

Induction de concepts pour la Qualité 4.0 explicable

Léa Charbonnier¹, Franco Giustozzi², Julien Saunier¹, Cecilia Zanni-Merk¹

¹ INSA Rouen Normandie, Univ Rouen Normandie, Université Le Havre Normandie, Normandie Univ, LITIS UR 4108, F-76000 Rouen, France

² INSA Strasbourg, University of Strasbourg, ICube laboratory, CNRS (UMR 7357), 67000 Strasbourg, France

{lea.charbonnier, julien.saunier, cecilia.zanni-merk}@insa-rouen.fr,
franco.giustozzi@insa-strasbourg.fr

Résumé

L'article présente une méthode permettant de diagnostiquer les causes des problèmes de qualité des produits en utilisant l'induction de concepts. Une nouvelle métrique d'évaluation, combinant la couverture des instances, la précision de la classification et la pertinence hiérarchique, est proposée pour identifier les concepts les plus informatifs. L'approche est validée à l'aide d'un ensemble de données synthétiques de maintenance prédictive. Les résultats montrent une identification précise des facteurs liés aux produits défectueux.

Mots-clés

Induction de concepts, Assurance qualité et Industrie 4.0 (Qualité 4.0), Ontologie.

Abstract

The article presents a method for diagnosing the causes of product quality issues using concept induction. A new evaluation metric that combines instance coverage, classification accuracy, and hierarchical relevance is proposed to identify the most informative concepts. The approach is validated using a synthetic predictive maintenance dataset. The results show accurate identification of factors related to defective products.

Keywords

Concept Induction, Quality Assurance and Industry 4.0 (Quality 4.0), Ontology.

Contexte

L'un des principaux défis pour l'industrie consiste à détecter rapidement les anomalies et à en identifier les causes racines afin de minimiser les répercussions économiques et écologiques [7]. Dans ce contexte, la Qualité 4.0 intègre des systèmes intelligents afin d'améliorer la gestion de la qualité. Il s'agit d'une extension de l'Industrie 4.0 qui utilise des technologies intelligentes dans les processus d'assurance qualité, c'est-à-dire les procédures visant à garantir que les produits répondent à des normes prédéfinies [1]. Les méthodes basées sur les données permettent d'identifier efficacement cer-

taines causes racines, mais elles nécessitent généralement de grands ensembles de données étiquetées [9] et reposent sur des modèles complexes dont les processus décisionnels sont difficiles à interpréter [4]. Ces approches privilégient souvent la performance prédictive au détriment de l'explicabilité, ce qui peut limiter leur adoption dans des contextes industriels où il est essentiel de comprendre le raisonnement à l'origine d'un diagnostic. L'induction de concepts constitue une alternative interprétable, permettant d'extraire automatiquement des concepts en logique de description [6, 8]. Formellement, étant donné une base de connaissances $\mathcal{O} = (\mathcal{T}, \mathcal{A})$, composée d'une TBox \mathcal{T} et d'une ABox \mathcal{A} , ainsi que deux ensembles disjoints d'individus P et N représentant respectivement des exemples positifs et négatifs, l'objectif est d'apprendre une expression de classe C telle que $\mathcal{O} \models C(a)$ pour tout $a \in P$ et $\mathcal{O} \not\models C(b)$ pour tout $b \in N$.

L'article original est paru à RuleML+RR 2025 [2]. Il propose une approche fondée sur l'induction de concepts et une représentation ontologique du domaine, combinées à une stratégie d'évaluation multicritère permettant d'identifier des concepts interprétables expliquant les causes potentielles des défauts de qualité.

Approche proposée : RCIQ4.0

L'article propose une nouvelle approche pour identifier des problèmes de qualité dans les processus de fabrication. Cette approche, illustrée par la figure 1, utilise l'induction de concepts pour découvrir et expliquer les causes de ces problèmes. Un élément clé de cette approche est une ontologie permettant de représenter les produits défectueux (exemples positifs), les produits conformes (exemples négatifs) et les situations machine. Celle-ci s'appuie sur l'ontologie contextuelle *Context Ontology* [3], qui fournit une représentation formelle du domaine de la fabrication. Le module *Concept Induction* utilise l'algorithme ECII [6] pour générer des expressions conceptuelles décrivant les produits défectueux.

ECII est un algorithme d'induction de concepts qui sé-

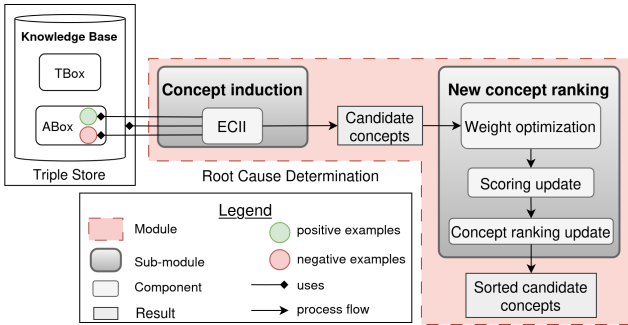


FIGURE 1 – Architecture de RCIQ4.0

lectionne un ensemble fini $\{C_1, \dots, C_n\}$ d'expressions de classes complexes sur \mathcal{L} ainsi que des expressions de classes complexes supplémentaires, ce qui donne $\mathcal{O}' = \mathcal{O} \cup \{A_k \equiv C_k | k = 1, \dots, n\}$ où A_i sont des classes atomiques n'apparaissant pas dans \mathcal{O} . Ensuite, un raisonneur est utilisé pour calculer l'appartenance de tous les individus issus des exemples à toutes les classes atomiques de \mathcal{O}' . Enfin, des expressions de classe candidates sont générées à l'aide de constructeurs de la logique de description (conjonction, disjonction, négation et restrictions existentielles). Cette stratégie minimise le nombre d'appels au raisonneur, en pré-calculant les appartenances aux classes candidates, ce qui permet une génération plus efficace des concepts et une amélioration des performances par rapport aux approches basées sur un raffinement itératif. Cependant, cette approche a pour contrepartie de restreindre l'espace de recherche des expressions potentielles. En effet, la grammaire ne décrit pas d'expressions \mathcal{ALC} arbitraires, mais une forme normale restreinte correspondant à la structure des concepts candidats générés par ECII, typiquement des combinaisons de classes atomiques et de restrictions existentielles, par exemple $\exists r.(A \sqcup B)$ ou $A \sqcap \exists r.B$. ECII est donc choisi pour son efficacité dans la génération d'expressions de classes complexes en logique descriptive, en particulier dans les ontologies riches en axiomes. Cependant, comme la méthode peut produire des centaines de concepts candidats, un processus de classement efficace devient essentiel pour déterminer quelles expressions méritent d'être examinées plus en détail.

Dans sa version originale, ECII classe les concepts uniquement selon leur couverture, ce qui tend à privilégier des concepts trop généraux. Afin d'obtenir des concepts plus discriminants, nous proposons d'évaluer chaque concept selon trois critères complémentaires : couverture, précision et hiérarchie. La couverture normalisée (Eq. 1) représente les exemples positifs correctement classés, c'est-à-dire les produits qui ont échoué au contrôle qualité et qui sont correctement décrits par le concept. La précision (Eq. 2) correspond à la proportion de vrais positifs déduits par le concept. La hiérarchie (Eq. 3) correspond à la profondeur ontologique

du concept parmi tous les concepts de classe candidats. L'objectif est d'évaluer si le concept cible les produits défectueux (vrais positifs) et évite les bons (faux positifs), ainsi que son ratio de généralisation et de spécificité.

$$n_cov = \frac{\text{Nb de produits défectueux identifiés}}{\text{Nb total de produits défectueux}} \times \text{Couverture maximale} \quad (1)$$

$$\text{precision} = \frac{\text{Nb de produits défectueux identifiés}}{\text{Nb total de produits identifiés}} \quad (2)$$

$$\text{hierarchy} = \frac{\text{Profondeur du concept}}{\text{Profondeur maximale}} \quad (3)$$

Les concepts sont ensuite classés en combinant les trois critères d'évaluation précédemment définis. Leur complémentarité permet un classement plus pertinent. Comme chaque critère est normalisé dans une plage comprise entre 0 et 1, ils peuvent être efficacement agrégés à l'aide d'une somme pondérée (équation 4).

$$\text{score} = \alpha \times n_cov + \beta \times \text{precision} + \gamma \times \text{hierarchy} \quad (4)$$

avec $\alpha, \beta, \gamma \in [0, 1]$ et $\alpha + \beta + \gamma = 1$

Afin d'identifier la combinaison optimale des poids α , β et γ , la fonction de notation définie dans l'équation 4 est optimisée sous certaines contraintes.

La méthodologie de classement proposée est appliquée à un cas d'utilisation afin d'évaluer son efficacité dans l'identification et l'interprétation des causes racines.

Étude de cas et résultats

Pour évaluer l'approche RCIQ4.0, le jeu de données Predictive Maintenance [5] est utilisé. Il fournit des informations sur les produits (ID et type), les valeurs des capteurs et les données sur les pannes des machines. En l'absence d'observations sur le contrôle qualité, des étiquettes de contrôle qualité synthétiques basées sur les valeurs et les descriptions de l'ensemble de données sont générées. Elles permettent de diviser les produits selon deux ensembles (défectueux et en bon état) qui sont utilisés pour l'induction de concept.

À partir des concepts générés par ECII et de leurs métriques associées, les poids α , β et γ sont déterminés en résolvant un problème d'optimisation. Les valeurs obtenues sont $\alpha = \beta = \gamma = 0.333$, indiquant que les trois critères contribuent de manière équilibrée au score final. Ces pondérations sont spécifiques au jeu de données et aux concepts générés et doivent être recalculées si ceux-ci sont modifiés. Les trois concepts les mieux classés selon leur score pondéré sont présentés dans le tableau 1. Les valeurs de précision élevées (Prec. = 1.0) indiquent que les concepts identifient uniquement des produits défectueux, tandis que les scores de hiérarchie élevés traduisent leur spécificité. Chaque concept associe les produits défectueux à une ou deux situations machine, ce qui facilite leur interprétation. La propriété d'objet `involvedInSituation`, qui relie un produit à une situation machine, permet ainsi d'identifier les conditions anormales associées aux défauts. Par

TABLE 1 – Concepts et leurs métriques associées : couverture, hiérarchie, précision et score (Eq. 1, 3, 2 et 4). La relation p représente la propriété `involvedInSit`.

Concepts	NCov.	Hier.	Prec.	Score
$\exists p. ((\text{Sit-PWF}) \sqcup (\text{Sit-HDF}))$	0.742	0.75	1.000	0.831
$\exists p. (\text{Sit-HDF})$	0.452	1.00	1.000	0.817
$\exists p. ((\text{Sit-OSF}) \sqcup (\text{Sit-HDF}))$	0.645	0.75	1.000	0.798

exemple, le premier concept relie les produits défectueux aux situations **Power Failure** (PWF) ou **Heat Dissipation Failure** (HDF), suggérant que ces défaillances peuvent être à l'origine du problème de qualité. Ainsi, la combinaison des métriques de couverture, de précision et de hiérarchie permet de sélectionner des concepts à la fois précis et interprétables, fournissant des explications potentielles aux défauts observés.

Discussion

Contrairement aux approches basées uniquement sur la couverture, la méthode proposée permet de privilégier des concepts plus spécifiques et interprétables, caractérisant les produits défectueux, mais elle présente certaines limites. En particulier, la qualité des concepts induits dépend fortement de la représentation ontologique et des données disponibles. De plus, la restriction de l'espace de recherche dans ECII peut limiter l'expressivité des concepts générés. Enfin, le choix des poids dans la fonction de score, bien qu'optimisé, reste dépendant du jeu de données considéré.

Conclusion

Cet article présente RCIQ4.0, une approche visant à identifier les causes potentielles de défauts de qualité au sein d'un processus de fabrication. La méthode repose sur l'induction de concepts afin d'extraire des concepts discriminants caractérisant les produits défectueux. Une nouvelle stratégie d'évaluation combinant couverture, précision et profondeur hiérarchique est proposée afin d'améliorer le classement des concepts. Cette mesure composite facilite l'identification de concepts explicatifs permettant de mieux comprendre l'origine des défauts de qualité.

L'approche proposée est générique et peut être appliquée à d'autres tâches d'analyse explicable basées sur des ontologies, dès lors que des exemples positifs et négatifs sont disponibles.

Remerciements

Ce travail a été financé par l'Agence nationale de la recherche française (numéro de subvention ANR-22-CE92-0007).

Références

[1] Adriana Ventura Carvalho, Daisy Valle Enrique, Amal Chouchene, and Fernando Charrua-Santos.

Quality 4.0 : An Overview. *Procedia Computer Science*, 181 :341–346, 2021.

- [2] Léa Charbonnier, Franco Giustozzi, Julien Saunier, and Cecilia Zanni-Merk. A Novel Concept Induction Approach for Explainable Quality 4.0. In *Rules and Reasoning*, pages 36–53, Cham, 2025. Springer Nature Switzerland.
- [3] Franco Giustozzi, Julien Saunier, and Cecilia Zanni-Merk. Context Modeling for Industry 4.0 : an Ontology-Based Proposal. *Procedia Computer Science*, 126 :675–684, 2018.
- [4] Hao Huang, Tapan Shah, John Karigiannis, and Scott Evans. Deep Root Cause Analysis : Unveiling Anomalies and Enhancing Fault Detection in Industrial Time Series. In *2024 International Joint Conference on Neural Networks (IJCNN)*, pages 1–8, June 2024.
- [5] Stephan Matzka. Explainable artificial intelligence for predictive maintenance applications. In *2020 Third International Conference on Artificial Intelligence for Industries (AI4I)*, pages 69–74, 2020.
- [6] Md Kamruzzaman Sarker and Pascal Hitzler. Efficient concept induction for description logics. In *Proceedings of the Thirty-Third AAAI Conference on Artificial Intelligence and Thirty-First Innovative Applications of Artificial Intelligence Conference and Ninth AAAI Symposium on Educational Advances in Artificial Intelligence*, volume 33, pages 3036–3043. AAAI Press, January 2019.
- [7] Md. Abdus Shabur. A comprehensive review on the impact of Industry 4.0 on the development of a sustainable environment. *Discover Sustainability*, 5(1) :97, May 2024.
- [8] Cara Leigh Widmer and et al. Towards human-compatible XAI. *Journal of Web Semantics*, 79 :100807, December 2023.
- [9] Chen Zhang, Di Hu, and Tao Yang. Research of artificial intelligence operations for wind turbines considering anomaly detection, root cause analysis, and incremental training. *Reliability Engineering & System Safety*, 241 :109634, January 2024.