



HAL
open science

Détection et reconnaissance d'endommagements dans les matériaux composites par Deep Learning

Antoine Hurmane, Jean-Michel Roche, Francois-Henri Leroy, Alexandre Boulch, Guy Le Besneray

► **To cite this version:**

Antoine Hurmane, Jean-Michel Roche, Francois-Henri Leroy, Alexandre Boulch, Guy Le Besneray. Détection et reconnaissance d'endommagements dans les matériaux composites par Deep Learning. 21ème Journées Nationales sur les Composites, École Nationale Supérieure d'Arts et Métiers (ENSAM) - Bordeaux, Jul 2019, Bordeaux, Talence, France. hal-02423015

HAL Id: hal-02423015

<https://hal.science/hal-02423015>

Submitted on 23 Dec 2019

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Détection et reconnaissance d'endommagements dans les matériaux composites par Deep Learning

Detection and recognition of damage in composite materials with Deep Learning

Antoine Hurmane¹, Jean-Michel Roche¹, François-Henry Leroy¹, Alexandre Boulch², Guy Le Besneray²

1 : DMAS
Onera – Université Paris Saclay
Adresse, F- code postale Ville Cedex 3
e-mail : antoine.hurmane@onera.fr

2 : DTIS
Onera – Université Paris Saclay
Adresse, F- code postale Ville Cedex 3

Résumé

Ces travaux proposent une méthodologie basée sur l'apprentissage pour la détection de fissures dans les matériaux composites. Des microscopies sous charge sont réalisées lors d'essais de traction sur des stratifiés de T700/M21. Le chant de l'échantillon est balayé par le microscope à l'aide d'une table micrométrique 3 axes. Ensuite, un algorithme de *Deep Learning* est sélectionné et adapté pour le traitement de microscopies optiques. Une série de microscopies est alors expertisée, c'est à dire que les fissures sont repérées manuellement, pour les différents paliers de chargement réalisés lors de l'essai. Les microscopies utilisées pour l'expertise sont des zooms x5. L'apprentissage est réalisé à partir de l'expertise pour tous les niveaux de charge. Une fois l'apprentissage réalisé on l'applique à d'autres séries d'images. Les résultats de cette première étude sont assez satisfaisants et donneront suite à une analyse plus quantitative.

Abstract

This work proposes a methodology based on deep learning to detect cracks within composite materials. Microscopies are taken under loading during tensile tests of T700/M21 laminates. The free edge of the sample is swept by the microscope thanks to a 3 axe table. Then, a deep learning network architecture is chosen and adapted to our case. A set of microscopies is expertized, meaning that cracks are highlighted by user, for different load levels. Microscopies used for expertise are x5 zooms. Learning is realized from the expertise. Finally, the result of learning is applied to different sets of images. Preliminary results are satisfying and will lead to more quantitative analysis.

Mots Clés : Endommagement, Contrôle Non-Destructif, Apprentissage, Microscopie

Keywords : Damage, Non-Destructive Inspection, Learning, Microscopy

1. Introduction

Détecter et reconnaître les endommagements dans les matériaux composites représente encore un défi pour automatiser le contrôle non-destructif ou encore faciliter l'inspection de pièces en service. Beaucoup d'approches sont développées dans ce sens, au travers de différentes instrumentation. L'émission acoustique est en ce sens une approche particulièrement utilisée [1]. Elle permet un suivi volumique en temps réel de l'endommagement d'une structure sous charge. A l'aide de traitements particuliers, on peut localiser les sources de l'endommagement et les classifier. Des techniques de suivi de la perte de rigidité sont aussi couramment utilisées, notamment dans le cas de la fatigue de structure. Néanmoins, cette technique ne permet pas de distinguer les lieux et les types d'endommagements. D'autres approches basées sur des observations optiques sont aussi fortement développées [5]. Les systèmes d'acquisition, (microscopie optique ou électronique à balayage, appareil photo), permettent d'observer les matériaux à leurs différentes échelles. Les méthodes d'analyses des images sont elles aussi variées : pour détecter les fissures, on retrouve, la corrélation d'images numériques [2], ou encore les méthodes de différence d'images. Ces méthodes sont très

efficaces, mais nécessitent une image de référence de l'échantillon sain. L'objectif de la méthode présentée dans ces travaux est de s'affranchir de l'image de référence. Cela permettra alors d'analyser des échantillons plus facilement, ou encore des images issues de coupes au cœur de la structure pour lesquelles il est délicat d'avoir un état de référence. Pour cela l'étude se base sur le *deep learning*, et plus précisément sur la segmentation sémantique. La segmentation sémantique, tâche consistant à attribuer une étiquette à chaque pixel d'une image, est un problème largement traité dans le domaine de la vision par ordinateur [3].

2. Algorithme de Deep Learning

Ces travaux se basent sur l'algorithme existant, Unet [4], en effectuant une segmentation sémantique à deux classes : fond et fissure. La Fig. 1 illustre un exemple de l'architecture U-net. Cet algorithme développé initialement pour la segmentation d'images médicales est reconnu et utilisé dans de nombreux domaines. Ce réseau est composé de deux parties, un encodeur qui réduit progressivement les dimensions spatiales de l'image, compressant ainsi le signal et un décodeur effectuant l'opération inverse pour revenir à la dimension initiale de l'image. De plus, afin de limiter les pertes d'information, notamment au niveau des bords des objets (effet de flou), [4] on utilise des Skip connections, qui injectent le signal à une échelle donnée de l'encodeur directement dans le décodeur. Les fissures représentent un très faible nombre de pixels par rapports à la quantité de pixel de fond. Une optimisation brutale du réseau conduit à une prédiction de fond uniquement. Afin de contrebalancer cette différence, l'importance des deux classes est pondérée au moyen d'une fonction de perte à l'optimisation (entropie croisée).

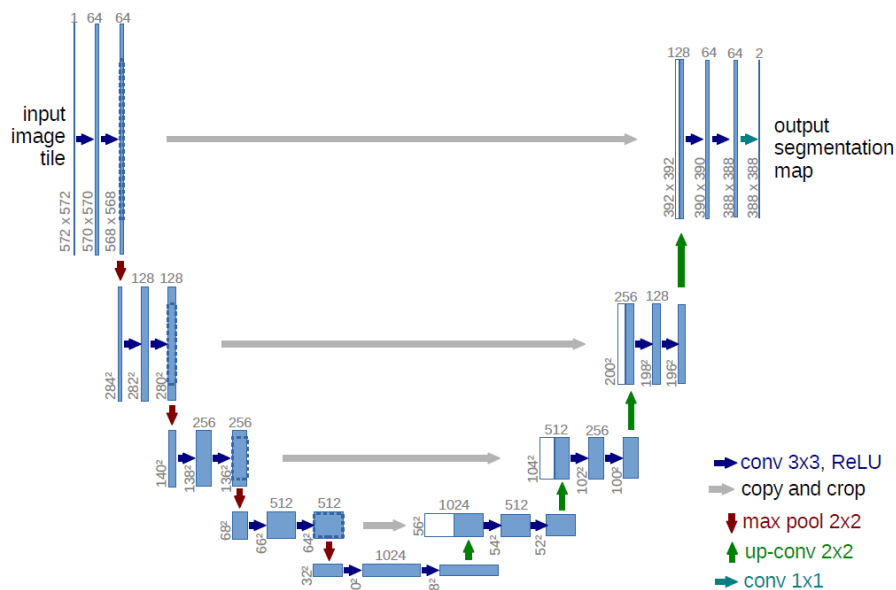


Fig. 1 Architecture U-net (exemple pour 32x32 pixels), issu de [4].

3. Détection de fissures transverses

3.1 Cas de l'étude

Dans cette étude nous nous intéressons à la détection de fissures dans un composite T700/M21 de plis unidirectionnels. Les résultats expérimentaux sont issus des travaux de thèse de Huchette [6]. Les essais étudiés sont des essais de traction avec paliers d'observation, réalisés sur une machine électromécanique Zwick de capacité 150 kN. Durant les paliers d'observation, un balayage du chant de l'échantillon est réalisé permettant les prises de vue à l'aide d'un microscope piloté par une table

3 axes micrométriques. Les microscopies sont réalisées avec différents zooms (x5, x10, x20 ou x50) en fonction de la définition souhaitée.

Arbitrairement nous avons choisi de réaliser l'apprentissage sur des microscopies optiques x5, prises sur la tranche de l'échantillon sous charge. Les paliers de contraintes réalisés, pour l'échantillon d'apprentissage, sont illustrés Fig. 2a). Sur la Fig. 2b) on peut observer un exemple de microscopie réalisée.

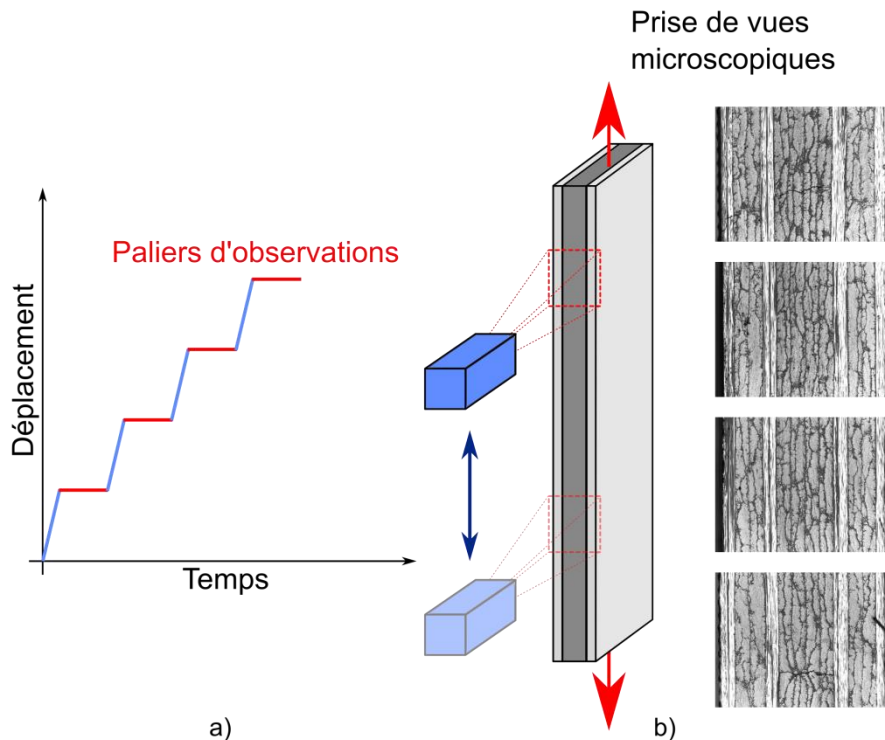


Fig. 2 Illustration de l'acquisition, a) chargement en paliers appliqué, b) exemple de microscopie.

3.2 Expertise des images

Pour réaliser l'apprentissage, il est nécessaire que les images soient expertisées en fonction de ce que l'on souhaite faire analyser au réseau de neurones. Sur l'ensemble des images l'expertise réalisée met en évidence les fissurations transverses ainsi que les micro-délaminages en pointe de fissures. La Fig. 3, illustre une image présentant une fissure transverse ainsi que l'expertise réalisée.

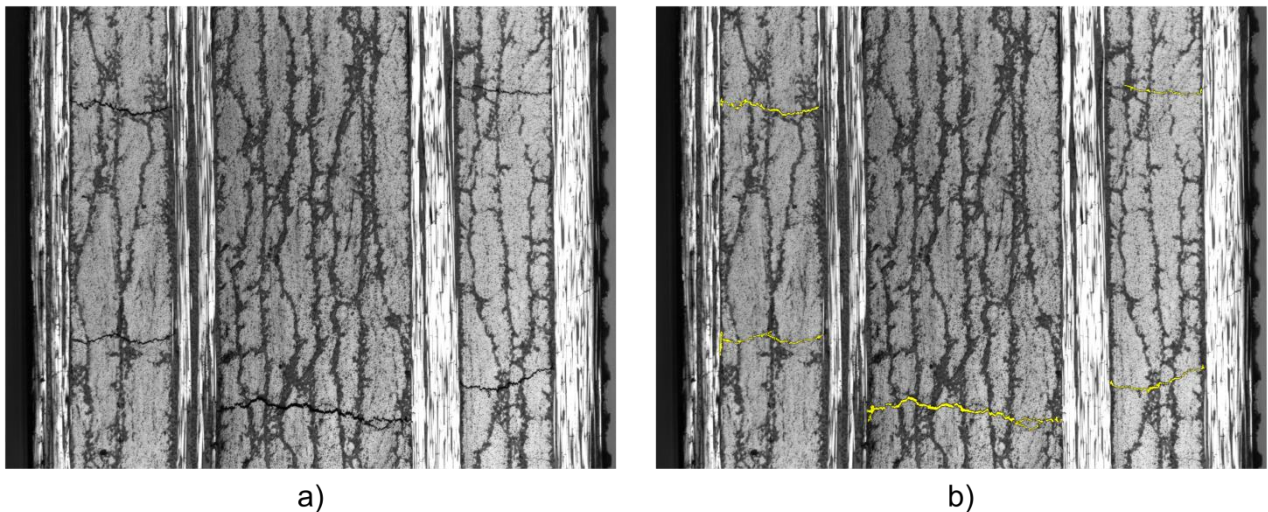


Fig. 3 Expertise des images, a) image brute, b) image expertisée.

3.3 Apprentissage

Le jeu d'images pour l'apprentissage est composé de 104 images. Classiquement nous divisons ce set d'images en deux sets, l'un pour l'apprentissage et l'autre pour la validation de l'apprentissage. Les données des fissures sont extraites des images expertisées en

4. Résultats de détection de fissures transverses

4.1 Validation de l'apprentissage

Une fois l'étape d'apprentissage réalisée sur un échantillon, nous soumettons cet apprentissage pour détecter les fissures sur le même échantillon mais sur des images acquises avec un zoom différent, x20.

Les résultats sont plutôt satisfaisants, la Fig. 4 compare une expertise faite indépendamment b) et les résultats obtenus par l'application de l'approche de *deep learning* avec l'apprentissage réalisé a). L'algorithme détecte correctement l'ensemble des fissures pour les différents niveaux de charge. On remarque cependant que les fissures ne sont pas toujours complètement connectées. Ce manque de connexion peut complexifier une étape de comptage automatique des fissures. On peut aussi remarquer que l'algorithme classe certaines zones comme rompues alors qu'elles ne le sont pas *a priori*, cependant cela semble se concentrer sur des faibles nombres de pixels.

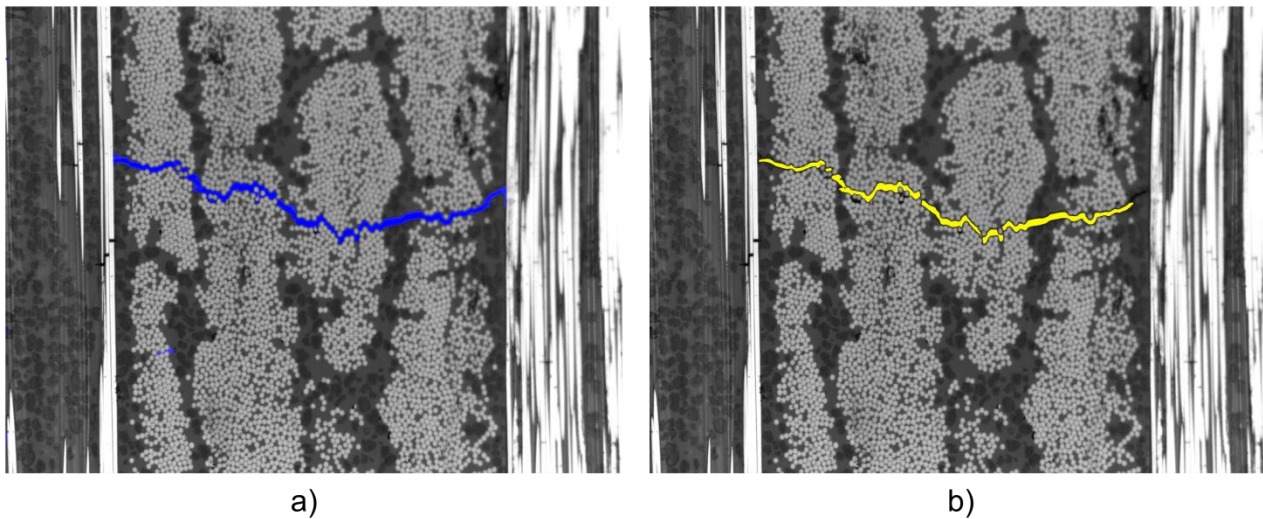


Fig. 4 Résultats de détection par deep learning a), comparés avec une expertise des images de microscopie b) pour un zoom x20.

4.2 Application à une autre stratification

La méthode de détection de fissures est appliquée à un même matériau mais de stratification $[0_2/90_2/0_2]$, toujours sollicité en traction monotone. Les microscopies sont prises pendant les différents paliers de chargement pour deux zooms, x10 et x20. La Fig. 5 présente les résultats de détection de fissures pour les deux zooms. L'algorithme détecte correctement la majeure partie des fissures, comme précédemment, les fissures détectées sont parfois discontinues. Cependant, comme on peut le voir Fig. 6. On constate par ailleurs quelques erreurs de détection, illustrées Fig. 6. Néanmoins sur l'ensemble des microscopies testées, les fissures sont toujours détectées : aucune fissure n'a été manquée par l'algorithme.

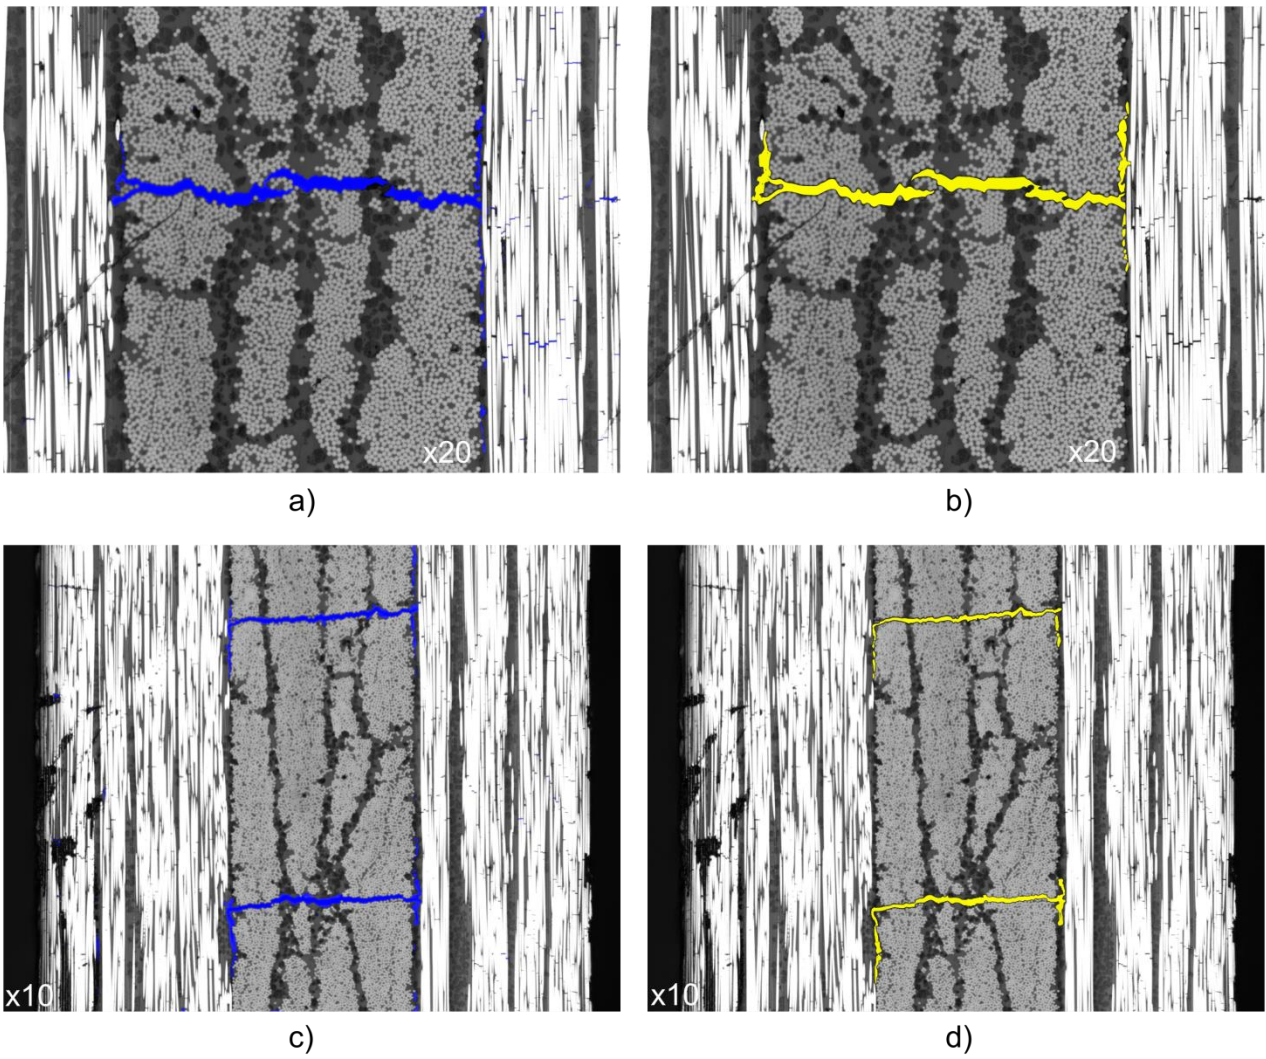


Fig. 5 Application de l'apprentissage sur un autre échantillon pour des zooms $x10$ et $x20$. a) et c) Résultats de l'algorithme pour les zooms $x20$ et $x10$, respectivement. b) et d) expertises a posteriori des images initiales, $x20$ et $x10$, respectivement.

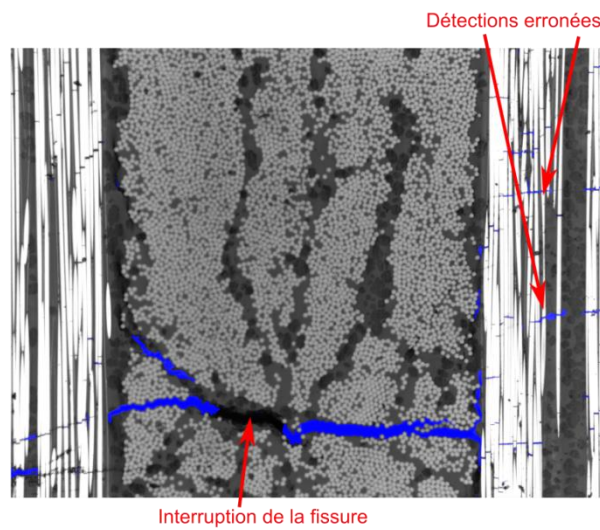


Fig. 6 Illustration de quelques erreurs de détections.

Conclusion

Dans ces travaux, un algorithme d'apprentissage basé sur la segmentation sémantique, U-net, a été utilisé pour détecter la présence de fissures sur des microscopies optiques. Le réseau a été entraîné sur des microscopies prises à plusieurs niveaux de charge pour un échantillon testé en traction. Pour l'apprentissage, chaque microscopie a été annotée afin de mettre les fissures en évidence. Une première étape d'application de l'apprentissage est de tester des microscopies issues du même essai, et donc du même échantillon, mais avec un plus fort grossissement. Les résultats obtenus sur cette série d'images étant satisfaisants, de nouvelles séries d'images ont été testées. Il s'agit d'images issues d'un essai de traction sur une stratification différente ; deux zooms différents ont été testés. Sur ce nouvel essai, l'ensemble des fissures sont détectées bien que quelques discontinuités des fissures détectées, et quelques erreurs de détection soient à signaler. Ces erreurs ne semblent pas être des fissures, et représentent uniquement des petits regroupements de pixels. La méthode mise en place est donc satisfaisante pour la détection de fissure. Elle a pour avantage de ne pas être basée sur une image de référence, ce qui la rend facilement applicable à la détection sur des coupes microscopiques à cœur d'échantillon, ou encore à des échantillons issus de structure.

Par la suite il sera intéressant d'étudier les résultats d'une détection sur des échantillons soumis à d'autres sollicitations mécaniques, tels que des impacts par exemple. L'apprentissage pourra être enrichi en expertisant différents types d'endommagements, tels que les fissures transverses, les délaminages, ou encore les ruptures de fibres.

Références

- [1] N. Godin, S. Huguet, R. Gaertner « Integration of the Kohonen's self-organising map and k-means algorithm for the segmentation of the AE data collected during tensile tests on cross-ply composites », *NDT&E International*, 38, , pp. 299–309, 2005.
- [2] F. Hild, A. Bouterf, S. Roux « Damage measurements via DIC », *International Journal of Fracture*, 105, pp. 77–105, 2015.
- [3] V. Badrinarayanan, A. Kendall, and R. Cipolla « Segnet: A deep convolutional encoder-decoder architecture for image segmentation », *arXiv preprint*, 2015.
- [4] O. Ronneberger, P. Fischer, and T. Brox « U-net: Convolutional networks for biomedical image segmentation », *International Conference on Medical image computing and computer-assisted intervention*, Springer, pp. 234–241, 2015.
- [5] A. Mohan, S. Poobal « Crack detection using image processing: A critical review and analysis », *Alexandria Engineering Journal*, 2017.
- [6] C. Huchette « Sur la complémentarité des approches expérimentales et numériques pour la modélisation des mécanismes d'endommagement des composites stratifiés », thèse de doctorat, Université Paris 6 / Onera, 2005.