

Problématique

- ✗ L'inspection manuelle, dans le domaine de textile, est coûteuse, lente et sujette à des erreurs humaines (fatigue, subjectivité) [1].
- ✗ La complexité visuelle des tissus (textures 3D, motifs variés, variations d'éclairage) rend la détection automatique particulièrement difficile [2].
- ✗ La grande diversité des défauts complique le processus de détection.

Objectifs


- ✓ Concevoir une station d'acquisition d'images standardisée afin de garantir une base de donnée de qualité.
- ✓ Développer un pipeline robuste de détection des défauts basée sur des méthodes d'IA, notamment PaDiM et PatchCore.

Acquisition des données

- **Choix du matériel** : Sélection et intégration d'un dispositif d'imagerie industriel (caméra, éclairage, support) permettant une capture stable.
- **Interface de collecte** : Développement d'une application web interactive permettant à des utilisateurs non spécialistes de capturer, visualiser et organiser les données de manière structurée.



(a) caméra industrielle utilisée



(b) Station expérimentale de collecte des données

Figure 1. Environnement d'acquisition et de collecte des données

Méthodologie de détection des défauts

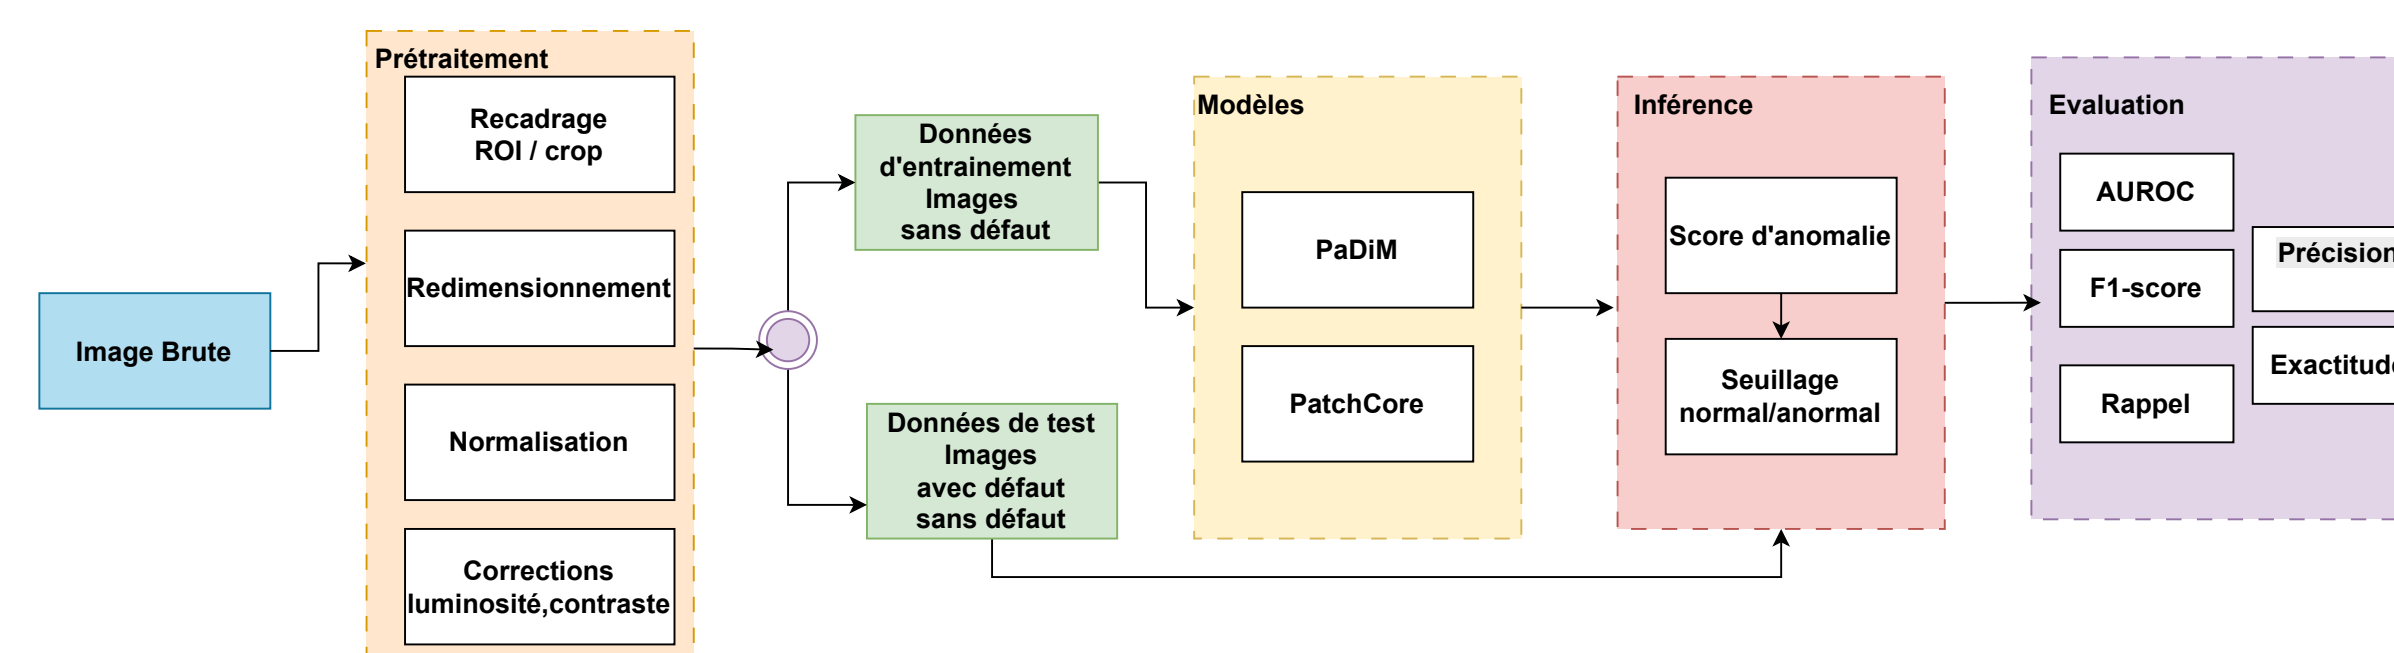


Figure 2. Architecture de système de détection des défauts dans les tuiles des tapis

- **Prétraitement** : Recadrage, redimensionnement et normalisation des images afin de réduire la variabilité.
- **Extraction des caractéristiques** : Extraction de représentations profondes via des CNN pré-entraînés.
- **Entraînement** : Apprentissage du comportement normal à partir d'images sans défaut.
 - ▷ **PaDiM** : modélisation par distributions gaussiennes multivariées.
 - ▷ **PatchCore** : construction d'un coreset représentatif des features normales.
- **Prédiction** : Détection des anomalies sur les nouvelles images.
 - ▷ **PaDiM** : distance de Mahalanobis pour mesurer l'écart.
 - ▷ **PatchCore** : distance au plus proche voisin dans la mémoire.

Base de données

- Environ 400 images de tapis dont 50 sont sans défaut contre une majorité d'images avec défaut.
- Forte variabilité visuelle : textures, motifs, couleurs et types de défauts (taille, forme, localisation).




Figure 3. Comparaison entre un tapis sain et un tapis présentant un défaut

Résultats

Les performances des modèles sont évaluées à l'aide de métriques standards, tandis que la matrice de confusion normalisée permet d'analyser finement la répartition des prédictions correctes et des erreurs.

Métrique	PaDiM	PatchCore
Exactitude	91.48%	98.11%
Précision	99.30%	99.35%
Rappel	91.88%	98.70%
Score F1	95.45%	99.02%
AUC (ROC)	97.26%	96.88%

Table 1. Comparaison des performances des modèles PaDiM et PatchCore

Classe réelle	Sans défaut	Défaut
Sans défaut	0.89	0.11
Défaut	0.06	0.94

Table 2. Matrice de confusion normalisée (PaDiM)

Conclusion et Perspectives

- Les modèles testés montrent une forte capacité de détection des défauts, avec des performances élevées en termes de précision et de rappel.
- L'intégration d'une infrastructure d'acquisition et d'une interface web facilite la collecte et la structuration des données en environnement industriel.
- Déploiement en temps réel du système de détection pour une inspection automatisée en conditions réelles.

Références

- [1] Briony Forsberg, Dr Henry Williams, Prof Bruce MacDonald, Tracy Chen, and Dr Kirstine Hulse. Textile anomaly detection : Evaluation of the state-of-the-art for automated quality inspection of carpet. *arXiv preprint arXiv :2407.18450*, 2024.
- [2] Mariam Nasim, Rafia Mumtaz, Muneer Ahmad, and Arshad Ali. Fabric defect detection in real world manufacturing using deep learning. *Information*, 15(8) :476, 2024.