for health: WHO guidance. World Health Organization. <https://www.who.int/publications/i/item/9789240029200>
- World Health Organization. (2023). Regulatory considerations on artificial intelligence for health. World Health Organization.

الملاحق

الملحق (أ): أداة استبانة مقترحة لتقييم الاستخدام والحوكمة

هذا الملحق أداة مقترحة للتحقق المستقبلي، ولا تدخل أي نتائج افتراضية له ضمن نتائج الدراسة الحالية. ويستخدم مقياس ليكرت الخماسي من 1 = لا أوافق بشدة إلى 5 = أوافق بشدة.

- 1. يساعد الذكاء الاصطناعي على تقليل زمن معالجة الطلب.
- 2. يساعد النظام على التعامل مع حجم أكبر من الطلبات.
- 3. توصيات النظام دقيقة في الخدمات التي يغطيها.
- 4. أفهم الفرق بين القرار المعتمد على الذكاء الاصطناعي والأتمتة القائمة على القواعد.
- 5. أعرف متى يجب إحالة الحالة لمراجع بشري.
- 6. يمكنني الاعتراض أو تعديل القرار بسهولة.
- 7. المسؤولية عن القرار النهائي واضحة.
- 8. التدريب الذي تلقينته كافٍ.
- 9. أثق باستخدام النظام ضمن حدود وضوابط واضحة.
- 10. يجب قياس إعادة العمل والأخطاء قبل التوسع الكامل في التنويم.

الملحق (ب): نموذج بيانات تجربة التنويم

الوصف	الحقل
دون بيانات شخصية.	التاريخ/الأسبوع
طارئ/اختياري/امتداد.	نوع الطلب
قرار آلي مباشر/توصية بالذكاء الاصطناعي/يدوي.	مسار القرار
موافقة/رفض/لا يحتاج إلى موافقة/معلق.	القرار الأول
بالدقائق.	زمن القرار
نعم/لا وسببها.	مراجعة بشرية
بعد المراجعة.	القرار النهائي
نعم/لا، مع تسجيل سبب التغيير.	إعادة العمل
معلومات ناقصة/خطأ سياسة/خطأ طبي/أخرى.	ملاحظة جودة

الملحق (ج): بيان سرية المصدر التشغيلي

استند التحليل إلى مؤشرات تشغيلية مجمعة من لوحة الموافقات الطبية الداخلية للفترة 2022-29 يوليو 2026. ولم تُدرج في النسخة الأكاديمية صور اللوحة أو تصميمها المرئي أو بيانات تعريفية على مستوى الطلب أو العضو أو مقدم الخدمة. واقتصر الاستخدام على القيم الضرورية للتحليل، مع استبعاد مؤشر القيمة المالية للهدر لعدم موثوقيته. ويخضع أي استخدام خارجي إضافي لموافقة الجهة المالكة وسياساتها المعتمدة.

Abstract

This study examines the association between the progressive expansion of artificial intelligence (AI) and automation and the efficiency of medical pre-authorization operations at Bupa Arabia for Cooperative Insurance. The research problem arises from the fact that a higher automated-processing share does not necessarily represent AI use alone, and improved speed may coexist with pressure on the manual pathway or unchanged decision quality. A longitudinal applied case-study design was used, based on aggregated operational indicators from January 2022 to 29 July 2026. The operational study population consisted of the pre-authorization requests represented by these aggregated indicators; no member-level or provider-identifiable data were used.

The analysis combined descriptive statistics, trend and growth comparisons, and a matched January-July comparison between 2025 and 2026. Paired-samples t tests and Wilcoxon signed-rank tests were used to assess monthly differences. Annual request volume increased from 14 million in 2022 to 20 million in 2025 (+42.9%), while the automated-processing share increased from 56.1% to approximately 68%. Total response-time performance remained close to 93% across the complete years, whereas manual response-time performance declined from 85.4% in 2022 to 82.6% in 2025. Rework remained between 1.4% and 1.5% during the complete years.

For January-July, 2026 request volume was 13.8% higher than the comparable 2025 period, while volume-weighted response-time performance declined from 94.08% to 92.82%. Monthly differences were statistically significant for volume ($p=0.018$) and response time ($p=0.003$), with Wilcoxon tests confirming the same direction. The findings support an association between technological expansion and operational scalability, while the effect on decision quality remains less conclusive because rework did not show sustained improvement, the manual-performance gap widened, and historical data do not isolate AI decisions from rule-based automation.

Keywords: artificial intelligence; medical pre-authorization; health insurance; automation; response time; rework; Bupa Arabia.

Midocean University

College of Management

Department of Business Administration - MBA

**The Association Between Expanding Artificial Intelligence Use and the
Efficiency of Medical Pre-Authorization Decisions**

**A Longitudinal Applied Case Study at Bupa Arabia for Cooperative
Insurance in Saudi Arabia**

**An Applied Research Project Submitted in Partial Fulfillment of the
Requirements for the Master of Business Administration**

Prepared by: Mohamed Abdulrahman Hussain Eisa

Student ID:

Supervised by:

Academic Year: 2026