

تطوير منهجية متكاملة لتشخيص الأعطال في منشأة صناعية

Development of an integrated approach for faults diagnosis in an industrial plant

توفيق بن ترسيه¹، ليلي حياة موسى²¹ جامعة باتنة 2 - الشهيد مصطفى بن بولعيد (الجزائر)، t.bentrcia@univ-batna2.dz² جامعة باتنة 2 - الشهيد مصطفى بن بولعيد (الجزائر)، h.mouss@univ-batna2.dz

تاريخ النشر: جويلية/2026

تاريخ القبول: 2026/06/16

تاريخ الإرسال: 2026/01/06

ملخص:

تمثل كيفية كشف و مراقبة الأعطال في وحدات الإنتاج إحدى الصعوبات الأساسية الشائعة في المجال الصناعي. يهدف هذا العمل إلى تطوير منهجية لتشخيص الصناعي عبر توظيف طرائق إحصائية والمنطق الضبابي. مقارنة بعدد المقاربات في أدبيات التشخيص الصناعي، تتمتع المنهجية المقترحة بمزايا تكميلية إضافة إلى الأخذ بعين الاعتبار عديد خصائص نظم الإنتاج الحالية. أتاح استخدام منشأة صناعية كنموذج تطبيقي تقييما موضوعيا إذ تم تصنيف بيانات التدريب بدقة 99.18% وبيانات الاختبار بدقة 100% كما قدمت مصفوفة الالتباس، مقاييس الكفاءة ونسبة الرفض لتأكيد فعالية المنهجية. نأمل أن تسهم نتائج هذه الدراسة في إرساء قاعدة صلبة لتحسين قواعد الصيانة وسط البيئة الصناعية.

الكلمات المفتاحية: تشخيص صناعي، معيار فيشر، تحليل المركبات الرئيسية، خوارزمية الجار الأقرب الضبابية، عتبة الرفض.

Abstract:

The strategy of detecting and monitoring faults in production processes constitutes a common basic difficulty in the industrial field. This work aims at developing an industrial diagnosis framework based on statistical methods and fuzzy logic. Compared to numerous approaches in literature, the proposed framework has complementary advantages in addition to taking into account various features of current production systems. The investigation of an industrial unit as a case study offers a fair evaluation with training and testing accuracies of 99.18% and 100%.

respectively. Besides, confusion matrix, performance measures and rejection rate are presented to validate the framework efficiency. We hope that the findings of this study contribute to elaborating a solid foundation for improving maintenance rules within the industrial environment.

Keywords: Industrial diagnosis, Fisher ratio, principal component analysis, fuzzy k-nearest neighbourhood algorithm, reject threshold.

مدخل:

من الملاحظ في الآونة الأخيرة التقدم الحثيث الذي يشهده العالم في مجال العلوم التطبيقية عامة وما صاحبه من تغيير في طرائق التصنيع بشكل خاص، حيث برزت العديد من التقنيات الجديدة التي جعلت من وسائل الإنتاج أكثر اندماجا وتفاعلا سواء مع بعضها البعض أو مع الوسط الخارجي (Schuh et al, 2008). بما أنه يمكن اعتبار الحفاظ على إنتاجية عالية للمؤسسات من بين الأهداف ذات الأهمية القصوى بالنسبة للمديرين في المجال الصناعي (Tokatli & Cinar, 2004)، تمثل كيفية رصد و اكتشاف الأعطال ضمن مجموعة المعدات المستخدمة في الإنتاج إحدى الصعوبات الأساسية التي تواجهها النظم الإنتاجية والتي من شأنها أن تعرقل تحقيق هذا الهدف. وبالتالي فإنه يصبح من الضروري التعجيل بالعثور على السبب الأكثر احتمالا عن هذه الاختلالات من أجل تجنب تطور العطل وزيادة التكاليف الإضافية للتصليح. تشكل مجموعة المناهج المكرسة للتعامل مع الظهور المبكر للأعطال داخل المؤسسة ما يعرف بالتشخيص الصناعي ولقد شهدت الأبحاث في هذا المجال تطورا متسارعا خلال العقدين الماضيين سواء من الناحية النظرية أو التطبيقية. ينبع هذا الاهتمام المتزايد بمشاكل التشخيص نظرا لكونه أحد الشواغل الرئيسة للوسط الصناعي والمتمثلة في زيادة الفعالية والمردودية من خلال تخفيض الأعباء المالية وزمن التصنيع (Haton, 1983; Bentrucia et al, 2004; Berghout et al, 2021). علاوة على ذلك، فإن للتشخيص تطبيقات عديدة في مختلف القطاعات عدا الصناعة كالطب والإدارة ومع هذا التوجه، تشكلت قاعدة علمية صلبة متعلقة بمشاكل وتطبيقات التشخيص الصناعي من خلال نشر العديد من الأعمال المرجعية المخصصة لمعالجة جوانب كثيرة (Dubuisson, 1990; Halme & Selkainaho, 1991; Pang et al, 2011).

هدفنا في هذا البحث يتمثل في اقتراح منهجية متكاملة لتشخيص الأعطال تأخذ بعين الاعتبار مختلف الخصوصيات المميزة لنظم الإنتاج الحديثة. تعتمد هذه الطريقة على توظيف عدة خوارزميات ومعايير نذكر منها على سبيل المثال اختيار السمات، تحليل المركبات الرئيسة و خوارزمية الجار الأقرب الضبابية. ومن ثم تم اختبار وتقييم أداء المنهجية المطورة عبر استخدامها لتشخيص الأعطال في منشأة صناعية.

أثناء عرض هذا العمل ارتأينا التطرق إلى العناصر الآتية. قمنا في القسم الأول بتقديم المفهوم النظري للتشخيص الصناعي مع إيضاح مختلف أساليب تصنيف نماذجه انطلاقا من الدراسات السابقة. يتضمن القسم

الثاني الهيكل العام للمنهجية المقترحة مع شرح مقتضب لكل مرحلة. ننتقل في القسم الثالث إلى وصف المنشأة الصناعية والتجارب العددية المحصل عليها خلال المحاكاة. وفي الأخير نختم باستخلاص بعض الملاحظات حول النتائج والقيود المفروضة على المنهجية المقترحة.

1. التشخيص الصناعي

في ما يلي نهتم بتعريف التشخيص الصناعي ومعايير تصنيف مختلف الطرائق المستعملة.

1.1 التمثيل الرياضي:

من أجل استيعاب مفهوم التشخيص الصناعي يجب بداية تعريف المصطلح الأساسي والمعطى كالاتي (AFNOR, 1988): "التشخيص هو تحديد السبب المحتمل للعطل باستخدام تفكير منطقي مبني على مجموعة معلومات نابعة من فحص أو اختبار".


يبين هذا التعريف جانبين مهمين للتشخيص الصناعي وهما:

• ملاحظة أعراض العطل؛

• تحديد السبب باستخدام التفكير المنطقي على أساس الملاحظات.

من الناحية الرياضية البحتة يمكن اعتبار حدوث عطل في منشأة إنتاجية كتابع معرف على فضاء الأسباب ويأخذ قيمه في فضاء الأعراض (Zwingelstein, 1995)، وبالتالي فإن مشكلة التشخيص الصناعي ما هي إلا مشكلة إيجاد الحل العكسي بين السبب والنتيجة كما هو موضح بالعلاقة الحتمية المحددة في الشكل 1.

الشكل رقم 1: العلاقة بين فضاء الأسباب وفضاء الأعراض في مشكلة التشخيص الصناعي



المصدر: من إعداد المؤلفين.

بناء على هذا الشكل، تتمثل مشكلة التشخيص الصناعي في تحديد الحل x لـ y مع معرفة التابع f حيث لدينا $f(x)=y$. الحل البديهي يتم الحصول عليه بتطبيق العلاقة العكسية:

(1)

$$x = f^{-1}(y)$$

إلا أنه في الواقع لا يمكن استخدام هذه العلاقة بشكل مباشر نظرا لأن مشكلة التشخيص الصناعي ليست مطروحة بشكل جيد وفقا لشروط Tikhonov المنشورة في (Tikhonov & Arsenine, 1976).

2.1 تصنيف الطرائق المستعملة:

تسمح هيكلية طرائق التشخيص الصناعي اعتمادا على معايير عدة بالحصول على تصنيفات مختلفة، حيث اقترح Zwingelstein تصنيفين ممكنين لهذه الطرائق (Zwingelstein, 1995). المنهج الأول يعتمد على توفر نموذج يصف العلاقة بين السبب والنتيجة ما يقتضي معرفة عميقة ومكلفة حول تشغيل النظام بينما يستند المنهج الثاني على نمط الاستدلال أي طريقة الانتقال من قيم المستشعرات إلى سبب العطل الأصلي سواء كانت الطريقة استنباطية أو استقرائية. كلا التصنيفين يعتبران مبسطين ولا يستجيبان لقيود الوحدات الصناعية. قدم Venkatasubramanian وآخرون في سلسلة من الأبحاث المنشورة تصنيفا أكثر دقة ومقاربة للواقع (Venkatasubramanian et al, 2003a; Venkatasubramanian et al, 2003b; Venkatasubramanian et al, 2003c)، حيث يعتمد على نوع المعلومات المقدمة في البداية كمدخلات لمنهجية التشخيص. خلصت هذه المراجعات إلى كون الأنظمة المبنية على طريقة واحدة تعاني من عدة نقائص حيث تتدرج ضمن الدراسات الأولى التي شجعت على تبني الأنظمة الهجينة كخيار مستقبلي رائد في مجال التشخيص الصناعي. أما Mouzakitis فقد توصل إلى تقسيم يحوي ثلاث فئات من طرائق التشخيص: طرائق تشخيص الأعطال المستندة على نموذج، طرائق تشخيص الأعطال المستندة على المعدات وأخيرا طرائق تشخيص الأعطال المستندة على البيانات التاريخية (Mouzakitis, 2013). رغم أن هذا العمل لم يتطرق صراحة إلى مفهوم الطرائق الهجينة إلا أنه أشار إليه ضمنا وهو ما يتوافق مع خلاصة مراجعات Venkatasubramanian حول أهمية التشخيص المتكامل في المنشآت الصناعية المعقدة.

يمكن ملاحظة قلة التطبيقات الصناعية لأنظمة التشخيص على أرض الواقع وهو ما يفسر من خلال التوجه التجاري للشركات الخاصة بتطوير مثل هذه الأنظمة فضلا عن وجود قصور نسبي في دمج عناصر التشخيص بالكامل في منظومة اتخاذ القرار للمنشآت الصناعية. حسب بعض الدراسات السابقة (Majstorovic, 1990; Ma & Jiang, 2011; Venkatasubramanian, 2011; Robeiro & Barata, 2011; Vogl et al, 2016)، لم يتم إعطاء صورة تفصيلية للمزايا المحصل عليها عبر استخدام أنظمة التشخيص، ولكن هناك بعض المبادئ التوجيهية العامة على أساس التجارب التي تدرس الخسائر الاقتصادية الناجمة عن الأعطال. وبالتالي فإن غياب دراسات دقيقة للمكاسب المحققة بتوظيف هذه الأنظمة قد يشكل عائقا أمام الاختيار الأمثل وتطوير الطريقة التي تناسب منشأة صناعية محددة.

إذا نظرنا إلى التشخيص الصناعي من وجهة نظر عملية، نجد أن غالبية تطبيقات تشخيص الأعطال مبنية على منهجية موجهة نحو البيانات التاريخية (Sahu et al, 2024; Zhao et al, 2026). من الممكن تفسير هذا التوجه إلى حقيقة كون المنهجية المؤسسة على البيانات التاريخية سهلة التنفيذ وتتطلب معرفة مسبقة

محدودة ومنخفضة من حيث التكلفة. علاوة على ذلك، يمكن ملاحظة أن أغلب النماذج الرياضية المتوفرة لعمليات التصنيع تسمح فقط بوصف الجانب المستقر للنظام ومن الصعب جدا وصف الجانب الديناميكي المتعلق بتطور الأعطال زمنيا. تعتبر المناهج الإحصائية من بين الأساليب المستندة إلى بيانات تاريخية الأكثر توفيرا حيث أثبتت هذه الطرائق فعاليتها من خلال الكشف السريع عن الحالات الشاذة أين استخدمت بنجاح في التطبيقات الصناعية. لكن من نافلة القول أنه رغم تعدد التقنيات الحالية للتشخيص الصناعي، لا توجد تقنية تحظى بإجماع الخبراء في ما يتعلق بكافة مقاييس الجودة. نقدم في الجدول الممثل أدناه (الجدول 1) مقارنة لبعض التقنيات المستخدمة في التشخيص الصناعي اعتمادا على عدة معايير متداولة (Dash & Venkatasubramanian, 2000). نلاحظ من خلال الجدول أن التقنيات المعروضة تختلف من حيث عدد معايير المقارنة المتاحة ما ينتج عنه اختلاف في خصائص الاستجابة ومجال التطبيقات. كما أنه توجد هناك بعض المعايير التي بالرغم من أهميتها يعسر تحققها على سبيل المثال معيار إمكانية الشرح ما يقتضي تركيزا أكبر على أساليب تصميم مناهج التشخيص الصناعي.

الجدول رقم 1: مقارنة عدة تقنيات للتشخيص الصناعي

التقنية المعيار	الرصد السريع	الاستقرار	إمكانية الشرح	رصد أنماط الأعطال الجديدة	رصد الأعطال المتعددة
تقنية رانز Kalman	ملائمة	حسب الحالة	غير ملائمة	ملائمة	ملائمة
تقنية تصنيف Bayes	ملائمة	ملائمة	غير ملائمة	غير ملائمة	حسب الحالة
تقنية الشبكات العصبونية	ملائمة	حسب الحالة	غير ملائمة	حسب الحالة	حسب الحالة
تقنية الأنظمة الخبيرة	ملائمة	ملائمة	ملائمة	غير ملائمة	غير ملائمة
تقنية تحليل المركبات الرئيسية	ملائمة	ملائمة	غير ملائمة	ملائمة	غير ملائمة
تقنية التجزئة العنقودية	ملائمة	غير ملائمة	غير ملائمة	ملائمة	ملائمة

المصدر: من إعداد المؤلفين اعتمادا على المرجع (Dash & Venkatasubramanian, 2000)

بناء على المناقشة السابقة لكل من تصنيفات وتطبيقات التشخيص الصناعي، يمكن استنتاج عدم نجاعة الاختصار على طريقة واحدة لتلبية جميع متطلبات مناهج التشخيص الصناعي حيث أن جميع الطرائق تعتبر قاصرة بمعنى أن جودة أدائها تتوقف على نوعية المعلومات المقدمة ومن الواضح أن التكامل بين هذه الطرائق يعطي مناهج أكثر فعالية. إن دمج عدة تقنيات من أجل تطوير مناهج هجينة يمكن أن يساعد على تجنب النقائص في الاستراتيجيات المعتمدة على الحلول الفردية (Gao et al, 2015). لبلوغ هذا الغاية، تبرز الحاجة الملحة إلى تبني استراتيجيات تعاونية، حيث تخصص كل طريقة لحل جزء من المشكلة بطريقة متناغمة مع بقية استراتيجية التشخيص، وهو ما يهدف هذا العمل إلى استكشافه من خلال دراسة حالة صناعية.

2. عرض منهجية التشخيص الصناعي المقترحة

نقترح في سياق هذا التوجه منهجية متكاملة تتألف من عدة مراحل على النحو المبين في الشكل 2، كما نقوم أيضا بشرح المفاهيم الخاصة ودور كل مرحلة. الفهم الجيد لمختلف الطرائق المدمجة في هذه المنهجية يستدعي تصفح الشروحات الرياضية في مراجع الاحصاء المتقدم والتعلم العميق مثلا (Duda et al, 2000; Deisenroth et al, 2020). استندنا إلى معيار فيشر (Fisher) كحجر الزاوية في بناء هذه المنهجية بدلا من الخوارزميات المعقدة مثل التعلم العميق (Deep Learning) نظرا للمبررات التالية:

- في حالة البيانات القليلة تكون الخوارزميات المعقدة عرضة لفرط الملاءمة (Overfitting) ما يعطي نتائج ممتازة في التدريب وكارثية في الاختبار بينما معيار فيشر أفضل من حيث الموثوقية والاستقرار مع العينات الصغيرة؛
- في التشخيص الصناعي تعتبر قابلية التفسير مطلبا مهما للتقييم فمعيار فيشر يربط المتغيرات الفيزيائية للنظام في إطار علاقة رياضية خطية تسمح بفهم سبب العطل. في المقابل يمكن النظر إلى الخوارزميات المعقدة كصناديق سوداء تصعب ترجمة نتائجها؛
- في حالة كون فئات الأعطال متميزة بوضوح في فضاء السمات يتفوق أداء معيار فيشر على الخوارزميات المعقدة. بالرغم من كون معيار فيشر طريقة كلاسيكية بالأساس إلا أنه لازال يشكل ركيزة في تطوير مناهج التشخيص الصناعي من خلال توظيف نسخ متطورة للتعامل مع البيانات غير الخطية أو كوحدة أساسية في المناهج الهجينة لضغط البيانات الضخمة وتحسين قابلية تفسير القرارات.

الشكل رقم 2: الهيكل العام للمنهجية المعتمدة في هذا العمل



المصدر: من إعداد المؤلفين.

1.2 الحصول على البيانات:

تشكل هذه المرحلة الوسيط بين الشقين الصناعي والبرمجي في منهجية التشخيص الصناعي حيث تكون المنشأة الصناعية مجهزة عموماً بمستشعرات مؤهلة لتحويل الكميات الفيزيائية مثل الضغط أو الحرارة إلى إشارات قابلة للقياس. تخضع الإشارات الناتجة إلى المعالجة باستعمال تقنيات مختلفة تهدف إلى التقليل من أثر إشارات الضجيج واستنباط القيم الفعالة التي تستخدم كمعطيات دخل لمنهجية التشخيص. قد تكون هذه المرحلة عرضة لإشكال بالغ الصعوبة في حالة ما تم التشكيك في فرضية كون المستشعرات مثالية ما يستلزم اللجوء إلى اعتماد استراتيجية التكرار (Frank, 1990).

2.2 تحديد مجموعة السمات المناسبة:

خلال تشغيل وسائل التصنيع في المنشأة يمكن الحصول على مجموعة واسعة من السمات الملتقطة أو المشتقة من الإشارات الأصلية أين يتم تعريف فئات التشغيل كمجموعة من النقاط في الفضاء المشكل انطلاقاً من السمات المختارة. نظراً لكون عدد المتغيرات المرتفع في كثير من الأحيان مكلفاً من حيث احتساب الوقت وزيادة على ذلك، لا تكون جميع المتغيرات المحسوبة بالضرورة ذات صلة بالأوضاع المدروسة، لذلك يجب استغلال تقنيات من أجل الاحتفاظ فقط بالسمات ذات الدلالة التمثيلية المعتبرة. يسمح معيار فيشر المطبق على كل متغير بقياس القدرة التمييزية لهذه المتغيرات ويعبر عن هذا المعيار بالنسبة لعدد من الفئات M و سمة كيفية α بالعلاقة الرياضية التالية:

$$(2) \quad J(\alpha) = \sum_{i=1}^M \sum_{l=1}^{M-1} \frac{m_i(\alpha) - m_l(\alpha)}{N_i \sigma_i^2(\alpha) - N_l \sigma_l^2(\alpha)}$$

حيث تمثل $m(\alpha)$ ، $\sigma^2(\alpha)$ و N كل من مركز ثقل، تباين وعدد متجهات فئة w باعتبار المركبة (السمة) α لمتجه البصمة. يعبر البسط في هذه العبارة عن مدى فصل الفئات في حين يعكس المقام تراص ملاحظات الفئة الواحدة، وكلما كانت قيم هذا المعيار كبيرة كلما كانت قابلية الفصل بين الفئات كبيرة. وبالتالي، فإن الحل

الأبسط لاختيار المتغيرات يتمثل في الأخذ بعين الاعتبار لعدد معين من المتغيرات المرتبة تنازليا وفقا لمعيار فيشر (Casimir, 2003).

3.2 تمثيل المعطيات في فضاء ذي بعد مختصر:

تحليل المركبات الرئيسية (أو اختصارا PCA باللغة الانجليزية) هي تقنية تسمح بإسقاط المعطيات من الفضاء الأصلي المتعدد الأبعاد d على فضاء بعدد أبعاد مستقلة أقل ($d' < d$) وبدون إهدار نسبة معتبرة من المعلومات المتاحة من المجموع الكلي للسمات. قبل تطبيق التحليل، يتم جعل السمات متجانسة من خلال مركزتها حول قيمها المتوسطة وقسمتها على الانحرافات المعيارية المرافقة بهدف منع السمات ذات السلم الأكبر من الهيمنة على التحليل وضمان مساهمة متوازنة. يعد هذا الإجراء نوعا من التوحيد القياسي مع اعتماد تحليل المركبات الرئيسية في هذه الحالة على مصفوفة الارتباط. يمكن تصور نتائج هذه التقنية من خلال اعتبار مسقط سحابة النقاط على المحورين أو الثلاثة محاور العاملة الأولى. وبعبارة أخرى، من خلال تصور مصفوفة البيانات في الفضاء الذي يحدده المتجهان أو الثلاثة متجهات المميزة الأولى. و يمكن قياس جودة التمثيل من خلال حساب النسبة المئوية من القصور الذاتي التي يفسرها كل محور عاملي أو الفضاء الجزئي ذو البعد d' الذي تم الحصول عليه (Hand et al, 2001). وتعرف هذه النسبة من القصور الذاتي بدلالة الجذور المميزة (λ) للفضاء الجزئي ذي البعد d' كالآتي:

(3)

$$\Gamma = \left(\sum_{p=1}^{d'} \lambda_p \right) / \left(\sum_{q=1}^d \lambda_q \right)$$

للحصول على تمثيل قريب من الواقع ينبغي أن تكون هذه النسبة قريبة من الواحد ولكن عمليا يحدد المستخدم عتبة الجودة في حدود 80% إلى 90%، ثم يختار المتجهات المميزة المرافقة للجذور المميزة التي يكون مجموعها أكبر من أو يساوي هذه العتبة، من أجل تحديد أساس الفضاء الجزئي.

4.2 وضع قواعد اتخاذ القرار الضبابية:

انطلاقا من مجموعة التدريب، من الممكن هيكلية بنية المجموعة إلى عدد من الفئات M ، وهذا ما يعني تعريف مصفوفة $U = [\mu(x_j, \omega_i)] = [\mu_{ij}]$ من معاملات انتماء الملاحظات $x_{j=1:k}$ إلى فئات مختلفة ω_i . وبعدها نتطرق إلى مسألة تعريف المصنف الذي سيجعل من الممكن اتخاذ القرار بشأن ورود ملاحظة جديدة x_{k+1} . وتستند هذه المرحلة من التمييز الضبابي على النقاط التالية (Derrac et al, 2014):

- حساب متجه انتماء ملاحظة جديدة x_{k+1} بالنسبة إلى مختلف فئات مجموعة التدريب؛
- تحديد قاعدة لاتخاذ القرار، وبصفة خاصة إدخال مفهوم الرفض إذا كانت درجة الانتماء إلى جميع الفئات أقل من قيمة حدية معينة.

5.2 استغلال النظام:


تشكل الطرائق سألغة الذكر العناصر الأساسية اللازمة لتطوير منهجية تشخيص معتمدة على تمييز الأنماط الضبابي وعندئذ يكون من الضروري تعريف فئة التشغيل بناء على ملاحظة جديدة في لحظة معينة.

من الواضح أنه على أساس المعرفة المتاحة حول فئات الأعطال وخوارزمية اتخاذ القرار يمكن فقط التأكد من وضع التشغيل القائم أو رفض ملاحظة مبهمة. كما يجب أن تكون المنهجية قابلة للتكيف و تسمح ببناء هيكل فئة جديد للملاحظات المرفوضة بمجرد أن يصبح عددها كبيرا. وبالتالي يتعين إعادة تشغيل مرحلة التدريب من أجل مراعاة هذه الفئة الإضافية أثناء اتخاذ القرارات لاحقا.

3. التطبيق ومناقشة النتائج

تتكون المنشأة الصناعية قيد الدراسة من مفاعل و مبادل حراري (Bentrcia et al, 2011; Bouzenita et al, 2013). تجري تفاعلات ناشرة للحرارة ($A \rightarrow B$) في المفاعل أين يتم ضبط درجة الحرارة في حدود قيمة ثابتة عن طريق سائل مسخن في المبادل الحراري حيث يقلل سائل تبريد آخر من درجة حرارة السائل الخارج من المفاعل. يتم التحكم في تدفق هذا السائل من قبل عنصر تحكم تناسبي تكاملي (PI) وصمام. بالإضافة إلى ذلك، يتم استخدام وحدة تحكم أخرى لتحقيق الاستقرار في مستوى السائل في المفاعل. إن خرج وحدة تحكم معينة عبارة عن قيم معيرة يتم تحويلها بعد ذلك إلى إشارات ملائمة للمشغل، بدلا من استغلال القياسات الخام للمستشعر. هذا النوع من العمليات شائع في وحدات الإنتاج المعتمدة على التفاعلات الكيميائية كما هو مبين في (Russell et al, 2000). نوضح في الشكل 3 مختلف مكونات هذه المنشأة الصناعية المستعملة لتطبيق مراحل منهجية التشخيص الصناعي المقترحة.

الشكل رقم 3: البنية التوضيحية للمنشأة الصناعية المستعملة في تقييم منهجية التشخيص الصناعي المقترحة



المصدر: من إعداد المؤلفين.

أما ما يتعلق بالمعطيات المستعملة للتشخيص فيتم تمثيل البيانات التاريخية لتشغيل المنشأة كمصفوفة ذات 15 عمودا و 300 سطر حيث تشير الأربعة عشر قيمة الأولى من كل سطر إلى الملاحظة (قيمة أجهزة الاستشعار الموثوقة عبر المنشأة في وقت معين). تعبر الأعمدة عن المعايير المقاسة بواسطة أجهزة الاستشعار إضافة إلى فئة التشغيل المرافق لكل ملاحظة إذ لدينا تسع فئات تشغيل مختلفة معروفة (1-9) إلى جانب فئة تشغيل مجهولة (10) كما هو معطى في الجدول 2.

الجدول رقم 2: الأنماط المراقبة لفئات تشغيل المنشأة الصناعية المدروسة

رقم الفئة	نمط التشغيل
1	عادية
2	انسداد في التدفق الداخل
3	انسداد في تدفق إعادة التدوير
4	تركيز عالي من المادة A
5	نقطة ضبط عالية لإعادة التدوير
6	تلوث المبادل الحراري
7	صمام التحكم في الحرارة عالق في الوضع المفتوح
8	تسرب في المفاعل
9	قياس تدفق إعادة التدوير مشبع
10	تعطل المضخة

المصدر: من إعداد المؤلفين.


قسمت قاعدة البيانات إلى مجموعة التدريب التي تضم 243 ملاحظة (27 ملاحظة لكل فئة تشغيل معروفة) ومجموعة الاختبار التي تتكون من 57 ملاحظة مقسمة إلى 27 ملاحظة خاصة بفئات التشغيل المعروفة (3 ملاحظات لكل فئة تشغيل معروفة) و 30 ملاحظة لفئة التشغيل المجهولة. تم سحب ملاحظات فئات التشغيل المعروفة ورافقها عشوائيا إما بمجموعة التدريب أو مجموعة الاختبار. من المهم الإشارة إلى أن المعلومات التفصيلية حول طريقة توليد البيانات مثل إجراء أخذ العينات الدقيق أو نموذج الضجيج غير متاحة لنا حاليا وهو ما يمثل قيودا لهذه الدراسة. توظف معطيات مجموعة التدريب لتصميم المصنف الضبابي في حين تستعمل معطيات مجموعة الاختبار لقياس القدرة التنبؤية للمصنف على الملاحظات الجديدة الواردة. أوردنا في ما يلي نتائج كل مرحلة من المنهجية المقترحة.

1.3 الحصول على البيانات:

تسمح هذه المرحلة بمعالجة بيانات التدريب واستخراج المعلومات ذات الصلة بمنهجية التشخيص،

وبالخصوص:

- العدد الأصلي لفئات الأعطال في مجموعة التدريب؛
 - العدد الأصلي للسماط قبل عملية الاختيار؛
 - تجميع البيانات على شكل فئات تشغيل لتسهيل الوصول والمعالجة.
- وبين الشكل 4 النتائج النهائية لعملية الحصول على البيانات.

الشكل رقم 4: نتائج الحصول على البيانات من خلال مجموعة التدريب

المصدر: من إعداد المؤلفين.

2.3 تحديد مجموعة السمات المناسبة:

يمكن تمثيل بصمة منشأة الإنتاج المدروسة بمتجه يحوي أربع عشرة مركبة ما يستلزم دراسة فئات التشغيل في فضاء بنفس العدد من الأبعاد، الأمر الذي يستغرق وقتا وجهدا مكلفين. وبالإضافة إلى ذلك، قد تكون بعض المتغيرات مرتبطة خطيا أو ليست ملائمة للتشخيص، وبالتالي فإن الحاجة ملحة لتخفيض بعد فضاء التمثيل الأصلي. كما أن الاختيار الملائم للسمات يجعل البحث في فضاء التمثيل أسرع وأكثر شمولاً. و المنتج المحصل عليه يجب أن يسمح بالتفريق بين مختلف فئات تشغيل المنشأة.

باستخدام مجموعة التدريب، يتم حساب معيار فيشر لكل متغير. هذا الحساب هو تقييم لقدرة كل متغير للتفريق بين فئات التشغيل إذ يكون للمتغير α قوة فصل أفضل كلما كانت قيم معيار فيشر المرتبط به أكبر و المتغيرات المختارة هي تلك التي تتوافق مع القيم الكبرى للمعيار. في حالتنا نقتصر على متجه ببعد مساو لأربعة، وهذا الاختيار تفسره النتائج الجيدة التي تم الحصول عليها. وبالتالي فإن تطبيق معيار فيشر يسمح بالحصول على متجه مكون من المتغيرات التالية:

- تدفق التبريد في المبادل الحراري (الوحدة غالبا المتر المكعب في الساعة)؛
- خرج وحدة التحكم في إعادة التدوير (الوحدة غالبا الملي أمبير)؛
- خرج وحدة التحكم في المستوى (الوحدة غالبا الملي أمبير)؛
- خرج وحدة التحكم في درجة حرارة المفاعل (الوحدة غالبا الملي أمبير).

3.3 تمثيل المعطيات في فضاء ذي بعد مختصر:

يمكن التحقق من مدى ملائمة اختيار المتغيرات المحصل عليه باستعمال معيار فيشر من خلال إسقاط المعطيات في فضاء ثنائي أو ثلاثي الأبعاد الناتج عن المتغيرات المختارة. الفضاء ثلاثي الأبعاد هو الأكثر

فعالية في تمثيل فئات التشغيل خصوصا إذا كانت نسبة القصور الذاتي قريبة من الواحد. قمنا بإجراء تحليل المركبات الرئيسية للانتقال من الفضاء رباعي الأبعاد الناتج في المرحلة السابقة إلى فضاء ثلاثي الأبعاد. يعرض الجدول 3 القيم الذاتية، نسب التباين المئوية ونسب التباين المئوية التراكمية التي تفسرها كل مركبة بدلالة الاحتفاظ بالمعلومات الأولية حيث يتضح أن الثلاثة مركبات الأولى تحتفظ ب 97.99% من المعلومات الابتدائية. الاقتصار على المركبات الرئيسية الثلاث الأولى يمكن تبريره بكونها تفسر مجتمعة القسم الأكبر من إجمالي التباين، متجاوزة أفضل عتبة شائعة الاستخدام والمقدرة ب 90%.


الجدول رقم 3: مساهمة القيم الذاتية الخاصة بإسقاط المعطيات التي تم تحديدها من قبل معيار فيشر

القيمة الذاتية	النسبة المئوية	النسبة المئوية التراكمية
2.04	51.13%	51.13%
1.03	25.81%	76.94%
0.84	21.05%	97.99%
0.08	2.01%	100%

المصدر: من إعداد المؤلفين.

يساعد مخطط باريتو (Pareto Chart) على تحديد النسبة المئوية للمعلومات التي يحتفظ بها كل محور من محاور الفضاء (الشكل 5) .


الشكل رقم 5: استعمال مخطط باريتو للتحقق من فعالية المركبات الرئيسية المختارة



المصدر: من إعداد المؤلفين.

يبين الشكل 6 رسم فئات التشغيل المختلفة في الفضاء ثلاثي الأبعاد المختار حيث يكفل معيار نسبة التباين المئوية التراكمية تمثيلا ثلاثي الأبعاد دقيقا وموثوقا للبيانات نتيجة احتفاظه بمحتوى المعلومات الابتدائية في مجموعة البيانات.

الشكل رقم 6: تمثيل فئات التشغيل في فضاء ثلاثي الأبعاد باستعمال المركبات الرئيسية المختارة



المصدر: من إعداد المؤلفين.

من خلال الشكل 6، يمكن ملاحظة أن كل فئة في مجموعة التدريب تحتل منطقة متراسة ومعزولة بوضوح في الفضاء ثلاثي الأبعاد (وهو ما يتجلى في انخفاض التباين داخل الفئة الواحدة والحدود الواضحة بين الفئات المختلفة). في حالة ظروف مثالية خالية من الضجيج، تضمن هذه الخصائص الهندسية للفئات تقييم مقاييس الأداء بفعالية رغم استخدام تقسيم عشوائي واحد ومجموعة اختبار تحوي 27 ملاحظة فقط ضمن الفئات المعروفة. علاوة على ذلك، يسمح التمثيل المتساوي للفئات المعروفة سواء في مجموعة التدريب أو الاختبار بتقييم متوازن وتقليل الانحياز في مقاييس الأداء، ما يمنح النتائج مصداقية أكبر على الرغم من الصغر النسبي لحجم مجموعة الاختبار. بناء على الحجج سالفة الذكر، نرجح إمكانية توظيف تقسيم عشوائي واحد لتقييم الكفاءة حيث من المستبعد أن تؤثر الفروقات الناتجة عن مجموعات تدريب مختلفة بشكل كبير على النتائج.

4.3 وضع قواعد اتخاذ القرار الضبابية:

من الضروري لإعداد قاعدة اتخاذ قرار ضبابية تحديد المجموعات الفرعية الضبابية وكذلك توابع الانتماء لهذه المجموعات الفرعية (Zadeh, 1965). ومن بين الطرائق المستخدمة لحساب درجة الانتماء نجد الطريقة القائمة على المسافة والتي تعتمد على اعتبار كل تابع انتماء $\mu_i(x_{k+1})$ كدرجة تشابه بين الملاحظة x_{k+1} والنماذج الأولية للفئة w_i . ويمكن قياس درجة هذا التشابه من خلال تابع للمسافة بين x_{k+1} و w_i كالاتي:

$$(4) \quad \mu_i(x_{k+1}) = f(d(x_{k+1}, w_i))$$

حيث $f: \mathbb{R}^+ \rightarrow [0,1]$ هو تابع مستمر ومتزايد، و $d(x_{k+1}, w_i)$ تمثل المسافة بين x_{k+1} و w_i . إن حساب المسافة بين المتجه x_{k+1} والفئة w_i يقتضي تعريف مفهوم المسافة بين نقطتين ومن جهة أخرى تعريف العناصر الممثلة للفئة w_i .

يعطى تعريف المسافة الإقليدية المستخدمة في دراستنا بالنسبة لملاحظتين x_j و $x_{j'}$ على النحو التالي:

$$(5) \quad d^2(x_j, x_{j'}) = (x_j - x_{j'})^T (x_j - x_{j'})$$

ويمكن أن تحدد المسافة بين x_j و w_i بقياس المسافة مقارنة بمجموعة عناصر نموذجية ثابتة $\{x\}_{j'=1:n}$ ممثلة للفئة وفي هذا العمل نتبنى مفهوم المسافة المتوسطة المعرفة كما يلي:

(6)

$$d(x_j, w_i) = \frac{1}{n} \sum_{j'=1}^n d(x_j, x_{j'})$$


لتكن $d(x_j, w_i)$ المسافة بين x_j والفئة w_i ونرغب بتحديد درجة انتماء الملاحظة x_j إلى w_i ، أي نستخدم لغرض التضبيب التابع الأسّي. من الناحية الرياضية، نلاحظ أن إدخال ثابت λ كمعامل للأُس يجعل من الممكن تعديل التناقص السريع جدا مع المسافة (Zieba, 1995):

(7)

$$\mu(x_j, w_i) = e^{-\lambda d(x_j, w_i)}$$


ويوضح الشكل 7 تأثير هذا الثابت على تناقص التابع الأسّي.

الشكل رقم 7: مقارنة بين التابع الأسّي مع معامل تعديل ($\lambda = 0.05$) وبدون معامل تعديل ($\lambda = 1$)




المصدر: من إعداد المؤلفين.

يبين الشكل 8 المسافة الإقليدية بين الملاحظة الأولى من مجموعة التدريب والفئات من خلال اتخاذ مجموعة كل ملاحظات الفئة كنموذج أولي (يعني اعتماد المسافة المتوسطة).

الشكل رقم 8: المسافة المتوسطة بين المنتج الأول وفئات التشغيل المختلفة في مجموعة التدريب

المصدر: من إعداد المؤلفين.

إن اعتبار تابع أسّي بمعامل تعديل يمكن من تثبيط الانخفاض السريع لتابع الانتماء، وبالتالي تفريق أكثر وضوحاً بين ملاحظات الفئات المختلفة (الشكل 9).


الشكل رقم 9: تابع الانتماء إلى فئات مختلفة للملاحظة الأولى من مجموعة التدريب مع اعتبار معامل التعديل $(\lambda = 0.05)$ 

المصدر: من إعداد المؤلفين.

للتحقق من مدى تمثيلية مجموعة التدريب من قبل توابع الانتماء المحصل عليها، نقوم بعملية استنتاج عكسية من خلال استخلاص فئات الانتماء للملاحظات باستخدام القاعدة التالية: "اختيار الفئة w_i للملاحظة x_j التي من أجلها تكون قيمة تابع الانتماء μ_{ij} لهذه الملاحظة عظمى".

النتائج الواردة في الشكل 10 تعكس درجة مقبولة من الدقة بالنسبة للانتماء الحقيقي للملاحظات إلى فئات تشغيل المنشأة (تم تصنيف ملاحظتين بطريقة خاطئة، وهو ما يمثل نسبة خطأ تقدر بـ 243/2 لمرحلة التدريب أي بدقة 99.18%).

الشكل رقم 10: مقارنة الانتماء المتوقع والانتماء الفعلي لمجموعة التدريب



المصدر: من إعداد المؤلفين.

5.3 استغلال النظام:

بمجرد إتمام عملية التدريب عبر تمييز الملاحظات من خلال توابع انتمائها إلى فئات التشغيل، ننتقل إلى توظيف المنهجية حيث تشمل هذه العملية تصنيف ملاحظات مجموعة الاختبار. ينقسم التصنيف إلى مرحلتين. أولاً، تقرب قيم توابع الانتماء لملاحظات الاختبار اعتماداً على قيم توابع الانتماء لمجموعة التدريب، وذلك باستخدام خوارزمية الجار الأقرب الضبابية (Keller et al, 1985; Bian, 2002)، حيث يعطى التابع الواجب استخلاصه من خلال العبارة التالية المتضمنة لوسيط كفي (معامل الترمويه الغامض $m \geq 1$):


$$(8) \quad \mu(x, \omega_i) = \left(\sum_{j=1}^k \mu(\omega_i, x_j) \times \|x - x_j\|^{-2/m-1} \right) / \left(\sum_{j=1}^k \|x - x_j\|^{-2/m-1} \right)$$

ومن ثم يتم اتخاذ قرار اختيار الفئة من خلال تطبيق قاعدة تعظيم درجة الانتماء μ_{ij} .

عند تطبيق خوارزمية الجار الأقرب الضبابية، استندنا على الإعداد الآتي للمعاملات والمتضمن عدد الجيران $k=5$ لتحديد أقرب الجيران لكل ملاحظة، معامل الترمويه الغامض $m=2$ لضبط درجة الغموض في توزيع الانتماء، و المعامل في تابع الانتماء الأسّي $\lambda=0.05$ لتنظيم تأثير المسافة على حساب درجات الانتماء. الشكلان 11 و 12 يعطيان المزيد من التفاصيل عن طريق تحديد فئة الانتماء الفعلية لكل ملاحظات مجموعة

الاختبار إضافة إلى إنشاء مصفوفة الالتباس الممتلئة بمصفوفة قطرية حيث أن القيم غير المعدومة تعبر عن عدد التصنيفات الصحيحة (3 تصنيفات لكل فئة).

الشكل رقم 11: نتائج تصنيف الملاحظات في مجموعة الاختبار



المصدر: من إعداد المؤلفين.

الشكل رقم 12: مصفوفة الالتباس المستخلصة من تصنيف مجموعة الاختبار

1	3	0	0	0	0	0	0	0	
2	0	3	0	0	0	0	0	0	
3	0	0	3	0	0	0	0	0	
4	0	0	0	3	0	0	0	0	
5	0	0	0	0	3	0	0	0	
6	0	0	0	0	0	3	0	0	
7	0	0	0	0	0	0	3	0	
8	0	0	0	0	0	0	0	3	
9	0	0	0	0	0	0	0	0	3
	1	2	3	4	5	6	7	8	9

المصدر: من إعداد المؤلفين.

بالاعتماد على مصفوفة الالتباس، قمنا بحساب عدة مقاييس لتقييم كفاءة منهجية التشخيص بطريقة موضوعية. تتمثل هذه المقاييس في الدقة الكلية، الدقة، الاسترجاع و درجة F1 كما هو موضح في الجدول 4. أظهرت النتائج أداء جيدا مع غياب للأخطاء ذات التصنيف إيجابيات أو سلبيات خاطئة، إلا أنه ينبغي التنبيه إلى أن صغر مجموعة الاختبار ربما يؤثر سلبا على قدرة التعميم عند تطبيق المنهجية على معطيات جديدة أو كبيرة الحجم.


الجدول رقم 4: عرض لبعض مقاييس تقييم أداء منهجية التشخيص الصناعي المقترحة

المقياس	الترميز	القيمة
الدقة الكلية	Accuracy	%100
الدقة	Precision	%100
الاسترجاع	Recall	%100
درجة F1	F1 - score	%100


المصدر: من إعداد المؤلفين.

للتحقق من مدى تأثير المنهجية المقترحة بتغيير بعض المعاملات، قمنا بإجراء دراسة حساسية وذلك عند تغيير عدد الجيران ضمن المجال [5-15] إضافة إلى تغيير معامل تابع الانتماء الأسّي ضمن المجال [0.05-0.3] حيث بينت نتائج الشكلين 13 و 14 ثبات قيم الدقة الكلية في الحالتين ما يعني أن المنهجية تمتلك استقرارا عاليا. هذا يؤكد أن تصنيف مجموعة الاختبار يعتمد أساسا على هيكلية البيانات بدرجة أكبر مقارنة مع قيم المعاملات المستعملة (فئات الأعطال موزعة على شكل تجمعات واضحة التمايز أين تبقى الفئة السائدة ثابتة في الجوار القريب بمعزل عن تمديد نطاق البحث أو ضبط درجة الانتماء).

الشكل رقم 13: ثبات الدقة الكلية للمنهجية المقترحة بدلالة التغير في عدد الجيران



المصدر: من إعداد المؤلفين.

الشكل رقم 14: ثبات الدقة الكلية للمنهجية المقترحة بدلالة التغير في معامل تابع الانتماء الأسّي

المصدر: من إعداد المؤلفين.

يعتبر رفض المسافة خاصة مهمة لجعل منهجية التشخيص قابلة للتكيف مع المعطيات الجديدة حيث تعرف عتبة رفض المسافة لفئة معينة ω_i عن طريق حساب توابع الانتماء بين عناصر الفئة والمجموعة النموذجية الممثلة لهذه الفئة وبالتالي يمكن صياغة عتبة الرفض بالعلاقة (Bentrcia et al, 2012):

(9)

$$T_{dist}^i = \min_{j=1:N_i} [\mu(x_j, \omega_i)]$$

حيث يمثل N_i عدد ملاحظات الفئة ω_i ويتيح تطبيق هذه الصيغة الحصول على عتبات الرفض بالنسبة لكل فئة كما هو مبين في الجدول 5. نلاحظ اختلاف قيم عتبة الرفض لفئات مجموعة التدريب وهو ما يمكن إرجاعه لاختلاف الشكل الهندسي لكل فئة والامتداد وفق المحاور المختلفة.

الجدول رقم 5: عتبة الرفض لكل فئة المستنتجة انطلاقاً من المعادلة (9)

الفئة	1	2	3	4	5	6	7	8	9
عتبة الرفض	0.77	0.67	0.79	0.66	0.78	0.24	0.76	0.79	0.4


المصدر: من إعداد المؤلفين.

عقب استعمال الفئة المجهولة والمستبعدة خلال عملية التدريب، تبين انه تم رفض كل الملاحظات (30 ملاحظة) المشكلة للفئة من قبل منهجية التشخيص. هذا ما يؤكد فعالية آلية رفض المسافة في تحديد الملاحظات الغير مشابهة لفئات الاعطال المعروفة.

يوضح تحليل المركبات الرئيسة لكافة المعطيات، بما في ذلك الملاحظات المرفوضة، أن هذه الأخيرة تشكل تجمع نقاط متراسة ومنفصلة عن بقية الفئات المعروفة. ما يعني أن آلية الرفض تسهل تحت ظروف خاضعة للسيطرة تمييز هذه الملاحظات غير النمطية والتي يمكن تفسيرها بظهور فئة جديدة من الأعطال في المنشأة الصناعية كما هو موضح أدناه (الشكل 15). ومع ذلك، لا بد من التأكيد على أن رفض المسافة عموماً لا

يعني بالضرورة بروز فئة أعطال جديدة، إذ أنه من المحتمل كون درجات الانتماء المتدنية ناجما أيضا عن أسباب أخرى مثل الانحراف في البيانات، ضجيج مرتفع أو عدم الترابط في بنية إحدى الفئات المعروفة .

الشكل رقم 15: تمثيل النقاط المرفوضة في فضاء ثلاثي الأبعاد مقارنة ببقية فئات التشغيل



المصدر: من إعداد المؤلفين.

لنتبين مدى فعالية خيار الرفض، قمنا بإجراء دراسة استتصالية من خلال مقارنة أداء منهجية التشخيص في حالتها حذف و إدراج خيار الرفض كما هو مبين في الجدول 6. نلاحظ أنه عند حذف خيار الرفض يتم تصنيف جميع الملاحظات مقبولة، بما فيها ذات درجة الانتماء الأقل من عتبات الرفض لجميع الفئات وهو ما تسبب في انخفاض الدقة الكلية إلى **47.37%** مقارنة بالدقة في حالة إدراج خيار الرفض المقدرة ب **100%**.

الجدول رقم 6: دراسة استتصالية لمساهمة خيار الرفض في أداء منهجية التشخيص

الدقة الكلية	عدد التصنيفات الصحيحة	عدد الملاحظات المقبولة	
47.37%	27	57	حالة حذف خيار الرفض
100%	27	27	حالة ادراج خيار الرفض

المصدر: من إعداد المؤلفين.

وفي سياق إبراز القيمة المضافة للعمل، أجرينا مقارنة مع نموذجين مرجعيين هما آلة الدعم المتجهي (Support Vector Machine) والغابة العشوائية (Random Forest) أين استخدمنا نفس المعطيات تحت نفس شروط التجزئة. بالنسبة لنموذج آلة الدعم المتجهي وظفنا دالة نواة غاوسية (Gaussian Kernel) لإنشاء حدود غير خطية كما أدرجنا معايرة البيانات لضمان نطاق موحد للمتغيرات. أما الغابة العشوائية فتم إنشاؤها من خلال 20 شجرة من القرار التصنيفية المدمجة لاحقا لتحسين التنبؤ. تظهر النتائج المعروضة في الجدول

7 تفوقا ملموسا للمنهجية المقترحة بدلالة مختلف مقاييس الأداء ما يمكن عزوه إلى فعالية معيار فيشر وخيار الرفض ضمن منهجية التشخيص الصناعي.

الجدول رقم 7: مقارنة أداء المنهجية المقترحة مع أداء آلة الدعم المتجهي والغابة العشوائية بالنسبة لمجموعة الاختبار

المقياس	المنهجية المقترحة	آلة الدعم المتجهي	الغابة العشوائية
الدقة الكلية	%100	%47.37	%47.37
الدقة	%100	%80.91	%74.44
الاسترجاع	%100	%90.00	%90.00
درجة F1	%100	%81.67	%77.00

المصدر: من إعداد المؤلفين.

الخلاصة :

حاولنا في هذا العمل وبالاتماد على دراسة حالة إبراز مزايا منهجية متكاملة للتشخيص الصناعي حيث صنفنا بيانات التدريب بدقة كلية **99.18%** كما قدمت نتائج واحدة لمجموعة الاختبار (**27** ملاحظة) ممثلة في مصفوفة الالتباس، مقاييس التقييم ونسبة الرفض. إلا أنه يستحب التنويه بأن هذه الفعالية لا يمكن الحصول عليها، وخصوصا عند كون الملاحظات تابعة لمجموعة التدريب، إلا إذا تم اختيار متغيرات متجه البصمة المميزة للمنشأة بشكل صحيح لتمثيل فئات التشغيل. ولقد أظهر تحليل المركبات الرئيسة انفصالا بصريا بين الفئات بعد اختيار السمات مع عرض مخطط باريتو كبرهان كمي على مثالية الاختيار. استغلال المنهجية المقترحة يشمل مرحلتين بداية بتطبيق تابع الانتماء الأسّي لتقدير مدى قرب ملاحظات مجموعة التدريب من مراكز الفئات المرافقة ثم استخدام خوارزمية الجار الأقرب الضبابية لحساب درجات انتماء الملاحظات الجديدة بناء على درجات انتماء جيرانها الأقرب المقدرة سابقا. كما اخترنا خوارزمية التصنيف مع رفض المسافة الذي يسمح برفض ملاحظة ما في حالة كون درجات انتمائها لكافة الفئات جد ضعيفة، حيث أن هذا الميزة لمنهجية التشخيص (إمكانية الرفض) مهمة جدا لأنها تساعد على إثراء قاعدة المعطيات وبناء فئات تشغيل جديدة. تشكل إمكانية الرفض آلية عملية لتمييز الملاحظات غير المشابهة لفئات مجموعة التدريب، وهو ما يمكن من دعم تحديث قاعدة البيانات في حالة توفر إجراء لاحق للتوسيم وإعادة التدريب. نأمل مستقبلا إدخال تحسينات على عدة محاور مثل استخدام التقنيات ما فوق الاجتهادية في اختيار متغيرات التصنيف، إلى جانب الاستفادة من الشبكات العصبية الضبابية في عمليتي التنبؤ واتخاذ القرار. كما يمكن اعتماد التحقق المتقاطع الطبقي كخيار تنافسي لتقييم مقاييس الأداء، خاصة في الحالات التي تتسم فيها الفئات بتراكب قوي أو بارتفاع التباين الداخلي.

تصريح إتاحة البيانات:

مجموعة البيانات التي تدعم نتائج هذه الدراسة متاحة من المؤلف الأول عند تقديم طلب معقول من طرف الباحثين المهتمين.

المراجع:

- [1] Schuh, G., & Monostori, L., & Csáji, B. Cs., & Döring, S. (2008). Complexity-based modeling of reconfigurable collaborations in production industry. *CIRP Annals-Manufacturing Technology*, 57(01), 445–450.
- [2] Tokatli, F. K., & Cinar, A. (2004). Fault detection and diagnosis in a food pasteurization process with hidden Markov models. *The Canadian Journal of Chemical Engineering*, 82(06), 1252–1262.
- [3] Haton, J. (1983). Knowledge based and expert systems in industrial applications. *IFAC Artificial Intelligence*, 16(20), 83–88.
- [4] Bentrchia, T., & Mouss, L. H., & Mouss, M. D. (2004). A reliability based approach for the design of hybrid expert systems in industrial diagnosis field. *The 2nd International Symposium on Innovation in Information & Communication Technology ISIICT'2004*, Amman, Jordan, April 21–22, 2004, 84–91.
- [5] Berghout, T., & Benbouzid, M., & Mueen, S. M., & Bentrchia, T., & Mouss, L. H. (2021). Auto-NAHL: A neural network approach for condition-based maintenance of complex industrial systems. *IEEE Access*, 09, 152829 –152840.
- [6] Dubuisson, B. (1990). *Diagnostic et Reconnaissance de Formes*. Hermès Publishing, Paris, France.
- [7] Halme, A., & Selkainäho, J. (1991). Advanced fault detection for sensors and actuators in process control. *IFAC fault detection, supervision and safety for technical processes*, 24(06), 91–97.
- [8] Pang, C. K., & Lewis, F. L., & Lee, T. H. & Dong, Z. Y. (2011). *Intelligent Diagnosis and Prognosis of Industrial Networked Systems*. CRC Press, Boca Raton, USA.
- [9] AFNOR. (1988). *Maintenance Industrielle. Recueil de Normes Françaises AFNOR*, AFNOR-UTE, 1988.
- [10] Zwingelstein, G. (1995). *Diagnostic des Défaillances Théorie et Pratique pour les Systèmes Industriels*. Hermès Publishing, Paris, France.
- [11] Tikhonov, A., & Arsénine, V. (1976). *Méthodes de Résolution de Problèmes Mal Posés*. Mir Edition, Moscou, URSS.
- [12] Venkatasubramanian, V., & Rengaswamy, R., & Yin, K., & Kavuri, S.N. (2003a). A review of process fault detection and diagnosis Part I: Quantitative model-based methods. *Computers and Chemical Engineering*, 27(03), 293–311.
- [13] Venkatasubramanian, V., & Rengaswamy, R., & Kavuri, S.N. (2003b). A review of process fault detection and diagnosis Part II: Qualitative models and search strategies. *Computers and Chemical Engineering*, 27(03), 313–326.
- [14] Venkatasubramanian, V., & Rengaswamy, R., & Kavuri, S.N. & Yin, K. (2003c). A review of process fault detection and diagnosis Part III: Process history based methods. *Computers and Chemical Engineering*, 27(03), 327–346.
- [15] Mouzakis, A. (2013). Classification of fault diagnosis methods for control systems. *Measurement and Control*, 46(10), 303–308.

-
- [16] Dash, S., & Venkatasubramanian, V. (2000). Challenges in the industrial applications of fault diagnostic systems. *Computers and Chemical Engineering*, 24(02–07), 785–791.
- [17] Majstorovic, V. D. (1990). Expert systems for diagnosis and maintenance: The state-of-the-art. *Computers in Industry*, 15(01–02), 43–68.
- [18] Ma, J., & Jiang, J. (2011). Applications of fault detection and diagnosis methods in nuclear power plants: A review. *Progress in Nuclear Energy*, 53(03), 255–266.
- [19] Venkatasubramanian, V. (2011). Systemic failures: Challenges and opportunities in risk management in complex systems. *AIChE Journal*, 57(01), 02–09.
- [20] Ribeiro, L., & Barata, J. (2011). Re-thinking diagnosis for future automation systems: An analysis of current diagnostic practices and their applicability in emerging IT based production paradigms. *Computers in Industry*, 62(07), 639–659.
- [21] Vogl, G. W., & Weiss, B. A., & Helu, M. (2019). A review of diagnostic and prognostic capabilities and best practices for manufacturing. *Journal of Intelligent Manufacturing*, 30(01), 79–95.
- [22] Sahu, A. R., & Palei, S. K., & Mishra, A. (2024). Data-driven fault diagnosis approaches for industrial equipment: A review. *Expert Systems*, 41(02), e13360.
- [23] Zhao, S., & Yang, H., & Kareck, T. L., & Khan, F., & Wang, Q. (2026). Data-driven fault detection and diagnosis in industrial process systems: A systematic review and perspective. *Reliability Engineering & System Safety*, 270, 112159.
- [24] Gao, Z., & Cecati, C., & Ding, S. X. (2015). A survey of fault diagnosis and fault-tolerant techniques Part I: Fault diagnosis with model-based and signal-based approaches. *IEEE Transactions on Industrial Electronics*, 62(06), 3757–3767.
- [25] Duda, R. O., & Hart, P. E., & Stork, D. G. (2000). *Pattern classification*. Wiley-Interscience, New York, USA.
- [26] Deisenroth, M. P., & Faisal, A. A., & Ong, C. S. (2020). *Mathematics for machine learning*. Cambridge University Press. Cambridge, UK.
- [27] Frank, P. M. (1990). Fault diagnosis in dynamic systems using analytical and knowledge-based redundancy a survey and some new results. *Automatica*, 26(03), 459–474.
- [28] Casimir, R. (2003). *Diagnostic des Défaits des Machines Asynchrones par Reconnaissance des Formes*. Thèse de Doctorat en Génie Electrique, Ecole Doctorale, Lyon, France.
- [29] Hand, D., & Mannila, H., & Smyth, P. (2001). *Principles of Data Mining*. MIT Press, Cambridge, USA.
- [30] Derrac, J., & García, S., & Herrera, F. (2014). Fuzzy nearest neighbor algorithms: Taxonomy, experimental analysis and prospects. *Information Sciences*, 260, 98–119.
- [31] Bentrchia, T., & Bouzenita, M., & Mouss, L. H. (2011). Enhancement of process state vector for industrial diagnostic applications using a statistical reduction approach. 1st International Conference on Automation and Mechatronics CIAM'2011, Oran, Algeria, November 22–24, 2011, 386–390.
-

-
- [32] Bouzenita, M., & Bentrchia, T., & Mouss, L. H. & Mouss, M. D. (2013). A neural modeling approach for the diagnosis of elementary failure modes in industrial plants. *Revue des Sciences et de la Technologie*, 04(01), 53–62.
- [33] Russell, E., & Chiang, L. H., & Braatz, R. D. (2000). *Data-driven Methods for Fault Detection and Diagnosis in Chemical Processes*. Springer-Verlag, London, UK.
- [34] Zadeh, L. (1965). Fuzzy sets. *Information and Control*, 08(03), 338–353.
- [35] Zieba, S. (1995). *Une Méthode de Suivi d'un Système évolutif: Application au Diagnostic de la Qualité d'usinage*. Ph.D Dissertation in System Control, University of Technology of Compiègne, France.
- [36] Keller, J., & Gray, M., & Givens, J. (1985). A fuzzy K-nearest neighbor algorithm. *IEEE Transactions on Systems, Man and Cybernetics*, 15(04), 580–585.
- [37] Bian, H. (2002). Fuzzy-rough nearest neighbor classification: An integrated framework. *Proceedings of IASTED International Symposium on Artificial intelligence and Applications*, 160–164.
- [38] Bentrchia, T., & Mouss, L. H., & Bensaadi, R., & Mouss, M. D. (2012). An efficient optimization method for the detection of new failures modes in industrial plants. *Revue des Sciences et de la Technologie*, 03(01), 43–52.