

### Problématique Industrielle

L'inspection manuelle des surfaces boisées est lente, subjective et inefficace.

✓ **Faible fiabilité** : Taux d'erreur humain élevé (<70% de fiabilité) dû à la fatigue.

✓ **Goulot de production** : Incapable de suivre les cadences élevées des lignes modernes.

✓ **Données inadéquates** : Jeux de données limités et non représentatifs des conditions réelles.

**Notre solution** : Automatiser le contrôle qualité par l'apprentissage profond en deux étapes — (1) **segmentation** des défauts, puis (2) **classification** du type de défaut.

### Objectifs

Développer un système de vision par ordinateur fiable et adapté à l'industrie. Le projet est structuré en **deux étapes successives** :

✓ **Étape 1 — Segmentation (travail réalisé)** : localiser précisément les défauts au pixel près à l'aide de U-Net, FCN + Porte d'attention et Mask R-CNN.

✓ **Étape 2 — Classification (travail en cours)** : identifier le type de défaut à l'aide de ResNet / EfficientNet, à partir des régions issues de l'étape 1.

✓ **Objectif final** : un pipeline complet segmentation + classification, compatible avec les cadences industrielles.

### Jeu de Données

Un ensemble de données complet et exigeant pour l'entraînement et la validation des modèles :

— **22 275 images** haute résolution de panneaux bois.

— **10 classes de défauts** (nœuds, fissures, résines, etc.).

— **Capture industrielle** : acquises à 9,6 m/s sous un éclairage LED de 3,5 M lux.

— **Division** : 70% entraînement — 15% test — 15% validation.



FIGURE 1 — Exemples d'anomalies du jeu de données : (a) nœud sain — (b) résine et nœud mort — (c) fissure et nœud absent.

### Méthodologie

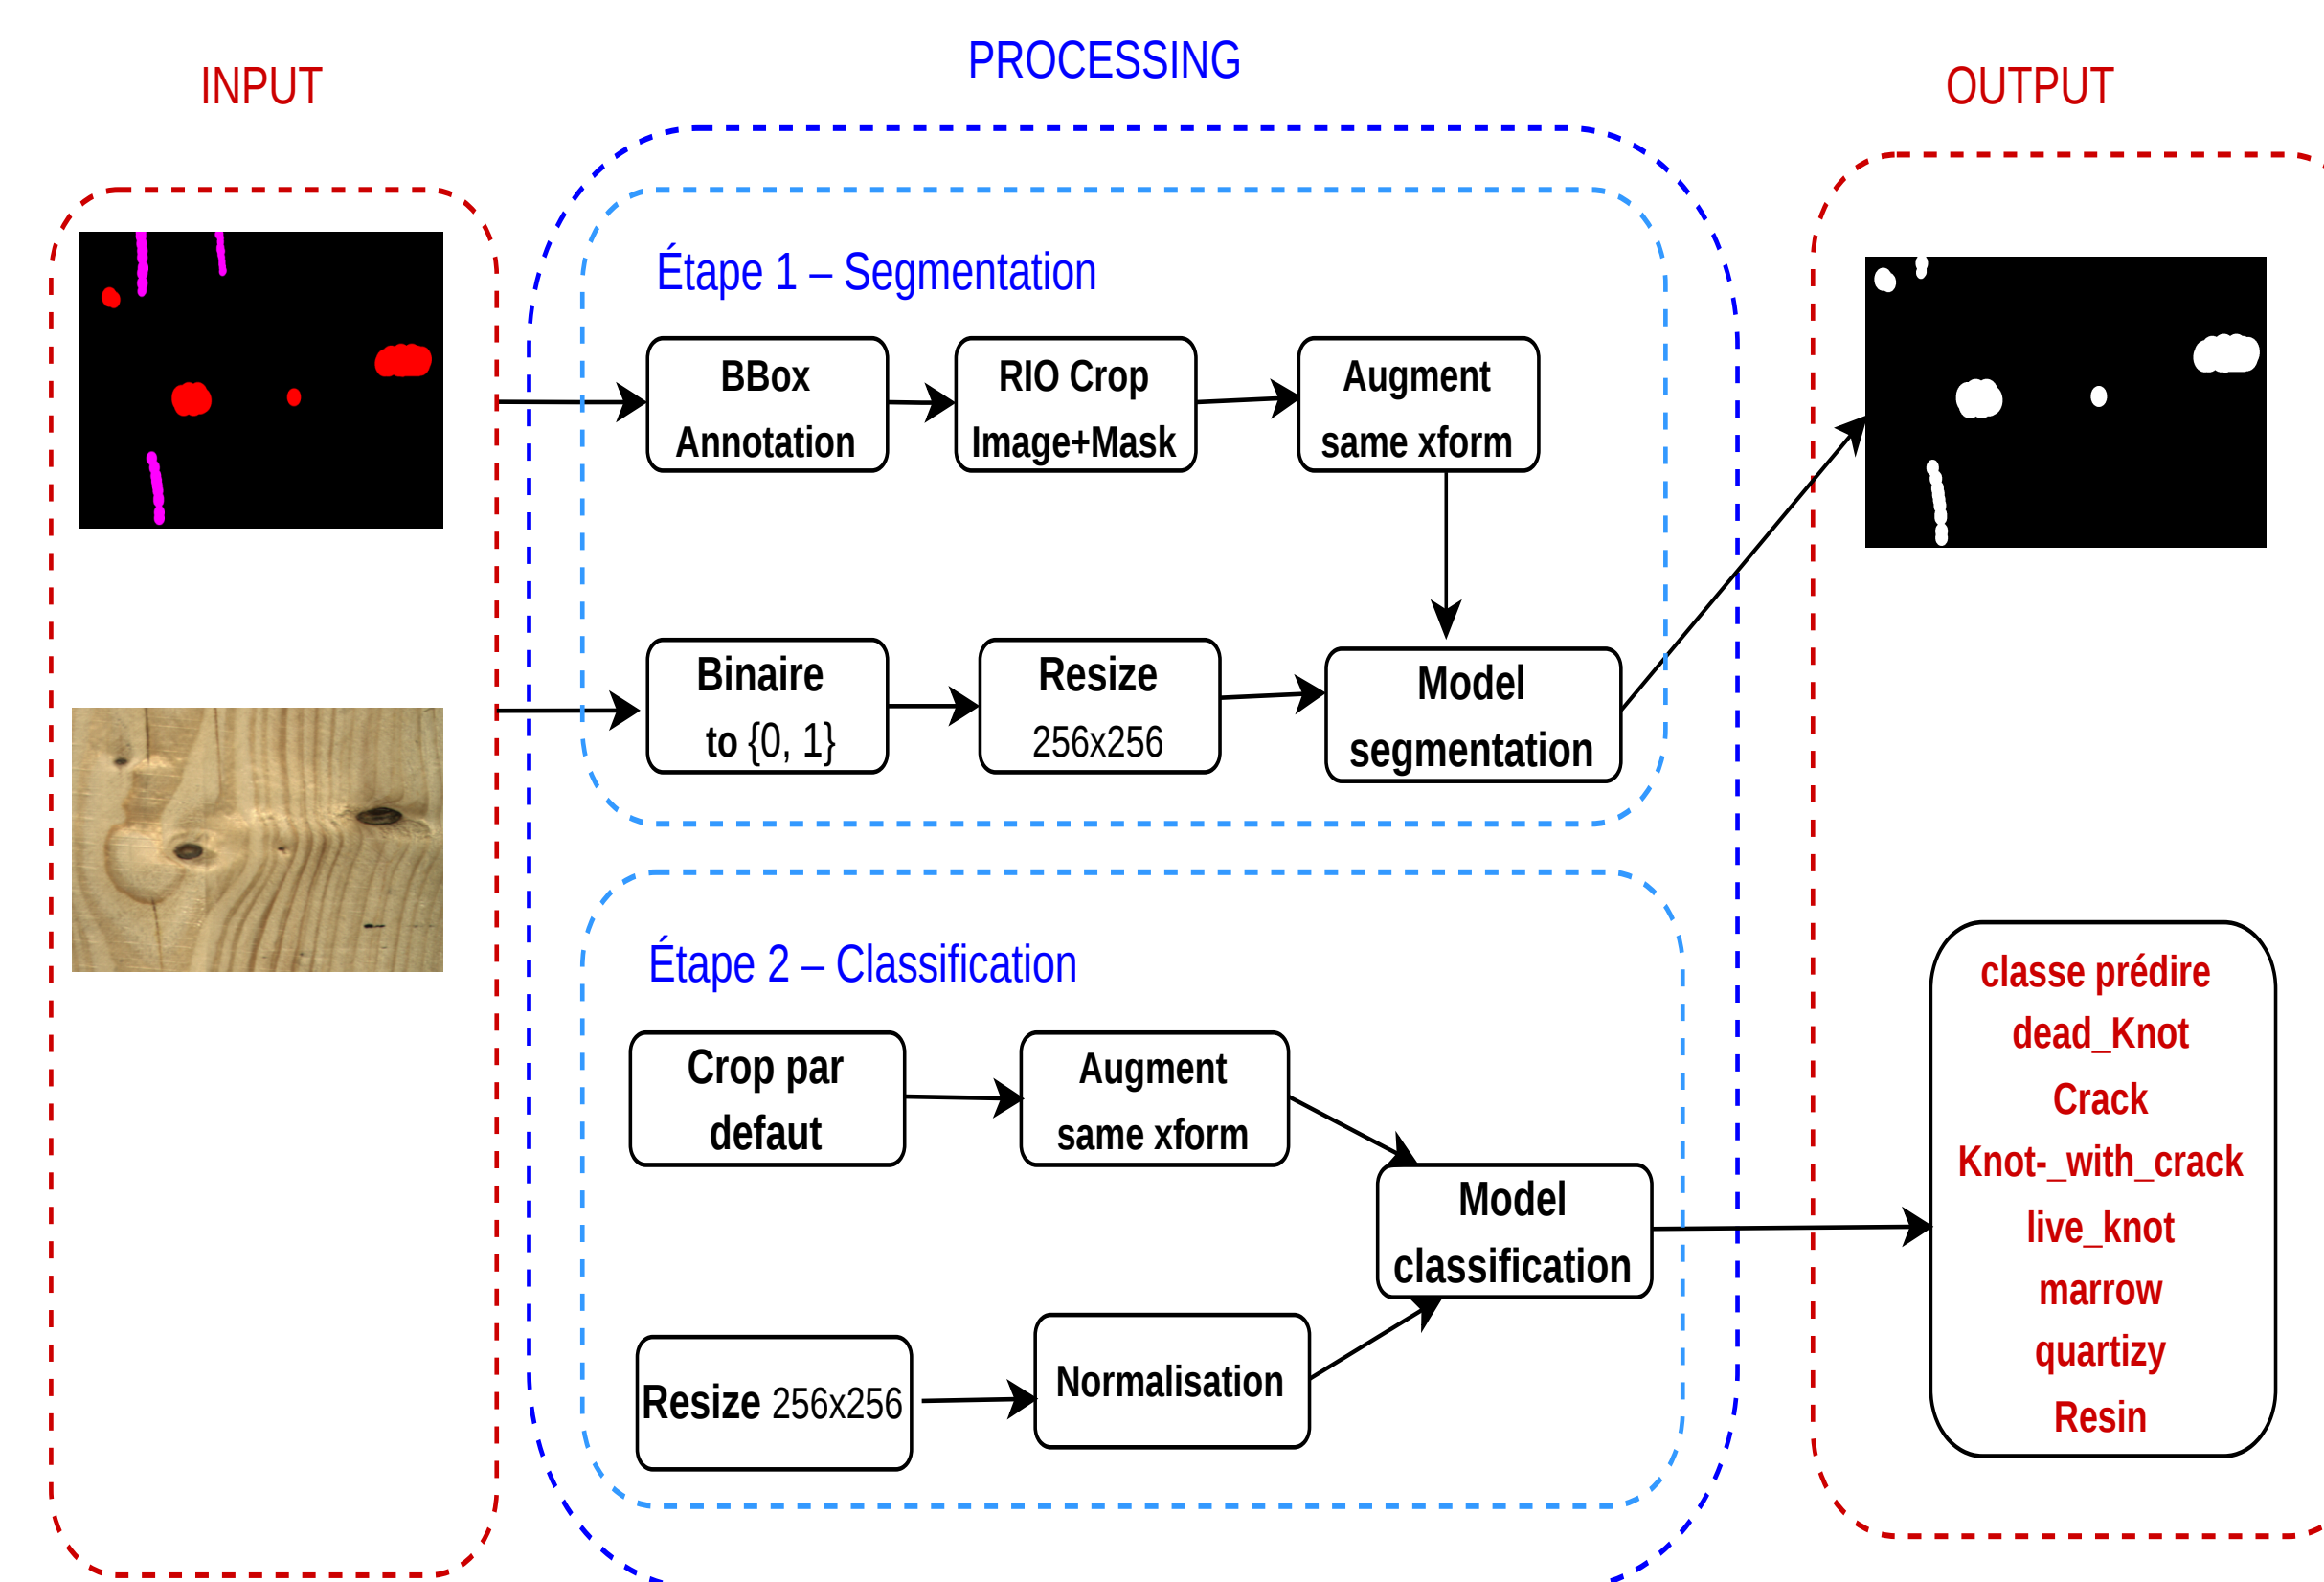


FIGURE 2 — Architecture globale du pipeline en deux étapes successives : (1) segmentation des défauts (réalisée), puis (2) classification des régions segmentées (en cours).

#### 1. Prétraitement des données

✓ **Filtrage** des images non informatives par analyse d'histogramme (canal vert).

✓ **Préparation** : redimensionnement (2800 × 1024), normalisation et égalisation d'histogramme.

#### 2. Segmentation des défauts (étape 1 — réalisée)

✓ **U-Net** : segmentation sémantique de haute précision avec perte combinée (Dice + Focal).

✓ **FCN + Porte d'attention** : focalisation sur les régions pertinentes.

✓ **Mask R-CNN** : segmentation d'instance pour séparer les défauts adjacents.

#### 3. Classification des régions segmentées (étape 2 — en cours)

✓ **ResNet101** : identification du type de défaut — Acc : 89,57%, F1 : 0,896 (24 époques).

✓ **EfficientNet-B4** : architecture légère et efficace — F1 : 0,862 (30 époques).

#### Panorama des approches

Modèle	Tâche	Rôle dans le système
U-Net	Seg.	Segmentation sémantique pixel-par-pixel
FCN + Attention	Seg.	Focalisation sur les régions pertinentes
Mask R-CNN	Seg.	Segmentation d'instance
ResNet101	Class.	Meilleure classification — F1 : 0,896
EfficientNet-B4	Class.	Architecture légère — F1 : 0,862

### Évaluation

✓ Division des données : **70%** entraînement — **15%** test — **15%** validation.

✓ Métriques de segmentation : **Dice** et **IoU**.

✓ Métriques de classification : **Précision**, **Rappel**, **F1**.

### Résultats

Modèle	Tâche	Dice	IoU / F1
U-Net	Segmentation	<b>0,90</b>	0,87
FCN + Attention	Segmentation	0,86	0,83
Mask R-CNN	Segmentation	0,84	0,85
ResNet101 <sup>†</sup>	<b>Classification</b>	—	<b>0,896</b>
EfficientNet-B4 <sup>†</sup>	Classification	—	0,862

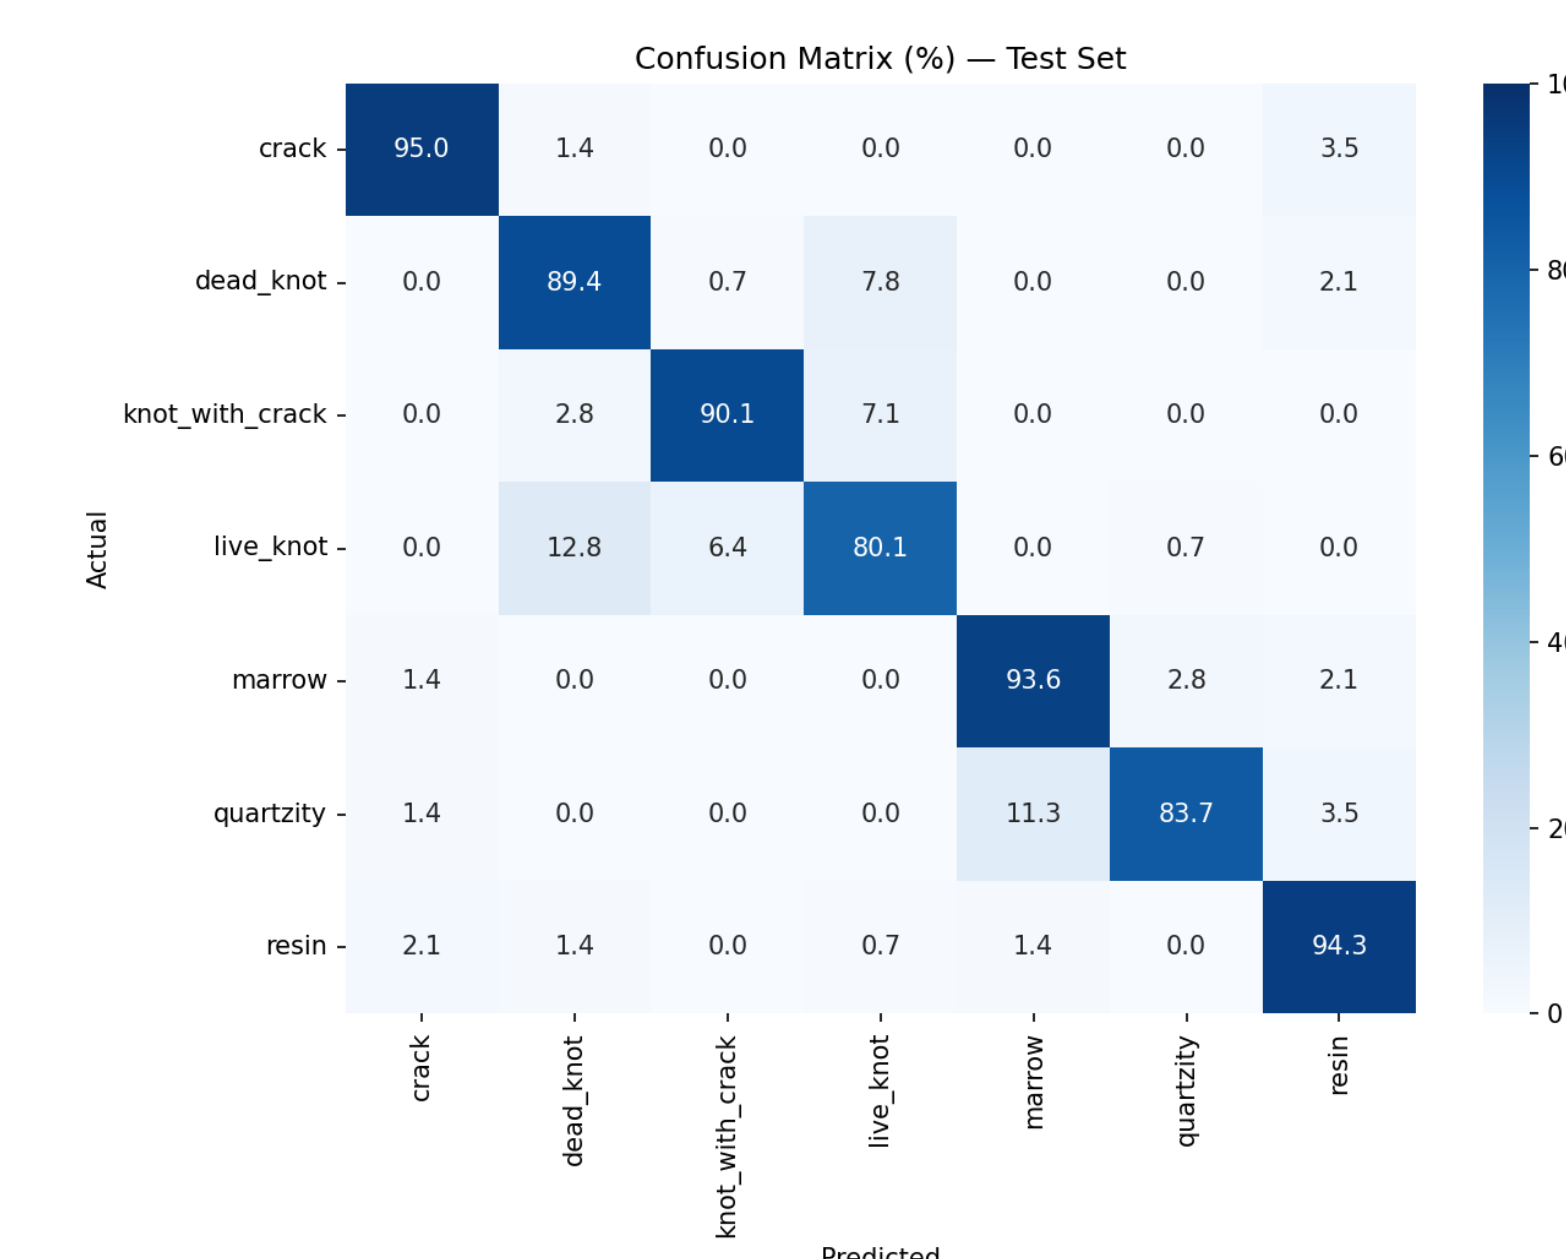


FIGURE 3 — Matrice de confusion — ResNet101 (résultats préliminaires).

### Conclusion et Perspectives

✓ **Étape 1 (segmentation) finalisée** : U-Net atteint un Dice de **0,90**, surpassant significativement l'inspection manuelle en fiabilité (>70%) et en vitesse.

✓ **Étape 2 (classification) en cours** : les résultats préliminaires sont prometteurs (**ResNet101** : Acc 89,57%, F1 0,896), à consolider sur l'ensemble de test complet.

✓ Prochaine étape : finaliser la classification et intégrer les deux modules dans un pipeline unique.

✓ Optimisation pour un déploiement embarqué en temps réel sur les lignes de production.

### Références

[1] K. He, X. Zhang, S. Ren, and J. Sun. Deep residual learning for image recognition. *CVPR*, pages 770–778, 2016.

[2] O. Ronneberger, P. Fischer, and T. Brox. U-Net : Convolutional networks for biomedical image segmentation. *MICCAI*, pages 234–241, 2015.