

Détection de défauts sur radiographies de pièces composites rotor grâce à l'IA

N. Griselin¹, D. Dubois², P. Barbier¹

¹ AIRBUS Helicopters

² ALTEN

nicolas.griselin@airbus.com

Résumé

Lors du contrôle qualité des pièces composites rotor, chaque pièce est systématiquement inspectée au moyen d'une méthode de contrôle non-destructive, basée sur l'analyse visuelle de clichés radiographiques prises sur ces pièces. Dans cet article, une approche automatique de détection des défauts grâce à l'utilisation de l'IA est utilisée. L'application au cas industriel est présentée avec une précision pour prédire des défauts d'environ 85%, un Recall de 96% et un F1-score de 90%. Cet article sera présenté lors du prochain ERF 2024 (<https://hal.science/hal-04588729>).

Mots-clés

Détection, défaut, radiographie, composite, IA, segmentation, Mask-RCNN.

Abstract

During the quality control of rotor composite parts, each part is systematically inspected using a non-destructive control method, based on visual analysis of X-ray shots taken on the parts. In this article, an automatic approach for defects detection using AI is used. Application to the industrial case is presented with precision to predict defects of about 85%, a recall of 96% and a F1-score 90%. This article will be presented during the next ERF 2024 (<https://hal.science/hal-04588729>).

Keywords

Detection, defect, x-ray, composite, AI, segmentation, Mask-RCNN.

1 Introduction

L'état de l'art et les progrès les plus récents dans le domaine de l'IA appliqué à la détection des défauts ont été décrit [1], offrant une compréhension complète de l'utilisation des techniques d'apprentissage pour la classification, la détection et/ou la segmentation des défauts.

La classification est largement utilisée dans diverses applications telles que l'étiquetage d'images, la récupération d'images basée sur le contenu et la catégorisation d'images. Il sert de base à de nombreux systèmes de vision par ordinateur et a été utilisé dans notre travail précédent [2] où nous avons décrit une approche en trois étapes pour détecter les défauts dans les images de radiographie de pièces composites à l'aide de modèles simples d'intelligence artificielle (CNN) pour la classification des images.

Toutefois, l'utilisation d'une telle approche est limitée et ne permet pas de définir le nombre de défauts ainsi que la localisation et la caractérisation précise de chaque défaut.

Les techniques de segmentation dans le traitement de l'image et la vision par ordinateur, par contre, permettent de s'affranchir de ces limitations. Ces méthodes peuvent jouer un rôle important dans les tâches nécessitant une localisation et une segmentation détaillées des objets, comme l'analyse d'images médicales et le comptage des objets. La segmentation par instance et la segmentation sémantique sont deux techniques de segmentation importantes utilisées dans la vision par ordinateur pour l'analyse et la compréhension de l'image. Bien que la segmentation sémantique et la segmentation par instance fonctionnent au niveau du pixel pour diviser les images en régions significatives, elles diffèrent dans leur niveau de granularité. La segmentation sémantique se concentre sur l'attribution d'étiquettes de classe à des pixels basés sur des catégories sémantiques, tandis que la segmentation d'instance va plus loin en fournissant des masques de segmentation séparés pour chaque instance objet dans la même classe. Les deux techniques sont des outils précieux dans la vision par ordinateur et ont leurs applications respectives en fonction des exigences spécifiques de la tâche à accomplir. Les figures 1 et 2 illustrent la différence entre la segmentation sémantique et la segmentation par instance appliquée à notre étude.

Bien que la segmentation sémantique puisse améliorer la localisation des défauts sur clichés radiographiques sans faire de distinction entre les différents cas d'objets appartenant à la même classe (voir figure 1), elle ne permet pas de compter le nombre de défauts et de caractériser chaque défaut. D'autre part, la segmentation par instances (voir figure 2) permet de classer chaque pixel en catégories sémantiques et de distinguer les instances d'objets individuelles de la même classe. Cela nous donne la possibilité d'identifier et de différencier chaque instance objet présente dans l'image et ainsi caractériser chaque défaut en fonction de leur longueur et de leur largeur. Les progrès récents de l'apprentissage profond, notamment avec l'avènement de réseaux neuronaux convolutifs (CNN) et d'architectures comme R-CNN, ont grandement amélioré la précision et l'efficacité des modèles de segmentation [3].

Dans ce travail, nous avons mis en place une approche de segmentation par instance en utilisant un modèle Mask R-CNN pour détecter les défauts mais aussi pour pouvoir

localiser et caractériser chaque défaut dans la radiographie.




Fig. 1 : Segmentation sémantique




Fig. 2: Segmentation par instance

2 Méthodologie

Dans cette étude, nous avons utilisé la même base de données que dans notre étude précédente [2]. Elle se compose d'images 16 bits, en niveau de gris, avec une taille de 1024 x 1024 pixels, contenant un ou plusieurs défauts de tailles et localisations variables. Ces images ont été extraites du fichier DICOM d'origine collecté lors de la prise des clichés radiographiques de la pièce composite et converties en format PNG pour réduire la taille du fichier image sans perte de qualité. Il y a 345 images avec un ou plusieurs défauts et 200 images sans aucun défaut. Après extraction de l'image au format PNG, on applique une méthode de prétraitement de l'image pour enlever les bordures inutiles, normaliser le niveau de gris, inverser l'échelle d'intensité et filtrer la valeur des pixels de l'image (fenêtrage) afin de pouvoir visualiser clairement les défauts. Nous avons ensuite effectué la labélisation de tous les défauts de notre ensemble de données : chaque défaut d'une image est localisé et labélisé comme étant un « défaut » afin de distinguer les différents objets de la même classe. A partir de la localisation de chaque défaut, nous avons créé un masque de segmentation au niveau des pixels concernés. Ce masque indique quels pixels de l'image appartiennent à cette instance particulière. En attribuant une labélisation unique et en générant des masques de segmentation, les algorithmes de segmentation par instance peuvent délimiter et séparer avec précision les objets individuels dans la même classe. Un deuxième traitement a été effectué sur toutes les images (et tous les masques) consistant en une rotation d'image pour avoir tous les défauts dans la même direction, suivie d'un recadrage d'image (réduction de la

taille de l'image à 300 x 300 pixels) pour optimiser davantage la précision du modèle.

Pour la formation du modèle, nous n'avons considéré que les images avec des défauts. L'ensemble de données résultant (345 images présentant des défauts) a été divisé en trois groupes : un ensemble de données d'entraînement (60 %), un ensemble de données de validation (20 %) et un ensemble de données de test (20 %). Nous avons ensuite utilisé l'ensemble des données d'entraînement et de validation pour entraîner un modèle Mask R-CNN, avant de l'appliquer à notre ensemble de données de test.

3 Résultats

L'application de notre modèle Mask R-CNN sur notre ensemble de données test a fourni des bons résultats. Le modèle a été appliqué sur les 69 images de l'ensemble de données test. Une même image pouvant comporter plusieurs défauts, 132 défauts différents ont ainsi été considérés pour les données test. Les résultats sur ces données sont présentés dans la matrice de confusion ci-dessous (voir table 1).

Table 1. Matrice de confusion pour données test

		Prédiction	
		Sans défauts	Avec défauts
Référence	Sans défauts		FP = 23
	Avec défauts	FN = 6	VP = 126

FP = Faux Positif, FN = Faux Négatif, VP = Vrai Positif.

Lors du calcul des critères de performance, nous obtenons une précision pour la détection des défauts d'environ 85%, un *Recall* de 96% et un *F1-score* d'environ 90%.

4 Travaux en cours

Nous travaillons actuellement sur l'optimisation du modèle afin d'améliorer ses performances. Les développements ultérieurs se concentreront également sur l'explicabilité du modèle ainsi que sur son intégration au sein du processus qualifié en suivant les préconisations émises par l'EASA [4]. D'autres défauts seront également inclus dans l'algorithme de détection dans les travaux futurs. Cet article sera présenté lors du prochain ERF 2024.

5 Références

- [1] Z. Ren, F.Z. Fang, N. Yan et Y. Wu, State of the Art in Defect Detection Based on Machine Vision, *Vertical International Journal of Precision Engineering and Manufacturing-Green Technology*, 2022.
- [2] N. Griselin et P. Barbier, Defects Detection in Rotor Composite Parts using AI, *Vertical Flight Society 79th Annual Forum Proceedings*, 2023.
- [3] Z. Ren, F.Z. Fang, N. Yan et Y. Wu, Deep CNN-based visual defect detection: Survey of current literature, *Computers in Industry* 148, 2023.
- [4] EASA Concept Paper: First usable guidance for Level 1&2 machine learning applications, *easa.europa.eu/ai*, 2023.