



تصميم وتنفيذ نظام تحكم ذكي بالماتلاب

لمطحنة فحم

بحث تكميلي لنيل درجة البكالوريوس مرتبة الشرف في الهندسة الكهربائية

إعداد:

1- محمد إبراهيم محبوب محمد

2- محمد صالح يحي محمد إدريس

3- محي الدين يوسف محمد المبارك

كلية الهندسة

جامعة الشيخ عبد الله البدرى

أبريل 2026



﴿فَتَعَالَى اللَّهُ الْمَلِكُ الْحَقُّ وَلَا تَعْجَلْ بِالْقُرْآنِ مِنْ قَبْلِ أَنْ يُقْضَىٰ إِلَيْكَ وَحْيُهُ
وَقُلْ رَبِّ زِدْنِي عِلْمًا﴾

صدق الله العظيم

[سورة طه: 114]

المُستخلص

يتناول هذا البحث - عبر بيئة الماتلاب البرمجية - التحكم الذكي لمطحنة فحم؛ وذلك لأهمية مطاحن الفحم في الصناعات الثقيلة وصناعة الطاقة، والمشكلة في أنظمة التحكم الصناعية التقليدية لا يتم فيها التشخيص المبكر للأعطال، وعدم الدقة المثالية في التقييم، وسوء التقدير، والأخطاء البشرية. كما أن اكتشاف حالات عدم الاستقرار والتنبؤ بالأنماط المتكررة يمثل سمة من سمات الحدود البشرية.

نسبة للعامل البشري في أنظمة التحكم الصناعية التقليدية، تم تصميم نموذج ذكي لشبكة عصبية لا خطية ذات انحدار ذاتي للتنبؤ بسلوك الاهتزاز الميكانيكي. بناءً على المنهج التحليلي تم إنشاء قاعدة بيانات للسلاسل الزمنية التي تضم 3,000 عينة حقيقية والتي تم جمعها من تشغيل مطحنة فحم تعمل بمصنع أسمنت بربر، استخدمت لتدريب واختبار النموذج لضمان واقعية النتائج.

تم التنبؤ بصورة دقيقة بسلوك الاهتزاز الميكانيكي علي مستوي نموذج الشبكة العصبية لأنه مؤشر حيوي مرتبط مباشرة بالاستقرار وكافة معلمات التشغيل، مثل معدل تغذية المطحنة في الساعة، ودرجة حرارة مخرج المطحنة، وفرق الضغط التفاضلي كمؤشر رئيسي لدرجة الملء الحالية بالنسبة للقيمة الاسمية، وغيرها من معلمات التشغيل.

وُجِدَ أن متوسط مربع الخطأ وصل إلى 0.007 خلال 11 تكراراً فقط، مقترناً بوقوع جميع ارتباطات الأخطاء ضمن حدود الثقة، مما مثل دليلاً دامغاً على قدرة النموذج على استيعاب العلاقات غير الخطية والديناميكية المعقدة الكامنة في بيانات التشغيل الصناعية.

Abstract

This research addresses –via the matlab software environment– the intelligent control of a coal mill; due to the importance of coal mills in heavy industries and the energy industry, and the problem in traditional industrial control systems where early fault diagnosis is not performed, non–ideal precision in evaluation, poor estimation occurs, and human errors exist. Additionally, the detection of instability conditions and the prediction of recurring patterns represent a characteristic of human limitations.

Due to the human factor in traditional industrial control systems, an intelligent model of a Nonlinear Autoregressive Neural Network with Exogenous Inputs was designed to predict mechanical vibration behavior. Based on the analytical methodology, a time–series database comprising 3,000 real samples was created, which were collected from the operation of a coal mill operating at Berber Cement Factory, and used for training and testing the model to ensure the realism of the results.

Mechanical vibration behavior was accurately predicted at the level of the neural network model because it is a vital indicator directly linked to stability and all operating parameters, such as the mill feed rate per hour, mill outlet temperature, differential pressure as a prim indicator of the actual filling degree relative to nominal value, and other operating parameters.

It was found that the mean square error reached 0.007 within only 11 iterations, coupled with the positioning of all error correlations within the confidence limits, representing conclusive evidence of the model's ability to capture the complex nonlinear and dynamic relationships inherent in industrial operational data.

إِهْدَاء

إلى روح أبي ألف رحمة ونور...

يا من علّمتني كيف أقف فوق الأرض بكل ثبات

إلى أمي الحنونة...

لا أجد كلمات يمكن أن تمنحك حقلك، فأنت ملحمة الحب والعطاء وفرحة العمر

إلى زوجتي...

أسمى رموز الإخلاص والوفاء رفيقة الدرب

شكر وعرفان

الشكر والثناء لله عز وجل أولاً على نعمة الصبر والمثابرة والقدرة على إنجاز هذا العمل،
فلله الحمد على هذه النعم...

وأقدم بالشكر والتقدير إلى أستاذي: إبراهيم أحمد، الذي تفضل بإشرافه على هذا
البحث، ولكل ما قدمه من دعم وتوجيه وإرشاد؛ لإتمام هذا العمل على ما هو عليه فله
أسمى عبارات الشكر والتقدير...

كما أتقدم بأسمى آيات الشكر والتقدير لأساتذة قسم الكهرباء الأجلاء، وذلك لما بذلوه
من وقت وجهد؛ فجزاهم الله عنا خير الجزاء، وجعل عملهم في ميزان حسناتهم...

كما أتوجه بالشكر لكل من ساعدني من قريب أو بعيد؛ ولو بكلمة أو دعوة صالحة...

فهرست المحتويات

i	الآية
ii	المُسْتَخْلَص
iii	Abstract
iv	الإهداء
v	الشكر والعرفان
vi	فهرست المحتويات
viii	فهرست الأشكال
1	الفصل الأول
1	المقدمة
2	1-1 مقدمة الفصل
2	1-2 مدخل:
3	1-3 مشكلة البحث
4	1-4 أهمية البحث
4	1-5 أهداف البحث
4	1-6 منهجية البحث
5	1-7 هيكلية البحث
8	الفصل الثاني
8	الإطار النظري
9	2-1 مقدمة الفصل
9	2-2 أهمية الفحم الحجري والبترولي
10	2-3 الدراسات السابقة
13	الفصل الثالث
13	تصميم النموذج
14	3-1 مقدمة الفصل:
14	3-2 المعلومات الأساسية المستخدمة في النموذج
14	3-3 الأداة البرمجية

22.....	التصميم الهندسي:	3-4
22.....	الأجزاء الرئيسية:	3-5
23.....	آلية التشغيل وتدفق المواد/ والغازات:	3-6
26.....	الفصل الرابع	
26.....	النتائج والمناقشة	
27.....	مقدمة الفصل	4-1
27.....	تدريب وتقييم النموذج	4-2
33.....	مناقشة النتائج	4-3
35.....	الباب الخامس	
35.....	الخاتمة والتوصيات	
36.....	مقدمة الفصل	5-1
36.....	الخاتمة	5-2
36.....	التوصيات	5-3
38.....	المراجع	

فهرست الأشكال

15	شكل رقم [3-1]
16	شكل رقم [3-2]
18	شكل رقم [3-3]
19	شكل رقم [3-4]
19	شكل رقم [3-5]
20	شكل رقم [3-6]
21	شكل رقم [3-7]
28	شكل رقم [3-8]
29	شكل رقم [3-9]
30	شكل رقم [3-10]
31	شكل رقم [3-11]
32	شكل رقم [3-12]
33	شكل رقم [3-13]

الاختصارات

1. AI – Artificial Intelligence
2. NARX – Non liner Auto Regressive eXogenous inputs
3. L – Layer
4. d – delay
5. LM – Levenberg Marquardt
6. MSE – Mean Squar Error
7. R– Relation Factor
8. VRM – Vertical Roller Mill
9. PBM – Population Balance Model
10. RTD – Resident Time Duration
11. PID – Proportional Integral Derivative
12. ANN – Artificial Neural Network
13. NTStool – Neural Time Series
14. APPs – Applications

15. DCS – Distributed Control System
16. GHI – Graphical Human Interface

الفصل الأول

المقدمة

1-1 مقدمة الفصل

يحتوي هذا الفصل على الإطار العام للبحث، حيث يبدأ بمدخل حول أهمية أنظمة التحكم وتطورها، ثم يستعرض مفاهيم التحكم الكلاسيكي والذكاء الاصطناعي والشبكات العصبية. كما يحدد هذا الفصل مشكلة البحث المتمثلة في قصور الأنظمة التقليدية في التنبؤ بالأعطال، ويبرز أهمية البحث وأهدافه ومنهجيته والوسائل والأدوات المستخدمة في البحث.

2-1 مدخل:

تُعد أنظمة التحكم ركيزة أساسية في تطور الحياة المعاصرة، حيث تُصمم هذه الأنظمة لأداء مهام محددة بدقة عالية، وبتوازن نسبي، وسرعة استجابة فائقة، تلعب أنظمة التحكم دورًا حيويًا في تحسين جودة الأداء البشري والتقني من خلال الوصول إلى نظام تحكم أمثل للغرض المحدد المقصود، مما يساهم في تقليل استهلاك الطاقة ووضع شروط دقيقة لأداء العمل في مختلف المجالات، تاريخيًا تطورت أنظمة التحكم من الأساليب الكلاسيكية التي تعتمد على التحليل الرياضي وتصميم المتحكمات، حيث يركز المهندس على تحديد قيم الثوابت لتقليل الخطأ في الحالة المستقرة وتحديد التردد الطبيعي ونسبة التخميد لضمان استقرار النظام وسرعة استجابته، ومع ذلك قد تتطلب هذه الأساليب قيمًا عددية محددة بدقة، تكون مكلفة إذا كانت الشروط صارمة للغاية [1]

مع تطور الحاجة إلى أنظمة أكثر مرونة، ظهر الذكاء الاصطناعي (AI) كعلم يهدف إلى بناء آلات قادرة على القيام بالمهام التي تتطلب ذكاءً بشريًا؛ بدأ الذكاء الاصطناعي رسميًا في الخمسينيات، يهدف إلى حل المشكلات المعقدة التي يصعب حلها باستخدام البرمجة التقليدية أو التحكم الكلاسيكي؛ وقد استخدم في مجالات عامة مثل الإدراك والتعليل المنطقي، ومجالات خاصة مثل التشخيص الطبي ولعب الشطرنج والتحكم البسيط في البيئات الصناعية،

من بين فروع الذكاء الاصطناعي، برز المنطق الضبابي (Fuzzy Logic) كحل لمعالجة قصور الحاسب الآلي في التعامل مع المصطلحات النسبية التي نستخدمها في حياتنا اليومية، مثل "حار جدًا" أو "قريب"، حيث أن الحياة ليست دائمًا أرقامًا دقيقة كما يتعامل معها الحاسب التقليدي. وقد استخدمت متحكمات بسيطة مبنية على المنطق الضبابي في بداياتها في فرامل القطارات وبعض الأجهزة المنزلية مثل الغسالات الكهربائية ومكيفات الهواء.

تُعد الشبكات العصبية الاصطناعية (Artificial Neural Networks) ذروة محاكاة العقل البشري، وهي عبارة عن نماذج مبنية على خوارزميات مصممة لمحاكاة الطريقة التي يؤدي بها العقل البشري مهام معينة. تتكون من وحدات معالجة بسيطة موزعة على التوازي، وتعتمد في عملها على ضبط "الأوزان" لتخزين وتحليل وتمييز الأنماط والتنبؤ؛ تتعلم الشبكات العصبية تلقائيًا إنشاء نماذج تعمل على ضبط البيانات، أو تصنيفها، أو تمييز النمط السائد، أو التنبؤ دون الحاجة إلى استخدام معادلات رياضية أو أدوات تحليل إحصائي، فتصبح قادرة على إعطاء إجابات صحيحة دون كتابة برنامج ضخم لكل حالة جديدة [2]. تشمل طرق التعليم؛ التعلم بإشراف (Supervised Learning) فيه تُعرض المدخلات مع مخرجاتها الصحيحة، والتعلم بدون إشراف (Unsupervised Learning) فيه تُعرض المدخلات بدون مخرجات.

1-3 مشكلة البحث

تتكون غالبية أنظمة التحكم الصناعي من جزء خاص بالعتاد (Hardware) وجزء خاص بالبرمجيات (Software)، بالإضافة إلى واجهة للتحكم البشري (Human Interface). ومع ذلك، تواجه هذه الأنظمة تحديات كبيرة تتمثل في بطء التشخيص المبكر للأعطال، وعدم الدقة المثالية في التقييم، وسوء التقدير، والأخطاء البشرية. كما أن اكتشاف حالات عدم الاستقرار والتنبؤ بالأنماط المتكررة يمثل سمة من سمات القيود البشرية، يمكن أن تؤدي هذه المشكلات إلى توقفات غير متوقعة، وتدهور في جودة المنتج، وزيادة

تكلفة الصيانة، لذلك برزت الحاجة إلى تطوير نظام تحكم ذكي قادر على التنبؤ بسلوك مطحنة الفحم بدقة وفعالية، بالاعتماد على الاهتزازات الميكانيكية التي تُعد مؤشرًا رئيسيًا لأغلبية الأعطال المحتملة.

1-4 أهمية البحث

يهدف هذا البحث إلى تقليل الاهتزازات الميكانيكية وعدم استقرار النظام، وتحسين كفاءة تشغيل مطحنة الفحم. ولتحقيق ذلك اخترنا أن نصمم وننفذ نظام تحكم ذكي افتراضي على مستوى شبكة عصبية لا خطية ذاتية الانحدار بمدخلات خارجية (NARX) في بيئة الماتلاب البرمجية تكمن أهمية هذا النهج في قدرته على حل مشكلة السلاسل الزمنية غير الخطية في بيانات التشغيل، مما يوفر تنبؤات دقيقة لسلوك المطحنة.

1-5 أهداف البحث

يسعى هذا البحث إلى تحقيق الأهداف التالية:

1-5-1 تصميم نموذج ذكي باستخدام شبكة عصبية من نوع السلاسل الزمنية للتنبؤ بسلوك مطحنة

فحم عمودية من طراز (Pfeiffer MPS 250 BK) وهي الموضوع الرئيسي للبحث.

1-5-2 دراسة تأثير المتغيرات المختلفة على الاهتزاز الميكانيكي داخل المطحنة.

1-5-3 تقييم دقة النموذج إحصائيًا باستخدام مقاييس الأداء المناسبة.

1-6 منهجية البحث

اعتمدت منهجية هذا البحث بشكل أساسي على المنهج التطبيقي حيث لم نكتفي ببناء نموذج الشبكة العصبية بل أُخْبِرَتْ كفاءته في التنبؤ بالاهتزازات الميكانيكية، وبشكل جزئي على المنهج التجريبي لأن بناء الشبكة العصبية بحد ذاته هو تجربة علمية تخضع للملاحظة والقياس، وبشكل جزئي على المنهج الوصفي التحليلي في مرحلة وصف طبيعة البيانات، ومقارنة النتائج.

تم اتباع عدة خطوات متسلسلة كالآتي:

1-6-1 تم جمع 3,000 عينة حقيقية؛ مستمدة من تشغيل مطحنة فحم بمصنع أسمنت بربر.

2-6-1 استخدمت شبكة عصبية غير خطية ذاتية الانحدار بمدخلات خارجية (NARX)

3-6-1 صممت الشبكة ب (L =5) طبقات مخفية (Hidden Layers)

4-6-1 حددت عدد فترات التأخير بمقدار (d =5) فترات لكل مدخلات النظام ومخرجاته السابقة

5-6-1 استخدمت دالة التنشيط من نوع (sigmoid) لضمان استقرار التعلم

6-6-1 قسمت البيانات الزمنية إلى 3 مجموعات % (15,15,70) تدريب، تحقق، اختبار.

7-6-1 دربت الشبكة باستخدام خوارزمية (LM) لسرعتها في التقارب في الأنظمة الهندسية

8-6-1 تم اختبار كفاءة النموذج من خلال قياس معامل الارتباط (R) ومتوسط الخطأ التربيعي

(MSE) مما أكد قدرة النموذج على استيعاب العلاقات غير الخطية والديناميكية المعقدة الكامنة في

بيانات التشغيل الصناعية.

9-6-1 بناءً على النتائج حقق نظام التحكم الذكي المقترح القائم على شبكة عصبية غير خطية

ذاتية الانحدار بمدخلات خارجية (NARX) نتائج باهرة في نمذجة الاهتزازات الميكانيكية لمطحنة

الفحم والتنبؤ بها.

7-1 هيكلية البحث

يتكون هذا البحث من خمسة فصول متكاملة لتغطية الجوانب النظرية والعملية والتحليلية لموضوع الدراسة،

وذلك وفق التسلسل التالي:

1-7-1 الفصل الأول: المقدمة

يحتوي هذا الفصل على الإطار العام للبحث، حيث يبدأ بمدخل حول أهمية أنظمة التحكم وتطورها، ثم يستعرض مفاهيم التحكم الكلاسيكي والذكاء الاصطناعي والشبكات العصبية. كما يحدد هذا الفصل مشكلة البحث المتمثلة في قصور الأنظمة التقليدية في التنبؤ بالأعطال، ويبرز أهمية البحث وأهدافه ومنهجيته والوسائل والأدوات المستخدمة في البحث.

2-7-1 الفصل الثاني: الإطار النظري

يركز هذا الفصل على الجانب المعرفي المتعلق بخام الفحم، ويستعرض أهم الدراسات السابقة التي تناولت مطاحن العجلات العمودية (VRMs) في جوانب النمذجة والتحكم والتحسين باستخدام الشبكات العصبية تحديداً، لربط البحث الحالي بالتطورات العلمية في هذا التخصص.

3-7-1 الفصل الثالث: تصميم النموذج

يشتمل هذا الفصل على تحديد المعلمات الأساسية المستخدمة في النموذج وشرح تصميم النموذج والجانب التطبيقي، مع شرح كيفية بناء نموذج التحكم الذكي باستخدام بيئة الماتلاب البرمجية، وتوضيح مراحل تصميم الشبكة العصبية من نوع (NARX)، كما يتناول هذا الفصل شرحاً مفصلاً لأجزاء مطحنة الفحم العمودية من طراز (Pfeiffer MPS 250 BK) وعملية التشغيل.

4-7-1 الفصل الرابع: النتائج والمناقشة

يستعرض هذا الفصل النتائج التي تم الحصول عليها بعد تدريب واختبار النموذج باستخدام عينة 3,000. ويتضمن تحليل دقة التنبؤ بالاهتزازات الميكانيكية، ومناقشة مدى تحقيق الأهداف المرجوة بناءً على المقاييس الإحصائية مثل متوسط الخطأ التربيعي (MSE) ومعامل الارتباط (R).

5-7-1 الفصل الخامس: الخاتمة والتوصيات

ينتج البحث بهذا الفصل الذي يلخص أهم النتائج التي توصل إليها البحث، ويقدم مجموعة من التوصيات والمقترحات العلمية والعملية لتطوير أنظمة التحكم في مطاحن الفحم مستقبلاً، ورفع كفاءة التشغيل وضمان استقرار النظام.

الفصل الثاني

الإطار النظري

2-1 مقدمة الفصل

يركز هذا الفصل على الجانب المعرفي المتعلق بخام الفحم، ويستعرض أهم الدراسات السابقة التي تناولت مطاحن العجلات العمودية (VRMs) في جوانب النمذجة والتحكم والتحسين باستخدام الشبكات العصبية تحديداً؛ لربط البحث الحالي بالتطورات العلمية في هذا التخصص.

2-2 أهمية الفحم الحجري والبترولي

يُعد الفحم الحجري والفحم البترولي من أهم مصادر الطاقة والمواد الخام في الصناعات الثقيلة الحديثة، على الرغم من تشابههما في المظهر الخارجي واللون الداكن، إلا أنهما يختلفان جذرياً من حيث المنشأ والتركيب الكيميائي ومجالات الاستخدام.

1-5-4 الفحم الحجري (Coal)

الفحم الحجري هو صخر رسوبي أسود أو بني اللون قابل للاشتعال، يتكون أساساً من عنصر الكربون بالإضافة إلى نسب متفاوتة من الهيدروجين، الكبريت، الأكسجين، والنيروجين؛ يتشكل الفحم الحجري طبيعياً عبر ملايين السنين نتيجة لتحلل بقايا النباتات الميتة في بيئات المستنقعات، حيث تتحول أولاً إلى مادة "الخث" (Peat)، ثم تتعرض لضغط وحرارة شديدين في طبقات الأرض العميقة لتتحول تدريجياً إلى فحم حجري [3].

2-2-1 الفحم البترولي (Petroleum Coke)

الفحم البترولي، المعروف اختصاراً باسم (Pet-coke)، هو مادة صلبة غنية جداً بالكربون، تُنتج كمنتج ثانوي (By-product) خلال عملية تكرير النفط الخام، وتحديداً في وحدات التكسير الحراري. يتميز الفحم البترولي بمحتواه الكربوني العالي جداً وانخفاض نسبة الرماد مقارنة بالفحم الحجري [4].

2-3 الدراسات السابقة

تُعتبر الدراسات السابقة ركيزة أساسية لأي بحث علمي، حيث توفر الإطار المعرفي وتساعد على تحديد الفجوات البحثية. في هذا السياق، تم استعراض عدد من الدراسات التي تناولت نمذجة ومحاكاة مطاحن الفحم، بالإضافة إلى تطبيقات الشبكات العصبية في التنبؤ والتحكم.

2-3-1 نمذجة ومحاكاة مطحنة العجلات العمودية (VRM).

أجرى كيانوش باراني ورسول فتاحي [5] دراسة حول نمذجة ومحاكاة مطحنة العجلات العمودية (VRM)، مشيرين إلى قلة الدراسات المتعلقة بعمليات محاكاة هذه المطاحن. في بحثهم استقصوا تطبيق نموذج توازن المجموعات (PBM) لمحاكاة مطحنة VRM في دائرة طحن كلنكر الأسمنت. قاموا بقياس توزيع زمن المكوث (RTD) واستخدموا نماذج الخزانات المتسلسلة ونموذج ويلر لوصف توزيع زمن البقاء. أظهرت النتائج أن جزيئات الكلنكر تقضي وقتاً قصيراً داخل مطحنة VRM، بمتوسط زمن مكوث يبلغ حوالي 67 ثانية. كما وجدوا أن نموذج الخزانات المتسلسلة كان أكثر ملاءمة لوصف توزيعات زمن البقاء في مطحنة VRM مقارنة بنموذج ويلر. وأشارت نتائج المحاكاة إلى أن معدلات الكسر النوعي تزداد مع زيادة حجم الجزيئات، وأن عملية الطحن في مطحنة VRM قابلة للتنبؤ بشكل جيد باستخدام نموذج توازن المجموعات.

2-3-2 نماذج التحكم في تدفق الوقود لمحطات الطاقة التي تعمل بالوقود الأحفوري

قدم بيوتر نيمتشيك [6] أطروحة دكتوراه حول نماذج التحكم في تدفق الوقود لمحطات الطاقة التي تعمل بالوقود الأحفوري. ركز البحث على تحليل الصعوبات والتحسينات المحتملة في التحكم بعملية طحن الفحم، بهدف السماح بإنتاج أكثر مرونة من هذه الوحدات. ولتحقيق ذلك، تم اشتقاق نموذج مناسب لمطحنة الفحم والتحقق من صحته. يصف النموذج دوران الفحم داخل المطحنة، تدفق الوقود،

وتوازن الحرارة. تم استخدام النموذج لاشتقاق قانون تحكم استقراري يعتمد على نظرية لياپونوف (Lyapunov theory)، والذي تبين أنه يحسن مؤشر الأداء العام. تم التحقق من المتحكم من خلال المحاكاة ومقارنته بمتحكم من نوع PID مضبوط جيداً ومستخدم في الصناعة، وأظهرت النتائج وجود تحسينات. بالإضافة إلى ذلك، تم استقصاء التحكم الإشرافي الأمثل لنظام الوقود في محطة طاقة حرارية.

2-3-3 تطبيقات الشبكات العصبية في التنبؤ بأداء مطاحن الفحم

أظهرت دراسة أجراها J. Smrekar وآخرون [7] في عام 2009 تطوير نماذج شبكات عصبية اصطناعية (ANN) لغلاية تعمل بالفحم في محطة طاقة حرارية، حيث تم تدريب الشبكات باستخدام بيانات حقيقية من المحطة. وقد شملت المعلمات المستخدمة تلك المتعلقة بمطاحن الفحم، وتدفقات الهواء والماء إلى الغلاية، مما يؤكد أهمية نمذجة مطاحن الفحم في سياق أداء محطات الطاقة.

2-3-4 في عام 2015، قام E. Oko وآخرون [8] بتطوير نموذج ديناميكي لغلاية أسطوانية باستخدام شبكات NARX العصبية للتنبؤ بضغط الأسطوانة ومستواها في محطة طاقة تعمل بالفحم. أظهرت تنبؤات النموذج توافقاً جيداً مع البيانات الفعلية، مما يسلط الضوء على فعالية شبكات NARX في نمذجة الأنظمة المعقدة في محطات الطاقة.

2-3-5 تناولت دراسة لـ V. Agrawal وآخرون [9] في عام 2015 مراجعة شاملة لطرق التحكم وتشخيص الأعطال المطبقة على مطاحن الفحم. أكدت الدراسة أن أداء الغلايات يتأثر بشكل كبير بمطاحن الفحم التي تقوم بطحن وتجفيف ونقل الفحم إلى الفرن، مشددة على الحاجة إلى تحسين طرق التحكم وتشخيص الأعطال.

6-3-2 في عام 2020، اقترح Y. Hu وآخرون [10] طريقة لتشخيص الأعطال في نظام مطحنة الفحم تعتمد على عينات أعطال نموذجية محاكاة. من خلال تحليل آلية الأعطال، تم تطوير نموذج تشخيصي فعال، مما يبرز دور تقنيات التعلم الآلي في صيانة مطاحن الفحم التنبؤية.

7-3-2 قدم Y. Jian وآخرون [11] في عام 2020 خوارزمية تعلم عميق قائمة على نموذج لتشخيص الأعطال في مطاحن الفحم، بهدف الكشف الفعال عن حالة تشغيل المطاحن. تؤكد هذه الدراسة على الاتجاه المتزايد نحو استخدام التعلم العميق لتحسين موثوقية وكفاءة مطاحن الفحم.

الفصل الثالث

تصميم النموذج

3-1 مقدمة الفصل:

يشتمل هذا الفصل على تحديد المعلومات الأساسية المستخدمة في النموذج وشرح تصميم النموذج والجانب التطبيقي، مع شرح كيفية بناء نموذج التحكم الذكي باستخدام بيئة الماتلاب البرمجية، وتوضيح مراحل تصميم الشبكة العصبية من نوع (NARX)، كما يتناول هذا الفصل شرحاً مفصلاً لأجزاء مطحنة الفحم العمودية من طراز (Pfeiffer MPS 250 BK) وعملية التشغيل.

3-2 المعلومات الأساسية المستخدمة في النموذج

- معدّل تردد جمع البيانات: ويقصد به زمن أخذ العينات الذي يساوي عينة كل دقيقة

- معدّل التغذية (Feed rate) tph

- درجة حرارة مخرج المطحنة (Out-let Temperature) C°


- فرق الضغط التفاضلي (Differential Pressure) mbar

- الاهتزاز الميكانيكي (Mechanical Vibration) mm/s

3-3 الأداة البرمجية

لتحقيق أهداف البحث في التنبؤ بسلوك مطحنة الفحم، تم استخدام بيئة الماتلاب، وتحديد أداة (NTStool). تُعد هذه الأداة جزءاً لا يتجزأ من التطبيقات (APPs) ضمن الأدوات الرياضية والإحصائية والتحسين (Math, Static And Optimization) في الماتلاب، والتي توفر بيئة شاملة لتصميم وتدريب ومحاكاة الشبكات العصبية غير الخطية المختلفة. يُعتبر الماتلاب منصة قوية للتحليل العددي والحوسبة التقنية، مما يجعله مثالي للتعامل مع الأنظمة الديناميكية غير الخطية التي تتغير خصائصها مع الزمن، مثل تدفق المواد والغازات داخل المطحنة. إن استخدام (NTStool) يسهل عملية بناء نماذج السلاسل الزمنية باستخدام


الشبكات العصبية، مما يتيح للمهندسين والباحثين التركيز على تحليل البيانات وتفسير النتائج بدلاً من التفاصيل البرمجية المعقدة كما موضح في الشكل رقم [1-3].



شكل رقم [1-3]

1-3-3 هيكلية الشبكة العصبية (Neural Network Architecture)

تم اختيار (NARX) لبناء نموذج الشبكة العصبية غير الخطية ذات الانحدار الذاتي مع مدخلات خارجية نظرًا لقدرته الفائقة على نمذجة الأنظمة الديناميكية غير الخطية. تكمن قوة هذا النموذج في قدرته على استخدام القيم السابقة للمخرجات والمدخلات للتنبؤ بالمخرجات المستقبلية مع المدخلات الحالية، وهو ما يُمثل بدقة القصور الذاتي والتأخير الزمني في الأنظمة الصناعية مثل مطاحن الفحم، الشكل رقم [2-3] يوضح الواجهة الحاسوبية لكل أنواع المشاكل غير الخطية المراد حلها بواسطة الشبكة العصبية من نوع Time Series.



شكل رقم [2-3]

يتميز نموذج (NARX) بقدرته على النقاط العلاقات المعقدة بين المتغيرات الزمنية، مما يجعله مناسباً بشكل خاص للتنبؤ بالاهتزازات لتحليل سلوك المطحنة بناءً على بيانات التشغيل السابقة كما موضح في الشكل رقم [2-3].

تم تمثيل العلاقة الرياضية للنموذج كما يلي:

$$y(t) = f(y(t-1), y(t-2), \dots, y(t-dy), x(t-1), x(t-2), \dots, x(t-dx))$$

حيث:

$y(t)$ هو مخرج الشبكة في الزمن t .

$x(t)$ هو المدخل الخارجي للشبكة في الزمن t .

dy هو عدد فترات التأخير للمخرجات.

dx هو عدد فترات التأخير للمدخلات الخارجية.


f هي دالة غير خطية يتم تقديرها بواسطة الشبكة العصبية.

2-3-3 إعداد ومعالجة البيانات (Data Processing):

تُعد جودة البيانات ومعالجتها خطوة حاسمة لضمان فعالية نموذج الشبكة العصبية. تم استيراد البيانات (المسماة في النموذج data) وتنسيقها في شكل مصفوفة زمنية مناسبة لمدخلات الشبكة العصبية. لضمان كفاءة التدريب وقدرة الشبكة على التعميم، تم تقسيم البيانات بعناية إلى ثلاث مجموعات رئيسية كما موضح في الشكل شكل رقم [3-3]

70% للتدريب (Training): تُستخدم هذه المجموعة لضبط الأوزان والارتباطات بين العصبونات داخل الشبكة. الهدف هو تعليم الشبكة التعرف على الأنماط والعلاقات في البيانات. 15% للتحقق (Validation): تُستخدم هذه المجموعة لمراقبة أداء الشبكة أثناء عملية التدريب. تساعد بيانات التحقق في تحديد متى يجب إيقاف التدريب لتجنب حالة الإفراط في المواءمة (Overfitting)، حيث تبدأ الشبكة في حفظ بيانات التدريب بدلاً من تعلم التعميم.

15% للاختبار (Testing): تُستخدم هذه المجموعة لقياس دقة النموذج النهائي على بيانات لم يسبق له رؤيتها. توفر هذه البيانات تقييماً غير متحيز لقدرة النموذج على التنبؤ بسلوك المطحنة في السيناريو الواقعي.




شكل رقم [3-3]

3-3-3 إعدادات الشبكة (Network Configuration): بناءً على المحاكاة الموضحة في الصور والتحليلات الأولية، تم تحديد المعايير التالية لإعدادات الشبكة العصبية لضمان تحقيق دقة عالية مع الحفاظ على كفاءة الحوسبة:

1-3-3-3 عدد الطبقات المخفية (Hidden Layers): تم ضبطها على 5 طبقات مخفية. هذا العدد يحقق توازنًا بين قدرة الشبكة على تعلم العلاقات المعقدة وتجنب التعقيد الحسابي الزائد الذي قد يؤدي إلى فرط المواءمة (over fitting).

2-3-3-3 عدد فترات التأخير: تم اختيار 5 فترات تأخير ($d=5$) لكل من المدخلات والمخرجات. يضمن هذا العدد تمثيل واستيعاب السلوك الديناميكي للنظام، حيث أن سلوك المطحنة يتأثر بالظروف السابقة لفترة زمنية معينة كما موضح في الشكل رقم [4-3]




شكل رقم [4-3]

3-3-3-3 خوارزمية التدريب: تم استخدام خوارزمية (LM) لتدريب الشبكة كما موضح في

الشكل رقم [5-3]. تُعرف هذه الخوارزمية بسرعتها واستقرارها في التقارب للعديد من مشاكل

الشبكات العصبية، خاصةً للشبكات ذات الحجم المتوسط، وتُعتبر خيارًا ممتازًا لتدريب نماذج

.(NARX)




شكل رقم [5-3]


4-3-3 التدريب وحفظ الشبكة

بعد إتمام عملية التدريب بنجاح والتحقق من أداء الشبكة على بيانات الاختبار، تم حفظ الشبكة الناتجة باسم `coal_mill_net`. يتيح حفظ النموذج المدرب إمكانية إعادة استخدامه لاحقًا للتنبؤ في

الوقت الفعلي دون الحاجة إلى إعادة التدريب كما موضح في الشكل رقم [3-6]



شكل رقم [3-6]



شكل رقم [7-3]

3-4 التصميم الهندسي:

تُعد مطحنة الفحم العمودية طراز (Pfeiffer MPS 250 BK) حلاً هندسياً متقدماً يجمع بين عمليات الطحن والتجفيف والتصنيف في وحدة واحدة [12]. تم تصميم هذه المطحنة خصيصاً للتعامل مع المواد الصلبة مثل الفحم الحجري والفحم البترولي، وتتميز بكفاءتها العالية في استهلاك الطاقة وقدرتها على معالجة المواد ذات الرطوبة العالية.

3-5 الأجزاء الرئيسية:

تتكون مطحنة الفحم العمودية طراز (Pfeiffer MPS 250 BK) من عدة أجزاء ميكانيكية وهيدروليكية تعمل بتكامل لضمان عملية تشغيل مستقرة كما موضحة في الشكل رقم [3-7]:

3-5-1 طاولة الطحن (Grinding Table):

3-5-2 هي الجزء الدوار الذي يستقبل المادة الخام. يتم تدويرها بواسطة صندوق تروس سفلي.

3-5-3 عجلات الطحن (Grinding Rollers): تتكون من ثلاث عجلات طحن تضغط على المادة الموجودة على طاولة الطحن بفعل وزن عجلات الطحن والنظام الهيدروليكي.

3-5-4 المصنف (Classifier): يقع في الجزء العلوي ويعمل على فصل الحبيبات الناعمة (المنتج) عن الحبيبات الخشنة (الراجع).

3-5-5 نظام الشد الهيدروليكي (Hydraulic Tensioning System): يوفر القوة اللازمة لضغط العجلات ويسمح بامتصاص الصدمات الناتجة عن عملية الطحن والمواد الغريبة.

3-5-6 حلقة الفوهات (Nozzle Ring): حلقة تحيط بطاولة الطحن وتزيد من سرعة الغازات الساخنة المارة عبرها، مما يسمح برفع المادة وتجفيفها بتأثير مروحة السحب الرئيسية.

3-5-7 صندوق التروس (Gearbox): يقوم بنقل الحركة من المحرك الكهربائي التزامني إلى

طاولة الطحن، محوّلًا الحركة الأفقية إلى حركة رأسية مع تقليل السرعة وزيادة العزم.

3-6 آلية التشغيل وتدفق المواد/ والغازات:

تعتمد عملية تشغيل المطحنة على التفاعل المستمر بين القوى الميكانيكية والمواد /والغازات:

3-6-1 التغذية (Feeding): يتم إدخال الفحم الخام بواسطة موازين عبر فتحة التغذية، ليسقط

مباشرة على مركز طاولة الطحن الدوارة.

3-6-2 الطحن (Grinding): تتحرك المادة نحو حافة الطاولة بفعل القوة الطاردة المركزية، وتمر

تحت عجلات الطحن التي تسحقها بفعل وزنها والضغط الهيدروليكي المحكم.

3-6-3 التجفيف والرفع (Drying and Lifting): عند وصول المادة إلى حافة الطاولة، تلتقطها

الغازات الساخنة المتدفقة من حلقة الفوهات، مما يؤدي إلى تجفيف الرطوبة فورًا ورفع الحبيبات نحو الأعلى.

3-6-4 التصنيف (Classification): تصل الحبيبات المعلقة في الغازات إلى المصنف، الحبيبات

التي حققت النعومة المطلوبة تخرج مع الغازات كمنتج نهائي، بينما تسقط الحبيبات الخشنة بفعل قوة

الطرد المركزي -المتولدة من سرعة مروحة المصنف- لتعود إلى طاولة الطحن مرة أخرى. يتم التحكم

في درجة النعومة بناءً على سرعة مروحة المصنف.

3-6-5 تدفق المواد (Material Flow): يبدأ مسار المادة من صوامع التغذية وصولاً إلى مركز

المطحنة. بعد سحقها، يتم رفعها بواسطة تيار الغازات. يتم فصل المنتج الناعم في المصنف، بينما

تعود المواد الخشنة عبر مخروط الراجع إلى مركز طاولة الطحن في دورة داخلية مستمرة (Internal Recirculation).

3-6-6 تدفق الغازات (Gas Flow): تدخل الغازات الساخنة - غالبًا غازات عادم من الفرن أو من مولد غازات ساخنة - من القاعدة السفلية للمطحنة بتأثير مروحة التعزيز (Booster Fan). تمر الغازات الساخنة عبر حلقة الفوهات التي تزيد من سرعتها لسرعة عالية، وتحمل الغازات المادة المطحونة عبر جسم المطحنة إلى المصنف. تخرج الغازات محملةً بالمنتج الناعم إلى مرشح الأكياس (Bag Filter) لفصل المنتج عن الغازات، ثم تخرج الغازات النظيفة عبر المدخنة (Chimney) بتأثير مروحة السحب الرئيسية (Mill Fan).

3-6-7 التوازن الحراري:

يعتمد التوازن الحراري في المطحنة على مبدأ حفظ الطاقة، حيث يجب أن تتساوى الحرارة الداخلة مع الحرارة المستهلكة والمفقودة، تُعد معادلة التوازن الحراري العامة كما يلي:

$$Q_{in} + Q_{gr} = Q_{evap} + Q_{mat} + Q_{gas} + Q_{loss}$$

حيث:

Q_{in} : الحرارة الداخلة من الغازات الساخنة القادمة من المصدر الحراري.

Q_{gr} : حرارة الطحن، وهي الطاقة الميكانيكية المتحولة إلى حرارة نتيجة الاحتكاك أثناء الطحن.

Q_{evap} : حرارة التبخير، وهي الطاقة المستهلكة لتبخير الرطوبة الموجودة في الفحم.

Q_{mat} : حرارة المادة، وهي الطاقة اللازمة لرفع درجة حرارة الفحم الخارج.

Q_{gas} : حرارة الغاز الخارج، وهي الطاقة المحمولة مع الغازات عند درجة حرارة المخرج.

Q_{loss} : الفقد الحراري، وهي الحرارة المفقودة عبر جدران المطحنة بالإشعاع والحمل.

الفصل الرابع

النتائج والمناقشة

4-1 مقدمة الفصل


يستعرض هذا الفصل النتائج التي تم الحصول عليها بعد تدريب واختبار النموذج باستخدام عينة 3,000. ويتضمن تحليل دقة التنبؤ بالاهتزازات الميكانيكية، ومناقشة مدى تحقيق الأهداف المرجوة بناءً على المقاييس الإحصائية مثل متوسط الخطأ التربيعي (MSE) ومعامل الارتباط (R).

4-2 تدريب وتقييم النموذج

تم تدريب واختبار النموذج باستخدام بيانات حقيقية مكونة من 3,000 عينة لبيانات ديناميكية مستمدة من تشغيل مطحنة فحم. يهدف هذا التدريب إلى تمكين الشبكة العصبية من تعلم الأنماط المعقدة وغير الخطية في بيانات التشغيل، ومن ثم التنبؤ بالاهتزازات الميكانيكية بكفاءة ودقة.

4-2-1 ملخص أداء عملية التدريب (Training Performance Summary)


يوفر الشكل رقم [4-8] ملخصاً شاملاً لعملية تدريب الشبكة العصبية. تم استخدام خوارزمية (LM) نظراً لسرعتها وكفاءتها في الشبكات متوسطة الحجم، مع اعتماد متوسط مربع الخطأ (MSE) كمقياس للأداء. تظهر لوحة التقدم أن التدريب توقف بعد 11 تكراراً (Epochs) فقط، وهو عدد منخفض جداً يدل على سرعة تقارب النموذج نحو الحل الأمثل. انخفض متوسط مربع الخطأ (MSE) بشكل كبير من 2.47 إلى 0.00711، بينما وصل تدرج الأداء (Gradient) إلى 0.0124، مما يؤكد وصول الشبكة إلى نقطة دنيا مستقرة. الأهم من ذلك، أن فحوصات الصلاحية (Validation Checks) توقفت عند القيمة 6، وهو ما يعني أن خطأ الصلاحية لم يزداد لستة تكرارات متتالية، مما يشير إلى أن الشبكة لم تتعرض للإفراط في التطابق وتمتلك قدرة جيدة على التعميم. تدعم هذه المؤشرات الكمية بشكل قاطع فعالية معمارية الشبكة المختارة (5 طبقات، 5 تأخيرات) ودقة النموذج الناتج.



شكل رقم [4-8]

2-2-4 تحليل توزيع الأخطاء (Error Histogram)


يوضح الشكل رقم [4-9] توزيع الأخطاء (الأهداف - المخرجات) للبيانات المستخدمة في مراحل التدريب والتحقق والاختبار. يظهر الرسم البياني أن معظم الأخطاء تتمركز حول الصفر، مما يشير إلى أن النموذج يتمتع بدقة عالية في التنبؤ. كما أن التوزيع متماثل نسبياً، مما يعكس أداءً جيداً للنموذج عبر جميع مجموعات البيانات (التدريب، التحقق، الاختبار). الخط البرتقالي يشير إلى نقطة الخطأ الصفري، وتظهر معظم الأعمدة الزرقاء (التدريب) والخضراء (التحقق) والحمراء (الاختبار) قريبة جداً من هذا الخط، مما يؤكد فعالية النموذج في تقليل الأخطاء.



شكل رقم [9-4]

3-2-4 استجابة السلاسل الزمنية (Time-Series Response)


يعرض الشكل رقم [10-4] استجابة النموذج للسلاسل الزمنية، حيث يقارن بين القيم المستهدفة (Targets) والمخرجات المتوقعة (Outputs) للنموذج عبر الزمن، بالإضافة إلى تمثيل الأخطاء. يوضح الجزء العلوي من الرسم البياني مدى تتبع مخرجات النموذج (الخطوط الملونة) للقيم الحقيقية (النقاط الملونة) عبر مراحل التدريب والتحقق والاختبار. يظهر توافق كبير بين المخرجات والأهداف، مما يدل على قدرة النموذج على التقاط الديناميكيات الزمنية للبيانات بشكل فعال. الجزء السفلي من الرسم البياني يوضح الأخطاء (الأهداف - المخرجات) عبر الزمن، حيث تظهر الأخطاء صغيرة ومتقلبة حول الصفر، مع وجود بعض الارتفاعات الطفيفة التي قد تشير إلى حالات شاذة أو نقاط بيانات صعبة التنبؤ بها، ولكنها لا تؤثر بشكل كبير على الأداء العام للنموذج.



شكل رقم [4-10]

4-2-4 الارتباط الذاتي للأخطاء (Error Autocorrelation)

يقدم الشكل رقم [4-11] تحليل الارتباط الذاتي للأخطاء، يهدف هذا التحليل إلى التحقق مما إذا كانت هناك أي أنماط متبقية أو ارتباطات غير ملقطة في الأخطاء بعد تدريب النموذج. من الناحية المثالية، يجب أن تقع جميع قيم الارتباط الذاتي (باستثناء الارتباط عند التأخر صفر) ضمن حدود الثقة (Confidence Limit) الموضحة بالخطوط المنقطعة. يظهر الرسم البياني أن معظم قيم الارتباط الذاتي تقع ضمن حدود الثقة، مما يشير إلى أن النموذج قد استوعب معظم الارتباطات الزمنية في البيانات وأن الأخطاء المتبقية هي ضوضاء عشوائية تقريبًا. هذا يعزز الثقة في أن النموذج قد تم تدريبه بشكل جيد ولا توجد معلومات مهمة متبقية في الأخطاء يمكن استغلالها لتحسين الأداء.




شكل رقم [4-11]

5-2-4 تحليل الارتباط المتقاطع بين المدخلات والأخطاء (Input-Error Cross-correlation).


بعد التحقق من عشوائية الأخطاء باستخدام الارتباط الذاتي، يُعد تحليل الارتباط المتقاطع بين المدخلات والأخطاء (Input-Error Cross-correlation) اختباراً حاسماً إضافياً لجودة النموذج. يوضح الشكل رقم [4-12] هذا التحليل، حيث يقيس مدى ارتباط الإشارة الداخلة (Input 1) بالخطأ الناتج (Error 1) عند فترات تأخير (Lags) مختلفة. الهدف المثالي هو أن يقع معامل الارتباط داخل حدود الثقة (Confidence Limit) لجميع قيم التأخير، مما يدل على أن النموذج قد استخلص جميع المعلومات المفيدة من المدخلات، وأن ما تبقى في إشارة الخطأ هو مجرد ضوضاء بيضاء غير مرتبطة بالمدخلات. يظهر الرسم البياني بوضوح أن جميع قيم الارتباط (الخط الأزرق) تقع داخل حدود الثقة (الخطوط الحمراء المنقطة) عند جميع التأخيرات المفحوصة من -20 إلى +20. هذه النتيجة القوية تؤكد أن الشبكة العصبية لم تهدر أي معلومات متاحة في المدخلات، وأن الأخطاء

المتبقية لا تحتوي على أي أثر منهجي للإشارة الأصلية، مما يعزز الثقة في كفاية النموذج وقدرته التنبؤية.



شكل رقم [12-4]

6-2-4 فحص أفضل معامل أداء للصلاحيّة لمتوسط الخطأ التربيعي (MSE) عبر الحقب. بناء على سلوك معامل أداء الصلاحيّة، وجد أن أفضل أداء قد تحقق عند الحقبة الخامسة تقريباً كما يوضح الشكل رقم [13-4].



شكل رقم [4-13]

3-4 مناقشة النتائج

تُظهر النتائج المستخلصة من التصميم والتدريب والتحليل الإحصائي الشامل إن نظام التحكم الذكي المقترح القائم على شبكة NARX العصبية قد حقق نجاحاً باهراً في نمذجة الاهتزازات الميكانيكية لمطحنة الفحم والتنبؤ بها.

1-3-4 الانخفاض الكبير في متوسط مربع الخطأ (MSE) وصولاً إلى 0.007 خلال 11 تكراراً فقط، مقترناً بوقوع جميع ارتباطات الأخطاء ضمن حدود الثقة، يمثل دليلاً دامغاً على قدرة النموذج على استيعاب العلاقات غير الخطية والديناميكية المعقدة الكامنة في بيانات التشغيل الصناعية.

2-3-4 تكتسب هذه النتائج أهمية عملية كبرى تتجاوز حدود النمذجة النظرية. فالدقة العالية في تتبع إشارة الاهتزاز والعشوائية التامة للأخطاء تسمحان باستخدام مخرجات النموذج كمؤشر موثوق للكشف المبكر عن الشذوذ.

3-3-4 أي انحراف مستقبلي بين القيم المقاسة وتنبؤات النموذج السليمة سيكون مؤشراً قوياً على تغير ديناميكي في المطحنة (كتآكل البطانات أو عدم اتزان في الطحن)، مما يتيح اتخاذ إجراءات الصيانة التنبؤية قبل تطور العطل، هذا بدوره يساهم بشكل مباشر في تحقيق أهداف البحث المتمثلة في تقليل الاهتزازات غير المرغوبة، وتجنب التوقفات المفاجئة المكلفة، وإطالة عمر المعدات.

الباب الخامس

الخاتمة والتوصيات

5-1 مقدمة الفصل

هذا الفصل يلخص أهم النتائج التي توصل إليها البحث، ويقدم مجموعة من التوصيات والمقترحات العلمية والعملية لتطوير أنظمة التحكم في مطاحن الفحم مستقبلاً، ورفع كفاءة التشغيل وضمان استقرار النظام.

5-2 الخاتمة

على الرغم من الأداء القوي للنموذج، يمكن استكشاف المزيد من التحسينات في المستقبل من خلال دمج مصادر بيانات إضافية أو استكشاف هياكل شبكات عصبية أكثر تعقيداً، أو تطبيق تقنيات التعلم العميق (Deep Learning) لزيادة دقة التنبؤ في السيناريوهات الأكثر تحدياً.

5-3 التوصيات

بناءً على الأداء القوي للنموذج المحفوظ تحت اسم (coal_mill_net)، تبرز مجموعة من التحليلات والتوصيات التي تهدف إلى رفع كفاءة النظام:

5-3-1 التكامل مع أنظمة التحكم الصناعية: يُوصى بدمج هذا النموذج المحفوظ مباشرة في أنظمة التحكم الحالية للمطحنة مثل نظام الـ (DCS) مما يتيح التنبؤ بالاهتزازات في الوقت الفعلي دون الحاجة لإعادة التدريب، ويساهم في تقليل التوقفات غير المخطط لها.

5-3-2 تحسين استراتيجيات الصيانة: يتيح التنبؤ الدقيق بالاهتزازات توفير نظام إنذار مبكر للأعطال قبل وقوعها بـ 2-3 دقائق، مما يساهم في تقليل تكاليف الصيانة التصحيحية وإطالة العمر الافتراضي لأجزاء المطحنة عالية التآكل مثل حلقة الطحن والدرافيل والبطانة الداخلية.

3-3-5 استكشاف تقنيات التعلم العميق (Deep Learning): يُوصى بإجراء دراسة للمقارنة بين

أداء نموذج (NARX) الحالي ونماذج الذاكرة طويلة وقصيرة المدى أو مع وحدات البوابات المتكررة

، حيث تتميز هذه النماذج بقدرة أعلى على التتبع لفترات زمنية طويلة.

4-3-5 تطوير واجهة مستخدم رسومية (GHI) للمشغلين حيث يتحول فيها النموذج الرياضي إلى

تطبيق عملي بواجهة مرئية تُظهر مؤشراً في الزمن الحقيقي للمطحنة.

المراجع

المصادر العربية

- [1] تصميم نظم التحكم الطبعة الأولى 2009 تأليف د. الحسن بشير العقاب
- [2] مقدمة في الذكاء الصناعي الطبعة الأولى 2006 تأليف ثائر محمد محمود / صادق فليح عطيات

المصادر الأجنبية

[3] D.W. van Krevelen Coal: Typology, Physics, Chemistry, Constitution Elsevier Science 3rd Edition 1993

[4] Jinsheng Wang, Edward J. Anthony, Juan Carlos Abanades – Clean and efficient use of petroleum coke for combustion & power generation July 2004

[5] Kianoush Barani, Rasoul Fatahi – نمذجة ومحاكاة مطحنة العجلات العمودية (VRM) – قسم هندسة التعدين، جامعة لورستان، خرم آباد، إيران – (22 July 2019)

<https://www.journalssystem.com/ppmp/pdf-112313-45441?filename=Modeling-and-simulation-o.pdf>

[6] Piotr Niemczyk – Model-based fuel flow control for fossil-fired power plants – PhD Thesis – 2013

https://publishup.uni-potsdam.de/opus4-ubp/frontdoor/deliver/index/docId/40462/file/otto_diss.pdf

[7] J. Smrekar, D. Pandit, M. Fast, M. Assadi, S. De – Development of artificial neural network model for a coal–fired boiler using real plant data Energy – 2009
<https://www.sciencedirect.com/science/article/abs/pii/S0360544208002880#:~:text=In%20this%20paper%2C%20development%20of,model%20for%20real%20life%20applications>

[8] E. Oko, M. Wang, J. Zhang – Neural network approach for predicting drum pressure and level in coal–fired subcritical power plant – Fuel – 2015
<https://www.sciencedirect.com/science/article/abs/pii/S0016236115001118>

[9] V. Agrawal, B. K. Panigrahi, P. M. V. Subbarao – Review of control and fault diagnosis methods applied to coal mills – Journal of Process Control – 2015
<https://www.sciencedirect.com/science/article/abs/pii/S0959152415000724>

[10] Y. Hu, et al. – Research on fault diagnosis of coal mill system based on simulated typical fault samples – Journal of Process Control – 2020
<https://www.sciencedirect.com/science/article/abs/pii/S0263224120304024?via%3Dihub>

[11] Y. Jian, X. Qing, Y. Zhao, L. He – Application of Model–Based Deep Learning Algorithm in Fault Diagnosis of Coal Mills – Mathematical Problems in Engineering – 2020

<https://onlinelibrary.wiley.com/doi/10.1155/2020/3753274>

[12] Gebr. Pfeiffer AG – Operating Instructions for Grinding Plant with Roller

Mill type MPS 250 BK – Gebr. Pfeiffer AG Press – 1st Edition – 2008

<https://www.scribd.com/document/625984716/chap-1-10>

الملاحق:

عينة تمثل 10% من بيانات التدريب

Vibr mm/s	Diff Pre mbar	Out Temp C°	Feed Rate tph	Time min
0.22	25.2	77.23	35.1	0
0.28	25.1	77.63	35	1
0.31	24.5	77.29	34.9	2
0.19	24.9	77.09	34.9	3
0.13	25	77.58	35.4	4
0.23	25.5	77.29	35	5
0.27	24.6	77.72	34.9	6
0.19	25.1	78.09	34.4	7
0.33	25.3	77.32	34.8	8
0.24	25.1	76.99	34.7	9
0.13	25	76.85	34.9	10
0.28	24.5	77.37	34.9	11
0.31	24.8	77.7	35.2	12
0.21	25.2	77.62	35.6	13
0.24	25	77.78	35.1	14
0.28	25.3	77.41	35.1	15
0.32	24.8	77.04	34.4	16
0.24	25.4	77.43	34.6	17
0.3	25	77.47	34.8	18
0.2	25.1	77.82	35.4	19
0.25	24.5	77.13	34.6	20
0.24	25.3	77.86	35.3	21
0.24	25.1	77.94	34.2	22
0.22	24.9	77.49	35.3	23
0.3	25.5	77.47	34.8	24
0.32	24.5	77.32	35.3	25
0.3	24.8	77.3	35.7	26
0.29	25.3	77.67	34.8	27
0.19	25.3	77.7	35.5	28
0.32	25	77.96	35.5	29
0.17	25.3	77.31	34.9	30
0.28	25.4	76.87	35	31
0.21	24.8	77.48	34.8	32
0.26	25.5	77.64	35.2	33
0.3	25	77.5	35.1	34
0.28	25	77.34	35.2	35
0.26	25	77.4	35	36

0.26	25	77.89	35.2	37
0.31	24.8	77.38	35	38
0.26	24.5	77.6	34.9	39
0.18	24.6	77.65	35.3	40
0.21	24.4	77.79	35	41
0.31	25	77.38	35.5	42
0.3	24.5	77.83	35.5	43
0.21	25.3	77.8	35	44
0.14	25.6	77.75	34.6	45
0.33	25.5	77.1	34.5	46
0.24	24.3	77.43	34.4	47
0.21	24.7	77.13	34.8	48
0.3	25.4	77.33	35.2	49
0.24	25.2	77.82	35	50
0.31	25	77.77	35.5	51
0.27	24.8	77.11	35.1	52
0.24	24.8	77.01	34.4	53
0.33	24.9	77.67	35.6	54
0.21	25	76.9	34.9	55
0.17	24.9	77.38	35.1	56
0.3	25.1	77.58	35.5	57
0.29	24.8	77.29	35	58
0.25	24.8	77.55	34.9	59
0.22	24.6	77.05	35.4	60
0.24	25.1	77.31	34.2	61
0.29	24.5	77.56	34.7	62
0.22	24.5	77.48	35.5	63
0.16	24.9	78.3	34.9	64
0.28	25.2	77.49	34.9	65
0.27	24.9	77.34	34.9	66
0.33	25.1	77.01	34.9	67
0.24	25.1	77.69	35.4	68
0.13	24.3	77.67	35.1	69
0.26	25.6	77.33	34.9	70
0.3	24.9	77.37	35.5	71
0.16	25.2	76.81	35.5	72
0.32	25.3	77.6	35.1	73
0.22	25.2	77.42	35.4	74
0.24	25.2	77.16	35.3	75
0.3	25.1	77.38	35.6	76
0.25	25.2	77.38	34.6	77
0.31	25.2	77.32	35	78
0.25	24.7	77.63	35	79
0.29	25.4	77.6	35	80
0.27	25.2	77.61	34.8	81
0.33	25.1	77.51	34.8	82
0.6	25.5	77.89	34.7	83
0.83	24.5	77.74	34.9	84
0.33	25.2	77.9	34.6	85

0.64	25.6	77.63	35.2	86
1.88	17.6	77.85	0	87
0.24	24.8	77.34	35	88
0.35	25.1	77.25	35.3	89
0.18	25.3	77.39	35.3	90
0.21	25.2	77.99	34.6	91
0.24	25	77.73	34.6	92
0.3	24.9	77.11	35.1	93
0.24	24.9	77.79	35.2	94
0.21	24.8	77.42	34.9	95
0.26	24.7	77.32	34.3	96
0.15	24.5	77.79	35.1	97
0.31	25.1	77.94	34.7	98
0.26	25.3	77.28	34.6	99
0.24	24.9	77.6	34.6	100
0.26	24.8	78.05	35.3	101
0.2	25.2	77.13	35.3	102
0.23	24.8	76.96	35.2	103
0.28	25.2	77.05	34.8	104
0.26	25.5	77.43	35.4	105
0.22	25.5	77.37	35	106
0.19	25	77.52	34.6	107
0.62	24.9	77.02	36	108
0.83	24.8	77.05	35.1	109
0.29	25.1	76.96	35.7	110
0.59	24.8	77.13	35.3	111
1.8	17.3	76.88	0	112
0.24	25.1	77.89	35.4	113
0.21	24.4	77.28	34.7	114
0.27	25	77.54	35	115
0.25	25.1	77.05	34.9	116
0.28	24.7	77.36	35.2	117
0.29	25.1	77.13	34.9	118
0.17	25.4	77.63	34.6	119
0.19	25.4	77.64	35.2	120
0.25	24.9	77.92	34.7	121
0.28	25.1	77.28	35.1	122
0.32	25.3	77.57	35.3	123
0.28	25.6	77.5	35.2	124
0.24	25	77.84	35	125
0.26	24.6	77.49	35.2	126
0.29	24.8	77.9	34.5	127
0.21	25	77.62	35.1	128
0.27	25.5	77.38	35.3	129
0.21	25.1	77.26	35.2	130
0.23	25.3	77.88	34.9	131
0.23	24.9	77.65	35	132
0.22	25.3	77.73	35.3	133
0.18	25.1	77.28	35.5	134

0.27	25	77.53	34.8	135
0.24	25.1	77.78	34.7	136
0.17	24.8	77.48	35	137
0.17	24.4	77.77	35.6	138
0.23	24.9	77.96	35.3	139
0.19	25.4	77.69	34.9	140
0.31	25.5	77.59	34.6	141
0.23	24.8	77.65	34.7	142
0.25	25.2	77.38	35.2	143
0.29	24.6	77.01	34.7	144
0.24	24.8	77.37	34.8	145
0.21	25.4	76.8	35.2	146
0.23	25.4	77.83	34.7	147
0.25	25.4	77.47	35.3	148
0.22	24.8	77.69	35.3	149
0.2	24.9	76.86	35.1	150
0.29	24.8	77.44	35.1	151
0.24	25	78.15	34.9	152
0.23	25	77.32	35.3	153
0.3	24.7	77.64	34.8	154
0.3	25.4	78.02	35.1	155
0.21	24.9	77.67	35	156
0.18	24.8	77.12	34.9	157
0.19	24.6	77.05	35.2	158
0.21	25.1	77.26	34.6	159
0.28	25.5	77.68	35.1	160
0.25	25.5	77.48	34.4	161
0.16	25	77.43	34.8	162
0.2	24.7	77.75	35.4	163
0.25	25.5	77.23	35	164
0.22	24.5	77.49	34.9	165
0.22	25.2	77.22	34.6	166
0.23	25	77.35	34.9	167
0.21	25.2	77.66	35	168
0.3	24.9	77.42	35.4	169
0.3	24.9	77.86	35.3	170
0.3	25.3	77.44	35.2	171
0.18	25.1	77.35	35.2	172
0.19	24.3	77.74	34.8	173
0.32	24.9	77.55	35	174
0.27	25.2	77.92	35.1	175
0.25	25.3	77.71	34.5	176
0.23	26.1	77.12	35.9	177
0.35	26.9	77.52	35.1	178
0.28	27.7	77.39	35	179
1.95	25.1	77.25	42.5	180
0.21	25.3	77.65	35.3	181
0.16	24.7	77.5	34.8	182
0.25	25.1	77.89	35	183

0.25	24.7	76.81	35.2	184
0.28	25.2	77.83	35.1	185
0.21	24.9	77.54	35.1	186
0.25	25.3	77.64	35.3	187
0.26	24.9	77.47	35.7	188
0.22	24.9	77.87	35.6	189
0.2	25.6	77.83	35.2	190
0.28	24.7	77.78	35.1	191
0.16	24.9	77.69	34.4	192
0.29	25	77.59	35	193
0.23	25	77.37	35	194
0.23	25	77.39	35.1	195
0.22	24.8	77.42	34.9	196
0.28	24.6	77.36	35.2	197
0.25	25	77.12	34.8	198
0.21	25.1	77.58	34	199
0.22	25.3	77.41	35.4	200
0.25	24.8	77.59	35.4	201
0.19	25.1	77.93	35.6	202
0.26	24.7	77.43	34.8	203
0.35	25.5	77.16	35.1	204
0.37	25.1	77.34	35	205
0.21	25.4	77.56	34.4	206
0.31	25.1	77.38	34.7	207
0.26	24.7	77.93	35	208
0.35	25.2	77.38	34.9	209
0.24	24.8	77.88	34.7	210
0.3	25.2	77.44	34.9	211
0.2	25.3	76.65	35	212
0.3	24.9	77.75	34.9	213
0.26	24.8	77.91	34.9	214
0.3	24.8	78.08	35.7	215
0.21	25	77.43	34.9	216
0.32	25.3	77.55	35.3	217
0.25	25.2	77.74	34.6	218
0.25	25.5	77.43	34.8	219
0.28	25.1	77.22	34.4	220
0.32	24.9	77.59	35.2	221
0.36	25.1	77.08	34.7	222
0.24	25.1	77.48	35	223
0.24	24.8	78.34	35.4	224
0.32	25.2	77.92	34.7	225
0.21	25	77.43	35	226
0.26	24.8	76.53	35.1	227
0.32	25.4	77.14	35.3	228
0.3	25.1	76.91	35.5	229
0.22	25.2	77.62	35.2	230
0.26	24.8	77.35	34.9	231
0.23	24.9	77.79	35.1	232

0.23	24.9	77.44	35.1	233
0.21	25.2	77.68	35.2	234
0.22	24.7	77.46	35.4	235
0.18	24.9	77.08	34.9	236
0.19	24.8	77.84	34.7	237
0.22	25.1	77.83	35	238
0.31	25.1	77.61	35.2	239
0.24	24.3	77.37	35.5	240
0.2	24.9	77.87	34.9	241
0.31	25.4	77.36	34.9	242
0.22	25.3	77.64	35.2	243
0.19	24.7	77.5	35.5	244
0.27	24.6	77.09	34.6	245
0.21	24.7	77.55	34.9	246
0.24	24.9	77.47	35.3	247
0.31	24.8	77.66	34.8	248
0.28	25.1	77.49	35	249
0.19	25.5	77.48	34.4	250
0.26	25.2	77.17	35.5	251
0.19	25.2	77.61	36	252
0.19	24.5	77.5	35.2	253
0.26	24.5	77.53	34.9	254
0.24	24.7	77.57	35	255
0.19	25.2	77.64	35.1	256
0.26	24.8	77.48	35.3	257
0.23	24.9	76.88	35	258
0.19	24.8	77.51	34.9	259
0.23	25.2	77.23	34.4	260
0.24	24.9	77.16	35.3	261
0.33	25	78.13	34.6	262
0.26	24.8	77.15	35	263
0.22	25.1	77.95	35.2	264
0.28	25.6	76.94	35	265
0.32	24.8	77.99	34.9	266
0.25	25.1	76.78	35.1	267
0.22	24.6	77.63	34.4	268
0.24	25.1	77.79	34.5	269
0.24	25	77.48	35.2	270
0.24	25.3	77.66	34.1	271
0.28	24.9	77.7	34.6	272
0.28	25.1	77.53	35.1	273
0.27	24.9	77.18	34.6	274
0.09	24.9	77.64	35.4	275
0.29	24.8	77.4	34.9	276
0.17	24.5	77.47	34.8	277
0.15	24.9	77.93	34.8	278
0.23	24.7	78	35.2	279
0.21	24.7	77.65	35	280
0.24	25.3	77.47	34.3	281

0.28	24.8	77.7	35.2	282
0.27	24.4	77.67	35.2	283
0.29	25.1	77.93	35.1	284
0.35	25	77.52	35.3	285
0.23	25.5	77.3	34.7	286
0.2	24.9	77.16	35.2	287
0.36	25.1	77.26	35.2	288
0.23	25.3	77.28	35	289
0.28	25.1	77.71	34.9	290
0.2	25	77.56	34.9	291
0.25	25	77.96	35.1	292
0.24	24.9	77.68	34.6	293
0.27	24.9	77.72	35.5	294
0.26	25.4	77.33	34.6	295
0.2	25.2	77.82	35	296
0.32	25	77.48	34.6	297
0.31	25.4	77.97	35.2	298
0.12	25.2	77.68	34.9	299
0.29	25.7	76.92	34.6	300