

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE SCIENTIFIQUE

UNIVERSITE ABDELHAMID IBN BADIS MOSTAGANEM
FACULTE DES SCIENCES ET DE LA TECHNOLOGIE
DEPARTEMENT GENIE ELECTRIQUE



Thèse de Doctorat 3^{ème} cycle LMD

Filière : Electronique
Spécialité : Electronique médicale
Présentée par :
M^{elle} OULHISSANE Lynda

Thème

**Systeme intelligent de détection des produits
dangereux dans les bagages en soutes des avions**

Soutenue publiquement le : 12/ 03 / 2024
Devant le jury composé de :

Mme. MIMI Malika	Professeure	Université Abdelhamid Ibn Badis Mostaganem	Présidente
Mr. MERAH Mostefa	Professeur	Université Abdelhamid Ibn Badis Mostaganem	Rapporteur
Mr. DAHMANI Mohammed	Professeur	Université des Sciences et de la Technologie d'Oran Mohamed-Boudiaf	Examineur
Mme. BENOUDNINE Hadjira	Professeure	Université Abdelhamid Ibn Badis Mostaganem	Examinatrice
Mr. YAGOUBI Benabdellah	Professeur	Université Abdelhamid Ibn Badis Mostaganem	Examineur

Année universitaire 2023 / 2024

Remerciement

Mes remerciements débutent par une reconnaissance profonde envers Allah Tout-Puissant, source de force et de courage qui a guidé la réalisation de ce projet de recherche sur plusieurs années. Cette réussite est une fierté personnelle, et je tiens à exprimer ma gratitude envers tous ceux qui ont contribué à son succès en me soutenant tout au long de ce parcours.

En premier lieu, mes parents méritent une reconnaissance particulière. Leur croyance en moi et leur soutien précieux aux moments critiques ont été inestimables. Cette thèse leur est dédiée en signe de ma gratitude profonde. Ma famille, y compris ma grande sœur et mon frère, a joué un rôle essentiel de différentes manières, et je les remercie sincèrement. Un remerciement spécial va à ma petite sœur Samia, que Dieu la protège, pour son soutien continu et son amour.

Le Professeur Mostefa MERAH, en tant que Directeur de thèse, mérite une mention spéciale. Ses conseils inestimables, sa patience et son soutien constants ont été cruciaux tout au long de mon parcours doctoral.

Un remerciement sincère est adressé à la Professeure Luminita Moraru et la Professeure Simona Moldovano de l'Université Dunarea de Jos à Galati, en Roumanie, dont le soutien essentiel a contribué à la réalisation de ma recherche.

Je souhaite présenter mes profonds remerciements à la Professeure MIMI Malika, de l'Université Abdelhamid Ibn Badis Mostaganem, pour sa contribution précieuse et d'avoir accepté de présider le jury de cette thèse de Doctorat, ainsi que pour l'attention qu'elle lui a porté.

J'adresse également mes sincères remerciements aux : Professeur DAHMANI Mohammed de l'Université des Sciences et de la Technologie d'Oran Mohamed-Boudiaf ; la Professeure BENOUDNINE Hadjira et le Professeur YAGOUBI Benabdellah tous les deux de l'Université Abdelhamid Ibn Badis Mostaganem pour l'intérêt qu'ils ont bien voulu manifester à l'égard de ce travail, en acceptant d'examiner cette thèse et de faire partie du jury.

Ma bien-aimée Dr. Deghoul Lylia de l'Université de Tizi-Ouzou mérite une reconnaissance particulière pour son rôle crucial en m'encourageant à poursuivre mes études. Mes remerciements s'étendent également à ses parents, ainsi qu'au Dr. Ziani Nora, pour leur soutien continu.

Une mention spéciale va à Monsieur Abdelmoula Ahmed, qui m'a accompagné depuis le premier jour du concours de doctorat. Mes remerciements s'étendent aussi à Monsieur Kadda Djebbar, Monsieur Arezki Larbi et Madame Bendani Djazia pour leur aide précieuse.

Mon gratitude sincère va à Monsieur Kaci Hamrioui pour son soutien constant et ses encouragements tout au long de mon parcours doctoral. Monsieur Abdallah Mehidi mérite un grand remerciement pour son soutien inestimable.

Enfin, je remercie chaleureusement mes amis et collègues de l'équipe de recherche au laboratoire LSS à Mostaganem. Leur aide, leur soutien et leur gentillesse ont été inestimables, et je les remercie pour la confiance qu'ils m'ont accordée, ainsi que pour les précieux liens d'amitié que nous avons développés.

Résumé

La détection d'objets dangereux de type explosif dans les bagages en soute représente un défi crucial pour minimiser les risques liés aux actes criminels et aux attaques terroristes. Cette complexité découle souvent du camouflage soigneux de ces objets dangereux, rendant leur identification difficile. Les explosifs, en particulier, sont rares, difficiles à discerner, et peuvent prendre diverses formes, y compris les détonateurs, qui peuvent être confondus avec des masses organiques inoffensives. Les agents de sécurité aéroportuaire sont confrontés à l'examen d'un grand volume d'images radiographiques à rayons X, engendrant stress, fatigue, et une baisse d'attention.

Face à ces défis, l'intelligence artificielle (IA) peut fournir une assistance précieuse dans la détection des détonateurs, même en présence d'images de qualité médiocre. Cette étude se penche sur la détection des détonateurs dans les images radiographiques des bagages en utilisant une architecture d'apprentissage profond : le CNN profond. Deux approches ont été explorées : la première utilisant des images radiographiques brutes à double énergie, et la seconde impliquant un prétraitement d'image. Trois méthodes pré-entraînées ont été appliquées : CLAHE, la transformation en ondelettes avec les fonctions mères Haar, Daubechies2 (Db2), Symlet2 (Sym2), et Coiflet2 (Coif2), ainsi que la méthode mixte CLAHE RGB-transformée en ondelettes.

Les performances des images prétraitées ont clairement surpassé celles des images brutes. Les méthodes de prétraitement les plus efficaces, atteignant un taux de précision de 100 %, se sont avérées être CLAHE (Canal Vert en Gris, Canal Bleu en Gris, et Canaux RGB), ainsi que les transformations en ondelettes avec la fonction mère Haar à deux niveaux HL.

Mots clés

Détection, classification, détonateur, CNN profond, prétraitement, image à rayon X.

Abstract

Detecting potentially explosive objects in checked baggage is a crucial challenge for minimizing risks associated with criminal acts and terrorist attacks. This complexity often arises from the careful concealment of these hazardous items, making their identification challenging. Explosives, in particular, are rare, difficult to discern, and can take various forms, including detonators that may be mistaken for harmless organic masses. Airport security agents face the daunting task of examining a large volume of X-ray radiographic images, leading to stress, fatigue, and decreased attention.

In response to these challenges, artificial intelligence (AI) can provide valuable assistance in detecting detonators, even in the presence of low-quality images. This study focuses on detonator detection in radiographic images of baggage using a deep learning architecture: the Deep Convolutional Neural Network (CNN). Two approaches were explored: the first utilizing raw dual-energy radiographic images, and the second involving image pre-processing. Three pre-trained methods were applied: CLAHE, wavelet transformation with mother functions Haar, Daubechies2 (Db2), Symlet2 (Sym2), and Coiflet2 (Coif2), as well as the mixed method CLAHE RGB-wavelet transformation.

The performance of pre-processed images clearly surpassed that of raw images. The most effective pre-processing methods, achieving a precision rate of 100%, were found to be CLAHE (Green Channel to Gray, Blue Channel to Gray, and RGB Channels), as well as wavelet transformations with the Haar mother function at two levels HL.

Keywords

Detection, classification, detonator, deep CNN, pre-processing, X-ray image.

ملخص

يُعد اكتشاف الأجسام الخطرة من نوع المتفجرات في الأمتعة المسجلة تحديًا حاسمًا لتقليل المخاطر المتعلقة بالأعمال الإجرامية والهجمات الإرهابية. تنشأ هذه التعقيدات غالبًا من التمييز الدقيق لهذه الأجسام الخطرة، مما يجعل تحديدها أمرًا صعبًا. المتفجرات، على وجه الخصوص، نادرة، وصعبة التمييز، وقد تأخذ أشكالًا متنوعة، بما في ذلك المحرصات، التي يمكن أن تختلط بسهولة بالكتل العضوية الغير ضارة. يواجه أفراد أمن المطارات تحدي فحص حجم كبير من الصور الشعاعية بالأشعة السينية، مما يؤدي إلى الإجهاد والتعب وانخفاض التركيز.

أمام هذه التحديات، يمكن للذكاء الاصطناعي (IA) أن يقدم مساعدة قيمة في اكتشاف المحرصات، حتى في وجود صور ذات جودة منخفضة. تركز هذه الدراسة على اكتشاف المحرصات في الصور الشعاعية للأمتعة باستخدام تصميم عميق للتعلم: شبكة النيورال العصبية التكاملية العميقة (CNN profond). تم استكشاف نهجين: الأول باستخدام صور شعاعية خام بطاقة مزدوجة، والثاني يشمل معالجة الصور. تم تطبيق ثلاث طرق مدربة مسبقًا: CLAHE، التحول بواسطة الموجات مع وظائف الأم Haar، Daubechies2 (Db2)، Symlet2 (Sym2)، و Coiflet2 و Coif2)، بالإضافة إلى الطريقة المختلطة CLAHE RGB-التحول بواسطة الموجات.

أظهرت أداء الصور المعالجة مسبقًا تفوقًا واضحًا على الصور الخام. أثبتت طرق المعالجة المسبقة الأكثر فعالية، التي وصلت إلى معدل دقة 100٪، أنها CLAHE (القناة الخضراء إلى الرمادي، القناة الزرقاء إلى الرمادي، وقنوات RGB)، وكذلك تحول الموجات مع وظيفة الأم Haar على مستويين HL.

كلمات مفتاحية

اكتشاف، تصنيف، محرض، الشبكة العصبية التكاملية العميقة، معالجة مسبقة، صورة بالأشعة السينية

Table des matières

Remerciement	i
Résumé	iii
Abstract	iv
ملخص	v
Table des matières	vi
Liste des tableaux	xi
Liste des figures	xii
Liste des notations	xiv
Liste des abréviations	xvi
Introduction générale	1
Chapitre 1. Techniques de détection des explosifs par rayons X	3
1.1. Introduction	3
1.2. Imagerie par rayons X	5
1.2.1. Techniques d'imagerie classique	5
1.2.2. Techniques d'imagerie double énergie	5
1.2.3. Technique d'imagerie rayonnement rétro-diffusé Compton	7
1.2.4. Technique d'imagerie tomographie	8
1.2.5. Méthode multi-énergie	9
1.3. Détection des explosifs dans les images à rayons X à double énergie	9
1.3.1. Caractéristiques des explosifs et des détonateurs	9
1.3.2. Types de détonateur	10
1.3.2.1. Détonateur électrique	10
1.3.2.2. Détonateur non électrique	10
1.3.2.3. Détonateur à retardement	11
1.3.2.4. Détonateur séquentiel	11
1.3.2.5. Détonateur à tube choc	11
1.4. Techniques d'optimisation de la détection des explosifs	12

1.4.1. Prétraitement des images	12
1.4.1.1. Amélioration de la netteté	13
1.4.1.2. Filtrage du bruit	13
1.4.1.3. Égalisation de l'histogramme.....	13
1.4.1.4. Normalisation des couleurs	13
1.4.1.5. Segmentation	13
1.4.1.6. Filtrage adaptatif.....	13
1.4.1.7. Amélioration du contraste	13
1.4.1.8. Suppression des ombres et des reflets	14
1.4.2. Algorithme de détection des explosifs.....	14
1.4.2.1. Collecte de données et annotation	14
1.4.2.2. Prétraitement des images	14
1.4.2.3. Entraînement du modèle CNN	14
1.4.2.4. Validation du modèle	15
1.4.2.5. Détection en temps réel	15
1.4.2.6. Post-traitement.....	15
1.4.2.7. Notification ou intervention humaine.....	15
1.4.2.8. Mise à jour continue	15
1.4.3. Limitations et défis de la détection des explosifs dans les images à rayons X à double énergie	16
1.4.3.1. Faible contraste.....	16
1.4.3.2. Taille et forme variables	16
1.4.3.3. Épaisseur des matériaux	16
1.4.3.4. Composés chimiques variés	16
1.4.3.5. Effets de superposition	16
1.4.3.6. Dose de rayonnement	16
1.4.3.7. Complexité matérielle	17
1.4.3.8. Intégrité de l'objet	17
1.4.3.9. Évolution des menaces	17
1.5. Machines de détection des explosifs basées sur les rayons X	17
1.5.1. Scanners à rayons X pour bagages	17
1.5.2. Scanners à rayons X pour colis et courrier	18
1.5.3. Scanners à rayons X pour la sécurité des frontières	19
1.6. Conclusion.....	19

Chapitre 2. État de l'art sur la détection des objets dangereux dans les images à rayons X à double énergie	20
2.1. Introduction	20
2.2. Approches de Détection d'Objets Dangereux dans les Images à Rayons X des Bagages	20
2.2.1. Méthodes traditionnelles.....	20
2.2.2. Réseaux de neurones convolutifs (Convolutional Neural Network ou CNN)..	21
2.2.2.1. Méthodes à deux étapes.....	21
2.2.2.2. Méthodes à une seule étape	21
2.3. Dispositifs de contrôle à rayons X pour la détection d'objets dangereux dans les bagages	22
2.4. Etudes sur la détection de substances dangereuses dans les images à rayons X des bagages	22
2.4.1. Méthodes à double énergie pour identifier les objets dangereux incluant les détonateurs.....	22
2.4.2. Evaluation de la performance opérationnelle dans la détection d'objets dangereux par imagerie 2D et 3D.....	23
2.4.3. Optimisation des images d'objets dangereux par ondelettes avant leur intégration dans une architecture CNN profonde	23
2.4.4. Amélioration des radiographies à rayons X par CLAHE avant leur intégration dans une architecture CNN profonde	24
2.5. Conclusion.....	25
Chapitre 3. Analyse des images à rayons X des bagages	27
3.1. Introduction	27
3.2. Définition de l'ondelette.....	27
3.2.1. Transformée en ondelettes continues (TOC).....	28
3.2.2. Transformée en ondelettes discrète (TOD)	30
3.2.2.1. L'aspect mathématique.....	30
3.2.2.2. Algorithme de compression par ondelettes	31
3.2.2.3. Etapes de compression par ondelettes	31
a. Algorithme d'arbre de zéro (EZW).....	32
b. Algorithme SPIHT	32
3.3. Structure pyramidale de la décomposition en ondelette.....	32

3.4. Approches de l'égalisation d'histogramme pour l'amélioration du contraste d'images	35
3.4.1. Égalisation globale de l'histogramme	35
3.4.2. Égalisation locale de l'histogramme	36
3.4.2.1. Égalisation d'histogramme (HE)	36
3.4.2.2. Égalisation d'histogramme adaptative (AHE)	37
3.4.2.3. Égalisation d'histogramme adaptative à contraste limité (CLAHE)	37
3.4.2.4. Égalisation d'histogramme avec chevauchement de blocs (BOHE)	37
3.4.2.5. Égalisation d'histogramme sans chevauchement de blocs (NOBHE)	38
3.4.2.6. Égalisation d'histogramme de sous-blocs partiellement chevauchants (POSHE)	38
3.4.2.7. Égalisation d'histogramme adaptative pondérée (WAHE)	39
3.5. Conclusion	40
Chapitre 4. Méthodes utilisées pour la détection des détonateurs	41
4.1. Introduction	41
4.2. Database	43
4.3. Expérience 1	45
4.4. Expérience 2	45
4.4.1. Prétraitement de l'image	45
4.4.1.1. Méthode 1	45
4.4.1.2. Méthode 2	45
4.4.1.3. Méthode 3	46
4.5. Classification Convolutional Neural Network (TensorFlow et Keras)	46
4.6. Critères d'évaluation	48
4.7. Conclusion	50
Chapitre 5. Résultats et discussions	51
5.1. Introduction	51
5.2. Discussions	56
5.3. Résultats	58
5.4. Conclusion	59

Conclusion générale	61
Références bibliographiques	63

Liste des tableaux

Tableau 1.1 Synthèse des Caractéristiques Distinctifs des Explosifs et des Détonateurs dans une Image à Rayons X.....	9
Tableau 2.1 Références et Méthodes.....	25
Tableau 3.1 Fonction mères d'ondelettes.....	28
Tableau 3.2 Propriétés principales des ondelettes (Danso et al. 2022).....	28
Tableau 3.3 Comparaison des avantages, inconvénients, et avancées liées à l'application de la transformée en ondelettes dans le traitement des images à rayons X des bagages.	34
Tableau 3.4 synthèse des Avantages et des Limitations des Diverses Catégories de Méthodes d'Amélioration de Contraste Basées sur l'Égalisation d'Histogramme (Majeed & Isa 2020).	39
Tableau 4.1 Étude d'ablation sur la base de données d'images brute.....	44
Tableau 4.2 Étude d'ablation sur les images HH et HL.....	47
Tableau 4.3 Hyperparamètres de l'architecture CNN profonde.	48
Tableau 4.4 Matrice de confusion binaire.....	48
Tableau 5.1 Résultat de la détection du CNN profond pour les images radiographiques brutes	51
Tableau 5.2 Résultats de la détection obtenus par le CNN profond lors de l'utilisation de la méthode d'amélioration d'image CLAHE et de la décomposition des canaux de couleur.....	52
Tableau 5.3 Résultats de la détection obtenus par le CNN profond pour les transformations en ondelettes appliquées aux sous-bandes HH et HL.	53
Tableau 5.4 Résultats de la détection du CNN profond pour les transformées en ondelettes appliquées aux sous bandes HH et HL.....	55
Tableau 5.5 Analyse comparative des performances de notre proposition par rapport à d'autres travaux sur les architectures CNN issus de la littérature.....	59

Liste des figures

Figure 1.1 Méthodes de Détection d'Explosifs d'après la Division de Technologie de Neutralisation des Explosifs Navals (NAVEODTECHDIV) 1997).....	4
Figure 1.2 Inspection des Bagages par Imagerie de Transmission sur un Tapis de Contrôle (à droite) avec l'Image Correspondante (à gauche).....	5
Figure 1.3 Image par transmission : a) classique, b) double énergie.	6
Figure 1.4 Capture simultanée d'une valise à l'aide de deux techniques : a) Imagerie par Rayons X en Transmission, b) Imagerie par Rayons X en Rétrodiffusion.....	7
Figure 1.5 Imagerie par double énergie (a), imagerie par rayons X en rétrodiffusion (b).....	8
Figure 1.6 Appareil de tomographie avec visualisation des objets sans superposition (Vogel 2007).	8
Figure 1.7 Types de détonateur : (A), (D) et (E) (Hirtenberger Defence Systems (HDS) 2018), (B) et (C) (Feltane 2021).....	12
Figure 1.8 Inspection des Bagages des Voyageurs avec le Dispositif WG IS5335 (Westminster 2022).....	18
Figure 1.9 Solution Personnalisée pour Optimiser l'Efficacité de vos Points de Contrôle de Filtrage (HTDS 2019).	18
Figure 1.10 scanner de courrier électronique de bureau (Westminster 2022).	18
Figure 1.11 WG IS1818 Scanner à rayons X pour cargaisons et palettes (Westminster 2022).	19
Figure 3.1 Transformation en colonnes et en lignes.	31
Figure 3.2 (a) Image en couleur et sa décomposition en ondelette au premier niveau. Présentation des bandes (b) LL, (c) HL, (d)LH, (e) HH de la décomposition.....	34
Figure 4.1 Schéma fonctionnel d'un système de détection de détonateur d'une image à rayons X double énergie.	42
Figure 4.2 Configuration opérationnelle de la méthode post-étude d'ablation. Les sous-bandes de décomposition, HH (Haute-Haute) et HL (Haute-Basse), dans la transformation en ondelette.	43
Figure 4.3 Classe 1: Exemple d'images sans détonateur classe 0 : Exemple d'image avec détonateur (détail dans l'image) (Oulhissane et al. 2023).	44

Figure 5.1 Amélioration CLAHE de l'image radiographique originale et ses résultats pour chaque canal de couleur d'une image RVB (a) original , (b) canal rouge , (c) canal vert , (d) canal bleu , (e) image RVB. 52

Figure 5.2 Analyse par transformation en ondelettes de l'image radiographique d'origine, avec les résultats spécifiques pour les sous-bandes HH et HL, par les fonctions d'ondelettes Daubechies2 (Db2), Haar, Coiflet2 (Coif2), et Symlet2 (Sym2)..... 53

Figure 5.3 Prétraitement de l'image par CLAHE RVB suivi d'une transformation en ondelettes (sous-bandes HH et HL). 54

Figure 5.4 Performance de classification moyenne du CNN pour les images radiographiques brutes et les modèles de prétraitement suggérés. 56

Liste des notations

Lettres minuscules

<i>Notations</i>	<i>Significations</i>
<i>a</i>	<i>Paramètre de dilatation</i>
<i>a₀</i>	<i>Facteur d'échelle</i>
<i>b</i>	<i>Paramètre de translation</i>
<i>c</i>	<i>Indice de position</i>
<i>f(t)</i>	<i>Signal en fonction du temps t</i>
<i>p</i>	<i>Paramètre d'échelle (échelle de l'ondelette)</i>
<i>q</i>	<i>Paramètre de position (décalage de l'ondelette)</i>
<i>s</i>	<i>Variable réelle positive</i>
<i>t</i>	<i>Variable réelle</i>
<i>u</i>	<i>Paramètre du temps</i>

Lettres Majuscules

<i>Notations</i>	<i>Significations</i>
<i>CWT(p,q)</i>	<i>Transformée en Ondelettes Continue de f(t)</i>
<i>DWT(j,k)</i>	<i>Transformée en Ondelettes Discrètes de f(t)</i>
<i>G</i>	<i>Niveau de gris amélioré</i>
<i>G_{max}</i>	<i>Niveau de gris maximum dans l'image</i>
<i>G_{min}</i>	<i>Niveau de gris minimum dans l'image</i>
<i>N</i>	<i>Nombre total de pixels ayant un niveau de gris R_k</i>
<i>N_k</i>	<i>Séquence de nombres allant de 0 à L-1</i>
<i>P(f)</i>	<i>Fonction de distribution de probabilité</i>
<i>P(R_k)</i>	<i>Probabilité d'apparition d'un niveau de gris R_k</i>
<i>R_k</i>	<i>k-ème niveau de gris</i>

Lettres grecques

<i>Notations</i>	<i>Significations</i>
τ_0	<i>Paramètre de dilatation dans l'intégrale</i>
Ψ	<i>Fonction</i>
Ψ	<i>Fonction ondelette mère</i>
Ψ^*	<i>Conjugué complexe de l'ondelette mère Ψ</i>
$\Psi(a, b)$	<i>Ondelette mère décalée et dilatée</i>
$\Psi_{p,q}$	<i>Ondelette décalée et dilatée</i>
$(f, \Psi_{p,q})$	<i>Produit intérieur $L^2(\mathbb{R})$ intégrable de moyenne nulle</i>

Liste des abréviations

<i>Abréviation</i>	<i>Signification</i>
<i>AHE</i>	<i>Égalisation d'histogramme adaptative</i>
<i>BBHE</i>	<i>Bi-histogramme préservant la luminosité égalisation</i>
<i>BOHE</i>	<i>Égalisation d'histogramme avec chevauchement de blocs</i>
<i>BHEMHB</i>	<i>Égalisation bi-histogramme à l'aide d'histogrammes modifiés</i>
<i>Bior</i>	<i>Ondelette Biorthogonales</i>
<i>BPDHE</i>	<i>Préservation de la luminosité égalisation dynamique de l'histogramme</i>
<i>CGAU</i>	<i>Ondelette Gaussiennes complexes</i>
<i>CLAHE</i>	<i>Égalisation d'histogramme adaptative à contraste limité</i>
<i>CNN</i>	<i>Réseau de Neurones Convolutifs</i>
<i>COIF</i>	<i>Ondelette Coiflet</i>
<i>CREW</i>	<i>Compression à l'aide d'ondelettes intégrées réversibles</i>
<i>CWT</i>	<i>Transformée en ondelettes continue</i>
<i>DHE</i>	<i>Égalisation dynamique de l'histogramme</i>
<i>Db</i>	<i>Ondelette de Daubechies</i>
<i>DSIHE</i>	<i>Double histogramme de sous-image égalisation</i>
<i>DWT</i>	<i>Transformée en Ondelettes Discrètes</i>
<i>EBCOT</i>	<i>Codage par bloc intégré avec optimisation de la troncature</i>
<i>EDS</i>	<i>Systèmes de Détection d'Explosifs</i>
<i>EDSHE</i>	<i>Égalisation dynamique de sous-histogrammes basée sur l'entropie</i>
<i>EPWIC</i>	<i>Codeur d'images en ondelettes prédictives intégrées</i>
<i>ESIHE</i>	<i>Égalisation d'histogramme de sous-image basée sur l'exposition</i>
<i>EZW</i>	<i>Codage d'Ondelettes avec Arbre des Zéros Incorporé</i>
<i>Faster R-CNN</i>	<i>Réseau de Neurones Convolutifs basé sur les Régions</i>
<i>FP</i>	<i>Faux positifs</i>
<i>GAUS</i>	<i>Ondelette Gaussiennes</i>
<i>GHE</i>	<i>Globale égalisation par histogramme</i>
<i>HE</i>	<i>Égalisation d'histogramme</i>
<i>HTDS</i>	<i>Systèmes de Détection de Haute Technologie</i>
<i>IAHE</i>	<i>Égalisation d'histogramme adaptative interpolée</i>
<i>INRS</i>	<i>Institut National de Recherche et de Sécurité</i>
<i>L</i>	<i>Filtre passe-bas</i>

LHE	<i>Égalisation locale par histogramme</i>
LL	<i>Filtre passe-bas passe-bas</i>
LH	<i>Filtre passe-bas passe-haut</i>
LZW	<i>Codage zéro en couches</i>
Meyr	<i>Ondelette de Meyer</i>
MHE	<i>Égalisation par histogramme modifié</i>
MORL	<i>Ondelette de Morlet</i>
MVB	<i>Ondelette de Morlet complexe</i>
NAVEODTECHDIV	<i>Division de la technologie de neutralisation des explosifs navals</i>
NOBHE	<i>Égalisation d'histogramme sans chevauchement de blocs</i>
PBX	<i>Explosifs à liaison plastique</i>
PETN	<i>Pentaérythritol tétranitrate</i>
POSHE	<i>Égalisation d'histogramme de sous-blocs partiellement chevauchants</i>
ReLU	<i>Unité Linéaire Redressée Rectifiée</i>
RDX	<i>Hexogène</i>
RLE	<i>Codage des longueurs d'onde</i>
RSIHE	<i>Égalisation récursive d'histogramme de sous-image</i>
RSWHE	<i>Égalisation d'histogramme récursivement séparée et pondérée pour la préservation de la luminosité</i>
RVB	<i>Rouge Vert Bleu</i>
SFQ	<i>Quantification espace-fréquence</i>
Shan	<i>Ondelette de Shannon complexe</i>
SPIHT	<i>Partitionnement Spatial des Images en Arbres Hiérarchiques Transformés</i>
SPIHT	<i>Partitionnement d'Ensemble dans un Arbre Hiérarchique</i>
Sym	<i>Ondelette Symlet</i>
TNT	<i>Trinitrotoluène</i>
TOC	<i>Transformée en ondelettes continues</i>
TOD	<i>Transformée en Ondelettes Discrètes</i>
TP	<i>Vrais positifs</i>
TN	<i>Vrais négatifs</i>
VGG	<i>Groupe de Géométrie Visuelle</i>
VQ	<i>Quantification Vectorielle</i>
WTHE	<i>Égalisation par histogramme à seuil pondéré</i>
YOLO	<i>You Only Look Once</i>

Introduction générale

La sécurité aérienne demeure une préoccupation majeure dans notre société moderne. L'efficacité de la détection des substances dangereuses, telles que les explosifs primaires, les détonateurs, les explosifs secondaires tels que le TNT, le C4, le PNT, ainsi que les armes à feu, dans les bagages en soute des avions, revêt une importance cruciale pour assurer la sécurité des passagers, de l'équipage et des aéronefs. Ces substances dangereuses peuvent être utilisées à des fins terroristes ou pour la propagation de maladies, faisant ainsi peser une menace sérieuse sur la sécurité aérienne. Des événements majeurs de notre histoire, tels que les attaques du 11 septembre 2001 aux États-Unis, ont souligné la nécessité de renforcer la sécurité dans le domaine de l'aviation. Ces tragédies ont suscité une prise de conscience mondiale quant à la vulnérabilité du secteur de l'aviation face à de tels actes de terrorisme, renforçant ainsi l'importance de la sécurité aérienne.

La présente thèse se consacre à l'étude et au développement d'un système intelligent de détection des substances dangereuses en soute d'avion, visant à améliorer de manière significative la capacité de détection, tout en minimisant les faux positifs et les retards inutiles dans le traitement des bagages. Cette recherche repose sur l'utilisation de technologies de pointe telles que l'apprentissage automatique, la vision par ordinateur, ainsi que sur l'intégration de méthodes novatrices pour l'analyse des données radiographiques et la reconnaissance des objets suspects.

De plus, cette étude s'intéresse également à une approche expérimentale de la détection de détonateurs dans des images à rayons X, en utilisant des techniques de prétraitement d'image, de classification par réseau neuronal convolutif (Convolutional Neural Network - CNN), et en évaluant les résultats obtenus. Ces méthodes sont cruciales pour identifier non seulement les explosifs, mais également les détonateurs, qui jouent un rôle essentiel dans la détonation des explosifs.

Cette recherche contribuera à améliorer la sécurité aérienne en éliminant les fausses alarmes, assurant ainsi une protection efficace des passagers, de l'équipage et des aéronefs. Cette thèse est divisée en cinq chapitres distincts. Elle se structure comme suit :

Le chapitre 1 explore les techniques de détection des explosifs par rayons X, examinant diverses méthodes d'imagerie, y compris l'imagerie par rayons X classique, l'imagerie double énergie, la radiographie rétro-diffusée Compton, la tomographie et la méthode multi-énergie. Il examine également la détection des explosifs dans les images à rayons X à double énergie, détaillant les caractéristiques des explosifs et des détonateurs, ainsi que les types de détonateurs.

Le chapitre 2 présente un état de l'art sur la détection des objets dangereux dans les images à rayons X à double énergie. Il explore les techniques de détection, des méthodes traditionnelles aux réseaux de neurones convolutifs (CNN), et examine les dispositifs de contrôle à rayons X pour la détection d'objets dangereux. De plus, il résume des études pertinentes sur la détection des produits dangereux dans les images à rayons X des bagages.

Le chapitre 3 se consacre à l'analyse des images à rayons X dans les bagages, mettant en avant l'utilisation d'ondelettes pour améliorer le contraste et l'aspect des images. Il explique les concepts fondamentaux des ondelettes, y compris les transformées continues et discrètes, ainsi que les approches d'égalisation d'histogramme pour l'amélioration du contraste d'images.

Le chapitre 4 détaille les méthodes utilisées pour cette détection, y compris la création d'une base de données, les expériences menées, le prétraitement des images et la classification par réseau de neurones convolutifs.

Le chapitre 5 présente les résultats obtenus lors de l'expérimentation et engage des discussions approfondies sur ces résultats.

En conclusion de cette thèse, une synthèse générale est présentée. Elle résume les principaux résultats obtenus et ouvre la voie à des perspectives à considérer dans des travaux futurs.

*Chapitre 1. Techniques de détection des
explosifs par rayons X*

1.1. Introduction

La détection d'explosifs demeure une priorité majeure dans le domaine de la sécurité, que ce soit dans les aéroports, les centres de transit, ou les zones sensibles.

Au fil des années, les progrès technologiques et scientifiques ont considérablement amélioré les techniques de détection, permettant ainsi le développement de méthodes novatrices et sophistiquées pour repérer avec précision et fiabilité les explosifs.

De manière générale, on peut catégoriser la détection en deux types principaux : la détection "en vrac" (également appelée "bulk detection" en anglais), qui a pour objectif de repérer l'explosif dans son ensemble, et la détection de traces, qui se concentre sur la localisation de faibles quantités de résidus. La Figure 1.1 illustre les principales méthodes existantes.

Notre recherche se focalise sur la détection des détonateurs dans les bagages, colis, et sacs. Dans cette optique, notre intérêt se porte particulièrement sur les méthodes de détection "en vrac", et plus spécifiquement sur l'utilisation de la technologie d'imagerie par rayons X.

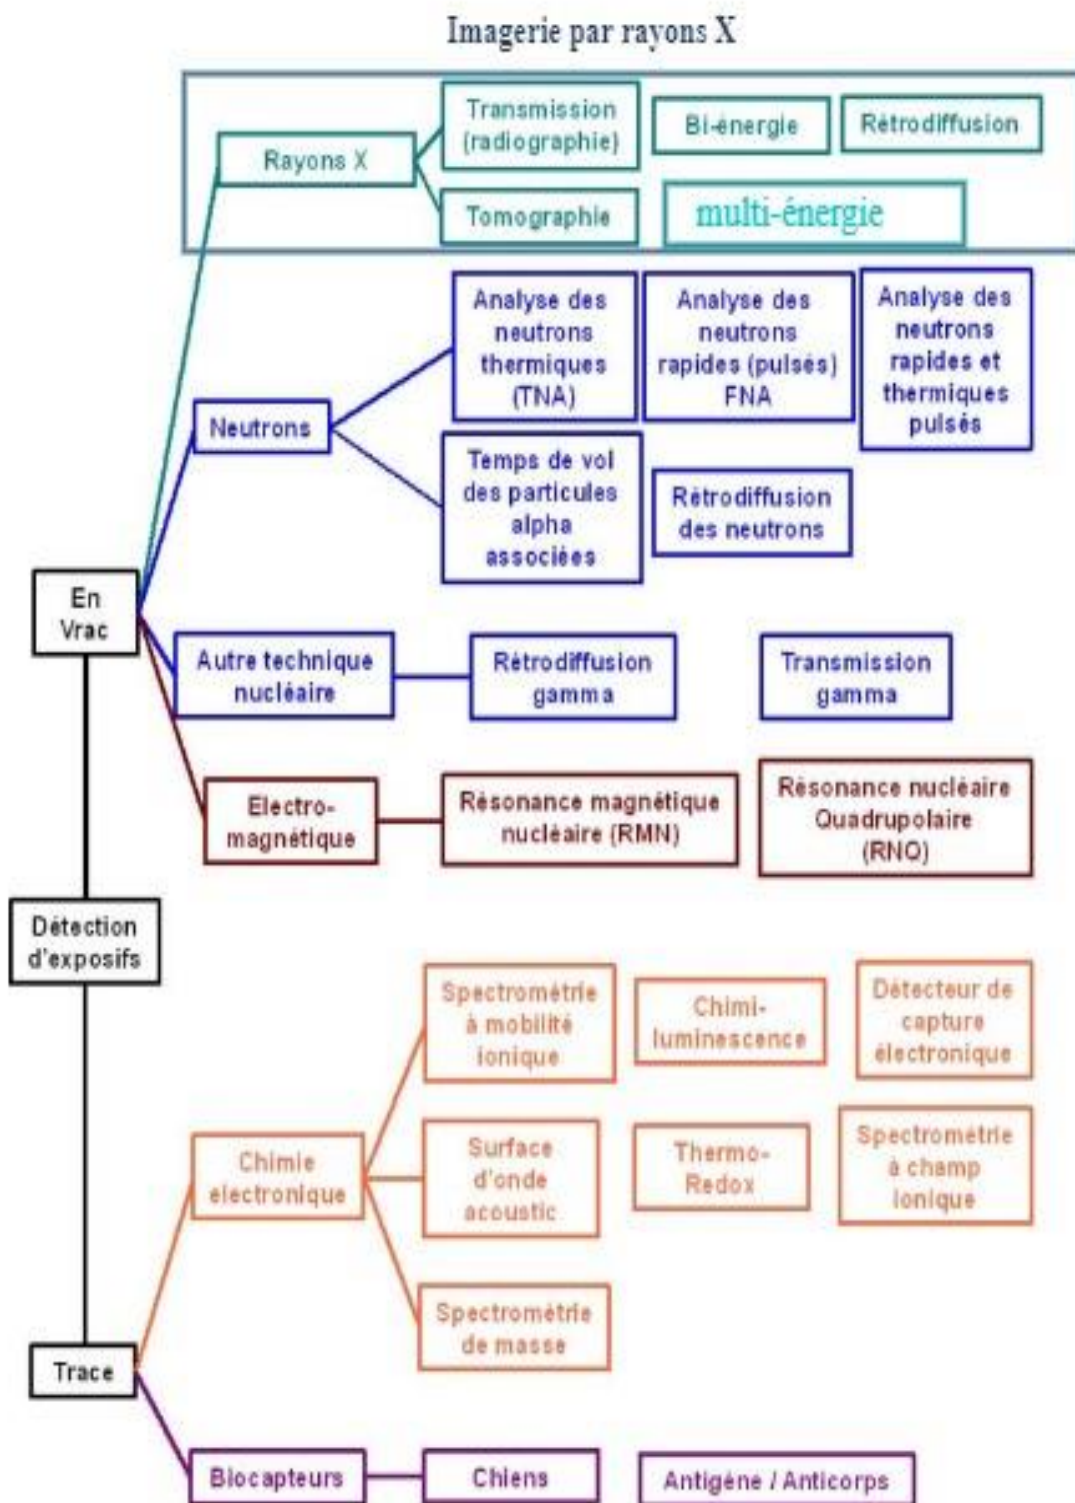


Figure 1.1 Méthodes de Détection d'Explosifs d'après la Division de Technologie de Neutralisation des Explosifs Navals (NAVEODTECHDIV) 1997).

1.2. Imagerie par rayons X

1.2.1. Techniques d'imagerie classique

La technique d'imagerie par transmission, utilisant les rayons X, est une méthode de contrôle répandue dans l'inspection des bagages. Elle offre des informations sur l'atténuation des matériaux, car ceux-ci présentent des propriétés d'absorption différentes pour les rayons X. En mesurant l'atténuation du faisceau de rayons X à travers l'objet, il devient possible de déterminer la composition des matériaux qu'il contient. Cette capacité permet de différencier les objets en fonction de leur densité et de leur composition, ce qui s'avère particulièrement utile pour la détection de substances interdites telles que les explosifs et les produits illicites (Figure 1.2).




Figure 1.2 Inspection des Bagages par Imagerie de Transmission sur un Tapis de Contrôle (à droite) avec l'Image Correspondante (à gauche).

Cette méthode offre également des détails approfondis sur la morphologie des objets. Les rayons X, en traversant les objets, laissent une empreinte de leur forme sur le détecteur, facilitant ainsi la reconstruction d'une image précise de l'objet. Cette donnée se révèle précieuse pour repérer des objets dissimulés ou identifier des formes suspectes.

1.2.2. Techniques d'imagerie double énergie

La méthode de transmission des rayons X avec deux énergies différentes offre la possibilité de classer les matériaux dans une base spécifique en exploitant leurs propriétés d'atténuation. Cette technique permet de générer des images radiographiques d'objets avec une

représentation en fausses couleurs des éléments recherchés, facilitant ainsi la détection et l'identification des matériaux d'intérêt, tels que les éléments légers ($Z < 10$), intermédiaires ($10 < Z < 20$), et lourds ($20 < Z$) (Eilbert 1992).

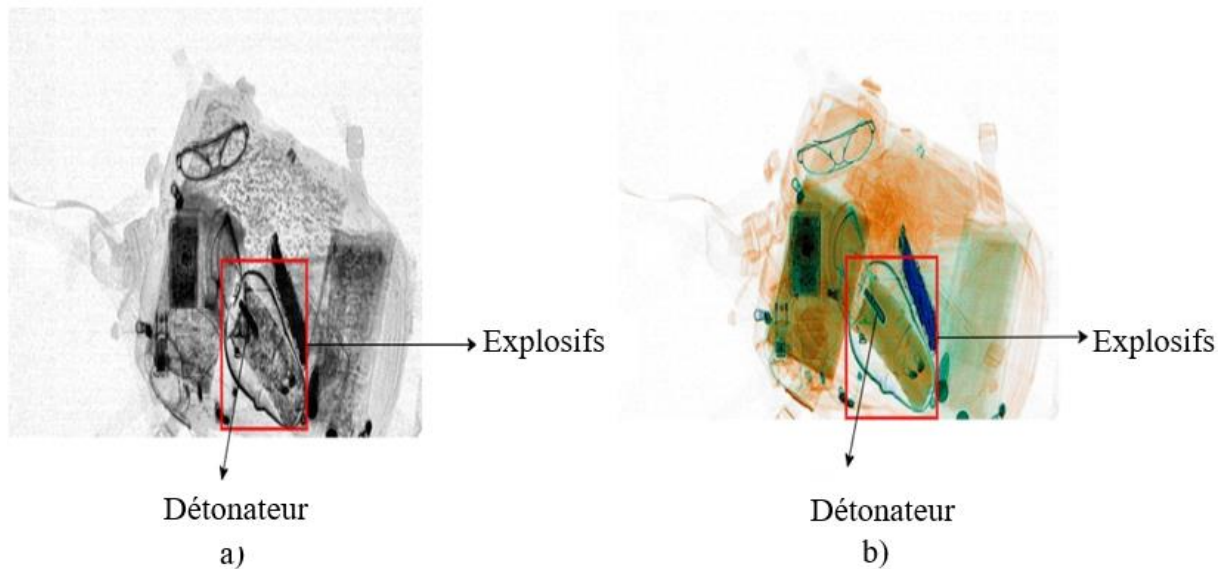


Figure 1.3 Image par transmission : a) classique, b) double énergie.

Une approche alternative consiste à utiliser des détecteurs à double couche pour mettre en œuvre cette technique. Ces détecteurs se composent de deux couches de matériaux distincts, comme décrit par Carmi en 2005. La première couche est conçue pour absorber les photons de basse énergie, tandis qu'un filtre séparateur permet à la seconde couche d'absorber simultanément les photons de haute énergie. De nombreux systèmes de détection d'explosifs (EDS - Explosives Detection Systems) emploient cette technique d'imagerie X à double énergie avec des détecteurs à double couche.

Cependant, il est important de noter que cette technique présente certaines limitations. Elle ne permet pas d'obtenir une composition chimique précise des objets inspectés. De plus, des ambiguïtés de détection persistent avec les matériaux organiques couramment utilisés, car leur numéro atomique (Z) peut être similaire à celui des explosifs. En conséquence, le taux de fausses alarmes demeure élevé lors de l'utilisation de cette technique.

Afin de réduire le taux de fausses alarmes et d'améliorer la fiabilité de cette méthode, il est impératif de prendre en considération les limitations inhérentes à l'accès à la composition chimique et aux ambiguïtés de détection. Des recherches supplémentaires sont nécessaires pour développer des solutions de détection d'explosifs plus avancées et précises.

1.2.3. Technique d'imagerie rayonnement rétro-diffusé Compton

Cette technique exploite le rayonnement rétrodiffusé, en particulier le rayonnement diffusé Compton, afin de révéler de manière plus précise les matériaux ayant de faibles valeurs de Z et de faibles densités. Elle vient compléter efficacement la technique par transmission, qui peut être impactée par la superposition de métaux. Un avantage notable de la technique de rétrodiffusion réside dans le positionnement du système de mesure du même côté de l'objet que la source, permettant ainsi son utilisation dans des conditions d'acquisition contraignantes. Deux exemples d'application sont les suivants :

Exemple 1 : Elle peut être employée dans des scans corporels à faible dose pour détecter des armes dissimulées sous les vêtements (Arodzero et al. 2021) ou pour le contrôle de bagages abandonnés contre un mur (Lalleman et al. 2011).




Figure 1.4 Capture simultanée d'une valise à l'aide de deux techniques : a) Imagerie par Rayons X en Transmission, b) Imagerie par Rayons X en Rétrodiffusion.

Exemple 2 : La technique de rétrodiffusion peut être appliquée dans des conditions d'acquisition complexes, comme un scan humain à faible dose, pour repérer un détonateur à l'intérieur d'une bouteille en plastique. De plus, un autre scan humain avec une double dose pourrait être réalisé pour détecter la présence d'un individu portant un détonateur.

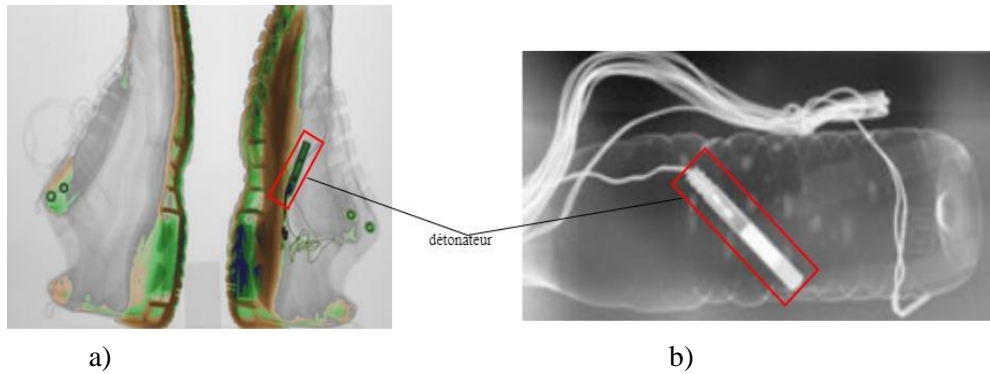


Figure 1.5 Imagerie par double énergie (a), imagerie par rayons X en rétrodiffusion (b).

1.2.4. Technique d'imagerie tomographique

La méthode implique la reconstruction du volume d'un objet en effectuant une série de mesures pendant la rotation de l'objet sur 360 degrés (Figure 1.6). La transmission des rayons X est mesurée dans le plan défini par la source et une rangée de pixels du détecteur. Chaque pixel du détecteur enregistre une valeur représentant le pouvoir d'atténuation μ intégré le long de la ligne de matière traversée. Ces mesures sont obtenues sous différentes incidences et sont ensuite utilisées pour reconstruire mathématiquement l'objet examiné. Plus précisément, le volume reconstruit attribue à chaque voxel un paramètre correspondant au coefficient d'atténuation local. Il est important de noter que ce coefficient d'atténuation est une moyenne sur le spectre polychromatique utilisé.



Figure 1.6 Appareil de tomographie avec visualisation des objets sans superposition (Vogel 2007).

Cette approche offre une solution au problème de superposition des matériaux. Néanmoins, ses capacités demeurent restreintes lorsqu'il s'agit de distinguer les explosifs des matériaux ordinaires qui affichent des pouvoirs d'atténuation similaires (Zentai 2008). De plus, en raison de son coût élevé et de sa lenteur par rapport à d'autres options disponibles sur le marché, cette technique est peu couramment utilisée pour la détection d'explosifs.

1.2.5. Méthode multi-énergie

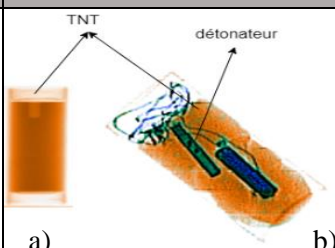
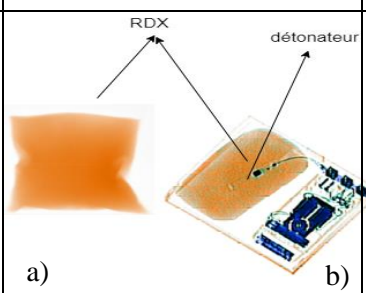
Grâce aux avancées récentes des détecteurs spectroscopiques en CdTe/CdZnTe, il est maintenant possible de mesurer des spectres en énergie, offrant ainsi la possibilité d'obtenir des informations sur une multitude d'énergies plutôt que de se limiter à des valeurs d'atténuation pour seulement deux énergies. Une méthode connue sous le nom de méthode multi-énergies par transmission a été élaborée, initialement pour le contrôle des bagages sur des systèmes à plusieurs tirs (BELDJOUDI 2011).

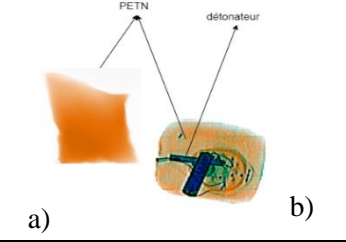
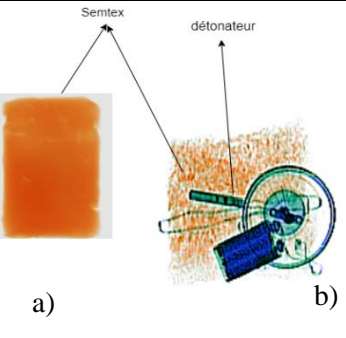
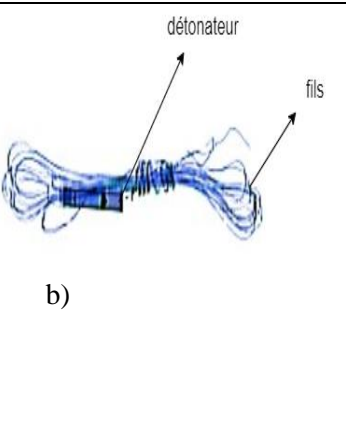
Cette méthode implique une estimation de la fonction de transmission d'un objet constitué d'un seul matériau inconnu, à partir de mesures spectrométriques, suivie d'une analyse de cette fonction (Beldjoudi et al. 2012). Pour ce faire, des mesures de calibrage sont réalisées afin d'apprendre les réponses du capteur spectrométrique en fonction de l'énergie des photons incidents. Ensuite, des algorithmes de traitement du signal spectrométrique sont appliqués pour extraire deux coefficients caractérisant le matériau et l'épaisseur de l'objet à partir de sa fonction de transmission.

1.3. Détection des explosifs dans les images à rayons X à double énergie

1.3.1. Caractéristiques des explosifs et des détonateurs

Tableau 1.1 Synthèse des Caractéristiques Distinctifs des Explosifs et des Détonateurs dans une Image à Rayons X.

Explosifs	Caractéristiques dans une image à rayons X	Image à rayons x	Référence
TNT (trinitrotolu-ène)	Se présente comme un matériau dense et compact, identifiable par une couleur distinctive dans l'image radiographique. Peut également révéler la présence de fils de détonateur connectés.		(Nicoloso 2014)
RDX (hexogène)	Apparaît généralement sous forme de cristaux ou de poudre extrêmement dense dans l'image radiographique. Les fils de détonateur peuvent également être discernés.		(Glavier et al. 2017)

<p>PETN (pentaérythritol tétranitrate)</p>	<p>Apparaît comme une poudre dense et compacte dans l'image à rayons X. Les fils de détonateur peuvent également être détectés.</p>		<p>(Martin 2017)</p>
<p>Semtex</p>	<p>Semtex est un type spécifique d'explosif qui contient généralement du RDX et du PETN. Il peut apparaître comme une masse dense avec des fils de détonateur dans l'image à rayons X.</p>		<p>(Ewing et al. 2013; Elbeih 2015)</p>
<p>Détonateurs</p>	<p>Les détonateurs apparaissent généralement comme des objets cylindriques denses avec des fils métalliques visibles dans l'image à rayons X. Les détonateurs sont souvent utilisés pour amorcer les explosifs et peuvent être détectés lors de l'inspection des bagages.</p>		<p>(Basebi & Thomas 2003)</p>

a) (Howell 2020), b)(High Tech Detection Systems 2023)

1.3.2. Types de détonateur

Il existe cinq types de détonateur (Figure 1.7) :

1.3.2.1. Détonateur électrique

Un détonateur électrique est un dispositif qui utilise un courant électrique pour initier une réaction explosive. Il se compose d'un élément de déclenchement électrique, souvent une capsule ou une ampoule contenant une substance réactive à l'électricité, associé à une charge explosive. Lorsqu'un courant électrique est appliqué à l'élément de déclenchement, il engendre une décharge électrique qui déclenche la réaction explosive de la charge principale (Ben-Hur & Weston 2010; Glavier 2017).

1.3.2.2. Détonateur non électrique

Un détonateur non électrique, également désigné sous le nom de détonateur mécanique ou détonateur à friction, fait appel à un mécanisme physique pour enclencher la

réaction explosive. Il peut comprendre des composants tels qu'un percuteur, une tige à friction ou un dispositif de choc. Lorsque le mécanisme est activé, généralement par un impact ou une force externe, il génère suffisamment de chaleur, de friction ou de pression pour amorcer la détonation de la charge explosive (Taton 2013).

1.3.2.3. Détonateur à retardement

Un détonateur à retardement est spécialement conçu pour introduire un laps de temps entre l'activation du détonateur et la détonation de la charge explosive. Il permet de programmer de manière précise le moment de l'explosion. Ces détonateurs à retardement sont fréquemment employés dans des domaines tels que la démolition contrôlée, les travaux de génie civil, l'exploitation minière, ainsi que dans des dispositifs pyrotechniques tels que les feux d'artifice. Ils sont configurés pour retarder la réaction explosive en utilisant divers mécanismes tels que des fils fusibles, des produits chimiques retardateurs, ou des systèmes électroniques programmables (Mishra et al. 2012).

1.3.2.4. Détonateur séquentiel

Un détonateur séquentiel est employé pour amorcer de manière séquentielle et coordonnée une série de charges explosives. Il permet de déclencher une séquence précise d'explosions avec des intervalles de temps préétablis. Ces détonateurs séquentiels sont fréquemment utilisés dans des carrières, des mines et d'autres opérations nécessitant des détonations contrôlées selon une séquence spécifique, dans un souci de sécurité ou d'efficacité. Leur conception vise à garantir une détonation ordonnée et sécurisée de plusieurs charges, réduisant ainsi les risques de réactions en chaîne non maîtrisées (Feltane 2021).

1.3.2.5. Détonateur à tube choc

Un détonateur à tube choc, également désigné sous le nom de détonateur à choc direct, est un type de détonateur employé lorsque la réaction explosive doit être amorcée par un impact direct. Il utilise un mécanisme de choc, généralement une tige en métal, pour transmettre une force d'impact à une charge explosive. Les détonateurs à tube choc sont fréquemment utilisés dans des applications militaires, notamment dans les munitions et les explosifs militaires, où une activation rapide et fiable est essentielle. Ils sont spécialement conçus pour résister à des conditions environnementales difficiles et à des forces d'impact élevées (Feltane 2021).

Il est important de noter que l'utilisation des détonateurs est réglementée et soumise à des protocoles stricts pour assurer la sécurité lors de leur manipulation et de leur utilisation.

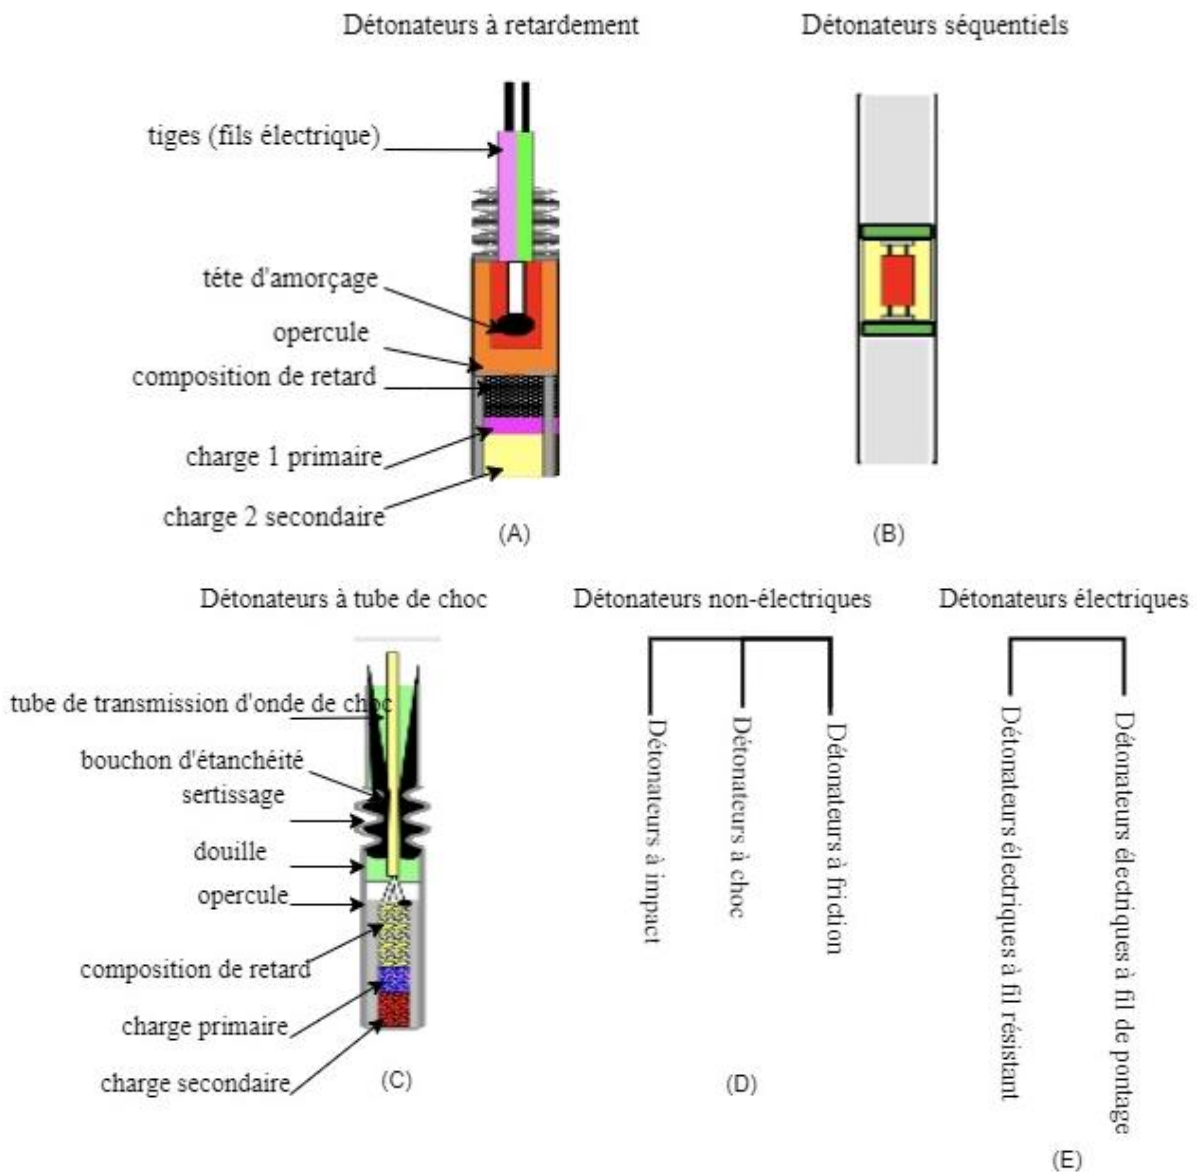


Figure 1.7 Types de détonateur : (A), (D) et (E) (Hirtenberger Defence Systems (HDS) 2018), (B) et (C) (Feltane 2021).

1.4. Techniques d'optimisation de la détection des explosifs

1.4.1. Prétraitement des images

Le prétraitement des images revêt une importance cruciale dans l'amélioration de la détection des explosifs et des détonateurs dans les images. Voici quelques techniques fréquemment employées pour améliorer la qualité des images et accroître l'efficacité de la détection :

1.4.1.1. Amélioration de la netteté

L'accentuation des contours et la réduction du flou peuvent rendre les objets explosifs et les détonateurs plus discernables. On peut appliquer des filtres de renforcement, tels que le filtre de Laplace ou le filtre de Sobel.

1.4.1.2. Filtrage du bruit

La suppression du bruit de l'image est cruciale pour prévenir les fausses détections. Des méthodes telles que la réduction de bruit par filtrage médian et l'utilisation du filtre gaussien sont adoptées en raison de la procédure de flou, particulièrement lorsque les bords des images des matériaux se chevauchent (Dmitruk et al. 2017).

1.4.1.3. Égalisation de l'histogramme

Cette méthode peut être employée pour élargir la plage dynamique des niveaux de gris dans l'image, ce qui contribue à améliorer la visibilité des détails cruciaux (Zhou et al. 2010).

1.4.1.4. Normalisation des couleurs

En cas de prises d'images dans des conditions d'éclairage variables, il peut être nécessaire de normaliser les couleurs afin d'assurer une apparence cohérente des objets explosifs et des détonateurs.

1.4.1.5. Segmentation

La segmentation d'image, par le biais d'une approche de segmentation automatique, permet de partitionner une image en zones ou éléments pertinents, facilitant ainsi l'isolation des explosifs et des détonateurs du reste de l'image (Grady et al. 2012).

1.4.1.6. Filtrage adaptatif

Les techniques de filtrage adaptatif ajustent les paramètres du filtre en fonction des caractéristiques locales de l'image, améliorant ainsi la détection des objets. L'utilisation du filtre de Gabor a été démontrée comme une méthode supplémentaire pour accroître la détection des objets en améliorant le contraste (Amir Movafeghi et al. 2020).

1.4.1.7. Amélioration du contraste

L'augmentation du contraste peut rendre les objets explosifs et les détonateurs plus visibles. Cette amélioration peut être obtenue grâce à des techniques telles que l'amélioration de contraste local, l'amélioration de contraste global et la correction gamma (Guan et al. 2009).

1.4.1.8. Suppression des ombres et des reflets

L'élimination des ombres et des reflets, susceptibles de perturber la détection, peut être réalisée grâce à des algorithmes dédiés. Une fois l'image prétraitée, différentes techniques de détection d'objets peuvent être appliquées pour identifier les explosifs et les détonateurs. Les réseaux de neurones convolutionnels (CNN), tels que YOLO (You Only Look Once) et Faster R-CNN (Region-based Convolutional Neural Network) (Ren et al. 2017). sont fréquemment utilisés pour cette tâche. Ces réseaux sont entraînés sur des ensembles de données contenant des exemples d'explosifs et de détonateurs afin d'apprendre à les reconnaître.

En résumé, le prétraitement des images représente une étape cruciale pour améliorer la détection des explosifs et des détonateurs. Ces techniques de prétraitement contribuent à améliorer la qualité des images, facilitant ainsi la tâche des algorithmes de détection d'objets. Une fois les images prétraitées, des méthodes de détection d'objets appropriées peuvent être employées pour identifier ces objets dangereux dans les images.

1.4.2. Algorithme de détection des explosifs

La détection des explosifs dans les images peut être effectuée en utilisant des techniques de vision par ordinateur et des réseaux de neurones convolutionnels (CNN) spécifiquement entraînés à cette fin. Voici une vue d'ensemble générale de l'algorithme de détection pour cette application :

1.4.2.1. Collecte de données et annotation

Constituez un ensemble d'images comprenant des explosifs. Il est essentiel d'annoter ces images en identifiant avec précision la position de chaque explosif. Cette tâche d'étiquetage a été réalisée manuellement par Reagan Leoncio Galvez et Elmer Pamisa Dadios en 2022 en utilisant un logiciel de marquage d'images.(Reagan Leoncio Galvez & Elmer Pamisa Dadios 2022).

1.4.2.2. Prétraitement des images

Appliquez les techniques de prétraitement d'images évoquées précédemment afin d'améliorer la qualité des images, éliminer le bruit et accentuer le contraste.

1.4.2.3. Entraînement du modèle CNN

Employez un modèle CNN pré-entraîné, tel qu'une version de ResNet, VGG, YOLO ou Faster R-CNN, et ajustez-le pour la détection d'explosifs. Vous avez la possibilité de

peaufiner le modèle sur vos données existantes ou de l'entraîner à partir de zéro, pour autant que vous disposiez d'un volume de données adéquat (Gaus et al. 2019).

1.4.2.4. Validation du modèle

Divisez vos données en ensembles d'entraînement, de validation et de test. Utilisez l'ensemble de validation pour ajuster les hyperparamètres et évaluer la performance du modèle au fur et à mesure. L'ensemble de test sera ensuite employé pour évaluer la performance finale du modèle (Mery et al. 2016).

1.4.2.5. Détection en temps réel

Une fois qu'une nouvelle image est acquise, appliquez le modèle CNN entraîné pour détecter les explosifs. Les zones de l'image contenant ces objets seront alors identifiées (Sun et al. 2022).

1.4.2.6. Post-traitement

Effectuez un post-traitement des résultats de détection si nécessaire. Par exemple, filtrez les détections en fonction de leur score de confiance, fusionnez les détections similaires ou éliminez les faux positifs. Pour plus d'informations à ce sujet, veuillez consulter l'étude (Fawcett 2006).

1.4.2.7. Notification ou intervention humaine

Après la détection d'explosifs, vous pouvez déclencher des actions telles qu'une notification à un opérateur humain pour vérification, ou activer un système d'alarme.

1.4.2.8. Mise à jour continue

La mise à jour régulière des modèles de détection d'explosifs est cruciale pour maintenir leur performance. La collecte continue de données et l'entraînement du modèle avec de nouvelles informations sont essentielles. La qualité et la quantité des données d'entraînement jouent un rôle clé dans le succès de cet algorithme. Des données variées et représentatives contribuent à améliorer les performances du modèle. La sécurité est une priorité majeure, nécessitant des procédures de validation et de tests rigoureuses en raison de l'importance critique de la détection d'explosifs.

1.4.3. Limitations et défis de la détection des explosifs dans les images à rayons X à double énergie

La détection d'explosifs dans les images à rayons X à double énergie est une entreprise complexe, confrontée à divers défis et limitations. Voici quelques-uns des principaux obstacles liés à cette technique :

1.4.3.1. Faible contraste

Les explosifs peuvent présenter une faible densité par rapport aux matériaux environnants, rendant ainsi leur détection ardue dans les images à rayons X. Le contraste entre ces objets et le fond de l'image peut être considérablement réduit.

1.4.3.2. Taille et forme variables

Les explosifs peuvent se présenter sous diverses tailles et formes, ce qui rend complexe la conception d'un modèle de détection unique adapté à toutes les situations.

1.4.3.3. Épaisseur des matériaux

La détection des explosifs peut être entravée par l'épaisseur et le type des matériaux environnants. Plus ces matériaux sont épais et denses, plus il devient difficile de détecter les explosifs.

1.4.3.4. Composés chimiques variés

Les explosifs sont constitués de divers composés chimiques, chacun présentant des propriétés de diffusion de rayons X distinctes. Il peut être complexe de détecter de manière efficace tous les types d'explosifs.

1.4.3.5. Effets de superposition

Dans les images à rayons X, la superposition de plusieurs objets peut compliquer la distinction entre eux, pouvant entraîner des fausses détections ou des erreurs de localisation.

1.4.3.6. Dose de rayonnement

L'utilisation de rayons X expose aux radiations ionisantes, pouvant être nocive pour la santé humaine. Il est impératif de maintenir la dose de rayonnement à un niveau sécuritaire pour les opérateurs et les personnes à proximité.

1.4.3.7. Complexité matérielle

La mise en place et l'entretien des systèmes de rayons X à double énergie sont souvent coûteux et complexes, exigeant une expertise technique pour leur utilisation et leur maintenance.

1.4.3.8. Intégrité de l'objet

Détecter des explosifs dans des bagages ou des colis doit être réalisé sans causer de dommages aux objets, ajoutant ainsi une contrainte supplémentaire à la technique.

1.4.3.9. Évolution des menaces

Les terroristes et les contrebandiers s'adaptent constamment pour échapper à la détection, nécessitant ainsi une évolution constante des méthodes de détection pour maintenir leur efficacité. Pour relever ces défis, les chercheurs et les ingénieurs travaillent sans relâche pour améliorer les techniques de détection des explosifs dans les images à rayons X à double énergie. Cela englobe le développement d'algorithmes de traitement d'image plus performants, de modèles de détection avancés, ainsi que l'exploration de nouvelles technologies de détection et de rayonnement. De plus, le strict respect des protocoles de sécurité est essentiel pour minimiser les risques pour la santé humaine lors de l'utilisation de rayons X.

1.5. Machines de détection des explosifs basées sur les rayons X

Les machines de détection basées sur les rayons X sont des dispositifs qui utilisent cette forme de rayonnement pour inspecter et identifier des objets, substances ou matériaux à l'intérieur de conteneurs, bagages, véhicules, ou d'autres objets. Elles sont largement utilisées dans des domaines tels que la sécurité, le contrôle des frontières, le contrôle de la qualité industrielle, la médecine, l'archéologie, et bien d'autres. Voici quelques types courants de ces machines de détection basées sur les rayons X :

1.5.1. Scanners à rayons X pour bagages

Ces machines sont déployées dans les aéroports, les gares, et les centres de transport pour inspecter les bagages des voyageurs. Leur fonction consiste à détecter des objets interdits ou dangereux, tels que des armes ou des explosifs, à l'intérieur des bagages.



Figure 1.8 Inspection des Bagages des Voyageurs avec le Dispositif WG IS5335 (Westminster 2022).

1.5.2. Scanners à rayons X pour colis et courrier

Ces machines sont employées pour examiner les colis, les lettres et les paquets postaux en quête de contenus illicites ou dangereux. Elles trouvent fréquemment leur utilité dans les services postaux, les bureaux gouvernementaux et les entreprises de livraison.



Figure 1.9 Solution Personnalisée pour Optimiser l'Efficacité de vos Points de Contrôle de Filtrage (HTDS 2019).



Figure 1.10 scanner de courrier électronique de bureau (Westminster 2022).

1.5.3. Scanners à rayons X pour la sécurité des frontières

Ces machines sont déployées aux points de contrôle des frontières et des douanes afin d'examiner les véhicules, les camions et les cargaisons à la recherche de contrebande, d'armes, de drogues ou d'autres marchandises illégales.



Figure 1.11 WG IS1818 Scanner à rayons X pour cargaisons et palettes (Westminster 2022).

1.6. Conclusion

En conclusion, ce chapitre nous a plongés dans les subtilités des techniques de détection des explosifs par rayons X, mettant en lumière l'imagerie à double énergie et les machines de détection basées sur les rayons X. Nous avons exploré diverses méthodes d'imagerie, des approches classiques à la rétrodiffusion Compton, en passant par la tomographie et la méthode multi-énergie. En outre, nous avons examiné de près la détection des explosifs dans les images à rayons X à double énergie, explorant les caractéristiques distinctives des explosifs et des détonateurs, ainsi que les techniques d'optimisation pour accroître la précision de la détection.

La détection des explosifs par rayons X demeure un domaine dynamique, où la recherche continue et l'innovation technologique sont cruciales pour renforcer la sécurité et surmonter les défis liés à la détection d'objets potentiellement dangereux. Ce chapitre pose les fondations pour appréhender ces technologies, ouvrant la voie à des développements futurs visant à améliorer la précision et l'efficacité de la détection des explosifs par rayons X.

***Chapitre 2. État de l'art sur la détection
des objets dangereux dans les
images à rayons X à double énergie***

2.1. Introduction

La sécurité de l'aviation civile est confrontée à des enjeux cruciaux, notamment la détection efficace d'objets dangereux tels que les explosifs, les armes à feu et autres articles prohibés dans les bagages en soute des avions. Face aux menaces terroristes croissantes et à la nécessité de prévenir la propagation de parasites et de maladies, la sécurité aérienne demeure une préoccupation constante.

La détection d'objets dangereux dans les images radiographiques des bagages en soute est devenue essentielle pour assurer la sécurité des passagers, de l'équipage et des aéronefs. Cependant, cette tâche est confrontée à des défis tels que la faible prévalence des cibles, la variabilité de la visibilité des objets, la superposition, le faible contraste et le risque de fausses alarmes. Les agents de sécurité sont confrontés à une tâche exigeante nécessitant concentration et résistance à la fatigue de l'attention.

Dans ce contexte, l'utilisation de la technologie des rayons X à double énergie apparaît comme une solution prometteuse pour améliorer la détection d'objets dans les bagages. Cette revue de l'état de l'art examinera les avancées majeures, explorant les techniques, algorithmes et technologies développés pour relever ces défis et renforcer la sécurité aérienne. Elle passera en revue les approches classiques, les méthodes d'apprentissage automatique, les techniques d'optimisation et les systèmes de détection innovants utilisant des images à double énergie. L'objectif est de fournir un aperçu complet des progrès réalisés dans la détection d'objets dans les images radiographiques des bagages en soute, mettant en évidence les méthodes prometteuses et les domaines nécessitant davantage de recherche et de développement.

2.2. Approches de Détection d'Objets Dangereux dans les Images à Rayons X des Bagages

Dans les écrits, diverses méthodes de détection d'objets lors de l'inspection des bagages par rayons X sont répertoriées et peuvent être regroupées en deux catégories :

2.2.1. Méthodes traditionnelles

Ce sont des méthodes traditionnelles d'apprentissage automatique qui reposent sur un schéma de représentation des caractéristiques appelé sac de mots visuels (BoVW - Bag-of-Visual-Words). Ces approches utilisent divers classificateurs, notamment :

- Les machines à vecteurs de support SVM (Ben-Hur & Weston 2010),

- Les plus proches voisins K-Nearest Neighbor K-NN (Wu et al. 2008),
- La régression linéaire LR (Larsen et al. 2000),
- Les arbres de décision DT (Wu et al. 2008; Haq et al. 2018).

2.2.2. Réseaux de neurones convolutifs (Convolutional Neural Network ou CNN)

Ces dernières années, les CNN profonds ont fait d'énormes progrès dans la détection d'objets. Les méthodes actuelles peuvent être divisées en deux groupes :

2.2.2.1. Méthodes à deux étapes

Ces approches opèrent la détection en deux étapes distinctes : la première génère un ensemble de propositions de régions candidates, tandis que la seconde les classe dans la catégorie d'objet cible. Parmi ces méthodes, on trouve R-CNN (Girshick et al. 2016), R-CNN rapide (Girshick et al. 2016), R-CNN plus rapide (Ren et al. 2017), R-FCN (Dai et al. 2016), R-FCN (Redmon et al. 2016) et FPN (Lin et al. 2017). Actuellement, les méthodes à deux étapes démontrent la plus grande précision parmi les approches de détection d'objets.

2.2.2.2. Méthodes à une seule étape

Ces approches se basent sur l'utilisation d'un unique réseau convolutif de type feed-forward pour prédire directement les classes et les boîtes englobantes, comme illustré par des modèles tels que YOLOv3 (Chouai et al. 2020), YOLOv4 (Liu et al. 2022), YOLOv5 (Zhang et al. 2022), YOLOv5 (Tao et al. 2021), YOLOv5 (Chatterjee et al. 2022) et SSD (Liu et al. 2016).

Bien que ces approches se distinguent par leur rapidité, il est important de noter que leur précision est généralement inférieure à celle des méthodes à deux étapes. Des études, telles que celle menée par (Akçay et al. 2016), ont démontré que les méthodes basées sur les CNN surpassent en performance les approches traditionnelles BoVW.

Des études ont été menées sur la détonation d'engins explosifs secondaires tels que le C4, le PNT, et d'autres, comme l'ont souligné (Evans 2005; Tringe et al. 2020). Cependant, peu de travaux se sont concentrés spécifiquement sur la détection des détonateurs dans les images à rayons X lors de l'inspection des bagages. Notamment, (Pincu & Kleinberger-Riedrich 2012) ont exploité la méthode à double énergie pour détecter des objets menaçants tels que les détonateurs, en séparant les matériaux organiques des inorganiques. D'autre part, (Gupta et al. 2019) ont élaboré un ensemble d'algorithmes visant à améliorer la performance de détection des détonateurs en optimisant la qualité de l'image. Dans une approche

différente, (Liu et al. 2022) ont tenté de repérer les détonateurs en utilisant des filtres de Gabor et la transformée de Hough. Leur méthode consistait à fusionner les informations extraites tout en tenant compte de la taille et de l'orientation du détonateur dans l'image.

2.3. Dispositifs de contrôle à rayons X pour la détection d'objets dangereux dans les bagages

Les systèmes de contrôle à rayons X sont essentiels pour détecter d'éventuels objets dangereux dans les bagages en soute d'avions. Les performances de ces dispositifs dépendent de caractéristiques physiques et techniques cruciales. En utilisant des rayons X à double énergie, ces systèmes fournissent des images radiographiques 2D et 3D des bagages. Les images 2D sont efficaces pour détecter des objets plats, tandis que les images 3D sont adaptées pour la détection d'objets volumineux. Ces dispositifs sont équipés de détecteurs de rayons X, de générateurs de rayons X, de systèmes de traitement d'images et de logiciels de détection d'objets dangereux. Les capacités de détection dépendent de la qualité des images radiographiques, des technologies d'affichage et des algorithmes de détection employés.

Par exemple, une étude a été conduite pour évaluer l'efficacité des opérateurs dans la détection des détonateurs de bombes en utilisant l'imagerie 2D et 3D (Hattenschwiler et al. 2019). Une autre recherche a introduit une méthode à double énergie visant à repérer des objets dangereux, dont des détonateurs, en distinguant entre les matériaux organiques et inorganiques (Pincu & Kleinberger-Riedrich 2012). Les réseaux neuronaux convolutifs (CNN) ont également gagné en popularité dans le domaine de l'analyse d'images aux rayons X pour le dépistage des bagages (Hattenschwiler et al. 2019).

2.4. Etudes sur la détection de substances dangereuses dans les images à rayons X des bagages

2.4.1. Méthodes à double énergie pour identifier les objets dangereux incluant les détonateurs

La détection des détonateurs dans les images à rayons X des bagages représente un défi crucial pour la sécurité aérienne. Les détonateurs, en tant que composants essentiels à l'initiation des explosifs, deviennent particulièrement dangereux lorsqu'ils sont transportés illégalement. Cette section examinera les progrès réalisés dans les méthodes de détection des détonateurs, mettant spécifiquement l'accent sur l'utilisation de l'imagerie à double énergie. Les dispositifs à double énergie offrent une meilleure distinction entre les matériaux,

améliorant ainsi la détection d'objets potentiellement dangereux tels que les détonateurs. Nous explorerons les techniques, algorithmes et systèmes développés pour repérer ces composants critiques, contribuant ainsi à renforcer la sécurité aérienne.

2.4.2. Évaluation de la performance opérationnelle dans la détection d'objets dangereux par imagerie 2D et 3D

L'évaluation de la performance des opérateurs de sécurité revêt une importance cruciale dans la détection des objets dangereux dans les images à rayons X. Cette partie de la revue se concentrera sur les études visant à évaluer la capacité des opérateurs à repérer les détonateurs de bombes dans les images 2D et 3D des bagages. Il est impératif de comprendre comment les agents de sécurité interagissent avec les images radiographiques et d'identifier les facteurs qui influent sur leur performance. Ces études fourniront des informations précieuses pour améliorer les méthodes de formation et optimiser les processus de détection des objets dangereux.

2.4.3. Optimisation des images d'objets dangereux par ondelettes avant leur intégration dans une architecture CNN profonde

Ces dernières années, le traitement des images à rayons X en utilisant la transformée en ondelettes combinée avec des CNN profonds a connu d'importants progrès dans le domaine de la santé. Plusieurs chercheurs se sont intéressés à la détection des maladies. (Kang et al. 2017) ont proposé un algorithme qui utilise un réseau CNN profond appliqué aux coefficients de la transformée en ondelettes. Le but est de supprimer efficacement les motifs de bruit complexes des images de tomodensitométrie dérivées d'une réduction de la dose de rayons X. (Verma et al. 2021) ont utilisé une architecture CNN basée sur les ondelettes pour détecter le SARS-nCoV. Ils ont appliqué les fonctions mères: Haar, Daubechies, Symlet, Biorthogonal, Coiflet et Discrete Meyer à deux niveaux (DWT) (Chui 1992). Ils ont trouvé une précision, un taux de rappel et un coefficient de similarité pour les instances à quatre classes (COVID-19, Bactérien PNA, viral PNA et Normal) respectivement de 98%, 98% et 99%. (Yasar & Ceylan 2021) ont travaillé sur les images radiographiques à deux classes COVID-19 et non COVID-19. Ils ont appliqué la méthode de la transformée en ondelettes complexes à double arbre (DT-CWT) sur les images susmentionnées.

Les transformées en ondelettes sont une technique d'analyse d'image puissante, utilisée dans divers domaines, y compris la détection d'objets dangereux. Cette section explorera comment les ondelettes peuvent être mises à profit pour la détection des détonateurs dans les

images à rayons X des bagages. Les ondelettes permettent de réduire le bruit, d'améliorer le contraste et de mettre en évidence les caractéristiques cruciales des objets dangereux, les rendant ainsi plus facilement détectables. Nous examinerons les méthodes et les approches qui ont été développées pour intégrer les ondelettes dans les systèmes de sécurité aérienne, contribuant ainsi à une meilleure détection des objets dangereux.

2.4.4. Amélioration des radiographies à rayons X par CLAHE avant leur intégration dans une architecture CNN profonde

Rahman (Rahman et al. 2021) ont examiné cinq méthodes d'amélioration d'image pour les radiographies pulmonaires (CXR) : égalisation d'histogramme (HE), égalisation d'histogramme adaptative limitée par le contraste (CLAHE), complément d'image, technique d'amélioration du contraste d'équilibre (BCET) et correction gamma. Leur étude a révélé que la correction gamma s'est avérée plus performante que les autres techniques pour détecter la COVID-19 à partir d'images CXR de poumons simples et segmentées. De plus, ils ont introduit un nouveau modèle UNet qui a montré des scores de précision, d'intersection sur l'union (IoU) et de coefficient de Dice respectivement de 98,63%, 94,3%, et 96,94% pour la segmentation des poumons. Les auteurs ont également évalué six réseaux CNN pré-entraînés (ResNet18, ResNet50, ResNet101, InceptionV3, DenseNet201, et ChexNet) ainsi qu'un modèle CNN peu profond, analysés sur des images CXR de poumons simples et segmentées. Le modèle ChexNet avec la technique d'amélioration gamma a présenté la meilleure performance sans segmentation d'image, tandis que DenseNet201 avec la technique d'amélioration gamma surpassait les performances pour les poumons segmentés.

Sanagavarapu (Sanagavarapu et al. 2021) ont utilisé l'histogramme CLAHE sur des images de scanner thoracique pour améliorer leurs caractéristiques. Ils ont employé le modèle d'architecture ResNet pour traiter le déséquilibre des classes lors de l'identification des tomodensitogrammes COVID-19 positifs, obtenant une précision de 87,23% avec les images améliorées par CLAHE. Alwazzan (Alwazzan et al. 2021) ont appliqué un algorithme CLAHE basé sur la séparation des canaux RVB de l'image. Ils ont également proposé le filtre Wiener pour l'amélioration des images de fond d'œil en couleur.

Rao (Rao et al. 2022) ont présenté une méthode basée sur la théorie du retinex et l'ajustement du contraste local. Ils ont appliqué deux techniques d'amélioration : le modèle de couleur HSV et la nouvelle méthodologie CLAHE pondérée qui a été appliquée à la composante de la luminosité dans le modèle de couleur $L^*a^*b^*$.

Le Tableau 2.1 résume quelque méthode d'amélioration et de détection

Tableau 2.1 Références et Méthodes.

Reference	Methode
(Mery et al. 2016)	Scale Invariant Feature Transform (SIFT)
(Zhang et al. 2010)	Processus statistique
(Tuli et al. 2020)	Bag-of-Visual-Words (BoVW)
(Larsen et al. 2000)	K-Nearest Neighbors, Logistic Regression
(Andrews et al. 2017)	Decision Trees
(Mery et al. 2016)	Scale Invariant Feature Transform (SIFT)
(Gaus et al. 2019)	RetinaNet
(Akçay et al. 2016; Griffin et al. 2019)	Apprentissage par transfert
(Gaus et al. 2019; Subramani et al. 2020)	Région (R-CNN) ; (Mask R-CNN) ; RetinaNet
(Ponnusamy et al. 2021)	You Only Look Once (YOLO)
(Wei et al. 2021)	CNN
(Danso et al. 2022)	Transformées en ondelettes
(Gao et al. 2021)	(USM) + CLAHE
(Pincu & Kleinberger-Riedrich 2012)	Méthode à double énergie
(Gupta et al. 2019)	Ondelettes

2.5. Conclusion

En synthèse de cette section, nous avons examiné les enjeux cruciaux de la sécurité aérienne liés à la détection d'objets dangereux, tels que les explosifs et les armes à feu, dans les bagages en soute des avions. Cette mission complexe est vitale pour assurer la sécurité des passagers, de l'équipage et des aéronefs, mais elle fait face à des défis multiples, notamment la rareté des cibles, la variabilité des images radiographiques, la superposition d'objets et le risque de fausses alarmes. Les progrès technologiques, en particulier l'exploitation de la technologie des rayons X à double énergie, présentent un potentiel prometteur pour rehausser la détection d'objets dangereux.

Nous avons exploré les deux grandes catégories de techniques de détection : les méthodes traditionnelles basées sur l'apprentissage automatique et les réseaux de neurones convolutifs (CNN). Les approches à deux étapes et à une seule étape des CNN ont été scrutées, avec une reconnaissance particulière de leur efficacité. De plus, nous avons examiné les recherches spécifiques sur la détection des détonateurs, soulignant son importance cruciale pour la sécurité aérienne.

Nous avons également abordé les dispositifs de contrôle à rayons X employés pour détecter les objets dangereux dans les bagages. Leur performance dépend de divers facteurs,

tels que la qualité des images radiographiques, la technologie d'affichage des images et les algorithmes de détection d'objets dangereux.

Enfin, nous avons discuté de l'utilisation des ondelettes et de l'égalisation d'histogramme adaptative limitée par le contraste (CLAHE) pour améliorer les images radiographiques avant leur intégration dans les architectures de réseaux de neurones profonds. Ces approches visent à réduire le bruit, améliorer le contraste et mettre en évidence les caractéristiques cruciales des objets dangereux, y compris les détonateurs.

*Chapitre 3. Analyse des images à rayons X
des bagages*

3.1. Introduction

L'analyse et le traitement d'images constituent une discipline intégrée à l'informatique et aux mathématiques appliquées, se penchant sur les images numériques et leurs diverses transformations dans l'objectif d'améliorer leur qualité ou d'en extraire des informations pertinentes. Dans le contexte spécifique des scanners à rayons X appliqués aux bagages, cela représente une facette spécialisée du traitement du signal qui se concentre sur les images et les données issues de ces dispositifs. Dans ce qui suit, nous présenterons quelques techniques utilisées dans le domaine de l'analyse des images à rayons X des bagages.

3.2. Définition de l'ondelette

Une ondelette est une fonction oscillante, dérivée du terme "onde", généralement désignée par ψ , caractérisée par une moyenne nulle. Elle exhibe une certaine régularité et une limitation spatiale, souvent qualifiée de "petite onde". À partir de cette ondelette mère ψ , il est possible de générer une famille d'autres ondelettes (équations (3.1) et (3.2)) :

$$\Psi_{u,s}(t) = \frac{1}{\sqrt{s}} \Psi\left(\frac{t-u}{s}\right) \text{ ou } (s \in \mathbf{R}^{+*}) \text{ et } (u \in \mathbf{R}) \quad (3.1)$$

$$\int_{-\infty}^{+\infty} \Psi(t) dt = 0 \quad (3.2)$$

Lorsque l'on considère les paramètres du temps (u) et d'échelle (s), l'ondelette $\Psi_{u,s}$ est fondamentalement la version décalée (ou translatée) de l'ondelette mère ψ , avec une dilatation (ou contraction) correspondante en fonction de s (lorsque s est inférieur à 1, on parle de contraction). Ainsi, à mesure que l'échelle s augmente, la résolution augmente également. Le coefficient multiplicateur de $\frac{1}{\sqrt{s}}$ revêt une importance cruciale, garantissant la conservation de l'énergie du signal dans cette transformation.

Avant de plonger dans les détails de certaines des fonctions mères d'ondelettes fréquemment utilisées, voici une liste de quelques-unes de ces fonctions, accompagnées de leurs abréviations correspondantes (Tableau 3.1).

Tableau 3.1 Fonction mères d'ondelettes.

Fonction mère d'ondelette	Abréviations
Ondelette de Haar	Haar
Ondelette de Daubechies	Db
Ondelette Symlet	Sym
Ondelette Coiflet	Coif
Ondelette Biorthogonales	Bior
Ondelette de Meyer	Meyr
Ondelette Gaussiennes	Gaus
Ondelette Gaussiennes complexes	Cgau
Chapeau mexicain	Mexh
Ondelette de Morlet	Morl
Ondelette de Morlet complexe	Cmor
Ondelette de Shannon complexe	Shan

Les fonctions mères d'ondelettes peuvent être définies par quatre caractéristiques principales : la présence de filtres associés, leur orthogonalité ou bi-orthogonalité, leur support (compact ou non), ainsi que leur nature en tant qu'ondelettes réelles ou complexes. Le tableau synthétise ces diverses caractéristiques (Danso et al. 2022).

Tableau 3.2 Propriétés principales des ondelettes (Danso et al. 2022).

Ondelettes à filtres			Ondelettes sans filtres	
A support compact		A support non compact	Réelles	Complexe
Orthogonales	Biorthogonales	Orthogonales	Gaus , Mexh, Morl	Cgau, Shan, Cmor
Db , Haar , Sym , Coif	Bior db	Meyr		

Les ondelettes avec des filtres sont associées à des analyses multi-résolutions, pouvant être orthogonales ou bi-orthogonales. Cela permet la réalisation de transformations discrètes et de calculs rapides en utilisant l'algorithme de Mallat (Shensa 1992).

À l'inverse, les ondelettes sans filtre sont utiles dans le contexte de la transformation en ondelettes continues. En général, les ondelettes à support compact n'ont pas de forme analytique. Cela signifie que bien que nous sachions comment calculer leur fonction, nous ne pouvons pas les exprimer à l'aide d'une formule mathématique (Pesquet-Popescu & Pesquet 2001).

3.2.1. Transformée en ondelettes continues (TOC)

La transformée en ondelettes continue (CWT) d'un signal $f(t)$ est définie par l'équation (3.3) :

$$\text{CWT}(\mathbf{p}, \mathbf{q}) = (f, \Psi_{\mathbf{p}, \mathbf{q}}) = \frac{1}{\sqrt{p}} \int_{-\infty}^{+\infty} f(\mathbf{t}) \cdot \Psi^*\left(\frac{\mathbf{t} - \mathbf{q}}{p}, \mathbf{t}\right) d\mathbf{t} \quad (3.3)$$

Dans ce contexte, $(f, \Psi_{\mathbf{p}, \mathbf{q}})$ représente le produit intérieur intégrable de moyenne nulle dans l'espace $L^2(\mathbb{R})$ (supposé ici à valeurs réelles). Les résultats de la CWT génèrent de multiples coefficients d'ondelettes, dépendant de p (échelle) et de q (position) (Danso et al. 2022).

La Transformée en Ondelettes Continues (TOC) joue un rôle crucial dans la détection d'explosifs et l'inspection des bagages par rayons X, offrant divers avantages et applications pour renforcer la sécurité dans les aéroports et les zones sensibles. Voici comment la TOC est appliquée dans ce contexte spécifique :

- **Amélioration de la Résolution** : L'inspection des bagages à rayons X exige une résolution élevée pour repérer des objets potentiellement dangereux. La TOC permet d'augmenter la résolution spatiale des images radiographiques, facilitant ainsi la détection d'objets suspects, tels que les explosifs, même s'ils sont dissimulés ou partiellement masqués.
- **Réduction du Bruit** : La TOC est utilisée pour réduire le bruit dans les images radiographiques des bagages, améliorant ainsi la qualité des images et minimisant les fausses alarmes, ce qui revêt une importance cruciale pour la sécurité aéroportuaire.
- **Détection de Formes et de Contours** : La TOC peut être employée pour détecter des formes et des contours dans les images radiographiques, facilitant ainsi la reconnaissance des objets suspects en se concentrant sur leur forme et leur structure, indépendamment de leur densité ou de leur matériau.
- **Analyse Multi-Échelle** : La TOC permet une analyse multi-échelle des images radiographiques des bagages, mettant en évidence à la fois les détails subtils et les caractéristiques globales, offrant ainsi une perspective complète pour l'inspection.
- **Segmentation d'Objets** : La TOC peut être utilisée pour segmenter les objets dans les images radiographiques, aidant à isoler les zones d'intérêt, telles que les objets suspects, des éléments environnants.
- **Intégration de Données Temporelles** : Dans les systèmes d'inspection en continu des bagages, la TOC peut être adaptée pour prendre en compte les données temporelles,

permettant ainsi la détection d'objets en mouvement ou de changements subtils dans les images.

- **Réduction des Faux Positifs** : En améliorant la qualité de l'image et en identifiant avec précision les objets suspects, la TOC contribue à réduire les faux positifs, ce qui est essentiel pour un processus d'inspection efficace et sûr.
- **Intelligence Artificielle et Détection Automatique** : La TOC peut être associée à des techniques d'intelligence artificielle pour automatiser la détection d'objets suspects, accélérant le processus d'inspection tout en maintenant un haut niveau de précision.

3.2.2. Transformée en ondelettes discrète (TOD)

La Transformée en Ondelettes Discrètes (TOD), également appelée Discrete Wavelet Transform (DWT) en anglais, constitue une technique de traitement du signal et de l'image utilisée pour analyser et représenter des signaux de manière multirésolution. Les ondelettes, en tant que fonctions mathématiques, permettent de décomposer un signal en différentes échelles de fréquence, facilitant ainsi la détection de caractéristiques significatives à différentes résolutions (équation (3.4)) (Chui 1992) :

$$DWT(j, k) = s_0^{-j/2} \int_{-\infty}^{+\infty} \Psi(s_0^j t - k\tau_0) f(t) dt \quad (3.4)$$

3.2.2.1. L'aspect mathématique

La transformée en ondelette repose sur le fait que toute fonction f intégrable, ce qui se note couramment par l'équation (3.5) :

$$\int_{-\infty}^{+\infty} f(x) dx \quad (3.5)$$

On peut être vue sous la forme d'une somme de fonction $\Psi_{s,b}(x)$.

Les fonctions ondelettes, toutes issues d'une seule et unique fonction, l'onde mère, de manière à ce que, pour tout b réel et a strictement positif, et pour tout x réel, sont représentées par l'équation (3.6) :

$$\Psi_{s,b} = \frac{1}{\sqrt{s}} \Psi\left(\frac{x-b}{s}\right) \quad (3.6)$$

a : Paramètre de dilatation. b : Paramètre de translation.

3.2.2.2. Algorithme de compression par ondelettes

Passons maintenant à l'algorithme pyramidal employé. La décomposition des coefficients d'ondelettes ne fait pas appel à une fonction de moyenne, mais repose sur l'utilisation de deux filtres distincts : un filtre passe-bas (L) et un filtre passe-haut (H). La conjonction de ces filtres permet de générer quatre sous-images distinctes, à savoir HH, HL, LH et LL. Ces filtres sont également désignés sous le nom de "filtres en quadrature à miroirs" (Arab et al. 2013).

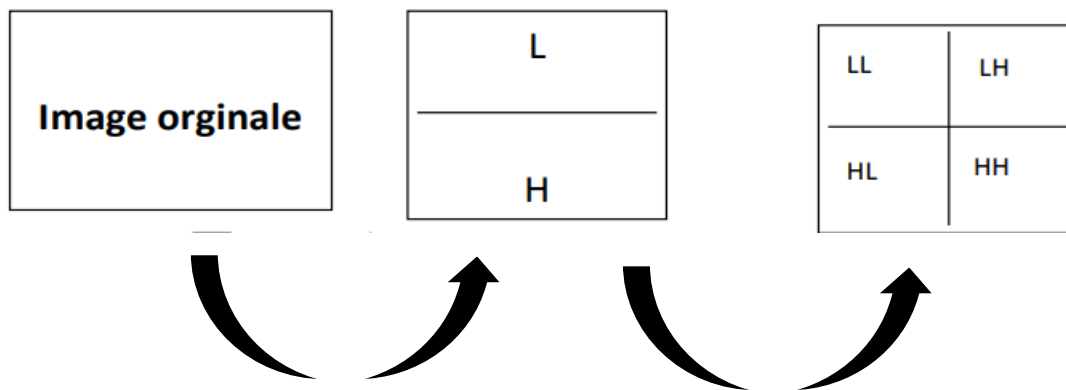


Figure 3.1 Transformation en colonnes et en lignes.

Chacune des quatre images obtenues par la transformation représente des informations bien distinctes.

3.2.2.3. Etapes de compression par ondelettes

Les étapes couramment suivies dans la compression par ondelettes sont les suivantes :

- 1) Transformation par ondelettes.
- 2) Quantification : Cette étape implique l'élimination des valeurs des coefficients de détails en dessous d'un certain seuil, en fonction du niveau d'efficacité souhaité. C'est à ce stade que surviennent les pertes d'information.
- 3) Codage des valeurs restantes : Les données restantes sont transmises à un encodeur d'entropie, c'est-à-dire à un algorithme de compression de données tel que LZW, RLE, et autres.

Les principaux algorithmes basés sur la DWT (Transformée en Ondelettes Discrète) comprennent EZW, SPIHT, SFQ, CREW, EPWIC, EBCOT le codage d'image à l'aide de paquets d'ondelettes, ainsi que la VQ (Quantification Vectorielle). Nous allons brièvement aborder quelques-uns de ces algorithmes (Saha 2000).

a. Algorithme d'arbre de zéro (EZW)

La méthode de compression progressive, baptisée "Embedded Zerotree Wavelet coding" (EZW), dont l'origine remonte à 1993 et a été développée par Shapiro (Mekouar 2002) et (BOUCETTA 2010), se distingue par sa simplicité et son efficacité remarquable. Elle a fait ses preuves dans les domaines de la compression, qu'il s'agisse de compression avec perte ou sans perte d'informations.

Dans une représentation par coefficients d'ondelettes d'une image, celle-ci est généralement structurée de manière à mettre en avant les caractéristiques principales de l'image dans les basses fréquences, tandis que les détails sont présents dans les hautes fréquences. L'EZW tire parti de cette disposition en effectuant un codage progressif des coefficients. Initialement, les basses fréquences L sont traitées, puis les détails (hautes fréquences) sont encodés. L'avantage majeur de cet algorithme réside dans le fait qu'il offre un niveau de compression à tout moment, permettant ainsi d'interrompre le processus de codage à tout moment.

Ce type de codage a connu diverses variantes développées par différents chercheurs de renom dans le domaine, ce qui en renforce la polyvalence. L'un des exemples les plus notables est le SPIHT (Set Partitioning In Hierarchical Tree), conçu par A. SAID et W. PEARLMAN (Mekouar 2002) et (Saha 2000)) qui est devenu la variante la plus répandue de l'EZW.

b. Algorithme SPIHT

La méthode SPIHT (Set Partitioning in Hierarchical Trees), proposée par A. Said et Pearlman (Mekouar 2002), diffère de ses antécédentes par la manière dont les coefficients sont classés ainsi que pour le traitement des coefficients significatifs. Un autre point important est que cette méthode génère un flot binaire intéressant (au niveau de la compression) sans passer par un codage entropique contrairement au codage EZW dont les résultats n'apparaissent qu'une fois associé au codage arithmétique (Mekouar 2002), (Saha 2000). Le principal avantage de cet algorithme est qu'il est plus rapide en exécution que EZW, et peut donner de meilleurs résultats (Mekouar 2002).

3.3. Structure pyramidale de la décomposition en ondelette

La transformée en ondelette repose sur la notion fondamentale de décomposer une image d'origine en deux composantes distinctes : une approximation globale (qui représente

l'aspect général de l'image et est obtenue à l'aide d'un filtre passe-bas) et des détails (qui capturent les modifications locales nécessaires pour reconstruire l'image d'origine et sont obtenus via un filtre passe-haut).

Pour obtenir ces approximations, nous effectuons une convolution avec une fonction d'échelle (qui est un filtre passe-bas), tandis que les détails, ou coefficients d'ondelettes, sont calculés en effectuant des convolutions avec une fonction d'ondelettes. Ensuite, nous réduisons la résolution de l'image en réduisant le nombre de points de moitié.

Ce processus est répété itérativement, chaque fois en prenant l'approximation actuelle et en la transformant en une nouvelle approximation avec deux fois moins de points (Acharya & Chakrabarti 2006).




Figure 3.2 (a) Image en couleur et sa décomposition en ondelette au premier niveau. Présentation des bandes (b) LL, (c) HL, (d)LH, (e) HH de la décomposition.

Tableau 3.3 Comparaison des avantages, inconvénients, et avancées liées à l'application de la transformée en ondelettes dans le traitement des images à rayons X des bagages.

Aspect	Avantages	Inconvénients	Amélioration générale
Détection d'objets	Capable de détecter des objets de petite taille grâce à la sensibilité aux détails.	Peut générer des faux positifs en cas de bruit ou de textures complexes.	Utilisation de techniques avancées de post-traitement pour réduire les faux positifs.
	Permet une meilleure séparation des différentes caractéristiques des objets.	Requiert plus de puissance de calcul et de mémoire.	Optimisation des paramètres de la transformée en ondelettes pour la tâche spécifique.
Compression d'image	Permet une compression efficace de l'image tout en conservant les détails.	Perte d'informations potentielles dans les hautes fréquences.	Utilisation de techniques de compression sans perte pour conserver davantage d'informations tout en réduisant la taille.
	Réduction de la taille des fichiers pour le stockage et la transmission.	Nécessite un codage adapté pour gérer la compression.	
Amélioration d'image	Réduction du bruit et de l'effet de rétrodiffusion dans les images rayons X.	Peut augmenter le temps de traitement.	Utilisation de techniques de débruitage et de réduction des artefacts pour améliorer la clarté des images.
	Amélioration de la qualité visuelle des images pour une meilleure interprétation.	Nécessite une expertise pour optimiser les paramètres.	Intégration de techniques de filtrage adaptatives pour une performance constante.
		Certaines méthodes peuvent être sensibles aux variations de l'éclairage.	

En résumé, l'utilisation de la transformée en ondelettes dans le traitement d'images à rayons X dans les bagages offre des avantages tels que la détection améliorée des petits objets, une compression efficace et une amélioration de la qualité visuelle. Cependant, elle peut être sujette à des inconvénients tels que la nécessité de paramétrages experts et une

sensibilité potentielle aux variations d'éclairage. Pour améliorer l'efficacité, des techniques de post-traitement, de codage adapté, de débruitage et de filtrage adaptatif peuvent être utilisées.

3.4. Approches de l'égalisation d'histogramme pour l'amélioration du contraste d'images

L'égalisation d'histogramme est une technique de traitement d'images visant à améliorer le contraste en ajustant la distribution des niveaux de gris dans une image. Cette méthode repose sur la transformation de l'histogramme de l'image, qui représente la répartition de la fréquence des niveaux de gris. Son objectif est de réduire la dynamique des niveaux de gris en étalant la gamme des valeurs de manière à couvrir l'ensemble de l'intervalle des niveaux de gris disponibles. Ainsi, les détails de l'image deviennent plus visibles, conférant à l'image un contraste plus prononcé.

Le contraste visuel revêt une importance cruciale dans la perception et l'analyse des images. Il permet de distinguer les détails, les contours et les structures, des aspects essentiels dans divers domaines tels que la radiographie médicale, la vision par ordinateur, la sécurité, la reconnaissance d'objets, entre autres. Un contraste bien équilibré améliore la lisibilité des images, facilite la détection d'objets d'intérêt et favorise une interprétation plus précise.

3.4.1. Égalisation globale de l'histogramme

Le Global Histogram Equalization (GHE) est une méthode d'histogramme qui prend en considération l'image d'origine fournie par l'utilisateur, l'améliore de manière globale, et présente simultanément l'image initiale et l'image améliorée. Cette approche marque une avancée significative dans l'amélioration du contraste des images. Le contraste des images est déterminé par la plage dynamique, qui représente le rapport entre les intensités des pixels les plus claires et les plus sombres. L'histogramme offre des informations cruciales sur le contraste ainsi que sur la répartition globale de l'intensité dans une image. L'image d'entrée, notée $f(x,y)$, est constituée de niveaux de gris discrets compris dans la plage dynamique $[0, L-1]$ (Senthilkumaran & Thimmiraja 2014).

Dans l'équation (3.7), s_k est restreint à une plage de valeurs de 0 à 1, et k varie de 0 à $[L-1]$. n_i représente le nombre de pixels ayant un niveau de gris R_i , tandis que n est le nombre total de pixels dans l'image d'origine, et $P(R_i)$ est la Fonction de Densité de Probabilité (PDF) des niveaux de gris d'entrée R_i . En utilisant cette PDF comme base, la Fonction de Densité Cumulative (CDF) est définie comme $C(R_k)$ (Abdullah-Al-Wadud et al. 2007).

$$s_k = c(R_k) = \sum_{i=0}^k p(R) = \sum_{i=0}^k \frac{ni}{n} \quad (3.7)$$

La transformation décrite dans l'équation (3.7) est connue sous le nom d'Égalisation Globale de l'Histogramme (EGH) ou de Linéarisation de l'histogramme. Dans ce contexte, sk peut être associé à la plage dynamique $[0, L-1]$ en le multipliant simplement par $(L-1)$.

3.4.2. Égalisation locale de l'histogramme

L'amélioration d'images numériques est cruciale pour optimiser la qualité visuelle des images, créant ainsi une représentation transformée mieux adaptée aux futures opérations de traitement automatisé, telles que l'analyse, la détection, la classification et la reconnaissance d'images. Les techniques d'amélioration d'images peuvent être catégorisées en deux types : l'amélioration dans le domaine spatial et l'amélioration dans le domaine de la transformation de distribution. L'égalisation d'histogramme adaptative (AHE) appartient à la catégorie des améliorations spatiales non uniformes (Rogers et al. 2016). Ces techniques utilisent une transformation entrée-sortie qui s'ajuste de manière dynamique en fonction des caractéristiques locales de l'image. L'AHE, également connue sous le nom d'égalisation d'histogramme locale, applique une transformation des niveaux de gris qui varie localement sur de petites régions de l'image (Rogers et al. 2016). Il est essentiel de noter que cette méthode ne supprime pas complètement l'augmentation du bruit dans les zones lisses de l'image. Plusieurs techniques d'égalisation d'histogramme local existent, telles que l'égalisation d'histogramme avec chevauchement de blocs (BOHE), l'égalisation d'histogramme sans chevauchement de blocs (NOBHE), l'égalisation d'histogramme de sous-blocs partiellement chevauchants (POSHE), l'égalisation d'histogramme adaptative interpolée (IAHE), l'égalisation d'histogramme adaptative pondérée (WAHE) et l'égalisation d'histogramme adaptative à contraste limité (CLAHE) (Josephus & Remya 2011). Toutes ces méthodes présentent des inconvénients tels que la génération et l'amplification du bruit, l'amélioration artificielle et une charge de calcul élevée.

3.4.2.1. Égalisation d'histogramme (HE)

L'égalisation d'histogramme est une méthode opérant dans le domaine spatial et relativement simple à appliquer. Elle agit en modifiant l'intensité de l'image, améliorant ainsi le contraste global de l'image. Cette technique peut être définie comme une transformation visant à améliorer le contraste d'une image en redistribuant de manière uniforme les niveaux de gris de l'image. L'expression de l'égalisation d'histogramme est l'équation (3.8) (Pant et al. 2014) :

$$P(R_k) = N_{k/N} \quad (3.8)$$

Dans cette équation, la séquence N_k varie de 0 à L-1, où R_k représente le k-ème niveau de gris. Le paramètre N est défini comme le nombre total de pixels dans l'image ayant un niveau de gris de R_k .

3.4.2.2. *Égalisation d'histogramme adaptative (AHE)*

L'Égalisation d'histogramme adaptative (AHE) applique une transformation à chaque pixel en utilisant une fonction dérivée de la zone environnante. Son objectif principal est d'accentuer le contraste local des images, qu'elles soient d'origine naturelle ou médicale. Cependant, cette méthode peut amplifier le bruit dans les zones uniformes, conduisant à des frontières floues et des valeurs de pixels altérées lors de la numérisation de l'image, ce qui peut entraîner une imprécision dans l'image résultante (Pant et al. 2014).

3.4.2.3. *Égalisation d'histogramme adaptative à contraste limité (CLAHE)*

À l'origine, le CLAHE (Égalisation d'histogramme adaptative à contraste limité) avait pour vocation d'améliorer la qualité des images médicales présentant un faible contraste. Cette méthode découpe les images en zones associées et applique une égalisation spécifique à chaque zone. Cette procédure a pour effet de régulariser la répartition des niveaux de gris, ce qui entraîne une meilleure visibilité des caractéristiques dissimulées dans l'image (Aurangzeb et al. 2021). Le CLAHE standard, avec ses niveaux de gris transformés, est exprimé à l'aide de la formule mathématique suivante, présentée en termes de distribution uniforme (équation (3.9)) :

$$G = [G_{max} - G_{min}] * P(f) + G_{min} \quad (3.9)$$

3.4.2.4. *Égalisation d'histogramme avec chevauchement de blocs (BOHE)*

L'égalisation adaptative de l'histogramme, notamment la méthode BOHE, souligne les détails, même si le bruit est souvent amélioré en même temps. Pour certaines applications, la BOHE peut être la solution optimale, mais son inconvénient majeur réside dans sa complexité de calcul. Les techniques sans chevauchement simplifient le calcul, mais elles souffrent généralement de l'effet de blocage. L'interpolation ou le lissage des histogrammes des blocs voisins réduit l'effet de blocage, mais cela a un impact sur le temps de calcul (Kong & Ibrahim 2011).

3.4.2.5. Égalisation d'histogramme sans chevauchement de blocs (NOBHE)

L'égalisation d'histogramme sans chevauchement de blocs (NOBHE) est une technique de traitement d'image visant à améliorer le contraste et la qualité visuelle en répartissant uniformément les niveaux de gris dans une image, sans superposition de blocs. Cette méthode divise l'image en blocs non chevauchants, calcule l'histogramme pour chaque bloc, puis applique une égalisation d'histogramme indépendante à chaque bloc. Le résultat final est une image avec un meilleur contraste, mais qui peut présenter des effets de blocs visibles aux frontières des blocs (Majeed & Isa 2020).

3.4.2.6. Égalisation d'histogramme de sous-blocs partiellement chevauchants (POSHE)

L'égalisation d'histogramme de sous-blocs partiellement chevauchants (POSHE) (Majeed & Isa 2021) est une technique de traitement d'image visant à améliorer le contraste et la qualité visuelle d'une image en ajustant la distribution des niveaux de gris dans des sous-blocs d'image. Voici un formulaire mathématique général pour la POSHE, suivi d'un exemple d'image pour illustrer son application (Larsen et al. 2000) :

- Formulaire Mathématique de la POSHE :
Soit $I(x, y)$ une image d'entrée de taille $M \times N$, où (x, y) sont les coordonnées des pixels.
- Division de l'image en sous-blocs :
Divisons l'image I en sous-blocs de taille $K \times L$ partiellement chevauchants. Soit $B(i, j)$ le sous-bloc situé à la position (i, j) , où i varie de 1 à $M-K+1$ et j varie de 1 à $N-L+1$.
- Calcul de l'histogramme cumulatif local :
Pour chaque sous-bloc $B(i, j)$, calculons l'histogramme cumulatif local $H_B(i, j)$ des niveaux de gris de ce sous-bloc.
- Normalisation de l'histogramme cumulatif local :
Normalisons l'histogramme cumulatif local $H_B(i, j)$ de chaque sous-bloc $B(i, j)$ pour obtenir un histogramme cumulatif normalisé $H_{Norm_B}(i, j)$.
- Transformation des niveaux de gris :
Appliquons une transformation $T_B(i, j)$ aux niveaux de gris du sous-bloc $B(i, j)$ en utilisant l'histogramme cumulatif normalisé $H_{Norm_B}(i, j)$.
- Reconstruction de l'image égalisée :
Après avoir appliqué la transformation $T_B(i, j)$ à chaque sous-bloc $B(i, j)$, reconstruisons l'image égalisée $I_{eq}(x, y)$.

3.4.2.7. Égalisation d'histogramme adaptative pondérée (WAHE)

La méthode d'approximation de l'histogramme pondéré (WAHE). La méthode WAHE ne modifie pas l'histogramme d'entrée à l'aide d'une fonction de transformation. Au lieu de cela, dans cette approche, les pixels présentant un contraste suffisant dans l'histogramme sont comptés pour éviter d'altérer les zones lisses (Singh & Bhandari 2020).

Tableau 3.4 synthèse des Avantages et des Limitations des Diverses Catégories de Méthodes d'Amélioration de Contraste Basées sur l'Égalisation d'Histogramme (Majeed & Isa 2020).

Classe	Méthode existante	Puissance	limitation
GHE	/	-Calcul simple -Bonne amélioration sur différents types d'images	-Contraste limité en raison de la prédominance -Apparence terne ou fade -Ne peut pas conserver le contraste et la luminosité de l'image originale -Erreur d'arrondi lors de la quantification des niveaux de gris
LHE	AHE CLAHE POSHE	-Adaptabilité -Préservation des détails	-Complexité computationnelle -Apparence d'image artificielle -Suramplification causée -Effet de blocage
Multi-histogramme HE	BBHE DSIHE BHEMHB RMSHE RSIHE MVSIHE DHE BPDHE EDSHE	-Réduire le risque de compression sur l'histogramme des basses fréquences -Amélioration optimale comme dans GHE (Égalisation d'histogramme global)	- Difficulté à déterminer le seuil optimal pour la segmentation de l'histogramme -Manque d'éléments d'exposition dans le calcul du seuil
Modification d'Histogramme à base HE	MHE WTHE RSWHE	-Prendre le contrôle du taux d'amélioration -Amplifier l'amélioration sur les compartiments de l'histogramme de basse fréquence -Préservation des détails	-L'amélioration est limitée au seuil plafonné -L'amélioration n'est pas évidente -Difficulté à déterminer le paramètre de seuil optimal pour la modification de l'histogramme

Exposition	ESIHE	<ul style="list-style-type: none"> - Capable de fournir une amélioration sur les images avec une certaine exposition -Utilisation de paramètres d'exposition dans le seuillage de l'histogramme. 	<ul style="list-style-type: none"> -Ne fonctionnent pas au mieux sur une seule image avec de multiples expositions -Affectent le contraste de la région bien exposée
-------------------	-------	--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------	----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------

3.5. Conclusion

Nous avons amorcé notre exploration par une introduction, mettant en lumière l'importance de l'analyse des images à rayons X dans le contexte de la sécurité aérienne. Ensuite, nous nous sommes plongés dans les fondements théoriques de la transformation en ondelette, mettant en relief les concepts essentiels tels que les fonctions mères, la transformation en ondelettes continues (TOC), et la transformation en ondelettes discrètes (TOD). Les aspects mathématiques de ces transformations ont également été abordés de manière approfondie.

Une plongée plus profonde dans la structure pyramidale de la décomposition en ondelette a suivi, démontrant comment cette approche permet de saisir des détails d'image à différentes échelles. Nous avons ensuite examiné les approches d'égalisation d'histogramme visant à améliorer le contraste des images. Cela a inclus l'égalisation globale de l'histogramme ainsi que l'égalisation locale de l'histogramme, avec des variantes telles que l'égalisation d'histogramme adaptative (AHE), l'égalisation d'histogramme adaptative à contraste limité (CLAHE), et bien d'autres.

Enfin, nous nous sommes penchés en détail sur l'égalisation d'histogramme adaptative pondérée (WAHE), offrant ainsi une approche prometteuse pour améliorer le contraste tout en maîtrisant le bruit dans les images. En guise de conclusion, ce chapitre nous a dotés d'une base solide pour appréhender les techniques de transformation en ondelette et d'égalisation d'histogramme, cruciales dans l'analyse des images radiographiques des bagages en soute d'avions. Ces techniques jouent un rôle essentiel dans l'amélioration de la qualité des images et la facilitation de la détection d'objets potentiellement dangereux. Les prochains chapitres approfondiront davantage la manière dont ces approches sont appliquées pour renforcer la sécurité aérienne.

***Chapitre 4. Méthodes utilisées pour la
détection des détonateurs***

4.1. Introduction

L'utilisation de scanners à rayons X pour inspecter les bagages est cruciale dans la prévention de la criminalité, la lutte contre les actes terroristes, et la prévention de la propagation de parasites et de maladies. La détection d'objets dangereux dans les images à rayons X est devenue une priorité, en particulier à la lumière de l'augmentation de la criminalité ces dernières années, ainsi que des risques liés à la propagation de parasites et de maladies. Notre intérêt se porte sur les systèmes intelligents de détection de produits dangereux, notamment les détonateurs, présents dans les bagages en soute des avions.

L'inspection de ces bagages constitue une tâche complexe, car les objets dangereux sont notoirement difficiles à repérer lorsqu'ils sont dissimulés dans des sacs bien emballés, cachés sous d'autres articles, ou camouflés de diverses manières, les rendant ainsi méconnaissables.

L'objectif est de présenter un nouveau schéma efficace pour la détection de détonateurs dans les images de bagages aux rayons X en comparant différentes méthodes de manipulation d'images et en évaluant leur impact sur les capacités prédictives des modèles de classification.

Pour remédier à la sous-utilisation des ondelettes dans les inspections de sécurité aux rayons X, nous introduisons les ondelettes comme une méthode de manipulation qui peut être utilisée pour obtenir des images de plus haute résolution et avec plus de détails définis. Cela nous a permis d'obtenir des informations sur la validité des processus de manipulation et leur relation avec la performance de la détection des détonateurs. Les expériences sont menées en utilisant la base de données High Tech Detection Systems (HTDS).

Dans l'approche proposée, nous avons choisi et construit une architecture CNN bien établie qui a obtenu d'excellentes performances en matière de classification et de détection d'objets (Moldovanu et al. 2021). Nous avons réalisé une vaste étude d'ablation pour établir un modèle de configuration optimal avec de bonnes performances sur l'ensemble des données (Montaha et al. 2021, 2022). Ainsi, nous avons expérimenté avec différentes images corrompues par du bruit gaussien et du bruit sel-et-poivre, divers hyper-paramètres modifiés et différentes structures de couches. Les architectures CNN proposées effectuent deux étapes d'analyse : (i) la détection des détonateurs dans l'image radiographique brute à l'aide du classificateur basé sur les CNN profonds, les bibliothèques TensorFlow et Keras, et (ii) le

même cadre de classificateur CNN est utilisé lorsque l'ensemble d'images d'entrée est prétraité en utilisant les méthodes suivantes : l'algorithme CLAHE, qui fonctionne de manière indépendante sur les images RVB et en outre sur les canaux de couleur individuels, les transformées en ondelettes avec les sous-bandes HH et HL, et une combinaison des techniques CLAHE et de la transformation en ondelettes RVB.

Les sorties sont analysées en termes d'exactitude, de précision, de rappel, de score F1 et de classification. Le schéma fonctionnel synthétise le système de détection de détonateurs à partir d'images radiographiques à double énergie des bagages. Pour démarrer, nous avons initié deux expériences distinctes. Dans la première expérience de ce travail, la base de données brute est directement utilisée dans un modèle CNN profond pré-entraîné pour la reconnaissance d'objets. En ce qui concerne la deuxième expérience, la base de données prétraitée est employée en utilisant trois méthodes différentes d'amélioration. La Figure 4.1 illustre cette configuration.

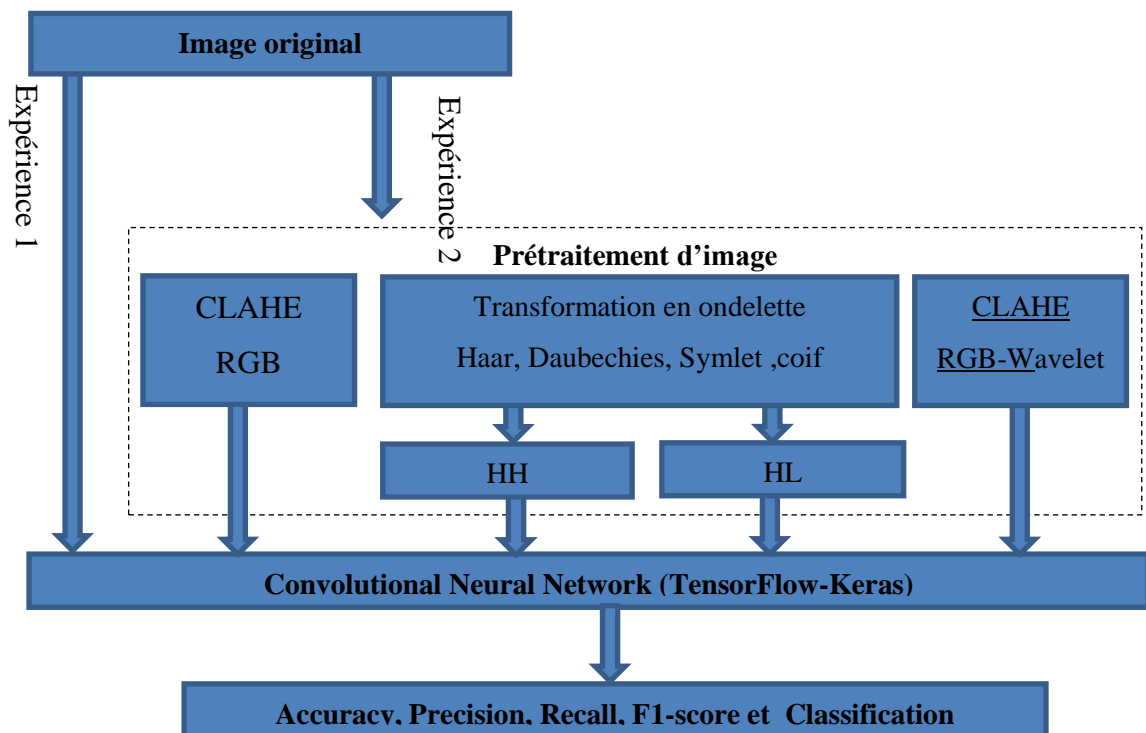


Figure 4.1 Schéma fonctionnel d'un système de détection de détonateur d'une image à rayons X double énergie.

Pour détecter des objets suspects, tels que des détonateurs, dans les images radiographiques 2D des bagages de la base de données HTDS, nous appliquons une série de méthodes et d'expériences, comme illustré dans le schéma bloc décrit dans la Figure 4.1.

4.2. Database

La base de données utilisée dans cette étude provient de High Tech Detection Systems (HTDS), une entreprise française spécialisée dans la vente et la maintenance d'équipements de sécurité de haute technologie utilisés pour le contrôle des passagers, la sécurité des bagages et des véhicules, ainsi que pour la sécurité du fret (High Tech Detection Systems 2023). Le jeu de données initial comprend 6 500 images réparties en deux catégories : la classe 0, qui englobe 5 500 images avec des détonateurs, et la classe 1, comprenant 1 000 images sans détonateurs, comme illustré dans la Figure 4.2.

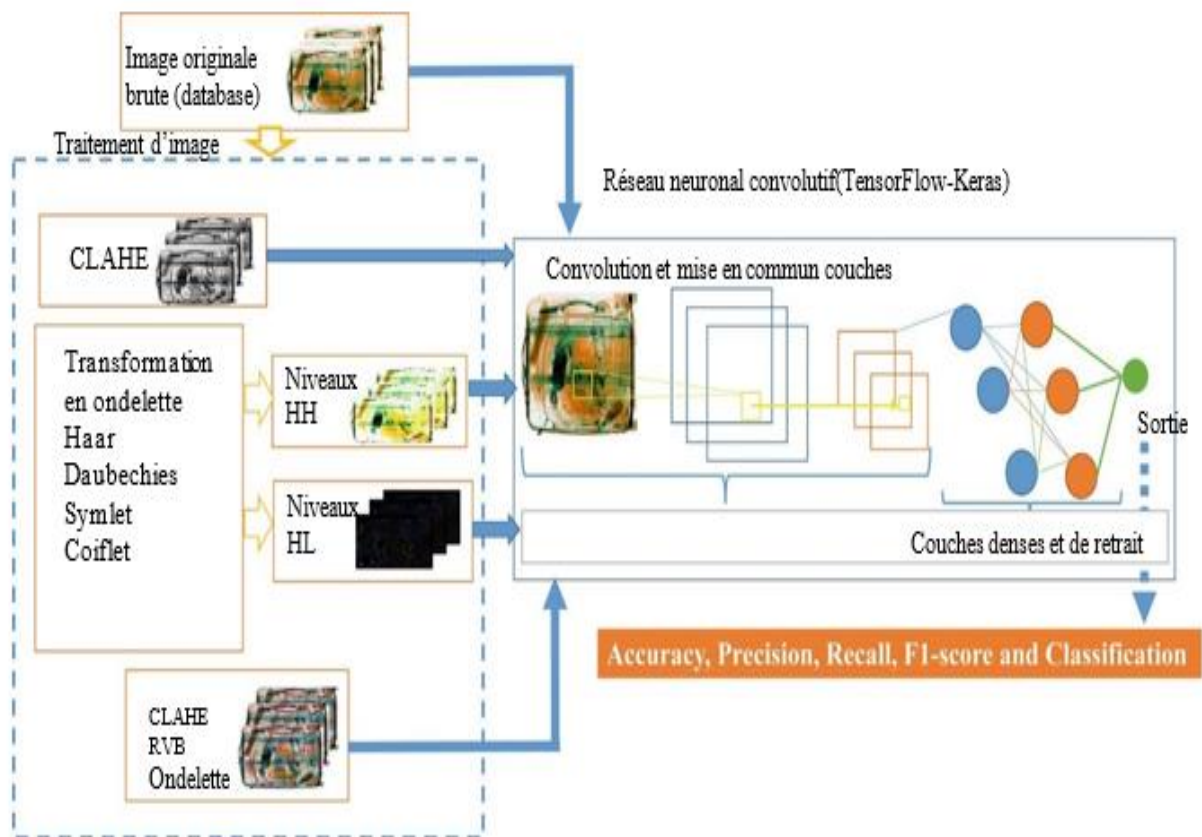


Figure 4.2 Configuration opérationnelle de la méthode post-étude d'ablation. Les sous-bandes de décomposition, HH (Haute-Haute) et HL (Haute-Basse), dans la transformation en ondelette.

Pour assurer une répartition équilibrée des classes, le jeu de données a été divisé en ensembles d'entraînement (70 %) et de test (30 %), avec une distribution similaire des classes dans chaque division. L'ensemble de test est composé d'échantillons qui n'ont jamais été utilisés lors de l'entraînement. Afin de balancer le nombre d'échantillons dans les deux classes, des rotations aléatoires ont été appliquées à chaque échantillon pour augmenter le jeu

de données. Le jeu de données final compte ainsi 15 115 échantillons. Les performances de la classification sont évaluées sur l'ensemble de test.




Figure 4.3 Classe 1: Exemple d'images sans détonateur classe 0 : Exemple d'image avec détonateur (détail dans l'image) (Oulhissane et al. 2023).

Exemples d'images radiographiques de bagages contenant plusieurs objets (rangée du haut) et sans/dans lesquels se trouve un détonateur (rangée du bas). Le détail d'un détonateur est illustré. Différents matériaux représentés en différentes couleurs sur une image pseudo-couleur obtenue à partir de scanners à rayons X à double énergie illustre la faible qualité et la faible résolution des images 2D.

Tableau 4.1 Étude d'ablation sur la base de données d'images brute.

Element d'ablation		Exactitude	Precision	Recall	F1-score	Confusion matrix
Images d'entrée	Image corrompue par un bruit gaussien	0.8746	0.91	0.90	0.91	1256 110 132 432
	Image corrompue par le bruit poivre et sel	0.8958	0.93	0.91	0.92	1285 92 109 444
Nombre de couche de convolution	1	0.8708	0.93	0.91	0.92	3304 237 305 350
	2	0.9159	0.96	0.94	0.95	3404 138 215 441
Taux d'apprentissage	0.01	0.9256	0.95	0.95	0.96	3421 149 163 463
	0.005	0.9338	0.95	0.97	0.96	3451 164 102 478

Taille de lot (Batch size)	16	0.9423	0.94	0.97	0.96	3499 163 81 502
	64	0.9427	0.96	0.96	0.96	3466 121 119 489

4.3. Expérience 1

La base de données non traitée est directement intégrée dans le modèle CNN profond pré-entraîné pour la détection d'objets.

4.4. Expérience 2

4.4.1. Prétraitement de l'image

4.4.1.1. Méthode 1

Dans la deuxième expérience, la méthode d'amélioration appliquée aux images radiographiques à double énergie est le CLAHE (Contrast Limited Adaptive Histogram Equalization) (Yu et al. 2020). Son utilisation vise à améliorer la qualité d'image et le contraste. Le contraste, une propriété cruciale liée à l'intensité des pixels, peut être représenté par l'équation (4.1) :

$$\text{Contrast} = \frac{\text{Object} - \text{Background}}{\text{Context}} \quad (4.1)$$

Le contraste d'un objet dans une image peut être ajusté en modifiant le mappage des intensités des pixels (Sanchez-Montero et al. 2019). Cette adaptation améliore l'identification des objets, préserve les détails lors du traitement morphologique, et facilite la conversion en RGB. La conversion RGB offre de la profondeur en extrayant les caractéristiques des canaux de couleur : le canal rouge est converti en niveaux de gris, de même pour le canal vert et le canal bleu (da Rocha et al. 2020).

4.4.1.2. Méthode 2

La méthode appliquée consiste en des transformations en ondelettes à deux niveaux : HL (haute basse) et HH (haute haute) (Chen et al. 2019), utilisant les fonctions mères telles que Haar, Daubechies2 (Db2), Symlet2 (Sym2), et Coiflet2 (Coif2) (Verma et al. 2021). Les transformations en ondelettes sont particulièrement utilisées pour la compression de données en éliminant les informations de haute fréquence imperceptibles à l'œil. Cette approche

contribue également à réduire le bruit en se basant sur la décomposition des paquets d'ondelettes et l'application d'un seuil adaptatif (Georgieva et al. 2014).

4.4.1.3. Méthode 3

La troisième méthode consiste en la conversion CLAHE RGB avec les transformations en ondelettes à deux niveaux HH et HL, utilisant les mêmes fonctions mères que la méthode précédente. Ainsi, cette approche s'appuie sur des images améliorées par la méthode CLAHE RGB (c'est-à-dire, la première méthode). Après le prétraitement des données, la taille de l'ensemble de la base de données est désormais prête à passer à l'étape d'extraction des caractéristiques par le modèle d'architecture CNN profond.

4.5. Classification Convolutional Neural Network (TensorFlow et Keras)

Nous avons mené des expérimentations approfondies pour évaluer la robustesse du modèle CNN proposé pour la classification binaire des images radiographiques à double énergie, distinguant entre détonateurs et non-détonateurs. L'architecture CNN a été implémentée à l'aide de TensorFlow et Keras. TensorFlow, une bibliothèque logicielle open source, est reconnue pour sa flexibilité dans la construction de modèles d'apprentissage en profondeur actuels (Yu et al. 2019). Keras, une bibliothèque open source de réseaux neuronaux en Python, fonctionne au-dessus de TensorFlow (Jose 2019).

Le CNN profond est composé de cinq couches profondément séparables, comprenant trois couches de convolution et deux couches denses. Les hyperparamètres du modèle d'architecture CNN profonde, après l'étude d'ablation, sont présentés dans le Tableau 4.3. La première couche de convolution compte 16 unités, la deuxième en compte 32, et la troisième en compte 64. La fonction d'activation Rectified Linear Unit (ReLU) est utilisée pour sa non-linéarité et sa capacité à éviter les erreurs de rétropropagation.

L'optimiseur Adam (Adaptive Moment Estimation) est employé avec un taux d'apprentissage par défaut de 0,001 et une décroissance de $1e^{-6}$. La taille du lot est fixée à 32, déterminée comme la solution optimale. Le nombre d'époques varie entre 60, 80, 100, 120, 140, et 160 pour améliorer le modèle. Le nombre d'époques sans amélioration dans la fonction de perte se situe entre 55 et 65 pour toutes les expériences. Le temps par époque varie de 72 à 76 secondes, avec une perte moyenne de 0,0677. Nous avons déterminé que le moment optimal pour arrêter l'entraînement est autour de l'époque 60, avec une précision élevée, une

durée réduite, et des pertes minimales. Les couches denses assurent une transformation des vecteurs 1D.

Tableau 4.2 Étude d’ablation sur les images HH et HL.

Métriques	Nombre de couches de convolution		Taux d'apprentissage		Taille du lot		Nombre de couches de convolution		Taux d'apprentissage		Taille du lot	
	1	2	0.01	0.005	16	64	1	2	0.01	0.005	16	64
Onde de Haar Niveau HH							Niveau de l'ondelette de Haar HL					
Précision	0.945	0.945	0.922	0.926	0.926	0.902	0.933	0.931	0.926	0.919	0.902	0.917
Précision	0.967	0.964	0.937	0.941	0.959	0.958	0.967	0.968	0.950	0.955	0.953	0.957
Rappel	0.969	0.972	0.971	0.971	0.951	0.922	0.955	0.950	0.964	0.946	0.929	0.941
Score F1	0.968	0.968	0.954	0.956	0.955	0.939	0.960	0.959	0.957	0.951	0.941	0.949
Ondelette Sym2 Niveau HH							Ondelette Sym2 Niveau HL					
Précision	0.937	0.957	0.930	0.919	0.919	0.917	0.940	0.943	0.946	0.943	0.949	0.941
Précision	0.961	0.965	0.944	0.944	0.955	0.943	0.972	0.968	0.969	0.957	0.953	0.960
Rappel	0.965	0.986	0.974	0.974	0.946	0.959	0.957	0.965	0.968	0.976	0.987	0.971
Score F1	0.963	0.975	0.959	0.959	0.951	0.951	0.965	0.966	0.951	0.67	0.970	0.965
Niveau HH de l'ondelette Coif2							Niveau HH de l'ondelette Coif2					
Précision	0.961	0.968	0.954	0.941	0.936	0.925	0.953	0.943	0.943	0.967	0.951	0.959
Précision	0.962	0.978	0.972	0.958	0.946	0.942	0.970	0.968	0.968	0.985	0.960	0.977
Rappel	0.993	0.986	0.975	0.973	0.978	0.971	0.975	0.965	0.965	0.976	0.983	0.975
Score F1	0.977	0.981	0.974	0.966	0.961	0.956	0.972	0.966	0.967	0.980	0.971	0.976
Niveau HH de l'ondelette Db2							Niveau HH de l'ondelette Db2					
Précision	0.957	0.960	0.952	0.967	0.950	0.954	0.960	0.947	0.956	0.965	0.951	0.956
Précision	0.965	0.975	0.966	0.986	0.966	0.961	0.966	0.972	0.981	0.948	0.959	0.976
Rappel	0.985	0.980	0.977	0.977	0.975	0.985	0.987	0.965	0.969	0.974	0.983	0.972
Score F1	0.975	0.977	0.972	0.981	0.971	0.973	0.976	0.968	0.974	0.979	0.971	0.974

Tableau 4.3 Hyperparamètres de l'architecture CNN profonde.

Couche (type)	Forme de la sortie (nombre de filtres)
Entrée	(None,200,200,3)
conv2d_1(Conv2D)	(None,200,200,3)
max_pooling2d_1(MaxPooling2D)	(Aucun,200,200,16)
conv2d_2(Conv2D)	(Aucun,100,100,16)
max_pooling2d_1 (MaxPooling2D)	(None,100,100,32)
conv2d_3 (Conv2D)	(Aucun, 50, 50, 32)
max_pooling2d_2 (MaxPooling2D)	(Aucun, 50, 50, 64)
dense_1 (Dense) + ReLU	(Aucun, 85)
dropout_1 (Dropout)	(Aucun, 50, 50, 64)
dense_2 (Dense)	(Aucune, 2)
Taille du lot	32
Taux d'apprentissage	0.001
Nombre d'époques	60

Les couches denses sont suivies de fonctions d'activation ReLU. La dernière couche dense ne spécifie pas de fonction d'activation, car les valeurs de logit sont utilisées, et la classification est réalisée à l'aide d'une fonction d'activation softmax.

Pour évaluer nos CNN proposés, nous les comparons en termes d'efficacité et de performance avec deux modèles largement utilisés, Efficient NetV2B0 et AlexNet. Tous les réseaux sont entraînés sur les mêmes ensembles de données pour assurer des comparaisons équitables.

4.6. Critères d'évaluation

Une comparaison détaillée entre les expériences 1 et 2 se concentre sur les indicateurs de performance tels que l'exactitude, la précision, le rappel, le F1-score et la classification. Ces mesures ont été évaluées en utilisant une matrice de confusion présentée dans le Tableau 4.4.

Tableau 4.4 Matrice de confusion binaire.

Matrice de Confusion	Réel A	Réel B
Prédiction A	XAA	XAB
Prédiction B	XBA	XBB

Dans ce contexte, la précision est définie comme le rapport entre le nombre d'observations correctement prédites et le nombre total d'observations (équation (4.2)).

$$\textit{Accuracy} = \frac{\sum TP + \sum TN}{\textit{Total Numbers Samples}} \quad (4.2)$$

Tels que :

TP représente le nombre d'images pour lesquelles une prédiction correcte a été faite pour une classe spécifique, tandis que TN représente le nombre d'images pour lesquelles une prédiction de classe sûre a été correctement rejetée. La précision est particulièrement efficace lorsque l'ensemble de données est symétrique et que les coûts associés aux faux positifs (FP) et aux faux négatifs (FN) sont similaires.

Cependant, en présence de coûts différents pour les négatifs (FP et FN), il est essentiel de prendre en compte à la fois la précision et la métrique Recall (équations (4.3) et (4.4)).

$$\textit{Precision} = \frac{\sum TP}{\sum TP + \sum FP} \quad (4.3)$$

$$\textit{Recall} = \frac{\sum TP}{\sum TP + \sum FN} \quad (4.4)$$

Le F1-score représente la moyenne pondérée de la précision et du rappel (équation (4.5)). Il est considéré comme la principale métrique à utiliser dans les situations où un équilibre entre la précision et le rappel est crucial, surtout en présence d'une distribution inégale des classes (équation (4.5)).

$$\textit{F1 - score} = 2 * \frac{\textit{Precision} * \textit{Recall}}{\textit{Precision} + \textit{Recall}} \quad (4.5)$$

L'évaluation de la performance de la classification se base sur la comparaison de la précision moyenne, du rappel, de la précision et du score F1, en utilisant le même ensemble de données de test et les méthodes de manipulation proposées. Ces mesures sont calculées à partir de la matrice de confusion pour les problèmes de classification binaire (c'est-à-dire une matrice 2x2). La matrice de confusion binaire offre des détails précis sur la performance du modèle, permettant de déterminer s'il peut efficacement différencier entre les classes et identifier des erreurs de prédiction spécifiques. Cette information peut guider des ajustements ou des améliorations du modèle. Les éléments de la matrice de confusion comprennent TP (vrais positifs), TN (vrais négatifs), FP (faux positifs) et FN (faux négatifs).

Les mesures de performance dérivées de cette matrice sont les suivantes : $rappel = [TP / (TP + FN)]$, $précision = [TP / (TP + FP)]$, $exactitude = [(TP + TN) / (TP + TN + FP + FN)]$, $score\ F1 = 2 [(précision \times rappel) / (précision + rappel)]$. Tous les résultats sont en moyenne sur l'ensemble de données de test. L'exactitude moyenne de la détection des détonateurs sur l'ensemble des échantillons indique combien de nos prédictions de détonateurs et de non-détonateurs sont correctes. Le rappel moyen indique combien d'échantillons de détonateurs sont prédits comme tels, et la précision moyenne montre combien de nos prédictions de détonateurs sont correctes.

4.7. Conclusion

En conclusion de ce chapitre, nous avons exploré les défis complexes associés à la détection d'objets dangereux, en particulier les détonateurs, dans les images radiographiques des bagages en soute d'avions. Nous avons identifié des obstacles majeurs, tels que la dissimulation habile des détonateurs et la difficulté accrue due à la faible résolution des images.

Notre objectif principal était d'introduire un schéma efficace de détection des détonateurs, en comparant diverses méthodes de traitement d'images et évaluant leur impact sur les performances des modèles de classification. Les expériences, menées avec une base de données de High Tech Detection Systems (HTDS), ont inclus des études d'ablation approfondies pour optimiser la configuration du modèle CNN profond que nous avons développé. Nous avons exploré différentes approches de prétraitement des images, telles que l'algorithme CLAHE, les transformations en ondelettes avec les sous-bandes HH et HL, ainsi qu'une combinaison de l'algorithme CLAHE et de la transformation en ondelettes RVB. Les performances de ces approches ont été analysées à travers diverses métriques.

Les résultats démontrent que notre modèle CNN profond est robuste et efficace pour la classification binaire des images radiographiques en détonateurs et non-détonateurs, surpassant d'autres modèles couramment utilisés. En somme, ce chapitre pose les bases de notre approche visant à améliorer la sécurité aérienne, en fournissant une plateforme pour nos futurs travaux axés sur la protection des passagers, de l'équipage, et des aéronefs contre les menaces potentielles.

Chapitre 5. Résultats et discussions

5.1. Introduction

Dans le cadre de cette thèse, notre exploration s'est concentrée sur la manière dont la manipulation de la qualité des images radiographiques aux rayons X peut générer une carte de caractéristiques permettant une discrimination améliorée des matériaux dangereux, tels que les détonateurs. Notre approche repose sur l'utilisation d'une architecture de réseau neuronal convolutif profond (CNN) implémentée avec les bibliothèques TensorFlow et Keras, exploitant la base de données fournie par les systèmes de détection de haute technologie (HTDS). Notre CNN profond se compose de deux classes distinctes, à savoir les détonateurs et les non-détonateurs. Pour éviter le surajustement, nous avons employé des techniques d'augmentation, aboutissant à un ensemble de données final de 15 115 échantillons, dont 4 535 ont été utilisés pour nos évaluations. La répartition entre les ensembles d'entraînement et de test a suivi une division aléatoire de 70/30. En raison de la rareté des échantillons initiaux, une validation croisée à cinq plis a été employée lors de l'entraînement sur les images radiographiques brutes, et la même architecture de CNN a été utilisée pour toutes les expériences.

Le Tableau 5.1 récapitule les performances de classification binaire pour l'ensemble de données d'images brutes, montrant une précision de classification de 0,9808. Toutes les prédictions des emplacements des détonateurs se sont avérées correctes.

Pour analyser l'impact de l'amélioration du contraste et de la transformation par ondelettes sur l'efficacité de la détection, nous avons examiné les performances de classification pour chaque approche proposée. La Figure 5.1 offre une représentation visuelle de l'amélioration de l'image radiographique par la méthode CLAHE, tandis que les résultats détaillés de cette méthode sont présentés dans le Tableau 5.2.

La méthode CLAHE a démontré une performance exceptionnelle, notamment sur les canaux vert et bleu, ainsi que sur les images RVB, atteignant une précision parfaite de 1,00. Ces valeurs surpassent celles des images radiographiques brutes (Tableau 5.1) de 1,92 %. Toutes les prédictions d'emplacement des détonateurs se sont révélées correctes pour les canaux G et B, ainsi que pour les images RVB. Bien qu'atteindre une précision de 100 % puisse sembler irréaliste, la méthode CLAHE a affiché d'excellentes performances.

Tableau 5.1 Résultat de la détection du CNN profond pour les images radiographiques brutes

	Exactitude	Classification	Précision	Rappel	Score- F1	Matrice de confusion
X-ray image original	0.9808	0	1.00	0.97	0.99	1344 37
		1	0.94	1.00	0.97	0 549

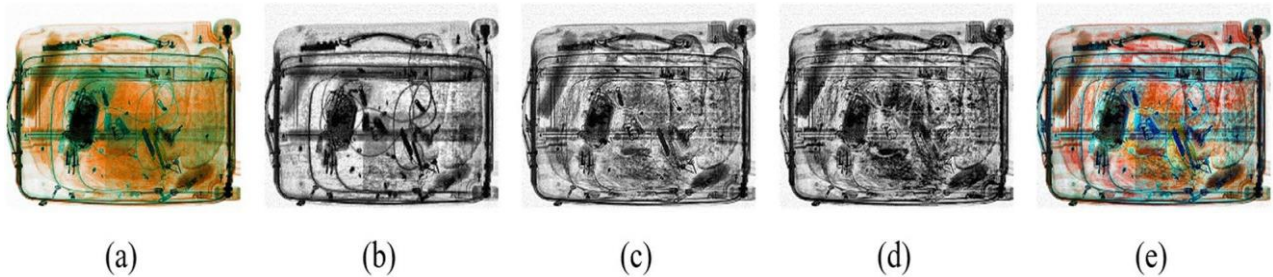


Figure 5.1 Amélioration CLAHE de l'image radiographique originale et ses résultats pour chaque canal de couleur d'une image RVB (a) original , (b) canal rouge , (c) canal vert , (d) canal bleu , (e) image RVB.

Tableau 5.2 Résultats de la détection obtenus par le CNN profond lors de l'utilisation de la méthode d'amélioration d'image CLAHE et de la décomposition des canaux de couleur.

CLAHE	Exactitude	Precision	Rappel	score F1	Matrice de confusion
Canal rouge	0.996	1.00	0.99	0.99	3766 17 0 550
Canal vert	1.00	1.00	1.00	1.00	3783 0 0 550
Canal bleu	1.00	1.00	1.00	1.00	3783 0 0 550
Image RGB	1.00	1.00	1.00	1.00	3783 0 0 550

L'introduction d'une amélioration potentielle de la discrimination par l'optimisation du contraste et de la qualité d'image, tout en minimisant la perte de détails, est perceptible. Cependant, il est à noter que le nombre d'échantillons TP (images avec détonateurs) est relativement réduit. Pour évaluer les impacts de la décomposition d'une image en un ensemble d'ondelettes et analyser les améliorations dans l'extraction des informations spectrales et temporelles locales, une décomposition d'image aux rayons X a été réalisée en utilisant les fonctions d'ondelettes Haar, Db2, Coif2 et Sym2. Les coefficients ou sous-bandes de détails HL et HH ont été particulièrement examinés. Les résultats sont illustrés dans la Figure 5.2, tandis que les détails relatifs aux performances de classification sont présentés dans le Tableau 5.3.

Observons que la fonction Coif2 au niveau HH a atteint une précision de 0,995, légèrement supérieure à Sym2 (0,994) et surpassant Db2 et Haar (0,990 et 0,986). Au niveau HL, la fonction Haar a obtenu une précision de 1,00 ; dépassant toutes les autres fonctions : Db2 (0,999), Coif2 (0,998) et Sym2 (0,995).




Figure 5.2 Analyse par transformation en ondelettes de l'image radiographique d'origine, avec les résultats spécifiques pour les sous-bandes HH et HL, par les fonctions d'ondelettes Daubechies2 (Db2), Haar, Coiflet2 (Coif2) et Symlet2 (Sym2).

Tableau 5.3 Résultats de la détection obtenus par le CNN profond pour les transformations en ondelettes appliquées aux sous-bandes HH et HL.

Niveau	Transformation en ondelette	Exactitude	Précision	Rappel	Score F1	Matrice de confusion
HH	Haar	0.986	1.00	0.98	0.99	3922 63 0 550
	Db2	0.990	0.99	0.98	0.99	3824 41 1 549
	Coif2	0.995	0.99	0.99	0.99	3824 1 19 531
HL	Haar	1.00	1.00	1.00	1.00	3952 0 0 549
	Db2	0.999	0.99	1.00	0.99	3951 1 0 549

	Coif2	0.998	0.99	0.99	0.99	4020 7 2 498
--	-------	-------	------	------	------	-----------------

De plus, les données du Tableau 4.3 montrent que les résultats de précision fournis par les transformations en ondelettes sont supérieurs à la précision obtenue lorsque les images radiographiques brutes sont directement alimentées dans le CNN (Tableau 5.1). Il est également noté que la transformée de Haar a une performance équivalente à la décomposition des canaux de couleur en termes de précision (100 %). Cependant, le nombre d'échantillons TP (images avec des détonateurs) est plus faible dans le cas de la décomposition des canaux RVB, tandis que le nombre d'échantillons TN (vrais négatifs) est similaire.

Lorsque les deux méthodes de transformation, CLAHE RVB et ondelettes, sont combinées, le résultat du prétraitement est illustré dans la Figure 5.3. Un résumé des performances de la classification est présenté dans le Tableau 5.4.




Figure 5.3 Prétraitement de l'image par CLAHE RVB suivi d'une transformation en ondelettes (sous-bandes HH et HL).

Tableau 5.4 Résultats de la détection du CNN profond pour les transformées en ondelettes appliquées aux sous bandes HH et HL.

Niveau	CLAHE RVB-ondelette	Exactitude	Précision	Rappel	Score F1	Matrice de confusion
HH	Haar	0.999	0.99	0.99	0.99	3645 1 1 548
	Sym2	0.992	0.99	1.00	0.99	3612 33 0 549
	Coif2	0.997	0.99	1.00	0.99	3633 13 0 549
	Db2	0.999	0.99	0.99	0.99	3640 6 1 548
HL	Haar	0.999	1.00	0.99	0.99	3651 0 3 547
	Coif2	0.999	0.99	0.99	0.99	3644 7 2 498
	Sym2	0.995	0.99	0.99	0.99	3640 11 6 494
	Db2	0.996	0.99	0.99	0.99	3651 0 4 550

On peut observer que l'ondelette de Haar au niveau HH a atteint une précision de 0,999, la plus élevée parmi les autres fonctions mères d'ondelettes, à savoir Db2 (0,999), Coif2 (0,997) et Sym2 (0,992). Pour le niveau HL, les ondelettes de Haar et Coif2 ont obtenu une précision de 0,999, ce qui est toujours le plus élevé par rapport à Db2 (0,996) et Sym2 (0,995).

En général, la précision de la classification obtenue avec la méthode CLAHE RVB-ondelette est significativement supérieure à celle obtenue pour les images radiographiques brutes, mais presque similaire aux résultats fournis par la décomposition en ondelettes. Nous soulignons une fois de plus que, bien que les mesures de performance aient de très bonnes valeurs, elles ne suffisent pas à indiquer une amélioration dans la détection des détonateurs. Dans le cas de la décomposition en ondelettes, le nombre d'échantillons TP (images avec des détonateurs) est plus élevé que dans le cas de la décomposition des canaux RVB ou de la transformation en ondelettes, tandis que le nombre de vrais négatifs (échantillons TN) est presque identique. Il y a un nombre insignifiant d'échantillons FN (c'est-à-dire une erreur de type II) dans la classification. Pour résumer les conclusions de notre étude, une statistique descriptive de la précision est fournie dans la Figure 5.4.

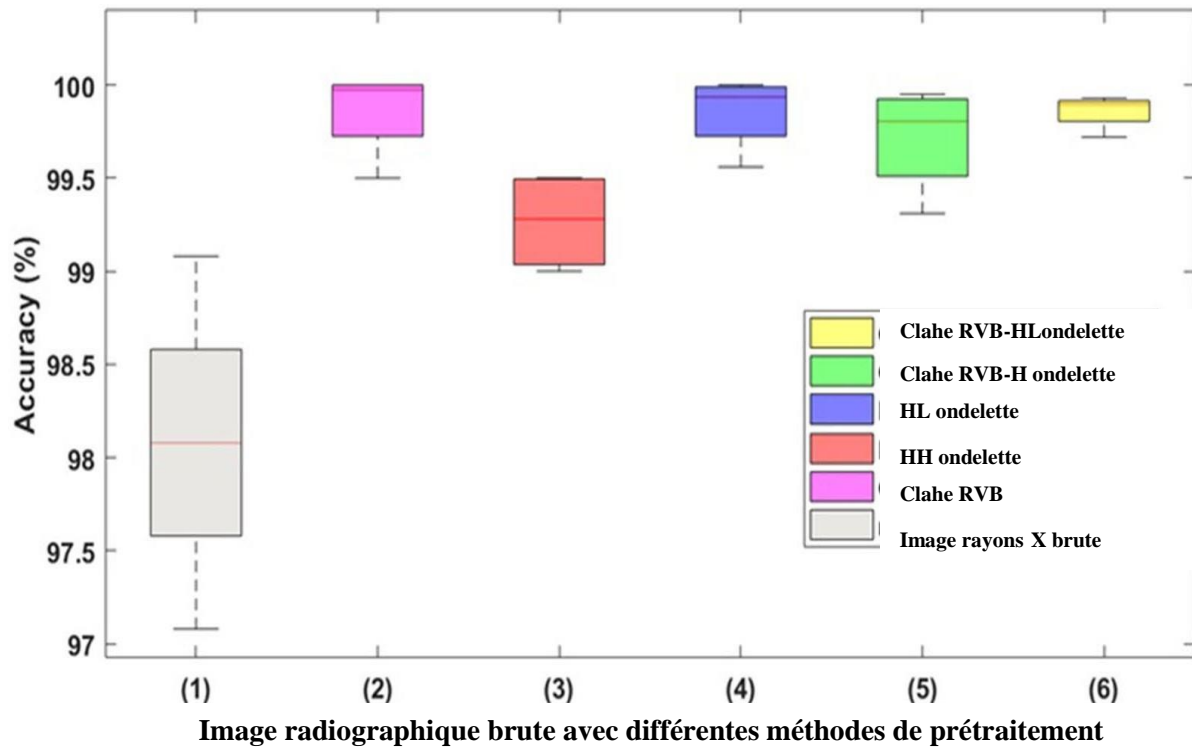


Figure 5.4 Performance de classification moyenne du CNN pour les images radiographiques brutes et les modèles de prétraitement suggérés.

5.2. Discussions

Bien que de nombreuses approches classiques d'amélioration du contraste aient été utilisées par d'autres chercheurs, notre contribution réside dans l'introduction des ondelettes comme méthode de manipulation pour obtenir des images à plus haute résolution et aux détails plus définis. Dans cette approche, nous avons examiné la précision de la détection lorsque des différences subtiles existent dans les détails de l'image, tels que les améliorations des contours, les modifications des informations de couleur, ou les différentes composantes de fréquence fournies par les transformations en ondelettes. Tous ces éléments peuvent être exploités pour différencier des caractéristiques presque similaires dans les images. Nos résultats démontrent une amélioration de la classification en exploitant les caractéristiques de haut niveau fournies par les transformations en ondelettes.

Un premier résultat clé présenté dans cet article est que la détection efficace de détonateurs peut être réalisée par des méthodes traditionnelles de traitement d'image, telles que la décomposition en ondelettes. Nous avons également démontré que la combinaison de techniques d'amélioration du contraste et de transformations en ondelettes de Haar au niveau de la sous-bande HL, associée à un modèle CNN profond, conduit à une amélioration significative du rappel (la capacité à identifier la classe positive, c'est-à-dire les images avec des détonateurs) et de la précision (l'exactitude des prédictions positives).

Les lignes centrales dénotent les valeurs minimales et maximales. Tant les images radiographiques brutes que celles traitées par ondelettes HL présentent une asymétrie nulle dans la distribution de la précision. Les autres méthodes exhibent des précisions avec une légère asymétrie négative. Globalement, les résultats les plus performants ont été obtenus avec la transformation en ondelettes de Haar dans la sous-bande HL, ainsi qu'avec la méthode CLAHE et les images RVB. Bien que les CNN profonds aient considérablement amélioré la classification d'images, nous reconnaissons que la qualité de l'image et la méthode de sous-échantillonnage par max-pooling peuvent altérer ou supprimer certaines caractéristiques cruciales pour la classification. Une étude d'ablation a été menée pour déterminer l'architecture et la configuration optimales de notre modèle CNN, mettant en évidence les performances du modèle dans différentes conditions. Altérer certaines composantes ou hyperparamètres a entraîné une diminution des performances du modèle, soulignant l'importance de l'architecture actuelle qui offre des performances optimales avec une faible complexité computationnelle.

Les transformations en ondelettes se sont avérées efficaces pour éliminer le bruit gaussien et extraire les détails des images. Les composantes HH et HL contiennent des représentations texturales de l'image originale, et en utilisant différentes composantes de fréquence et caractéristiques des canaux de couleur, nous avons pu extraire des informations plus informatives, améliorant ainsi la performance de la détection. La méthode CLAHE, en égalisant l'histogramme pixel par pixel, a amélioré le contraste et la qualité de l'image.

L'utilisation de différentes manipulations de l'image, telles que la méthode CLAHE RVB-Ondelette (sous-bandes HH et HL) et les transformations en ondelettes au niveau des sous-bandes HH et HL, a montré des faux négatifs et faux positifs. En revanche, les images traitées avec la méthode CLAHE RVB et l'ondelette de Haar (sous-bande HL) n'ont montré ni faux positifs ni faux négatifs. Les résultats préliminaires suggèrent que les méthodes CLAHE

& RVB, ainsi que la transformation en ondelettes de Haar appliquée à la sous-bande HL, sont particulièrement adaptées à l'identification des détonateurs par l'approche CNN. Les différences subtiles dans les résultats de la manipulation d'images dans la détection de détonateurs peuvent être expliquées par les diverses approches. L'amélioration du contraste fonctionne en utilisant la carte d'intensité des pixels, réduisant la perte de détails sans altérer la position des pixels dans l'image. CLAHE applique l'équilibrage des couleurs par ajustement de l'histogramme, tandis que les transformations en ondelettes considèrent la contribution de l'information spectrale et temporelle locale à l'extraction des contours. En somme, ces méthodes complémentaires offrent des perspectives variées pour améliorer la détection des détonateurs.

5.3. Résultats

En résumé, notre étude a révélé que l'ajout de tâches de prétraitement supplémentaires, notamment CLAHE-RVB-ondelette avec les sous-bandes HH et HL, n'a pas nécessairement conduit à une augmentation de la précision. Les sous-bandes de haute fréquence HH et HL ont préservé la plupart des informations, permettant au CNN de conserver davantage de caractéristiques et d'assurer une classification précise. Le Tableau 5.5 présente une comparaison des valeurs de précision obtenues dans notre travail par rapport à d'autres approches de classification et aux stratégies de détection basées sur des architectures de CNN profond, intégrant l'amélioration CLAHE et les transformations en ondelettes. Nous avons effectué ces comparaisons en utilisant deux modèles pré-entraînés, EfcientNetV2B0 et AlexNet, pour assurer des conditions équitables. Ces modèles ont été pré-entraînés sur la base de données ImageNet, contenant des millions d'images étiquetées. Nos résultats expérimentaux ont été comparés à des études antérieures utilisant des méthodes similaires mais avec différents types d'images et bases de données, en se concentrant principalement sur les mesures de précision. Cette approche nous a permis de situer nos performances dans le contexte de la littérature existante et de démontrer la robustesse de notre modèle dans la détection de détonateurs. Selon le nombre notable de faux positifs, avec une moyenne de 16. En revanche, l'EfcientNetV2B0 présente les performances les moins satisfaisantes, tandis que notre réseau les surpasse, indépendamment des manipulations d'images. Ces résultats mettent en évidence la robustesse de notre approche.

Bien qu'AlexNet affiche une précision élevée (0,9945), il génère un à ce stade, nos expériences sont plutôt des preuves de concept, mais elles suggèrent que notre idée pourrait

devenir réalité. Cependant, il est important de noter certaines limitations actuelles. Notre jeu de données était relativement restreint pour entraîner efficacement notre CNN. Bien que nous ayons utilisé l'augmentation des données pour lutter contre le surajustement, nous explorons également la capacité entropique de notre modèle CNN, c'est-à-dire la quantité d'informations qu'il peut stocker. L'architecture de notre CNN permet une grande capacité de stockage d'informations, renforçant ainsi son potentiel d'être plus précis en exploitant davantage de caractéristiques. Une autre limitation pourrait découler de la nature encombrée du jeu de données d'images aux rayons X, potentiellement entraînant une non-détection des détonateurs par le CNN. Cependant, nos résultats indiquent que le CNN est un outil précis, avec une occurrence insignifiante d'échantillons faux négatifs (voir Tableaux 5.3 et 5.4). Une étude future plus approfondie et complexe, incluant un plus grand nombre d'images, des tailles de bagages variées, l'extraction de caractéristiques spécifiques aux échantillons organiques, l'exploration d'autres types de réseaux neuronaux, etc., est prévue. De plus, l'extension de la recherche à la classification multi-classe, incluant d'autres objets dangereux dans les images aux rayons X tels que TNT, C4 et PBX (explosifs à liaison plastique en anglais), sera également envisagée.

Tableau 5.5 Analyse comparative des performances de notre proposition par rapport à d'autres travaux sur les architectures CNN issus de la littérature.

References	Image modality	Method	Accuracy
(Verma et al. 2021)	X-ray images	Wavelet based Deep CNN: the DWT featured sub-images are input to the CNN algorithm	0.9887
(Kusrini et al. 2022)	X-ray images	CNN the VGG16 learning architecture: CLAHE + RGB + Gaussian filter and thresholding images	0.9875
(Wu et al. 2023)	X-ray images	Wavelet transforms + contrastive learning + COVID-Net model	0.9355
(Hussein et al. 2022)	X-ray images	CLAHE, CNN	0.9100
Proposed work	X-ray images	CLAHE (Green channel + Blue channel + RGB image), Deep CNN	1.00
		Wavelet (HH-Haar-CLAHE RGB), Deep CNN	0.9995
		Wavelet (HH-Wavelet Coif2), Deep CNN	0.9950
		EfficientNetV2B0	0.9920
		AlexNet	0.9945

5.4. Conclusion

Dans ce chapitre nous avons mis en lumière l'efficacité d'une approche intégrée utilisant un réseau neuronal convolutif profond (CNN) avec des méthodes de prétraitement d'image telles que CLAHE et la transformation en ondelettes pour améliorer la détection de détonateurs dans des images radiographiques aux rayons X. Les résultats ont démontré une précision exceptionnelle, atteignant jusqu'à 100 %, surpassant ainsi d'autres approches de la littérature. Malgré des résultats prometteurs, des défis persistent, tels que la taille du jeu de données et la complexité des scénarios, ouvrant la voie à des recherches futures pour des améliorations continues. Ces conclusions suggèrent des applications potentielles significatives dans les domaines de la sécurité et de la détection d'objets dangereux.

Conclusion générale

Cette thèse s'est attelée au développement de la reconnaissance automatique des détonateurs dans les scanners de bagages, visant à influencer directement les performances des opérateurs humains confrontés aux risques potentiels d'erreurs d'interprétation ou d'inattention dans des environnements opérationnels.

L'objectif principal de cette recherche était de concevoir un système d'aide à la décision en appliquant des méthodes de vision artificielle et de reconnaissance d'objets aux images radiographiques des bagages. Cette approche a été comparée à différentes stratégies de vision par ordinateur proposées au cours des dernières années. L'objectif central était d'explorer les implications de diverses techniques d'amélioration d'image sur la détection automatique des détonateurs dans les images radiographiques à double énergie lors de l'inspection des bagages.

Les tâches exécutées au cours de cette étude comprenaient deux expériences distinctes utilisant l'architecture CNN profond avec les bibliothèques TensorFlow et Keras, basées sur la base de données de la société HTDS (High Tech Detection Systems). La première expérience a employé des images brutes de bagages à rayons X, tandis que la deuxième a intégré trois méthodes d'amélioration d'images : la méthode CLAHE, la méthode des transformations en ondelettes, et la méthode CLAHE RGB-Wavelet.

L'approche adoptée combinait une architecture de réseau neuronal convolutif profond (CNN) avec diverses méthodes de prétraitement d'image pour renforcer la capacité de discrimination. Cela incluait le choix d'une architecture CNN appropriée pour la classification binaire des images en détonateurs et non-détonateurs. Le modèle a été formé avec des données d'entraînement, suivi d'évaluations de performance à travers des tests. Les deux principales approches de prétraitement d'image étaient l'amélioration du contraste avec l'algorithme CLAHE et la décomposition des images par des transformations en ondelettes.

Les résultats ont révélé que l'amélioration du contraste grâce à CLAHE a atteint des performances remarquables, avec une précision de 100 % dans certaines configurations,

notamment dans les canaux vert et bleu des images RVB. De plus, la décomposition des images en sous-bandes de détails à l'aide de différentes fonctions d'ondelettes a significativement amélioré la détection, atteignant des précisions de 99,9 %. En combinant astucieusement CLAHE avec la transformation en ondelettes, des niveaux élevés de précision ont été obtenus pour la détection des détonateurs. Les résultats ont été comparés à d'autres approches de la littérature, démontrant la supériorité de notre méthode, avec une précision pouvant atteindre 100 % dans la détection des détonateurs.

Notre travail a clairement établi que l'association de méthodes de prétraitement d'image telles que CLAHE et la transformation en ondelettes, avec un CNN profond, peut considérablement améliorer la détection des détonateurs dans les images radiographiques. Ces résultats ouvrent des perspectives prometteuses pour des applications dans le domaine de la sécurité, notamment la détection d'objets dangereux tels que les explosifs et les détonateurs dans les bagages en soute.

Néanmoins, malgré la satisfaction et les perspectives prometteuses offertes par les résultats obtenus, cette étude présente quelques limitations. La taille restreinte du jeu de données et la complexité des scénarios représentent des défis, tout comme l'obtention d'informations exhaustives sur les systèmes commerciaux existants. De plus, la collecte de données se limitant à un petit ensemble de bagages provenant de HTDS suscite des interrogations quant à la généralisation des conclusions.

Pour les perspectives futures, les travaux à venir seront axés sur l'exploitation d'images à rayons X à double vue, l'adoption d'une nouvelle base 3D de scanners de bagages récemment déployée dans les aéroports, l'intégration d'ensembles de données plus vastes, et la considération d'objets dangereux supplémentaires. L'amélioration continue des méthodes de prétraitement d'image et l'exploration d'architectures de réseau neuronal hybrides demeureront également des axes de recherche prioritaires. Ces perspectives ouvrent la voie à des avancées significatives dans le domaine de la sécurité aéroportuaire et de la détection d'objets potentiellement dangereux.

Références bibliographiques

- Abdullah-Al-Wadud, M., Kabir, M., Dewan, M. & Chae, O. (2007). A Dynamic Histogram Equalization for Image Contrast Enhancement. *Consumer Electronics, IEEE Transactions on*, 53, 593-600. <https://doi.org/10.1109/TCE.2007.381734>
- Acharya, T. & Chakrabarti, C. (2006). A Survey on Lifting-based Discrete Wavelet Transform Architectures. *Journal of VLSI signal processing systems for signal, image and video technology*, 42 (3), 321-339. <https://doi.org/10.1007/s11266-006-4191-3>
- Akcay, S., Kundegorski, M.E., Devereux, M. & Breckon, T.P. (2016). Transfer learning using convolutional neural networks for object classification within X-ray baggage security imagery. *Proceedings of 2016 IEEE International Conference on Image Processing (ICIP)*, Phoenix, AZ, USA, septembre 2016. 1057-1061. IEEE. <https://doi.org/10.1109/ICIP.2016.7532519>
- Alwazzan, M.J., Ismael, M.A. & Ahmed, A.N. (2021). A Hybrid Algorithm to Enhance Colour Retinal Fundus Images Using a Wiener Filter and CLAHE. *Journal of Digital Imaging*, 34 (3), 750-759. <https://doi.org/10.1007/s10278-021-00447-0>
- Amir Movafeghi, Rokrok, B. & Yahaghi, E. (2020). Dual-energy X-ray Imaging in Combination with Automated Threshold Gabor Filtering for Baggage Screening Application. *Russian Journal of Nondestructive Testing*, 56 (9), 765-773. <https://doi.org/10.1134/S1061830920090065>
- Andrews, J.T.A., Jaccard, N., Rogers, T.W. & Griffin, L.D. (2017). Representation-learning for anomaly detection in complex x-ray cargo imagery. *Proceedings of Anomaly Detection and Imaging with X-Rays (ADIX) II*, mai 1 2017. 46-56. SPIE. <https://doi.org/10.1117/12.2261101>
- Arab, F., Daud, S.M. & Hashim, S.Z. (2013). Discrete Wavelet Transform Domain Techniques. *Proceedings of 2013 International Conference on Informatics and Creative Multimedia (ICICM)*, Kuala Lumpur, Malaysia, septembre 2013. 340-345. IEEE. <https://doi.org/10.1109/ICICM.2013.73>
- Arodzero, A., Alreja, V., Boucher, S., Burstein, P., Kulinich, P., Lanza, R.C., Palermo, V. & Tran, M. (2021). X-ray Backscatter Security Inspection with Enhanced Depth of Effective Detection and Material Discrimination. *Proceedings of 2021 IEEE Nuclear*

- Science Symposium and Medical Imaging Conference (NSS/MIC)*, octobre 2021. 1-4.
<https://doi.org/10.1109/NSS/MIC44867.2021.9875935>
- Aurangzeb, K., Aslam, S., Alhussein, M., Naqvi, R.A., Arsalan, M. & Haider, S.I. (2021). Contrast Enhancement of Fundus Images by Employing Modified PSO for Improving the Performance of Deep Learning Models. *IEEE Access*, 9, 47930-47945.
<https://doi.org/10.1109/ACCESS.2021.3068477>
- Basebi, T. & Thomas, R.M. (2003). A study of moving mesh methods applied to a thin flame propagating in a detonator delay element. *Computers & Mathematics with Applications*, 45 (1), 131-163. [https://doi.org/10.1016/S0898-1221\(03\)80012-3](https://doi.org/10.1016/S0898-1221(03)80012-3)
- BELDJOUDI (2011). *Approche multi-énergies associée à un détecteur spectrométrique rayons X pour l'identification de matériaux - TEL - Thèses en ligne.* (Thèse de Doctorat). <https://theses.hal.science/tel-00708579> [2023-09-06]
- Beldjoudi, G., Rebuffel, V., Verger, L., Kaftandjian, V. & Rinkel, J. (2012). An optimised method for material identification using a photon counting detector. *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, 663 (1), 26-36.
<https://doi.org/10.1016/j.nima.2011.09.002>
- Ben-Hur, A. & Weston, J. (2010). A User's Guide to Support Vector Machines. In: Carugo, O. & Eisenhaber, F. (éd.) *Data Mining Techniques for the Life Sciences*. Humana Press. 223-239. https://doi.org/10.1007/978-1-60327-241-4_13
- Chatterjee, R., Chatterjee, A., Islam, S.H. & Khan, M.K. (2022). An object detection-based few-shot learning approach for multimedia quality assessment. *Multimedia Systems*,
<https://doi.org/10.1007/s00530-021-00881-8>
- Chen, B., Cui, J., Xu, Q., Shu, T. & Liu, H. (2019). Coupling denoising algorithm based on discrete wavelet transform and modified median filter for medical image. *Journal of Central South University*, 26 (1), 120-131. <https://doi.org/10.1007/s11771-019-3987-9>
- Chouai, M., Merah, M., Sancho-Gómez, J.-L. & Mimi, M. (2020). Supervised feature learning by adversarial autoencoder approach for object classification in dual X-ray image of luggage. *Journal of Intelligent Manufacturing*, 31 (5), 1101-1112.
<https://doi.org/10.1007/s10845-019-01498-5>
- Chui, C.K. (1992). *An Introduction to Wavelets*. Academic Press.
- Dai, J., Li, Y., He, K. & Sun, J. (2016). R-FCN: Object Detection via Region-based Fully Convolutional Networks., 2016. Curran Associates, Inc.

- <https://proceedings.neurips.cc/paper/2016/hash/577ef1154f3240ad5b9b413aa7346a1e-Abstract.html> [2023-02-19]
- Danso, S., Liping, S., Hu, D., Odoom, J., Quancheng, L. & Mushtag, M. (2022). Security inspection image processing methods applying wavelet transform filters on terahertz active imageS. *Revista de Investigaciones Universidad del Quindío*, 34 (1), 37-51. <https://doi.org/10.33975/riuuq.vol34n1.853>
- Dmitruk, K., Denkowski, M., Mazur, M. & Mikołajczak, P. (2017). Sharpening filter for false color imaging of dual-energy X-ray scans. *Signal, Image and Video Processing*, 11 (4), 613-620. <https://doi.org/10.1007/s11760-016-1001-7>
- Elbeih, A. (2015). Characteristics of a New Plastic Explosive Named EPX-1. *Journal of Chemistry*, 2015, e861756. <https://doi.org/10.1155/2015/861756>
- Evans, P. (2005). Three-dimensional X-ray Imaging for Security Screening. *Security Journal*, 18. <https://doi.org/10.1057/palgrave.sj.8340188>
- Ewing, R.G., Clowers, B.H. & Atkinson, D.A. (2013). Direct Real-Time Detection of Vapors from Explosive Compounds. *Analytical Chemistry*, 85 (22), 10977-10983. <https://doi.org/10.1021/ac402513r>
- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27 (8), 861-874. <https://doi.org/10.1016/j.patrec.2005.10.010>
- Feltane, S. (2021). Etude de l'effet des travaux de tir a l'explosif autour d'une excavation souterraine – cas du tunnel d'ait yahia moussa / tizi ouzou. universite badji mokhtar – annaba badji.
- Gao, Q., Hong, R., Zhu, X. & Liu, X. (2021). An X-ray Image Enhancement Algorithm for Dangerous Goods in Airport Security Inspection. *Proceedings of 2021 Asia-Pacific Conference on Communications Technology and Computer Science (ACCTCS)*, Shenyang, China, janvier 2021. 43-46. <https://doi.org/10.1109/ACCTCS52002.2021.00017>
- Gaus, Y.F.A., Bhowmik, N., Akçay, S., Guillen-Garcia, P.M., Barker, J.W. & Breckon, T.P. (2019). Evaluation of a Dual Convolutional Neural Network Architecture for Object-wise Anomaly Detection in Cluttered X-ray Security Imagery. arXiv. <http://arxiv.org/abs/1904.05304> [2023-09-10]
- Georgieva, V., Kountchev, R. & Draganov, I. (2014). An Adaptive Enhancement of X-Ray Images. 79-88. <https://doi.org/10.1007/987-3-319-00029-9>
- Girshick, R., Donahue, J., Darrell, T. & Malik, J. (2016). Region-Based Convolutional Networks for Accurate Object Detection and Segmentation. *IEEE Transactions on*

- Pattern Analysis and Machine Intelligence*, 38 (1), 142-158.
<https://doi.org/10.1109/TPAMI.2015.2437384>
- Glavier, L. (2017). *Conception et développement d'un micro détonateur électrique intégrant des nanothermites pour l'amorçage par impact d'explosifs secondaires*. (phdthesis). Université Paul Sabatier - Toulouse III. <https://theses.hal.science/tel-01483791> [2023-09-12]
- Glavier, L., Nicollet, A., Jouot, F., Martin, B., Barberon, J., Renaud, L. & Rossi, C. (2017). Nanothermite/RDX-Based Miniature Device for Impact Ignition of High Explosives. *Propellants, Explosives, Pyrotechnics*, 42 (3), 308-317.
<https://doi.org/10.1002/prop.201600154>
- Grady, L., Singh, V., Kohlberger, T., Alvino, C. & Bahlmann, C. (2012). Automatic Segmentation of Unknown Objects, with Application to Baggage Security. Fitzgibbon, A., Lazebnik, S., Perona, P., Sato, Y., & Schmid, C. (éd.), Berlin, Heidelberg, 2012. 430-444. Springer. https://doi.org/10.1007/978-3-642-33709-3_31
- Griffin, L.D., Caldwell, M., Andrews, J.T.A. & Bohler, H. (2019). "Unexpected Item in the Bagging Area": Anomaly Detection in X-Ray Security Images. *IEEE Transactions on Information Forensics and Security*, 14 (6), 1539-1553.
<https://doi.org/10.1109/TIFS.2018.2881700>
- Guan, X., Jian, S., Hongda, P., Zhiguo, Z. & Haibin, G. (2009). An Image Enhancement Method Based on Gamma Correction. *Proceedings of 2009 Second International Symposium on Computational Intelligence and Design*, décembre 2009. 60-63.
<https://doi.org/10.1109/ISCID.2009.22>
- Gupta, P., Sinno, Z., Glover, J.L., Paulter, N.G. & Bovik, A.C. (2019). Predicting Detection Performance on Security X-Ray Images as a Function of Image Quality. *IEEE Transactions on Image Processing*, 28 (7), 3328-3342.
<https://doi.org/10.1109/TIP.2019.2896488>
- Haq, A.U., Li, J.P., Memon, M.H., Nazir, S. & Sun, R. (2018). A Hybrid Intelligent System Framework for the Prediction of Heart Disease Using Machine Learning Algorithms. *Mobile Information Systems*, 2018, 1-21. <https://doi.org/10.1155/2018/3860146>
- Hattenschwiler, N., Mendes, M. & Schwaninger, A. (2019). Detecting Bombs in X-Ray Images of Hold Baggage: 2D Versus 3D Imaging. *Human Factors*, 61 (2), 305-321.
<https://doi.org/10.1177/0018720818799215>
- High Tech Detection Systems (2023). *SÛRETÉ & DÉTECTION*. <https://www.htds.fr/> [2023-02-27]

- Hirtenberger Defence Systems (HDS) (2018). SOLUTIONS PYROTECHNIQUES DE POINTE. Membre du Groupe Hirtenberger. https://www.schaffler.org/wp-content/uploads/2018/09/HiFIRE_Brochure.pdf [2023-09-12]
- Howell, J. (2020). *Explosives: Portable X-Ray Imaging* / *LinkedIn*. <https://www.linkedin.com/pulse/explosives-portable-x-ray-imaging-john-howell/> [2023-09-10]
- HTDS (2019). *EasyTrayBack. 2019 HTDS - Tous droits réservés - Mentions légales - Protection des données personnelles - Français / Anglais - Réalisation NineteenGroupe*. <https://www.htds.fr/surete-detection/scanner-rayon-x/scanners-rx-conventionnel/easytrayback/> [2023-09-16]
- Hussein, F., Mughaid, A., AlZu'bi, S., El-Salhi, S.M., Abuhaija, B., Abualigah, L. & Gandomi, A.H. (2022). Hybrid CLAHE-CNN Deep Neural Networks for Classifying Lung Diseases from X-ray Acquisitions. *Electronics*, 11 (19), 3075. <https://doi.org/10.3390/electronics11193075>
- Jose, R. (2019). A Convolutional Neural Network (CNN) Approach to Detect Face Using Tensorflow and Keras. SSRN Scholarly Paper. <https://papers.ssrn.com/abstract=3599641> [2023-03-05]
- Josephus, C.S. & Remya, S. (2011). Multilayered Contrast Limited Adaptive Histogram Equalization Using Frost Filter. *Proceedings of 2011 IEEE Recent Advances in Intelligent Computational Systems*, septembre 2011. 638-641. <https://doi.org/10.1109/RAICS.2011.6069388>
- Kang, E., Min, junhong & Ye, J.C. (2017). Wavelet Domain Residual Network (WavResNet) for Low-Dose X-ray CT Reconstruction. arXiv. <http://arxiv.org/abs/1703.01383> [2023-02-10]
- Kong, N.S.P. & Ibrahim, H. (2011). Multiple layers block overlapped histogram equalization for local content emphasis. *Computers & Electrical Engineering*, 37 (5), 631-643. <https://doi.org/10.1016/j.compeleceng.2010.12.001>
- Kusrini, K., Arif, M., Yudianto, A. & al Fatta, H. (2022). The effect of Gaussian filter and data preprocessing on the classification of Punakawan puppet images with the convolutional neural network algorithm. *International Journal of Electrical and Computer Engineering*, 12, 3752-3761. <https://doi.org/10.11591/ijece.v12i4.pp3752-3761>
- Lalleman, A.-S., Ferrand, G., Rossé, B., Thfoin, I., Wrobel, R., Tabary, J., Billon Pierron, N., Mougel, F., Paulus, C. & Verger, L. (2011). A dual X-ray backscatter system for

- detecting explosives: Image and discrimination of a suspicious content. *Proceedings of 2011 IEEE Nuclear Science Symposium Conference Record*, octobre 2011. 299-304. <https://doi.org/10.1109/NSSMIC.2011.6154503>
- Larsen, K., Petersen, J.H., Budtz-Jørgensen, E. & Endahl, L. (2000). Interpreting Parameters in the Logistic Regression Model with Random Effects. *Biometrics*, 56 (3), 909-914. <https://doi.org/10.1111/j.0006-341X.2000.00909.x>
- Lin, T.-Y., Dollar, P., Girshick, R., He, K., Hariharan, B. & Belongie, S. (2017). Feature Pyramid Networks for Object Detection. *Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, HI, juillet 2017. 936-944. IEEE. <https://doi.org/10.1109/CVPR.2017.106>
- Liu, D., Liu, J., Yuan, P. & Yu, F. (2022). A Data Augmentation Method for Prohibited Item X-Ray Pseudocolor Images in X-Ray Security Inspection Based on Wasserstein Generative Adversarial Network and Spatial-and-Channel Attention Block. *Computational Intelligence and Neuroscience*, 2022, e8172466. <https://doi.org/10.1155/2022/8172466>
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C.-Y. & Berg, A.C. (2016). SSD: Single Shot MultiBox Detector. Leibe, B., Matas, J., Sebe, N., & Welling, M. (éd.), Cham, 2016. 21-37. Springer International Publishing. https://doi.org/10.1007/978-3-319-46448-0_2
- Majeed, S.H. & Isa, N.A.M. (2020). Iterated Adaptive Entropy-Clip Limit Histogram Equalization for Poor Contrast Images. *IEEE Access*, 8, 144218-144245. <https://doi.org/10.1109/ACCESS.2020.3014453>
- Majeed, S.H. & Isa, N.A.M. (2021). Adaptive Entropy Index Histogram Equalization for Poor Contrast Images. *IEEE Access*, 9, 6402-6437. <https://doi.org/10.1109/ACCESS.2020.3048148>
- Martin, C. (2017). *Initiation en détonation d'explosifs secondaires par des nanothermites : de la transition à la détonation d'un explosif secondaire nanométrique sous l'action d'une nanothermite à la transmission ultérieure de cette détonation à un explosif secondaire*. (phdthesis). Université de Strasbourg. <https://theses.hal.science/tel-01968044> [2023-09-12]
- Mekouar, M. (2002). Compression d'images médicales par ondelettes et régions d'intérêt (French text). 1. <https://www.elibrary.ru/item.asp?id=5249789> [2023-09-28]

- Mery, D., Svec, E. & Arias, M. (2016). Object Recognition in X-ray Testing Using Adaptive Sparse Representations. *Journal of Nondestructive Evaluation*, 35 (3), 45. <https://doi.org/10.1007/s10921-016-0362-8>
- Mishra, P.K., Bolic, M., Yagoub, M.C.E. & Stewart, R.F. (2012). RFID technology for tracking and tracing explosives and detonators in mining services applications. *Journal of Applied Geophysics*, 76, 33-43. <https://doi.org/10.1016/j.jappgeo.2011.10.004>
- Moldovanu, S., Damian Michis, F.A., Biswas, K.C., Culea-Florescu, A. & Moraru, L. (2021). Skin Lesion Classification Based on Surface Fractal Dimensions and Statistical Color Cluster Features Using an Ensemble of Machine Learning Techniques. *Cancers*, 13 (21), 5256. <https://doi.org/10.3390/cancers13215256>
- Montaha, S., Azam, S., Rafid, A.K.M.R.H., Ghosh, P., Hasan, M.Z., Jonkman, M. & De Boer, F. (2021). BreastNet18: A High Accuracy Fine-Tuned VGG16 Model Evaluated Using Ablation Study for Diagnosing Breast Cancer from Enhanced Mammography Images. *Biology*, 10 (12), 1347. <https://doi.org/10.3390/biology10121347>
- Montaha, S., Azam, S., Rafid, A.K.M.R.H., Hasan, Md.Z., Karim, A., Hasib, K.Md., Patel, S.K., Jonkman, M. & Mannan, Z.I. (2022). MNet-10: A robust shallow convolutional neural network model performing ablation study on medical images assessing the effectiveness of applying optimal data augmentation technique. *Frontiers in Medicine*, 9. <https://www.frontiersin.org/articles/10.3389/fmed.2022.924979> [2023-10-11]
- Naval Explosive Ordnance Disposal Technology Division (NAVEODTECHDIV) (1997). *Requirements Analysis and Technology Assessment for Portable Explosive Detectors*
- Nicoloso, J. (2014). *Combustion confinée d'explosif condensé pour l'accélération de projectile. Application en pyrotechnie spatiale.* (phdthesis). ISAE-ENSMA Ecole Nationale Supérieure de Mécanique et d'Aérotechnique - Poitiers. <https://theses.hal.science/tel-01060036> [2023-09-12]
- Oulhissane, L., Merah, M., Moldovanu, S. & Moraru, L. (2023). Enhanced detonators detection in X-ray baggage inspection by image manipulation and deep convolutional neural networks. *Scientific Reports*, 13 (1), 14262. <https://doi.org/10.1038/s41598-023-41651-y>
- Pant, S.R., Ghimire, D., Park, K. & Lee, J. (2014). A local technique for contrast preserving medical image enhancement. Ourselin, S. & Styner, M.A. (éd.) *Proceedings of SPIE Medical Imaging*, San Diego, California, USA, mars 21 2014. 90342H. <https://doi.org/10.1117/12.2042299>

- Pesquet-Popescu, B. & Pesquet, J.-C. (2001). Ondelettes et applications. *Le traitement du signal et ses applications*,. <https://doi.org/10.51257/a-v1-te5215>
- Pincu, R. & Kleinberger-Riedrich, O. (2012). A Review Digital Radiography in the Service of Security.
- Ponnusamy, V., Marur, D.R., Dhanaskodi, D. & Palaniappan, T. (2021). Deep Learning-Based X-Ray Baggage Hazardous Object Detection – An FPGA Implementation. *Revue d'Intelligence Artificielle*, 35 (5), 431-435. <https://doi.org/10.18280/ria.350510>
- Rahman, T., Khandakar, A., Qiblawey, Y., Tahir, A., Kiranyaz, S., Abul Kashem, S.B., Islam, M.T., Al Maadeed, S., Zughaier, S.M., Khan, M.S. & Chowdhury, M.E.H. (2021). Exploring the effect of image enhancement techniques on COVID-19 detection using chest X-ray images. *Computers in Biology and Medicine*, 132, 104319. <https://doi.org/10.1016/j.compbimed.2021.104319>
- Rao, K., Bansal, M. & Kaur, G. (2022). Retinex-Centered Contrast Enhancement Method for Histopathology Images with Weighted CLAHE. *Arabian Journal for Science and Engineering*, 47 (11), 13781-13798. <https://doi.org/10.1007/s13369-021-06421-w>
- Reagan Leoncio Galvez & Elmer Pamisa Dadios (2022). Threat object detection and analysis for explosive ordnance disposal robot. *Global Journal of Engineering and Technology Advances*, 11 (1), 078-087. <https://doi.org/10.30574/gjeta.2022.11.1.0074>
- Redmon, J., Divvala, S., Girshick, R. & Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. *Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, juin 2016. 779-788. IEEE. <https://doi.org/10.1109/CVPR.2016.91>
- Ren, S., He, K., Girshick, R. & Sun, J. (2017). Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39 (6), 1137-1149. <https://doi.org/10.1109/TPAMI.2016.2577031>
- da Rocha, D.A., Barbosa, A.B.L., Guimarães, D.S., Gregório, L.M., Gomes, L.H.N., da Silva Amorim, L. & Peixoto, Z.M.A. (2020). An unsupervised approach to improve contrast and segmentation of blood vessels in retinal images using CLAHE, 2D Gabor wavelet, and morphological operations. *Research on Biomedical Engineering*, 36 (1), 67-75. <https://doi.org/10.1007/s42600-019-00032-z>
- Rogers, T.W., Jaccard, N., Morton, E.J. & Griffin, L.D. (2016). Automated X-ray Image Analysis for Cargo Security: Critical Review and Future Promise. arXiv. <http://arxiv.org/abs/1608.01017> [2023-10-06]

- Saha, S. (2000). Image compression—from DCT to wavelets: a review. *XRDS: Crossroads, The ACM Magazine for Students*, 6 (3), 12-21. <https://doi.org/10.1145/331624.331630>
- Sanagavarapu, S., Sridhar, S. & Gopal, T.V. (2021). COVID-19 Identification in CLAHE Enhanced CT Scans with Class Imbalance using Ensembled ResNets. *Proceedings of 2021 IEEE International IOT, Electronics and Mechatronics Conference (IEMTRONICS)*, Toronto, ON, Canada, avril 2021. 1-7. <https://doi.org/10.1109/IEMTRONICS52119.2021.9422556>
- Sanchez-Montero, R., Martinez-Rojas, J.-A., Lopez-Espi, P.-L., Nuñez-Martin, L. & Diez-Jimenez, E. (2019). Filtering of Mammograms Based on Convolution with Directional Fractal Masks to Enhance Microcalcifications. *Applied Sciences*, 9 (6), 1194. <https://doi.org/10.3390/app9061194>
- Senthilkumaran, N. & Thimmiaraja, J. (2014). Histogram Equalization for Image Enhancement Using MRI Brain Images. *Proceedings of 2014 World Congress on Computing and Communication Technologies*, février 2014. 80-83. <https://doi.org/10.1109/WCCCT.2014.45>
- Shensa, M.J. (1992). The discrete wavelet transform: wedding the a trous and Mallat algorithms. *IEEE Transactions on Signal Processing*, 40 (10), 2464-2482. <https://doi.org/10.1109/78.157290>
- Singh, N. & Bhandari, A.K. (2020). Image contrast enhancement with brightness preservation using an optimal gamma and logarithmic approach. *IET Image Processing*, 14 (4), 794-805. <https://doi.org/10.1049/iet-ipr.2019.0921>
- Subramani, M., Rajaduari, K., Choudhury, S.D., Topkar, A. & Ponnusamy, V. (2020). Evaluating One Stage Detector Architecture of Convolutional Neural Network for Threat Object Detection Using X-Ray Baggage Security Imaging. *Revue d'Intelligence Artificielle*, 34 (4), 495-500. <https://doi.org/10.18280/ria.340415>
- Sun, F., Zhang, X., Liu, Y. & Jiang, H. (2022). Multi-Object Detection in Security Screening Scene Based on Convolutional Neural Network. *Sensors (Basel, Switzerland)*, 22 (20), 7836. <https://doi.org/10.3390/s22207836>
- Tao, R., Wei, Y., Jiang, X., Li, H., Qin, H., Wang, J., Ma, Y., Zhang, L. & Liu, X. (2021). Towards Real-World X-Ray Security Inspection: A High-Quality Benchmark and Lateral Inhibition Module for Prohibited Items Detection. *Proceedings of Proceedings of the IEEE/CVF International Conference on Computer Vision*, 2021. 10923-10932. https://openaccess.thecvf.com/content/ICCV2021/html/Tao_Towards_Real-World_X-

- Ray_Security_Inspection_A_High-Quality_Benchmark_and_Lateral_ICCV_2021_paper.html [2023-02-20]
- Taton, G. (2013). *Conception et réalisation d'un microsysteme d'initiation pyrotechnique intelligent et sécurisé pour applications spatiales*. (phdthesis). Université Paul Sabatier - Toulouse III. <https://theses.hal.science/tel-00989770> [2023-09-12]
- Tringe, J.W., Zellner, M.B., Mortensen, C.H., Gagliardi, F.J., Smith, J.A. & Champley, K.M. (2020). Dynamic three-dimensional observation of corner turning in LX-17 with flash x-rays. *Proceedings of shock compression of condensed matter - 2019: Proceedings of the Conference of the American Physical Society Topical Group on Shock Compression of Condensed Matter*, Portland, OR, USA, 2020. 060038. <https://doi.org/10.1063/12.0001040>
- Tuli, A., Bohra, R., Moghe, T., Chaturvedi, N. & Mery, D. (2020). Automatic Threat Detection in Single, Stereo (Two) and Multi View X-Ray Images., New Delhi, India., 2020. 1-7. <https://doi.org/10.1109/INDICON49873.2020.9342253>
- Verma, A.K., Vamsi, I., Saurabh, P., Sudha, R., G.r., S. & S., R. (2021). Wavelet and deep learning-based detection of SARS-nCoV from thoracic X-ray images for rapid and efficient testing. *Expert Systems with Applications*, 185, 115650. <https://doi.org/10.1016/j.eswa.2021.115650>
- Vogel, H. (2007). Search by X-rays applied technology. *European Journal of Radiology*, 63 (2), 227-236. <https://doi.org/10.1016/j.ejrad.2007.03.039>
- Wei, Y., Zhu, Z., Yu, H. & Zhang, W. (2021). An automated detection model of threat objects for X-ray baggage inspection based on depthwise separable convolution. *Journal of Real-Time Image Processing*, 18 (3), 923-935. <https://doi.org/10.1007/s11554-020-01051-1>
- Westminster (2022). *Scanner de courrier et de petits colis à rayons X WG IS5335*. Westminster Group Plc. <https://fr.wg-plc.com/product/wg-is5335-x-ray-mail-small-parcel-scanner> [2023-09-16]
- Wu, X., Kumar, V., Ross Quinlan, J., Ghosh, J., Yang, Q., Motoda, H., McLachlan, G.J., Ng, A., Liu, B., Yu, P.S., Zhou, Z.-H., Steinbach, M., Hand, D.J. & Steinberg, D. (2008). Top 10 algorithms in data mining. *Knowledge and Information Systems*, 14 (1), 1-37. <https://doi.org/10.1007/s10115-007-0114-2>
- Wu, Y., Dai, Q. & Lu, H. (2023). COVID-19 diagnosis utilizing wavelet-based contrastive learning with chest CT images. *Chemometrics and Intelligent Laboratory Systems*, 236, 104799. <https://doi.org/10.1016/j.chemolab.2023.104799>

- Yasar, H. & Ceylan, M. (2021). A new deep learning pipeline to detect Covid-19 on chest X-ray images using local binary pattern, dual tree complex wavelet transform and convolutional neural networks. *Applied Intelligence*, 51 (5), 2740-2763. <https://doi.org/10.1007/s10489-020-02019-1>
- Yu, H., Li, X., Lou, Q., Lei, C. & Liu, Z. (2020). Underwater image enhancement based on DCP and depth transmission map. *Multimedia Tools and Applications*, 79 (27), 20373-20390. <https://doi.org/10.1007/s11042-020-08701-3>
- Yu, L., Li, B. & Jiao, B. (2019). Research and Implementation of CNN Based on TensorFlow. *IOP Conference Series: Materials Science and Engineering*, 490 (4), 042022. <https://doi.org/10.1088/1757-899X/490/4/042022>
- Zentai, G. (2008). X-ray imaging for homeland security. *Proceedings of 2008 IEEE International Workshop on Imaging Systems and Techniques*, Chania, Greece, septembre 2008. 1-6. <https://doi.org/10.1109/IST.2008.4659929>
- Zhang, Q., Zhang, H. & Lu, X. (2022). Adaptive Feature Fusion for Small Object Detection. *Applied Sciences*, 12 (22), 11854. <https://doi.org/10.3390/app122211854>
- Zhang, Y., Jin, R. & Zhou, Z.-H. (2010). Understanding bag-of-words model: a statistical framework. *International Journal of Machine Learning and Cybernetics*, 1 (1), 43-52. <https://doi.org/10.1007/s13042-010-0001-0>
- Zhou, Y., Panetta, K. & Agaian, S. (2010). CT baggage image enhancement using a combination of alpha-weighted mean separation and histogram equalization. Agaian, S.S. & Jassim, S.A. (éd.) *Proceedings of SPIE Defense, Security, and Sensing*, Orlando, Florida, avril 23 2010. 77080G. <https://doi.org/10.1117/12.849587>

ملخص

يُعد اكتشاف الأجسام الخطرة من نوع المتفجرات في الأمتعة المسجلة تحديًا حاسمًا لتقليل المخاطر المتعلقة بالأعمال الإجرامية والهجمات الإرهابية. تنشأ هذه التعقيدات غالبًا من التمييز الدقيق لهذه الأجسام الخطرة، مما يجعل تحديها أمرًا صعبًا. المتفجرات، على وجه الخصوص، نادرة، وصعبة التمييز، وقد تأخذ أشكالًا متنوعة، بما في ذلك المحرضات، التي يمكن أن تختلط بسهولة بالكتل العضوية الغير ضارة. يواجه أفراد أمن المطارات تحدي فحص حجم كبير من الصور الشعاعية بالأشعة السينية، مما يؤدي إلى الإجهاد والتعب وانخفاض التركيز. أمام هذه التحديات، يمكن للنكاه الاصطناعي (IA) أن يقدم مساعدة قيمة في اكتشاف المحرضات، حتى في وجود صور ذات جودة منخفضة. تركز هذه الدراسة على اكتشاف المحرضات في الصور الشعاعية للأمتعة باستخدام تصميم عميق للتعليم: شبكة النيورال العصبية التكاملية العميقة (CNN) (profond). تم استكشاف نهجين: الأول باستخدام صور شعاعية خام بطاقة مزدوجة، والثاني يشمل معالجة الصور. تم تطبيق ثلاث طرق مدرية مسبقًا: CLAHE، التحول بواسطة الموجات مع وظائف الأم Haar، Daubechies2 (Db2)، Symlet2 (Sym2)، و Coiflet2 (Coif2)، بالإضافة إلى الطريقة المختلطة CLAHE RGB-التحول بواسطة الموجات. أظهرت أداء الصور المعالجة مسبقًا تفوقًا واضحًا على الصور الخام. أثبتت طرق المعالجة المسبقة الأكثر فعالية، التي وصلت إلى معدل دقة 100٪، أنها CLAHE (القناة الخضراء إلى الرمادي، القناة الزرقاء إلى الرمادي، وقنوات RGB)، وكذلك تحول الموجات مع وظيفة الأم Haar على مستويين HL.

كلمات مفتاحية

اكتشاف، تصنيف، محرض، الشبكة العصبية التكاملية العميقة، معالجة مسبقة، صورة بالأشعة السينية.

Abstract

Detecting potentially explosive objects in checked baggage is a crucial challenge for minimizing risks associated with criminal acts and terrorist attacks. This complexity often arises from the careful concealment of these hazardous items, making their identification challenging. Explosives, in particular, are rare, difficult to discern, and can take various forms, including detonators that may be mistaken for harmless organic masses. Airport security agents face the daunting task of examining a large volume of X-ray radiographic images, leading to stress, fatigue, and decreased attention.

In response to these challenges, artificial intelligence (AI) can provide valuable assistance in detecting detonators, even in the presence of low-quality images. This study focuses on detonator detection in radiographic images of baggage using a deep learning architecture: the Deep Convolutional Neural Network (CNN). Two approaches were explored: the first utilizing raw dual-energy radiographic images, and the second involving image pre-processing. Three pre-trained methods were applied: CLAHE, wavelet transformation with mother functions Haar, Daubechies2 (Db2), Symlet2 (Sym2), and Coiflet2 (Coif2), as well as the mixed method CLAHE RGB-wavelet transformation.

The performance of pre-processed images clearly surpassed that of raw images. The most effective pre-processing methods, achieving a precision rate of 100%, were found to be CLAHE (Green Channel to Gray, Blue Channel to Gray, and RGB Channels), as well as wavelet transformations with the Haar mother function at two levels HL.

Keywords

Detection, classification, detonator, deep CNN, pre-processing, X-ray image.

Résumé

La détection d'objets dangereux de type explosif dans les bagages en soute représente un défi crucial pour minimiser les risques liés aux actes criminels et aux attaques terroristes. Cette complexité découle souvent du camouflage soigneux de ces objets dangereux, rendant leur identification difficile. Les explosifs, en particulier, sont rares, difficiles à discerner, et peuvent prendre diverses formes, y compris les détonateurs, qui peuvent être confondus avec des masses organiques inoffensives. Les agents de sécurité aéroportuaire sont confrontés à l'examen d'un grand volume d'images radiographiques à rayons X, engendrant stress, fatigue, et une baisse d'attention.

Face à ces défis, l'intelligence artificielle (IA) peut fournir une assistance précieuse dans la détection des détonateurs, même en présence d'images de qualité médiocre. Cette étude se penche sur la détection des détonateurs dans les images radiographiques des bagages en utilisant une architecture d'apprentissage profond : le CNN profond. Deux approches ont été explorées : la première utilisant des images radiographiques brutes à double énergie, et la seconde impliquant un prétraitement d'image. Trois méthodes pré-entraînées ont été appliquées : CLAHE, la transformation en ondelettes avec les fonctions mères Haar, Daubechies2 (Db2), Symlet2 (Sym2), et Coiflet2 (Coif2), ainsi que la méthode mixte CLAHE RGB-transformée en ondelettes.

Les performances des images prétraitées ont clairement surpassé celles des images brutes. Les méthodes de prétraitement les plus efficaces, atteignant un taux de précision de 100 %, se sont avérées être CLAHE (Canal Vert en Gris, Canal Bleu en Gris, et Canaux RGB), ainsi que les transformations en ondelettes avec la fonction mère Haar à deux niveaux HL.

Mots clés

Détection, classification, détonateur, CNN profond, prétraitement, image à rayon X.