

تشخيص أعطال المضخات الترددية الثلاثية باستخدام التعلم العميق المعتمد على التحليل المويجي للبيانات

Diagnosis of Triplex Reciprocating Pump Faults Using Deep Learning Based on Wavelet Analysis of Data

إعداد: الباحث/ مريسي سعيد مريسي الغامدي

ماجستير العلوم في الذكاء الاصطناعي، المملكة العربية السعودية

Email: mrese42700094@gmail.com**الملخص:**

يهدف هذا البحث إلى توظيف تقنيات الذكاء الاصطناعي العميق في تحليل البيانات الصناعية لتشخيص أعطال الأنظمة الميكانيكية المعقدة، وذلك من خلال إجراء تطبيق عملي على المضخات الترددية الثلاثية؛ حيث تم بناء نموذج ديناميكي في بيئة بايثون يحاكي السلوك الفيزيائي للمضخة في الحالات السليمة وفي وجود أعطال ميكانيكية وهيدروليكية شائعة، ولتجاوز صعوبات الحصول على بيانات تتعلق بالبارامترات الواقعية للمضخة أثناء التشغيل؛ تم توليد بيانات اصطناعية تحاكي إشارات التشغيل الواقعية كالضغط والاهتزاز والتيار الكهربائي مع تضمين ضجيج يحاكي الظروف العملية.

استُخدم التحويل المويجي المستمر (CWT) لتحويل هذه الإشارات إلى خرائط طيفية زمنية (Scalograms)، ثم جرى توظيف نماذج التعلم العميق متمثلة في الشبكات التلافيفية (CNN) وشبكات الذاكرة الطويلة (LSTM) والنموذج الهجين بينهما لتصنيف الأعطال تلقائيًا، وأظهرت النتائج تفوق النموذج التلافي (CNN) بدقة بلغت 96%، ما يؤكد قدرة خوارزميات التعلم العميق على استخلاص الأنماط الدقيقة من البيانات الصناعية وتحسين موثوقية الصيانة التنبؤية.

في ضوء ما توصل له البحث من نتائج يوصي الباحث بتوسيع قاعدة بيانات الاهتزازات لتشمل بيانات حقيقية لمضخات ترددية تغطي أعطالاً وظروف تشغيل متنوعة، وذلك لتعزيز قدرة النموذج على التعميم. كما ينصح باستكشاف بنى الشبكات العصبية التلافيفية الأكثر عمقًا، بما في ذلك البنى المتقدمة أو التعلم بالنقل باستخدام شبكات كبيرة مُدرّبة مسبقًا عند توفر موارد حاسوبية عالية. وأخيرًا، يقترح الباحث دمج بيانات استشعار إضافية، مثل الضغط ودرجة الحرارة، لإنشاء نظام تشخيص أكثر شمولًا وموثوقية.

الكلمات المفتاحية: الذكاء الاصطناعي، التعلم العميق، التحويل المويجي المستمر، الشبكات التلافيفية، تشخيص الأعطال، المضخات الترددية الثلاثية، البيانات الاصطناعية، الصيانة التنبؤية.

Diagnosis of Triplex Reciprocating Pump Faults Using Deep Learning Based on Wavelet Analysis of Data

Meresi Saeed Alghamdi

Master of Science in Artificial Intelligence, Saudi Arabia

Abstract

This study aims to employ advanced deep learning techniques for industrial data analysis to diagnose faults in complex mechanical systems. A practical application was conducted on triplex reciprocating pumps, where a dynamic model was developed in a Python environment to simulate the physical behavior of the pump under both normal and faulty operating conditions, including typical mechanical and hydraulic failures. To overcome the limitations of acquiring real operational data, synthetic data were generated to emulate realistic sensor signals—such as pressure, vibration, and electric current—while incorporating controlled noise to reflect real-world variability. The Continuous Wavelet Transform (CWT) was applied to convert these signals into time–frequency Scalograms, which capture both temporal and spectral characteristics. Deep learning architectures, specifically Convolutional Neural Networks (CNNs), Long Short-Term Memory (LSTM) networks, and a hybrid CNN–LSTM model, were employed for automated fault classification. The results revealed that the CNN model outperformed the others, achieving an accuracy of 96%, confirming its capability to extract subtle, discriminative features from complex industrial data and enhance the reliability of predictive maintenance. This work provides a meaningful scientific contribution toward expanding the use of artificial intelligence in industrial systems and establishes a foundation for integrating physical modeling with deep learning to develop intelligent, self-diagnostic maintenance frameworks.

The researcher recommends expanding the vibration database with real-world reciprocating pump data covering diverse faults and operating conditions to enhance model generalization. They also advise exploring deeper CNN architectures, including advanced structures or transfer learning with large pre-trained networks when high computing resources are available. Finally, the researcher suggests integrating additional sensor data, such as pressure and temperature, to create a more comprehensive and reliable diagnostic system.

Keywords: Artificial Intelligence; Deep Learning; Continuous Wavelet Transform; Convolutional Neural Network; Fault Diagnosis; Synthetic Data; Predictive Maintenance.

1. المقدمة:

1.1. الخلفية والأهمية:

يعتبر الذكاء الاصطناعي أحد المحركات الأساسية للتحويل التقني المعاصر الذي أطلق عليه الثورة الصناعية الرابعة، حيث شكلت تطبيقاته في تحليل البيانات الصناعية وتشخيص الأعطال قفزة نوعية في طرق التشغيل والصيانة داخل المنشآت الحيوية؛ وبرز تشخيص أعطال المضخات الترددية الثلاثية من بين هذه التطبيقات كحالة دراسية مهمة تجمع بين التحديات الميكانيكية المعقدة وفرص التمكين الرقمي من خلال التعلم العميق وتحليل الإشارات.

تُستخدم هذه المضخات على نطاق واسع في قطاعات النفط والغاز والتحلية والمعالجة الكيميائية، لقدرتها العالية على ضخ الموائع اللزجة أو التي تحتوي على شوائب في ضغط ومرتفعة وتدفق مستقر (He et al., 2017)؛ غير أن طبيعة عملها المعتمدة على الحركة الترددية المتزامنة لعدة مكابس وصمامات تجعلها عرضة لأعطال متكررة ومتنوعة، كالتسرب وتآكل المحامل وانسداد الصمامات، وهي مشكلات قد تؤدي إلى انخفاض الكفاءة وزيادة استهلاك الطاقة وارتفاع تكاليف الصيانة (Zhu et al., 2019). ومع التحوّل الصناعي العالمي نحو الأتمتة والتحليل الذكي، أصبحت الصيانة التنبؤية توجهاً بحثياً متنامياً لأغراض تحسين الأداء وتقليل الأعطال، إذ تعتمد على تحليل بيانات المستشعرات لتوقع الأعطال قبل حدوثها، وفي هذا الإطار، أثبتت تقنيات التعلم العميق (Deep Learning) قدرتها على استخلاص الأنماط الخفية من البيانات الصناعية، والتعرف على مؤشرات الخلل في مراحل مبكرة، خصوصاً عند استخدام تمثيلات زمنية-ترددية مثل التحويل المويجي المستمر (CWT) التي تحوّل الإشارات إلى صور طيفية قابلة للمعالجة عبر الشبكات العصبية (Zhao et al., 2021؛ Lei et al., 2020).

يكتسب هذا المجال أهمية استراتيجية مضاعفة في المملكة العربية السعودية، إذ يُعد قطاع النفط والغاز من أهم ركائز الاقتصاد الوطني، ويمثل تطوير أنظمة تشخيص ذكية للأعطال خطوة عملية لدعم مستهدفات رؤية السعودية 2030 في تنويع الاقتصاد وتعزيز الكفاءة والاستدامة الصناعية (وثيقة مجلس الشؤون الاقتصادية والتنمية، 2016)؛ كما يتقاطع هذا التوجه مع مبادرات التحوّل الرقمي التي تسعى إلى توطين المعرفة التقنية وتطوير حلول قائمة على البيانات والذكاء الاصطناعي في مجالات الطاقة والصناعة (وزارة الاقتصاد والتخطيط، 2022).

ومن هذا المنطلق، تهدف هذه الدراسة إلى تطوير نموذج ذكي لتشخيص أعطال المضخات الترددية الثلاثية اعتماداً على بيانات اصطناعية مولدة من نموذج فيزيائي للمضخة، ثم معالجتها باستخدام التحويل المويجي والتعلم العميق، لتقديم إطار بحثي يسهم في بناء أنظمة صيانة تنبؤية وطنية متقدمة تجمع بين الدقة العلمية والقيمة التطبيقية في بيئة التشغيل السعودية.

2.1. مشكلة البحث والفجوة المعرفية

على الرغم من التقدم الكبير في تقنيات مراقبة الحالة واستخدام خوارزميات التعلم الآلي في تشخيص الأعطال الصناعية، ما تزال هناك تحديات واضحة في اكتشاف الأعطال الخاصة بالمضخات الترددية الثلاثية بشكل مبكر قبل تفاقمها. ويتمثل أحد أبرز هذه التحديات في ندرة البيانات الحقيقية الموثوقة التي تغطي حالات الأعطال المتنوعة، وخاصة الأعطال البادئة (incipient faults) أو الحالات التي تنزامن فيها أكثر من عطلالة في الوقت نفسه (Yang et al., 2019)؛ إذ أن جمع البيانات الواقعية يتطلب عادة تشغيل المعدات في ظروف قد تكون ضارة، كما أنه يستغرق وقتاً طويلاً ويحتاج إلى موارد مكلفة؛ إضافة إلى ذلك، فإن الإشارات الناتجة عن المضخات الترددية غالباً ما تكون غير خطية وغير ثابتة مع الزمن، كما تتأثر بالضجيج، مما يجعل استخراج الخصائص المميزة منها أمراً معقداً (Zhang & Li, 2018; Wang & Hu, 2006)؛

أما الأساليب التقليدية التي تعتمد على التحليل الطيفي البسيط، فإنها قد تعجز عن التعامل مع هذا المستوى من التعقيد (Wu et al., 2020).

أمام هذه التحديات، تبرز الحاجة إلى تطوير نماذج محاكاة قادرة على توليد بيانات صناعية اصطناعية واقعية تمثل مختلف سيناريوهات الأعطال، لتكون بديلاً عملياً لندرة البيانات الحقيقية (Jamil & Azami, 2021)؛ ورغم وجود بعض الدراسات التي تناولت نمذجة المضخات الترددية لغرض تشخيص الأعطال (Al-Jumaili & Jabbar, 2020)، إلا أن معظمها ركز على عدد محدود من أنواع الأعطال أو استخدم نماذج مبسطة لا تعكس السلوك الديناميكي الحقيقي للمضخة، خصوصاً في حالة الأعطال المتعددة أو المتطورة مع الزمن؛ كذلك، وعلى الرغم من دخول تقنيات التعلم الآلي إلى هذا المجال (Mao et al., 2018)، ما تزال هناك فجوة بحثية واضحة في تطبيق وتقييم النماذج الحديثة من التعلم العميق، التي تمتاز بقدرتها العالية على تحليل الأنماط المعقدة في البيانات المتتابعة وغير المستقرة، وعلى سبيل التخصيص لم يتم حتى الآن استثمار التكامل المنهجي بين قدرة تحويل الموجات المستمر (CWT) على تحليل الإشارات غير الثابتة، وبين قدرة شبكات الذاكرة طويلة وقصيرة المدى (LSTM) على معالجة العلاقات الزمنية الممتدة، ضمن إطار متكامل لتشخيص أعطال المضخات الترددية الثلاثية؛ وهي الفجوة التي يسعى هذا البحث إلى سدها. (Hochreiter & Schmidhuber, 1997).

3.1. أهداف البحث ومساهماته العلمية:

يهدف هذا البحث إلى تطوير إطار متكامل ومبتكر للكشف الدقيق والفعال عن الأعطال في المضخات الترددية الثلاثية من أجل توظيفه في مجالات صناعية حساسة تتطلب كشف مبكر وموثوقية عالية، من خلال توظيف قوة النمذجة الحاسوبية المتقدمة وتقنيات التعلم العميق.

ولتحقيق هذا الهدف الرئيس، يسعى البحث إلى تحقيق الأهداف الفرعية التالية:

1. بناء نموذج رياضي وفيزيائي شامل للمضخة الترددية الثلاثية باستخدام بيئة Python، بحيث يحاكي سلوكها الديناميكي في حالتي التشغيل السليم ووجود الأعطال المختلفة، مثل تسرب الأختام أو انسداد صمامات السحب والطرء أو تآكل المحامل.
2. توليد بيانات اصطناعية غنية وواقعية للإشارات المستشعرة (مثل الضغط والاهتزاز والتيار الكهربائي) اعتماداً على النموذج المحاكي، مع إدخال عناصر ضجيج لتعزيز واقعيته؛ وبذلك يتم تغطية ظروف تشغيل متعددة وأنواع مختلفة من الأعطال ودرجات شدتها.
3. تطبيق تقنيات متقدمة في معالجة الإشارات، وبشكل خاص تحويل الموجات المستمر (CWT) باستخدام دالة مورليه (Morlet wavelet)، لاستخراج خصائص مميزة وثابتة يمكنها عكس الحالة الصحية أو نوع العطل بدقة.
4. تصميم وتدريب وتقييم نماذج من التعلم العميق، ولا سيما شبكات LSTM وربما دمجها مع الشبكات الالتفافية (CNN) (LSTM)، لتصنيف أنواع الأعطال في المضخة اعتماداً على الخصائص المستخرجة.
5. تنفيذ تقييم شامل لأداء النماذج المقترحة باستخدام مجموعة من المقاييس الإحصائية (مثل الدقة، والاسترجاع، والدقة النوعية، ومعامل F1)، ومقارنتها لتحديد مدى فعالية النهج المعتمد.

مساهمات البحث الرئيسية

تتمثل مساهمة البحث في المجالات العلمية والعملية في خمس نقاط رئيسية:

- 1) إعادة تعريف منهجية التشخيص الصناعي: من خلال اتباع أسلوب جديد يجعل من البيانات الاصطناعية بيئة تعليمية كاملة للنماذج الذكية، ويضع الأساس لبناء مختبر افتراضي للأعطال الصناعية القابلة للتكرار والدراسة.

- (2) دمج الفيزياء بالذكاء الاصطناعي: عبر الربط بين الأسس الرياضية للنظام الفيزيائي وقدرات الشبكات العصبية، في نموذج تكاملي يجمع بين الفهم السببي والقدرة التنبؤية، وهو توجه حديث في الذكاء الاصطناعي الصناعي.
- (3) تذليل عقبة البيانات أمام الدراسات التطبيقية: لأنه يعالج مشكلة ندرة بيانات الأعطال الحقيقية بطريقة مبتكرة عبر توليد بيانات اصطناعية موثوقة تتبع السلوك الديناميكي الواقعي للنظام، ما يفتح المجال لأبحاث مماثلة في صناعات أخرى تعاني من ندرة العينات التشغيلية.
- (4) تحسين دقة التشخيص: أظهرت نتائج النماذج المقترحة أن الدمج بين التحليل المويجي والتعلم العميق يمكن أن يرفع من دقة التمييز بين الحالات التشغيلية إلى مستويات عالية جداً، مما يجعل النظام المراد تطويره خطوة عملية نحو تطبيقات الصيانة الذكية المستقبلية.
- (5) إطار مرن وقابل للتطبيق: باتباعه المنهجية القائمة على النمذجة والمحاكاة، يُمكن إعادة تكيف الإطار المقترح ليشمل معدات صناعية أخرى تتشابه في الطبيعة الترددية أو الهيدروليكية، مما يمنح البحث بعداً تطبيقياً واسعاً يتجاوز حدود نوع واحد من المعدات.

2. مراجعة الأدبيات:

يستعرض هذا القسم أبرز ما ورد في الدراسات والأبحاث السابقة ذات الصلة باستخدامات الذكاء الاصطناعي والمضخات الترددية؛ وتحليل التقنيات المستخدمة في التشخيص والتنبؤ بالأعطال لوضع الدراسة في سياقها العلمي الصحيح، وتوضيح المفاهيم النظرية والمعرفية المتعلقة بها.

1.2. المضخات الترددية الثلاثية: المبادئ والتحديات التشغيلية

تستخدم المضخات الترددية الثلاثية في العديد من المجالات الصناعية كمكون رئيسي لما تتميز به من قدرة على ضخ الموائع تحت ضغوط مرتفعة مع الحفاظ على تدفقات مستقرة (Jardine et al., 2006)؛ ويعتمد مبدأ عملها على الحركة الترددية لثلاثة مكابس تعمل بشكل متزامن لتقليل التذبذبات في التدفق وتحقيق كفاءة هيدروليكية عالية (He et al., 2017).

إلا أن هذه البنية التي تشمل عناصر متحركة مثل المكابس وحشوات الإحكام وصمامات السحب والطرود بشكل معقد، تجعلها عرضة لأنواع متعددة من الأعطال يمكن تصنيفها إلى أعطال ميكانيكية (مثل تآكل المحامل أو كسر المكبس أو تسرب الأختام)، وأعطال هيدروليكية (Lebbe et al., 1992) (مثل انسداد الصمامات أو ظاهرة التجويف أو مشاكل خطوط السحب والطرود)، وأعطال كهربائية ترتبط بالمحرك أو نظام التحكم (Zhu et al., 2019)، تؤثر بشكل مباشر على أداء المضخة، مسببة انخفاض الكفاءة وارتفاع مستويات الضجيج والاهتزاز وزيادة استهلاك الطاقة، إضافة إلى توقفات تشغيلية غير مخططة (Lei et al., 2020)؛ وتشير الدراسات إلى أن الأعطال المرتبطة بالصمامات والتسربات تُعد من أكثر المشكلات شيوعاً في هذا النوع من المضخات، مما يستدعي تطوير حلول تشخيصية فعالة ودقيقة (Zaki et al., 2021).

2.2. تقنيات مراقبة الحالة وتشخيص الأعطال

يمكن اعتبار تشخيص حالة المضخات الترددية التشغيلية، أحد المجالات البحثية القابلة للتطوير والتوسع، باعتبارها تهدف إلى تعزيز موثوقية المعدات وتقليل تكاليف الصيانة، وقد استخدمت طرق متقدمة نسبياً في هذا المجال تعتمد على تحليل البيانات المستمدة من المستشعرات المثبتة على المضخة، حيث تُعدّ تحليلات الاهتزاز من أكثر التقنيات شيوعاً، إذ يُستخدم فيها تحويل فورييه السريع (FFT) للكشف عن الترددات المميزة التي ترتبط بأعطال ميكانيكية محددة (Jardine et al., 2006)؛

غير أن هذه الأساليب قد تكون غير كافية للتعامل مع الإشارات غير الخطية وغير الثابتة التي تنتجها المضخات الترددية، لا سيما عند وجود أعطال متعددة أو تغير ظروف التشغيل

(Zhang & Li, 2018.; Wang & Hu, 2006)

وإلى جانب الاهتزازات، تُستخدم تحليلات الضغط والتدفق لتقييم الأداء الهيدروليكي للمضخة، حيث إن التغيرات في أنماط الضغط عند صمامات السحب أو الطرد قد تشير إلى مشاكل في الصمامات أو تسربات أو ظاهرة التجويف (Wu et al., 2020)؛ كما أثبتت تقنية تحليل التوقيع الكهربائي للمحرك MCSA فاعليتها في تشخيص الأعطال الميكانيكية والكهربائية عبر مراقبة التغيرات في الطيف الترددي للتيار الكهربائي المغذي للمحرك (Kim et al., 2020).

وقد طُورت عدة نماذج لتمثيل سلوك المضخات الترددية ومحاكاة ظروف الأعطال المختلفة؛ ركّز بعضها على النمذجة الميكانيكية لدراسة أعطال المكابس أو المحامل (Jamil & Azami, 2021)، بينما تناولت دراسات أخرى النمذجة الديناميكية للموانع داخل المضخة لمحاكاة مشاكل الصمامات والتسربات (Al-Jumaili & Jabbar, 2020)، وتُعدّ مثل هذه النماذج أدوات بديلة مهمة للحصول على بيانات تحاكي الأعطال في بيئة محكمة بظروف التشغيل وطول مدد المراقبة اللازمة لأخذ العينات الكافية، ما يوفر حلاً عملياً لندرة البيانات الواقعية؛ إلا أن العديد من النماذج المتاحة ما زالت مبسطة ولا تغطي التفاعلات الديناميكية المعقدة بين مكونات المضخة، كما أن بعضها لم يستفد من إمكانيات الأدوات الحديثة في الحلول العددية وتحليل الإشارات (Lee et al., 2021).

3.2. تطبيقات التعلم الآلي في تشخيص أعطال المعدات

لقد شهد مجال الصيانة وتشخيص الأعطال الصناعية تقدماً هائلاً مع دخول تقنيات التعلم الآلي ML والتعلم العميق DL، لما توفره من قدرة عالية على تحليل البيانات المعقدة واكتشاف الأنماط الخفية التي يصعب كشفها باستخدام الأساليب التقليدية المقارنة لأنها اعتمدت على الحوسبة التقليدية سابقاً التي اقتصرَت فاعليتها على كشف الأعطال وتصنيفها لكن الأساليب الحديثة التي استخدمت الذكاء الاصطناعي أضافت لها فعالية أكبر في مجال التنبؤ بالأعطال قبل وقوعها.

أولاً: خوارزميات التعلم الآلي التقليدية.

استُخدمت العديد من الخوارزميات التقليدية في تشخيص الأعطال الصناعية؛ إذ أثبتت آلات الدعم الناقل (SVM) كفاءة عالية في التصنيف خصوصاً مع مجموعات البيانات الصغيرة والمتوسطة (Yang et al., 2021)، في حين تُعدّ خوارزميات الأشجار العشوائية (Random Forest) وأشجار القرار (Decision Trees) (Mello et al., 2020) من الأدوات واسعة الاستخدام لما توفره من قابلية تفسير وسرعة في معالجة البيانات متعددة الأبعاد (Kim et al., 2016)؛ كما لاقت خوارزميات أقرب الجيران (KNN) وتقنيات التعزيز مثل Gradient Boosting و XGBoost رواجاً كبيراً في العديد من تطبيقات التشخيص الصناعي. (Sun et al., 2018)

وتتطلب هذه الخوارزميات عادةً مرحلة دقيقة من استخراج الخصائص لضمان الأداء الأمثل عند تحليل البيانات الخام. (Lee & Kim, 2017)

ثانياً: خوارزميات التعلم العميق.

أتاحت نماذج التعلم العميق مثل الشبكات الالتفافية والشبكات العصبية التكرارية إمكانية التعلم المباشر من البيانات الخام دون الحاجة إلى تدخل بشري كبير في تحديد الخصائص على عكس النماذج الأخرى. (Zhang et al., 2023)

الشبكات الالتفافية (CNN) تتميز بقدرتها العالية على معالجة البيانات ثنائية الأبعاد مثل السبكتروغرام أو السكالوغرام الناتجين عن التحليل الزمني الترددي، مما يجعلها مثالية لتشخيص الأعطال التي تظهر على شكل أنماط مميزة في هذه المجالات (Mao et al., 2018).

- الشبكات العصبية التكرارية (RNN) و شبكات الذاكرة الطويلة والقصيرة (LSTM) تُعدّ مناسبة جدًا لتحليل البيانات الزمنية، حيث تمتاز شبكات LSTM بقدرتها على التقاط العلاقات طويلة المدى في الإشارات، مما يجعلها فعالة في تحليل الإشارات التي تتغير خصائصها مع الزمن أو التي تحتوي على أنماط زمنية معقدة تدل على تطور العطل
- (Hochreiter & Schmidhuber, 1997; Yang et al., 2019)؛ وتشير دراسات حديثة إلى تفوق هذه الشبكات في تطبيقات تنبؤ العمر التشغيلي المتبقي (RUL) وتشخيص أعطال المعدات الدوارة (Yang et al., 2019).

ثالثًا: الاستخلاص المتقدم للخصائص.

رغم التطور الكبير في تقنيات التعلم العميق، ما يزال تحليل الموجات (Wavelet Transform) أداة أساسية في فهم الإشارات المعقدة؛ إذ يوفر التحويل المويجي المستمر (CWT) قدرة عالية على تحليل الإشارات غير الثابتة بدقة زمنية وترددية جيدة (Ma et al., 2025 ; Kong & Chen, 2004).

و تُعدّ موجة مورليه (Morlet Wavelet) من أكثر الأنواع شيوعًا وفعالية في تطبيقات تشخيص الأعطال نظرًا لتوازنها بين دقة الزمن والتردد، وقدرتها على التقاط التغيرات المفاجئة في الإشارة التي قد تشير إلى وجود خلل (Lee et al., 2021)؛ وتُستخدم الخصائص المستخرجة من نتائج CWT، سواء على شكل معاملات أو خرائط طيفية، كمداخل قوية لخوارزميات التعلم الآلي والعميق، مما يعزز دقة التصنيف والتمييز بين الحالات التشغيلية المختلفة.

3. منهجية البحث:

يهدف هذا الفصل إلى توضيح الإطار المنهجي الذي اعتمد عليه البحث من الناحية العلمية والتطبيقية؛ إذ يتم تعويض الناحية الفيزيائية من خلال بناء نموذج رياضي وفيزيائي محاكي للمضخة الترددية الثلاثية، وتوليد بيانات اصطناعية تمثل الحالات المختلفة للأعطال، ومعالجة الإشارات الناتجة عنها، ثم تصميم وتدريب نماذج من التعلم العميق لتصنيف الأعطال بدقة، وقد تم تنفيذ جميع هذه الخطوات باستخدام لغة البرمجة بايثون (Python) بالاستفادة من مكتباتها العلمية الكبيرة والمتخصصة التي تسهل عملية البرمجة والمعايرة بدون تعقيد وتمكن من تغيير البارامترات والمواصفات بشكل مباشر دون الحاجة إلى بناء دوال ومعادلات رياضية وفيزيائية فرعية لحساب كل منها.


1.3. تطوير نموذج المضخة الترددية الثلاثية

لتجاوز عدم القدرة على إجراء التجارب على مضخات حقيقية لصعوبة تأمينها وتشغيلها في ظروف عمل حقيقية ومراقبتها لفترات طويلة وأخذ العينات وتسجيل البيانات، كان بناء نموذج رياضي وفيزيائي محاكي للمضخة خطوة بديلة فعالة لتوليد بيانات واقعية يمكن الاعتماد عليها في تدريب نماذج التعلم الآلي وإكسابه القدرة على تمييز أنماط الأعطال والتغيرات المتدرجة التي تطرأ عليها من الحالة السليمة حتى ظهور العطل بهدف محاكاة السلوك الديناميكي للمضخة في جميع حالاتها السليمة وحالات الأعطال المختلفة.

1.1.3. مكونات النموذج والصياغة الرياضية

تم بناء النموذج بالاعتماد على المكونات الفيزيائية الرئيسة للمضخة، والتي تشمل ما يلي:

- المحرك وعمود المرفق (Crankshaft) يُمثل دوران العمود المرفقي كحركة دورانية منتظمة أو متغيرة تبعًا لظروف التشغيل، وتُشتق حركة المكابس الترددية من تلك الحركة الدورانية.
 - المكابس: تُنمذج حركتها كتذبذب ترددي يعتمد على أبعاد العمود المرفقي وأذرع التوصيل، وتُحسب السرعة والموقع لكل مكبس مما يؤثر مباشرة في تغيير حجم الأسطوانة أثناء عملية الضخ.
 - الصمامات: تُنمذج صمامات السحب والطرود كعناصر تدفق ذات مقاومة متغيرة ترتبط بدرجة الفتح ومعدل التدفق المار خلالها، كما تُدرج في النموذج خصائص الصمام مثل زمن الاستجابة والذبذبات المصاحبة للحركة.
 - خطوط الأنابيب: تمثل أنابيب السحب والطرود وسائط ديناميكية يتغير فيها ضغط السائل وسرعته باستمرار، ويُستخدم في تمثيلها قانون حفظ الكتلة ومعادلات بيرنولي المعدلة لاحتساب الفقد بالاحتكاك، مع الأخذ في الاعتبار خصائص السائل الفيزيائية مثل الكثافة واللزوجة ومعامل الانضغاط.
 - الخزانات (Reservoirs): يُمثل خزان السحب والطرود كمصدر أو مصرف للموائع بضغط ثابت أو متغير وفقًا لحالة التشغيل.
- وتُبنى الصياغة الرياضية للنموذج على نظام من المعادلات التفاضلية العادية (ODEs) والمعادلات الجبرية التي تصف العلاقات المتبادلة بين هذه المكونات؛ فعلى سبيل المثال، يُحسب معدل التدفق عبر الصمامات بناءً على فرق الضغط ومقاومة التدفق، في حين تُحسب القوى المؤثرة على المكابس من خلال الضغوط داخل الأسطوانات.
- كما تُدرج في النموذج المعاملات الهندسية (مثل أبعاد المكبس وطول ذراع التوصيل) والخصائص الفيزيائية (مثل لزوجة السائل واحتكاك المكونات المتحركة).



الشكل (1) محاكاة تقريبية لشكل المضخة في الحالة السليمة مولد بالذكاء الاصطناعي

2.1.3. تنفيذ النموذج الافتراضي باستخدام بيئة بايثون

تم تطوير النموذج الرياضي بالكامل باستخدام لغة بايثون نظرًا لما توفره من مرونة في الحسابات العددية والمحاكاة، حيث استخدمت مكتبة NumPy لإجراء العمليات الرياضية على المصفوفات، في حين استخدمت مكتبة SciPy.integrate وبالتحديد الدالة solve_ivp لحل نظام المعادلات التفاضلية الناتجة عن النموذج الديناميكي؛ إذ تسمح هذه الدالة باختيار طرق عديدة مختلفة وتوفر مرونة في التعامل مع الأنظمة المعقدة من المعادلات.

نُظم الكود في شكل دوال أو أصناف برمجية (Classes) تمثل كل مكون من مكونات المضخة على حدة (مثل صنف خاص بالصمام وآخر بالمكبس)، مما يسهل عملية إدارة النموذج وتعديله عند الحاجة، ثم جرى دمج هذه المكونات ضمن نظام متكامل يمثل منظومة المضخة الكاملة، بحيث تُمرّر المتغيرات (كالضغط والموضع والسرعة) بين المكونات في كل خطوة زمنية لمحاكاة التفاعل الديناميكي الكامل بين أجزاء النظام.


2.2.3. نمذجة الأعطال وتوليد البيانات الاصطناعية

لإنشاء قاعدة بيانات شاملة لتدريب واختبار النماذج، جرى تمثيل مجموعة من سيناريوهات الأعطال الشائعة بالإضافة إلى حالة التشغيل السليم للمضخة.

1.2.3. تحديد وتمثيل الأعطال المستهدفة

تم التركيز خلال التجارب على تمثيل الأعطال التي تُعد من الأعطال الشائعة في المضخات الترددية الثلاثية (Szczepaski): (Kijak, 2023; Kong & Chen, 2004; Du et al., 2013 & كما يلي:

تسرب أختام المكبس (Piston Seal Leakage): يُمثل هذا العطل بإضافة مسار جانبي لتدفق السائل بمقاومة متغيرة تتزايد مع شدة العطل، مما يسمح بتسرب السائل أثناء شوط الطرد.



الشكل (2) تمثيل بصري افتراضي لتسرب المكبس تم توليده بالذكاء الاصطناعي

- انسداد صمام السحب: (Suction Valve Blockage) يُحاكي بزيادة مقاومة التدفق عبر صمام السحب، مما يعيق امتلاء الأسطوانة ويخفض ضغط السحب، ويمكن أن يتراوح بين انسداد جزئي وكامل؛
- انسداد صمام الطرد: (Discharge Valve Blockage) يتمثل في زيادة مقاومة التدفق في صمام الطرد، الأمر الذي يؤدي إلى ارتفاع غير طبيعي في ضغط الطرد وصعوبة في طرد السائل؛
- تآكل المحامل: (Bearing Wear) يُبسّط هذا العطل بإضافة قوة احتكاك إضافية على حركة المكبس أو عمود المرفق، مما يؤثر في الديناميكا الميكانيكية وينعكس على الاهتزازات؛
- ظاهرة التجويف: (Cavitation) رغم صعوبة تمثيلها بدقة، يمكن تقريبها بحدوث انخفاض حاد في ضغط السحب عندما يقل الضغط عن ضغط البخار للسائل.
- تمثل شدة كل عطل كمتغير عددي يتراوح بين (0%) في الحالة السليمة و(100%) في الحالة الشديدة، ويتم إدراج هذه القيمة ضمن معادلات النموذج الرياضي للتحكم بدرجة الخل.

2.2.3. ظروف التشغيل وتوليد البيانات

أُجريت المحاكاة تحت ظروف تشغيلية متنوعة لضمان عمومية النموذج وقدرته على التعامل مع مختلف الحالات، وشملت ما يلي:

- سرعات المحرك: (Motor Speeds) تم تشغيل النموذج عند معدلات دوران مختلفة (RPM) لمحاكاة اختلاف ظروف التشغيل.
- ضغوط السحب والطرد: جرى تغيير ضغوط الخزانات في جانبي السحب والطرد لتمثيل تغير الأحمال التشغيلية.
- خصائص السائل ودرجة الحرارة: أُخذت في الاعتبار تغيرات طفيفة في الكثافة واللزوجة نتيجة اختلاف درجة الحرارة لزيادة واقعية البيانات.
- ولكل حالة تشغيلية سواء كانت سليمة أو متأثرة بعطل معين وبدرجة محددة جرى تشغيل المحاكاة لمدة زمنية كافية لتوليد سلاسل زمنية طويلة، وبذلك أنشئت مجموعات بيانات تغطي مئات السيناريوهات المختلفة، بما يضمن التنوع الكافي لتدريب نماذج التعلم العميق لاحقاً.

3.2.3. توليد بيانات الاستشعار الاصطناعية وإضافة الضجيج

لرصد الفجوة بين النمذجة النظرية والتطبيق العملي، تم توليد بيانات استشعار اصطناعية عالية الدقة من خلال المحاكاة الديناميكية للنموذج الرياضي للمضخة، كما ورد في القسم (3.1)، وتُعد هذه الخطوة مهمة لتكوين قاعدة بيانات واقعية تحاكي ظروف التشغيل الحقيقية وأنماط الأعطال الفعلية، بما يعوّض نقص البيانات الميدانية.

بدأت عملية المحاكاة بتحديد ظروف التشغيل ونوع العطل المطلوب تمثيله، وفي كل حالة تم تعديل المعاملات الفيزيائية ذات الصلة داخل النموذج (مثل مقاومة الصمام أو قوة الاحتكاك أو مسار التسرب) بما يتوافق مع درجة العطل وشدته، مما يؤثر مباشرة في سلوك المضخة الديناميكي.

من نواتج النموذج، تم استخراج إشارات المستشعرات الاصطناعية التالية:

- ضغط الأسطوانة: ($P_c(t)$) مشتق من الديناميكا الهيدروليكية وحركة المكابس داخل كل أسطوانة؛
- تسارع المكبس: $ap(t)$ مستخلص من الديناميكا الميكانيكية لمجموعة المكبس ويُستخدم كمؤشر للاهتزاز؛

- التيار الكهربائي للمحرك: $Im(t)$ يُحسب اعتمادًا على الحمل الميكانيكي الكلي الذي تفرضه المضخة على المحرك الرئيسي، ولتقريب هذه البيانات من الواقع الصناعي، أُضيفت ضوضاء اصطناعية محسوبة لمحاكاة التشويش الناتج عن أجهزة الاستشعار والعوامل البيئية، مما يجعل البيانات أكثر واقعية واستقرارًا للتدريب (Becker, 2022).

3.3. مثال على بيانات الاستشعار الاصطناعية

لتوضيح عملية توليد البيانات من النموذج الرياضي، في الجدول (1) عينة من بيانات الاستشعار الاصطناعية "النظيفة" التي تم الحصول عليها مباشرة من المحاكاة الفيزيائية للمضخة، بينما يُظهر الجدول (2) نفس البيانات بعد إضافة ضوضاء واقعية لمحاكاة ظروف القياس الحقيقية.

جدول (1) عينة من بيانات الاستشعار الاصطناعية "النظيفة" (من المحاكاة الفيزيائية)

الزمن (ث)	ضغط الأسطوانة الأولى (بار)	تسارع المكبس الأول (م/ث ²)	تيار المحرك (أمبير)
0.000	10.00	0.00	5.00
0.001	10.25	0.50	5.10
0.002	10.80	1.20	5.25
0.003	11.50	1.80	5.40
0.004	12.30	2.30	5.55
0.005	13.00	2.50	5.65

جدول (2) عينة من بيانات الاستشعار الاصطناعية المشوشة (بعد إضافة ضوضاء) AWGN

الزمن (ث)	الضغط (بار)	تسارع المكبس (م/ث ²)	تيار المحرك (أمبير)
0.000	10.02	0.03	5.01
0.001	10.23	0.48	5.08
0.002	10.77	1.22	5.23
0.003	11.55	1.78	5.42
0.004	12.28	2.33	5.53
0.005	12.98	2.47	5.66

أساس توليد القيم وبنية البيانات

القيم المعروضة في هذه الجداول نتيجة المحاكاة الديناميكية للسلوك الفيزيائي للمضخة كما تم شرحه في القسم (3.1). ويستند توليدها إلى المبادئ التالية:

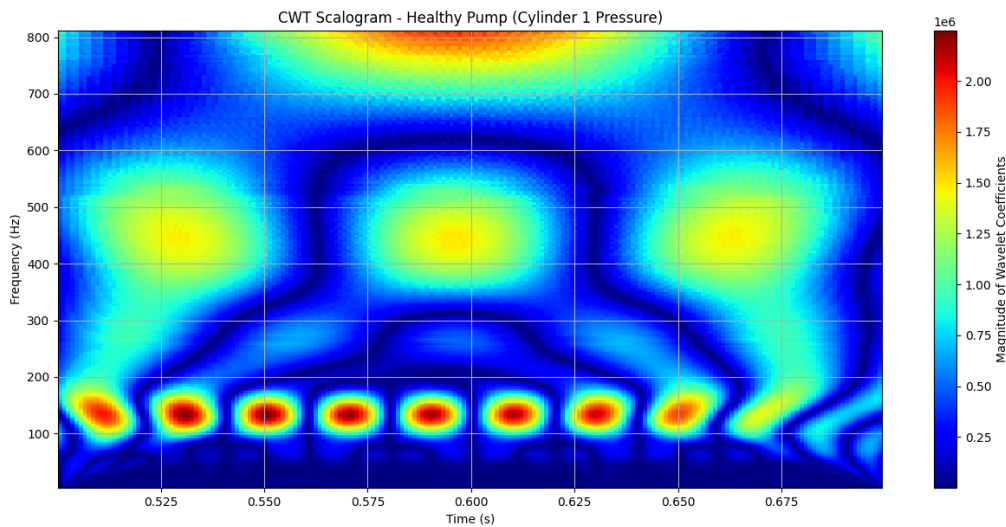
- قيم ضغط الأسطوانات: $P_c(t)$

تُستخرج هذه القيم من ديناميكا تدفق السائل وحركة المكبس داخل أسطوانات المضخة، ففي الحالة السليمة يتذبذب الضغط ضمن نطاق تشغيلي طبيعي (بين 10 و 30 بار) بشكل موجي شبه جيبى يعكس حركة المكبس ودورات الصمامات، وهو سلوك يتوافق

مع الخصائص المميزة للمضخات الترددية (Mao et al., 2018)، وعند إدخال عطل مثل تسرب أختام المكبس (يُمدج بمعامل تسرب يقلل من كفاءة الأسطوانة)، يظهر انخفاض واضح في القيم القصوى للضغط بنسبة تتراوح بين 5-15% بحسب شدة العطل، مع تشوه في شكل الموجة؛ أما في حالة انسداد صمام الطرد (يمثل كمقاومة هيدروليكية مرتفعة)، فيرتفع الضغط المتوسط والذروي ليصل إلى أكثر من 35 بار، وتظهر قمم ضغطية حادة تدل على عدم انتظام عملية الطرد (Zhang & Li, 2018; Wang & Hu, 2006).

• قيم تسارع المكبس: $a_p(t)$

تُستخلص هذه القيم من ديناميكا الحركة الميكانيكية للمكونات المتحركة، وتعتمد على تفاعل المكبس مع القوى الهيدروليكية وقوى العطالة، في الظروف الطبيعية تتراوح قيم التسارع بين $50 \pm$ م/ث² تقريباً، وتُظهر نمطاً دورياً منتظماً. إلا أن وجود خلل ميكانيكي أو هيدروليكي يؤدي إلى ظهور قوى إضافية تغير من سعة التسارع (قد تتضاعف عن القيم السليمة) وتدخل مكونات ترددية جديدة في الإشارة، مما يجعلها مؤشراً دقيقاً للاهتزازات المستخدمة في تشخيص الأعطال (Wu et al., 2020). تُحسب هذه القيم اعتماداً على الحمل الميكانيكي الكلي الذي تفرضه المضخة على المحرك الكهربائي، والذي يشمل قوى الضغط والاحتكاك؛ ويتراوح تيار المحرك في الحالة السليمة بين 5 و 8 أمبير تقريباً، مع تذبذبات دورية تعكس دورة الضخ، أما في حالة وجود خلل مثل تآكل المحامل أو انسداد الصمامات، فيزداد الحمل الميكانيكي، وينعكس ذلك على شكل زيادة في متوسط التيار بنسبة 10-20% أو ظهور مكونات جانبية جديدة في طيف التردد للتيار الكهربائي، بما يتوافق مع مبادئ تحليل توقيع التيار للمحركات (MCSA) في تشخيص الأعطال (Kim et al., 2020; Becker, 2022)، ويتم البناء على هذه البيانات الاصطناعية في مرحلة معالجة الإشارات وتحليلها، مما يجعلنا قادرين على استخراج خصائص مميزة باستخدام التحويل المويجي المستمر (CWT) ومن ثم توظيفها في تدريب نماذج التعلم العميق لتصنيف الأعطال بدقة عالية.



الشكل (3) مخطط سكالوجرام للتحويل المويجي المستمر لمضخة سليمة (ضغط المكبس رقم 1)

4.3. إضافة الضوضاء وبنية البيانات

لزيادة واقعية وصلابة مجموعة البيانات الاصطناعية، تم إدخال ضوضاء بيضاء غاوسية مضافة (Additive White Gaussian Noise – AWGN) إلى كل إشارة تم توليدها من النموذج الفيزيائي للمضخة.

تُعد هذه الخطوة ضرورية لأن بيانات المستشعرات الحقيقية تكون عادةً عرضة للتشويش الناتج عن المؤثرات البيئية أو الأجهزة نفسها، ويُتحكم في مستوى الضوضاء عبر نسبة الإشارة إلى الضوضاء (SNR)، مما يتيح محاكاة مستويات مختلفة من جودة المستشعرات أو بيانات التشغيل (Torrence & Compo, 1998)، ويُعبر عن عملية إضافة الضوضاء رياضياً بالمعادلة الآتية:

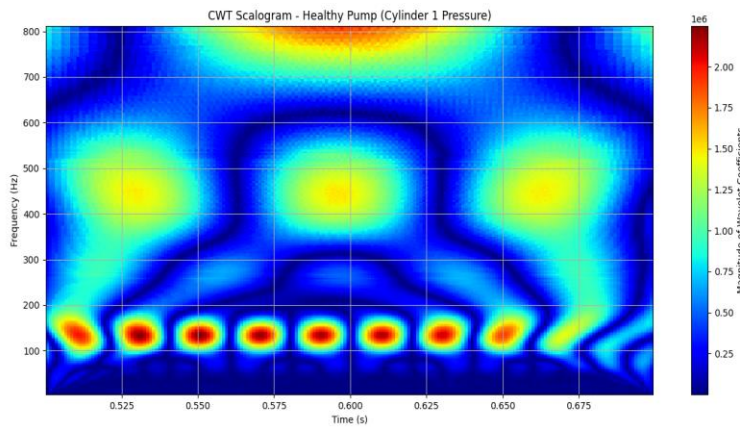
$$x_{noisy}(t) = x_{clean}(t) + \alpha_{noise}(t)$$

- $x_{noisy}(t)$ الإشارة الاصطناعية بعد إضافة الضوضاء عند الزمن t .
- $x_{clean}(t)$: الإشارة الأصلية "النظيفة" الناتجة مباشرة من النموذج الرياضي عند الزمن نفسه.
- $noise(t)$: عينة من توزيع ضوضاء غاوسية بيضاء ذات متوسط صفر وانحراف معياري مقداره واحد.
- α : معامل تحكم في سعة الضوضاء، حيث تؤدي زيادة قيمته إلى خفض نسبة الإشارة إلى الضوضاء (SNR) أي زيادة مستوى التشويش.

بعد توليد الإشارات الزمنية، تُخزّن البيانات مع وسومها (Labels) التي تشير إلى حالة التشغيل (سليمة أو نوع العطل وشدة)، يُحفظ هذا التنظيم في هيئة مصفوفات NumPy أو جداول Pandas DataFrames لسهولة المعالجة لاحقاً خلال مراحل التدريب على التعلم العميق.

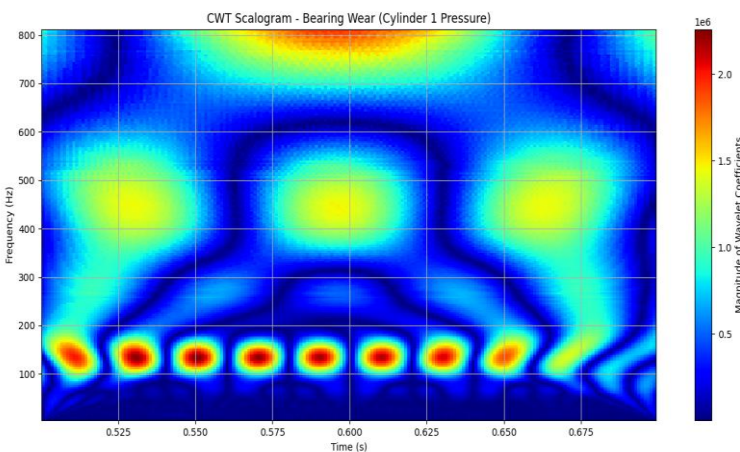
جدول (3) البنية المفاهيمية لمجموعة البيانات الاصطناعية مع الوسوم والبيانات الوصفية

رقم السجل	نوع الحالة	شدة العطل	SNR (ديسيبل)	النطاق الصحي النموذجي (ضغط/تسارع/تيار)	الأساس الفيزيائي أو المرجعي للنطاق
001	سليمة	غير متاح	30	10-30 بار ± 50 / م/ث ² / 5-8 أمبير	تصميم المضخة، سرعة التشغيل، (Jamil & Azami, 2021), (Al-Jumaili & Jabbar, 2020) خصائص السائل، الحالة المثالية
002	تسرب أختام المكبس	20%	25	انخفاض الضغط الذروي بنسبة 5-15%	تأثير التسرب على معادلات حفظ الكتلة في الأسطوانة، سلوك الأعطال الموثق (Zhang & Li, 2018)
003	انسداد صمام الطرد	60%	20	ارتفاع الضغط (>35 بار) / زيادة تيار المحرك (10-20%)	زيادة المقاومة الهيدروليكية في معادلات تدفق الصمام، أنماط الأعطال المعروفة (Kim et al., 2020), (Zhang & Li, 2018)



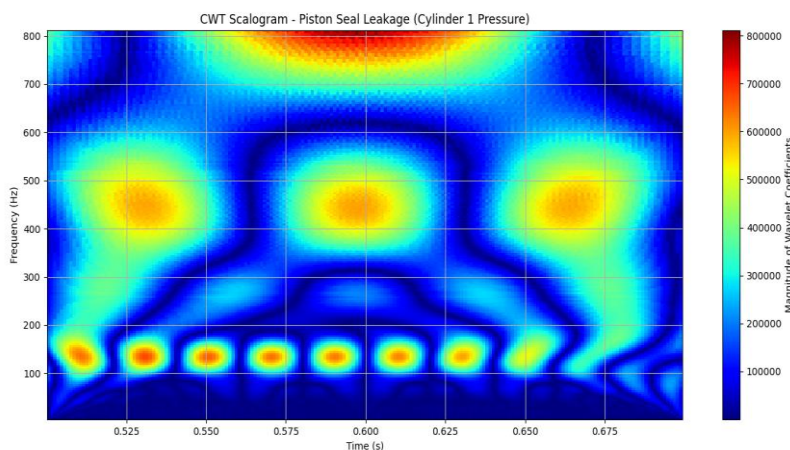
مخطط CWT
سكالوجرام لمضخة
سليمة

الشكل (4) مخطط CWT سكالوجرام لمضخة سليمة



مخطط CWT
سكالوجرام لتآكل
المحمل

الشكل (4) مخطط CWT سكالوجرام لتآكل المحمل



CWT مخطط
تسرب في المكبس

الشكل (6) مخطط CWT تسرب في المكبس

تمثل هذه الرسوم الطيف الزمني-التردد للإشارات بعد معالجتها باستخدام التحويل المويجي المستمر (CWT)، حيث تُظهر الاختلافات البصرية بين الحالة السليمة وأنماط الأعطال المختلفة، مما يسهل على نماذج التعلم العميق تمييزها لاحقاً.

5.3. معالجة الإشارات واستخراج الخصائص

تُعدّ معالجة الإشارات خطوةً أساسيةً لتحويل البيانات الخام إلى خصائص يمكن لنماذج التعلم العميق الاستفادة منها في عملية التعرف على الأعطال. وتشمل هذه المرحلة عدداً من العمليات التمهيدية على الإشارات المُولدة قبل البدء باستخراج الخصائص. أولاً، ترشيح الضوضاء، حيث تُستخدم المرشحات الرقمية مثل المرشح الممرّر للنطاق (Band-pass) أو المرشح منخفض التمرير (Low-pass) لإزالة المكونات غير المرغوبة دون التأثير في العناصر الحاملة للمعلومات المرتبطة بالعتل، وهي خطوة ضرورية لضمان نقاء الإشارة واستقرار تحليلها (Mao et al., 2018; Wang & Hu, 2006; Lee et al., 2021). ثانياً، التقسيم الزمني، حيث تُقسّم السلاسل الزمنية الطويلة إلى نوافذ زمنية قصيرة متداخلة أو منفصلة لتقليل حجم البيانات في كل جزء، وتمكين تحليل التغيرات الموضوعية بمرور الزمن، خصوصاً قبل تطبيق التحليل المويجي أو تحويلات التردد الأخرى (Lee et al., 2021; Zhang et al., 2023).

تُهيئ هذه الخطوات البيانات بشكل يجعلها أكثر ملاءمة لاستخراج الخصائص الترددية والزمنية الدقيقة التي تُستخدم لاحقاً في التدريب الذكي للنماذج.

6.3. التحليل المويجي المستمر (CWT) واستخراج الخصائص

يُعدّ التحويل المويجي المستمر من الركائز الأساسية في المنهجية المقترحة لتشخيص أعطال المضخة الترددية الثلاثية، إذ يُحوّل إشارات المستشعرات الخام من المجال الزمني إلى تمثيل زمني-تردد يُعرف باسم السكالوغرام (Scalogram). تكمن أهمية هذا التحويل في قدرته على استخلاص خصائص مميزة يصعب تمييزها في الإشارات الزمنية الأصلية، لا سيما في بيانات التشغيل التي تتسم بالضوضاء أو التعقيد الديناميكي العالي، وعلى خلاف تحويل فورييه التقليدي، يتميز CWT بدقة عالية في تحديد مواقع التغيرات في كل من الزمن والتردد معاً، مما يجعله أداة فعّالة لتحليل الإشارات غير الثابتة والأحداث العابرة التي تمثل السمات المميزة للأعطال في المضخات (Torrence & Compo, 1998; Mao et al., 2018; Lee et al., 2021; Zhang et al., 2023).

ويُطبّق هذا التحويل على كل إشارة من الإشارات الاصطناعية كالضغط، والتسارع، والتيار الكهربائي لالتقاط محتواها الترددي المحلي وتتبع تطوره عبر الزمن، مما يُتيح تمثيلاً بصرياً غنياً يُستخدم لاحقاً في تدريب الشبكات العصبية على تصنيف الحالات الصحية والأعطال بدقة عالية.

كما يُعرّف التحويل المويجي المستمر (CWT) رياضياً بالعلاقة التالية: (Torrence & Compo, 1998)

$$CWT(a, b) = \int_{-\infty}^{+\infty} \frac{1}{\sqrt{|a|}} x(t) \psi\left(\frac{t-b}{a}\right) dt$$

حيث:

- α : هو معامل المقياس، الذي يرتبط عكسياً بالتردد، فكلما زاد المقياس قلّ التردد؛
- b : هو معامل الإزاحة الزمنية الذي يحدد موقع الإشارة على محور الزمن؛
- $\psi(t)$: هو المرافق المركب للموجة الأم.

تم اختيار موجة مورليه لتكون الموجة الأم في هذا البحث، لما تتميز به من توازن دقيق بين الدقة الزمنية والترددية، ولانتشار استخدامها في تحليل الاهتزازات وتشخيص الأعطال، وتم تحديد نطاق المقاييس المناسب لضمان تغطية شاملة للترددات ذات الصلة وإظهار الأنماط الدالة على الأعطال بشكل واضح.

ينتج عن تطبيق CWT مصفوفة ثنائية الأبعاد (سكالوغرام) تمثل الطاقة الموزعة للإشارة عبر الزمن والتردد. تُظهر هذه السكالوغرامات أنماطاً مميزة يمكن من خلالها تمييز الحالات السليمة عن حالات العطل؛ فعلى سبيل المثال، قد يظهر العطل في صورة تركّز للطاقة عند نطاق ترددي معين خلال جزء محدد من دورة الضخ، وهو ما يمكن رؤيته بوضوح بصري في الخريطة الموجية.

تُستخدم هذه السكالوغرامات كمدخلات أساسية في مرحلة التعلم العميق اللاحقة، إذ يتيح تحويل البيانات الزمنية أحادية البعد إلى صور ثنائية الأبعاد تحويل مهمة استخراج الخصائص إلى مهمة تعرف على الأنماط يمكن معالجتها بفعالية عالية باستخدام الشبكات الالتفافية CNNs.

7.3. التعلم العميق وتصنيف الأعطال

بعد الانتهاء من معالجة الإشارات واستخراج الخصائص عبر CWT، تُستخدم البيانات الناتجة في تدريب نماذج التعلم العميق من أجل تصنيف الحالات التشغيلية للمضخة وتحديد نوع العطل.

1.7.3. إعداد البيانات للتعلم العميق

قبل إدخال البيانات إلى النماذج العصبية، يجب إجراء عدة خطوات أساسية لضمان جودة التدريب:

- تحويل البيانات: تُحوّل خرائط السكالوغرام أو الخصائص الإحصائية المستخرجة منها إلى مصفوفات NumPy مناسبة لإدخالها في مكتبات TensorFlow/Keras.
- التطبيع والتجسيم: تُطبّق تقنيات التطبيع مثل Min–Max Scaling و Standardization لتوحيد نطاق القيم (بين 0 و 1 أو بمتوسط صفري وانحراف معياري يساوي 1)، وذلك لتسريع عملية التعلم وتحسين استقرارها.
- تقسيم البيانات: تُقسّم قاعدة البيانات إلى ثلاث مجموعات رئيسية: مجموعة التدريب (70%) لتعليم النموذج، مجموعة التحقق (15%) لضبط المعاملات ومنع فرط التكيف، ومجموعة الاختبار (15%) لتقييم أداء النموذج على بيانات غير مرئية مسبقاً.
- ترميز الفئات: (One-Hot Encoding) تُحوّل تسميات الحالات (مثل "سليم"، "تسرب"، "انسداد") إلى تمثيل رقمي ثنائي لتلائم مهام التصنيف متعدد الفئات.

2.7.3. تصميم نماذج التعلم العميق (LSTM / CNN–LSTM)

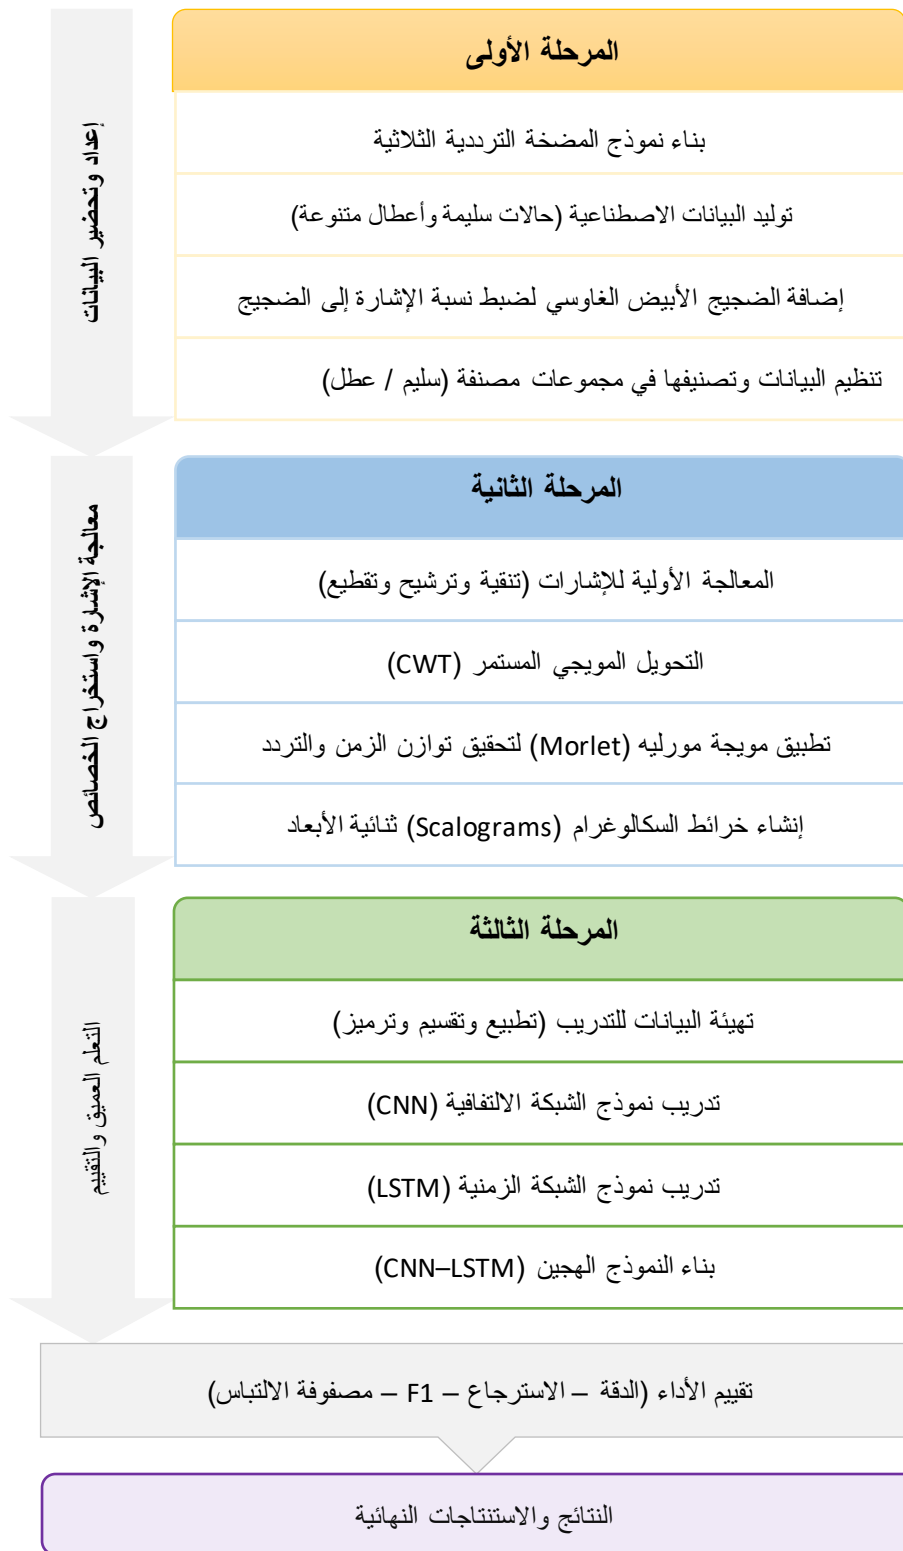
تم تصميم النماذج العميقة باستخدام مكتبات Tensor Flow لما توفره من مرونة وسرعة في بناء الشبكات العصبية (Sun et al., 2018)، وقد تم اعتماد هيكلين أساسيين للتجربة والمقارنة:

- نموذج LSTM: يتألف من طبقة أو أكثر من شبكات الذاكرة الطويلة والقصيرة، المصممة خصيصاً لمعالجة البيانات التسلسلية بفضل قدرتها على تذكر الأنماط الزمنية الطويلة داخل الإشارة. (Hochreiter & Schmidhuber, 1997)
- تدرج طبقات Dropout: بين الطبقات أو قبل الطبقات الكثيفة لتقليل فرط التعلم (Overfitting).

- النموذج الهجين CNN-LSTM : يجمع بين قدرات الشبكات الالتفافية (CNN) في استخلاص الخصائص المكانية والترددية من خرائط السكالوغرام، وقدرات LSTM في تحليل الأنماط الزمنية يُستخدم نوع Conv2D عند التعامل مع خرائط ثنائية الأبعاد Scalograms ، تليه مرحلة Flatten أو Reshape لتجهيز المخرجات وربطها بطبقات LSTM اللاحقة. يتيح هذا الدمج التعرف على التغيرات الترددية عبر CNN ، إلى جانب التتابعات الزمنية عبر LSTM ، وهو ما أثبتت فعاليته في تطبيقات مشابهة (Lee & Kim, 2017; Li et al., 2020)

3.7.3. تدريب النماذج وتقييم أدائها

- عملية التدريب:
تم تدريب النماذج باستخدام دالة الفقد المناسبة للتصنيف متعدد الفئات (Categorical Cross-Entropy) والمُحسّن Adam المعروف بكفاءته في تسريع تقارب الشبكات. (Yang et al., 2021)
استخدمت دقة التصنيف (Accuracy) كمؤشر رئيسي لقياس تقدم النموذج أثناء التدريب، مع تطبيق آلية الإيقاف المبكر عند توقف التحسن في أداء مجموعة التحقق لمنع فرط التكيف.
- تقييم الأداء:
بعد انتهاء التدريب، تم اختبار النماذج على مجموعة البيانات المستقلة لقياس أدائها العام باستخدام مجموعة من المقاييس القياسية، تشمل:
 - الدقة: (Accuracy) نسبة التصنيفات الصحيحة من إجمالي العينات؛
 - الاستدعاء: (Recall) نسبة الحالات التي تم اكتشافها بشكل صحيح من جميع الحالات الفعلية؛
 - الدقة الإيجابية: (Precision) نسبة الحالات الصحيحة بين جميع الحالات التي صُنفت على أنها موجبة؛
 - معامل F1: المتوسط التوافقي بين الدقة والاستدعاء، ويُستخدم عندما تكون فئات البيانات غير متوازنة؛
 - مصفوفة الالتباس: (Confusion Matrix) لتوضيح أداء النموذج في تمييز كل فئة وتحديد الفئات التي حدث فيها التباس (Kankar et al., 2011).
- وأخيراً، أُجري تحليل مقارنة بين أداء النماذج LSTM مقابل CNN-LSTM لتحديد البنية الأكثر فعالية في تصنيف الأعطال وتمييز الحالات التشغيلية المختلفة للمضخة.



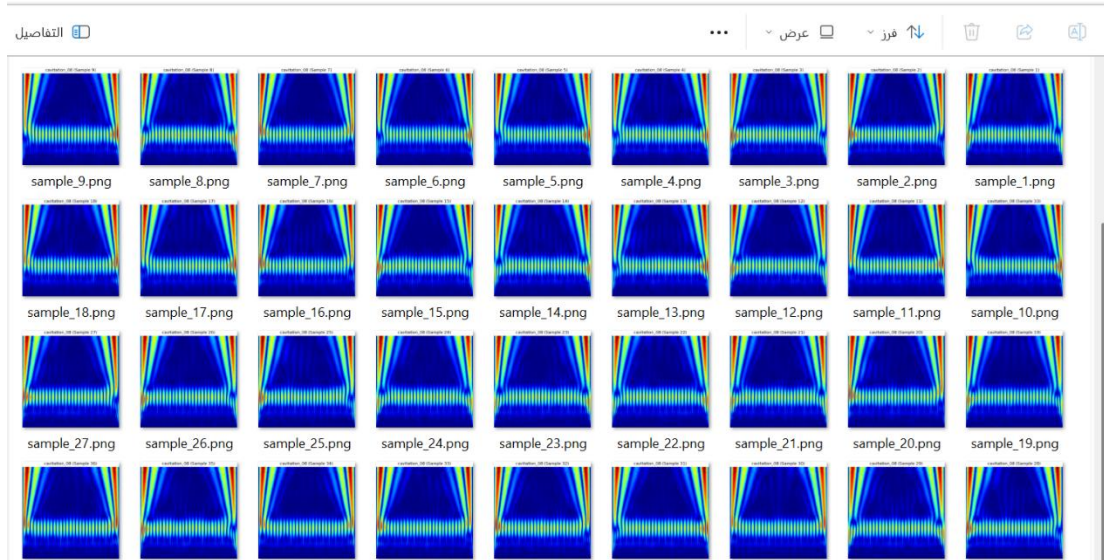
4. النتائج والمناقشة:

في هذا الفصل يتم استعراض نتائج التجارب التي أجريت لتقييم فعالية استخدام التحويل المويجي المستمر في تمثيل بيانات اهتزازات المضخة الترددية الثلاثية على شكل خرائط سكالوغرام، ومن ثمّ توظيفها في تصنيف حالات الأعطال باستخدام نماذج التعلم العمي حيث تم دراسة ثلاثة نماذج رئيسية:

- الشبكة العصبية التلافيفية (CNN)،
- شبكة الذاكرة القصيرة وطويلة المدى (LSTM)،
- النموذج الهجين CNN-LSTM الذي يجمع بين الخصائص المكانية والزمنية.

1.4. التقييم المبني على مجموعات بيانات صغيرة

في المرحلة الأولى من التجارب، تم اختبار النماذج الثلاثة باستخدام مجموعات بيانات محدودة الحجم (من 50 إلى 100 صورة)، وذلك للتحقق من الجدوى الأولية وتحديد النموذج الأكثر وعدًا قبل تخصيص موارد حوسبة كبيرة للتدريب على مجموعات أكبر. خلال هذه المرحلة، أظهر النموذج CNN أداءً أوليًا أفضل، إذ بلغت دقته نحو 60% عند اختبار 100 صورة، في حين كانت نتائج النماذج الأخرى ضعيفة جدًا ولم تتجاوز 10%. وبالنظر إلى التكلفة الزمنية والموارد الحاسوبية العالية المطلوبة لتدريب النماذج المعقدة على بيانات كبيرة، وإلى الأداء المبني المشجع لشبكة CNN، تقرر التركيز على تطوير هذا النموذج وتحسينه في المراحل اللاحقة.



الشكل (5) لقطة شاشة لعينة من مجموعة صور لأحد الأعطال وهو التكهف cavitation مع التدرج الزمني (كل مجموعة 50 صورة)

2.4. التقييم النهائي لأداء نموذج CNN

بعد تحديد نموذج CNN كأفضل مرشح، تمت زيادة حجم العينة التدريبية بشكل كبير، حيث دُرّب النموذج على أكثر من 500 صورة تم تعزيزها بطرق زيادة البيانات (Data Augmentation) للاستفادة الكاملة من قدرات التعلم العميق. لأغراض التقييم النهائي والمقارنة، جرى اختبار جميع النماذج على مجموعة اختبار موحدة تتكوّن من 50 صورة (خمس صور لكل فئة من الفئات العشر)، ولم تُستخدم أيٌّ منها في عملية التدريب.

الشكل (6) لقطة شاشة لنتائج التدريب والاختبار – مرحلة أولى


الشكل (7) لقطة شاشة لنتائج التدريب – مرحلة متوسطة

الشكل (8) مقارنة أداء النماذج المختلفة على مجموعة الاختبار الموحدة

جدول (4) يلخص أداء النماذج المختلفة على مجموعة الاختبار الموحدة

النموذج	حجم بيانات التدريب	دقة الاختبار	ملاحظات
CNN تجريبي	50 صورة	60%	تجربة أولية تأشيريه فقط لاختبار الزمن والاستقرار، ضعف الأداء يُعزى إلى قلة البيانات اللازمة لتعلم النموذج الهجين المعقد
CNN LSTM تجريبي	50 صورة	10.0%	تجربة أولية تأشيريه فقط لاختبار الزمن والاستقرار، ضعف الأداء يُعزى إلى قلة البيانات اللازمة لتعلم النموذج الهجين المعقد، لذلك لم تُستكمل عملية التدريب لتجنب هدر الموارد.
CNN– LSTM (تجريبي)	100 صورة	10.0%	الأداء بقي منخفضًا رغم زيادة بسطة في البيانات، مما يؤكد أن النموذج يتطلب بيانات أكبر بكثير لتحقيق تحسن ملحوظ.
LSTM الصرف تجريبي	50 صورة	ضعيف جدًا / غير صالح	لم يتمكن وحده من استخلاص الخصائص المكانية المعقدة مباشرة من الصور، مما يؤكد الحاجة إلى طبقات الالتفاف في هذا النوع من المهام.
CNN مع تعزيز البيانات	500 صورة	96.0%	أظهر أداءً متميزًا يؤكد كفاءة الشبكات الالتفافية في استخراج الخصائص المكانية من خرائط السكالوغرام، وقدرتها على تحقيق دقة عالية عند توفر بيانات كافية للتدريب.

يبين الشكل (10) منحنيات دقة التحقق (Validation Accuracy) ودالة الفقد (Loss) لنموذج CNN حيث يظهر تراجع كبير في الفاقد مقابل تزايد كبير في الدقة للتدريب مع تتالي العينات



الشكل (9) منحنيات دقة التحقق (Validation Accuracy) ودالة الفقد (Loss) لنموذج CNN

3.4. مناقشة النتائج:

أولاً: تفوق نموذج CNN

حقق النموذج الأصلي CNN دقة عالية بلغت 96.0% على مجموعة الاختبار النهائية، وهو تحسن كبير مقارنة بالدقة الأولية البالغة 60%، مما يبرز الأثر الحاسم لحجم وجودة البيانات في أداء نماذج التعلم العميق. تؤكد النتائج أن بنية CNN مناسبة جدًا لتحليل خرائط السكالوغرام نظرًا لقدرتها على تمييز الأنماط المكانية والترددية المرتبطة بأنواع الأعطال المختلفة، أما الأخطاء القليلة (صورتان من أصل خمسين) فكانت بين فئات متقاربة في الخصائص مثل التمييز بين درجات تآكل المحامل أو تسرب الأختام، وهو ما يشير إلى وجود صعوبة طفيفة في الفصل بين الحالات المتشابهة جدًا من حيث الطابع الطيفي.

ثانيًا: محدودية النماذج الأخرى (LSTM ، والهجين CNN-LSTM)

على الرغم من الافتراض النظري بأن دمج LSTM قد يحسن القدرة على التقاط الأنماط الزمنية في الإشارات، فإن التجارب الأولية على مجموعات صغيرة أظهرت أداءً ضعيفًا للغاية لكلا النموذجين (LSTM و CNN-LSTM) يُعزى هذا الضعف إلى أن النماذج العميقة المعقدة تتطلب كميات ضخمة من البيانات لتعلم الأنماط الدقيقة وتعميمها، وفي حال نقص البيانات لا تتمكن من استخلاص خصائص ذات معنى، بل قد تتعرض لفرط التكيف أو الفشل في التعلم. من هذا المنطلق، كان التركيز على النموذج الأبسط والأكثر استقرارًا (CNN) خيارًا منطقيًا من حيث الكفاءة الحسابية والفاعلية التحليلية.

تُظهر النتائج أن الشبكات الالتفافية CNN هي البنية الأكثر كفاءة وموثوقية في تصنيف أعطال المضخات الترددية باستخدام خرائط السكالوغرام، خصوصًا عند توفر بيانات تدريب كافية ومثثلة لمختلف الحالات التشغيلية. أما النماذج الهجينة أو الزمنية فقد تُظهر تفوقًا محتملاً في دراسات مستقبلية إذا تم دعمها ببيانات أكبر وأكثر تنوعًا.

5. الاستنتاجات:

تضمن البحث في شقه العملي تطوير إطار تجريبي ذكي يستند إلى النمذجة الرياضية وتوليد البيانات الاصطناعية وتحليل الإشارات المتقدمة باستخدام تحويل الموجات المستمر (CWT)، وصولاً إلى بناء نماذج تعلم عميق قادرة على التمييز بين الحالات السليمة وأشكال الأعطال المختلفة في المضخة الترددية الثلاثية.

تم اختبار ثلاثة نماذج رئيسية ضمن هذا الإطار، هي: الشبكة العصبية الالتفافية (CNN)، وشبكة الذاكرة الطويلة والقصيرة (LSTM)، والنموذج الهجين (CNN-LSTM) الذي يدمج بين قدرات التحليل المكاني والتتابعي.

أظهرت النتائج، بعد سلسلة من التجارب متعددة المراحل على بيانات محاكية بلغ عددها أكثر من 500 عينة سكالوغرام مولدة ضمن بيئة رقمية مضبوطة أُضيفت إليها مستويات مدروسة من الضجيج لتعزيز الواقعية، أن النموذج CNN كان الأكثر كفاءة واستقرارًا بين النماذج الثلاثة.

حقق النموذج دقة تصنيف بلغت 96.0% على مجموعة الاختبار الموحدة (50 صورة موزعة على 10 فئات تمثل أعطالاً متنوعة)، مع معدل فقد منخفض واستقرار ملحوظ في منحنيات التدريب والتحقق المتبادل، ما يؤكد قدرته العالية على استخراج السمات المكانية والترددية الدقيقة من صور السكالوغرام الناتجة عن تحويل الموجات.

وقد تميز النموذج بقدرته على التعرف على الفروق الدقيقة بين الأعطال ذات الأنماط المتقاربة؛ مثل تسرب الأختام الجزئي مقابل التآكل الميكانيكي للمحامل – بفضل تعلمه التمثيلات الهرمية للخصائص في الطبقات الالتفافية.

أما النموذجان LSTM و CNN-LSTM، فقد أظهرتا أداءً محدودًا في المراحل الأولية من التدريب على مجموعات صغيرة (50–100 عينة فقط)، حيث لم تتجاوز دقة التنبؤ 10%، نتيجة لافتقارها إلى بيانات كافية لتعلم الأنماط الزمنية المعقدة المتداخلة في الإشارات الاصطناعية، وقد تم رصد ظاهرة التقارب البطيء والتشتت العالي في منحنيات الأداء، مما أشار إلى عدم استقرار عملية التعلم ضمن هذه الحدود التجريبية.

تدل هذه النتائج على أن النماذج الالتفافية أكثر ملاءمة من النماذج الزمنية أو الهجينة عند التعامل مع بيانات مصورة مشتقة من تحويلات موجية، خصوصًا في المراحل المبكرة من تطوير أنظمة تشخيص الأعطال المعتمدة على بيانات محاكاة، ومع ذلك، يوصى بإعادة تقييم النماذج الهجينة عند توافر بيانات حقيقية موسعة، إذ يُتوقع أن تحقق أداءً تفوقيًا في تتبع الأنماط الديناميكية طويلة المدى التي لا يمكن التقاطها بالتحليل المكاني وحده.

أكدت التجارب التي أجريت على النماذج أن الجمع بين المعالجة الرقمية للإشارات وتقنيات التعلم العميق يمثل توجّهًا فعالًا نحو بناء أنظمة ذكية ذات قدرات كشف مبكر وتنبؤ عالي الدقة بالأعطال في المعدات الصناعية المعقدة.

ويبرز البحث قيمة المنهج المعتمد في سد الفجوة القائمة بين النمذجة الفيزيائية والتحليل المعتمد على البيانات، مما يفتح المجال لتطبيقات أوسع في الصيانة التنبؤية والتحول الرقمي للقطاع الصناعي، خصوصًا في بيئات التشغيل الحساسة كمرافق النفط والغاز والطاقة.

6 التوصيات والأعمال المستقبلية:

- في ضوء النتائج المتحصل عليها، يمكن اقتراح عدد من التوجهات المستقبلية لتوسيع نطاق البحث وتطوير النظام المقترح:
1. توسيع قاعدة البيانات بجمع بيانات اهتزاز إضافية من مضخات ترددية واقعية تشمل أنواعًا متعددة من الأعطال وتحت ظروف تشغيل مختلفة، لزيادة قدرة النماذج على التعميم وتحسين أدائها عند التطبيق العملي.
 2. استكشاف بنى أعمق من CNN من خلال دراسة تطبيق هياكل أكثر تطورًا من الشبكات الالتفافية، أو الاستفادة من التعلم بالنقل باستخدام شبكات مدربة مسبقًا على مجموعات بيانات ضخمة لتحسين دقة التصنيف وسرعة التدريب وذلك عند توفر موارد حاسوبية عالية كالمخدمات عالية السرعة.
 3. تحسين أداء النماذج الهجينة وإعادة تقييم النموذج الهجين CNN-LSTM أو تطوير بنى هجينة جديدة تجمع بين قدرات التعلم المكاني والزمني لاستثمار ميزات كلا النهجين، في حال توفر كميات أكبر من البيانات.
 4. دمج أنواع بيانات إضافية من خلال توسيع النظام ليشمل بيانات من مستشعرات أخرى مثل الضغط أو درجة الحرارة إلى جانب الاهتزاز، لبناء نظام تشخيص أكثر شمولية وموثوقية.
 5. التطبيق العملي في بيئة صناعية بتطوير واجهة استخدام أو نظام مراقبة فوري يعتمد على النموذج المدرب لتطبيقه في خطوط الإنتاج الفعلية أو بيانات الضخ الميدانية، بما يتيح تشخيص الأعطال آليًا في الوقت الحقيقي.
- ختاماً يبرهن هذا العمل على أن التكامل بين التحليل المويجي المستمر والشبكات الالتفافية العميقة يعطي نهجًا فعالاً لتشخيص أعطال المضخات الترددية، ويُعد خطوة أساسية نحو تطوير أنظمة صيانة تنبؤية ذاتية (Pelella et al., 2025) ذكية تسهم في تعزيز الكفاءة التشغيلية وتقليل التكاليف في القطاعات الصناعية الحيوية.

جدول (5) المصطلحات والاختصارات العلمية الواردة في البحث

الرمز / المصطلح	التعريف المختصر
CWT	التحويل المويجي المستمر لتحليل الإشارات غير الثابتة زمنياً
Scalograms	CWT تمثيل طيفي زمني ثنائي الأبعاد ناتج من
LSTM	شبكة ذاكرة طويلة المدى لتعلم الأنماط الزمنية
CNN	شبكة عصبية تلافيفية لتحليل الصور أو الخرائط الموجية

7. المراجع:

- Al-Jumaili, M. H. F., & Jabbar, M. A. (2020). *Modelling and simulation of reciprocating pump for fault diagnosis based on artificial neural networks. Journal of Engineering Science and Technology, 15*(5), 3432–3449.
- Becker, V. (2022). *Current-based techniques for condition monitoring of pumps* [Doctoral dissertation, Universitat Politècnica de València].
- Chen, L., Zhang, Z., & Qi, T. (2024). *A fault diagnosis approach for triplex pump based on digital twin and ensemble learning. In Proceedings of the 2024 7th International Conference on Energy, Electrical and Power Engineering (CEEPE)* (pp. 469–476). IEEE.
- Du, J., Wang, S., & Zhang, H. (2013). *Layered clustering multi-fault diagnosis for hydraulic piston pump. Mechanical Systems and Signal Processing, 36*(2), 487–504.
- Dutta, N., Kaliannan, P., & Paramasivam, S. (2022). *A comprehensive review on fault detection and analysis in the pumping system. International Journal of Ambient Energy, 43*(1), 6878–6898.
- He, Q., Zhang, X., & Liu, T. (2017). *Fault diagnosis of a reciprocating pump using vibration signal analysis and manifold learning. Mechanical Systems and Signal Processing, 86*, 15–28.
- Hochreiter, S., & Schmidhuber, J. (1997). *Long short-term memory. Neural Computation, 9*(8), 1735–1780.
- Jamil, S. S., & Azami, A. (2021). *Dynamic modeling of a reciprocating pump for fault detection and diagnosis. International Journal of Automation and Computing, 18*(2), 297–308.
- Jardine, A. K. S., Lin, D., & Banjevic, D. (2006). *A review on machinery diagnostics and prognostics implementing condition-based maintenance. Mechanical Systems and Signal Processing, 20*(7), 1483–1510.

- Kankar, P. K., Sharma, S. C., & Harsha, S. P. (2011). *Fault diagnosis of ball bearings using machine learning methods. Expert Systems with Applications*, 38(3), 2174–2182.
- Kim, C. H., Song, J. S., Joo, Y. H., & Lee, J. M. (2020). *Motor current signature analysis-based fault detection of reciprocating compressor valve. Journal of Mechanical Science and Technology*, 34(1), 27–33.
- Kim, J. S., Kim, Y. H., & Choi, S. Y. (2016). *Intelligent fault diagnosis of rotating machinery using random forest. Journal of Mechanical Science and Technology*, 30(1), 25–30.
- Kingma, D. P., & Ba, J. (2015). *Adam: A method for stochastic optimization. International Conference on Learning Representations (ICLR)*.
- Kong, F., & Chen, R. (2004). *A combined method for triplex pump fault diagnosis based on wavelet transform, fuzzy logic and neuro-networks. Mechanical Systems and Signal Processing*, 18(1), 161–168.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). *Deep learning. Nature*, 521(7553), 436–444.
- Lee, H. L., Lin, M. T., & Chen, C. Y. (2021). *Fault diagnosis of induction motor based on continuous wavelet transform and deep learning. Journal of Engineering Science and Technology Review*, 14(3), 219–226.
- Lee, Y. S., & Kim, J. K. (2017). *Feature extraction and classification of fault signals using multi-scale analysis and deep belief network. Expert Systems with Applications*, 84, 1–13.
- Lebbe, L., Mahauden, M., & De Breuck, W. (1992). *Execution of a triple pumping test and interpretation by an inverse numerical model. Applied Hydrogeology*, 1(4), 20–34.
- Lei, Y., Yang, B., Jiang, X., Li, N., & Li, M. (2020). *Applications of deep learning in rotating machinery fault diagnosis: A review. Mechanical Systems and Signal Processing*, 137, 106400.
- Li, Y., Ma, G., Chen, B., & Li, M. (2020). *Rolling bearing fault diagnosis based on multi-scale feature fusion and improved LSTM neural network. Applied Soft Computing*, 97, 106771.
- Ma, W., Ma, S., Zou, Z., Fu, B., Ma, J., Liu, J., & Zhang, Q. (2025). *Literature review on fault mechanism analysis and diagnosis methods for main pump systems. Machines*, 13(11), 1000.
- Mao, R., Wang, X., & Li, Y. (2018). *Fault diagnosis of rolling bearing based on continuous wavelet transform and convolutional neural network. Sensors*, 18(9), 2977.

- Mello, L. H. S., Ribeiro, M. P., Santos, T. O., Varejão, F. M., & Rodrigues, A. L. (2020). *Metric learning for electrical submersible pump fault diagnosis*. In *2020 International Joint Conference on Neural Networks (IJCNN)* (pp. 1–8). IEEE.
- Pelella, F., Passarelli, A. F., Llopis-Mengual, B., Viscito, L., Navarro-Peris, E., & Mauro, A. W. (2025). *State-of-the-art methodologies for self-fault detection, diagnosis and evaluation (FDDE) in residential heat pumps*. *Energies*, 18(13), 3286.
- Powers, D. M. W. (2011). *Evaluation: From precision, recall and F-measure to ROC, informedness, markedness and correlation*. *Journal of Machine Learning Technologies*, 2(1), 37–63.
- Szczepański, P., & Kijak, R. (2023). *The complete set of distinguishable diagnostic states for a centrifugal pump system*. *Problemy Mechatroniki*, 14(1), 35–45.
- Sun, Y., Wang, C., Wu, W., & Yu, C. (2018). *Fault diagnosis of rolling bearing based on XGBoost algorithm*. *IOP Conference Series: Materials Science and Engineering*, 392(5), 052028.
- Torrence, C., & Compo, G. P. (1998). *A practical guide to wavelet analysis*. *Bulletin of the American Meteorological Society*, 79(1), 61–78.
- Wang, J., & Hu, H. (2006). *Vibration-based fault diagnosis of pump using fuzzy technique*. *Measurement*, 39(2), 176–185.
- Wu, D., Ni, K., Guo, Z., & Dong, H. (2020). *Fault diagnosis of reciprocating pump based on vibration and acoustic signal feature fusion*. *Journal of Sound and Vibration*, 464, 114945.
- Yang, Y., Xiang, S., & Wang, Y. (2019). *Remaining useful life prediction of rolling bearings based on deep convolutional generative adversarial network and deep belief network*. *Reliability Engineering & System Safety*, 182, 1–13.
- Yang, Z., Jiang, M., & Wang, Y. (2021). *Reciprocating pump fault diagnosis based on improved convolutional neural network and transfer learning*. *Sensors*, 21(21), 7310.
- Zaki, A. B. M., Abdullah, S. N., & Hassan, S. A. (2021). *Predictive maintenance strategy for industrial pump based on vibration analysis*. *IOP Conference Series: Materials Science and Engineering*, 1198(1), 012004.
- Zhang, C., Zhang, P., & Li, X. (2023). *A review on deep learning for fault diagnosis of rotating machinery*. *Mechanical Systems and Signal Processing*, 183, 109618.

- Zhang, H., & Li, C. (2018). *Fault diagnosis of reciprocating pump based on pressure signal and empirical mode decomposition*. *Measurement*, 114, 466–474.
- Zhang, Y., Li, P., & Zhang, W. (2023). *Deep learning-based condition monitoring for mechanical systems using TensorFlow and Keras: A practical framework*. *IEEE Access*, 11, 67850–67863.
- Zhao, J., Liang, D., Lin, P., & Qu, S. (2021). *Research on fault diagnosis of reciprocating pump based on multi-sensor information fusion*. *Measurement Science and Technology*, 32(9), 095007.
- Zhu, Z., Lu, G., Ma, J., & Gu, D. (2019). *Fault diagnosis of reciprocating compressor based on multi-feature fusion and deep belief network*. *Applied Thermal Engineering*, 148, 883–893.

رؤية السعودية 2030. (2016). وثيقة مجلس الشؤون الاقتصادية والتنمية. المملكة العربية السعودية، الرياض.

وزارة الاقتصاد والتخطيط. (2022). التقرير السنوي لاقتصاد المملكة العربية السعودية 2022. وزارة الاقتصاد والتخطيط، الرياض.

Appendix A. Physical Modelling and Synthetic Data Generation Framework

A.1. Mathematical Modeling of the Triplex Reciprocating Pump

The triplex reciprocating pump model is constructed based on the conservation laws of mass and momentum within each cylinder, as well as valve dynamics. Each piston $i \in \{1,2,3\}$ is assumed to operate with a 120° phase shift to ensure nearly continuous flow.

1. Piston Kinematics:

$$x_i(t) = r \cos(\omega t + \varphi_i) + l - \sqrt{(l^2 - (r \sin(\omega t + \varphi_i))^2)}$$

2. Chamber Pressure Dynamics:

$$dP_i/dt = (\beta / V_i(t)) * (Q_{in,i} - Q_{out,i} - A_p * dx_i/dt)$$

3. Valve Flow Modeling:

$$Q_v = C_d * A_v * \sqrt{2 * |P_{up} - P_{down}| / \rho} * \text{sign}(P_{up} - P_{down})$$

4. Fault Representation:

- Seal Leakage: Modeled as a bypass orifice with variable resistance R_{leak} inversely proportional to leak severity.
- Valve Blockage: Represented by reduction of A_v by a percentage (20–80%).
- Bearing Wear: Modeled as sinusoidal fluctuation in piston velocity phase and amplitude.

A.2. Synthetic Signal Generation

Synthetic datasets were generated using the simulated time-domain pressure and vibration signals, under both healthy and faulty conditions.

Sampling frequency $f_s = 10$ kHz, duration per sample = 1.0 s, total signals = 600 (divided into 6 fault classes + healthy).

Noise Injection:

$$y(t) = s(t) + \eta(t), \text{ where } \eta(t) \sim N(0, \sigma^2) \text{ with SNR ranging between 20–40 dB.}$$

Transformation using Morlet wavelet:

$$CWT : W(a, b) = \int s(t) \psi * ((t - b)/a) dt, \text{ producing } 224 \times 224 \text{ scalograms for CNN input.}$$

A.3. Python Implementation Overview

```
import numpy as np
import pywt
from scipy.signal import savgol_filter
def simulate_pump_signal(fault_type = 'healthy', noise_level = 0.02):
    t = np.linspace(0, 1, 10000)
    base = np.sin(2 * np.pi * 10 * t) + 0.3 * np.sin(2 * np.pi * 50 * t)
    if fault_type == 'leak':
        base *= (1 - 0.15 * np.sin(2 * np.pi * 2 * t))
    elif fault_type == 'valve_block':
        base += 0.2 * np.sin(2 * np.pi * 70 * t)
    noise = np.random.normal(0, noise_level, len(t))
    return savgol_filter(base + noise, 51, 3)
signal = simulate_pump_signal('leak', 0.03)
coeffs, freqs = pywt.cwt(signal, scales = np.arange(1, 128), wavelet = 'morl')
```

Appendix B. Neural Network Architecture and Training Parameters

B.1. Overview

This appendix details the deep learning architectures used for the classification of reciprocating pump fault conditions. Three models were evaluated: a Convolutional Neural Network (CNN), a Long Short-Term Memory network (LSTM), and a hybrid CNN–LSTM model combining spatial and temporal learning capabilities.

B.2. CNN Architecture

The CNN model was designed to process 2D scalogram images of size $224 \times 224 \times 3$ generated from the Continuous Wavelet Transform (CWT). It consists of four convolutional blocks followed by fully connected layers and a softmax output layer.

Layer Configuration:

- Input Layer: $224 \times 224 \times 3$ (Scalogram images)
- Conv2D (32 filters, 3×3 kernel, ReLU activation)
- MaxPooling2D (2×2)
- Conv2D (64 filters, 3×3 kernel, ReLU activation)
- MaxPooling2D (2×2)
- Conv2D (128 filters, 3×3 kernel, ReLU activation)
- Flatten
- Dense (128 neurons, ReLU)
- Dropout (0.5)
- Output Layer: Dense (7 neurons, Softmax)

B.3. LSTM Architecture

The LSTM network was used for time-sequence representations derived from vibration signals directly. It consisted of one or two stacked LSTM layers followed by dense layers for classification.

Layer Configuration:

- Input: Sequential signal data (10000 time steps)
- LSTM Layer (64 units)
- Dropout (0.3)
- Dense (64 neurons, ReLU)
- Output Layer: Dense (7 neurons, Softmax)

B.4. Hybrid CNN–LSTM Model

The hybrid CNN–LSTM model combines spatial feature extraction from scalograms (via CNN) and temporal dependency learning (via LSTM). The CNN layers extract key spatial-frequency features, which are then flattened and reshaped into sequences to feed into the LSTM layer.

Layer Configuration:

- CNN feature extractor: same as CNN above (up to Flatten)
- Reshape to (timesteps, features)

- LSTM (64 units)
- Dense (128 neurons, ReLU)
- Dropout (0.5)
- Output Layer: Dense (7 neurons, Softmax)

B.5. Training Parameters

All models were trained using the same hyperparameters to ensure fair comparison:

- Optimizer: Adam
- Learning Rate: 0.001
- Batch Size: 32
- Epochs: 100
- Loss Function: Categorical Cross-Entropy
- Validation Split: 20%
- Early Stopping: Enabled (patience=10)

B.6. Evaluation Metrics

The following statistical metrics were used to evaluate model performance:

1. Accuracy: $(TP + TN) / (TP + TN + FP + FN)$
2. Precision: $TP / (TP + FP)$
3. Recall: $TP / (TP + FN)$
4. F1-Score: $2 \times (Precision \times Recall) / (Precision + Recall)$
5. Confusion Matrix: Visual comparison of predicted vs actual classes.

جميع الحقوق محفوظة © 2025، الباحث/ مريسي سعيد مريسي الغامدي، المجلة الأكاديمية للأبحاث والنشر العلمي

(CC BY NC)

Doi: <http://doi.org/10.52132/Ajrsp/v7.80.10>