



الجمهورية العربية السورية

وزارة التعليم العالي والبحث العلمي

جامعة دمشق

كلية الهندسة الميكانيكية والكهربائية

قسم هندسة الحواسيب والأتمتة

معالجة مشكلة الصيانة التنبؤية باستخدام تقنية التعلم العميق

رسالة أعدت لنيل درجة الماجستير في هندسة الروبوت وبرمجته

إعداد

المهندس محمد نور عبد الوهاب

إشراف

الأستاذ الدكتور المهندس محمد مازن المحاييري

أستاذ مساعد في قسم هندسة الحواسيب والأتمتة

العام الدراسي

2021/2022

لجنة الحكم

تم تأليف لجنة الحكم على رسالة الماجستير بعنوان "معالجة مشكلة الصيانة التنبؤية باستخدام تقنية التعلم العميق" بقرار مجلس البحث العلمي والدراسات العليا رقم /3141/ بتاريخ 2022/07/04 من السادة الأساتذة:

أ.د.م. محمد مازن المحايري الأستاذ المساعد في قسم هندسة
جامعة دمشق الحواسيب والأتمتة - كلية الهندسة
الميكانيكية والكهربائية

عضواً مشرفاً

د.م. هيام خدام المدرّسة في قسم هندسة الحواسيب
جامعة دمشق والأتمتة - كلية الهندسة الميكانيكية
والكهربائية

عضواً

د.م. محمد تاج الدين الحسيني المدرّس في قسم هندسة الحواسيب
جامعة دمشق والأتمتة - كلية الهندسة الميكانيكية
والكهربائية

عضواً

تصريح خطي

أنا الموقع أدناه أصرح بعلمي الكامل وقبولي:

1. أن كل ما ينتج عن البحث والرّسالة هو ملكية فكرية ومالية بالتشارك مع جامعة دمشق، وأني ألتزم بأخذ موافقة الجامعة في حال رغبتني بنشر البحث أو الرّسالة أو جزء منها نصاً أو مضموناً خارج إطار الجامعة (من دور نشر أو مكّتبات أو مواقع إلكترونية وغيرها من وسائل النشر).

2. أنه لا يوجد أي جزء من هذه الرّسالة اقتُبس من عمل علمي آخر أو أنجز للحصول على شهادة أخرى في جامعة دمشق أو أية جامعة أو معهد تعليمي داخل الجمهورية العربية السورية أو خارجها.

الاسم والتوقيع

شكر وتقدير

أتوجّه بالشكر والتقدير إلى كلّ من ساهم في دعم إنجاز هذا البحث، وأخصّ بالذكر جميع كوادِر جامعة دمشق

وقسم هندسة الحواسيب والأتمتة في كلية الهندسة الميكانيكية والكهربائية، وأسَمّي منهم:

• د.م. محمد مازن المحاييري، المشرف العلمي على إنجاز هذا البحث.

• د.م. محمد تاج الدين الحسيني.

• د.م. هيام خدام.

• د.م. رائوف حمدان.

كما أتوجّه بالشكر والتقدير إلى شركة تكنوليد للأتمتة المتكاملة وشركة سورس كود لتعاونهم في تقديم الدعم

لإنجاز هذا البحث.

فهرس المحتويات (Table of Contents)

vii.....	قائمة الأشكال والرسوم البيانية (List of Figures)
ix	قائمة الجداول (List of Tables)
x	قائمة المصطلحات والاختصارات (List of Terms)
1.....	ملخص (Abstract)
2.....	1. الجزء التمهيدي (الإطار العام)
2.....	1.1. مقدمة:
3.....	2.1. مشكلة البحث:
4.....	3.1. تساؤلات البحث:
4.....	4.1. أهداف البحث:
4.....	5.1. أهمية البحث:
5.....	6.1. حدود البحث:
5.....	7.1. منهج البحث وأدواته:
6.....	8.1. طريقة تنفيذ البحث:
7.....	2. أدبيات البحث
7.....	1.2. الصيانة التنبؤية (PdM):
7.....	1.1.2. الصيانة وهندسة الصيانة (Maintenance & Maintenance Engineering):
8.....	2.1.2. أنواع الصيانة:
9.....	3.1.2. تعريف الصيانة التنبؤية (PdM Definition):
10	4.1.2. مصادر البيانات في الصيانة التنبؤية (PdM Data Sources):
10	5.1.2. تقنيات مراقبة الحالة بمكونات مضافة (Added Components CM Techniques):

12	6.1.2. المقاييس المستتجة في الصيانة التنبؤية (PdM Inferred Metrics) :
13	7.1.2. نمذجة آلة الصيانة التنبؤية (PdM Machine Modelling) :
15	8.1.2. مناهج إنشاء آلة الصيانة التنبؤية (PdM Machine Creation Methods) :
16	2.2. التعلّم العميق (Deep Learning) :
16	1.2.2. تعلّم الآلة ودورة حياة الآلة المتعلّمة (ML & Learning Machine Lifecycle) :
20	2.2.2. الشبكة العصبونية الاصطناعية وخوارزمية الانتشار الخلفي (ANN & BP Algorithm) :
22	3.2.2. مفهوم التعلّم العميق (DL Concept) :
23	2.2.4. الشبكة العصبونية التلافيفية (Convolutional Neural Network) :
25	5.2.2. الشبكة العصبونية العودية (Recurrent Neural Network) وتقنية (LSTM) :
29	6.2.2. المرمز الآلي العميق (Deep Auto-Encoder) :
30	7.2.2. شبكة التصديق العميقة (Deep Belief Network) :
34	8.2.2. الشبكة المولدة الندية (Generative Adversarial Network) :
	3.2. توجهات البحث في معالجة مسألة الصيانة التنبؤية بالتعلّم العميق (Handling PdM by DL)
35	(Research Trends) :
45	3. الإجراءات البحثية
45	1.3. تصميم بنى عميقة مخصصة لمسائل صيانة تنبؤية :
46	1.1.3. استنتاج استقرائي لخوارزمية الانتشار الخلفي (BP) :
52	2.1.3. وضع مراحل استراتيجية تصميم بنى عميقة مخصصة للصيانة التنبؤية :
55	2.3. تصميم بنية عميقة تُعالج مسائل بيانات ذات ميّزات تفضلية :
66	3.3. وضع استراتيجية عامة لمعالجة مسألة الصيانة التنبؤية باستخدام التعلّم العميق :
66	1.3.3. تحليل في مسألة الصيانة التنبؤية :
69	2.3.3. فاعلية التعلّم العميق كمنهج في معالجة مسألة الصيانة التنبؤية :

3.3.3.	وضع مراحل الاستراتيجية المقترحة لمعالجة مسألة الصيانة التنبؤية:	70
4.3.	تطبيق الاستراتيجية المقترحة لمعالجة مسألة الصيانة التنبؤية على حالة رولمان دوّار بسرعات دورانية متغيرة:	74
1.4.3.	مراحل العمل:	74
2.4.3.	تقييم نتائج معالجة حالة الرولمان ومقارنتها مع معالجة الحالة نفسها بمناهج مغايرة:	93
4.	الخلاصة والتوصيات:	98
1.4.	نتائج البحث:	98
2.4.	آفاق مستقبلية ومقترحات:	100
	المراجع (References)	102

قائمة الأشكال والرسوم البيانية (List of Figures)

- الشكل (2-1): نموذج مبسط لجريان المعلومات في منشأة ستطبق فيها صيانة تنبؤية 13
- الشكل (2-2): نموذج ابتدائي لآلة الصيانة التنبؤية 14
- الشكل (2-3): تنظيم عملية استخلاص الميزات 19
- الشكل (2-4): بنية الخلية العودية (RECURRENT CELL) 26
- الشكل (2-5): الخلية العودية بعد نشرها عبر الزمن 26
- الشكل (2-6): بنية خلية (LSTM) 28
- الشكل (2-7): تنظيم بنية المرمز الآلي 29
- الشكل (2-8): بنية شبكة (RBM) 31
- الشكل (2-9): بنية شبكة التصديق العميقة (DBN) 33
- الشكل (2-10): تنظيم مقترح لمستوى تحديد الأعطال وتوقعها من إطار عمل للصيانة التنبؤية 37
- الشكل (2-11): بنية معالجة مسألة خطأ الحركة الارتجاعية، ونتائج تنبؤ فعلي 38
- الشكل (2-12): بنية (SAE-LSTM) مستخدمة في كشف انحراف أداء آلة دوارة 39
- الشكل (2-13): بنية عميقة مستخدمة في تشخيص أعطال رولمان في ظروف سرعة متغيرة 40
- الشكل (2-14): استخدام مرمز آلي عميق ككاشف ميزات يغذي بنية عنقدة 41
- الشكل (2-15): بنية المرمز الآلي العميق والنافذة المنزلقة على إشارات الاهتزاز 42
- الشكل (2-16): بنية هجينة لحساب مؤشر صحة آلة ميكانيكية 43
- الشكل (3-1): تنظيم البنية العميقة الخاصة بمعالجة مسألة مراقبة الحالة من خلال إشارة موضع 57
- الشكل (3-2): بنية عميقة متعددة المسارات خاصة بإشارة تحسس 72
- الشكل (3-3): بنية آلة الصيانة التنبؤية النهائية (PDM MACHINE) 74
- الشكل (3-4): تنظيم جملة المحور الدوار والمحرك المخبرية 75
- الشكل (3-5): الطيف الترددي لإشارة الاهتزاز (H-A-2-CH1) 79
- الشكل (3-6): مقارنة الأطياف الترددية للإشارات ككل ولنوافذ مقطوعة منها بطول (50) ميلي ثانية 81
- الشكل (3-7): بنية كاشف العطل كمصنّف ثنائي 82
- الشكل (3-8): معاملات أداء (FAULT_DETECTOR_6_5) أثناء تدريبه 85

- الشكل (3-9): نتائج اختبار (FAULT_DETECTOR_6_5) على إشارات جديدة 86
- الشكل (3-10): بنية محدّد العطل كمصنّف متعدّد 87
- الشكل (3-11): معاملات أداء محدّد العطل (FI_6_7) أثناء تدريبه 91
- الشكل (3-12): القيم الزمنية لمرشحات طبقة الطّي الأولى في كاشف العطل 91
- الشكل (3-13): الأطياف الترددية لمرشحات طبقة الطّي الأولى في كاشف العطل 92
- الشكل (3-14): الأطياف الترددية لمرشحات طبقة الطّي الثانية في كاشف العطل 92
- الشكل (3-15): منحنيات تدريب بنى (DBN) ككواشف عطل 96

قائمة الجداول (List of Tables)

الجدول (1-2): دلالات رموز النموذج الرياضي للمسار الأمامي في خلية (LSTM)	28
الجدول (2-2): دلالات حدود معادلات توصيف شبكة (RBM)	31
الجدول (3-2): مجالات فاعلية البنى العميقة الأساسية في معالجة بيانات الصيانة	36
الجدول (4-2): فاعلية البنى العميقة الأساسية في مسألة الصيانة التنبؤية	38
الجدول (1-3): دلالات معاملات النموذج الرياضي لشبكة (FNN)	47
الجدول (2-3): تحقق القضية الاستقرائية على أول ثلاث قيم (M)	50
الجدول (3-3): التنظيم الرياضي لوحدة التفاضل كعنصر حسابي	56
الجدول (4-3): المعاملات والبنى الرياضية الممثلة للبنية العميقة التفاضلية	57
الجدول (5-3): تصنيف ثوابت النموذج الرياضي الممثل للبنية العميقة التفاضلية	59
الجدول (6-3): الحالات الصحية المختلفة للزولمان	75
الجدول (7-3): دلالات صيغة تسمية الإشارات في معالجة مسألة الزولمان	78
الجدول (8-3): المتحولات المستقلة في تجربة كاشف العطل	83
الجدول (9-3): المتحولات المضبوطة أثناء تدريب كاشف العطل	84
الجدول (10-3): أمثلة معاملات كاشف العطل كمصفف ثنائي في حالة الزولمان	85
الجدول (11-3): إشارات الاهتزاز المستخلص منها بيانات تدريب محدّد العطل واختباره	87
الجدول (12-3): المتحولات المستقلة في تصميم محدّد العطل كمصفف متعدّد	88
الجدول (13-3): المتحولات المضبوطة في تصميم محدّد العطل	89
الجدول (14-3): معاملات تدريب بعض البنى المجربة واختبارها كمحدّد عطل	90
الجدول (15-3): نتائج اختبار بنى مصنفات كمحدّد عطل على الإشارات (Y-X-3-CH1)	90
الجدول (16-3): نتائج أداء محدّدات عطل مصممة وفق منهج مقترح	94
الجدول (17-3): دقة تحديد العطل المتوسطة باستخدام تحويل (VMD)	95
الجدول (18-3): دقة بنى مختلفة تظهر فاعلية تطبيق تحويل ترددي	96

قائمة المصطلحات والاختصارات (List of Terms)

ANN	Artificial Neural Network	الشبكة العصبونية الاصطناعية
BP	Back Propagation Algorithm	خوارزمية الانتشار الخلفي
BPTT	Back Propagation Trough Time	خوارزمية الانتشار الخلفي عبر الزمن
CD	Contrastive Divergence	خوارزمية التّغاير المتباين
CM	Condition Monitoring	مراقبة الحالة
CNN	Convolutional Neural Network	الشبكة العصبونية التلافيفية
DAE	Deep Auto Encoder	المرمّز الآلي العميق
DBN	Deep Belief Network	شبكة التّصديق العميقة
DIKW	Data Information Knowledge Wisdom	البيانات، المعلومات، المعرفة، الحكمة
DL	Deep Learning	التعلّم العميق
FFN	Feed Forward Network	الشبكة العصبونية الأمامية
GAN	Generative Adversarial Network	الشبكة المولدة الاعلانية
LRF	Local Receptive Field	حقل الاستقبال المحلي
LSTM	Long Short Term Memory	الخلية ذات ذاكرة قصيرة طويلة الأمد
ML	Machine Learning	تعلّم الآلة
PdM	Predictive Maintenance	الصيانة التنبؤية
PM	Preventive maintenance	الصيانة الوقائية
RBM	Restricted Boltzmann Machine	آلة بولتزمان المقيدة
RNN	Recurrent Neural Network	الشبكة العصبونية العودية
RUL	Residual Useful Life	العمر المفيد المتبقّي

ملخص (Abstract)

تُعدّ الصيانة التنبؤية (PdM) تقنية مهمة من الناحية التطبيقية والاقتصادية، وبالرغم من ضخامة حجم البيانات والمعلومات اللازم معالجتها عند تطبيق الصيانة التنبؤية في النظم الهندسية، وتعقيد هذه المسألة أمام النمذجة الرياضية، إلا أنّ التعلّم العميق (Deep Learning) يطرح نفسه كمنهج مناسب لبناء آلات الصيانة التنبؤية الناجحة بامتلاكه فاعليات كالاستخلاص الآلي للميزات والصمود أمام أنماط البيانات الجديدة والشاذة، والأهم، الخاصية التنبؤية والرصد الآلي لنمو الظواهر البيانية.

الصيانة التنبؤية مسألة عامة تُطرح في مختلف الآلات والنظم الهندسية، وتتجه معظم الأبحاث والتجارب عامة نحو معالجة حالات خاصة، ويهدف هذا البحث إلى استشفاف ما هو عام من مفاهيم وأساليب في معالجة مسألة الصيانة التنبؤية باستخدام التعلّم العميق، والتعلّم العميق هو مجال بحثي متكيف في تطوره مع المسائل التطبيقية المختلفة، ويهدف هذا البحث إلى تحري توجيهات بحثية للتعلّم العميق تفرضها مسألة الصيانة التنبؤية.

بدأ البحث بمراجعة أدبيات الصيانة التنبؤية والتعلّم العميق، ثم توجه نحو التحليل الاستنباطي، واقترح استراتيجيات عمل عامة في محورين، الأول هو تصميم بنى عميقة مخصصة لمسائل صيانة تنبؤية، والثاني هو تطبيق تقنيات التعلّم العميق في معالجة مسألة الصيانة التنبؤية، وعولجت حالة رولمان دوار بسرعات متغيرة باستخدام استراتيجية مقترحة، واستخدمت مكتبة (Tensorflow) الخاصة بالتعلّم العميق، حيث كانت دقة كشف العطل (99.91%) وتحديد العطل (98.44%) متفوقة على قيم أداء البنى الضحلة (70% - 90%)، ومضاهية للبنى العميقة (90% - 99.9%) بدون أي استخلاص ميزات يدوي.

تبين في هذا البحث ارتباط مسألة الصيانة التنبؤية مع الدراسة الهندسية للآلة أو الجهاز بصورة وثيقة، وتأثير معلومات الدراسة في جودة آلة الصيانة التنبؤية، وإمكانية حل المسألة من دون أي استخلاص ميزات يدوي وباستخدام موارد حاسوبية مكتبية وبرمجيات مفتوحة المصدر، وبالتالي اتباع استراتيجية عامة.

الكلمات المفتاحية: الصيانة التنبؤية (PdM)، مراقبة الحالة (CM)، الشبكة العصبونية الاصطناعية (ANN)، خوارزمية الانتشار الخلفي (BP)، التعلّم العميق (DL)، الشبكة العصبونية التلافيفية (CNN)، خوارزمية الانتشار الخلفي عبر الزمن (BPTT)، معالجة إشارة الاهتزاز (Vibration Signal Processing).

1. الجزء التمهيدي (الإطار العام)

1.1. مقدمة:

منذ بدء الثورة الصناعية، كان موضوع صيانة التجهيزات الهندسية تحدياً كبيراً، حيث يتم إنفاق مليارات الدولارات على صيانة التجهيزات الهندسية حول العالم، لأنه في الواقع لا توجد تجهيزات وآلات هندسية تعمل في حالتها الفنية المثالية إلى الأبد، ومن ثم فإن العطل وتراجع الأداء هو حالة طبيعية واقعية تبديها أية آلة أو جهاز، والمراقبة والتصحيح والإصلاح هي أنشطة دورية متكررة في أي مصنع أو منشأة، وهذه الأنشطة هي رد الفعل الطبيعي على ظاهرة الأعطال وتراجع الأداء [1].

هندسة الصيانة (Maintenance Engineering) تبحث في تطوير المفاهيم والمعايير والاحتياجات التقنية في طور المفاهيمي بهدف استخدامها واتباعها في طور التشغيل لضمان دعم عمليات الصيانة للتجهيزات [2]. وتقدم هندسة الصيانة مفاهيم وأدوات ومناهج تطبيقية لتنظيم أنشطة الصيانة وإكسابها الفاعلية ورفع مردودها، وهندسة الصيانة مجال بحثي تتقاطع فيه اختصاصات تطبيقية ونظرية عدة، وكسائر المجالات البحثية، فإن هندسة الصيانة في حالة تطور مستمر يواكب التطور الصناعي والتكنولوجي والأجيال الصناعية المتلاحقة التي باتت تعتمد توجهه الرقمنة (Digitization) الشامل.

تُعَد الصيانة التنبؤية (Predictive Maintenance) تقنية حديثة من تقنيات هندسة الصيانة، تهتم بتصميم آلات حسابية قادرة على استيعاب وتمثيل خصائص أداء النظم الهندسية المختلفة، واستقبال بيانات أداء هذه النظم خلال مرحلة الاستثمار ومعالجتها بهدف توليد مؤشرات أداء (Performance Indicators) يمكن الاعتماد عليها في توجيه سير عمليات الصيانة، وأهم الخصائص المنشودة من آلة الصيانة التنبؤية هي فاعلية التنبؤ المستند إلى خصائص الأداء، والتعامل مع حالات جديدة للبيانات التي ينتجها النظام أو الآلة قيد المراقبة. وترتبط مسألة الصيانة التنبؤية بصورة وثيقة مع مبحث معالجة الإشارات (Signal Processing) كون مصدر البيانات الرئيسي فيها هو إشارات تحسّس الحالة وأنماط الأداء وي طرح مبحث التعلم العميق (Deep Learning) نفسه كخيار فعال في معالجة هذه المسألة كونه منهجاً يتيح تصميم آلات حسابية قادرة على التعلم الذاتي للميزات (Features) والأنماط (Patterns) من البيانات ومنيعه تجاه معالجة أنماط جديدة من البيانات لم تتدرّب عليها، وفي الوقت

نفسه تحقق خاصية التنبؤ والكشف المبكر لظهور الأنماط والميزات في بيانات التشغيل، وذلك يتيح التنبيه إلى الاقتراب من حالات صحية شاذة للنظام أو لآلة الهندسية قيد المراقبة.

2.1. مشكلة البحث:

• توجه الأبحاث في مسألة الصيانة التنبؤية باستخدام التعلم العميق نحو معالجة حالات محددة بمعزل عن عمومية المسألة، وتغليب الطابع الأكاديمي مع عدم وجود استراتيجيات عمل مرجعية قياسية موحدة يمكن اتباعها في معالجة مسألة الصيانة التنبؤية باستخدام التعلم العميق، فالقطاعات التطبيقية التي تتطلب استثمار تقنية الصيانة التنبؤية متنوعة ومختلفة بشكل يجعل عمل مهندس الصيانة التنبؤية يتقاطع مع عمل مهندسي التصميم والتشغيل وتأطير هذه العلاقة يفيد في زيادة الفاعلية.

• بالرغم من امتلاك البنى العميقة مقدرات كبيرة في استخلاص الميزات والأنماط آلياً، إلا أن مراحل استخلاص يدوي وتحويلات لا تزال توضع من قبل الباحثين عند معالجة مسألة الصيانة التنبؤية باستخدام التعلم العميق. حيث تُعدّ النظم والآلات التي تُطبّق فيها الصيانة التنبؤية مصدر بيانات غزير، ويجب على مهندس الصيانة التنبؤية التعامل مع حجم بيانات ضخم ذي محتوى معلوماتي كبير واصف لأنماط تشغيل في أطوار تشغيل مختلفة وحالات أداء صحية متعددة للنظم، وآلة الصيانة التنبؤية (PdM Machine) يجب أن تمتلك القدرة على استخلاص محتوى معلوماتي من بيانات تشغيل النظم التطبيقية وربطه مع معلومات الأداء المثالي والمتدهور لهذه النظم بهدف توليد الخرج المطلوب كمؤشرات أداء (Performance Indicators) بصيغة معلومات سهلة الفهم من المستخدم البشري أو نظام إدارة المنشأة، وذلك يعني استخلاص ميزات (Features) وأنماط (Patterns) من بيانات التشغيل ترتبط مباشرة مع حالات صحية للنظام، وكشف مبكر لنمو هذه الأنماط والميزات قبل أن تتطور حالة النظام إلى عطل كبير.

• توجه الأبحاث في مسألة الصيانة التنبؤية باستخدام التعلم العميق نحو أمثلة البنى العميقة القياسية لتكون أكثر ملاءمة لهذه المسألة، واقتراح بُنى هجينة فيها مراحل تعلم عميق، وبذلك يكون التحليل النظري في تطوير البنى العميقة وتكييفها لمسائل الصيانة التنبؤية محورياً بحثياً مهماً.

3.1. تساؤلات البحث:

- تحديد ماهية المفاهيم الأساسية في تقنية التعلم العميق وإمكانية تأطير عملية تطوير بنى جديدة تناسب مسائل تطبيقية في الصيانة التنبؤية.
- تأطير معالجة مسألة الصيانة التنبؤية باستخدام تقنية التعلم العميق من خلال البحث التحليلي الاستنباطي.
- إمكانية الاستغناء الكامل عن مرحلة الاستخلاص اليدوي للميزات من إشارات تشغيل النظم التطبيقية وآلية أتمتة عملية استخلاص الميزات.
- العلاقة بين مهندس الصيانة التنبؤية كمهندس تعلم عميق والفريق الهندسي المسؤول عن تصميم وتشغيل النظام أو الآلة الهندسية.

4.1. أهداف البحث:

- وضع استراتيجية عامة لمعالجة مسألة الصيانة التنبؤية باستخدام التعلم العميق، بشكل يغطي المراحل المختلفة كصياغة المسألة وتجميع المعلومات وتحصيل البيانات وتصميم البنية العميقة وتدريبها، وفي النهاية استثمار هذه البنية ضمن نظام واقعي.
- تقييم الاستراتيجية المقترحة لمعالجة مسألة الصيانة التنبؤية باستخدام التعلم العميق على حالة تطبيقية.
- وضع استراتيجية عامة لتصميم بنية عميقة مخصصة لمسألة صيانة تنبؤية، من خلال انجاز تحليل في الأسس الرياضية لمبحث التعلم العميق.
- تطبيق الاستراتيجية المقترحة لتصميم بنية عميقة مخصصة لمسألة صيانة تنبؤية، على حالة تطبيقية.

5.1. أهمية البحث:

تعد الصيانة التنبؤية تقنية واحدة مهمة وركناً أساسياً من أركان الجيل الصناعي الرابع، وهي مرشحة لتكون إلزامية في تصميم الآلات الهندسية مستقبلاً، وبتقديم خطوط العمل العامة لتصميم بنى عميقة قادرة على معالجة مسألة الصيانة التنبؤية باستخدام برمجيات مفتوحة المصدر وموارد حاسوبية بسيطة يغدو اعتماد تقنية الصيانة التنبؤية سهلاً ومنظماً ومضمون الفاعلية. واختيار البنى العميقة المناسبة للمسائل المختلفة ومنها مسألة الصيانة التنبؤية

يكون أنجح بعد التّوسّع في الأسس الرّياضيّة لمبحث التعلّم العميق وتقديم منهج رياضي شامل وخصوصاً سياسة تحديد المعاملات الداخليّة للبنية العميقة والمعاملات الوسيطة وخوارزميّة التّدريب، كما يصبح اقتراح البنى الجديدة من قبل الباحثين مرتكزاً إلى أسس رياضيّة مدروسة. ويضاف إلى ذلك تسهيل استثمار البنى العميقة في نظم حاسوبية مختلفة من خلال امتلاك النّموذج الرّياضي الدّقيق القابل للتّطبيق ومحدّد التّعقيد من ناحية التّنفيد الرّمزي.

6.1. حدود البحث:

إن موضوع هذا البحث واسع ومتشعب ولا تكفي دراسة واحدة لتغطية جميع نواحيه ومفرداته، ولذلك تُعالج فصوله مفاهيم وأدوات أساسية مفيدة في معالجة مسألة الصيانة التنبؤية بالتعلّم العميق، سواء تحليلياً أو تطبيقياً، ويّصف البحث بعموميّة النّطاق دون التعميم وبمحاولة وضع تأسيس يمكن الاستناد إليه.

ومسألة الصيانة التنبؤية تنقسم وظيفياً إلى قسمين، الأول هو محور عمل تخصّصي في تصميم الآلات والأجهزة، كالنّصميم الميكانيكي والكهربائي والإلكتروني، وفيه تُجزّز تصاميم منظومات تحسّس الحالة والتحكّم، والمحور الثاني هو محور عمل على مسألة معالجة بيانات لتوليد معاملات توصيف، وهذا البحث يركّز على المحور الثاني بمقاربة تعلّم عميق ويفترض وجود تصميم كامل للآلة الهندسيّة أو الجهاز قبل البدء بمعالجة المسألة.

7.1. منهج البحث وأدواته:

- يتّبع هذا البحث منهجاً استنباطياً تحليلياً تطبيقياً في دراسة موضوع الصيانة التنبؤية وتقنيّة التعلّم العميق، بمراجعة الأدبيات والتّوجّهات البحثيّة، ووضع تحليلات نظريّة باستخدام تقنيّات التحليل المناسبة، ليتمّ اقتراح استراتيجيّات منظّمة عامّة للتّعاطي مع الإشكاليّات البحثيّة. ثمّ ينتقل البحث إلى تطبيق الطّرق والقواعد المستنبطة لمعالجة مسألة الصيانة التنبؤية باستخدام تقنيّة التعلّم العميق على حالات محدّدة (حالة تصميم بنية عميقة تُعالج إشارات ميّزاتها تفاضليّة وحالة رولمان دوّار بسرعات متغيّرة وحالات صحيّة متعدّدة).

- نُفذت التّجارب العمليّة باستخدام مكتبات معالجة الإشارة الرّقمية والتعلّم العميق مفتوحة المصدر مثل (Numpy - Scipy - Matplotlib - Tensorflow - Keras) والتي تُستثمر بلغة (Python) البرمجيّة غرضيّة التّوجّه، وكان الحاسب الشّخصي متوسّط الإمكانيّات كافياً لإتمام التّجارب بزمان مقبول.

8.1. طريقة تنفيذ البحث:

بعد مراجعة الأدبيات والتوجهات البحثية، يتطرق البحث إلى الأسس الرياضية الخاصة بمبحث التعلّم العميق، موضحاً إمكانية تطبيق منهج البرهان الاستقرائي الرياضي في استنتاج قوانين تصميم وتدريب الشبكات العصبونية والبنى العميقة وتعميمها. ومن ثم يتطرق البحث إلى التحليل في مسألة الصيانة التنبؤية كمسألة تعلّم آلة، ويقترح استراتيجية عامة لحل هذه المسألة بتقنيات التعلّم العميق، ويعرض البحث سير عملية تطبيق هذه الاستراتيجية على حالة عنصر آلة ميكانيكي هو رولمان دوار بسرعة دورانية متغيرة زمنياً. وينتهي البحث بتلخيص عدد من النتائج التحليلية والتطبيقية واقتراح محاور بحثية وتجريبية تُقدّر بأن تكون مهمة ومفيدة.

2. أدبيات البحث

1.1.2. الصيانة التنبؤية (PdM):

الصيانة التنبؤية هي مبحث فرعي من هندسة الصيانة، ويُمكن عدّها نوعاً وظيفياً من أنواع الصيانة تُطرح فيه مفاهيم وطرق ومعاملات تُفيد في دعم عمليات الصيانة ككل وتوجيهها، ويرتبط مع خصائص تصميم الآلة أو المنشأة المستهدفة وأدائها، فتطبيق هذه التقنية يرتبط مع بنية الآلة أو المنشأة المستهدفة وقد يضيف إليها، وتطبيق هذه التقنية هو في جوهره مسألة تصميم آلة حسابية تُعالج بيانات دخل لتعطي معلومات تتسم بالخاصة التنبؤية.

1.1.2. الصيانة وهندسة الصيانة (Maintenance & Maintenance Engineering):

تعرّف الصيانة (Maintenance) بأنها مجموعة الأفعال المناسبة التي تتخذ لضمان بقاء الآلة أو التجهيزة في حالة محددة هي حالة الصلاحية للاستثمار، أو لإعادتها إلى هذه الحالة، بينما يعرف مصطلح هندسة الصيانة (Maintenance Engineering) على أنه تطوير المفاهيم والمعايير والاحتياجات التقنية في الطور المفاهيمي بهدف استخدامها واتباعها في طور التشغيل لضمان دعم عمليات الصيانة للتجهيزات.

فرضت هندسة الصيانة على الهيكل التنظيمي للمنشأة الهندسية (Plant Staff Organization) وجود كادر محدّد مسؤول عن عمليات الصيانة ومراقبة كفاءة عمل الآلات والمعدات، كقسم متكامل له خطط عمل وتدريب ومخصّصات من موارد المنشأة حيث يدعى دائرة الصيانة (Maintenance Directory).

تستند دائرة الصيانة إلى خطة الصيانة (Maintenance Plan) وهي مستند رسمي يحدّد الإجراءات الفنية والإدارية التي سيتم اتباعها لمتابعة أعمال صيانة المنشأة وتنظيمها، حيث تقوم الإدارة الفنية للمنشأة بإنجاز دراسة تطبق فيها مفاهيم هندسة الصيانة وأدواتها على هذه المنشأة وتجهيزاتها مراعية طبيعة التجهيزات وما تستلزمه من إجراءات دورية واستعدادات للإجراءات الطارئة كقطع تبديلية احتياطية وعدد مثلاً [1].

تواجه هندسة الصيانة العديد من التحديات أهمّها [2]:

- تقليل تكاليف حالات الانحراف عن الحالات المثالية للتشغيل أو حالات الحاجة إلى الصيانة من خلال مثلاً تخطيط موارد القطع التبدليّة الاحتياطية، وتخطيط قوائم المتعاقدين الخارجيين المناسبين، وتخطيط أزمّة توقّف الآلات والتجهيزات (الدورية والطارئة).
- رفع مستوى استقرار العملية الإنتاجية: استقرار العملية الإنتاجية يساعد على تخطيط هذه العملية ووضع سياسات الإنتاج مثل تخطيط جودة المنتج النهائي وتخطيط كمية الإنتاج، وبطبيعة الحال إن استقرار العملية الإنتاجية مرتبط بصورة وثيقة مع مستوى الاعتمادية الذي تقدّمه الآلات وخطوط الإنتاج ومختلف التجهيزات في ظل سياسات كوادرات الصيانة في المنشأة.
- استثمار العمر التشغيلي للآلات والمعدّات بالصورة الأمثل: وذلك من خلال الالتزام بمنهجيات تشغيل هذه الآلات والمعدّات وما يلزمها من مراقبة وإجراءات دورية بحيث لا يقل زمن استثمارها عن العمر التشغيلي الاسمي.
- دعم سياسات التحسين والتطوير في المنشأة بمعلومات من واقع العمل وبإجراءات تراكمية.

2.1.2. أنواع الصيانة:

توجد في المراجع البحثية تصنيفات متعدّدة لأنواع الصيانة، ولكن يمكن عموماً إرجاع التصنيفات المتعدّدة لأنواع الصيانة إلى ثلاثة أنواع [1]، [4]، [6] :

(1) الصيانة الوقائية (Preventive Maintenance): جميع الأفعال المنجزة بحسب جدول دوري مخطّط محدّد بهدف حفظ التجهيزة في حالة فنية محدّدة من خلال الفحص والترميم، وهذه الأفعال هي خطوات وقائية يتم تنفيذها لتقليل احتمالية العطل أو احتمالية الوصول إلى مستوى غير مقبول من الأداء أكثر ممّا هي تهدف إلى اصلاح الأعطال.

(2) الصيانة التصحيحية (Corrective Maintenance): هي عملية الصيانة غير المخطّطة والتي تهدف إلى إعادة الآلة أو التجهيزة إلى حالة محدّدة، ويتم الشروع بالصيانة التصحيحية بسبب ملاحظة فريق الصيانة حالة عطل أو انخفاض أداء في الآلة، وتسمّى أحياناً الصيانة الرّد-فعليّة (Reactive Maintenance).

(3) الصيانة التنبؤية (Predictive Maintenance): استخدام أدوات علوم الحساب ومعالجة البيانات بهدف تشخيص حالة الآلة أو التجهيزة أو المنشأة أثناء العمل الطبيعي، والتنبؤ بأعطال مستقبلية تستلزم صيانة وقائية محدّدة انطلاقاً من الحالة الحالية لها.

3.1.2. تعريف الصيانة التنبؤية (PdM Definition):

توجد تعريفات متعدّدة للصيانة التنبؤية [5]، حيث تعرّف الصيانة التنبؤية بأنها استخدام أدوات علوم الحساب ومعالجة البيانات بهدف تشخيص حالة الآلة أو التجهيزة أو المنشأة أثناء العمل الطبيعي، والتنبؤ بأعطال مستقبلية تستلزم صيانة محدّدة حالياً انطلاقاً من الحالة الحالية لهذه الآلة أو التجهيزة [1].

كما تعرّف الصيانة التنبؤية بأنها تقنية تتيح مراقبة الحالة التشغيلية بغرض إنتاج بيانات يضمن على أساسها فترات أعظمية بين أعمال الإصلاح وتصغير عدد وكلفة أعمال الصيانة التصحيحية الناجمة عن أعطال الآلة [5].

يعدّ المشرفون على الصناعات ذات المنشآت غزيرة التجهيزات أن حدوث الأعطال غير المتوقعة في منشآتهم هو الخطر التشغيلي الأساسي على استثمارهم في تلك المنشآت، حيث إنّ حصول زمن توقف غير متوقع في المنشأة يسبب أثراً اقتصادياً تدميراً خصوصاً في سلاسل الإنتاج متعددة المراحل ومترابطة التعاقب كصناعة السكر وصناعة الإسمنت، ففي مثل هذه السلاسل الإنتاجية متعددة المراحل يكون تعطل إحدى الماكينات في خط الإنتاج الطويل سبباً في خسارة كمية كبيرة من المواد الأولية وسبباً في انخفاض مستوى جودة المنتج.

ومن ثمّ مستوى اعتمادية وموثوقية البنية التحتية للمنشأة هو عامل أساسي حاسم في الاستثمار الصناعي ككل، ورفع مستوى الاعتمادية والموثوقية للمنشأة يرتبط بصورة وثيقة مع تخطيط عملية الصيانة، فوجود خطة دقيقة وواقعية للصيانة يرفع بصورة كبيرة من وثوقية أداء المنشأة. وكما رأينا مسبقاً، فالصيانة التصحيحية تطبق عند حدوث العطل والصيانة الوقائية تطبق استناداً إلى تحليل السلوك المثالي للمنشأة، بينما تطرح الصيانة التنبؤية نفسها كتقنية واعدة كونها ترتبط مع حالة المنشأة واقعياً ولحظياً [3].

فالصيانة التنبؤية توجّه أعمال كل من الصيانة التصحيحية والصيانة الوقائية [3]، فهي تفعل أعمال الصيانة التصحيحية والصيانة الوقائية استناداً إلى تنبؤات بالأعطال أو تخمينات لتدهور الأداء استناداً إلى مراقبة واقع

المنشأة في الزمن الحقيقي وتحليله مع الأخذ بالحسبان للأداء المثالي للمنشأة وتاريخ أداء المنشأة ([3] الفصل 1.2).

إنّ الصيانة التنبؤية (PdM) منهج يقوم على تحليل المعلومات والبيانات بهدف التنبؤ متى ستحتاج الآلة أو المنشأة إلى صيانة، وهي جزء رئيسي داعم لبرنامج إدارة المنشأة، حيث تكون مهمة الصيانة التنبؤية هي توجيه سير عمل الصيانة التصحيحية والصيانة الوقائية استناداً إلى دراسة واقع أداء الآلات أو التجهيزات وتحليله، وهذا يعطي فاعلية أكبر من نمط العمل التقليدي الذي يعتمد على تنفيذ إجراءات تصحيحية عند وقوع عطل وإجراءات وقائية اعتماداً على تقديرات مجرّدة مثل متوسط عمر زيت التشحيم ومتوسط عمر العوازل المطاطية، وبوجود الصيانة التنبؤية ستكون الإجراءات محفّزة بواقع المنشأة وتجهيزاتها وليس بتخمينات نظرية. ([3] الفصل 1.1)

4.1.2. مصادر البيانات في الصيانة التنبؤية (PdM Data Sources):

يمكن تصنيف البيانات التي تستخدمها آلة الصيانة التنبؤية في صناعة التنبؤات إلى الفئات الآتية ([4] الفصل 4):

(1) بيانات مراقبة الحالة في الزمن الحقيقي (Real-Time Condition Monitoring Data): وهذه البيانات تنقسم بدورها إلى:

■ بيانات المكونات الأساسية في الآلة أو المنشأة من حساسات ومشغلات.

■ بيانات المكونات المضافة إلى الآلة أو المنشأة بغرض مراقبة الحالة.

(2) بيانات البيئة التشغيلية المحيطة مثل بيانات شبكة التغذية الكهربائية وبيانات نظام التدفئة والتكييف.

(3) بيانات الأداء المثالي للتجهيزات، ويعتمد عليها في تقدير تدهور أداء التجهيزات، مثل منحنيات (تيار - عزم) في المحركات الكهربائية ومنحنيات (غزارة - ضغط) في المضخات.

5.1.2. تقنيات مراقبة الحالة بمكونات مضافة (Added Components CM Techniques):

عند تطبيق تقنية الصيانة التنبؤية على الآلات أو المنشآت قد تُضاف حساسات خاصة إلى بنية الآلة أو المنشأة بهدف مراقبة حالة الآلة في الزمن الحقيقي، وهذه الحساسات تُدعى مكونات مضافة كونها لا تدخل في تصميم

حلقات التّحكم في البنية الأساسيّة وتُستخدم فقط لمراقبة حالة التّشغيل وكشف حالات تدهور الأداء في وقت مبكر (2) [الفصل 2.3].

حساسات مراقبة الاهتزاز (Vibration Monitoring Sensors) تُضاف إلى الآلات والعناصر الميكانيكيّة مثل الأجزاء الدوّارة وعلب السّرعة، حيث إنّ أنماط الاهتزازات الميكانيكية التي تنشأ فيها هي مؤشرات دقيقة عن الحالة الفنية لها، ومراقبة أنماط الاهتزازات الميكانيكية الناتجة عن هذه الآلات والعناصر وتحليلها هي وسيلة فعّالة لتشخيص حالة التجهيزات الميكانيكيّة وتطبيق مفهوم الصيانة التنبؤية، حيث تقوم آلة الصيانة التنبؤية بتحليل بيانات الاهتزاز المرتبطة بالحالة الفنيّة للآلة وتقدّم تنبؤات مسبقة عن تدهور هذه الحالة.

يتمّ تحصيل الاهتزازات من نقاط محددة من جسم الآلة الميكانيكيّة بعد تركيب حسّاسات الاهتزاز فيها استناداً إلى دراسة ميكانيكيّة تُحدّد نقاط التّركيب المناسبة وتأخذ بالحسبان تأثير حمل الآلة وسرعة التشغيل على ملف الاهتزازات الناتجة وذلك من أجل تمييز الأنماط الطبيعية للاهتزاز عن الأنماط الشاذة الدالّة على انحراف في الحالة الفنيّة، وعموماً، تظهر معلومات الحالة الفنيّة ضمن الطيف الترددي لبيانات الاهتزاز بصورة أوضح، ومن أمثلة ذلك، عند وجود تشوّه ميكانيكي في نقطة من جزء دوار، تظهر مركبة تردديّة ذات مطال محدّد في طيف إشارة الاهتزاز المحصّلة منه ويكون ترددها متناسباً مع سرعة الدّوران.

الحالة الفنيّة في الآلات ترتبط مع الإصدار الحراريّ المرافق الناتج عنها، وتستخدم تقنية التصوير الحراري (Thermography) لتحصيل بيانات الإصدار الحراريّ من الآلات بهدف تحديد حالتها الفنيّة، حيث تُستخدم كاميرات تصوّر انبعاثات الأشعة تحت الحمراء (Infrared Radiation) المرتبطة مع الطاقة الحرارية المرافقة الناتجة عن الآلة، وتحليل بيانات هذه الانبعاثات يمكن تمييز نقاط زائدة السخونة تشير إلى تدهور الحالة الفنيّة للآلة عن الوضع الطبيعي واقترابها من عطل. وفي تقنية التصوير الحراري تُراعى خصائص الإصدار الحراري لجسم الآلة وتأثيرات البيئة المحيطة في دراسة تحديد نقاط تركيب حسّاسات التصوير الحراري مثل حساسات الحرارة النقطيّة وكاميرات التصوير الحراري، والصّعوبة الأساسيّة في هذه التّقنيّة هي تعذّر الوصول إلى النّقاط الداخليّة في الآلة. ويمكن تقييم أداء الآلات وحالتها الفنيّة بمراقبة الإصدار الصوتي والإصدار فوق الصوتي (Ultrasonic

(Emission) المرافق للتشغيل، وتستخدم حساسات خاصة بمراقبة هذا الإصدار الذي تظهر في طيفه الترددي والزمني معاملات دالة على الحالة الفنية للآلة وتدهور هذه الحالة.

تحليل احتكاك المفاصل (Tribology) هي تقنية لمراقبة الحالة الفنية للآلات وتنفذ بوسائل متعددة مثل تحليل زيت التشحيم (Lubricating oil analysis) مخبرياً أو بواسطة حساسات خاصة، لأن كشف وجود مواد إضافية في زيت التشحيم هو مؤشر على تدهور الأداء، فالشوائب المعدنية تدل على تآكل في الأجزاء الدوارة، ووجود مواد كيميائية تدل على تسرب في دارة التشحيم.

6.1.2. المقاييس المستنتجة في الصيانة التنبؤية (PdM Inferred Metrics):

الصيانة التنبؤية هي مجال بحثي متجدد تقترح فيه نماذج وأطر عمل مختلفة، وكون هذا المجال البحثي يعالج قطاعات صناعية وحالات هندسية متعددة كالآلات الميكانيكية والآلات الكهربائية والنظم الإلكترونية وغيرها، فلا يمكن وضع نموذج موحد أو إطار عمل موحد لتقنية الصيانة التنبؤية، وتتفق معظم الأبحاث والدراسات على تحديد محورين تسترشد الصيانة التنبؤية بهما في تنظيمها المعلوماتي هما (3) [3] الفصل 3.2 - [4] الفصل 5 - [5] الفصل 5.2 - [6] الفصل 3):

1) كشف الانحراف (Anomaly Detection) في الحالة الفنية للتجهيزة أو الآلة أو المنشأة، حيث تنتج آلة الصيانة التنبؤية معاملات دالة على الانحراف تقع ضمن ثلاثة أصناف:

- كشف عطل (Fault Detection): توليد إنذار صريح بوجود عطل أو إشكال فني.
- تحديد عطل (Fault Identification): توليد معلومات تحدد نطاق العطل في بنية الآلة.
- توقع عطل (Fault Prediction): توليد توقع حصول عطل مع تخمين زمني ونطاق إن أمكن.

2) توصيف صحة (Health Indication) الحالة الفنية للتجهيزة أو الآلة أو المنشأة حيث تنتج آلة الصيانة التنبؤية معاملات مثل:

- العمر المفيد المتبقي (Residual Useful Life): وهو زمن مخمن بعده تصبح الآلة أو جزء منها في حالة عطل أو حاجة إلى صيانة.


- مؤشّر صحة (Health Indicator): قيمة كمية نسبية إلى المئة، تعبّر عن الحالة الصحية لأجزاء في الآلة أو للآلة ككل.

7.1.2. نمذجة آلة الصيانة التنبؤية (PdM Machine Modelling):

تُعالج مسألة الصيانة التنبؤية حالة آلة أو منشأة هندسية محدّدة (Asset) تمتلك في الحالة العامّة:

- بنية فيزيائية (Infrastructure) لها خصائص تشغيل (Operation Characteristics) محدّدة، وتعمل في بيئة تشغيليّة ذات خصائص محدّدة، فنظام التغذية الكهربائية مثلاً يُعدّ بيئة عمل للآلة، ومن خصائصه تردد التغذية، جهد التغذية، الاستطاعة الرديّة.
- نظام تحكّم (Control System) مكوّن من عدد من المتحكّمات (Controllers) تتنفّذ إجراءات التحكّم الحسابيّة وتعطي أوامر التشغيل إلى مشغلات الآلة وتستقبل معلومات التشغيل من حسّاسات في الآلة.
- حسّاسات مراقبة حالة مضافة (Condition Monitoring Added Sensors): كحسّاسات الاهتزاز والحرارة والإصدار الصوتي.


ويمكن وضع نموذج عام لمسار المعلومات في الآلة أو المنشأة ذات التّوصيف أعلاه بمخطّط رمزيّ (Symbolic Graph) بالشكل (1-2)، حيث نظام إدارة المعلومات (Information Management System) هو هرميّة المتحكّمات ونظم المراقبة والإدارة، وآلة الصيانة التنبؤية (PdM Machine) هي جزء من هذا النظام.



الشكل (1-2): نموذج مبسّط لجريان المعلومات في منشأة ستطبق فيها صيانة تنبؤية

تُراعى خصائص تشغيل المنشأة (Asset Operation Characteristics)، كخصائص الأداء المثالي وخصائص الأداء المتدهور، في مرحلة تصميم آلة الصيانة التنبؤية لأنها تعبّر عن تطوّر الحالة الفنية للآلة الهندسية أو المنشأة. وخصائص التشغيل عديدة، فمثلاً، تمتلك الآلة الكهربائية وسم استهلاك كهربائي (Machine Electrical Signature) يوصّف طبيعة استهلاك القدرة الكهربائية من قبل الآلة على شكل منحنيات للاستطاعة الكهربائية المستهلكة والتيار الكهربائي المستهلك في حالات التشغيل المختلفة وفي حالات الأعطال وتدهور الأداء، كما تعطي منحنيات الأداء المثالي للآلات، مثل منحنيات عمل مضخات السوائل، معلومات مفيدة عن خصائص التشغيل. يُعدّ التعامل مع خصائص الأداء المتدهور للآلة أو لأجزائها مشكلة أساسية في الصيانة التنبؤية، لأنّ خصائص الأداء المتدهور غالباً لا تتبع نماذج ثابتة ومحدّدة، وفي الوقت نفسه يتمّ تقييم الحالة الصحية للآلة وتوليد معاملات التقييم، مثل الزمن المفيد المتبقي (RUL)، استناداً إلى هذه الخصائص. فمثلاً كشف انحراف معيّن في سلوك الآلة أثناء حالات تشغيل عابرة يشير إلى تدهور أداء (Degradation)، ولكنّ تقدير مدى التدهور يرتبط بوجود معلومات مرجعية عن خصائص الأداء المتدهور.

يمكن رصد تدهور الأداء بتحليل إشارات حساسات مراقبة الحالة وحساسات الحلقات التحكّمية في الآلة على التوازي، مثل حالة ارتفاع مستوى الإصدار الحراريّ من آلة ميكانيكية مترافقاً مع ظهور نمط معيّن في طيف إشارة الاهتزاز ونمط جديد في وسم الاستهلاك الكهربائي. كما أنّ قياس مردود الآلة يفيد في تخمين تدهور الأداء، فمع كشف آلة الصيانة التنبؤية لانخفاض المردود، تدعم الآلة قرار الحكم بوجود تدهور أداء. ويمكن وضع نموذج ابتدائي لآلة الصيانة التنبؤية في الشكل (2-2).



الشكل (2-2): نموذج ابتدائي لآلة الصيانة التنبؤية

8.1.2. مناهج إنشاء آلة الصيانة التنبؤية (PdM Machine Creation Methods):

مسألة الصيانة التنبؤية هي في الشكل العام مسألة تصميم آلة معالجة بيانات تمتلك تمثيلاً لخصائص تشغيل آلة أو منشأة وتدهور أدائها، وتستقبل بيانات تشغيل هذه الآلة أو المنشأة في الزمن الحقيقي، لتولّد معاملات أو مقاييس تعبّر عن الحالة الفنية للآلة أو المنشأة وتوقعات لتطوّر هذه الحالة الفنية. هذه المسألة عموماً يمكن معالجتها بأحد منهجين ([6] الفصل 2.4)، **النمذجة الرياضية للآلة أو المنشأة**، بتصميم نموذج رياضيّ يستوعب المعلومات الأساسية ويستقبل معلومات الحالة ويصنع معلومات الصيانة، أو **بمنهج تعلم الآلة (Machine Learning Method)**، حيث تُجهّز حزم بيانات من قراءات واقعية تجريبية لحساسات الحالة والتشغيل، ومن ثمّ تُصمّم بنية آلة متعلّمة وتُدرّب على هذه الحزم بحيث تصبح قادرة على صناعة معلومات الصيانة.

يقوم منهج النمذجة الرياضية على استخدام تقنيات معالجة الإشارة (Signal Processing) في استخلاص الميزات من معلومات الحالة، كالتحليل الإحصائي الزمني والتحليل الترددي، ومن ثمّ تغذية النموذج الرياضي المنشأ بهذه الميزات من أجل صناعة معلومات الصيانة، وهذا المنهج ينطوي على صعوبات عديدة كالحاجة إلى وجود معرفة دقيقة عن الآلة أو المنشأة تتيح النمذجة الرياضية، ومثل هذه المعرفة غير موجودة في غالب الآلات الواقعية وخصوصاً مع سلوك الإصدار المرافق كالاhtزاز والإصدار الحراريّ، حيث الحالة هنا هي حالة نظام ديناميكيّ متطرّف في تغيير خصائصه ولا خطيّه. كما أنّ النموذج الرياضيّ لابدّ أن يحوي تقريبات (Approximations) ترفع مستوى الخطأ والاعتمادية، والنمذجة الرياضية عموماً تتّصف بمستوى متدنّي من قابلية التعميم على الآلات والنظم الواقعية.

وبالإمكان تجاوز مرحلة النمذجة الرياضية باتباع منهج تعلم الآلة (Machine Learning Method) في معالجة مسألة الصيانة التنبؤية، لأنّ بُنى تعلم الآلة تستوعب خصائص النظم الواقعية بالتدريب على بيانات تجريبية، فتكون مهمة مهندس الصيانة التنبؤية هي التعبير عن خصائص الآلة أو المنشأة بحزم بيانات تدريبية. وتمتلك نظم تعلم الآلة خاصية مهمة بالنسبة إلى مسألة الصيانة التنبؤية، هي التعامل مع الخطأ (Fault-Tolerance)، حيث لا

تنهار بنية الآلة المدربة كآلة صيانة تنبؤية عند مواجهة أنماط بيانات جديدة متطرفة، وهي الحالة العامة في الآلات الهندسية، وهذا يعني تحقيق مستوى عالٍ من التعميم والموثوقية (Dependability & Reusability).

وبذلك تكون الصيانة التنبؤية تقنية حسابية مرتبطة ببنية فيزيائية لآلة أو منشأة محددة، وهذه التقنية هي مجال بحثي تتقاطع فيه عدة تخصصات، ويمكن الفصل بشكل عام بين محورين بحثيين متكاملين للعمل في تقنية الصيانة التنبؤية، الأول هو محور تصميم وتشغيل الآلات والنظم الهندسية المختلفة كالميكانيكية والكهربائية والالكترونية، والثاني هو محور تصميم النظم الحاسوبية القادرة على تنفيذ وظائف تمثيل أداء هذه النظم الهندسية ومحاكاة سلوكها والتنبؤ به، وي طرح التعلم العميق نفسه كمنهج مناسب لتصميم مثل هذه النظم الحاسوبية.

2.2. التعلم العميق (Deep Learning):

يقدم التعلم العميق (Deep Learning)، بوصفه منهجاً متكاملًا في معالجة مسائل تعلم الآلة، العديد من البنى العميقة القياسية القادرة على معالجة مسائل تطبيقية معقدة. واستعراض المفاهيم والطرق والبنى الأساسية في التعلم العميق يشكل تأسيساً للبحث في كيفية استثمار هذا المنهج في معالجة مسائل الصيانة التنبؤية.

1.2.2. تعلم الآلة ودورة حياة الآلة المتعلمة (ML & Learning Machine Lifecycle):

إنّ التعلم (Learning) هو نشاط يكتسب من خلاله المتعلم معرفة جديدة أو مهارة جديدة، ولنجاح عملية التعلم يجب أن يمتلك المتعلم قدرات كالتجريد (Abstraction) والتمثيل (Representation).

ويهتمّ مبحث الذكاء الصناعي (Artificial Intelligence) بدراسة الأسس التي تتيح تصميم نظم حاسوبية قادرة على التعلم، حيث تتبع أدبيات الذكاء الصناعي عموماً منهجين لتصميم مثل هذه النظم، الأول هو المنهج القواعدي بوصفه منهجاً معرفياً يهتمّ بتصميم نظم معرفية آلية قادرة على تحصيل المعرفة من بيئتها، وعلى التعامل مع المسائل الجديدة باستخدام أدوات التحليل المعرفية المنطقية كالقياس والاستقراء والاستنباط، والثاني هو المنهج التجريبي أو منهج تعلم الآلة (Machine Learning Method) الذي يهتمّ بتصميم آلات حسابية تمتلك معاملات داخلية قابلة للضبط خلال مرحلة تصميمية تُدعى مرحلة التدريب، حيث يُعبّر عن خصائص البيئة الواقعية بتحضير حزم بيانات تدريبية تُستخدم في تدريب الآلة الحسابية وضبط قيم معاملات الداخلية بشكل يعطي

الآلة القدرة على معالجة حالات جديدة في المستقبل، ويكون الاهتمام هو بصنع مادة تدريبية حقيقية تعبر عن البيئة التي ستعمل فيها الآلة وليس بوضع نموذج للبيئة [8].

تُبنى مسائل تعلم الآلة على حقيقة أن الأغراض (Objects) الواقعية تتميز عن بعضها بصفات مميزة تُدعى الميزات (Features) حيث يُمكن تعريف الشكل العام للغرض من خلال تحديد عدد من الميزات، وتمييز غرض محدد من خلال حالة كل من هذه الميزات في الواقع، ويُطرح مفهوم العينة (Sample) كترتيب قيم عدد من الميزات يمثل حالة محددة في الواقع، وبذلك يُعرف فضاء كمّي يدعى فضاء الميزات (Feature Space) وكل نقطة فيه تمثل حالة واقعية محددة لغرض، وتكون حزمة البيانات التدريبية (Dataset) مجموعة من العينات التي تمثل حالة أو مسألة معينة [8].

وعموماً تُبنى مسائل تعلم الآلة على ثلاث مسائل بسيطة رئيسية هي التصنيف (Classification) أي وسم عينة بواحد من مجموعة وسوم تسمى أصناف (Classes) تبعاً لموقع العينة في فضاء الميزات، والإرجاع (Regression) أي استنتاج نموذج عام يتبعه توضع العينات في فضاء الميزات، والعقدة (Clustering) أي استنتاج أنماط تشابه العينات بحسب قيم الميزات. والمسألة الرئيسية تُحلل إلى تركيب من عدد من هذه المسائل [14].

وترتكز مسألة تعلم الآلة على أربع ركائز هي بيانات التدريب، موديل الآلة، تابع الكلفة الذي يقيم أداء الموديل، خوارزمية التدريب. ويوجد العديد من بُنى الموديلات القادرة على التعلم ومنها (SVM – Random Forest – KNN) ويركّز هذا البحث على بنية الشبكة العصبونية الاصطناعية (ANN).


توجد أربعة مناهج رئيسية في تعلم الآلة هي:

- التعلم المُشرف عليه أو الموجه (Supervised learning): حيث كل عينة من حزمة بيانات التدريب موسومة من قبل المصمم، وبعد التدريب ستمكّن الآلة من وسم عينات جديدة لم تتدرّب عليها مسبقاً، كحالة مسألة التصنيف والإرجاع.

- **التعلم غير المُشرف عليه أو غير الموجّه (Unsupervised learning):** حيث حزمة بيانات التدريب هي عينات غير موسومة، وتقوم الآلة بتطبيق خوارزميات يقدمها هذا المنهج تمكّنها من إنجاز عمليات مثل العنقدة (Clustering) وتخفيض أبعاد (Dimension Reduction) فضاء الميزات.
 - **التعلم شبه المُشرف عليه (Semi-supervised learning):** حيث حزمة بيانات التدريب هي مزيج من العينات الموسومة وغير الموسومة، ومن أمثلته تدريب نوع من الآلات يدعى المولدات (Generators) على عينات موسومة، وبعد التدريب يكون المولد قادراً على توليد عينات جديدة تشبه العينات التي تدرب عليها ولا تطابقها، وتدعى هذه العملية تضخيم البيانات (Data Amplification).
 - **التعلم المعزز (Reinforcement learning):** وهو يُستخدم في المسائل التي لا يوجد فيها وسوم لعينات التدريب، ولكن توجد معرفة تتيح المفاضلة بين حلول عدّة ممكنة تقدّمها الآلة.
- يمكن النظر إلى مسألة تعلم الآلة على أنها تطبيق احتسابي (Computational Application) خاص وتنعكس خصوصيته على دورة حياته كتطبيق احتسابي، وعموماً تتفق المراجع على تنظيم دورة حياة الآلة المتعلّمة في سبع مراحل متعاقبة [9]، [10]، [11]، [12] ، يمكن أن يكون فيها حلقات عوديّة بحسب المسألة، وهذه المراحل هي:
- (1) **صياغة المسألة (Problem Formation):** تُدرس المسألة وبيئتها الواقعيّة، وإمكانية تحليل المسألة إلى تركيب من المسائل الأساسيّة كالتصنيف والإرجاع والعنقدة.
 - (2) **تحصيل البيانات (Data Acquisition):** تُؤمّن بيانات التدريب المعبرة عن البيئة بإنجاز تجارب عمليّة أو بالأخذ من حزم البيانات المُشاركة بحثياً.
 - (3) **تجهيز البيانات (Data Preparation):** تُنفذ معالجة أوليّة للبيانات (Pre-Processing) تبدأ بتطبيق تحويلات (Transformations) كالتّقييس الإحصائيّ إلى مجال مناسب، والإزاحة إلى متوسط صفريّ، وبعدها تُنظّف البيانات من القيم المتطرّفة والناقصة والمحتوية على أخطاء صياغة، وتُسوّى قيم القياسات لتكون متعادلة بينيّاً في مجالاتها، وقد يُطبّق تخفيض أبعاد (Dimensionality Reduction) بدمج قياسين أو أكثر في

قياس جديد معبر عن ميزات هذه القياسات، باستخدام خوارزميات مثل (Principal Component Analysis).

(4) استخلاص الميزات (Feature Extraction): إن البيانات (Data) هي ترميزات مجردة (Abstract Encodings) وتنفيذ عملية قياس (Measurement) مباشرة في بيئة تعطي بيانات تحتوي معلومات معبرة عن البيئة وحالتها، والميزات (Features) هي معلومات (Information) ذات دلالة بالنسبة إلى نظام إدراكي معين، فمثلاً، الرقم (40) هو تجريد ليس دالاً على أية معلومة ولكن كون نتيجة قياس درجة حرارة جسم الإنسان هي (40) درجة مئوية تجعل هذا التجريد دالاً على معلومة محدّدة، وكون حالة حرارة الجسم عندئذ مرتفعة هي ميزة (Feature) يدركها الطبيب. عملية استخلاص الميزات من بيانات القياسات المباشرة هي مرحلة يتم فيها الانتقال من فضاء قياسات (Measurement Space) إلى فضاء ميزات (Feature Space) نقاطه هي العينات، ويتفق ذلك مع تقسيم (DIKW) لهرمية المعرفة في النظم الحاسوبية كما يوضح الشكل (3-2). وفي المسائل العملية قد تتراكم الميزات بشكل هرمي فتكون ميزة ما مرتبطة بوجود عدد من الميزات



الشكل (3-2): تنظيم عملية استخلاص الميزات

الأبسط، والأبسط بدورها ترتبط بميزات أكثر بساطة، واستخلاص الميزات يتم بالتحليل الرياضي في معظم الحالات وخصوصاً في مسائل معالجة قراءات الحساسات في الآلات الهندسية كون الميزات ترتبط بالخصائص

الرياضية لهذه القراءات، كحالة وجود مركبة ترددية نامية ترددياً في طيف إشارة اهتزاز محور دوار بسرعة متزايدة، دالة على عطب في نقطة من محور الدوران. وتستخدم تقنيات معالجة الإشارة كالتحليل الترددي والتحليل الزمني الترددي والتحليل الإحصائي في استخلاص الميزات.

(5) **تحديد بنية الآلة (ML Structure Determination):** يتم اختيار موديل الآلة الأنسب مع مراعاة عوامل مثل حجم المحتوى المعلوماتي لبيانات التدريب والمقدرة التمثيلية في الموديل والموارد الحاسوبية المتاحة للتصميم والاستثمار.

(6) **التدريب والاختبار (Training & Testing):** تُنظم حزمة بيانات التدريب إلى أقسام تدريب وتحقق واختبار، ويُنفذ التدريب وفق الخوارزمية المناسبة وباستراتيجية مناسبة مثل (K-Fold Cross Validation)، يتوقف التدريب بعد وصول معاملات الأداء إلى قيم مناسبة.

(7) **الاستثمار (Deployment):** القضية الأكثر أهمية في الاستثمار هي تحديد موقع الآلة المدربة في النظام الحاسوبي الخاص بالبيئة الواقعية، ومن ثم تنفيذ الآلة ضمن هذا النظام كنموذج احتسابي محدد المعاملات.

2.2.2 الشبكة العصبونية الاصطناعية وخوارزمية الانتشار الخلفي (ANN & BP Algorithm):

الشبكة العصبونية الاصطناعية (Artificial Neural Network = ANN) هي موديل آلة حاسوبية قادرة على التعلم تم استلهامها من بنية الدماغ البيولوجي كمجموعة كبيرة من العصبونات المترابطة في شبكة، ومن سلوكه في المقدرة على تعديل البنية الداخلية أثناء النشاط، ومبحث الشبكات العصبونية هو فرع من مبحث تعلم الآلة تُطبق فيه آلية ضبط معاملات الشبكة بالتدريب بمرورها في دورة حياة الآلة المتعلمة [13].

والشبكة العصبونية هي شبكة مترابطة كمخطط موجّه (Directed Graph)، عقده هي وحدات حسابية تُدعى العصبونات (Neurons) والعصبون يستقبل شعاع دخل ويولّد قيمة خرج باستخدام العناصر الآتية:

- وصلات (Synapses) يُقرن كل منها بوزن، وكل وصلة تستقبل مركبة من شعاع الدّخل.

- جامع (Adder) يجمع الإشارات الموزونة من الوصلات.

- حد انحياز (Bias) يُضاف إلى مجموع الإشارات الموزونة.

• تابع تفعيل (Activation Function) دخله هو مجموع الإشارات الموزونة مع الانحياز، ويولد خرج العصبون من أجل شعاع دخل معين، ومجال خرج تابع التفعيل يكون $[0 \ 1]$ أو $[-1 \ +1]$ غالباً. تُنظَّم الشبكة العصبونية في تتالي من الطبقات بحيث كل طبقة تمتلك عدداً من العصبونات، ويرتبط العصبون مع عصبونات الطبقة السابقة من خلال وصلاته، وتمتلك الشبكة العصبونية قدرة تمثيلية تناسب مسائل تعلم الآلة التي يجب فيها توليد شعاع خرج يسم شعاع دخل معين، وتؤدي توابع تفعيل العصبونات دوراً أساسياً في إكساب الشبكة القدرة على تمثيل عدم الخطية لأن غياب هذه التوابع يعني اختزال الشبكة العصبونية إلى عصبون وحيد مكافئ [9]. المعاملات المضبوطة في تدريب الشبكة العصبونية هي قيم الأوزان المشبكية والانحياز، وهذه المعاملات يتم تهيئتها بقيم ابتدائية (Weight Initialization) تكون قيم متحول عشوائي ذي توزيع احتمالي عادةً.

الخوارزمية الأساسية لتدريب الشبكة العصبونية هي خوارزمية الانتشار الخلفي (Backpropagation Algorithm)، وهي خوارزمية تدريب موجه تستخدم حزمة بيانات تدريب موسومة وتعتمد تابع خسارة (Loss Function) محدد يمكن بواسطته تقييم أداء الشبكة لأن دخله هو كل من شعاع خرج الشبكة وشعاع وسم عينة الدخل الموافقة لهذا الخرج، وفكرة الخوارزمية هي تكرار حساب قيمة تابع الخسارة من أجل كل عينة تدريب ومن ثم تعديل قيم الأوزان المشبكية بمقدار يتناسب عكساً مع مقدار مساهمة كل وزن في تشكيل قيمة تابع الخسارة التي يُراد أن تكون أصغر ما يمكن في الخطوة التالية أثناء التكرار، فمسألة التدريب تُصاغ على شكل مسألة أمثلة (Optimization) لقيم الأوزان المشبكية نحو قيم صغيرة لتابع الخسارة استناداً إلى عينات التدريب.

آلية خوارزمية (BP) هي تكرار لمسارين للإشارة من أجل جميع عينات التدريب، المسار الأول هو المسار الأمامي (Forward Pass) الذي يتقدم فيه الحساب طبقة تلو الطبقة وصولاً إلى طبقة الخرج ويُحسب فيه خرج كل عصبون، والمسار الثاني هو المسار الخلفي (Backward Pass) الذي يتقدم فيه الحساب بصورة معاكسة بدءاً من طبقة الخرج ووصولاً إلى الطبقة الأولى، ويُحسب فيه من أجل كل عصبون قيمة تابع يدعى المشتق المحلي (Local Derivative). يُطبق مسار أمامي يليه مسار خلفي، وبعد ذلك تُطبق التعديلات على الأوزان المشبكية للعصبونات وفق القوانين الآتية التي تُستنتج رياضياً بحل مسألة الأمثلة المذكورة في الحالة العامة لشبكة عصبونية:

$$\Delta w_{ji}(n) = \eta \cdot \delta_j(n) \cdot y_i(n) \dots (1 - 2)$$

$$\delta_j(n) = \begin{cases} \delta_j^{(1)}(v_j(n)) \cdot e_j(n) & : j \text{ is an output neuron} \\ \delta_j^{(1)}(v_j(n)) \cdot \sum_{k=1}^K (\delta_k(n)) \cdot (w_{kj}(n)) & : j \text{ is a hidden neuron} \end{cases} \dots (2-2)$$

3.2.2. مفهوم التعلّم العميق (DL Concept):

التعلّم العميق (Deep Learning) هو مبحث فرعي من تعلّم الآلة، ويمكن الجزم بأنه فرع من مبحث الشبكات العصبونية لأنّ البنى العميقة هي شبكات عصبونية خاصة تستخدم أدوات الشبكات العصبونية ومفاهيمها.

إنّ نظم تعلّم الآلة (ML Systems) تمتلك القدرة على التعلّم من البيانات الصّرفة (Raw Data) بعد أن يقوم المصمّم البشري بتطبيق عملية استخلاص ميزات من هذه البيانات، وفي مسائل معينة يكون من الصعب أو المستحيل استخلاص الميزات يدوياً من قبل المصمّم، مثل حالات فضاء ميزات ذي درجة بالغة التّعّد وحالات ميزات خفية دقيقة وغير خطية ومضمّنة في حزم بيانات كبيرة الحجم، والتعلّم العميق يتعامل مع هذا النوع من المسائل، وتتفق المراجع التخصّصية على أنّ ما يميّز هذا المنهج عن تعلّم الآلة التقليدي أو التعلّم الضحل (Shallow Learning) هو ثلاث سمات رئيسية [8],[9],[12],[15]:

- إلغاء مرحلة الاستخلاص اليدوي للميزات من البيانات من قبل المصمّم، والاستعاضة عنها بوضع تقدير لطبيعة الميزات وتدرّجها في التجريد والتّركيب الهرمي.
 - استخدام بنية شبكة عصبونية عميقة متعدّدة الطبقات وذات عناصر بنيوية خاصة يقدّمها التعلّم العميق، وتصميم هذه البنية بحيث تُناسب تقدير طبيعة الميزات والمسألة.
 - تدريب الآلة العميقة بحزمة بيانات تدريبية ذات حجم كبير يكفي لضبط معاملاتها الداخلية، لأنّ الآلة العميقة تمتلك عدداً كبيراً من المعاملات الداخلية.
- تنظيم بنية الآلة العميقة هو طبقيّ التّوجّه، حيث يُقدّم التعلّم العميق طبقات بنيوية خاصة للاستخدام في تصميم الآلات العميقة مثل طبقة الطّي (Convolution Layer) والطبقة العودية (Recurrence Layer)، وعموماً تُنظّم بنى الشبكات أو الآلات العميقة في مرحلتين بنيويتين متعاقبتين [8]:

(1) **مرحلة استخلاص الميزات:** وفيها تُرتَّب الطبقات المسؤولة عن استخلاص الميزات آلياً وبشكل ينسجم مع التنظيم المتدرج في التجريد للميزات كترائب هرمي من ميزات بسيطة تتعقّد نحو ميزات المعقّدة.

(2) **مرحلة حلّ المسألة:** وهي مرحلة بنويّة على شكل آلة تعلّم عاديّة قادرة على حل مسألة في فضاء ميزات. تُدرَّب الآلة أو الشبكة العميقة كبنية واحدة في معظم المسائل، مثل حالة الشبكات العصبونية التلافيفية، ولكن توجد بعض الآلات تُدرَّب فيها مرحلة استخلاص الميزات لوحدها بشكل غير موجّه، ومن ثم تُدرَّب الآلة العميقة ككل تدريباً موجّهاً، مثل حالة استخدام شبكات التصديق العميقة كمرحلة استخلاص ميزات.

2.2.4. الشبكة العصبونية التلافيفية (Convolutional Neural Network):

استلهمت بنية الشبكة العصبونية التلافيفية (Convolutional Neural Network) من القشرة البصريّة في الدّماغ (visual cortex) التي تمتلك مناطق خلويّة حسّاسة لمناطق محدّدة من الحقل المرئي، حيث تستجيب عصبونات محدّدة في الدّماغ إلى ميزات محدّدة، فمثلاً، تتفعل عصبونات محدّدة عند وجود خطوط بتموضع معيّن، كاستئثار بعض العصبونات بالخطوط الأفقية وبعض العصبونات بالخطوط المائلة أو العموديّة، والمفهوم الرئيسي في الشبكات التلافيفية هو الحصول على ميزات بسيطة في الطبقات الخفيّة السطحيّة، ومن ثمّ تركيب ميزات أعقد في الطبقات التّالية، وشبكات (CNN) هي الأكثر تعبيراً عن منهج التعلّم العميق لأنّ الشبكة تقوم بعملية استخلاص الميزات من بيانات الدّخل آلياً دون تدخّل من المصمّم خارج إطار وضع مرحلة استخلاص ميزات مُناسبة.

تنفيذ طيّ تابعين زمنيّين يعطي تابعاً زمنياً جديداً طيفه الترددي هو جداء الطيفين التردديين للتابعين، وبالنظر إلى أحد التابعين على أنّه مرشّح (Filter)، يكون ناتج الطي هو إشارة زمنيّة مرشّحة بواسطة هذا المرشّح. هذه الحقيقة تُطبّق في مبحث معالجة الإشارات وهي أساسيّة في عمليّة استخلاص الميزات من الإشارات الفضائيّة (Spatial Signals) كالصور والسلاسل الزمنيّة، لأنّ الكثير من الميزات ترتبط بنمط معيّن في الطيف الترددي للإشارة، يمكن الكشف عن وجوده بترشيح هذه الإشارة بمرشّح ذي قيم مُناسبة، ويكون دور مُستخلص الميزات هو وضع مرشّح ذي قيم مُناسبة لكشف ميّزة منشودة.

بنية شبكة (CNN) تُنظَّم إلى مرحلتين، الأولى هي مرحلة استخلاص ميزات (Feature Extraction) بتوالي طبقات طَيَّ كُلِّ منها يمتلك عدداً محدداً من المرشحات (Filters)، والثانية هي مرحلة تصنيف أو إرجاع وتكون غالباً توالي طبقات كاملة الاتصال كُلِّ منها يمتلك عدداً من العصبونات العادية.

تقوم طبقة الطَيَّ بعملية ترشيح شعاع دخلها مع كُلِّ من مرشحاتها، وكل عملية ترشيح تُنتج شعاعاً جديداً يغذي تابع تفعيل مناسب لنحصل على خارطة ميزات (Feature Map)، وتعمل شبكة (CNN) في نمط رقمي حيث يكون المرشح وشعاع الدَّخْل وخارطة الميزات مصفوفات رقمية، وعملية الطَيَّ في التطبيق العملي تُنفَّذ بحساب (Cross Correlation) بين الدَّخْل والمرشح لتقادي قلب خارطة الميزات الناتجة نسبةً إلى الدَّخْل. وبنية الشبكة العصبونية التلافيفية (CNN) ترتكز على ثلاثة مفاهيم أساسية هي:

- **حقل استقبال محلي (Local Receptive Field):** في الشبكات العصبونية العادية، كل عصبون يتصل مع كل عصبون في الطبقة السابقة، بينما الشبكات التلافيفية تتبع تنظيمياً يتصل فيه المرشح مع منطقة محدَّدة من الدَّخْل فقط تسمَّى حقل الاستقبال المحلي، فالمرشح في طبقة معينة يهتم بوجود أو عدم وجود الميزة التي يختص بها بغض النظر عن مكان تموضعها في شعاع دخل الطبقة.
- **مشاركة الأوزان (Weight Sharing):** تُستخدم المرشحات نفسها لكل حقول الاستقبال في شعاع دخل طبقة.

- **التقصي (Pooling):** التقصي هو عملية حسابية تقلل حجم خارطة الميزات التي ينتجها مرشح معين، من خلال حساب قيمة واحدة معبرة عن عدد من عناصر خارطة الميزات التي كُلِّ منها هو ناتج طَيَّ المرشح مع شعاع دخل الطبقة، وتوجد تقنيات عدَّة لتطبيق التقصي مثل (Max Pooling) حيث يُستعاض عن شعاع من الميزات بالقيمة الأعلى بين عناصر الشعاع، و(Average Pooling) حيث يُستعاض عن شعاع من الميزات بمتوسط قيم عناصر الشعاع.

تُناسب شبكة (CNN) المسائل التي تكون فيها الميزات مرتبطة بأنماط ترددية في القياسات مثل مسائل الإبصار الحاسوبي، والنقطة الأكثر تمييزاً لهذه الشبكة هي عدم الحاجة إلى حساب قيم المرشحات، لأنَّ هذه المرشحات

معاملات داخلية تُضبط بعملية تدريب الشبكة، كما أن توالي طبقات الطّي يُناسب حالات وجود تراكب هرمي متدرّج للميزات.


تُدرّب شبكة (CNN) تدريباً موجّهاً بتعميم خوارزمية (Backpropagation) وتكون قيم خلايا المرشحات من المعاملات المضبوطة خلال التدريب، تُحدّد المسألة التي تُعالجها شبكة (CNN) عدد أبعاد شعاع الدّخل والمرشحات، ففي مسألة تصنيف الصّور يكون الدّخل ثنائي أو ثلاثيّ الأبعاد، وفي مسألة تصنيف السّلاسل الزّمنية يكون الدّخل أحاديّ البعد.

5.2.2. الشبكة العصبونية العودية (Recurrent Neural Network) وتقنيّة (LSTM):

الميزات في مسألة تعلّم الآلة تكون مُضمّنة في البيانات المُحصّلة بالقياس، ويمكن التّمييز بين الميزات الممكن كشفها في قياس واحد، كحالة وجود زاوية في صورة محدّدة، وبين الميزات السياقية (Contextual Features) التي لا يمكن كشفها في قياس واحد وتُكشف برصد تسلسل من القياسات المتعاقبة. تُستخدم الشبكة العصبونية العودية (Recurrent Neural Network) في معالجة البيانات المتضمّنة ميزات سياقية، كونها تمتلك القدرة على حفظ حالة داخلية وتحديثها نتيجة وجود تغذية خلفية من خرج الشبكة إلى عنصر ذاكرة داخليّ فيها. في الشّبكات العميقة يمكن استخدام الطبقة العودية (Recurrence Layer) كطبقة بنيوية، والطبقة العودية تتكوّن من عدد من الخلايا العودية (Recurrent Cells) التي كلّ منها يمتلك عنصر ذاكرة داخليّ تحتفظ فيه بحالة راهنة (State)، وتُحدّث هذه الحالة مع ورود شعاع دخل جديد [9]، واستناداً إلى بنية الخلية العودية الموضّحة بالشكل (2-4) يمكن توصيف المسار الأماميّ للإشارة عبر هذه الخلية في الخطوات الآتية، مع ملاحظة وجود ثلاثة أشعة وزنيّة هي أوزان الدّخل، أوزان الحالة، أوزان الخرج:

- استقبال شعاع دخل.
- حساب الدّخل الموزون بأوزان الدّخل.
- تنفيذ حساب دخله هو الدّخل الموزون والحالة السّابقة المحفوظة في عنصر تأخير زمني.
- حساب قيمة الحالة الجديدة بتوزين الخرج الحسابيّ السّابق بأوزان الحالة.

- حساب قيمة خرج الخلية النهائي بتوزيع الخرج الحسابي السابق بأوزان الخرج.




الشكل (2-4): بنية الخلية العودية (Recurrent Cell) [16]

ورياً تصوغ المعادلتان الآتيتان آلية المسار الأمامي في خلية عودية فيها الخرج في اللحظة (t) يعتمد على قيمة شعاع الدّخل في هذه اللحظة وعلى قيمة شعاع الحالة الداخلي في اللحظة السابقة:

$$\mathbf{h}(t) = \phi_h \left(\mathbf{W}_i^h \cdot \mathbf{x}(t) + \mathbf{W}_h^h \cdot \mathbf{h}(t-1) \right) \dots (3-2)$$

$$\mathbf{y}(t) = \phi_o \left(\mathbf{W}_h^o \cdot \mathbf{h}(t) \right) \dots (4-2)$$

ونتيجةً لوجود مميزات سياقية في حزمة بيانات تدريب الشبكة العودية فإن ترتيب العينات يتم الحفاظ عليه، وتُدرّب



الشكل (2-5): الخلية العودية بعد نشرها عبر الزمن [16]

الشبكة العودية باستخدام خوارزمية تناسب بنيتها وآلية عملها، والخوارزمية الأكثر استخداماً هي خوارزمية الانتشار

الخلفي عبر الزمن (Backpropagation Through Time) التي تنطلق من فكرة أنه عند تطبيق سلسلة جزئية محدّدة من بيانات التدريب على الخلية يوجد شبكة أمامية مكافئة تماماً لهذه الخلية نحصل عليها من خلال نشر (Unfolding) هذه الخلية زمنياً كما يوضح الشكل (2-5).

خوارزمية (BPTT) تُشبه خوارزمية (BP) من حيث تعريف تابع خسارة (Loss Function)، وأمثلة قيم أشعة الأوزان خلال تطبيق عينات التدريب بصورة متعاقبة بحيث تُصبح قيمة تابع الخسارة أصغر ما يمكن، وبالتحليل الرياضي، يمكن الوصول إلى قوانين حساب قيم تعديل الأوزان.

تُعاني الشبكات العودية في شكلها الأساسي من مشكلة تظهر عندما يُطلب من الشبكة أن تحتفظ في ذاكرتها تمثيلاً للمعلومات البعيدة زمنياً عن الخرج في نهاية سلسلة تدريبية طويلة، والسبب الرئيسي في ذلك هو تعرّض قيم المشتقات المحلية المنتشرة خلفياً في المسار الخلفي أثناء التدريب إلى التناهي في الصغر أو التناهي في الكبر، ممّا يجمّد عملية تحديث الأوزان أو يجعلها ضئيلة الأثر. ففي قوانين التعديل الوزني المذكورة أعلاه مثلاً، يُلاحظ وجود حساب جداء سلسلة من قيم المشتقات وهذا الجداء عُرضة للتناهي في الصغر (Vanishing) أو الكبر (Exploding) ممّا يهدّد بانهياء عملية التدريب.

تُدعى هذه المشاكل باسم (Vanishing Gradient) و (Exploding Gradient)، وأنجح حلولها هو تطبيق مفهوم البوابات (Gates) في تصميم بنى طبقات عودية قادرة على حفظ معلومات سياق طويل دون تناهي التدرّج. والبوابة (Gate) هي عامل تقيس يُطبّق على متحوّل حالة الخلية العودية، وتأخذ البوابة قيمةً بين الصفر إلى واحد. إحدى هذه البنى هي خلية (LSTM) أو (Long Short Term Memory) التي تمتلك القدرة على الاحتفاظ بحالات قديمة من خلال انتخاب حالتها الداخلية وتقييمها قبل تحديث هذه الحالة وتحديث الخرج، بشكل يتيح حفظ معلومات سياق طويل، كونها تمتلك ثلاث بوابات داخلية هي بوابة النسيان (Forget Gate) وبوابة التذكّر (Remember Gate) وبوابة الاختيار (Select Gate). بنية خلية (LSTM) يوضحها الشكل (2-6)، والمسار الأمامي للإشارة فيها تحدّد المعادلات الآتية:

$$\sigma_f(t) = \sigma(W_f \cdot x(t) + R_f \cdot y(t-1) + b_f) \dots (5-2)$$

$$\tilde{h}(t) = g_1(W_h \cdot x(t) + R_h \cdot y(t-1) + b_h) \dots (6-2)$$

$$\sigma_u(t) = \sigma(W_u \cdot x(t) + R_u \cdot y(t-1) + b_u) \dots (7-2)$$


$$h(t) = \sigma_u(t) \odot \tilde{h}(t) + \sigma_f(t) \odot h(t-1) \dots (8-2)$$

$$\sigma_o(t) = \sigma(W_o \cdot x(t) + R_o \cdot y(t-1) + b_o) \dots (9-2)$$

$$y(t) = \sigma_o(t) \odot g_2(h(t)) \dots (10-2)$$

الجدول (1-2): دلالات رموز النموذج الرياضي للمسار الأمامي في خلية (LSTM)

$x(t)$	شعاع دخل الخلية في اللحظة (t)
$y(t)$	شعاع خرج الخلية في اللحظة (t)
$h(t)$	شعاع حالة الخلية في اللحظة (t)
$\odot$	جداء على مستوى العنصر بين مصفوفتين (Hadamard product)
W_f, W_h, W_u, W_o	مصفوفات أوزان ارتباط شعاع الدّخل مع عصبونات الخلية الداخليّة
R_f, R_h, R_u, R_o	مصفوفات أوزان التّغذية الخلفيّة من خرج الخلية السّابق للّحظة (t)
b_f, b_h, b_u, b_o	أشعة انحياز
$\sigma(\cdot)$	تابع (sigmoid)
$g_1(\cdot), g_2(\cdot)$	توابع تفعيل توضع عادةً (hyperbolic tangent)
$\sigma_f(t)$	بوابة النسيان (Forget Gate)
$\tilde{h}(t)$	الحالة المرشحة دون تقييس
$\sigma_u(t)$	بوابة التذكّر أو التّحديث (Update or Remember Gate)
$\sigma_o(t)$	بوابة الاختيار أو الخرج (Select or output Gate)



الشكل (2-6): بنية خلية (LSTM)


6.2.2. المرّمز الآلي العميق (Deep Auto-Encoder):

المرّمز الآلي (Auto-Encoder) هو بنية آلة متعلّمة تستخدم مفهوم ضغط البيانات (Data Compression) حيث يمكن ترميز (Encoding) بيانات معيّنة بخوارزمية ترميز إلى صيغة مضغوطة ذات حجم أقل من الأصل ولاحقاً يمكن استعادة هذه البيانات بفكّ ترميز (Decoding) البيانات المضغوطة بخوارزمية معاكسة، ويحقّق أيّ ضغط بيانات جودة (Quality) معيّنة تتعلّق بمدى ضياع الميزات بعد الضّغط وفكّ الضّغط، ويحاكي المرّمز الآلي (Auto-Encoder) خوارزمية ضغط بيانات آليّة من خلال توليد صيغة مضغوطة تقابل شعاع دخله، ويمكن إعادة توليد شعاع الدّخل من هذه الصّيغة بواسطة المرّمز الآلي نفسه، ويمكن اعتبار هذه الآليّة استخلاصاً آلياً للميزات من البيانات لأنّ الصّيغة الوسيطة المولّدة آلياً واصفة لشعاع الدّخل وبحجم مضغوط [9].

بنية المرّمز الآلي (Auto-Encoder) تُنظّم في مرحلتين متعاقبتين، مرحلة التّرميز وتليها مرحلة فكّ التّرميز، تربطهما طبقة وسيطة تسمّى طبقة الرّمز، وكلّ من هاتين المرحلتين هو عبارة عن شبكة عصبونية كما يوضّح الشّكل (7-2)، وعادةً يكون حجم مرحلتي التّرميز وفكّ التّرميز متطابقاً وفي الوقت نفسه التّنظيم متعاكس ويكون حجم شعاع التّرميز المولّد أصغر من شعاعي الدّخل والخرج المتطابقان بحيث:

- دخل مرحلة التّرميز هو شعاع دخل (X) من أشعة دخل المرّمز الآلي، وخرجها هو رمز أو تمثيل (Coding or Representation) جديد (h) لهذا الشّعاع.

- دخل مرحلة فكّ التّرميز هو الرّمز (h) أو التّمثيل الجديد لشعاع الدّخل، وخرجها هو شعاع يطابق شعاع دخل مرحلة التّرميز.



الشّكل (7-2): تنظيّم بنية المرّمز الآلي

يقوم المرّمز الآلي بإنشاء تمثيل جديد لكل شعاع دخل يغذّى به في مرحلة التّرميز، ومن ثمّ يقوم بإعادة بناء شعاع الدّخل من هذا الرّمز، وتتحقّق هذه الآلية بعد تدريب المرّمز الآلي تدريباً غير مشرف عليه (Unsupervised)

(Training) بحزمة كافية من أشعة الدّخل غير الموسومة (Unlabeled Dataset) وهذا ما يضبط الأوزان الداخليّة في مرحلتي التّرميز وفكّ التّرميز، وغالباً تكون خوارزمية التّدريب هي خوارزمية (BP) بالرّغم من عدم وجود وسوم لأشعة دخل التّدريب، وذلك من خلال تعريف تابع الخطأ على أنّه الفرق بين شعاع الدّخل والشّعاع المعاد بناؤه، أي خرج المررّز الآلي المنشود هو نفسه دخله، وهذه الآلية تضمن توليد المررّز الآلي لرموز تعبّر عن أشعة الدّخل.

تُستخدم بنية المررّز الآلي في عمليّات مثل تصغير أبعاد (Dimensionality Reduction) حزمة بيانات واستخلاص ميّزات (Feature Extraction) من حزمة بيانات وإزالة الضّجيج (Noise Removal) من حزمة بيانات، كما يُمكن استخدام المررّز الآلي كمولّد بيانات (Generator) في بعض حالاته.


المررّز الآلي العميق (Deep Auto-Encoder) هو مررّز آلي تدخل في بنيته الطّبقات البنيويّة العميقة كطبقات الطّي والخلايا العوديّة طويلة الأمد، والتّحدّي التّصميمي الأكبر في تصميم مررّز آلي عميق هو تحديد أبعاد الرّمز الوسيط المولّد، لأنّ طبيعة الميّزات الموجودة في بيانات الدّخل تكون غير محدّدة بدقّة، وغالباً يتمّ أمثلة أبعاد الرّمز الوسيط الأنسب تجريبياً، ولتحقيق التّقابل بين بنيتي مرحلة التّرميز وفكّ التّرميز قد تُستخدم بنى طبقات عميقة خاصّة مثل طبقة الطّي المعاكس (De-Convolutional Layer) في المررّز الآلي العميق ذي طبقات الطّي.

7.2.2. شبكة التّصديق العميقة (Deep Belief Network):

تُعالج شبكة التّصديق العميقة (Deep Belief Network) المسائل التي يكون في بياناتها ميّزات ذات طبيعة تتبع توزيعات احتماليّة معيّنة، وبنية (DBN) هي تكديس لبنى آلة بولتزمان المقيدة (Restricted Boltzmann Machine)، و(RBM) هي موديل مولّد (Generative Model) قادر على أن يتعلّم توزّعاً احتمالياً (Probability Distribution) على مجموعة مداخله، بنيته هي طبقتان من العصبونات كاملتا الاتّصال، مع حفظ شرط التّقيد بمنع الاتّصال بين أيّ عصبونين في الطبقة نفسها، هما [15]:

- طبقة مرئيّة (Visible layer) تستقبل شعاع دخل (v) بطول (m).

• طبقة خفية (Hidden layer) تولّد شعاع خرج (h) بطول (n).



الشكل (2-8): بنية شبكة (RBM)

ليس من الضروري أن يكون عدد عصبونات الطبقة المرئية يساوي عدد عصبونات الطبقة الخفية، والمعاملات المضبوطة في تدريب آلة (RBM) هي قيم مصفوفة الأوزان البينية (W) بين عصبونات الطبقتين الخفية والمرئية، والانحياز الخاص بكل عصبون، وآلية عمل آلة (RBM) تُنظّم في مسارين، مسار صاعد من الطبقة المرئية إلى الطبقة الخفية يولّد فيه ترميز يقابل شعاع الدّخل، ومسار هابط من الطبقة الخفية إلى الطبقة المرئية يُعاد فيه توليد شعاع الدّخل، ففي أثناء مرحلة التدريب تُضبط الأوزان بحيث تُرجّح أكثر احتمالية توليد بيانات التدريب ذاتها دوماً، حيث الشعاع المرئي (v) هو شعاع بيانات الدّخل، بينما الشعاع الخفي (h) يمثل حالات الطبقة الخفية والتي تعبّر عن ميزات خفية (Hidden Features) متضمّنة في شعاع الدّخل، ويُحسب التوزيع الاحتمالي على زوج (v, h) من وحدة خفية ووحدة مرئية بالمعادلة الآتية:

$$p(v, h) = \frac{e^{-E(v, h)}}{\sum_{v, h} e^{-E(v, h)}} \dots (11 - 2)$$

$$E(v, h) = - \sum_i a_i v_i - \sum_j b_j h_j - \sum_i \sum_j v_i w_{ij} h_j \dots (12 - 2)$$

$$E(v, h) = -a^T v - b^T h - v^T W h \dots (13 - 2)$$

ويوضّح الجدول (2-2) دلالات الرّموز في هذه المعادلات.

الجدول (2-2): دلالات حدود معادلات توصيف شبكة (RBM)

طاقة الترتيب (Configuration Energy) للشعاعين (v, h)	$E(v, h)$
حد انحياز في عصبون طبقة مرئية (i).	a_i
حد انحياز في عصبون طبقة خفية (j).	b_j

w_{ij}	الوزن المشبكي بين عصبون الدّخل (i) وعصبون الخرج (j).
v	شعاع الطبقة المرئية
h	شعاع الطبقة الخفية

ومن أجل شعاع بيانات (v)، يكون الاحتمال الشرطي لتفعيل وحدة في الطبقة الخفية هو:

$$P(h_j = 1 | v) = \sigma \left(b_j + \sum_{i=1}^m w_{ij} \cdot v_i \right) : \sigma(x) = \frac{1}{1 + e^{-x}} \dots (14 - 2)$$

ومع كون أحداث تفعيل الوحدات الخفية مستقلةً متتوياً نتيجة شرط عدم الاتصال البيني بين عصبونات طبقة معينة، وكذلك أحداث تفعيل الوحدات المرئية، فيمكن استخدام الوحدات الخفية لإعادة بناء شعاع الدّخل بتفعيل الوحدات المرئية من خلال الاحتمالات الشرطية:

$$P(v_i = 1 | h) = \sigma \left(a_i + \sum_{j=1}^n w_{ij} \cdot h_j \right) \dots (15 - 2)$$

ويكون:

$$P(v | h) = \prod_{i=1}^m P(v_i | h) \dots (16 - 2)$$

$$P(h | v) = \prod_{j=1}^n P(h_j | v) \dots (17 - 2)$$

تُدرّب آلة (RBM) بشكل يُحسن قدرتها على إعادة بناء أشعة الدّخل، والتدريب هو تدريب غير موجه يتم بخوارزميات أشهرها هي خوارزمية (Contrastive Divergence)، حيث تُستخدم حزمة بيانات تدريب كمصفوفة (V) كل سطر منها هو شعاع دخل مرئي (v)، ويهدف التدريب إلى أمثلة قيم الأوزان والانحياز التي تجعل جداء الاحتمالات الآتي أكبر ما يمكن:

$$\operatorname{argmax}_w \prod_{v \in V} P(v) : P(v) = \frac{\sum_h e^{-E(v,h)}}{\sum_{v,h} e^{-E(v,h)}} \dots (18 - 2)$$

وبذلك تهدف خوارزمية (Contrastive Divergence) إلى أمثلة قيم الأوزان التي تجعل طاقة الشعاع (v) أصغر ما يمكن ومجموع طاقات بقية الأشعة أكبر ما يمكن، وبفرض أنّ معامل الوزن المضبوط هو:

$$\theta \in \{a_i, b_j, w_{i,j}\}$$

فيُحسب مشتق تابع خطأ بالنسبة لهذا المعامل وليكن التابع اللوغاريتمي:

$$\frac{\partial \log(P(v))}{\partial \theta} = - \sum_h p(h | v) \frac{\partial E(v, h)}{\partial \theta} + \sum_{v, h} p(v, h) \frac{\partial E(v, h)}{\partial \theta} \dots (19 - 2)$$

عندئذٍ يمكن صياغة خوارزمية (Contrastive Divergence) في الخطوات الآتية:

(1) اختيار شعاع تدريب $(v(0))$.

(2) حساب $(h(0))$ الموافق له:

$$P(h | v) = \prod_{j=1}^n P(h_j | v)$$

(3) حساب $(v(1))$ المُعاد بناؤه:

$$P(v | h) = \prod_{i=1}^m P(v_i | h)$$

(4) حساب $(h(1))$ الموافق له كما سبق.

(5) تحديث الأوزان الداخلية كما يأتي مع اعتماد معامل تعليم (η) :


$$\Delta w_{i,j} = \eta (v_i(0) \cdot h_j(0) - v_i(1) \cdot h_j(1))$$

$$\Delta b_j = \eta (h_j(0) - h_j(1))$$

$$\Delta a_i = \eta (v_i(0) - v_i(1))$$

(6) تكرار الخطوات (1-5) من أجل كل من أشعة التدريب.

وشبكة التصديق العميقة (DBN) هي تكديس وحدات (RBM) كما يوضح الشكل (2-9).



الشكل (2-9): بنية شبكة التصديق العميقة (DBN)

تُدرَّب شبكة التصديق العميقة على مرحلتين، في المرحلة الأولى تُدرَّب وحدات (RBM) بخوارزمية (Contrastive Divergence) بشكل تصاعدي يبدأ بالوحدة الأولى وبعد إتمام تدريبها ينتقل إلى الوحدة التالية، وهكذا حتّى نهاية تدريب كل الوحدات، وفي المرحلة الثانية تتم أمثلة بنية الشبكة المدربة بشكل موجّه يعتمد على الانتشار الخلفي ومعلومات المصمّم عن حزمة بيانات التدريب والوسوم المناسبة لأشغتها.

8.2.2. الشبكة المولدة النديّة (Generative Adversarial Network):

الشبكة المولدة النديّة (Generative Adversarial Network) تتكوّن من شبكتين عميقتين موضوعتين كنّدين بشكل يهدف إلى أن تولّد إحدى الشبكتين، وتُدعى المولّد (Generator)، عيّانات جديدة مختلفة عن عيّانات حزمة التدريب ولكن بالوقت نفسه تشبه عيّانات التدريب إلى درجة أنّ الشبكة الثانية، وتُدعى المميّز (Discriminator)، لا تستطيع التمييز بين العيّنة المولدة وعيّانات حزمة التدريب الأصلية، وعادةً تُستخدم بنية ثالثة في ضمّ المولّد والتمييز إلى بنية واحدة عميقة. بعد تدريب شبكة (GAN) سوف يكون بالإمكان توليد أيّ عدد نريده من العيّانات الجديدة والمشابهة لعيّانات التدريب وبالوقت نفسه مختلفة عنها. تُدرَّب شبكة (GAN) على جلسات (Rounds)، في كلّ جلسة يتمّ:

- تدريب المميّز على عيّانات أصلية وضبط أوزانه حتّى يصل إلى مرحلة التّصنيف الصّحيح.
- تحفيز المولّد على توليد عيّانات مزيفة ومن ثمّ تغذية المميّز بها، فإذا صنّفها المميّز مزيفة تُضبط أوزان المولّد كونه أخطأ في خداع المميّز.
- تحفيز المولّد على توليد عيّانات مزيفة ومن ثمّ تغذية المميّز بها، فإذا صنّفها المميّز على أنها صحيحة تُضبط أوزان المميّز كونه أخطأ في تمييز الخدعة.
- تكرار التّسلسل النّديّ السّابق حتّى الحصول على العيّانات المُصطنعة المقبولة من قبل المصمّم.

ويتوضّح في هذا الفصل الطّابع الرّياضيّ الدقيق في منهج التعلّم العميق، والتّنوّع الكبير في البنى العميقة وإمكانات أمثلتها وأمثلة تدريبها وتصميمها، وسوف تُوضّح توجّهات البحث في معالجة مسائل صيانة تنبؤية

باستخدام التعلّم العميق حقيقة كون التعلّم العميق منهجاً مناسباً وناجحاً في هذه المسائل، والبحث فيه من منظور هذه المسائل هو محور بحثي مهم.

3.2. توجهات البحث في معالجة مسألة الصيانة التنبؤية بالتعلّم العميق (Handling) :(PdM by DL Research Trends)

إنّ معالجة مسألة الصيانة التنبؤية باستخدام تقنيات تعلّم الآلة عموماً، والتعلّم العميق خصوصاً، هو مجال بحثي فاعل تُنشر فيه العديد من الدراسات والتجارب من قبل الباحثين، وتُستثمر جميع البنى العميقة القياسية في الأبحاث المختلفة التي تعالج مسائل صيانة تنبؤية.

تأخذ بعض هذه الأبحاث المنحى التأسيسي الإرشادي الذي يتناول المسألة بدرجة معينة من العمومية، والمهتم بتقديم الأدوات وشرح المفاهيم الرئيسية. ففي أطروحة لنيل درجة الماجستير بعنوان (دراسة في تعلّم الآلة والصيانة التنبؤية [5]) مقدّمة في الجامعة النرويجية للعلوم والتكنولوجيا، بدأت الدراسة ببحث نظريّ في موضوعات الصيانة التنبؤية، تعلّم الآلة، نقل التعلّم، الشبكات العصبونية، لتنتقل بعدها إلى تجربة عملية لآلة تخمّن الزمن المفيد المتبقي (RUL) لمحرك تريبوفان تُتاح حزمة بيانات أدائه من وكالة ناسا، حيث صيغت مسألة قيمة (RUL) كمسألة إرجاع (Regression)، مع اعتماد أنّ هذه القيمة هي عدد دورات تشغيل المحرك المتاحة قبل أن يدخل المحرك في حالة عطل، ومن ثمّ حُلّت المسألة بشبكة عصبونية أمامية (FNN).

وفي أطروحة لنيل درجة الدكتوراه مقدّمة في الجامعة النرويجية للعلوم والتكنولوجيا قسم الهندسة الميكانيكية والصناعية بعنوان (مقاربات معتمدة على التعلّم العميق من أجل الصيانة التنبؤية [6])، كان هدف الدراسة هو تصميم إطار عمل (Framework) متكامل يفيد في تطبيق مفهوم الصيانة التنبؤية في أيّ منشأة، حيث بدأت الدراسة بتعريف مفهوم الصيانة التنبؤية من حيث موقعها ضمن ترتيب منهج الجيل الصناعي الرابع (Industry 4.0) وعلاقتها بالصيانة الوقائية والتصحيحية والمكاسب المحققة بتطبيق منهج الصيانة التنبؤية، وبينت الدراسة تعدّد الأبحاث في معالجة مسألة الصيانة التنبؤية بتقنيات تعلّم الآلة والتعلّم العميق، وكذلك فاعلية التعلّم العميق في النّعاطي مع بيانات التشغيل والتشخيص الضخمة، وبعد استعراض بنى آلات عميقة استُخدمت في معالجة

مسألة الصيانة التنبؤية، وضعت الدراسة توصيفاً لمجالات فاعلية عدد من البنى العميقة الأساسية في معالجة بيانات الصيانة يعرضها الجدول (2-3).


الجدول (2-3): مجالات فاعلية البنى العميقة الأساسية في معالجة بيانات الصيانة، [6]

البنية	مجال الفاعلية في معالجة بيانات الصيانة
Deep FNN	ربط تدهور الأداء بأشعة الدّخل، وكشف الأعطال عند توفّر حجم كافٍ من بيانات التشغيل التاريخية الموسومة.
SAE	تتجيم خصائص الأعطال، واستخلاص الميّزات والمعلومات عن الأعطال من البيانات الخام، وتصغير أبعاد فضاء دخل الآلة من القياسات.
DBN	تتجيم المعلومات المخفية في بيانات تشغيل مترابطة.
LSTM	معالجة سلاسل بيانات الدّخل الزمنية والقدرة على استخلاص الميّزات السياقية.
CNN	مقدرة قوية على استخلاص الميّزات من حزم بيانات ضخمة، وخصوصاً البيانات الصورية، بالإضافة إلى المقدرة على تعلّم تمثيلات مفيدة للميّزات من خلال عمليات الطّي والإدراك المتدرّج حيث بنية (CNN) تنتج أنماط معبرة قوية في خارطات الميّزات (Feature Maps) تمثّل صحة الآلة الفيزيائية.

ثمّ عالجت الدراسة مسألة تصميم إطار عمل (Framework) لتطبيق الصيانة التنبؤية ضمن مفاهيم الجيل الصناعي الرابع (Industry 4.0)، مستعرضة تحديات مهمّة تواجهها آلة الصيانة التنبؤية كوجود مستوى ولوج إلى البيانات (Data Access) عالٍ، وضرورة التعامل مع نظم هندسية مختلفة المصادر والمصنّعين، ولزوم القدرة على التعامل مع بيانات صناعية ضخمة، وضرورة كون توقّعات آلة الصيانة التنبؤية على درجة عالية من الموثوقية. حيث اقترحت الدراسة تنظيمًا عامًّا لإطار العمل من مستويات عدّة، وفيه مستوى خاص بتحديد وتوقّع الأعطال (Failure Prediction and identification) يُنظّم إلى المراحل الآتية، والتي يوضّحها الشكل (2-10):

- معالجة أوليّة (Preprocessing) للبيانات.
- استخلاص ميّزات (Feature Extraction) من البيانات.
- آلة تشخيص (Diagnosis Machine) حسابية مهمتها:

- كشف الأعطال (Fault Detection).
- تحديد الأعطال (Fault Identification).
- آلة تنبؤ (Prognosis Machine) حسابية مهمتها:
- توقع الأعطال (Fault Prediction).
- تخمين تدهور الأداء (Degradation Assessment).



الشكل (2-10): تنظيم مقترح لمستوى تحديد الأعطال وتوقعها من إطار عمل للصيانة التنبؤية [6]


كما بينت دراسة بعنوان (مراجعة في مراقبة الصحة البنيوية المعتمدة على إشارات الاهتزاز باستخدام التعلم العميق [22]) أن جميع بنى التعلم العميق الشائعة تقريباً تستخدم في مجال تشخيص الأعطال والتنبؤ بها باستخدام إشارات الاهتزاز الميكانيكي، وتتفوق هذه البنى على بنى تعلم الآلة الكلاسيكية، كما تكون معظم البنى المستخدمة بنى هجينة مثل (CNN-LSTM) و (AE-LSTM)، وعرضت الدراسة مزايا ومساوئ عامة تظهر عند استخدام البنى العميقة الأساسية في معالجة إشارات الاهتزاز بهدف التشخيص، يلخصها الجدول (2-4) باختصار.

الجدول (2-4): فاعلية البنى العميقة الأساسية في مسألة الصيانة التنبؤية، [22]

البنية	المزايا	المساوئ
AE	سهولة الإنجاز وسهولة تتبع الكلفة والخطأ أثناء التدريب.	لزوم حجم ضخم من بيانات التدريب.
DBN	فعالة في معالجة البيانات وحيدة البعد واستخلاص الميزات العامة من بيانات خام.	بطيئة في التدريب.
CNN	فعالة في معالجة البيانات متعددة الأبعاد وفعالة في استخلاص الميزات المحلية.	معقدة البنية وتستلزم زمن تدريب طويلاً وحجماً حسابياً كبيراً.
RNN	فعالة في معالجة البيانات التسلسلية.	صعوبة في الإنجاز والتدريب.


فيما يأتي، سيُعرض عدد من الأبحاث التطبيقية التي تُعالج مسائل صيانة تنبؤية بالتعمق العميق، لينتم التوصل إلى عدد من التوجهات والسمات العامة.

في الأطروحة [6] أُنجِزت دراسة حالة تفصيلية لاستخدام الصيانة التنبؤية في معالجة مشكلة خطأ الحركة الارتجاجية (Backlash Error)، باستخدام بنموذج مكون من شبكة تصديق عميقة (DBN) تليها طبقة قرار عصبونية أمامية كما يوضح الشكل (2-11)،



الشكل (2-11): بنية معالجة مسألة خطأ الحركة الارتجاجية، ونتائج تنبؤ فعلي [6]

وفي الحالة السابقة تظهر أهمية الارتباط بين الدراسة الهندسية التصميمية للآلة وتصميم البنية العميقة كآلة صيانة تنبؤية، وكذلك في الأطروحة نفسها [6] تمت معالجة مسألة كشف انحراف في أداء آلة ميكانيكية دوارة مخبرية استناداً إلى خطأ إعادة بناء إشارة اهتزاز بواسطة بنية (SAE-LSTM) منظمة وفق الشكل (2-12)، وبالرغم من جودة أداء الآلة العميقة المصممة، وكون دقة كشف الانحراف من رتبة (95%) في كل حالات التشغيل، إلا أنّ سير إنجاز هذه الحالة يُظهر عدم التركيز على العلاقة بين الدراسة الهندسية التصميمية للآلة الميكانيكية وتصميم البنية العميقة.




الشكل (2-12): بنية (SAE-LSTM) مستخدمة في كشف انحراف أداء آلة دوارة [6]

وكمثال على تطبيق منهج تعلّم غير موجه صرف، عالج بحث (دراسة بحثية عن خوارزميات تعلّم الآلة غير الموجهة من أجل الكشف المبكر عن الأعطال في الصيانة التنبؤية [17]) مسألة كشف الأعطال (Fault Detection) في حالة عدم وجود أية بيانات تاريخية عن المنظومة باستخدام خوارزميات تعلّم الآلة غير الموجهة، حيث تمّ تحصيل بيانات اهتزاز (Vibration Data) من حسّاس مراقبة اهتزاز على مروحة عادم، وبعد أخذ البيانات كل 240 دقيقة ولمدة 12 يوماً وبتردد اعتيان 2048 هرتز طبقت معالجة زمنية ترددية على البيانات لإنشاء فضاء ميّزات متعدّد يشمل معاملات مثل ذروة التسارع وذروة السرعة للاهتزاز وضغط أبعاده باستخدام تقنية (PCA) و (T square statistics). معالجة هذه البيانات بتطبيق العنقدة (Clustering) تمّ بعد تحديد عدد

العناقيد الأمثل بثلاثة تمثّل وضع طبيعي، وضع تنبيه، وضع عطل، وتطابقت ميزات التجميع الناتج مع التحليل الفيزيائي لسلوك الاهتزازات الناتجة عن العادم من حيث تمثيلها لأوضاع طبيعية وتنبيه وأداء غير نظامي بعد استخدام خوارزميات عنقدة متعدّدة.

في رسالة لنيل درجة الماجستير مقدّمة في جامعة أونتاريو الغربية في كندا قسم هندسة الكهرباء والحاسوب بعنوان (إطار عمل للشبكات العصبونية التلافيفية من أجل الصيانة التنبؤية [18])، استخدمت بنى (CNN) في معالجة مسألة صيانة تنبؤية حيث طرحت الدراسة فكرة مهمّة هي أنّ العطل يسبقه عادةً نماذج شاذة في إشارات حالة الآلة الهندسية وتشغيلها، وكانت فكرة الدراسة هي تطبيق تحويل بيانات (Data Transformation) على إشارات أحادية البعد محصّلة من آلة للحصول على إشارات ثنائية البعد، هو تحويل (Grammian Angular Field = GAF) ومن ثمّ استخدام الإشارات الناتجة في تدريب بنية مصنّف (CNN)، وكانت دقّة التصنيف في كلّ الحالات من رتبة (95%) وتفوّقت بنية مصنّف (CNN) على عدد من البنى الضحلة مثل (SVM).

في ورقة بحثية بعنوان (تشخيص دقيق لأعطال رولمان دوّار في ظروف سرعة محور متغيّرة باستخدام الشبكات العصبونية التلافيفية وطيف الاهتزاز [19]) طرّح منهج لتشخيص أعطال الرولمان ودرجة تهالكه في ظروف سرعة دوران متغيّرة، بتطبيق تحويل (STFT) على إشارات الاهتزاز المحصّلة من الرولمان ومن ثمّ تطبيق إشارات الطيف الناتجة كدخل لتدريب مصنّف عميق نوع (VGG16) كما يوضّح الشكل (2-13)، حيث بدايةً يتمّ تقسيم إشارات




الشكل (2-13): بنية عميقة مستخدمة في تشخيص أعطال رولمان في ظروف سرعة متغيّرة [19]

الاهتزاز إلى قطاعات (Segments) كلّ منها بطول ثابت هو (5 [Sec]) ومن ثمّ يطبّق تحويل (STFT) على كلّ قطاع للحصول على إشارة طيف زمني-ترددي ثنائية البعد من كلّ قطاع، إشارات الأطياف تُستخدم كحزمة بيانات لتدريب واختبار بنية (CNN-VGG16).


وبتطبيق المنهج المقترح لتشخيص حالة رولمان وحيد، وباعتماد معيار الدقّة المتوسطة كمجموع قيم الحساسية لكلّ صنف، مقسوماً على عدد الأصناف، كانت دقّة تمييز الأعطال من رتبة (98.8% - 99.4% - 98.9% - 99.3%)، وعدد أدوار التدريب لا يتجاوز أربعة أدوار.

في ورقة بحث بعنوان (مقاربة تعلّم عميق لتحليل التسلسل متعدّد الميزات في الصيانة التنبؤية [20])، عولجت مسألة تحليل ترابط واعتمادية الميزات في حزمة بيانات تدريبية باستخدام بنية مررّز آلي عميق، وطُبقت الدراسة نوعين من المررّزات الآلية أحدهما بطبقات طي والآخر بطبقات كاملة الاتّصال، بهدف الاستخلاص الآلي للميزات الممثلة في حزمة بيانات من رولمان دوّار، ومن ثمّ تطبيق العقدة عليها، ويوضّح الشكل (2-14) تنظيم النموذج المطبّق، الذي يبدأ بمرحلة استخلاص ميزات تليها مرحلة مررّز آلي وينتهي بمرحلة عقدة، ويلاحظ استخلاص أنماط مختلفة من الميزات الزمنية والترددية والزمنية-الترددية. بيّنت الدراسة تفوّق بنية المررّز الآلي ذي طبقات الطّي في معالجة المسألة.



الشكل (2-14): استخدام مررّز آلي عميق ككاشف ميزات يغيّدي بنية عقدة [20]


في ورقة بحث بعنوان (تحليل اهتزاز مضخة نابذة لتخمين التّهالك باستخدام مررّز آلي يعتمد بنية (WaveNet) [21]) عولجت مسألة تحليل الاهتزاز الناتج عن مضخة نابذة بهدف تحصيل الحالة الصحيّة للمضخة والكشف المبكر عن أعطالها باستخدام بنية تعلّم آلة عميقة هي مررّز آلي يستخدم بنية (WaveNet) في طبقاته الداخليّة بهدف التّخلّص من مرحلة استخلاص الميّزات اليدوي ومن ثمّ تخفيف الاعتماد على الخبرة المعرفيّة في مجال عمل الآلة الميكانيكيّة، وأيضاً بهدف إدخال الخصائص المتعلّقة بإصدار اهتزازات ذات تردّدات عالية. أُخذت بيانات التّدريب الصّرفة كقياسات للاهتزاز بعدد (216) قياس من ستّة مضخّات، وبتردّد اعتيان (1600) هرتز وبطول (4096) عينة للقياس الواحد، حيث أخذت القياسات من على سطح المضخة بثلاثة اتّجاهات وهذا ما يجعل الحجم الكلّي لكل قياس هو (3 X 4096)، وطُبّقَت تسوية على البيانات الصّرفة. صُنعت عيّنات التّدريب بتنفيذ نافذة منزلقة بطول (512) وبخطوة (128) على طول كل قياس كما يوضّح الشّكل (2-15). وقُيِّمت الإشارات المُعاد بناؤها بحساب معامل (Power Spectral Density) والرّمز المولّد يمكن استخدامه مستقبلاً لحساب خطأ إعادة البناء والتنبؤ بالحالة الصحيّة.



الشّكل (2-15): بنية المررّز الآلي العميق والنّافذة المنزلقة على إشارات الاهتزاز [21]

في ورقة بحث بعنوان (الكشف المبكر لأعطال أجزاء الآلة اعتماداً على التعلّم العميق والتعرّف الديناميكي [23])، اقترح حل لمسألة تنبؤ وكشف الأعطال في آلة ميكانيكية يتكوّن من بنية هجينة يوضّحها الشكل (2-16)، تضمّ مرحلة تعلّم عميق ومرحلة تعرّف ديناميكي حيث تتسلسل ثلاث مراحل بعد تحصيل إشارات اهتزاز طويلة المدى هي:

- استخلاص الاستجابات النبضية (Impulse Responses) للآلة الميكانيكية من إشارات الاهتزاز على المدى الطويل بواسطة آلة تعلّم عميق.
- اقتراح خوارزمية تعرّف (Identification Algorithm) على الخصائص الديناميكية لأجزاء الآلة من الاستجابات النبضية.
- تصميم مؤشر حالة (Health Indicator) للآلة الميكانيكية يستخدم الخصائص الديناميكية للتنبؤ بحالة أجزاء الآلة.



الشكل (2-16): بنية هجينة لحساب مؤشر صحة آلة ميكانيكية [23]

في ورقة بحث بعنوان (مقاربة جديدة لكشف الانحراف باستخدام التعلّم العميق بتنبؤ مؤخر [24]) طوّر نمط خاص من خلية (LSTM) واختبر، هو (dLSTM = delayed Long Short-Term Memory) بهدف كشف الانحراف في سلاسل البيانات الزمنية (Time-Series Data)، حيث اعتمدت الدراسة طريقة إنشاء البنية

العميقة لنموذج مثالي يعبر عن الحالة السليمة لأداء الآلة باستخدام بيانات التشغيل للآلة في حالتها السليمة، ومن ثم في حالات التشغيل الواقعية تحسب البنية العميقة مقدار انحراف بيانات الآلة عن النموذج المثالي بهدف الكشف المبكر للأعطال، وبهذه الطريقة تصبح بيانات التشغيل في حالات العطل غير ضرورية في مرحلة تصميم البنية العميقة وتدريبها، وتخمين الانحراف عن وضع التشغيل المثالي يتم من خلال حساب تنبؤ وحساب خطأ هذا التنبؤ بحيث توافق قيم الخطأ الكبيرة وضع عطل أو الاقتراب منه، وبالعكس قيم الخطأ الصغيرة توافق حالة صحيحة.

وبعد مراجعة الأعمال البحثية السابقة ككل، تُلاحظ التوجهات والسمات العامة الآتية، التي تُشكل دوافع بحثية تطويرية وتبريرية:

- توجه نحو معالجة حالات محدّدة بمعزل عن عمومية المسائل.
- تغليب الطابع الأكاديمي للبحث وعدم تأطير مسألة الصيانة التنبؤية إلى شكل هندسي تطبيقي، فمثلاً لا يتم الاهتمام بتنظيم العلاقة بين دورة حياة البنية العميقة المستخدمة لحلّ مسألة صيانة تنبؤية مع الدراسة الهندسية التصميمية للآلة المستهدفة أو المنشأة، والدراسة الهندسية تحتوي على معلومات جوهرية في تصميم بنية آلة الصيانة التنبؤية مثل خصائص التشغيل وترددات الاعتيان وإجرائيات نظم التحكم وحلقاتها، وعدم تأطير فاعليات البنية العميقة كآلة صيانة تنبؤية، مثل الكشف والتحديد والتنبؤ والتقييم.
- وضع مراحل استخلاص ميزات يدوية، تحويلات، ومعالجة أولية، عند استخدام بنى عميقة في معالجة حالات صيانة تنبؤية، والتوجه إلى تطبيق تحويلات رفع أبعاد الإشارات الزمنية إلى إشارات ثنائية البعد عند استخدام بنى (CNN) القياسية، وخصوصاً التحويلات الزمنية-الترددية مثل (STFT).
- اقتراح تحسينات بنيوية في بنى عميقة قياسية لتصبح أكثر فعالية في معالجة مسألة صيانة تنبؤية معينة، وتصميم بنى حسابية هجينة تمتلك مرحلة بنية عميقة.
- تحقيق قيم معاملات أداء واختبار جيدة، وممتازة في بعض الحالات.

3. الإجراءات البحثية

1.3. تصميم بنى عميقة مخصصة لمسائل صيانة تنبؤية:

تُظهر توجّهات البحث في معالجة مسألة الصيانة التنبؤية باستخدام التعلّم العميق وجود أعمال بحثية تهتم بتحسين البنى العميقة الموجودة كي تصبح أكثر ملاءمة لهذه المسائل [24]، ووجود أعمال بحثية تهتم بتصميم نظم حسابية هجينة فيها مراحل بُنى عميقة [23]. والتعلّم العميق بشكل عام يتكيف بحثياً مع المسائل التطبيقية.

وبالتحليل، نجد أنّ الميزات هي في جوهرها معلومات، كما يوضح الشكل (2-3)، والميزات التي يتم التعامل معها في مسائل الصيانة التنبؤية تتصف بإمكانية تمثيلها كمياً كبيانات رقمية، وبإمكانية وضع مخطط معلوماتي هرمي ترتبط فيه هذه الميزات صعوداً من الميزات البسيطة نحو ميزات نهائية يُطلب من آلة الصيانة التنبؤية إنتاج قيمها، كدرجة التآكل ووجود عطل معيّن واحتمال كون تراجع الأداء هو عطل معيّن، واستخلاص الميزات المضمنة في بيانات تشغيل وحالة الآلات هو مهمة أساسية أمام آلة الصيانة التنبؤية.

والتنظيم الرياضي للبنى العميقة يُظهر وجود مفهوم مهم يمكن تسميته المسار الإدراكي (Perceptual Route) وهو مسار الإشارات بدءاً من شعاع القياس كبيانات، وصولاً إلى المعلومة النهائية كقيمة شعاع خرج، ومن ثم، البنية العميقة، بالرغم من كونها مُقادة بالبيانات وتمتلك مقدرة تمثيلية تتعلق بعمقها ونوع طبقاتها، إلا أنّ تنظيم الاتصال البيني بين الطبقات هو تمثيل لتقدير المصمّم لارتباط المعلومات النهائية مع بعضها، وقد تفرض مسألة صيانة تنبؤية معينة وجود مسارات إدراكية مستقلة في مراحل معينة عن باقي المسارات، مثل حالة مسألة حركة جسم متعددة درجات الحرية، والتي يجب فيها أن تظهر معلومات السرعة في الخرج بالرغم من كون معلومات التسارع تنتج عن معالجة بيانات السرعة، وهذا ما يعني ضرورة وجود مسار إدراكي من الدّخل إلى الخرج وبالوقت نفسه يغذي طبقات داخلية. بينما يلاحظ في الحزم القياسية للتعلّم العميق مثل (Keras) و(Tensorflow) أنّ تصميم بنية عميقة طبقية يغلب عليه حالة تمام الاتصال بين الطبقات. وفي مسائل صيانة تنبؤية معينة قد يواجه مهندس البيانات حالات إشارات من حساسات تمتلك ميزات تتطلب معالجة رياضية خاصة مثل أنماط الإصدار الحراري والتسخين الذاتي في الآلات، التي تمتلك ميزات تفاضلية وأسية النمو.

وهذا الفصل هو دراسة استنباطية موجزة في تصميم البنى العميقة، ينتهي باستراتيجية عامة تُقيد في تصميم بُنى عميقة جديدة.

1.1.3. استنتاج استقرائي لخوارزمية الانتشار الخلفي (BP):

إنَّ التَّعلُّمَ العميق هو تخصص في مبحث الشبكات العصبونية يُؤسَّس على تطوير الأسس والموديلات الرياضية فيه. وعموماً، يشترك المبحثان في طبيعة المسائل المُستهدفة التي يُمكن توصيفها رياضياً بحالة نظام واقعي محدّد الدّخل والخرج، كلّ من دخله وخرجه شعاع، وفعاليتّه يمكن عدّها تابع تحويلٍ موجود ولكن غير معروف، وبرصد السّلك الواقعي لهذا النّظام في لحظات زمن متقطّعة عددها الكلي $(T \in \mathbb{N})$ نحصل على مجموعة ثنائيات (شعاع دخل - شعاع خرج) تُدعى حزمة بيانات (Data Set) واصفة للنّظام أو المسألة:

$$DS_T = \{(X(i), Y(i)) : (T \in \mathbb{N}) \wedge (i \in \mathbb{N}) \wedge (i \leq T)\} \dots (1 - 3)$$

$$DS_T = \{(X(0), Y(0)), (X(1), Y(1)), \dots, (X(T), Y(T))\} \dots (2 - 3)$$

والشبكة العصبونية الأمامية (Feed Forward Network) هي إجرائية احتسابية (Computational Procedure) رياضية تمتلك بنية داخلية قابلة للضبط بالتدريب على حزمة بيانات المسألة مطبقة تعميم معيّن باكتسابها القدرة على توليد شعاع خرج صحيح أو مقبول عند تغذيتها بشعاع دخل جديد لم تتدرّب عليه، ويمكن وضع نموذج رياضي عام لشبكة (FFN) بالمعادلات الآتية التي يوضّح الجدول (1-3) دلالات معاملاتها:

$$FNN_N(X(t)) = Y_N(t) : \begin{pmatrix} Y_n(t) = L_n(Y_{n-1}(t)) : n \leq N \\ Y_0(t) = X(t) \end{pmatrix} \dots (3 - 3)$$

$$L_n(X(t)) = \begin{bmatrix} \beta_1(X(t)) \\ \beta_2(X(t)) \\ \vdots \\ \beta_{c_n}(X(t)) \end{bmatrix} \dots (4 - 3)$$

$$\beta_{(n,c)}(X(t)) = \emptyset_{(n,c)} \left(\sum_{b=0}^{c_{n-1}} w_{(n,b,c)} \cdot y_{(n-1,b)}(t) \right) \dots (5 - 3)$$

الجدول (3-1): دلالات معاملات النموذج الرياضي لشبكة (FNN)

المعامل	الشرح
$N \in \mathbb{N}^*$	عدد طبقات الشبكة.
$n \in \mathbb{N}^*$	عدد طبيعي متحول يشير إلى ترتيب طبقة ضمن شبكة، قيمته العظمى (N).
$C_n \in \mathbb{N}^* : 1 \leq n \leq N$	عدد العصبونات في الطبقة (n) من الشبكة.
$C_0 = u \in \mathbb{N}^*$	عدد مرغبات طبقة صفرية غير موجودة تكون في الواقع بنية ذاكرة قادرة على حفظ شعاع الدّخل ذي (u) مركبة.
FNN_N	شبكة عصبونية ذات (N) طبقة.
$L_n : \left(\begin{matrix} n \in \mathbb{N}^* \\ 1 \leq n \leq N \end{matrix} \right)$	الطبقة ذات الترتيب (n) من الشبكة.
$Neu_{n,c} : \left(\begin{matrix} c \in \mathbb{N}^* \\ 1 \leq c \leq C_n \end{matrix} \right)$	العصبون ذو الترتيب (c) في الطبقة (n) من الشبكة.
$w_{(n,b,c)}$	الوزن المشبكي للوصلة بين العصبون (c) في الطبقة (n) والعصبون (b) في الطبقة (n-1).
$w_{(n,0,c)} = b_{(n,c)}$	حد انحياز خارجي للعصبون (c) في الطبقة (n) من الشبكة.
$\emptyset_{(n,c)}(x) : \left(\begin{matrix} 1 \leq n \leq N \\ 1 \leq c \leq C_n \end{matrix} \right)$	تابع تفعيل العصبون (c) في الطبقة (n).
$y_{(n,0)}(t) = +1 : \forall n : 1 \leq n \leq N$	قيمة واحدة ثابتة في أي طبقة (n) معممة على جميع العصبونات.
$v_{(n,c)}(t) = \sum_{b=0}^{C_{n-1}} w_{(n,b,c)} \cdot y_{(n-1,b)}(t)$	جهد تفعيل العصبون (c) في الطبقة (n) في اللحظة (t).
$y_{(n,c)}(t) = \emptyset_{(n,c)}(v_{(n,c)}(t))$	قيمة خرج العصبون (c) في الطبقة (n) في اللحظة (t).
$X(t) = \begin{bmatrix} x_1(t) \\ x_2(t) \\ \vdots \\ x_u(t) \end{bmatrix}$	شعاع دخل الشبكة في اللحظة (t)
$Y_n(t) = \begin{bmatrix} y_{(n,1)}(t) \\ y_{(n,2)}(t) \\ \vdots \\ y_{(n,C_n)}(t) \end{bmatrix}$	شعاع خرج الطبقة (n) في اللحظة (t).

شعاع خرج طبقة صفرية افتراضية في اللحظة (t) .	$Y_0(t) = \begin{bmatrix} y_{(0,1)}(t) \\ y_{(0,2)}(t) \\ \vdots \\ y_{(0,c_0)}(t) \end{bmatrix}$
--	---

يظهر المسار الأمامي لانتشار الإشارات عبر الشبكة في هذا النموذج، وفي نهاية كل لحظة زمنية (t) من لحظات مرحلة التدريب توجد قيمتان لشعاع خرج هما القيمة المحسوبة من قبل الشبكة والقيمة المثالية من حزمة البيانات:

$$Y_N(t) = \begin{bmatrix} y_{(N,1)}(t) \\ y_{(N,2)}(t) \\ \vdots \\ y_{(N,c_n)}(t) \end{bmatrix} = \text{FNN}[X(t)] \dots (6-3) \quad Y(t) = \begin{bmatrix} y_{(1)}(t) \\ y_{(2)}(t) \\ \vdots \\ y_{(c_n)}(t) \end{bmatrix} \dots (7-3)$$

ومن ثمّ يمكن تعريف تابع خسارة (Loss Function) يعبر عن مدى صحة تنبؤ الشبكة ويأخذ قيمة محدّدة في نهاية كل تطبيق لشعاع دخل من حزمة البيانات، حيث تنقص قيمته كلّما اقتربت قيمة الشعاع المحسوب من قبل الشبكة من قيمة الشعاع المثالية:

$$\epsilon : \mathbb{R}^{C_n} \rightarrow \mathbb{R} : \epsilon(Y(t), Y_N(t))$$

ويمكن البرهان بالاستقراء الرياضي أنّ تابع الخسارة يتبع كلّ من الأوزان المشبكية في أي لحظة، وكون جميع توابع التفعيل في العصبونات مستمرة وقابلة للاشتقاق فيمكن في أي لحظة (t) استخدام قاعدة المشتقات الجزئية (Chain Rule) لإيجاد قيمة مشتق تابع الخسارة بالنسبة إلى أيّ من هذه الأوزان:

$$\frac{\partial \epsilon(t)}{\partial w_{(n,b,c)}(t)} : (1 \leq n \leq N) \wedge (1 \leq b \leq C_{n-1}) \wedge (1 \leq c \leq C_n)$$

وتُعرّف إجراءات ضبط معاملات الشبكة بتكرار تطبيق شعاع دخل وحساب قيمة تابع الخسارة وحساب مشتق تابع الخسارة بالنسبة إلى كلّ وزن، ومن ثمّ حساب معامل تعديل وزن مشبكي يعاكس مقدار مساهمة الوزن في تشكيل قيمة تابع الخسارة، مؤرّن بمعامل تعليم (η) :

$$\Delta w_{(n,b,c)}(t) = -\eta \frac{\partial \epsilon(t)}{\partial w_{(n,b,c)}(t)} \dots (8-3)$$

وتلخّص خوارزمية التدريب في الخطوات الآتية:

Repeat for : $t \leq T$

$$1) Y_N(t) = FNN_N(X(t))$$

$$2) \epsilon(Y(t), Y_N(t))$$

$$3) \frac{\partial \epsilon(t)}{\partial w_{(n,b,c)}(t)} : (1 \leq n \leq N) \wedge (0 \leq b \leq C_{n-1}) \wedge (1 \leq c \leq C_n)$$

$$4) \Delta w_{(n,b,c)}(t) = -\eta \frac{\partial \epsilon(t)}{\partial w_{(n,b,c)}(t)}$$

$$5) w_{(n,b,c)}(t+1) = w_{(n,b,c)}(t) + \Delta w_{(n,b,c)}(t)$$

ومسألة التدريب تُلزم إيجاد قوانين معممة لتعديل الأوزان المشبكية على أي شبكة عصبونية أمامية مهما كان عدد طبقاتها ومهما كان عدد العصبونات في أي طبقة، وينجح المنهج الرياضي الاستقرائي في الوصول إلى هذه القوانين العامة.

يبدأ الاستنتاج الاستقرائي للقوانين العامة لتعديل الأوزان المشبكية ببناء ملاحظة استقرائية تحليلية بالاعتماد بشكل رئيسي على قاعدة المشتقات الجزئية، حيث من أجل أوزان الوصلات الواصلة إلى الطبقة (N)

$$\forall i, j : \left(\begin{matrix} 1 \leq j \leq C_N \\ 0 \leq i \leq C_{N-1} \end{matrix} \right) :$$

$$\frac{\partial \epsilon(t)}{\partial w_{(N,i,j)}(t)} = \left(\frac{\partial \epsilon(t)}{\partial y_{(N,j)}(t)} \right) \cdot \left(\emptyset_{(N,j)}^{(1)}(v_{(N,j)}(t)) \right) \cdot (y_{(N-1,i)}(t)) \dots (9-3)$$

ومن أجل أوزان الوصلات الواصلة إلى الطبقة (N-1):

$$\forall i, j : \left(\begin{matrix} 1 \leq j \leq C_{N-1} \\ 0 \leq i \leq C_{N-2} \end{matrix} \right) :$$

$$\begin{aligned} & \frac{\partial \epsilon(t)}{\partial w_{(N-1,i,j)}(t)} \\ &= \left(\emptyset_{(N-1,j)}^{(1)}(v_{(N-1,j)}(t)) \right) \cdot \left(\sum_{r=1}^{C_N} \left(\frac{\partial \epsilon(t)}{\partial y_{(N,r)}(t)} \right) \cdot \left(\emptyset_{(N,r)}^{(1)}(v_{(N,r)}(t)) \right) \cdot (w_{(N,j,r)}(t)) \right) \cdot (y_{(N-2,i)}(t)) \dots (10-3) \end{aligned}$$

ومن أجل أوزان الوصلات الواصلة إلى الطبقة (N-2):

$$\forall i, j : \left(\begin{matrix} 1 \leq j \leq C_{N-2} \\ 0 \leq i \leq C_{N-3} \end{matrix} \right) :$$

$$\frac{\partial \epsilon(t)}{\partial w_{(N-2,i)}(t)} = \left(\emptyset_{(N-2,j)}^{(1)} \left(v_{(N-2,j)}(t) \right) \right) \cdot \left(\sum_{b=0}^{C_N-1} \left(\emptyset_{(N-1,b)}^{(1)} \left(v_{(N-1,b)}(t) \right) \right) \cdot \left(w_{(N-1,j,b)}(t) \right) \cdot \left(\sum_{r=1}^{C_N} \left(\frac{\partial \epsilon(t)}{\partial y_{(N,r)}(t)} \right) \cdot \left(\emptyset_{(N,r)}^{(1)} \left(v_{(N,r)}(t) \right) \right) \cdot \left(w_{(N,b,r)}(t) \right) \right) \right) \cdot \left(y_{(N-3,i)}(t) \right) \dots (11-3)$$

ونلاحظ وجود قضية استقرائية رياضية $(P(m))$ مفتوحة على متحول طبيعي $(m=N-n)$ ، ومن أجل أول ثلاث قيم للمتحول (m) يعرض الجدول (2-3) تفصيل القضية المحققة عند هذه القيم.

الجدول (2-3): تحقق القضية الاستقرائية على أول ثلاث قيم (m)

m	P(m)
0	$P(0): \forall i, j : \left(\begin{matrix} 1 \leq j \leq C_N \\ 0 \leq i \leq C_{N-1} \end{matrix} \right) : \frac{\partial \epsilon(t)}{\partial w_{(N,i,j)}(t)} = \delta_{N,j}(t) \cdot \left(y_{(N-1,i)}(t) \right) :$ $\delta_{N,j}(t) = \left(\frac{\partial \epsilon(t)}{\partial y_{(N,j)}(t)} \right) \cdot \left(\emptyset_{(N,j)}^{(1)} \left(v_{(N,j)}(t) \right) \right)$
1	$P(1): \forall i, j : \left(\begin{matrix} 1 \leq j \leq C_{N-1} \\ 0 \leq i \leq C_{N-2} \end{matrix} \right) : \frac{\partial \epsilon(t)}{\partial w_{(N-1,i,j)}(t)} = \delta_{N-1,j}(t) \cdot \left(y_{(N-2,i)}(t) \right) :$ $\delta_{N-1,j}(t) = \left(\emptyset_{(N-1,j)}^{(1)} \left(v_{(N-1,j)}(t) \right) \right) \cdot \left(\sum_{r=1}^{C_N} \left(\delta_{N,r}(t) \right) \cdot \left(w_{(N,j,r)}(t) \right) \right)$
2	$P(2): \forall i, j : \left(\begin{matrix} 1 \leq j \leq C_{N-2} \\ 0 \leq i \leq C_{N-3} \end{matrix} \right) : \frac{\partial \epsilon(t)}{\partial w_{(N-2,i,j)}(t)} = \delta_{N-2,j}(t) \cdot \left(y_{(N-3,i)}(t) \right) :$ $\delta_{N-2,j}(t) = \left(\emptyset_{(N-2,j)}^{(1)} \left(v_{(N-2,j)}(t) \right) \right) \cdot \left(\sum_{b=0}^{C_N-1} \left(\delta_{N-1,j}(t) \right) \cdot \left(w_{(N-1,j,b)}(t) \right) \right)$

وبوجود هذه الملاحظة الاستقرائية يمكن طرح القضية الاستقرائية الآتية:

$$P(m): \forall i, j : \left(\begin{matrix} 1 \leq j \leq C_{N-m} \\ 0 \leq i \leq C_{N-m-1} \end{matrix} \right) : \frac{\partial \epsilon(t)}{\partial w_{(N-m,i,j)}(t)} = \delta_{N-m,j}(t) \cdot \left(y_{(N-m-1,i)}(t) \right) :$$

$$\delta_{N-m,j}(t) = \left(\frac{\partial \epsilon(t)}{\partial y_{(N,j)}(t)} \right) \cdot \left(\emptyset_{(N,j)}^{(1)} \left(v_{(N,j)}(t) \right) \right) : m = 0$$

$$\left(\left(\emptyset_{(N-m,j)}^{(1)} \left(v_{(N-m,j)}(t) \right) \right) \cdot \left(\sum_{r=1}^{C_{N-m+1}} \left(\delta_{N-m+1,r}(t) \right) \cdot \left(w_{(N-m+1,j,r)}(t) \right) \right) \right) : m > 0 \dots (12-3)$$

ونضع الفرض الاستقرائي الآتي:

$$P(k \in \mathbb{N}): \forall i, j : \left(\begin{matrix} 1 \leq j \leq C_{N-k} \\ 0 \leq i \leq C_{N-k-1} \end{matrix} \right) : \frac{\partial \epsilon(t)}{\partial w_{(N-k,i,j)}(t)} = \delta_{N-k,j}(t) \cdot \left(y_{(N-k-1,i)}(t) \right) :$$

$$\delta_{N-k,j}(t) =$$

$$\left(\begin{array}{l} \left(\frac{\partial \epsilon(t)}{\partial y_{(N,j)}(t)} \right) \cdot \left(\emptyset_{(N,j)}^{(1)} \left(v_{(N,j)}(t) \right) \right) : k = 0 \\ \left(\emptyset_{(N-k,j)}^{(1)} \left(v_{(N-k,j)}(t) \right) \right) \cdot \left(\sum_{r=1}^{C_{N-k+1}} \left(\delta_{N-k+1,r}(t) \right) \cdot \left(w_{(N-k+1,j,r)}(t) \right) \right) : k > 0 \end{array} \right) \dots (13-3)$$

ويكون الطّلب الاستقرائي هو كون الاقتضاء $(P(k) \Rightarrow P(k+1))$ بديهية حيث:

$$P(k+1): \forall i, j : \left(\begin{array}{l} 1 \leq j \leq C_{N-k-1} \\ 0 \leq i \leq C_{N-k-2} \end{array} \right) : \frac{\partial \epsilon(t)}{\partial w_{(N-k-1,i,j)}(t)} = \delta_{N-k-1,j}(t) \cdot \left(y_{(N-k-2,i)}(t) \right) :$$

$$\delta_{N-k-1,j}(t) = \left(\emptyset_{(N-k-1,j)}^{(1)} \left(v_{(N-k-1,j)}(t) \right) \right) \cdot \left(\sum_{r=1}^{C_{N-k}} \left(\delta_{N-k,r}(t) \right) \cdot \left(w_{(N-k,j,r)}(t) \right) \right) \dots (14-3)$$

ويمكن بالتحليل الرياضي برهان أنّ الاقتضاء $(P(k) \Rightarrow P(k+1))$ بديهية، ممّا يعني إمكانية تعميم القضية

الاستقرائية $(P(m))$ مهما كانت قيمة (N) :

$$\forall m \in \mathbb{N} :$$

$$P(m): \forall i, j : \left(\begin{array}{l} 1 \leq j \leq C_{N-m} \\ 0 \leq i \leq C_{N-m-1} \end{array} \right) : \frac{\partial \epsilon(t)}{\partial w_{(N-m,i,j)}(t)} = \delta_{N-m,j}(t) \cdot \left(y_{(N-m-1,i)}(t) \right) :$$

$$\delta_{N-m,j}(t)$$

$$= \left(\begin{array}{l} \left(\frac{\partial \epsilon(t)}{\partial y_{(N,j)}(t)} \right) \cdot \left(\emptyset_{(N,j)}^{(1)} \left(v_{(N,j)}(t) \right) \right) : m = 0 \\ \left(\emptyset_{(N-m,j)}^{(1)} \left(v_{(N-m,j)}(t) \right) \right) \cdot \left(\sum_{r=1}^{C_{N-m+1}} \left(\delta_{N-m+1,r}(t) \right) \cdot \left(w_{(N-m+1,j,r)}(t) \right) \right) : m > 0 \end{array} \right) \dots (15-3)$$

وبالعودة إلى الدليل (n) حيث $(m = N - n)$ يكون التعميم النهائي لقوانين حساب مشتق تابع الخسارة بالنسبة

إلى الأوزان المشبكية مهما كان عدد طبقات الشبكة هو:

$$\forall n \in \mathbb{N} : (1 \leq n \leq N):$$

$$\forall i, j \in \mathbb{N} : \left(\begin{array}{l} 1 \leq j \leq C_n \\ 0 \leq i \leq C_{n-1} \end{array} \right) : \frac{\partial \epsilon(t)}{\partial w_{(n,i,j)}(t)} = \delta_{n,j}(t) \cdot \left(y_{(n-1,i)}(t) \right) :$$

$$\delta_{n,j}(t) = \begin{cases} \left(\frac{\partial \epsilon(t)}{\partial y_{(N,j)}(t)} \right) \cdot \left(\phi_{(N,j)}^{(1)} \left(v_{(N,j)}(t) \right) \right) & : n = N \\ \left(\phi_{(n,j)}^{(1)} \left(v_{(n,j)}(t) \right) \right) \cdot \left(\sum_{r=1}^{C_{n+1}} \left(\delta_{n+1,r}(t) \right) \cdot \left(w_{(n+1,j,r)}(t) \right) \right) & : n < N \end{cases} \dots (16 - 3)$$

ونلاحظ عند تنفيذ عمليات حساب قيم التعديل المشبكي وجود مسار انتشار للإشارات يبدأ بالطبقة الأخيرة (N) ويتابع في عمق الشبكة وصولاً إلى طبقة الدّخل الأولى، يُدعى بالمسار الخلفي (Backward Pass)، وهو، كما يوضّح البرهان السابق، لا يُوضّع افتراضاً بل استنتاجاً. يدعى التّابع $(\delta_{n,j}(t))$ باسم المشتق المحلي (Local Gradient) للعصبون (j) في الطبقة (n) وتكون صيغة تعديل الوزن المشبكي لأيّ وصلة:

$$\Delta w_{(n,b,c)}(t) = -\eta \frac{\partial \epsilon(t)}{\partial w_{(n,b,c)}(t)} = -\eta \cdot \left(\delta_{n,j}(t) \right) \cdot \left(y_{(n-1,i)}(t) \right) \dots (17 - 3)$$

2.1.3. وضع مراحل استراتيجية تصميم بنى عميقة مخصّصة للصيانة التنبؤية:

يُمكن استشفاف استراتيجية عمل عامّة لتصميم شبكة عصبونية من الاستنتاج الاستقرائي السابق لخوارزمية (BP) تشرحه المراحل المتعاقبة الآتية:

- تحديد المسألة الأساسية التي تعالجها الشبكة قيد التصميم، وهي مسألة تعلّم آلة.
- وضع نموذج رياضي طبقي ذي تنظيم (دخل - خرج).
- تصميم عنصر حسابي كوحدة وظيفيّة بنيويّة على مستوى الطبقة، هو العصبون في حالة شبكة (FNN).
- تعريف مسار أمامي للإشارات موزون بمعاملات، من خلال وضع مخطّط ترابط بين الطبقات وبين العناصر الحسابيّة إن لزم.
- وضع مسألة أمثلة (Optimization Problem) لمعاملات الرّبط البيني بالنسبة إلى تابع خسارة.
- إنجاز تحليل رياضيّ لحل مسألة الأمثلة، بهدف الوصول إلى قوانين عامّة لضبط معاملات الرّبط البيني، وإجرائيّة تدريب حسابيّة للشبكة، وقد يتضمّن التحليل برهان استقرائي على عموميّة القوانين والإجرائيّة، وسبب ظهور الحاجة إليه هو البنية الطبقيّة ذات العدد المتغيّر من الطبقات. وبصورة عامّة يظهر بعد تطبيق التحليل

الرياضي مسار خلفي للإشارات، ومعاملات خاصة بالعناصر الحسابية ذات طبيعة تفاضلية، كحالة المشتق المحلي للعصبون كما ظهر في الفقرة السابقة.

الاستراتيجية المذكورة يمكن استخدامها لتصميم خلية عصبونية عودية (Recurrent Cell) قادرة على حل مسائل سياقية، بتعريف مسألة تعلّم الآلة كمسألة سياقية بطول سياق هو (K) عينة من قيم الدّخل، ووضع نموذج رياضي طبقي فيه عنصران حسابيان أحدهما يحسب قيمة متحوّل الحالة الداخلي بوجود حلقة تغذية خلفية وعنصر ذاكرة، والثاني عصبون يحسب قيمة شعاع الخرج، ووضع معادلات المسار الأمامي التي توافّق الشكل (2-4):

$$\mathbf{h}(t) = \phi_h \left(\mathbf{W}_i^h \cdot \mathbf{x}(t) + \mathbf{W}_h^h \cdot \mathbf{h}(t-1) \right) \dots (18-3)$$

$$\mathbf{y}(t) = \phi_o \left(\mathbf{W}_h^o \cdot \mathbf{h}(t) \right) \dots (19-3)$$

وضع مسألة أمثلة لقيم الأوزان بالنسبة إلى تابع الكلفة (ϵ)، ومعامل التعلّم (η) حيث تُحدّث الأوزان فقط بعد كل تطبيق (K) عينة كاملة:

$$\epsilon(K) = 0.5 \sum_{k=1}^K (d(k) - y(k))^2 \dots (20-3)$$

فُتستنتج قوانين التعديل الوزني العامة الآتية:

$$\Delta \mathbf{W}_h^o(K) = \eta \cdot \sum_{k=1}^K \delta_o(k) \cdot \mathbf{h}(k) : \delta_o(k) = \mathbf{e}(k) \cdot \left(\phi_o^{(1)}(\mathbf{v}_o(k)) \right) \dots (21-3)$$

$$\Delta \mathbf{W}_h^h(K) = \eta \cdot \sum_{k=1}^K \mathbf{e}(k) \cdot \left(\phi_o^{(1)}(\mathbf{v}_o(k)) \right) \cdot \mathbf{W}_h^o(K) \cdot \sum_{q=1}^k \mathbf{h}(q-1) \cdot \prod_{j=q}^k \phi_h^{(1)}(\mathbf{v}_h(j)) \dots (22-3)$$

$$\begin{aligned} & \Delta \mathbf{W}_i^h(K) \\ &= \eta \cdot \sum_{k=1}^K \mathbf{e}(k) \cdot \left(\phi_o^{(1)}(\mathbf{v}_o(k)) \right) \cdot \mathbf{W}_h^o(K) \cdot \sum_{q=0}^k \mathbf{x}(q) \cdot \left(\mathbf{W}_h^h(K) \right)^{k-q} \cdot \prod_{q=1}^k \phi_h^{(1)}(\mathbf{v}_h(q)) \dots (23-3) \end{aligned}$$

يُلاحظ في هذه الاستراتيجية التعميم على أي عدد للطبقات، وتصميم عنصر أو عناصر حسابية، وبما أنّ المسائل التي يعالجها التعلّم العميق تتبع نموذج مسائل الشبكات العصبونية الصّحلة نفسه، يصبح من الأوضح تمييز معيار

أساسي في وصف شبكة عصبونية بأنها عميقة أو ضحلة، وهو آلية استخلاص الميزات من بيانات الدّخل يدويّاً في الشبكات الضحلة وآلياً في العميقة.

وبمراجعة البنى العميقة القياسية يُلاحظ وجود عناصر حسابية خاصة في طبقات مرحلة استخلاص الميزات هي عناصر معالجة إشارة تمتلك معاملات قابلة للضبط تُحدّد قيمها الميزات التي تنتجها هذه العناصر، ففي طبقات الطّيّ العنصر الحسابي هو عنصر ترشيح يمتلك مرشحاً كمصفوفة ثابتة، وينفذ عملية طي بين دخله وهذا المرشح ليعطي شعاع خرج كشعاع ميزات، والمعالجة هي استخلاص ميزات مكانية ترددية (Spatial Frequential Features).

وفي الطبقات العودية مثل (LSTM) و (GRU) العنصر الحسابي هو عنصر تغذية خلفية يمتلك مصفوفة أوزان توزّن إشارة التغذية الخلفية من الخرج وتُطبّق تقييس بوابة معيّن، وينفذ عملية حساب خرج تعتمد على تسلسل قيم الدّخل في إطار زمني محدّد، والمعالجة هي استخلاص ميزات ممتدة زمانياً أو سياقية (Contextual Features). وفي طبقات (Restricted Boltzmann Machine) التي تُكّس لبناء شبكة (DBN)، العنصر الحسابي هو عنصر حساب احتمالية معينة، وينفذ عملية حساب احتمال رياضي لقيمة شعاع الدّخل موزوناً بمصفوفة أوزان كثوابت لتولّد الشبكة ككل محاكاة توزيع احتمالي يُفترض وجوده مضمناً في حزمة بيانات التدريب، والمعالجة هي استخلاص ميزات تتبع توزيعاً احتمالياً (Probabilistic Features).

مسائل الصيانة التنبؤية التي تفرض تصميم بنى عميقة جديدة تتّصف بصفتين هما وجود تخطيط مسارات إدراكية خاصة، ووجود إشارات تحسّس حالة في الزمن الحقيقي تحمل ميزات تحتاج معالجة رياضية خاصة. ولتصميم بنية عميقة خاصة بمسألة صيانة تنبؤية محدّدة يمكن اتّباع الاستراتيجيّة الآتية:

- تحديد المسألة الأساسية التي تعالجها الشبكة قيد التصميم.
- تحليل طبيعة الميزات المضمّنة في إشارات تحسّس الحالة، وآلية استخلاصها رياضياً.
- تصميم عناصر حسابية كوحدات وظيفية بنيوية مهمتها استخلاص ميزات رياضي، وتوافق الميزات المدروسة.

- وضع نموذج رياضي طبقي ذي تنظيم (دخل - خرج) ويُراعى فيه وضع مرحلتين، مرحلة استخلاص مميزات آلي ومرحلة طبقات ضحلة.
- تعريف مسار أمامي للإشارات موزون بمعاملات، بوضع مخطط ترابط بين الطبقات وبين العناصر الحسابية إن لزم.
- وضع مسألة أمثلة (Optimization Problem) لمعاملات الربط البيني بالنسبة إلى تابع خسارة مناسب.
- إنجاز تحليل رياضي لحل مسألة الأمثلة، للوصول إلى قوانين عامة لضبط معاملات الربط البيني، وإجرائية تدريب حسابية للشبكة، وقد يتضمن التحليل برهان استقرائي على عمومية القوانين والإجرائية، وبصورة عامة يظهر بعد تطبيق التحليل الرياضي مسار خلفي، ومعاملات خاصة بالعناصر الحسابية هي المشتقات المحلية.

2.3. تصميم بنية عميقة تُعالج مسائل بيانات ذات مميزات تفاضلية:

هذا الفصل يهتم باستثمار كل ما تمّ استعرض من تحليلات ومفاهيم في مسألة تطبيقية هي تصميم بنية عميقة خاصة بمسألة شائعة في مجال الصيانة التنبؤية، وهي مسألة إشارة تحسّس حالة ذات مميزات تفاضلية.

تحديد المسألة: المسألة هي مسألة مراقبة الحالة من خلال الحركة الميكانيكية، وهي مسألة شائعة وأساسية في قطاع الآلات الصناعية، حيث ترتبط الحالة الصحية للآلات وأجزائها بصورة وثيقة مع الأنماط الحركية المختلفة للأجزاء المتحركة، وتُصمّم آلة صيانة تنبؤية دخلها هو إشارة موضع جزء متحرك كإشارة تحسّس حالة. لاحقاً يمكن تعميم هذه البنية العميقة إلى معالجة أيّ مسألة ذات إشارات حالة بمميزات تفاضلية.


تحليل طبيعة المميزات المضمنة: المميزات والأنماط الحركية ذات طبيعة فضائية (Spatial) تفاضلية (Differential) بالنسبة إلى الموضع، فالسرعة هي مشتق الموضع زمنياً والتسارع هو مشتق السرعة زمنياً. وهي تقرض مخطّط مسارات إدراكية يلزم فيه وجود مسار إدراكي مباشر من الدّخل إلى نهاية مرحلة استخلاص المميزات، ويلزم فيه وجود مسار إدراكي مباشر من الطبقة التفاضلية الأولى إلى نهاية مرحلة استخلاص المميزات.

تصميم العنصر الحسابي المناسب: العنصر الحسابي يُسمى وحدة تفاضل ويتكوّن من (شعاع أوزان، شعاع انحياز، تابع تفعيل شعاعي على مستوى العنصر، مستمر وقابل للاشتقاق). ويستقبل شعاع دخل في اللحظة (t) طوله (J) لينجز عملية تفاضل رقمي على هذا الشعاع مولّداً شعاع جديد يتمّ تنفيذ جداء على مستوى العنصر بينه وبين شعاع الأوزان، ويُجمع الناتج مع شعاع الانحياز ويكون الشعاع الناتج دخلاً لتابع التفعيل الذي يولّد الخرج النهائي لوحدة التفاضل، ويُفرض كون المركبة الأولى من شعاع الخرج صفريّة كنوع من حشو الأصفار بهدف جعل طول شعاع الخرج مساوياً لطول شعاع الدّخل. وهو (J)، ويوضّح الجدول (3-3) تنظيم وحدة التفاضل.

الجدول (3-3): التنظيم الرياضي لوحدة التفاضل كعنصر حسابي

الدّالة	الصّيغة
شعاع دخل بطول (J)	$X_J(t) = \begin{bmatrix} x_0(t) \\ x_1(t) \\ \vdots \\ x_{J-1}(t) \end{bmatrix}$
شعاع خرج الوحدة (k) في الطبقة (n)	$Y_{(n,k,J)}(t) = \begin{bmatrix} y_{(n,k,0)}(t) \\ y_{(n,k,1)}(t) \\ \vdots \\ y_{(n,k,J-1)}(t) \end{bmatrix}$
شعاع أوزان	$W_{(n,k)} = [w_{(n,k,0)} \quad w_{(n,k,1)} \quad \dots \quad w_{(n,k,J-1)}] : w_{(n,k,0)} = 0$
شعاع انحياز	$B_{(n,k)} = [b_{(n,k,0)} \quad b_{(n,k,1)} \quad \dots \quad b_{(n,k,J-1)}] : b_{(n,k,0)} = 0$
شعاع جهود تحريض	$V_{(n,k,J)}(t) = \begin{bmatrix} v_{(n,k,0)}(t) \\ v_{(n,k,1)}(t) \\ \vdots \\ v_{(n,k,J-1)}(t) \end{bmatrix} : \begin{pmatrix} v_{(n,k,i)}(t) = w_{(n,k,i)}(x_i(t) - x_{i-1}(t)) \\ v_{(n,k,0)}(t) = 0 \end{pmatrix}$
المركبة (i)	$y_{(n,k,i)}(t) = \phi_{(n,k)}(v_{(n,k,i)}(t) + b_{(n,k,i)}) : \phi_{(n,k)}(0) = 0$

تنظيم البنية الطبقي: تنظيم البنية العميقة ككل مكون من تعاقب مرحلتين، الأولى مرحلة استخلاص مميزات مكونة من طبقتين، كل طبقة تمتلك عدداً محدداً من وحدات التفاضل، والثانية طبقتان عصبونيتان كما يوضح الشكل (1-3).



الشكل (1-3): تنظيم البنية العميقة الخاصة بمعالجة مسألة مراقبة الحالة من خلال إشارة موضع تمتلك طبقة استخلاص المميزات في البنية قيد التصميم عدداً محدداً من وحدات التفاضل، ويحدد هذا العدد عدد خوارزمات المميزات التي تولدها الطبقة، ومسار الإشارات في هذه البنية يراعي طبيعة التحليل الأفضل للمسألة، حيث تُنظّم عصبونات الطبقة الثالثة في ثلاث مجموعات، تتصل الأولى منها مع شعاع الدّخل مباشرةً ومعه فقط، كشعاع معبّر عن موضع الجسم المتحرك، والثانية تتصل مع شعاع خرج طبقة التفاضل الأولى كشعاع معبّر عن سلوك السرعة، والثالثة مع شعاع خرج طبقة التفاضل الثانية كشعاع معبّر عن سلوك التسارع. وتُمثّل البنية العميقة رياضياً بالمعاملات والبنى المحددة في الجدول (4-3).

الجدول (4-3): المعاملات والبنى الرياضية الممثلة للبنى العميقة التفاضلية

المعامل	الدلالة
$n \in \{1, 2, 3, 4\}$	ترتيب طبقة ضمن الشبكة، متحول.
$J \in \mathbb{N}^*$	طول شعاع دخل الشبكة، ثابت.
$K_m : m \in \{1, 2\}$	عدد وحدات التفاضل في الطبقة (m)، ثابت.
$k_m \in \{0, 1, 2, \dots, K_m - 1\}$	وحدة التفاضل (k_m) في الطبقة (m)، متحول.
$W_{(m,k_m)}$	شعاع أوزان وحدة التفاضل (k_m)، طولُه (J).
$B_{(m,k_m)}$	شعاع انحياز وحدة التفاضل (k_m)، طولُه (J).

تابع تفعيل وحدة التفاضل (k_m) .	$\emptyset_{(m,k_m)}(.)$
عدد عصبونات طبقة الخرج.	C_4
عدد عصبونات الطبقة (3) وهي منظّمة في ثلاث مجموعات.	$C_3 = 3 \times C_{3i}$
الوزن المشبكي للوصلة بين العصبون (c) في الطبقة (4) والعصبون (b) في الطبقة (3).	$w_{(4,b,c)}$
حد انحياز خارجي للعصبون (c) في الطبقة (4) من الشبكة.	$w_{(4,0,c)} = b_{(4,c)}$
الوزن المشبكي للوصلة بين العصبون (c) في الطبقة (3q) والنقطة ذات الترتيب (b) في شعاع خرج الطبقة $(q - 1)$.	$w_{(3q,b,c)}$
حد انحياز خارجي للعصبون (c) في الطبقة (3) من الشبكة.	$w_{(3,0,c)} = b_{(3,c)}$
تابع تفعيل العصبون (c) في الطبقة (n).	$\emptyset_{(n,c)}(x) : \begin{pmatrix} n \in \{3, 4\} \\ 1 \leq c < C_n \end{pmatrix}$
قيمة واحدة ثابتة مفترضة.	$y_{(3,0)}(t) = +1$ $y_{(4,0)}(t) = +1$
شعاع جهود تفعيل وحدة التفاضل (k_m) في اللحظة (t).	$V_{(m,k_m)}(t)$
خارطة الميزات المولدة بوحدة التفاضل (k_m) في اللحظة (t).	$Y_{(m,k_m)}(t)$
جهد تفعيل العصبون (c) في الطبقة (n) في اللحظة (t).	$v_{(n,c)}(t) : n \in \{3, 4\}$
قيمة خرج العصبون (c) في الطبقة (n) في اللحظة (t).	$y_{(n,c)}(t) : n \in \{3, 4\}$
شعاع دخل الشبكة في اللحظة (t) وهو شعاع دخل المجموعة (1) في الطبقة (3).	$Y_0(t) = X(t)$
شعاع خرج الطبقة (1) في اللحظة (t) وهو بطول (J) وهو شعاع دخل المجموعة (2) في الطبقة (3).	$Y_1(t)$
شعاع خرج الطبقة (2) في اللحظة (t) وهو بطول (J) وهو شعاع دخل المجموعة (3) في الطبقة (3).	$Y_2(t)$
شعاع خرج المجموعة (1) في الطبقة (3) في اللحظة (t) وهو بطول (J).	$Y_{31}(t)$
شعاع خرج المجموعة (2) في الطبقة (3) في اللحظة (t) وهو بطول (J).	$Y_{32}(t)$
شعاع خرج المجموعة (3) في الطبقة (3) في اللحظة (t) وهو بطول (J).	$Y_{33}(t)$
شعاع خرج الطبقة (3) ككل في اللحظة (t) وهو بطول (3J).	$Y_3(t) = [Y_{31}(t) \ Y_{32}(t) \ Y_{33}(t)]$
شعاع خرج الطبقة (4) في اللحظة (t) وهو بطول (C_4) .	$Y_4(t)$

المسار الأمامي (Forward Pass): يُلاحظ أنّه من أجل أيّ عصبون في الطبقة الرابعة يكون:

$$y_{(4,c)}(t) = \emptyset_{(4,c)}(v_{(4,c)}(t)) = \emptyset_{(4,c)}\left(\sum_{b=0}^{c_3} w_{(4,b,c)} \cdot y_{(3,b)}(t)\right) \dots (24 - 3)$$

ومن أجل أيّ عصبون في الطبقة الثالثة يكون:

$$y_{(3q,c)}(t) = \emptyset_{(3q,c)}(v_{(3q,c)}(t)) = \emptyset_{(3q,c)}\left(\sum_{b=0}^{J-1} w_{(3q,b,c)} \cdot y_{(q-1,b)}(t)\right) \dots (25 - 3)$$

ومن أجل أيّ طبقة استخلاص ميزات يكون:

$$Y_{(n,k_n)}(t) = \emptyset_{(n,k_n)}\left(\begin{matrix} 0 \\ w_{(n,k_n,1)}(y_{(n-1,1)}(t) - y_{(n-1,0)}(t)) + b_{(n,k_n,1)} \\ w_{(n,k_n,2)}(y_{(n-1,2)}(t) - y_{(n-1,1)}(t)) + b_{(n,k_n,2)} \\ \vdots \\ w_{(n,k_n,J-1)}(y_{(n-1,J-1)}(t) - y_{(n-1,J-2)}(t)) + b_{(n,k_n,J-1)} \end{matrix}\right) \dots (26 - 3)$$

صياغة مسألة الأمثلة (Optimization Problem) لمعاملات البنية: يمكن تصنيف ثوابت النموذج الرياضي

إلى صنفين كما يوضح الجدول (5-3)، وكلّ من هذه الثوابت هو رقم.

الجدول (5-3): تصنيف ثوابت النموذج الرياضي الممثل للبنية العميقة التفاضلية

ثوابت غير محدّدة لبنية الشبكة	ثوابت محدّدة لبنية الشبكة
$w_{(1,k,i)} : (1 \leq k \leq K_1) \wedge (0 \leq i \leq J - 1)$	J
$b_{(1,k,i)} : (1 \leq k \leq K_1) \wedge (0 \leq i \leq J - 1)$	K_1
$w_{(2,k,i)} : (1 \leq k \leq K_2) \wedge (0 \leq i \leq J - 1)$	K_2
$b_{(2,k,i)} : (1 \leq k \leq K_2) \wedge (0 \leq i \leq J - 1)$	C_3
$w_{(3q,b,c)} : (0 \leq b \leq 3J - 1) \wedge (1 \leq c \leq C_3)$ $\wedge (1 \leq q \leq 3)$	C_4
$w_{(4,b,c)} : (0 \leq b \leq C_3) \wedge (1 \leq c \leq C_4)$	

بفرض حزمة بيانات التدريب:

$$DS_T = \{(X(i), Y(i)) : (T \in \mathbb{N}) \wedge (i \in \mathbb{N}) \wedge (i \leq T)\} \dots (27 - 3)$$

وتابع الخسارة (Loss Function):

$$\epsilon : \mathbb{R}^{C_4} \rightarrow \mathbb{R} : \epsilon(Y(t), Y_N(t))$$

يُلاحظ كون تابع الخسارة في أي لحظة (t) يتعلّق بكلّ من قيم الأوزان الداخلية، فالمشتقات الجزئية الآتية موجودة في أي لحظة:

$$\frac{\partial \epsilon(t)}{\partial w_{(4,b,c)}(t)} : (0 \leq b \leq C_3) \wedge (1 \leq c \leq C_4) \dots (28 - 3)$$

$$\frac{\partial \epsilon(t)}{\partial w_{(3q,b,c)}(t)} : (0 \leq b \leq J - 1) \wedge (1 \leq c \leq J) \wedge (1 \leq q \leq 3) \dots (29 - 3)$$

$$\frac{\partial \epsilon(t)}{\partial w_{(2,k,i)}(t)} : (1 \leq k \leq K_2) \wedge (0 \leq i \leq J - 1) \dots (30 - 3)$$

$$\frac{\partial \epsilon(t)}{\partial b_{(2,k,i)}(t)} : (1 \leq k \leq K_2) \wedge (0 \leq i \leq J - 1) \dots (31 - 3)$$

$$\frac{\partial \epsilon(t)}{\partial w_{(1,k,i)}(t)} : (1 \leq k \leq K_1) \wedge (0 \leq i \leq J - 1) \dots (32 - 3)$$

$$\frac{\partial \epsilon(t)}{\partial b_{(1,k,i)}(t)} : (1 \leq k \leq K_1) \wedge (0 \leq i \leq J - 1) \dots (33 - 3)$$

يُفترض معامل تعلّم (η) وتُعتدّ إجرائيّة التدريب:

For all : $t \leq T$

1) $Y_4(t)$

2) $\epsilon(Y(t), Y_4(t))$

3) $\frac{\partial \epsilon(t)}{\partial w(t)}$: for all (w)

4) $\Delta w(t) = -\eta \frac{\partial \epsilon(t)}{\partial w(t)}$: for all (w)

5) $w(t + 1) = w(t) + \Delta w(t)$

التحليل الرياضي لحل مسألة الأمثلة:

- نجد بالتحليل الرياضي أنّه من أجل $((0 \leq b \leq C_3) \wedge (1 \leq c \leq C_4))$

$$\frac{\partial \epsilon(t)}{\partial w_{(4,b,c)}(t)} = \left(\frac{\partial \epsilon(t)}{\partial y_{(4,c)}(t)} \right) \cdot \left(\emptyset_{(4,c)}^{(1)} \left(v_{(4,c)}(t) \right) \right) \cdot \left(y_{(3,b)}(t) \right) \dots (34 - 3)$$

$$\frac{\partial \epsilon(t)}{\partial w_{(4,b,c)}(t)} = \delta_{(4,c)} \cdot y_{(3,b)}(t) \dots (35 - 3)$$

- نجد بالتحليل الرياضي أنّه من أجل $((0 \leq b \leq J - 1) \wedge (1 \leq c \leq J))$:

$$\frac{\partial \epsilon(t)}{\partial w_{(31,b,c)}(t)} = \left(\emptyset_{(31,c)}^{(1)} (v_{(31,c)}(t)) \right) \cdot \left(\sum_{r=1}^{c_4} \left(\frac{\partial \epsilon(t)}{\partial y_{(4,r)}(t)} \right) \cdot \left(\emptyset_{(4,r)}^{(1)} (v_{(4,r)}(t)) \right) \cdot (w_{(4,c,r)}(t)) \right) \cdot (y_{(0,b)}(t)) \dots (36 - 3)$$

$$\frac{\partial \epsilon(t)}{\partial w_{(32,b,c)}(t)} = \left(\emptyset_{(32,c)}^{(1)} (v_{(32,c)}(t)) \right) \cdot \left(\sum_{r=1}^{c_4} \left(\frac{\partial \epsilon(t)}{\partial y_{(4,r)}(t)} \right) \cdot \left(\emptyset_{(4,r)}^{(1)} (v_{(4,r)}(t)) \right) \cdot (w_{(4,c,r)}(t)) \right) \cdot (y_{(1,b)}(t)) \dots (37 - 3)$$

$$\frac{\partial \epsilon(t)}{\partial w_{(33,b,c)}(t)} = \left(\emptyset_{(33,c)}^{(1)} (v_{(33,c)}(t)) \right) \cdot \left(\sum_{r=1}^{c_4} \left(\frac{\partial \epsilon(t)}{\partial y_{(4,r)}(t)} \right) \cdot \left(\emptyset_{(4,r)}^{(1)} (v_{(4,r)}(t)) \right) \cdot (w_{(4,c,r)}(t)) \right) \cdot (y_{(2,b)}(t)) \dots (38 - 3)$$

- وبتطبيق مفهوم المشتق المحلي (Local Gradient) في الشبكة العصبونية الأمامية:

$$\frac{\partial \epsilon(t)}{\partial w_{(31,b,c)}(t)} = \delta_{(31,c)} \cdot y_{(0,b)}(t) \dots (39 - 3)$$

$$\frac{\partial \epsilon(t)}{\partial w_{(32,b,c)}(t)} = \delta_{(32,c)} \cdot y_{(1,b)}(t) \dots (40 - 3)$$

$$\frac{\partial \epsilon(t)}{\partial w_{(33,b,c)}(t)} = \delta_{(33,c)} \cdot y_{(2,b)}(t) \dots (41 - 3)$$

- نجد بالتحليل الرياضي من أجل $((1 \leq k \leq K_2) \wedge (0 \leq i \leq J - 1))$:

$$Y_4(t) = \begin{bmatrix} y_{(4,1)}(t) \\ y_{(4,2)}(t) \\ \vdots \\ y_{(4,C_4)}(t) \end{bmatrix} \Rightarrow \left(\begin{array}{l} \frac{\partial \epsilon(t)}{\partial w_{(2,k,i)}(t)} = \sum_{r=1}^{c_4} \frac{\partial \epsilon(t)}{\partial y_{(4,r)}(t)} \cdot \frac{\partial y_{(4,r)}(t)}{\partial w_{(2,k,i)}(t)} \\ \frac{\partial \epsilon(t)}{\partial b_{(2,k,i)}(t)} = \sum_{r=1}^{c_4} \frac{\partial \epsilon(t)}{\partial y_{(4,r)}(t)} \cdot \frac{\partial y_{(4,r)}(t)}{\partial b_{(2,k,i)}(t)} \end{array} \right) \dots (42 - 3)$$

$$y_{(4,r)}(t) = \emptyset_{(4,r)} \left(\sum_{b=0}^{c_3} w_{(4,b,c)} \cdot y_{(3,b)}(t) \right) \dots (43 - 3)$$

- وبما أنّ التّابعيّة محصورة بالشّعاع $(Y_2(t))$:

$$\frac{\partial y_{(4,r)}(t)}{\partial w_{(2,k,i)}(t)} = \left(\emptyset_{(4,r)}^{(1)} (v_{(4,r)}(t)) \right) \sum_{b=0}^{J-1} (w_{(4,b,r)}(t)) \cdot \left(\frac{\partial y_{(33,b)}(t)}{\partial w_{(2,k,i)}(t)} \right) \dots (44 - 3)$$

$$\frac{\partial y_{(4,r)}(t)}{\partial b_{(2,k,i)}(t)} = \left(\emptyset_{(4,r)}^{(1)} (v_{(4,r)}(t)) \right) \sum_{b=0}^{J-1} (w_{(4,b,r)}(t)) \cdot \left(\frac{\partial y_{(33,b)}(t)}{\partial b_{(2,k,i)}(t)} \right) \dots (45 - 3)$$

$$y_{(33,b)}(t) = \emptyset_{(33,b)} \left(\sum_{c=0}^{J-1} w_{(33,c,b)} \cdot y_{(2,c)}(t) \right) \dots (46-3)$$

$$\frac{\partial y_{(33,b)}(t)}{\partial w_{(2,k,i)}(t)} = \left(\emptyset_{(33,b)}^{(1)} \left(v_{(33,b)}(t) \right) \right) \cdot (w_{(33,i,b)}) \cdot \left(\frac{\partial y_{(2,i)}(t)}{\partial w_{(2,k,i)}(t)} \right) \dots (47-3)$$

$$\frac{\partial y_{(33,b)}(t)}{\partial b_{(2,k,i)}(t)} = \left(\emptyset_{(33,b)}^{(1)} \left(v_{(33,b)}(t) \right) \right) \cdot (w_{(33,i,b)}) \cdot \left(\frac{\partial y_{(2,i)}(t)}{\partial b_{(2,k,i)}(t)} \right) \dots (48-3)$$

$$y_{(2,i)} = \sum_{k_n=0}^{K_2} \emptyset_{(2,k_n)} \left(w_{(2,k_n,i)} \left(y_{(1,i)}(t) - y_{(1,i-1)}(t) \right) + b_{(2,k_n,i)} \right) \dots (49-3)$$

$$\frac{\partial y_{(2,i)}(t)}{\partial w_{(2,k,i)}(t)} = \left(\emptyset_{(2,i)}^{(1)} \left(v_{(2,i)}(t) \right) \right) \cdot \left(y_{(1,i)}(t) - y_{(1,i-1)}(t) \right) \dots (50-3)$$

$$\frac{\partial y_{(2,i)}(t)}{\partial b_{(2,k,i)}(t)} = \left(\emptyset_{(2,i)}^{(1)} \left(v_{(2,i)}(t) \right) \right) \cdot (1) \dots (51-3)$$

$$\frac{\partial y_{(33,b)}(t)}{\partial w_{(2,k,i)}(t)} = \left(\emptyset_{(33,b)}^{(1)} \left(v_{(33,b)}(t) \right) \right) \cdot (w_{(33,i,b)}) \cdot \left(\emptyset_{(2,i)}^{(1)} \left(v_{(2,i)}(t) \right) \cdot \left(y_{(1,i)}(t) - y_{(1,i-1)}(t) \right) \right) \dots (52-3)$$

$$\frac{\partial y_{(33,b)}(t)}{\partial b_{(2,k,i)}(t)} = \left(\emptyset_{(33,b)}^{(1)} \left(v_{(33,b)}(t) \right) \right) \cdot (w_{(33,i,b)}) \cdot \left(\emptyset_{(2,i)}^{(1)} \left(v_{(2,i)}(t) \right) \right) \dots (53-3)$$

$$\frac{\partial y_{(4,r)}(t)}{\partial w_{(2,k,i)}(t)} = \left(\emptyset_{(4,r)}^{(1)} \left(v_{(4,r)}(t) \right) \right) \sum_{b=0}^{J-1} \left(w_{(4,b,r)}(t) \cdot \left(\left(\emptyset_{(33,b)}^{(1)} \left(v_{(33,b)}(t) \right) \right) \cdot (w_{(33,i,b)}) \cdot \left(\emptyset_{(2,i)}^{(1)} \left(v_{(2,i)}(t) \right) \cdot \left(y_{(1,i)}(t) - y_{(1,i-1)}(t) \right) \right) \right) \dots (54-3)$$

$$\frac{\partial y_{(4,r)}(t)}{\partial b_{(2,k,i)}(t)} = \left(\emptyset_{(4,r)}^{(1)} \left(v_{(4,r)}(t) \right) \right) \sum_{b=0}^{J-1} \left(w_{(4,b,r)}(t) \cdot \left(\left(\emptyset_{(33,b)}^{(1)} \left(v_{(33,b)}(t) \right) \right) \cdot (w_{(33,i,b)}) \cdot \left(\emptyset_{(2,i)}^{(1)} \left(v_{(2,i)}(t) \right) \right) \right) \dots (55-3)$$

$$\frac{\partial \epsilon(t)}{\partial w_{(2,k,i)}(t)} = \sum_{r=1}^{c_4} \frac{\partial \epsilon(t)}{\partial y_{(4,r)}(t)} \cdot \left(\left(\emptyset_{(4,r)}^{(1)} \left(v_{(4,r)}(t) \right) \right) \sum_{b=0}^{J-1} \left(w_{(4,b,r)}(t) \cdot \left(\left(\emptyset_{(33,b)}^{(1)} \left(v_{(33,b)}(t) \right) \right) \cdot (w_{(33,i,b)}) \cdot \left(\emptyset_{(2,i)}^{(1)} \left(v_{(2,i)}(t) \right) \cdot \left(y_{(1,i)}(t) - y_{(1,i-1)}(t) \right) \right) \right) \dots (56-3)$$

$$\frac{\partial \epsilon(t)}{\partial b_{(2,k,i)}(t)} = \sum_{r=1}^{c_4} \frac{\partial \epsilon(t)}{\partial y_{(4,r)}(t)} \cdot \left(\left(\emptyset_{(4,r)}^{(1)} \left(v_{(4,r)}(t) \right) \right) \sum_{b=0}^{J-1} \left(w_{(4,b,r)}(t) \cdot \left(\left(\emptyset_{(33,b)}^{(1)} \left(v_{(33,b)}(t) \right) \right) \cdot (w_{(33,i,b)}) \cdot \left(\emptyset_{(2,i)}^{(1)} \left(v_{(2,i)}(t) \right) \right) \right) \dots (57-3)$$

$$\frac{\partial \epsilon(t)}{\partial w_{(2,k,i)}(t)} = \emptyset_{(2,i)}^{(1)} \left(v_{(2,i)}(t) \right) \cdot \left(\sum_{b=0}^{J-1} \delta_{(33,b)} \cdot w_{(33,i,b)} \right) \cdot \left(y_{(1,i)}(t) - y_{(1,i-1)}(t) \right) \dots (58-3)$$

$$\frac{\partial \epsilon(t)}{\partial \mathbf{b}_{(2,k,i)}(t)} = \emptyset_{(2,i)}^{(1)} \left(\mathbf{v}_{(2,i)}(t) \right) \cdot \left(\sum_{b=0}^{J-1} \delta_{(33,b)} \cdot \mathbf{w}_{(33,i,b)} \right) \dots (59-3)$$

- ويلاحظ بروز مشتق محلي لخلية وحدة التفاضل (k) :

$$\frac{\partial \epsilon(t)}{\partial \mathbf{w}_{(2,k,i)}(t)} = \delta_{(2,k,i)} \cdot \left(\mathbf{y}_{(1,i)}(t) - \mathbf{y}_{(1,i-1)}(t) \right) \dots (60-3)$$

$$\frac{\partial \epsilon(t)}{\partial \mathbf{b}_{(2,k,i)}(t)} = \delta_{(2,k,i)} \dots (61-3)$$

- نجد بالتحليل الرياضي أنه من أجل $((1 \leq k \leq K_1) \wedge (0 \leq i \leq J-1))$:

$$\mathbf{Y}_4(t) = \begin{bmatrix} \mathbf{y}_{(4,1)}(t) \\ \mathbf{y}_{(4,2)}(t) \\ \vdots \\ \mathbf{y}_{(4,C_4)}(t) \end{bmatrix} \Rightarrow \left(\begin{array}{l} \frac{\partial \epsilon(t)}{\partial \mathbf{w}_{(1,k,i)}(t)} = \sum_{r=1}^{C_4} \frac{\partial \epsilon(t)}{\partial \mathbf{y}_{(4,r)}(t)} \cdot \frac{\partial \mathbf{y}_{(4,r)}(t)}{\partial \mathbf{w}_{(1,k,i)}(t)} \\ \frac{\partial \epsilon(t)}{\partial \mathbf{b}_{(1,k,i)}(t)} = \sum_{r=1}^{C_4} \frac{\partial \epsilon(t)}{\partial \mathbf{y}_{(4,r)}(t)} \cdot \frac{\partial \mathbf{y}_{(4,r)}(t)}{\partial \mathbf{b}_{(1,k,i)}(t)} \end{array} \right) \dots (62-3)$$

$$\mathbf{y}_{(4,r)}(t) = \emptyset_{(4,r)} \left(\sum_{b=0}^{C_3} \mathbf{w}_{(4,b,c)} \cdot \mathbf{y}_{(3,b)}(t) \right) \dots (63-3)$$

- وبما أن التابعية محصورة بالشعاعين $(\mathbf{Y}_1(t))$ و $(\mathbf{Y}_2(t))$:

$$\frac{\partial \mathbf{y}_{(4,r)}(t)}{\partial \mathbf{w}_{(1,k,i)}(t)} = \left(\emptyset_{(4,r)}^{(1)} \left(\mathbf{v}_{(4,r)}(t) \right) \right) \sum_{b=0}^{J-1} \left(\mathbf{w}_{(4,b,r)}(t) \right) \cdot \left(\frac{\partial \mathbf{y}_{(3q,b)}(t)}{\partial \mathbf{w}_{(1,k,i)}(t)} \right) : \mathbf{q} \in \{3, 2\} \dots (64-3)$$

$$\frac{\partial \mathbf{y}_{(4,r)}(t)}{\partial \mathbf{b}_{(1,k,i)}(t)} = \left(\emptyset_{(4,r)}^{(1)} \left(\mathbf{v}_{(4,r)}(t) \right) \right) \sum_{b=0}^{J-1} \left(\mathbf{w}_{(4,b,r)}(t) \right) \cdot \left(\frac{\partial \mathbf{y}_{(3q,b)}(t)}{\partial \mathbf{b}_{(1,k,i)}(t)} \right) : \mathbf{q} \in \{3, 2\} \dots (65-3)$$

$$\mathbf{y}_{(32,b)}(t) = \emptyset_{(32,b)} \left(\sum_{c=0}^{J-1} \mathbf{w}_{(32,c,b)} \cdot \mathbf{y}_{(1,c)}(t) \right) \dots (66-3)$$

$$\mathbf{y}_{(33,b)}(t) = \emptyset_{(33,b)} \left(\sum_{c=0}^{J-1} \mathbf{w}_{(33,c,b)} \cdot \mathbf{y}_{(2,c)}(t) \right) \dots (67-3)$$

$$\frac{\partial \mathbf{y}_{(32,b)}(t)}{\partial \mathbf{w}_{(1,k,i)}(t)} = \left(\emptyset_{(32,b)}^{(1)} \left(\mathbf{v}_{(32,b)}(t) \right) \right) \cdot \left(\mathbf{w}_{(32,i,b)} \right) \cdot \left(\frac{\partial \mathbf{y}_{(1,i)}(t)}{\partial \mathbf{w}_{(1,k,i)}(t)} \right) \dots (68-3)$$

$$\frac{\partial y_{(32,b)}(t)}{\partial b_{(1,k,i)}(t)} = \left(\emptyset_{(32,b)}^{(1)} \left(v_{(32,b)}(t) \right) \right) \cdot (w_{(32,i,b)}) \cdot \left(\frac{\partial y_{(1,i)}(t)}{\partial b_{(1,k,i)}(t)} \right) \dots (69 - 3)$$

$$\frac{\partial y_{(33,b)}(t)}{\partial w_{(1,k,i)}(t)} = \sum_{c=0}^{J-1} \left(\emptyset_{(33,b)}^{(1)} \left(v_{(33,b)}(t) \right) \right) \cdot (w_{(33,c,b)}) \cdot \left(\frac{\partial y_{(2,i)}(t)}{\partial w_{(1,k,i)}(t)} \right) \dots (70 - 3)$$

$$\frac{\partial y_{(33,b)}(t)}{\partial b_{(1,k,i)}(t)} = \sum_{c=0}^{J-1} \left(\emptyset_{(33,b)}^{(1)} \left(v_{(33,b)}(t) \right) \right) \cdot (w_{(33,c,b)}) \cdot \left(\frac{\partial y_{(2,i)}(t)}{\partial b_{(1,k,i)}(t)} \right) \dots (71 - 3)$$

$$y_{(1,i)} = \sum_{k_n=0}^{K_1} \emptyset_{(1,k_n)} \left(w_{(1,k_n,i)} \left(y_{(0,i)}(t) - y_{(0,i-1)}(t) \right) + b_{(1,k_n,i)} \right) \dots (72 - 3)$$

$$y_{(2,i)} = \sum_{k_n=0}^{K_2} \emptyset_{(2,k_n)} \left(w_{(2,k_n,i)} \left(y_{(1,i)}(t) - y_{(1,i-1)}(t) \right) + b_{(2,k_n,i)} \right) \dots (73 - 3)$$

$$\frac{\partial y_{(1,i)}(t)}{\partial w_{(1,k,i)}(t)} = \left(\emptyset_{(1,i)}^{(1)} \left(v_{(1,i)}(t) \right) \right) \cdot \left(y_{(0,i)}(t) - y_{(0,i-1)}(t) \right) \dots (74 - 3)$$

$$\frac{\partial y_{(1,i)}(t)}{\partial b_{(1,k,i)}(t)} = \left(\emptyset_{(1,i)}^{(1)} \left(v_{(1,i)}(t) \right) \right) \cdot (1) \dots (75 - 3)$$

$$\frac{\partial y_{(2,i)}(t)}{\partial w_{(1,k,i)}(t)} = \sum_{k_n=0}^{K_2} \left(\emptyset_{(2,k_n)}^{(1)} \left(v_{(2,i)}(t) \right) \right) \cdot (w_{(2,k_n,i)}) \cdot \left(\frac{\partial y_{(1,i)}(t)}{\partial w_{(1,k,i)}(t)} \right) \dots (76 - 3)$$

$$\frac{\partial y_{(2,i)}(t)}{\partial b_{(1,k,i)}(t)} = \sum_{k_n=0}^{K_2} \left(\emptyset_{(2,k_n)}^{(1)} \left(v_{(2,i)}(t) \right) \right) \cdot (1) \dots (77 - 3)$$

$$\frac{\partial y_{(1,i)}(t)}{\partial w_{(1,k,i)}(t)} = \left(\emptyset_{(1,i)}^{(1)} \left(v_{(1,i)}(t) \right) \right) \cdot \left(y_{(0,i)}(t) - y_{(0,i-1)}(t) \right) \dots (78 - 3)$$

- وبذلك يكون:

$$\frac{\partial y_{(32,b)}(t)}{\partial w_{(1,k,i)}(t)} = \left(\emptyset_{(32,b)}^{(1)} \left(v_{(32,b)}(t) \right) \right) \cdot (w_{(32,i,b)}) \cdot \left(\left(\emptyset_{(1,i)}^{(1)} \left(v_{(1,i)}(t) \right) \right) \cdot \left(y_{(0,i)}(t) - y_{(0,i-1)}(t) \right) \right) \dots (79 - 3)$$

$$\frac{\partial y_{(32,b)}(t)}{\partial b_{(1,k,i)}(t)} = \left(\emptyset_{(32,b)}^{(1)} \left(v_{(32,b)}(t) \right) \right) \cdot (w_{(32,i,b)}) \cdot \left(\emptyset_{(1,i)}^{(1)} \left(v_{(1,i)}(t) \right) \right) \dots (80 - 3)$$

$$\begin{aligned} & \frac{\partial y_{(33,b)}(t)}{\partial w_{(1,k,i)}(t)} \\ &= \sum_{c=0}^{J-1} \left(\emptyset_{(33,b)}^{(1)} \left(v_{(33,b)}(t) \right) \right) \cdot (w_{(33,c,b)}) \cdot \left(\sum_{k_n=0}^{K_2} \left(\emptyset_{(2,k_n)}^{(1)} \left(v_{(2,i)}(t) \right) \right) \cdot (w_{(2,k_n,i)}) \cdot \left(\frac{\partial y_{(1,i)}(t)}{\partial w_{(1,k,i)}(t)} \right) \right) \dots (81 - 3) \end{aligned}$$

$$\frac{\partial y_{(33,b)}(t)}{\partial b_{(1,k,i)}(t)} = \sum_{c=0}^{J-1} \left(\varnothing_{(33,b)}^{(1)}(v_{(33,b)}(t)) \cdot (w_{(33,c,b)}) \cdot \left(\sum_{k_n=0}^{K_2} \left(\varnothing_{(2,k_n)}^{(1)}(v_{(2,i)}(t)) \right) \right) \dots (82-3) \right)$$

$$\begin{aligned} & \frac{\partial y_{(4,r)}(t)}{\partial w_{(1,k,i)}(t)} \\ &= \left(\varnothing_{(4,r)}^{(1)}(v_{(4,r)}(t)) \right) \sum_{b=0}^{J-1} \left(w_{(4,b,r)}(t) \cdot \left(\left(\varnothing_{(32,b)}^{(1)}(v_{(32,b)}(t)) \right) \cdot (w_{(32,i,b)}) \cdot \left(\left(\varnothing_{(1,i)}^{(1)}(v_{(1,i)}(t)) \right) \cdot (y_{(0,i)}(t) - y_{(0,i-1)}(t)) \right) \right) \right) \\ &+ \left(\varnothing_{(4,r)}^{(1)}(v_{(4,r)}(t)) \right) \sum_{b=0}^{J-1} \left(w_{(4,b,r)}(t) \cdot \left(\sum_{c=0}^{J-1} \left(\varnothing_{(33,b)}^{(1)}(v_{(33,b)}(t)) \right) \cdot (w_{(33,c,b)}) \cdot \left(\sum_{k_n=0}^{K_2} \left(\varnothing_{(2,k_n)}^{(1)}(v_{(2,i)}(t)) \right) \cdot (w_{(2,k_n,i)}) \cdot \left(\left(\varnothing_{(1,i)}^{(1)}(v_{(1,i)}(t)) \right) \cdot (y_{(0,i)}(t) \right. \right. \right. \\ &\left. \left. \left. - y_{(0,i-1)}(t)) \right) \right) \right) \dots (83-3) \end{aligned}$$

$$\begin{aligned} \frac{\partial y_{(4,r)}(t)}{\partial b_{(1,k,i)}(t)} &= \left(\varnothing_{(4,r)}^{(1)}(v_{(4,r)}(t)) \right) \sum_{b=0}^{J-1} \left(w_{(4,b,r)}(t) \cdot \left(\left(\varnothing_{(32,b)}^{(1)}(v_{(32,b)}(t)) \right) \cdot (w_{(32,i,b)}) \cdot \left(\varnothing_{(1,i)}^{(1)}(v_{(1,i)}(t)) \right) \right) \right) \\ &+ \left(\varnothing_{(4,r)}^{(1)}(v_{(4,r)}(t)) \right) \sum_{b=0}^{J-1} \left(w_{(4,b,r)}(t) \cdot \left(\sum_{c=0}^{J-1} \left(\varnothing_{(33,b)}^{(1)}(v_{(33,b)}(t)) \right) \cdot (w_{(33,c,b)}) \cdot \left(\sum_{k_n=0}^{K_2} \left(\varnothing_{(2,k_n)}^{(1)}(v_{(2,i)}(t)) \right) \right) \right) \dots (84-3) \end{aligned}$$

- ويلاحظ بروز مشتقات محلية في الوحدة (k) وبتطبيق مفهوم المشتقات المحلية:

$$\delta_{(11,k,i)} = \varnothing_{(1,i)}^{(1)}(v_{(1,i)}(t)) \cdot \left(\sum_{b=0}^{J-1} \delta_{(32,b)} \cdot w_{(32,i,b)} \right) \dots (85-3)$$

$$\delta_{(12,k,i)} = \varnothing_{(1,i)}^{(1)}(v_{(1,i)}(t)) \cdot \sum_{k_n=0}^{K_2} \delta_{(2,k_n,i)} \cdot w_{(2,k_n,i)} \dots (86-3)$$

$$\frac{\partial \epsilon(t)}{\partial w_{(1,k,i)}(t)} = (\delta_{(11,k,i)} + \delta_{(12,k,i)}) \cdot (y_{(0,i)}(t) - y_{(0,i-1)}(t)) \dots (87-3)$$

$$\frac{\partial \epsilon(t)}{\partial b_{(1,k,i)}(t)} = \delta_{(11,k,i)} + \delta_{(12,k,i)} \dots (88-3)$$

وبتحديد صيغ التعديل الوزني بعد معرفة علاقات المشتقات المختلفة لتابع الخسارة يكتمل تصميم البنية المطلوبة

ويمكن اعتماد هذا التصميم في مسائل واقعية وتقييمه.

وبالرغم من تعقيد التحليل الرياضي وطوله، إلا أن الفقرات السابقة توضح إمكانية تصميم بنى عميقة خاصة بمسائل

صيانة تنبؤية محدّدة، وهذه التصميمات ترسخ فهم نقاط فاعلية البنى العميقة وتؤسس لوضع طرق واستراتيجيات عمل

على مسائل تطبيقية كما سيشرح الفصل الآتي.

3.3. وضع استراتيجية عامة لمعالجة مسألة الصيانة التنبؤية باستخدام التعلّم العميق:

بعد دراسة كلّ من مسألة الصيانة التنبؤية في شكلها العام، ومنهج التعلّم العميق كأسس ومفاهيم وتطبيقات، يهدف هذا الفصل إلى توظيف كلّ ما سبق دراسته من أجل وضع استراتيجية عامة لمعالجة مسألة الصيانة التنبؤية، تحقق العموميّة والفاعليّة.

1.3.3. تحليل في مسألة الصيانة التنبؤية:

إنّ مسألة الصيانة التنبؤية، كمسألة هندسيّة متكاملة، يُمكن إنجازها بالعمل على محورين وظيفيّين:

- المحور الأول هو محور تصميم هندسي تخصّصي مُتكامل مع أعمال تصميم الآلة أو التّجهيز الهندسيّة قيد المُعالَجة، وفيه تُوضَع تصاميم بنيويّة خاصّة بالصيانة التنبؤية مثل تحديد تقنيّات مراقبة الحالة المناسبة وتوصيف تجهيزات التّحسّس.

- المحور الثّاني هو محور عمل في مسألة معالجة بيانات، وضّحتها الفقرة (8.1.2).

فمسألة الصيانة التنبؤية يشترك في معالجتها مهندسو تصميم متخصصون في مجال تصميم الآلة أو التّجهيز، كمجال التّصميم الميكانيكي أو الكهربائي أو الإلكتروني، ومهندس بيانات، مهمّته استيعاب مجمل المعلومات التّصميميّة الخاصّة بهذه الآلة أو التّجهيز، وتصميم البنية المناسبة كآلة صيانة تنبؤية تُعالج صنفين رئيسيّين من البيانات هما:

(1) بيانات توصيف أداء (Operation Description Data) للآلة أو التّجهيز قيد المُعالَجة، وتُصنّف بدورها إلى صنفين:

- بيانات التّشغيل المثاليّة (Ideal Operation Data).

- بيانات تدهور الأداء والأعطال (Degradation & Faults Data).

(2) بيانات إشارات قياس (Measurement Signals Data) في الزّمن الحقيقي، تحمل محتوى معلوماتي واصلف لحالة الآلة أو التّجهيز قيد المراقبة، وهذه البيانات تُصنّف إلى ثلاثة أصناف:

• بيانات حسّاسات مراقبة الحالة (Condition Monitoring Sensors Data).

• بيانات حسّاسات ومشغلات المتحكّات (Controllers Sensors & Actuators Data).

• بيانات حسّاسات بيئة التشغيل (Environment Monitoring Sensors Data).

وعموماً، يُطبّق منهج الصيانة التنبؤية على آلة أو جهاز فيزيائي ذي تصميم هندسي محدّد، ويمتلك دراسة هندسية تصميمية، ويهتمّ مهندس الصيانة التنبؤية، كمهندس بيانات، بالأجزاء الآتية من هذه الدراسة:

• دراسة تحديد نقاط النّحسّ والتّشغيل المناسبة للتّحكّم بالآلة أو الجهاز، وفيها تُحدّد معاملات مثل مواقع

التركيب ودقّة القياس وزمن الاستجابة، وتُعدّ تفاصيل هذه المعاملات مهمّة بالنسبة إلى مهندس الصيانة التنبؤية.

• دراسة تحديد نقاط النّحسّ المناسبة لمراقبة حالة الآلة، كحساسات الاهتزاز والإصدار الصوتي والإصدار

الحراري، وكذلك تُحدّد عوامل مثل مواقع التركيب ودقّة القياس وزمن الاستجابة.

• دراسة تحديد نقاط النّحسّ المناسبة لمراقبة حالة بيئة التشغيل، وهذه الدراسة تُعدّ أساسية في العديد من

الصناعات، كالدوائية والغذائية، وتكمن أهميتها بالنسبة إلى مهندس الصيانة التنبؤية في ارتباط مؤشرات حالة

معينة، كالتراكم الحراري، مع حالة بيئة التشغيل.

• دراسة توصيف خصائص التشغيل للآلة أو الجهاز، التي تُصاغ على شكل ملفّات ذات صياغة قياسية،

كملف فلسفة التشغيل (Operation Philosophy) وملف دراسة استجابات الآلة (Cause-Effect)

(Study) وملف سياسة الإيقاف الطارئ (Emergency Stop Policy).

• دراسة نظام التّحكّم، التي تُحدّد نقاط الدّخل والخرج وإجرائيات التّحكّم، وسلوك الحلقات التّحكّمية والعلاقات

بينها، وتُقدّم هذه الدراسة معلومات مهمّة في تصميم آلة الصيانة التنبؤية كزمن الصّعود (Rise Time) وقيمة

التّجاوز (Overshoot) وزمن الاستقرار (Settling Time) في الحلقات التّحكّمية.

تُعدّ صياغة خصائص التشغيل على شكل قواعد وعلاقات كمية وأنماط تربط معاملات التشغيل ومراقبة الحالة

والبيئة مهمّة أساسية أمام مهندس الصيانة التنبؤية، والاستناد إلى البنود المذكورة من الدراسة التصميمية يجعل هذه

المهمّة أكثر تنظيماً وفاعلية، خصوصاً في مرحلة وضع مخطّط التجارب التشغيلية التي تهدف إلى التعرّف إلى

خصائص تشغيل معينة كالإقلاع في حالات مختلفة، والانتقال من طور تشغيل إلى آخر، فالتجارب التشغيلية مرحلة أساسية من مراحل صياغة خصائص التشغيل، خصوصاً في تحديد خصائص تدهور الأداء والأعطال، لأن هذه الخصائص تستعصي على النمذجة الكمية وتظهر كأنماط غير انسيابية، والأهم أنها مكان تقاطع جوانب هندسية متعددة، فمثلاً وجود عطل تآكل محور دوار يرتبط مع ظهور نمط شاذ في وسم التيار الكهربائي للمحرك المرتبط معه، وظهور أنماط شاذة في إشارات الاهتزاز، وظهور خلل في استقرار حلقة التحكم بسرعة المحرك. وبمراجعة أنواع إشارات تحسّس الحالة شائعة الاستخدام في تصميم الآلات والأجهزة يُلاحظ أنّ الميزات المعبرة عن الحالة الصحية تُستخلص بتطبيق تقنيات معالجة الإشارة، مثل:

• **التحليل الترددي أو الطيفي**، خصوصاً في معالجة إشارات الاهتزاز الميكانيكي وإشارات الإصدار الصوتي وفوق الصوتي [7].

• **التحليل الزمني الإحصائي**، كرصد ارتفاع مطال الإشارة ورصد ظهور أنماط أو قيم شاذة فيها.

• **التحليل الزمني-الترددي**، كرصد نمو وتطور مركبة ترددية معينة في طيف الإشارة.

وآلة الصيانة التنبؤية، كآلة معالجة إشارة، تُصمّم كموديل له خصائص استجابة زمنية مناسبة لاستيعاب محتوى الإشارات من الميزات دون ضياع، وبذلك يبني الموديل التنبؤات والتقييمات مع مراعاة التعبير الزمني للإشارات المختلفة الذي قد يكون من رتبة ميلي ثانية في إشارات الاهتزاز، ويرتفع إلى رتبة الثواني في إشارات الإصدار الحراري. وعموماً، تؤخذ معاملات الاستجابة الزمنية وترددات الاعتيان من دراسات تحديد نقاط التحسّس التي تُبنى على أساس الطبيعة الفيزيائية للآلة الهندسية وأنماط حالاتها الصحية كظواهر فيزيائية.

الخاصية التنبؤية (Predictive Facility) في تقنية الصيانة التنبؤية يمكن تبسيطها إلى القدرة على الكشف المبكر عن أعطال معينة قبل تطورها إلى أعطال أكبر وأكثر خطورة وكلفة، مع تقديم معلومات تغيد في تحديد نطاق التدهور من أجل تدخل إصلاحي سريع وفعال، وبذلك يمكن اعتبار أنّ كشف أعطال بسيطة من قبل آلة الصيانة التنبؤية كأعراض مبكرة لأعطال كبيرة هو شكل من أشكال التنبؤ.

2.3.3. فاعلية التعلم العميق كمنهج في معالجة مسألة الصيانة التنبؤية:

الفاعلية الأكثر أهمية في تقنيات التعلم العميق من منظور الصيانة التنبؤية هي الاستخلاص الآلي للميزات (Automatic Feature Extraction) والاستغناء عن مرحلة استخلاص الميزات اليدوي، حيث تمتلك البنية العميقة المقدرة على استخلاص الميزات الدقيقة من حزم البيانات والمعبرة عن المسألة الأساسية التي تعالجها هذه البنية.

يُضاف إلى فاعلية الاستخلاص الآلي للميزات خاصية مهمة في البنى العميقة هي المقدرة التمثيلية الإدراكية العميقة (Deep Representational Perceptual Capability)، فالبنية العميقة قادرة على تمثيل تركيبات هرمية متدرجة للميزات المضمنة في بيانات دخلها حتى عندما تكون الميزات من أنماط مختلفة وبتراكيب معقدة، والمقدرة التمثيلية تُصمم في بنية عميقة من خلال وضع تنظيم بنيوي طبقي ذي مخطط مسارات إدراكية مناسب، حيث يكون دور مهندس التعلم العميق هو توجيه عملية استخلاص الميزات الآلي بتصميم بنية عميقة ذات مقدرة تمثيلية إدراكية مناسبة وتحسين هذه البنية تجريبياً، وذلك يُفيد في مسألة الصيانة التنبؤية التي يهدف حلها إلى توليد معلومات تنبؤية حقيقية استناداً إلى الميزات المستخلصة دون الاهتمام بهذه الميزات بحد ذاتها، وفاعلية الاستخلاص الآلي للميزات تُتيح التعامل مع ميزات لا يمكن تمثيلها بصورة مفهومة بشرياً.

كما أن التعلم العميق هو منهج مُقاد بالبيانات (Data-Driven) ولذلك عادةً يتم تمثيل المعرفة الموجودة لدى مهندس التعلم العميق عن المسألة الأساسية بحزم بيانات، ومن منظور مسألة الصيانة التنبؤية تتيح هذه الفاعلية سهولة في التصميم وتضمين عوامل مؤثرة من خلال وضع تأثير هذه العوامل ضمن حزم البيانات المجهزة للتدريب، وذلك يكون على درجة عالية من الأهمية عند تمثيل خصائص أداء الآلة الهندسية الذي يُعطى في الدراسات التصميمية على شكل قواعد عامة وعلاقات بين معاملات تشغيلية.

ويمتلك منهج التعلم العميق فاعلية كون القرارات والأحكام التي تعطيها البنى العميقة تتمتع بسماحية الخطأ (Fault-Tolerance) وهذا ما يعني عدم انهيار قرار البنية العميقة عند مواجهة حالات واقعية جديدة تماماً بل مقدرتها على ترجيح كون الحالات الجديدة تتبع نمط معين، وهذه الميزة تجعل منهج التعلم العميق فعال للغاية في معالجة

مسألة صيانة تنبؤية كون أحكام آلة الصيانة التنبؤية ترجيحية، ككشف تدهور للأداء وترجيح كونه مرتبطاً بعطل في جزء من الآلة أو التجهيزة.

3.3.3. وضع مراحل الاستراتيجية المقترحة لمعالجة مسألة الصيانة التنبؤية:

يُقدّم تنظيم عملية تصميم آلة الصيانة التنبؤية باستخدام تقنية التعلم العميق في تسلسل المراحل الآتية (A – M):
(A) استلام الدراسة الهندسية للآلة الفيزيائية (Physical Machine Engineering Study) التي يجب تصميم آلة صيانة تنبؤية لها.

(B) تحديد نطاق آلة الصيانة التنبؤية (PdM Machine Scope Identification) وحصر مجموعة الأعطال المحتملة وعلاقاتها البيئية، والنطاق يتدرج تعقيداً كما يلي:

• جهاز (Equipment).

• آلة (Machine).

• خط إنتاج (Production Line).

• معمل (Factory) أو نظام تصنيع (Manufacturing System).

(C) تحليل فلسفة التشغيل واستجابات الآلة ونظام التحكم، بهدف:

C.1. تحديد الإشارات والمعاملات المترابطة بحلقات وإجراءات تحكم، وتحديد تردد الاعتيان المناسب أو المتاح لتحصيل البيانات من هذه الإشارات.

C.2. تحديد الترابطات الواجب رصدها بين إشارات ومعاملات في حالات التشغيل المختلفة.

C.3. وضع توصيف عام لسلوك الآلة الفيزيائية في الحالات المثالية وحالات تدهور الأداء وحالات الأعطال استناداً إلى الخطوتين السابقتين وإلى فلسفة التشغيل.

(D) مراجعة دراسة منظومة تحسس ومراقبة حالة الآلة وحالة البيئة، بهدف:

D.1. تصنيف إشارات تحسس الحالة إلى مجموعات كلّ منها تخصّ طبيعة فيزيائية محدّدة (اهتزاز ميكانيكي – إصدار صوتي – إصدار فوق صوتي – إصدار حراري...).

D.2. حصر أنماط الأداء المرتبطة بإشارات هذه الحساسات، ويُقصد بأنماط الأداء حالات تشغيل مثالية وحالات أعطال مختلفة.

D.3. تحديد تردد الاعتيان المناسب لكل من إشارات تحسّس الحالة استناداً إلى الدراسة الفيزيائية للإشارة وعلاقتها بأنماط الأداء للآلة ككل، أي تحديد ترددات حديثة بتجاوزها تضيع ميزات معبرة عن أنماط أداء.

(E) تجهيز حزم بيانات التدريب:

E.1. تجهيز حزم بيانات واصفة للسلوك المثالي للآلة الفيزيائية في حالات تشغيل مختلفة، برصد إشارات نظام التحكم وإشارات حساسات الحالة والبيئة، ويتطلب ذلك تشغيل الآلة الفيزيائية فعلياً في ظروف التشغيل المختلفة.


E.2. تجهيز حزم بيانات واصفة لأعطال الآلة الفيزيائية في حالات تشغيل مختلفة. والطريقة الأفضل هي افتعال أعطال في أجزاء محدّدة من الآلة مخبرياً وتحصيل بيانات التشغيل بوجود هذه الأعطال، ومن الممكن إنجاز ذلك تحليلياً من خلال تطبيق ظواهر الأعطال المقدّمة نظرياً على حزم بيانات السلوك المثالي المحصّلة عملياً لاصطناع حزم بيانات الأعطال.

E.3. تجهيز حزم بيانات واصفة لتدهور أداء الآلة الفيزيائية في حالات تشغيل مختلفة، بصورة تحليلية، وذلك عند توفر المعلومات الواصفة لتدهور الأداء، أو بصورة تجريبية عند كون ذلك متاحاً، ويمكن الاستغناء عن هذه المرحلة في المسائل التي يتوفّر فيها حزم بيانات واصفة للأعطال ودراسة تؤكّد أنّ طبيعة الميزات نامية خطياً مع سير تشكّل الأعطال.

(F) من أجل كلّ من إشارات تحسّس الحالة، إجراء التحليل الآتي على مستوى إشارة وحيدة:

- F.1.** دراسة طبيعة الميزات المضمّنة في الإشارة، ككون الميزات مثلاً ترددية، زمنية، مكانية، إحصائية.
- F.2.** وضع مسألة تصنيف ثنائي ببنية عميقة تناسب طبيعة الميزات وبإشارة دخل وحيدة هي هذه الإشارة وبالحالي خرج (أداء سليم - عطل)، كون حالة العطل توافق بيانات أيّ عطل من الأعطال المرتبطة بهذه الإشارة، وحل هذه المسألة بعد تقدير قيمة ابتدائية لطول النافذة الزمنية من الإشارة الكافي لإعطاء حكم بوجود عطل أو عدم وجوده.
- F.3.** أمثلة طول النافذة الزمنية السابق بتغييره مع بقاء المصنّف ناجحاً.

- F.4. وضع تقدير لعدد وطبيعة تراكم الميزات الفرعية استناداً إلى الموديل الأكثر نجاحاً كمصنّف ثنائي.
- F.5. وضع مسألة تصنيف متعدّد ببنية عميقة بإشارة دخل وحيدة هي هذه الإشارة، وبحالات خرج متعدّدة هي الأعطال المرتبطة ببيانات هذه الإشارة مع حالة وضع سليم، وتحدّد بنية المصنّف استناداً إلى طول النافذة الزمنية وعدد وطبيعة تراكم الميزات الفرعية المحدّدين في (F.3 – F.4)، ويوضع قرار التصنيف بصيغة احتمالية كحالة تابع تفعيل (Softmax). وحلّ هذه المسألة من خلال أمثلة بنية المصنّف.
- F.6. أمثلة طول النافذة الزمنية السابق بتغييره مع بقاء المصنّف المتعدّد ناجحاً.
- F.7. تحديث تقدير عدد وطبيعة تراكم الميزات الفرعية استناداً إلى بنية المصنّف المتعدّد الأكثر نجاحاً.
- F.8. تصميم مقيّم صحة (Health Evaluator) مناسب باستخدام بيانات تدهور الأداء المجهزة في (E.3). حيث يمكن، مثلاً، تصميم مرزّز آلي عميق ومعامل تقييم صحة متناسب مع طاقة الرمز الوسيط، وفي حالة أنماط



الشكل (2-3): بنية عميقة متعدّدة المسارات خاصّة بإشارة تحسّس

ميّزات نامية خطئياً يمكن نسخ المصنّف الثنائي في (F.2) وتعديل الموديل الجديد ليصبح مقيّم صحة يجعل تابع تفعيل طبقة الخرج فيه أكثر نعومة.

F.9. الآن توجد بنية عميقة متعدّدة المسارات يوضّحها الشكل (2-3)، وهي ذات زمن استجابة يساوي طول النافذة الزمنية المحدّد، بالإضافة إلى تقدير للميّنات الفرعية وتراكبها.

(G) دراسة الترابط المتبادل بين إشارات تحسّس الحالة على مستوى الأعطال، بتحديد الإشارات المرتبطة بكلّ عطل من أعطال الآلة، وذلك بهدف تخطيط مسارات ارتباط الإشارات في آلة الصيانة التنبؤية النهائية.

(H) من أجل كلّ مجموعة إشارات ومعاملات تشغيل وإشارات بيئة مترابطة بحلقات تحكّم، يتمّ وضع مسألة تنبؤ بالقيمة (Value Prediction) ببنية عميقة تُدرّب ببيانات التشغيل المثالية الخاصة بهذه الإشارات، ومن ثمّ وضع معيار تقييم انحراف (Drift Evaluator) دخله هو خطأ التنبؤ للبنية السابقة وقيمه تتناسب عكساً مع هذا الخطأ بحيث يأخذ قيمة عظمى على بيانات التشغيل المثالي وقيمة دنيا على بيانات الأعطال وقيمة متناسبة مع مدى التدهور على بيانات تدهور الأداء.

(I) تصميم بنية حساب الانحراف الإجمالي عن وضع التشغيل المثالي للآلة، دخلها هو قيم تقييمات الانحراف لإشارات التشغيل ومعاملاته في الخطوة (H).

(J) من أجل كلّ عطل، تصميم بنية حسابية تقوم بحساب قيمة احتمال إجمالي حالي لوقوع العطل كمسألة حساب احتمالية حدث هو هذا العطل، تعتمد على:

- قيم الاحتمال من كل محدّد عطل في بنية خاصّة بإشارة تحسّس حالة ترتبط بهذا العطل مصمّمة في (F.9).
- قيم الحالة الصحيّة من كل مقيّم صحّة في بنية خاصّة بإشارة تحسّس حالة ترتبط بهذا العطل مصمّمة في (F.9).

- قيمة الانحراف الإجمالي عن وضع التشغيل المثالي المعطاة من البنية المصمّمة في (I).

(K) تصميم بنية حسابية تعطي تقييماً إجمالياً للحالة الصحيّة للآلة الفيزيائية اعتماداً على:


- قيم الحالة الصحيّة المعطاة من كل مقيّم صحّة في بنية عميقة خاصّة بإشارة تحسّس حالة.
- قيمة الانحراف الإجمالي عن وضع التشغيل المثالي.

(L) تصميم بنية حسابية تعمل فقط عند كشف عطل وتعطي خرج ثنائي بوجود عطل أو عدم وجوده مع خرج

البنية المصمّمة في (J)، دخلها هو خرج كل كاشف عطل في بنية خاصّة بإشارة تحسّس حالة ترتبط بهذا العطل

مصمّمة في (F.9)، وتتفعل عند تجاوز قيمة خرج أيّ كاشف عطل القيمة (95%).

(M) ضم جميع البنى السابقة في آلة الصيانة التنبؤية النهائية (PdM Machine) كبنية متعددة المسارات تُنظّم شبكة مساراتها بحسب الخطوات (B – F – G – I – J – K – L) وهي تعمل على صعيد التشخيص (Diagnosis) والتنبؤ (Prognosis) ويوضحها الشكل (3-3).



الشكل (3-3): بنية آلة الصيانة التنبؤية النهائية (PdM Machine)

وهكذا تصبح مسألة الصيانة التنبؤية مسألة قابلة للحل باستخدام تسلسل عمل مدروس، ومن المهم تقييم فاعلية الاستراتيجية المقترحة على الحالات التطبيقية المتنوعة، حيث يعالج الفصل الآتي واحدة من هذه الحالات.

4.3. تطبيق الاستراتيجية المقترحة لمعالجة مسألة الصيانة التنبؤية على حالة رولمان

دوّار بسرعات دورانية متغيرة:

الحالة التي يُعالجها هذا الفصل هي تجربة مخبرية منقّدة في قسم الهندسة الميكانيكية في جامعة أوتاوا في كندا من قبل اثنين من الباحثين في عام (2018)، وبيانات هذه التجربة مُصاغة على شكل حزم بيانات قياسية [25]، وسوف يُستعرض تنظيم هذه التجربة وبياناتها تباعاً وفق الاستراتيجية المقترحة في معالجة مسألة صيانة تنبؤية.


1.4.3. مراحل العمل:

أ) استلام الدراسة الهندسية:

المنظومة التي يُصمّم لها آلة صيانة تنبؤية هي منظومة مخبرية مؤلفة من محور دوّار (Rotating Axe) محكوم بواسطة رولمانين (Bearings) أحدهما في حالة مثالية والآخر في حالات مختلفة من الأعطال الممكنة بصورة

مفتعلة بهدف التجريب، ويقود هذا المحور الدّوّار محرّك كهربائي مُقاد بمتحكّم سرعة (AC Drive)، حيث يدور بسرعات دورانيّة مختلفة، ويوضّح الشّكل (3-4) تنظيم هذه الجملة الهندسيّة.

وتوجد ورقة بيانات (Data Paper) واصفة لهذه التّجربة ولمحتوى حزمة البيانات المتاحة على شبكة الإنترنت [25].



الشّكل (3-4): تنظيم جملة المحور الدّوّار والمحرّك المخبريّة [25]

(ب) تحديد نطاق آلة الصيانة التنبؤية والأعطال:

نطاق آلة الصيانة التنبؤية في هذه الحالة هو الرّولمان قيد التّشخيص (Diagnosed Bearing)، أي إنّ النّطاق هو عنصر من آلة (Machine Part)، وبما أنّ الرّولمان يعدّ عموماً نقطة ضعف في أيّ آلة ميكانيكيّة لكون الأعطال التي تظهر في رولمان تؤثر بعمق على أداء الآلة الميكانيكيّة ككل وقد تقود إلى أعطال أكبر وأخطر (71 [صفحة 89])، فإنّ المسألة يمكن عدّها جزءاً من تصميم آلة صيانة تنبؤية على مستوى آلة.

تغطّي بيانات التّجربة خمس حالات صحيّة (Health Conditions) للرّولمان المشخّص، توافق هذه الحالات الصحيّة خمسة أعطال محتملة في الرّولمان يوضّحها الجدول (3-6)، وهذه الأعطال افْتُعِلت في بنية الرّولمان بهدف الحصول على بيانات واقعيّة.

الجدول (3-6): الحالات الصحيّة المختلفة للرّولمان

Healthy.	صحّة جيّدة.
Faulty with an inner race defect.	عطل سببه تضرّر المضجع الدّاخلي.

Faulty with an outer race defect.	عطل سببه تضرّر المضجع الخارجي.
Faulty with a ball defect.	عطل سببه تضرّر الكرات.
Faulty with combined defects on inner race, outer race and a ball.	عطل سببه تضرّر كلّ من المضجعين الداخلي والخارجي والكرات معاً.

(ج) تحليل فلسفة التشغيل واستجابات الآلة ونظام التّحكّم:

المعامل الأساسي في متابعة تشغيل هذه الجملة الميكانيكية الكهربائية هو السرعة الدورانية للمحور الدّوّار (Axe

Rotational Speed) ولا توجد تفاصيل توضّح بنية نظام التّحكّم في السرعة، وتُفيد التجربة أنّ التشغيل المخبري

تمّ بشكل شمل أربع حالات لسرعة التشغيل الدورانية هي:

- حالة سرعة متزايدة (Increasing speed).
- حالة سرعة متناقصة (Decreasing speed).
- حالة سرعة متزايدة ثمّ متناقصة (Increasing then decreasing speed).
- حالة سرعة متناقصة ثمّ متزايدة (Decreasing then increasing speed).

تمّ تحصيل قيمة سرعة التشغيل الدورانية للمحور الدّوّار بواسطة مرّمز (Encoder) نوع (Incremental

Encoder) يمتلك قيمة (Cycles Per Revolution / CPR = 1024).

(د) مراجعة دراسة منظومة تحسّس ومراقبة حالة الآلة:

رُكّب حسّاس اهتزاز (Accelerometer) على الرّولمان المشخّص بهدف تحصيل إشارة اهتزاز من هذا الرّولمان

في الزّمن الحقيقي، وهي إشارة تحسّس الحالة الوحيدة في هذه التجربة. والاهتزاز الميكانيكي كظاهرة فيزيائية يرتبط

بصورة وثيقة بالطّيف التّرددي المعبّر عنه، فمعظم الأعطال الميكانيكية في الآلة تعبر عن نفسها بمركّبات تردّدية

أو أطياف تردّدية في الطّيف التّرددي العام لإشارة الاهتزاز، ([2] الفصل 7.72)، وتسري هذه الحقيقة على إشارات

الاهتزاز المحصلة من رولمان دوّار، حيث يعتمد المنهج التقليدي في الصيانة التنبؤية إلى رصد مركّبات تردّدية

محدّدة في طيف إشارة اهتزاز الرّولمان بهدف تشخيص حالته، فالحالات الصحية المختلفة للرّولمان ترتبط بصورة

وثيقة مع نمط إشارة الاهتزاز الصّادرة عنه ([7] صفحة 88). ومن ثمّ يوجد ترابط وثيق بين الحالة الصحية

للرّولمان، كواحدة من الحالات الخمس المذكورة، وبين ملف الاهتزاز المسجّل من حساس الاهتزاز.

ويُميز في الطيف الترددي لإشارة اهتزاز رولمان أربع قيم ترددات أساسية تتناسب قيمة كل منها طردياً مع سرعة دوران المحور بثوابت تتعلق بأبعاد الرولمان، وتكون الأنماط الترددية المعبرة عن أعطال الرولمان من مضاعفات هذه القيم وفي جوار هذه المضاعفات [7]:

- Ball Spin Frequency [BSF].
- Fundamental Train Frequency [FTF].
- Ball Pass Frequency Outer ring [BPFO].
- Ball Pass Frequency Inner ring [BPFI].

ومن المهم الانتباه إلى حقيقة أنّ تغيرات طبيعة وطاقّة الطيف الترددي للرولمان مع تشكّل أعطال معينة فيه تكون نامية تبدأ بقيم صغيرة وتزداد مع تطوّر العطل [7] (صفحة 89)، وهذه المعلومة مفيدة في تصميم مقيّم الصحة لاحقاً. ومجال الرصد الترددي لإشارة الاهتزاز يتراوح عادةً بين (0.5 – 20 [KHz]).

إشارات الاهتزاز التي تمّ تحصيلها خلال التجارب تمّ اعتيائها بتردد اعتياني قيمته (Sampling Frequency = 200 [KHz])، وزمن نافذة الاعتيان هو (Sampling Duration = 10 [Sec])، ومن ثمّ المحتوى الترددي لكل إشارة اهتزاز يغطّي مجال حدّه الأعظمي (100 [KHz]).

هـ) تجهيز حزم بيانات التدريب:

إنّ نطاق المسألة هو رولمان دوّار بسرعات متغيرة، وإشارة القياس الوحيدة المغذية لآلة الصيانة التنبؤية هي إشارة اهتزاز هذا الرولمان كإشارة تحسّس حالة وحيدة، وبالرغم من وجود إشارة المرمز المعبرة عن السرعة الدورانية، إلّا أنّ هذه الإشارة مضمّنة في ملف الاهتزاز كون الاهتزازات الصادرة تتعلّق بسرعة دوران الرولمان بشكل لحظي [7]، ومع حقيقة النمو التدريجي للأنماط الطيفية خلال تطوّر العطل، فيلزم تجهيز بيانات اهتزاز توصّف في حالات التشغيل المختلفة كلّ من السلوك المثالي للرولمان وأعطال الرولمان فقط. تقدّم التجربة (60) حزمة بيانات تغطّي الحالات الصحية الخمس للرولمان وحالات السرعة الدورانية الأربع لكل حالة، حيث يوجد بيانات (20) حالة تشغيلية مختلفة من حيث الحالة الصحية وحالة السرعة الدورانية، ولكلّ من هذه الحالات العشرين توجد ثلاث حزم

قياس لزيادة الموثوقية، وتضم كل حزمة من هذه الحزم الستين حزمتين فرعيتين إحداهما بيانات اهتزاز بطول زمني (10) ثوانٍ و(2000000) عينة، والثانية تضم بيانات المرمز الموافقة.

حوّلت حزم البيانات من الصيغة (.mat) إلى ملفات (CSV) باستخدام بيئة (Matlab) كون ملفات (CSV) أفضل للاستخدام في بيئة (Jupiter)، وعدد الملفات بعد التحويل كان مجموعة من (120) ملف بيانات منظّمة إلى خمسة مجموعات كل منها توافق حالة من الحالات الصحية للزولمان الخمس المذكورة سابقاً، وكل مجموعة تتكوّن من (24) ملف تتنظم على شكل (12) زوج من الملفات كل زوج هو ملف إشارة اهتزاز وملف إشارة سرعة دورانية، وذلك يتطابق مع وجود أربع حالات للسرعة الدورانية وثلاثة قياسات لكل حالة. ولتنظيم التعامل وُضعت صيغة موحّدة لتسمية كل ملف من المئة والعشرين ملفاً تحدّد الإشارة التي يمثلها هي (X-Y-N-CHi) ويوضح الجدول (7-3) دلالات هذه الصيغة.

الجدول (7-3): دلالات صيغة تسمية الإشارات في معالجة مسألة الزولمان


المحرف	الدلالة	القيم الممكنة
X	الحالة الصحية التي تمثلها الإشارة	H: Healthy Bearing
		I: Inner Race Fault
		O: Outer Race Fault
		B: Ball Fault
		C: Combination of Faults
Y	حالة السرعة الدورانية للزولمان	A: Increasing speed
		B: Decreasing speed
		C: Increasing then decreasing speed
		D: Decreasing then increasing speed
N	رقم التجربة	(1) أو (2) أو (3)
CHi	قناة الإشارة	CH1: Vibration Signal
		CH2: Encoder Signal

وبذلك توجد حزم بيانات اهتزاز توافق الحالة المثالية لعمل الزولمان في جميع حالات السرعة المتغيرة، وعدد هذه الحزم (12) حزمة كل منها بطول (2000000) عينة وبطول زمني يساوي عشر ثوانٍ. ويوجد لكل حالة عطل

من أعطال الرولمان (12) حزمة بيانات اهتزاز توافق حالة هذا العطل للرولمان في جميع حالات السرعة المتغيرة، كل منها بطول (2000000) عينة وبطول زمني يساوي عشر ثوان.

(و) تصميم بنية الكشف والتحديد والتقييم من أجل إشارة الاهتزاز كإشارة تحسّس حالة:

و.1. طبيعة الميزات المضمّنة في إشارة الاهتزاز ترددية، كون الأعطال الميكانيكية في الآلة تعبر عن نفسها بمركبات ترددية وأنماط أطراف ترددية في الطيف الترددي لإشارة اهتزاز محصلة منها، وبالفعل عند تطبيق التحليل الترددي على إشارات الاهتزاز الخاصة بكل حالة صحية لوحظ وجود أنماط للطيف الترددي تشترك فيها الإشارات الممثلة لحالة صحية واحدة وفي الوقت نفسه تتمايز أطراف الإشارات الخاصة بحالات صحية متغيرة. والتحليل الترددي المنجز يهدف إلى تأكيد قضية الطبيعة الترددية للميزات في إشارات الاهتزاز، ولا يهدف إلى استخلاص أية ميزات أو أنماط لأن ذلك سيكون دور البنى العميقة التي ستوضع لاحقاً، وعلى سبيل العرض، يعرض الشكل (5-3) الطيف الترددي لإشارة الاهتزاز (H-A-2-CH1).



الشكل (5-3): الطيف الترددي لإشارة الاهتزاز (H-A-2-CH1)

إنّ نمط العمل المرصود للرولمان هو في حالات سرعات دورانية متغيرة وليست ثابتة، والطيف الترددي يتغير مع تغير السرعة [7]، ويجب أخذ هذه الحقيقة بالحسبان في تصميم البنى العميقة. وبخصوص الميزات الزمنية لإشارات الاهتزاز، فالمعاملات الأكثر أهمية هي متوسطات مطال الاهتزاز التي تزداد في حالات الأعطال عامةً، ولكن هذه الميزات الزمنية تكون مضمّنة في الطيف الترددي لإشارة الاهتزاز.

و.2. اتّبع تصميم كاشف العطل كمصنّف ثنائي دورة حياة بنية عميقة بدأت بصياغة المسألة كمسألة تصنيف ثنائي لأشعة دخل أحادية البعد موسومة بوسم يحدّد كونها تمثّل حالة عطل أو عمل سليم. وفي تحصيل البيانات استُخدمت جميع إشارات اهتزاز الحالة الصحيّة السليمة في حالات السرعة المختلفة ووسمها بالقيمة (0.0)، واستُخدمت جميع إشارات اهتزاز النّجربة (1) لكلّ من الأعطال وحالات السرعة ووسمها بالقيمة (1.0)، فالإشارات المستخدمة هي (H-Z-Z-CH1) و (Z-Z-1-CH1) من أجل كل قيم (Z) الممكنة بحسب الجدول (3-7). وفي تجهيز البيانات حُدّد طول النّافذة الزّمنية الواحدة المقطعة من إشارة اهتزاز، والذي يجب أن يحمل الميّزات دون ضياع، بالاعتماد على التّحليل الآتي:


- ترّد اعتيان إشارات الاهتزاز ($f_s = 200 \text{ [KHz]}$) والمحتوى التّردي للإشارات ذو حد أعظمي (100 [KHz]).

- طول المجال التّردي الذي تظهر فيه الميّزات في الزّولمان هو من رتبة (20 [KHz])، ومعاملات تغيّر القيم مع تغيّرات السرعة الدّورانية تزيد عن (100) [7].

- ومن ثمّ دقّة الطّيف التّردي (Spectrum Resolution) من رتبة عشرات الهرتز مقبولة.

- وبتحديد طول النّافذة (50 [mS]) أي (10000) عيّنة من إشارة الاهتزاز باقتطاع تقسمي دون انزلاق تكون دقّة الطّيف (20 [Hz]).

- بإجراء تحليل طيفي على خمس إشارات اهتزاز توافق الحالات الصحيّة الخمس للزّولمان، وعلى نافذة بهذا الطّول من كلّ منها، تبيّن أنّ إشارة النّافذة تحمل محتوى ترددي معبّر مشابه للإشارة الأصليّة كما يوضّح الشّكل (3-6).




الشكل (3-6): مقارنة الأطياف الترددية للإشارات ككل ولنوافذ مقطوعة منها بطول (50) ميلي ثانية

الحفاظ على شكل النوافذ الزمني هو أمر ضروري لعدم التأثير على الطيف الترددي، وبمراجعة الأشكال العامة لكل إشارات الاهتزاز تبين أن مجال المطال لأي إشارة يقع ضمن $(-1 + 1)$ ولا يتجاوزه إلا بعدد ضئيل جداً من العينات في عدد قليل من الإشارات، وبذلك تنحصر المعالجة الأولية في تسوية هذه القيم الشاذة إلى المجال $(-1 + 1)$ واستخلاص النوافذ الزمنية بطول (10000) عينة لكل منها ووضع الوسوم لتجهيز حزمة التدريب النهائي. وفي تحديد البنية العميقة، بمراعاة طبيعة ميزات إشارة الاهتزاز وكون البيانات موسومة، حُدِّدَت البنية (1D-CNN) كبنية مناسبة لأن استخلاص الميزات الآلي يتم بتنفيذ طي بين شعاع دخل وحيد البعد، هو النافذة

(Window) المقطوعة الموسومة، وبين مرشحات داخلية وحيدة البعد تُضبط قيمها بالتدريب، ويعني ذلك أن مصنف (1D-CNN) يبني قرار التصنيف بعد التدريب (وجود عطل / عدم وجود عطل) استناداً إلى تحليل ترددي خاص لشعاع الدّخل يتم فيه ترشيح هذا الشعاع ترددياً بمرشحات ضُبطت قيمها تدريبياً بحيث تتحسّس الميزات الترددية المميزة لحالة الشعاع.

يشير مصطلح (عينّة) إلى عينّة من عينات إشارة الاهتزاز الأصلية ذات (2000000) عينّة، والطول الزمني بين عينتين هو (0.000005) ثانية، بينما (عينّة تدريب) تشير إلى نافذة ذات طول (10000) عينّة أو (50) ميلي ثانية، وتنظيم طبقات المصنّف كان كما يوضّح الشكل (3-7).



الشكل (3-7): بنية كاشف العطل كمصنّف ثنائي

يمتلك المصنّف في مرحلة استخلاص الميزات طبقتي طَي (Conv1D) متعاقبتين تفصلهما طبقة تقصّي (MaxPooling1D). طبقة الطَي الأولى مهمتها استخلاص الميزات الترددية الأساسية من النافذة الزمنية، وتابع تفعيلها هو التابع المطابق (Identity) للحفاظ على الشكل الزمني لشعاع الدّخل، وطبقة الطَي الثانية مهمتها تركيب الميزات الترددية الأساسية إلى عدد مناسب من الميزات العامة المرتبطة بالحالة الصحية للرولمان. ومرحلة التصنيف تتكوّن من طبقة (Dense) عدد عصبوناتا يساوي عدد مرشحات طبقة الطَي الثانية الذي هو عدد ميزات نهائية مركّبة، تليها طبقة (Dense) ثانية وحيدة العصبون كطبقة خرج تابع تفعيلها هو (sigmoid)، وذلك لأنّ مسألة التصنيف بعد تنفيذ استخلاص الميزات ستكون بسيطة ولا تحتاج عدد طبقات أكثر من طبقتين.

ولبدء التدريب والاختبار، وُضعت قيم معاملات المصنّف كمتحوّلات مستقلة (Independent Variables) يعرضها الجدول (3-8) ومتحوّلات مضبوطة يعرضها الجدول (3-9).

الجدول (3-8): المتحوّلات المستقلة في تجربة كاشف العطل

المتحوّل	القيمة	الواحدة	تبرير تحديد القيمة
نسبة عيّنات التدريب	68%	من	• سياسة تقسيم شائعة.
نسبة عيّنات التّحقّق	17%	حزمة	• إتاحة وجود حجم عيّنات تدريب كافٍ
نسبة عيّنات الاختبار	15%	البيانات	• لتقارب المصنّف.
طول المرشّح في طبقة الطّي الأولى	1001	عيّنة	• تحقيق دقّة مناسبة في طيف الفلتر التّرددي. • تجنّب حالات (Overfitting) و (Underfitting). • توليد خارطة ميّزات (Feature map) بطول (9000) عيّنة، كقيمة مناسبة.
حجم نافذة التّقصّي في طبقة (MaxPooling1D).	100	عيّنة	• الدخل هو خارطة ميّزات زمنية بطول (9000) عيّنة يحمل طيفها التّرددي ميّزة أساسية محدّدة، وقرار التّصنيف يهتم بوجود هذه الميّزة ولا يهتمّ بتفاصيل شكلها. • الخرج هو خارطة ميّزات زمنية بطول (90) عيّنة يكتّف التّقصّي الأعظمي تعبيرها عن وجود ميّزة دون الاهتمام بتفاصيل هذه الميّزة. • هذه القيم تخفّض عدد معاملات الموديل، ممّا يجنّب حالات (Overfitting) و (Underfitting).
طول خطوة التّقصّي في طبقة (MaxPooling1D).	100	عيّنة	
طول المرشّح في طبقة الطّي الثّانية	90	عيّنة	• توليد خارطة ميّزات (Feature Map) بطول عيّنة واحدة، وهذه الطبقة مسؤولة عن تحديد وجود أو عدم وجود ميّزة عامّة، ومن ثمّ هذه القيمة مناسبة لإعطاء هذا الحكم.

تابع تفعيل طبقة الطّي الثانية	Relu	---	• خرج هذه الطبقة يصل إلى مرحلة التصنيف، وهذا التابع يلغي القيم السالبة، وهذا يناسب مرحلة التصنيف.
تابع الخسارة (Loss) (Function)	Binary Crossentropy	---	• يستخدم هذا التابع عادةً في مسائل التصنيف الثنائي.
خوارزمية التدريب (Optimizer)	Adam	---	• محسّن بسيط ويحقّق آلية ضبط معدّل التعلّم.
معامل مراقبة الأداء	الدقة (Accuracy)	%	• مناسب، ويستخدم عادةً في مسائل التصنيف الثنائي.

الجدول (3-9): المتحوّلات المضبوطة أثناء تدريب كاشف العطل

المتحوّل	المجال التجريبي	تبرير تحديد مجال القيم التجريبي
عدد المرشحات في طبقة الطّي الأولى	[1 - 7]	هو مجال عدد الميزات الترددية الأساسية المرتبطة بعطل ميكانيكي بحسب الدراسات النظرية.
عدد المرشحات في طبقة الطّي الثانية	[1 - 7]	مجال متوقّع لعدد الميزات العامة.
القيمة الابتدائية لعدد أدوار التدريب (Epochs)	20	تُحدّد القيمة الأنسب مع سير التجارب.

قبل البدء بأمثلة كاشف العطل، صُمّمت مصنّعات ثنائية بين حالة (Healthy) وحالة كلّ عطل لوحده بهدف تحديد قيم ابتدائية للمتحوّلات المضبوطة، وبيّنت النتائج أنّ أربعة مرشحات في كلّ طبقة طي وتدريب لمدة 12 دوراً تعطي مصنّعات دقة اختبارها مثالية (Test Accuracy = 100%)، ومن هذه القيم بدأت عملية تدريب وأمثلة كاشف العطل الكلّي ليتبيّن أنّ (6) مرشحات في طبقة الطّي الأولى و(5) مرشحات في طبقة الطّي الثانية، والتدريب (15) دوراً تعطي مصنّفاً أدائه ممتاز، كما يوضّح الجدول (3-10).


واعتمد هذا المصنّف ككاشف عطل باسم (Fault_Detector_6_5)، لأنّ زيادة عدد المرشحات، وإن رفعت دقة الاختبار إلى (100%) إلا أنّها ستقود حتماً إلى حالات (Overfitting).

الجدول (3-10): أمثلة معاملات كاشف العطل كمصنّف ثنائي في حالة الرّولمان

A	B	C	Accuracy			Loss		
			Train	Val	Test	Train	Val	Test
4	4	12	0.9916	0.9937	0.99285715818	0.0259	0.0190	0.02218683353
4	4	22	0.9976	0.9916	0.99285715818	0.0104	0.0260	0.03301928492
5	4	20	0.9989	0.9863	0.98333334922	0.0058	0.0702	0.05869572730
7	4	11	0.9950	0.9968	0.99285715818	0.0218	0.0118	0.02203554666
6	5	15	1.0000	0.9979	0.99761903285	0.0005	0.0049	0.01256358206

A = Filter count in 1st Conv1d layer
B = Filter count in 2nd Conv1d layer
C = Total Count of Training Epochs


وكانت معاملات رصد تدريب المصنّف (Fault_Detector_6_5) متّصفة بالانسيابية والنّعومة كما يوضّح الشّكل (3-8).



الشّكل (3-8): معاملات أداء (Fault_Detector_6_5) أثناء تدريبه

اختبِر كاشف العطل (Fault_Detector_6_5) على إشارات اهتزاز للرّولمان لم يتمّ التّدريب أو التّحقّق أو الاختبار عليها أثناء التّصميم، ومن دون تطبيق أيّة معالجة أوليّة، وكان الأداء جيّداً جداً كما يوضّح الشّكل (3-9). فكاشف العطل يقدّم قيمة احتماليّة كل (50) ميلي ثانية، وفي مرحلة الاستثمار الواقعي سيُبنى قرار كشف عطل في أطر زمنيّة من رتبة النّواني، وهذا يعني أنّ قيمة خرج ستؤخذ كمتوسّط لعدد من قيم الخرج من رتبة العشرات، وهذا يقود إلى تنعيم القيمة الذي سيجعلها مطابقة للحكم الثّنائي الصّحيح.

و3. ولا داعي لأمثلة طول النّافذة الزّمنيّة (50) ميلي ثانية لأنّ الأداء عنده ممتاز وهو يحقّق الإفادة من تردّد الاعتيان العالي لإشارة الاهتزاز، ولكنّ وضع خطوة انسحاب (Stride) عمليّة الطّي في أوّل طبقة طي رَفَع قيمة دقّة الاختبار إلى (100%)، وقيمة دقّة الاختبار على الإشارات الجديدة إلى (99.91%).



الشكل (3-9): نتائج اختبار (Fault_Detector_6_5) على إشارات جديدة

و4. يمكن تقدير طبيعة الميزات المضمنة في الإشارة ذات الطول (10000)، والكافية لإعطاء حكم بوجود أو


عدم وجود عطل، بأنها تنتظم في هرمية من مستويين، الأول يحمل ست ميزات أساسية، والثاني يحمل خمس

ميّزات مركّبة بصورة معيّنة من الميّزات الأساسية، وكل ميّزة مركّبة في المستوى الثاني تتعلّق بجميع الميّزات في المستوى الأساسي.

و.5. اتّبع تصميم محدّد العطل كمصنّف متعدّد دورة حياة بنية عميقة بدأت بصياغة المسألة كمسألة تصنيف متعدّد لأشعة دخل أحاديّة البعد طولها (10000) عيّنة بعد نجاح هذا الطّول في كشف العطل، موسومة بوسم يحدّد الحالة الصحيّة المرتبطة بها، من خلال تعريف خمسة وسوم هي (1.0 - 2.0 - 3.0 - 4.0) توافق الأعطال الأربعة و(0.0) كحالة عدم وجود عطل. وفي تحصيل البيانات اختيرت لكلّ من الحالات الصحيّة الخمس، بيانات ثمانية قياسات زمنيّة كل منها بطول (10) ثوانٍ وبحالة سرعة دورانيّة من الحالات الأربع، ويوضّح الجدول (3-11) إشارات الاهتزاز المستخلص منها بيانات تدريب محدّد العطل واختباره، وتمّ استخلاص نوافذ زمنيّة بطول (10000) عيّنة لكلّ منها، ووسم النّوافذ بواحد من خمسة وسوم توافق الحالة الصحيّة.

الجدول (3-11): إشارات الاهتزاز المستخلص منها بيانات تدريب محدّد العطل واختباره

الإشارة	الحالة الصحيّة الموافقة
H-X-1-CH1 (X = A, B, C, D)	Healthy bearing
H-X-2-CH1 (X = A, B, C, D)	
I-X-1-CH1 (X = A, B, C, D)	Inner Race Fault
I-X-2-CH1 (X = A, B, C, D)	
O-X-1-CH1 (X = A, B, C, D)	Outer Race Fault
O-X-2-CH1 (X = A, B, C, D)	
B-X-1-CH1 (X = A, B, C, D)	Ball Fault
B-X-2-CH1 (X = A, B, C, D)	
C-X-1-CH1 (X = A, B, C, D)	Combination of Faults
C-X-2-CH1 (X = A, B, C, D)	



الشكل (3-10): بنية محدّد العطل كمصنّف متعدّد

في تجهيز البيانات، حُوِّلت الوسوم إلى ترميز (One-Hot Encoding)، وحُدِّدت البنية العميقة كمصنّف (1D-CNN) ذي طبقتي طي، استناداً إلى طبيعة الميزات وتراكبها المستنتجة في (F.4)، ويوضّح الشكل (3-10) بنية محدّد العطل العامة.

طبقة الطّي الأولى في المصنّف المتعدّد تمتلك تابع تفعيل مطابق (Identity)، وطبقة الطّي الثانية تمتلك تابع تفعيل (Relu)، ومرحلة التصنيف تتكوّن من طبقتين كاملتي الاتصال، الأولى عدد عصبوناتا يساوي عدد مرشّحات طبقة الطّي الثانية، والثانية عدد عصبوناتا يساوي عدد الأصناف وهو خمسة، وتابع تفعيلها هو (Softmax) المستخدم في مسائل التصنيف المتعدّد، والذي يعطي توزيعاً احتمالياً بين الأصناف المختلفة كخرج. ولبدء التدريب والاختبار وُضِعَت قيم معاملات المصنّف المتعدّد كمتحوّلات مستقلة (Independent Variables) يعرضها الجدول (3-12)، ومتحوّلات مضبوطة يعرضها الجدول (3-13).

الجدول (3-12): المتحوّلات المستقلة في تصميم محدّد العطل كمصنّف متعدّد

المتحوّل	القيمة	الواحدة	تبرير تحديد القيمة
نسبة عيّنات التدريب	68%	من	• سياسة تقسيم شائعة، وكانت ناجحة في تجربة تصميم كاشف العطل.
نسبة عيّنات التّحقّق	17%	حزمة	
نسبة عيّنات الاختبار	15%	البيانات	
طول المرشّح في أوّل طبقة طي	1001	عيّنة	• استناداً إلى نتائج تجربة تصميم كاشف العطل، اعتُمدت هذه القيم مع نجاحها في كشف الميّزات، مع وضع انسحاب بقيمة (10) في أوّل طبقة طي وتصغير نافذة وخطوة التقصّي إلى (10) لتحقيق دقّة تردديّة أعلى.
خطوة انسحاب الطّي في أوّل طبقة طي	10	خطوة	
طول نافذة تقصّي (MaxPooling1D).	10	عيّنة	
طول خطوة تقصّي (MaxPooling1D).	10	عيّنة	
طول المرشّح في ثاني طبقة طي	90	عيّنة	
خطوة انسحاب الطّي في ثاني طبقة طي	1	خطوة	

تابع الخسارة (Loss) (Function)	Categorical Crossentropy	---	• مناسب لمسائل التصنيف المتعدد.
خوارزمية التدريب (optimizer)	Adam	---	• نجح هذا المحسن في حل مسألة تصميم كاشف العطل.
مقياس مراقبة الأداء	الدقة (Accuracy)	---	• مناسب، وشائع في مسائل التصنيف المتعدد.

الجدول (3-13): المتحولات المضبوطة في تصميم محدّد العطل

المتحول	مجال القيم التجريبي	تبرير تحديد مجال القيم التجريبي
عدد المرشحات في أول طبقة طي	يبدأ من (6) صعوداً	استناداً إلى تقدير طبيعة الميزات المنجز .
عدد المرشحات في ثاني طبقة طي	يبدأ من (5) صعوداً	
متوسط عدد أدوار التدريب (Epochs)	يبدأ من (20)	استناداً إلى سير تجربة تصميم كاشف العطل ونتاؤها.

ولتمييز المصنّفات التجريبية التي تختلف بعدد المرشحات في طبقتها، اعتمد الترميز الآتي:

$$FI_{X_Y} : \begin{cases} X: \text{Filters Count in 1st Conv Layer} \\ Y: \text{Filters Count in 2nd Conv Layer} \end{cases}$$

جُرب عدد من قيم (X, Y) وتبيّن أنّ زيادة عدد المرشحات عن (6, 7) لا يقود إلى تحسين كبير في الأداء الذي هو في حالة ممتازة بدءاً من هاتين القيمتين، ويعرض الجدول (3-14) معاملات تدريب واختبار لبعض المصنّفات. وقد اختُبرت جميع هذه المصنّفات على إشارات اهتزاز للرولمان لم يتمّ التدريب أو التّحقّق أو الاختبار عليها في التصميم، وهي الإشارات (Z-Z-3-CH1) من أجل كل قيم (Z) الموجودة، ويعرض الجدول (3-15) نتائج هذا الاختبار الذي على أساسه اختير المصنّف (FI_6_7) ككاشف العطل.


وكان قد لزم لتدريب المصنّف (FI_6_7) ثمانية عشر دور تدريب، وحقّقت معاملات رصد تدريبه نعومة وانسيابية تدلّ على نجاح الموديل وأنّه مناسب للمسألة كما يوضّح الشكل (3-11).

الجدول (3-14): معاملات تدريب بعض البنى المجربة واختبارها كمحدد عطل

X	Y	E	Accuracy			Loss		
			Training	Validation	Testing	Training	Validation	Testing
6	5	22	1.0000	0.9898	0.9918	0.0018	0.0241	0.01884
6	7	18	1.0000	0.9964	0.9950	0.0018	0.0118	0.01265
8	6	18	0.9976	0.9906	0.9926	0.0115	0.0345	0.02748
10	8	20	1.0000	0.9964	0.9959	0.0003	0.0061	0.01976
15	8	12	1.0000	0.9942	0.9926	0.0015	0.0257	0.02316
X: Filters Count in 1 st Conv1D layer								
Y: Filters Count in 2 nd Conv1D layer								
E: Epochs Count								

الجدول (3-15): نتائج اختبار بنى مصنفات كمحدد عطل على الإشارات (Y-X-3-CH1)

Classifier → ↓ Input Waveform	FI_6_5	FI_6_7	FI_8_6	FI_10_8	FI_15_8
HA3	98.00%	99.28%	98.26%	99.44%	99.39%
HB3	96.50%	98.86%	97.97%	99.41%	99.04%
HC3	99.23%	99.27%	97.63%	99.43%	99.39%
HD3	90.82%	97.22%	91.01%	97.05%	93.15%
IA3	99.06%	98.99%	95.49%	99.00%	99.10%
IB3	99.21%	99.01%	98.22	99.50%	99.29%
IC3	98.72%	99.33%	95.87	99.48%	99.05%
ID3	99.44%	99.41%	98.58	98.98%	98.80%
OA3	99.50%	99.49%	99.44%	99.50%	99.50%
OB3	99.45%	99.21%	98.86%	99.49%	99.50%
OC3	99.49%	99.44%	99.41%	99.50%	99.50%
OD3	99.39%	99.28%	99.04%	99.47%	99.46%
BA3	95.49%	99.06%	97.42%	98.20%	97.64%
BB3	84.75%	95.83%	93.32%	88.40%	87.15%
BC3	99.38%	99.39%	99.13%	99.49%	99.30%
BD3	88.27%	91.53%	91.03%	91.89%	91.85%
CA3	98.77%	98.78%	98.00%	99.30%	99.39%
CB3	98.32%	98.46%	98.18%	98.40%	99.10%
CC3	99.46%	98.26%	98.12%	99.44%	99.47%
CD3	99.33%	98.70%	97.64%	99.11%	99.45%
Average Accuracy:	97.13%	98.44%	97.13%	98.22%	97.93%




الشكل (3-11): معاملات أداء محدّد العطل (FI_6_7) أثناء تدريبه

و6. وكان طول النافذة الزمنية (50) ميلي ثانية كافياً لتحقيق دقة كشف عطل (99.91%)، ودقة تحديد عطل (98.5%)، وهي قيم ممتازة تعني أنّ هذا الطول مناسب ولا يحتاج للأمثلة.


و7. ولدراسة طبيعة الميزات وتراكبها، يوضّح الشكل (3-12) القيم الزمنية لمرشحات طبقة الطّي الأولى في كاشف العطل. وباستعراض الأطياف الترددية لهذه المرشحات في الشكل (3-13)، يُلاحظ أنّ المرشحات تهتمّ بكشف أنماط ترددية ولا تهتمّ بمركبات محدّدة، وهذه الخاصية هي التي أكسبت كاشف العطل قدرته على توليد الخرج الصحيح مع تغيير السرعة الدورانية للزولمان وتغيّر نمط طيف الاهتزاز معه.

Time Waveform of the 1st Conv layer six filters




الشكل (3-12): القيم الزمنية لمرشحات طبقة الطّي الأولى في كاشف العطل

وباستعراض الأطياف الترددية لمرشحات طبقة الطّي الثانية في كاشف العطل، والبالغ عددهم ثلاثين، التي يعرضها الشكل (3-14)، يُلاحظ أنّ هذه المرشحات تمتلك قيم ترشيح حدية مركّزة على ترددات منخفضة، وهذا ينسجم مع عمل طبقة (Maxpooling). وبذلك نجد أنّ طبقة الطّي الأولى تستخلص ستّة أنماط ميزات ترددية أساسية



الشكل (3-13): الأطياف الترددية لمرشحات طبقة الطي الأولى في كاشف العطل

يصعب الوصول إليها بالتحليل اليدوي، وهي تكفي لقرار التصنيف، وطبقة الطي الثانية تستخلص ميزات نهائية مركبة تعبر عن مستوى طاقة الميزات الترددية الأساسية في شعاع الدخّل.



الشكل (3-14): الأطياف الترددية لمرشحات طبقة الطي الثانية في كاشف العطل

وتكرار التحليل السابق من أجل مرشحات محدّد العطل يعطي نتائج مشابهة تماماً.

و8. بما أنّ طبيعة الأنماط الترددية للزولمان تنمو بشكل خطّي في ظهورها مع تطوّر تشكّل العطل في الزولمان، وبمراجعة التحليل المنجز في (F.7)، يمكن تصميم مقيّم صحة (Health Evaluator) للزولمان بنسخ كاشف

العطل وجعل تابع تفعيل عصبون الخرج (sigmoid) أكثر نعومةً تجاه شعاع دخله بإعطاء الثابت (α) قيمة تتراوح بين (0.2 – 0.5) في صيغته الرياضية:

$$\text{Sigmoid}(X) = \frac{1}{1 + e^{-\alpha X}} \dots (89 - 3)$$

وبذلك تكون النسبة المئوية المولدة كقيمة معبرة عن التقارب من حالة عطل أكثر تأثراً ببداية تشكّل الميزات الأساسية.

9.9. تمّ توحيد كاشف ومحدّد العطل ومقيم الصحة في بنية واحدة ذات زمن استجابة يساوي (50) ميلي ثانية. ولأنّ مسألة الرّولمان الدّوار قيد المعالجة، هي حالة جزء من آلة، تنتهي استراتيجية تصميم آلة الصيانة التنبؤية لهذا الجزء بتقديم آلة حسابية إجمالية مكونة من كاشف العطل، محدّد العطل ومقيم الصحة.

2.4.3. تقييم نتائج معالجة حالة الرّولمان ومقارنتها مع معالجة الحالة نفسها بمناهج مغايرة:

بما أنّ ما تمّ اقتراحه في (3.3.3) هو استراتيجية عامّة لمعالجة مسألة صيانة تنبؤية، لا إجرائية أو خوارزمية، لذلك فإنّها تتّصف بقابليّة التّطبيق على مسائل صيانة تنبؤية مختلفة، وقد صُمّمت هذه الاستراتيجية بتطبيق منهج استنباطي تحليلي تمّ خلاله مراجعة أدبيّات المسألة وطرق معالجتها الشّائعة بهدف تحريّ عموميّة المسألة وتقديم دليل عمل فعّال، وعند تطبيق هذه الاستراتيجية على حالة الرّولمان الدّوار بسرعات دورانية متغيّرة وبحالات صحيّة متعدّدة، سارت عمليّة التّصميم بشكل منظمّ وأعطت نتائج ممتازة كدقّة كشف عطل (99.91%)، ودقّة تحديد عطل (98.44%)، وعدم تطبيق أيّة عمليّات استخلاص يدوي لميزات وزمن تدريب بنية عميقة واحدة من رتبة (420) ثانية، بالرّغم من صعوبة المسألة كون الميزات متغيّرة ديناميكياً مع تغيّرات السرعة الدّورانية.

تُعَدّ هذه النّتائج ممتازة من ناحية الأداء والتّصميم، وبمضاهاة نتائج حالات معالجة المسألة نفسها بتقنيّات تعلم عميق مغايرة تكون هذه النّتائج من ناحية الدّقة إما أفضل أو موازية، وتبقى دوماً أبسط من ناحية زمن التّصميم وتعقيد البنى المصمّمة. ففي الاستراتيجية المقترحة تُستخلص الميزات بشكل آلي، وتتّسم مناهج معالجة مسألة الرّولمان الدّوار المذكورة بتطبيق آليّة معيّنة لاستخلاص الميزات يدوياً، ففي ورقة بحث بعنوان (منهج لاستخلاص

ميّزات أعطال وتشخيص أعطال الرّولمان معتمد على دمج الميّزات [26] اقترح منهج لتصميم محدّد عطل من ثلاث خطوات:

- (1) استخلاص الميّزات الزّمنية-الترّدديّة من إشارة الاهتزاز بتطبيق تحويل (WPT).
 - (2) تطبيق آليّة (Multi-Weight Singular Value Decomposition = MWSVD) على مصفوفة الميّزات الناتجة للحصول على مصفوفة مصغّرة.
 - (3) تدريب مصنّف (SVM) كمحدّد للعطل.
- وعند تطبيق هذا المنهج على حالة الرّولمان الدّوار، عُولجت حالة التّباطؤ (Deceleration) فقط من حالات السّرعة الدّورانيّة، وعُولجت ثلاث حالات صحيّة فقط هي (Healthy – Inner Race Fault – Outer Race Fault)، ولم تُذكر أسس اختيار طول النّافذة الزّمنيّة المعتمد من إشارة الاهتزاز (1024) عيّنة، ويوضّح الجدول (16-3) نتائج أداء محدّد العطل مع مقارنتها بنتائج أداء بنى مغايرة.

الجدول (16-3): نتائج أداء محدّدات عطل مصمّمة وفق منهج مقترح في [26]

البنية	متوسّط الدّقة Average Accuracy	زمن معالجة إشارة دخل بطول (1 [Sec])
WPT-PCA+SVM	%56.56	34.80 [Sec]
WPT-SVD+SVM	%80.16	20.47 [Sec]
WPT-WSVD+SVM	%61.38	17.21 [Sec]
WPT-MWSVD+SVM	%87.80	10.62 [Sec]

وتظهر فاعليّة الاستراتيجيّة المقترحة في (3.3.3) في معالجة المسألة بشكل متكامل واختيار طول النّافذة الزّمنيّة بشكل مدروس، فمحدّد العطل الذي صُمّم في (4.3.3)، بالإضافة إلى بساطة موديله الحسابي، أعطى دقّة تحديد عطل (%98.44) على كامل مجال السّرعات الدّورانيّة وحالاتها وجميع الأعطال، وزمن حساب تنبؤ من رتبة (0.005 [Sec]).

توظيف مقدرة الاستخلاص الآلي للميّزات لبنى التّعلم العميق باختيار البنية المناسبة يعطي فاعليّة جيّدة ويتيح الاستغناء عن عمليّات استخلاص يدوي ومعالجة أوليّة معقّدة كالتّحويل (Multi Synchronizing Transform = MSST) المقترح في ورقة بحث (تشخيص أعطال رولمان دوّار في ظروف سرعة

متغيرة باستخدام تحويل (MSST) [27] بهدف توليد مصفوفة ميزات زمنية-ترددية تكون فيها ميزات أعطال الرولمان خطية قدر الإمكان، واللاخطية في الميزات لم تكن مشكلة أمام شبكة (1D-CNN) ككاشف عطل أو محدّد عطل.

الاستراتيجية المقترحة في (3.3.3) لا تلغي خيار تطبيق تحويلات على إشارات دخل البنى العميقة بهدف جعل الميزات أكثر وضوحاً وخطية، إنّما ترشد نحو دراسة طبيعة الميزات بحسب الأدبيات والدراسة التصميمية والبدء بتجريب البنى العميقة التي تستخلص الميزات آلياً قبل اعتماد تحويلات حسابية خاصة بعد وضع تقدير مناسب لطول النافذة الزمنية المستخلصة من الإشارة، فالنقد الموجّه للآلية المستخدمة لتشخيص أعطال رولمان في ورقة بحث (تشخيص وتخمين أعطال ذكي لرولمان دوّار بسرعة متغيرة زمنياً بالاعتماد على بنية (VMD-DenseNet) [28] ليس هو تطبيق تحويل (VMD = Variational Mode Decomposition) على إشارات الاهتزاز لتوليد مصفوفات إشارات ثنائية البعد، وإنّما النقد هو اعتماد إشارة الاهتزاز ذات الطول (10) ثوانٍ كإشارة دخل كاملة للإجرائية المقترحة، وبالرغم من كون دقة محدّدات العطل المصمّمة في [28] جيّدة، كما يوضّح الجدول (3-17)، إلّا أنّها ستكون أفضل في حال وضع تحليل لطول النافذة الزمنية، وتصميم محدّدات العطل في هذه الورقة بشكل يشمل كلّ الأعطال هو توجّه سليم.

الجدول (3-17): دقة تحديد العطل المتوسطة باستخدام تحويل (VMD) [28]


البنية العميقة التالية لمرحلة تحويل (VMD)	متوسط الدقة (Average Accuracy)
Alexnet	%80
GoogleNet	%84
ResNet	%84
MobileNet	%88
ShuffleNet	%88
DenseNet	%92

وتتأكّد أهمية تحديد طول النافذة الزمنية المقطعة من إشارة تحسّس حالة استناداً إلى تحليل منظمّ مع مراجعة نتائج ورقة بحثية بعنوان (مراقبة حالة رولمان دوّار باستخدام تحويل (Multi-Order FRFT) وبنية (SSA-DBN)

[29] والتي عالجت مسألة الرولمان الدّوار نفسها بسرعات متغيّرة بمنهج طُبّق فيه تحويل (Multi-Order Fractional Fourier Transform) على إشارات الاهتزاز باقتطاع نوافذ زمنيّة بطول مدروس تحليلياً من رتبة عشرة ميلي ثانية ومن ثم تدريب بنية عميقة، حيث صُمّم كاشف عطل في حالة سرعة دورانيّة متزايدة فقط وحالتين صحيّتين فقط (Healthy – Inner Race Fault)، وكانت دقّة كشف العطل وفق هذا المنهج (100%) متفوّقةً على مناهج أخرى لا يتم فيها تطبيق التّحويل، كما يوضّح الجدول (3-18) ويُعلّل هذا النّجاح مقارنةً مع [26] و [28] بإجراء تحليل لطبيعة الإشارة وميّزاتها وتحديد طول نوافذ أو عدد عيّينات زمنيّة مناسب، وتثبت الاستراتيجية (3.3.3) أنّها تتيح إعطاء الدّقة نفسها تقريباً على كامل حالات السّرعة والأعطال وبمنحنيات تدريب أنعم، حيث يوضّح الشّكل (3-15) أنّ تدريب بنية (DBN) ينطوي على تأرجح وقفزات.

الجدول (3-18): دقّة بنى مختلفة تظهر فاعليّة تطبيق تحويل ترددي [29]

البنية المستخدمة	التّحويل المطبق	متوسط الدّقة (Accuracy)
SVM	من دون تطبيق تحويل	55.00%
SVM	Multi-Order FRFT	83.33%
BP	من دون تطبيق تحويل	70.00%
BP	Multi-Order FRFT	98.33%
DBN	من دون تطبيق تحويل	91.20%
DBN	Multi-Order FRFT	96.38%
SSA-DBN	من دون تطبيق تحويل	95.00%
SSA-DBN	Multi-Order FRFT	100.00%



الشّكل (3-15): منحنيات تدريب بنى (DBN) ككاشف عطل [29]

ويؤكد التحليل المنجز في هذا الفصل أنّ الاستراتيجية المقترحة ناجحة تطبيقياً وضرورية، وهي تتعامل مع مسألة الصيانة التنبؤية كمسألة هندسية متكاملة مرتبطة مع تصاميم وأدبيات نظرية، وهذه المسألة تمتلك شكلاً أو صيغة أساسية عامة من الممكن التعامل معها باستخدام الاستراتيجية المقترحة قبل أن يتمّ التوجه نحو الأدوات الخاصة كالتحويلات الرياضية والتعديلات التصميمية.

4. الخلاصة والتوصيات

1.4. نتائج البحث:

- إن مسألة الصيانة التنبؤية كمسألة تعلّم عميق تتطلب فاعليّات كشف وتحديد وتنبؤ وتقييم، هي مسألة متكاملة تكون معالجتها أنجح عند العمل عليها كمسألة واحدة تناسب في مراحل متعاقبة، فتصميم كاشف العطل كمصنّف ثنائي ومعاملاته تكون أساساً لتصميم محدّد العطل، وتصميم كلا البنيتين يوجّه تصميم بنى التنبؤ والتقييم لاحقاً، وفي معالجة حالة الرولمان الدّوار كان تصميم محدّد العطل سهلاً وواضحاً بعد تصميم كاشف العطل واختباره كتوفّر قيم أوليّة للمعاملات وتقدير لطبيعة الميزات وتراكبها.

- ترتبط مسألة الصيانة التنبؤية كمسألة تعلّم عميق بشكل وثيق مع الدراسة الهندسيّة التصميميّة للآلة أو التّجهيزة المستهدفة، فمراجعة دراسة وضع منظومة تحسّس الحالة يتيح لمهندس الصيانة التنبؤية معلومات مهمّة في تصميم البنى العميقة وتدريبها، مثل مجال عمل حسّاس الحالة الترددي. وفي معالجة حالة الرولمان الدّوار كان اختيار الطّول الزّمني للنّافذة المقطّعة من إشارة الاهتزاز بناءً على تحليل دقيق سبباً في نجاح كاشف العطل ومحدّده، وكان عدم الاهتمام بهذه النّاحية سبباً في انخفاض أداء بنى مصمّمة في تجارب أخرى [26] [28]. كما أنّ التّحليل النظري لطبيعة الميزات في إشارات تحسّس الحالة وسلوكها مع تغيّر معاملات التّشغيل وأطواره يسهّل تصميم بنى تمتلك خاصيّة التنبؤ، كما هي حالة الرولمان الدّوار.

- استخدام التعلّم العميق في معالجة مسألة الصيانة التنبؤية يتيح الاستغناء عن عمليّة استخلاص ميزات وخصائص مضمّنة في بيانات تحسّس الحالة للآلات يدويّاً، وينحصر دور مهندس الصيانة التنبؤية في أمثلة البنية الأكثر قدرّة على معالجة المسألة من حيث عدد الطّبقات ونوعها وتنظيم المسارات الإدراكيّة، فنتائج معالجة حالة الرولمان الدّوار كانت مماثلة أو أفضل من مناهج طُبّقت فيها عمليّات استخلاص ميزات وتحويلات. وتكون معلومات الدّراسة الهندسيّة على قدر كبير من الأهميّة لأنّها تغيد في تحديد شكل عام للبنية العميقة تنطلق منه تجارب الأمثلة. والاستغناء عن الاستخلاص اليدوي للميزات يقترن بتعامل البنية العميقة مع أنماط ميزات داخليّة تصنعها البنية ويصعب فهمها بشريّاً، ولكنّ ذلك لا يتعارض مع هدف المسألة الأساسي وهو تقديم معلومات مفيدة

وموثوقة في توجيه عملية الصيانة بغض النظر عن طريقة توليد هذه المعلومات، فمسألة الصيانة التنبؤية ليست مسألة معالجة إشارة وإنما مسألة تنبؤ ورصد للحالة.

- تمتلك البنى العميقة مقدرة استخلاص أنماط ميزات (Feature Patterns) ديناميكية مع تغير ظروف تشغيل الآلات، فمعالجة مسألة الرولمان الدوار بتطبيق تحويلات زمنية-ترددية على الإشارة الأصلية تكون ناجحة [29]، ولكن يمكن الوصول إلى الأداء نفسه باختيار بنى عميقة تحقق الصمود أمام تغيرات أنماط الميزات الديناميكي، والعامل الأساسي هو اختيار الطبقات العميقة المناسبة لطبيعة إشارات تحسّس معينة. وأثبتت بنية (1D-CNN) القدرة على ملاحظة تغيرات أنماط ميزات الأعطال في الرولمان مع تغيرات السرعة الدورانية بينما كان أداء بنية (DBN) بدون تحويل ترددي أقل جودة كما وضح الجدول (3-18).

- في حالة الرولمانات الدوّارة بسرعات دورانية متغيرة، تكون ميزات الأعطال هي أنماط ديناميكية لأطياف وليست قيماً ترددية، وتنجح بنية عميقة من نوع (1D-CNN) في تمثيل هذه الأنماط وملاحظتها، وذلك بتصميم مرحلة استخلاص ميزات آلي مكونة من طبقتي طي متعاقبتين الأولى تستخلص أنماطاً أساسية والثانية تستخلص حالة وجود هذه الأنماط وطاقتها حالياً.

- يمكن تحسين أداء بنية كشف أنماط طيفية ديناميكية مكونة من طبقتي طي متعاقبتين بوضع طبقة (Maxpooling) وبوضع قيمة مناسبة لخطوة قفز الطي (Stride) في الطبقة الأولى، ويجب عندئذٍ أمثلة قيم طول نافذة النقصي وخطوتها الانزلاقية وخطوة قفز الطي، وترتبط قيمة قفز الطي (Stride) في طبقة طي مع الدقة الترددية المحققة والمحددة استناداً إلى دراسة إشارة تحسّس الحالة قيد المعالجة. وفي معالجة حالة الرولمان الدوار ارتفعت دقة كاشف العطل من (99.7%) إلى (99.91%) فقط بإضافة قيمة قفز الطي (Stride = 10) في طبقة الطي الأولى.

- عند معالجة حالات إشارات تحسّس تحمل ميزات لا توافق الطبقات العميقة المتاحة، وعند وجود تركيب هرمية أنماط ميزات تفرض مسارات إدراكية مستقلة لا يمكن تحقيقها بالحرز البرمجية الجاهزة، يمكن تصميم طبقات عميقة خاصة بآلية رياضية برمجية كما وضح الفصل (2.3).

- استخدام التعلّم العميق في معالجة مسألة الصيانة التنبؤية يمكن إنجازه باستخدام موارد عادية وبرمجيات مفتوحة المصدر وبزمن تصميم واختبار مقبول تطبيقياً، فمعالجة حالة الرولمان الدوار تمت باستخدام برمجيات مفتوحة المصدر بشكل كامل، وكان زمن تدريب البنية الواحدة لا يتجاوز ساعة واحدة باستخدام حاسب شخصي ذي معالج (Intel Core i7-8565U @ 1.80 GHz) وذاكرة بحجم (8 GB).

2.4. آفاق مستقبلية ومقترحات:

- دراسة تأثير وضع طبقة (Maxpooling) على خرج طبقة طي، والعلاقة بين الطيف الترددي لخارطة الميزات التي تنتجها طبقة الطي ومعاملات طبقة (Maxpooling) كطول نافذة التقصي وطول خطوة الانزلاق، وإعادة الدراسة نفسها على حالة استخدام طبقة (Average Pooling).

- دراسة تفسير كون استخدام نافذة زمنية بطول (50) ميلي ثانية من إشارة اهتزاز تردد اعتيانها (200 [KHz]) يجعل أداء بنية (1D-CNN) أفضل في كشف وتحديد أعطال رولمان دوار، بشكل يتيح وضع قاعدة عامة لتحديد قيمة تردد اعتيان إشارة اهتزاز مناسبة وطول نافذة زمنية مناسب.

- دراسة تحديد البنية العميقة الأفضل في معالجة تنبؤ بقيمة خرج متحكم (PID)، فحقيقة أنّ (95%) من حلقات التحكم المغلقة هي حلقات (PID) ترشح هذه الدراسة لتكون مفيدة في معالجة مسائل الصيانة التنبؤية للآلات وخطوط الإنتاج ذات نظم تحكم.

- تطبيق الاستراتيجية المقترحة لمعالجة مسألة صيانة تنبؤية على مستويات أكبر من جزء آلة، مثل مستوى آلة كاملة متعددة الإشارات وذات خصائص تشغيل ونظام تحكم.

- تصميم تابع خسارة (Loss Function) مناسب للاستخدام في مسائل تصميم مرّمز آلي عميق لإشارة اهتزاز تردّد اعتيائها أكبر من (100 [KHz]) مع آلية تقييم إعادة بناء مناسبة، حيث أجريت تجربة تصميم مرّمز آلي لإشارة اهتزاز الرّولمان الدّوار بهدف الوصول إلى رمز وسيط مرتبط بالحالة الصحيّة، ولم ينجح المرّمز الآلي إلا من أجل رمز وسيط ذي ستّة أبعاد، والإشارة المُعاد بناؤها كان يصعب تقييم جودتها، وحُدّد سبب ذلك في الحاجة إلى تابع خسارة مناسب لهذه المسألة من حيث كون الإشارة كبيرة كميّانات وميّزاتها تردّدية.

- اختبار البنية العميقة التفاضليّة المقترحة في الفصل (2.3) على مسألة واقعيّة لحركة جزء آلة.

(References) المراجع

- [1] Dhillon B.S., (2002) "Engineering Maintenance - A Modern Approach", CRC Press LLC.
- [2] R. Keith Mobley, Lindley R. Higgins, Darrin J. Wikoff, (2008) "Maintenance engineering Handbook", 7th edition, McGraw-Hill
- [3] Wieger Tiddens, (2018) "Setting sail towards predictive maintenance" PhD thesis, University of Twente, Enschede, The Netherlands
- [4] Vincent F. A. Meyer zu Wickern, (2019) "Challenges and Reliability of Predictive Maintenance", RHEIN-WAAL University of Applied Sciences
- [5] Kåre Hartlapp Lærum, (2018) "A study of Machine Learning for Predictive Maintenance", Master thesis, Norwegian University of Science and Technology
- [6] Zhe Li, (2018) "Deep Learning Driven Approaches for Predictive Maintenance", PhD thesis, Norwegian University of Science and Technology
- [7] CARLOS A. JAUREGUI CORREA A. LOZANO GUZMAN, (2020) "Mechanical Vibrations & Condition Monitoring" Academic Press, Elsevier
- [8] Wolfgang Ertel, (2017) "Introduction to Artificial Intelligence" UTiCS
- [9] Andrew Glassner, (2018) "Deep Learning: From Basics to Practice" (<http://www.imaginary-institute.com>)
- [10] Geoff Hulten, (2018) "Building Intelligent Systems - A Guide to Machine Learning Engineering", Apress
- [11] Fabio Porto, (2019) "Machine Learning Life-Cycle", Data EXtreme Lab (DEXL), <http://dexl.lncc.br/>
- [12] Pablo Duboue , (2020) "The Art of Feature Engineering - Essentials for Machine Learning", Cambridge University Press
- [13] Ivan Nunes da Silva, Danilo Hernane Spatti, Rogerio Andrade Flauzino, Luisa Helena, Bartocci Liboni, Silas Franco dos Reis Alves (2017) "Artificial Neural Networks - A Practical Course", Springer
- [14] Aston Zhang, Zachary C. Lipton, Mu Li, Alexander J. Smola (2019) "Dive into Deep Learning" <https://d2l.ai/>
- [15] M. Arif Wani, Farooq Ahmad Bhat, Saduf Afzal, Asif Iqbal Khan (2020) "Advances in Deep Learning", Springer
- [16] Filippo Maria Bianchi, Enrico Maiorino, Michael C. Kampffmeyer, Antonello Rizzi, Robert Jenssen (2017) "Recurrent Neural Networks for Short-Term Load Forecasting" Springer
- [17] Nagdev Amruthnath, Tarun Gupta (2018) "A Research Study on Unsupervised Machine Learning Algorithms for Early Fault Detection in Predictive Maintenance" International Conference on Industrial Engineering and Applications
- [18] Willamos Silva (2019) "CNN-PDM: A Convolutional Neural Network Framework For Assets Predictive Maintenance" The University of Western Ontario
- [19] Minh Tuan Pham, Jong-Myon Kim, Cheol Hong Kim (2020) "Accurate Bearing Fault Diagnosis under Variable Shaft Speed using Convolutional Neural Networks and Vibration Spectrogram" MDPI Journal, www.mdpi.com/journal/applsci

- [20] Jin Yuan, Kesheng Wang and Yi Wang (2018) "Deep Learning Approach to Multiple Features Sequence Analysis in Predictive Maintenance" Springer Nature Singapore
- [21] Fan-yun Yen, Ziad Katrib (2020) "WaveNet based Autoencoder Model: Vibration Analysis on Centrifugal Pump for Degradation Estimation" Annual Conference of the Prognostics and Health Management Society
- [22] Gyungmin Toh, Junhong Park (2020) "Review of Vibration-Based Structural Health Monitoring Using Deep Learning" applied sciences
- [23] Bo Luo, Haoting Wang, Hongqi Liu, Bin Li, Fangyu Peng (2018) "Early Fault Detection of Machine Tools Based on Deep Learning and Dynamic Identification" IEEE Transactions on Industrial Electronics
- [24] Shigeru Maya, Ken Ueno, Takeichiro Nishikawa (2019) "dLSTM: a new approach for anomaly detection using deep learning with delayed prediction" International Journal of Data Science and Analytics
- [25] Huang, Baddour (2018) "Bearing vibration data collected under time-varying rotational speed conditions", Department of Mechanical Engineering, University of Ottawa, Ottawa, Ontario, Canada
<https://data.mendeley.com/datasets/v43hmbwxpm/2>
- [26] Huibin, Zhangming, Juhui, Jiongqi, Haiyin (2021) "Bearing Fault Feature Extraction and Fault Diagnosis Method Based on Feature Fusion" MDPI, Basel, Switzerland, www.mdpi.com
- [27] Qi Liu, Yanxue Wang (2021) "Fault Diagnosis of Rolling Bearing under Variable Speed Conditions using MSST Transform" Journal of Physics, <https://doi.org/10.1088/1742-6596/1820/1/012124>
- [28] Shih-Lin, (2021) "Intelligent Fault Diagnosis and Forecast of Time-Varying Bearing Based on Deep Learning VMD-DenseNet" MDPI, Basel, Switzerland, www.mdpi.com
- [29] Jie, Shule, Xinyu (2022) "Condition Monitoring of Rolling Bearing Based on Multi-Order FRFT and SSA-DBN" MDPI, Basel, Switzerland, www.mdpi.com
- [30] NumPy User Guide , Release 1.20.0, (2021), NumPy community, <https://numpy.org>
- [31] SciPy Reference Guide, Release 1.6.2, (2021), SciPy community, <https://scipy.org>
- [32] Matplotlib Reference Guide, Release 3.4.1 (2021), matplotlib development team, <https://matplotlib.org>
- [33] Keras API Doc & Guides, (2022) <https://keras.io>
- [34] Tensorflow API Doc & Guides, (2022) <https://tensorflow.org>

Abstract

Predictive Maintenance (PdM) is considered as an important technique from the applicative and economical perspectives, and although of hugeness of data and information required to be processed when applying PdM in engineering systems, and complexity of this problem in front of mathematical modelling, Deep Learning (DL) poses itself as a convenient method for constructing successful PdM machines due to possessing functionalities as automatic feature extraction and sustainability in front of irregular and new data patterns, and most important, predictive facility and automatic observation of data phenomenon growth.

PdM is a general problem that may arise in several machine or engineering systems, and most of researches tend to handle special cases. This research aims to infer general concepts and ways in handling PdM using DL. DL is a research field adaptive in evolution with various applicative problems, so this research aims to deduce research directives of DL posed by PdM.

Research started by revision of PdM and DL literature, then moved to deductive analysis, then, suggested general work strategies, covering two axes, the first is designing new deep structures dedicated to PdM problems, and the second is application of DL techniques in handling PdM problems; A rotating bearing at varying rotational velocities case strategy was handled using a proposed strategy; Tensorflow DL library was used, results showed fault detection accuracy of (99.91%) and fault identification accuracy of (98.44), exceeding shallow learning metrics of (70% - 90%) and balancing with DL metrics (90% - 99.9%), without any manual feature extraction.

In this research, deep relation between PdM problem and engineering study of processed device or machine was illustrated, where study information affect PdM machine quality; PdM problem may be managed without any manual feature extraction, using desktop computing resources and open-source soft frameworks.

Keywords: PdM, Condition Monitoring, ANN, Backpropagation, DL, CNN, Backpropagation Trough Time, Vibration Signal Processing

Syrian Arab Republic

Ministry of Higher Education and Scientific Research

Damascus University

Faculty of Mechanical & Electrical Engineering

Computer & Automation Engineering Department



Handling Predictive Maintenance Problem using Deep Learning Technique

**A dissertation submitted in partial fulfillment of the
requirements for the degree of master in
Robot Engineering and Programming**

by

Eng. Mohammad Noor Abdelwahab

Supervisor

Dr. Eng. Mohammad Mazen Al-Mahairi

Academic Year

2021 / 2022