

Problématique

- ✗ Les systèmes industriels (scanners) sont performants mais coûteux et peu accessibles.
- ✗ L'inspection manuelle est lente, subjective et source de variabilité [1].
- ✗ La diversité et la complexité des défauts rendent leur détection fiable difficile [2].

Objectifs

L'objectif principal de ce travail est de proposer une solution automatisée et fiable pour la détection des défauts du bois basée sur l'IA.

Plus précisément :

- ✓ Concevoir et entraîner un modèle d'IA capable de détecter la présence d'un défaut dans une planche de bois.
- ✓ Entraîner un modèle de classification permettant d'identifier le type de défaut présent.
- ✓ Concevoir un système efficace et adaptable aux contraintes industrielles.

Méthodologie suivie

Le système proposé utilise une pipeline de deep learning pour détecter et classifier automatiquement les défauts du bois à partir d'images.




FIGURE 1 – Exemples d'images de bois utilisées pour l'apprentissage

I. Prétraitement :

- Organisation du jeu de données et division en train/val/test.
- Redimensionnement et normalisation des images.
- Conversion en tenseurs pour l'apprentissage.

II. Extraction des caractéristiques :

- Utilisation de modèles CNN pré-entraînés (Transfer Learning).
- Extraction automatique de caractéristiques visuelles profondes.

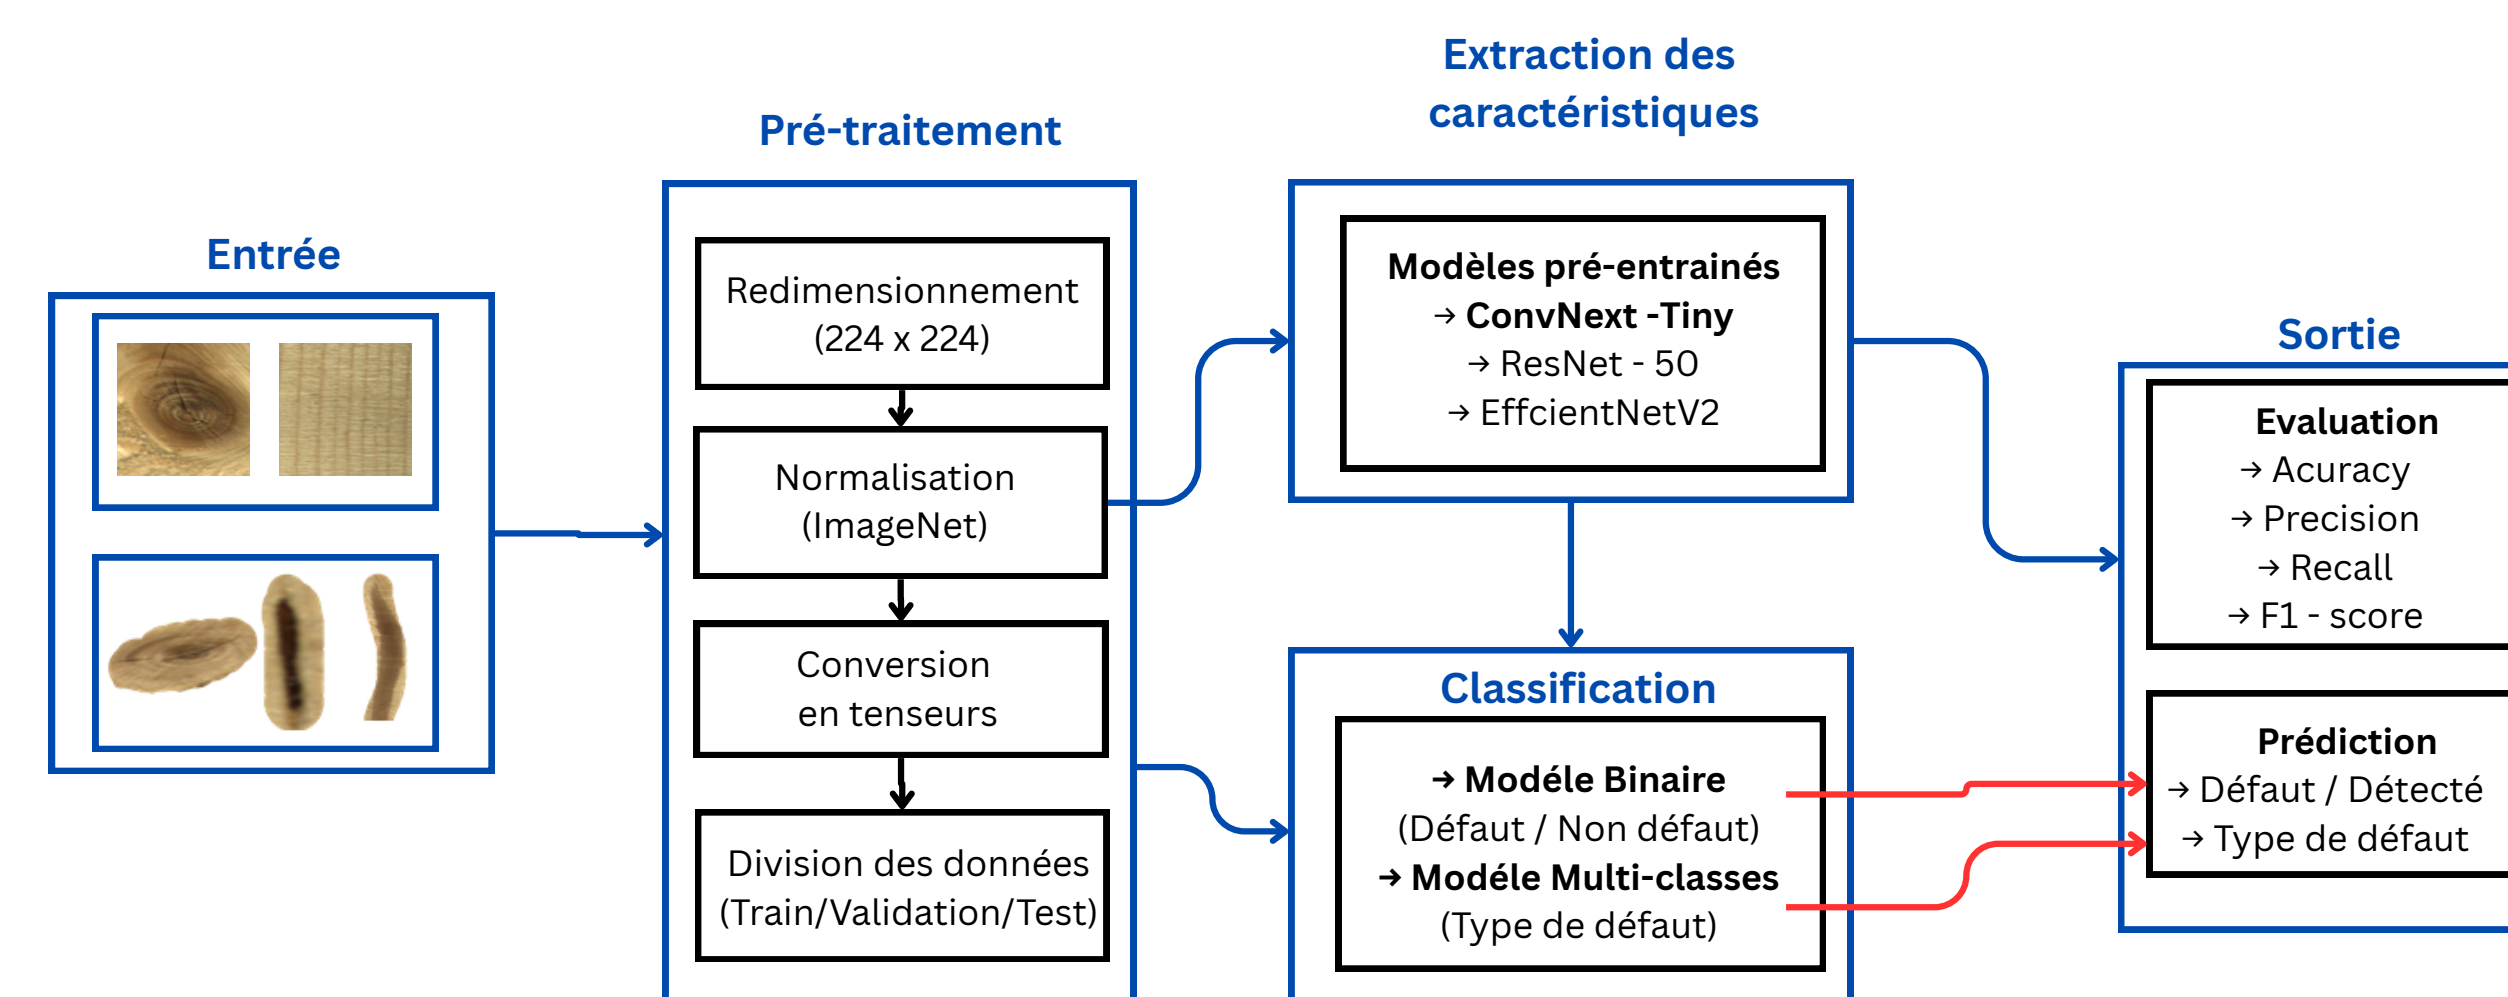


FIGURE 2 – Pipeline globale de détection et classification des défauts du bois

III. Classification :

- Une première étape de classification binaire permet de détecter la présence d'un défaut.
- Une seconde étape de classification multi-classes identifie le type de défaut.
- La classification utilise des jeux de données différents : les images avec contours pour la détection et les images sans contours pour leur classification.

IV. Stratégie d'entraînement :

- Validation croisée pour le modèle binaire.
- Ajustement du nombre d'époques (10 à 50).
- Utilisation de l'early stopping pour éviter le surapprentissage.

Évaluation

Nous avons utilisé le dataset "**Wood Defect Detection**" contenant 14 000 images de bois et plus de **43 000 annotations de défauts**.



FIGURE 3 – Exemples d'images de la base de données Zenodo

À partir de cette base de données, nous avons développé des scripts permettant de générer :

— Base de données 1 : (1952 images)

976 images sans défaut :




FIGURE 4 – Exemples d'images sans défaut

976 images avec défauts (976/7 pour chaque défaut) :




FIGURE 5 – Images avec défauts

Base de données 2 : (15 384 images)

Les images sont réparties en 7 classes, après un script visant à supprimer les contours du bois.



FIGURE 6 – Images avec défauts sans contours du bois

Résultats

Cette section présente les performances des modèles pour la détection des défauts du bois selon plusieurs métriques.

TABLE 1 – Évaluation des performances des modèles binaires

Modèle	Exactitude (%)	Rappel (%)	Score F1 (%)
ResNet50	89.20	88.10	89.00
ConvNeXt	91.80	90.95	91.60
EfficientNet	90.10	89.30	90.00

TABLE 2 – Comparaison des performances des modèles de classification

Modèle	Configuration	Exactitude (%)	Test (%)	Rappel (%)	Score F1 (%)
ConvNeXt	+5 époques	87.95	86.80	87.10	87.40
ConvNeXt	+10 époques	88.82	87.60	88.00	88.30
ConvNeXt	+30 époques	89.68	89.22	89.30	89.65
EfficientNetV2	–	77.24	75.80	76.10	76.50
EfficientNetV2	+ Dropout	87.30	86.00	86.40	86.90
Data Efficient	–	88.08	87.00	87.50	87.90

Les matrices de confusion des meilleurs modèles sont présentées ci-dessous :

TABLE 3 – ConvNeXt (Binaire)

	Détecté	Non détecté
Détecté	93.00%	7.00%
Non détecté	9.05%	90.95%

TABLE 4 – ConvNeXt (Multiclasse)

	Fissure	Nœud mort	Nœud vivant	Moelle	Quartzite	Nœud fissuré	Résine
Fissure	97.90%	0.00%	0.00%	0.00%	0.00%	0.30%	1.80%
Nœud mort	0.00%	92.46%	0.25%	0.00%	0.89%	0.25%	0.00%
Nœud vivant	0.00%	0.27%	85.97%	0.00%	0.00%	4.52%	0.23%
Moelle	0.00%	0.00%	0.00%	99.38%	0.00%	0.00%	0.00%
Quartzite	1.47%	0.00%	0.00%	19.97%	80.88%	2.21%	1.47%
Nœud fissuré	0.00%	0.00%	2.87%	0.00%	0.00%	97.13%	0.00%
Résine	5.73%	0.85%	0.85%	1.91%	0.21%	0.00%	90.85%

Conclusion

✓ Ce travail démontre l'efficacité du deep learning pour la détection et la classification des défauts

✓ L'approche basée sur des modèles pré-entraînés et une classification en deux étapes assure une bonne précision

- Explorer des approches d'apprentissage auto-supervisé afin de réduire la dépendance aux données annotées (non étiquetées).

Références

[1] T. Huang, X. Xie, and J. Wang, "Deep learning-based approaches for wood defect detection and classification," Computers and Electronics in Agriculture, vol. 179, p. 105824, 2020.

[2] A. Kumar and G. V. G. Raju, "Limitations of manual visual inspection in industrial quality control systems," Journal of Manufacturing Processes, vol. 45, pp. 123–130, 2019.