

Combinaison ontologie et satisfaction de contraintes pour la reconnaissance d'objets dans des images satellitaires haute résolution

Zouhayra Ayadi*, Ali Ayadi***
Maguelonne Teisseire** Cédric Wemmert***

*LIRMM, Univ. Montpellier, CNRS,
Montpellier 34090, France
zouhaira.ayadi@umontpellier.fr,

**TETIS, Univ. Montpellier, AgroParisTech, CIRAD, CNRS, INRAE,
Montpellier 34090, France
maguelonne.teisseire@inrae.fr

***ICube UMR 7357 Université de Strasbourg, CNRS,
67412 Illkirch-Graffenstaden, Strasbourg, France
ali.ayadi@unistra.fr
wemmert@unistra.fr

Résumé. Avec l'urbanisation croissante et la complexité des infrastructures modernes, la reconnaissance d'objet complexe dans les images satellitaires à haute résolution spatiale représente un défi majeur, notamment en milieu urbain. Les méthodes basées sur l'apprentissage profond, bien que puissantes, nécessitent souvent de grands jeux de données annotées et peinent à modéliser les relations spatiales et contextuelles complexes entre les objets urbains. Cet article propose une approche hybride en deux niveaux qui associe des ontologies évolutives aux problèmes de satisfaction de contraintes (CSP) pour modéliser des objets complexes, tout en améliorant l'efficacité de leur résolution grâce à une méthode combinant FAC-3, le backjumping et l'optimisation par essaims de particules (PSO). L'objectif principal est d'améliorer la reconnaissance d'objets complexes en modélisant simultanément les relations spatiales et sémantiques tout en optimisant l'exploration des solutions possibles. Les CSPs capturent les contraintes spatiales, FAC-3 réduit l'espace de recherche, et PSO évite les minima locaux, améliorant ainsi l'efficacité globale de la recherche. La formalisation de l'ontologie, des CSPs et leur traduction en règles SWRL, ainsi que leur utilisation, sont détaillées. Enfin, une application illustrative de la reconnaissance d'objets urbains complexes est présentée.

1 Introduction

La reconnaissance d'objets complexes, notamment en milieu urbain, est un enjeu majeur dans divers domaines tels que l'urbanisme, la gestion des infrastructures et la surveillance environnementale. L'urbanisation rapide et le développement des villes intelligentes compliquent

L'identification des objets complexes, tels que les ports, aéroports ou îlots urbains, dans les images satellitaires en raison de relations spatiales et contextuelles multiples souvent sujettes à des incertitudes. Leur modélisation et détection exigent une prise en compte des caractéristiques individuelles et de leur agencement spatial, une tâche qui s'avère complexe. Les approches classiques, notamment celles basées sur l'apprentissage automatique et les réseaux neuronaux, bien que performantes, nécessitent de grandes quantités de données annotées manuellement, un processus coûteux et chronophage. De plus, elles peinent à intégrer des connaissances sur les relations spatiales entre les objets, limitant leur application aux objets complexes nécessitant des connaissances préalables. Les CSPs et les ontologies constituent une alternative prometteuse dans ce contexte. Les CSPs modélisent les objets complexes via leurs relations spatiales et les contraintes définies, tandis que les ontologies les structurent dans un cadre de connaissances formel et extensible. Nous proposons une approche hybride combinant CSP et ontologie évolutive pour relever ces défis. Nos principales contributions sont les suivantes :

- Définition d'un cadre hybride CSP-Ontologie pour la reconnaissance d'objets complexes, combinant contraintes flexibles, relations spatiales et contextuelles ;
- Exploration hybride CSP-PSO combinant les méthodes CSP classiques avec PSO pour optimiser la résolution du réseau de contrainte et éviter les minima locaux ;
- Transférabilité des contraintes grâce à une flexibilité accrue, permettant la reconnaissance de nouveaux types d'objets sans redéfinition manuelle complète ;
- Modélisation explicite des relations spatiales et contextuelles des objets complexes, améliorant la précision de la reconnaissance dans des environnements urbains denses et hétérogènes.

1.1 Originalité

L'approche EvRSO-CSP se distingue par l'intégration de multiple techniques pour la reconnaissance d'objets complexes dans les images satellitaires. Contrairement aux méthodes traditionnelles, elle combine l'exploration globale de solutions via PSO avec la validation locale via CSP, le tout dans le cadre d'une ontologie dynamique. Ses principales innovations comprennent :

- Le capture des variations spatiales grâce à des ontologies dynamiques et évolutives qui, contrairement aux ontologies statiques, permettent l'adaptation aux nouvelles informations issues des images satellitaires ;
- L'intégration des CSPs aux ontologies pour modéliser explicitement les objets urbains et leurs interactions spatiales et contextuelles ;
- L'utilisation de PSO pour explorer efficacement l'espace de recherche, tandis que CSP assure la validation locale, optimisant les solutions et améliorant la précision ;
- L'amélioration de la flexibilité et de la transférabilité en détectant des objets auparavant invisibles grâce à des contraintes flexibles, éliminant ainsi le besoin de réentraînement ou de redéfinition manuelle.

1.2 Motivations et gap de recherche

Les méthodes traditionnelles basées sur l'apprentissage profond et les CSPs statiques sont confrontées à des limites majeures face à la complexité des objets complexes. Bien qu'efficaces

dans l'extraction de caractéristiques, ces méthodes ne parviennent pas à capturer explicitement les relations spatiales et contextuelles essentielles à la reconnaissance des objets. Les approches actuelles manquent de flexibilité à identifier de nouveaux types d'objets dans des environnements dynamique, en raison du coût et du temps requis pour réentraîner les modèles. Par ailleurs, peu de méthodes modélisent simultanément des relations sémantiques de haut niveau et des relations spatiales entre les objets, un défi que l'intégration des CSPs et des ontologies pourrait relever, mais qui reste sous-exploitée. Notre méthode hybride EvRSO-CSP propose une solution robuste et flexible, parfaitement adaptée aux environnements urbains dynamique, en surmontant les limites de calcul et de modélisation des approches traditionnelles.

2 État de l'art

La reconnaissance d'objets complexes dans les images satellitaires a suscité un intérêt croissant ces dernières années, avec une évolution des approches, passant des méthodes traditionnelles basées sur des règles aux techniques avancées d'apprentissage profond.

Des approches basées sur des règles et des ontologies aux méthodes d'apprentissage automatique. Les premières méthodes de reconnaissance d'objets reposaient sur des règles définies manuellement pour décrire des caractéristiques telles que la forme, la couleur et la texture, ainsi que leurs relations spatiales (Blaschke et al., 2014). Bien que ces approches soit interprétables et permettent une formalisation explicite des connaissances, elles manquaient de flexibilité face aux variations des scènes et des objets. De plus, la subjectivité inhérente à la définition des règles de détection limitait davantage leur efficacité. Pour remédier à ces limites, les ontologies ont offert une approche plus formelle, modélisant les objets et leurs relations, et se sont révélées utiles pour la détection d'objets (Ruiz-Sarmiento et al., 2015; Ennouri et al., 2021). Cependant, les ontologies statiques montrent leurs limites dans des environnements dynamiques ou incertains, étant incapables de capturer les changements des objets ou de leurs relations, et ainsi d'optimiser la détection dans des conditions incertaines. Durant cette dernière décennie, les approches basées sur l'apprentissage profond ont dominé la détection d'objets en télédétection grâce à leur capacité à extraire des caractéristiques visuelles à la fois de bas et de haut niveau (Zhang et al., 2019; Gao et al., 2024; Zhang et al., 2024). Ces méthodes apprennent automatiquement des représentations pertinentes à partir de grandes bases de données, mais exigent des volumes considérables de données étiquetées. Cette exigence rend leur mise en œuvre coûteuse et gourmande en ressources, un défi important en imagerie satellitaire, où les données étiquetées sont souvent rares.

CSP et reconnaissance d'objets. Les CSPs ont été appliqués dans divers domaines, notamment la médecine (Goodarzian et al., 2021), la bioinformatique (Ruffini et al., 2019) et la reconnaissance d'objets. En télédétection, des méthodes de résolution complètes, telles que l'AC3 et le backtracking, ont été appliquées pour relever des défis complexes de détection (Vane-gas et al., 2016; Ayadi et al., 2023). Bien qu'efficaces, ces méthodes souffrent d'une convergence lente ou de minima locaux dans des cas complexes, ce qui les rend inadéquates aux problèmes à grande échelle. En revanche, les méthodes incomplètes, basées sur des recherches locales et des métaheuristiques, fournissent des solutions rapides sans explorer tout l'espace. Leur

complémentarité a suscité un intérêt croissant pour l'hybridation, et de nombreuses approches combinant CSP et métaheuristiques se sont révélées utiles (Nanivadekar et Kolekar, 2022; Xue et al., 2019; Åstrand et al., 2020). Dans ce contexte, nous visons à combiner FAC-3, PSO et le backjumping.

Approches hybrides CSP-ontologie. L'intégration des CSPs et des ontologies offre une solution prometteuse pour la reconnaissance d'objets, notamment en imagerie satellitaire. Les ontologies permettent de formaliser les relations sémantiques à différents niveaux d'abstraction, tandis que les CSPs gèrent les contraintes spécifiques entre attributs ou concepts. Ensemble, elles fournissent un cadre robuste, alliant la flexibilité des ontologies à la capacité des CSPs à gérer les contraintes. Plusieurs travaux ont exploré cette hybridation. Récemment, Amini et al. (2021) a combiné les ontologies et les CSPs pour raisonner explicitement sur les contraintes pour la reconnaissance d'objets. S'appuyant sur ces idées, notre article propose une approche hybride innovante associant CSP et ontologie pour la reconnaissance d'objets urbains complexes dans des images satellitaires à haute résolution, tirant parti des avantages de ces deux techniques.

3 Approche hybride proposée CSP-Ontologie

3.1 Aperçu de l'approche hybride proposée

L'architecture proposée intègre plusieurs techniques innovantes. Elle combine une ontologie évolutive modélisant les objets et leurs relations avec des CSPs pour résoudre les problèmes de reconnaissance d'objets complexes. De plus, une méthode hybride de résolution de CSP a été développée, intégrant le PSO, le backjumping et FAC-3, permettant la gestion efficace des contraintes tout en optimisant les processus de reconnaissance d'objets. Comme illustré dans la figure 1, l'architecture générale commence par un processus de segmentation, qui extrait les objets simples et leurs caractéristiques à partir d'images satellitaires. Ces caractéristiques alimentent une ontologie dynamique, représentant des objets complexes, leurs propriétés et leurs relations spatiales. Le module CSP modélise le réseau de contraintes sous forme d'un triplet (X, D, C) en fonction des objets détectés et de leurs relations. Il résout les contraintes en se basant sur une méthode hybride combinant la propagation de contraintes (FAC-3) et le backjumping pour réduire l'espace de solutions, tandis que PSO optimise l'exploration de cet espace. L'architecture intègre la gestion des contraintes floues pour traiter l'incertitude et l'imprécision, proposant des solutions flexibles adaptées aux données imprécises.

3.2 Segmentation de l'image et extraction des caractéristiques

Ce module segmente les images satellitaires en deux étapes principales pour identifier les objets simples. D'abord, l'algorithme mean-shift multi-échelle divise l'image en segments correspondant à ces objets. Ensuite, leurs caractéristiques, telles que la forme, la couleur et la texture, sont extraites et associées aux objets définis dans l'ontologie.

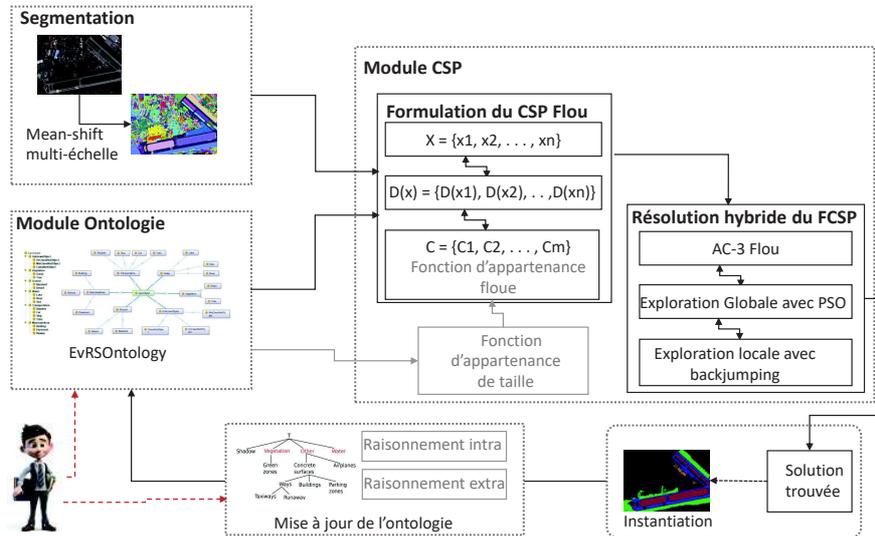


FIG. 1 – Aperçu de l'approche hybride CSP-Ontologie.

3.3 Modélisation et mise à jour de l'ontologie

3.3.1 Modélisation ontologique

L'ontologie évolutive, nommée *EvRSOntology* pour "*evolutive remote sensing ontology*", accessible via ce lien¹, est conçue pour l'interprétation d'images satellitaires, en particulier pour la détection d'objets complexes. *EvRSOntology*, définie en OWL, comprend environ 50 concepts répartis en trois couches (définies ci-dessous) et plus de 100 propriétés. Elle inclut également environ 200 instances générées à partir des objets identifiés dans les images. La sémantique dans *EvRSOntology* se compose de quatre parties :

- **Concepts** : catégories abstraites d'objets (e.g. *Infrastructure de transport* inclut *Gare*, *Port*, etc.). Chaque classe correspond à une catégorie d'objets complexes, subdivisée en sous-classes dédiées aux objets spécifiques et à leurs composants ;
- **Propriétés** : expriment les caractéristiques inhérentes des objets et définissent les relations spatiales et sémantiques entre les différentes classes. Les relations spatiales incluent les relations topologiques et métriques, tandis que les relations sémantiques couvrent les connexions hiérarchiques et compositionnelles ;
- **Entités** : instances de concepts représentant les objets simples directement détectables dans une image satellitaire. Par exemple, une instance de *Eau* pourrait être *Mer*. Chaque entité correspond à une classe spécifique et se voit attribuer des propriétés pour décrire ses relations avec d'autres entités ;
- **Règles d'inférence** : développées pour améliorer la détection d'objets (e.g., "Un aéroport doit nécessairement contenir des pistes, des terminaux et des parkings").

1. <https://github.com/ayadi90zou/EvRSOntology/>.

Ontologie et satisfaction de contraintes pour la reconnaissance d'objets

Pour implémenter *EvSOntology*, nous adoptons une approche hybride descendante (top-down) et ascendante (bottom-up) Nasri et al. (2018). Dans l'approche descendante, les concepts principaux sont définis par des catégories génériques, puis affinés en sous-catégories basées sur des objets urbains identifiables. Dans l'approche ascendante, les segments extraits d'images satellitaires alimentent les instances de l'ontologie, qui sont ensuite regroupées pour enrichir les relations et les règles de correspondance. *EvSOntology* est structurée en trois couches :

1. La *couche d'abstraction du domaine* définit les objets à un niveau général et abstrait. Elle regroupe des concepts généraux représentant des objets complexes. Chaque catégorie correspond à une classe générique d'objets urbains complexes (e.g., *erso : Infrastructure urbaine*, *erso : Infrastructure de transport* sont des sous-classes de *erso : CompGeoObject*);
2. La *couche de collection des catégories* organise les objets géographiques en sous-classes plus spécifiques (e.g., *Aéroport* et *Port* appartiennent à la classe *Infrastructure de transport*);
3. La *couche des objets composants simples* représente les composants de base observés dans les images satellitaire (e.g., *erso : Pistes* et *erso : Parkings*).

Nous introduisons une classe *erso : autreObjet* pour les nouveaux objets détectés par le CSP qui ne correspondent à aucune des classes existantes. Cette structure en couches prend en charge le raisonnement automatique, permettant à *EvSOntology* d'évoluer et d'affiner sa structure pour une meilleure reconnaissance d'objets complexes. Ces couches sont interconnectées par des relations de composition et d'appartenance, formant une hiérarchie qui facilite la navigation descendante, des concepts abstraits aux instances détaillées. Les relations spatiales et hiérarchiques des objets complexes identifiés sont exploitées pour vérifier leur cohérence avec les règles "sûres" définies en SWRL.

3.3.2 Évolution ontologique

EvSOntology est une ontologie évolutive qui intègre de nouveaux objets détectés par CSP via deux types de raisonnement inspirés de Li et al. (2022) : (1) *Le raisonnement intra-taxonomique* enrichit les catégories existantes en ajoutant de nouvelles informations sur des objets similaires ou légèrement différents des objets déjà connus. Ce raisonnement s'applique lorsque les nouveaux objets détectés appartiennent à des classes déjà présentes dans *EvSOntology*. (2) *Le raisonnement extra-taxonomique* intervient lorsque l'objet détecté ne correspond à aucune des classes existantes. Il permet d'identifier de nouveaux objets et de les ajouter comme nouvelles classes dans *EvSOntology*. Ces raisonnements permettent de maintenir une ontologie évolutive s'adaptant aux nouvelles informations fournies par les images satellitaires ou par des règles, pour une flexibilité maximale dans la représentation des objets et de leurs relations.

3.4 Module CSP

Ce module est au cœur de notre approche et se déroule en deux étapes clés : (1) modélisation des réseaux de contraintes et (2) résolution du FCSP. Chaque étape est détaillée ci-dessous.

3.4.1 Formulation du problème CSP

A cette étape, le problème de reconnaissance est modélisé par un réseau de contraintes flou, sous la forme d'un triplet (X, D, C_f) , où :

- $X = \{x_1, x_2, \dots, x_n\}$ représente les objets simples (sous-composants) de l'objet complexe à identifier, modélisés par la troisième couche de l'ontologie ;
- $D(x_i)$ contient les valeurs possibles pour chaque variable, correspondant à différents segments pour chaque objet simple, issus de la segmentation de l'image ;
- $C = \{C_1, C_2, \dots, C_m\}$ est l'ensemble des contraintes floues, où chaque contrainte C_i est associée à une fonction de satisfaction floue. Ces contraintes correspondent aux relations spatiales et contextuelles modélisées dans l'ontologie.

Dans le FCSP (Vanegas et al., 2016), chaque contrainte C_i est représentée par une fonction $\mu_{C_i} : D(x_i) \times D(x_j) \rightarrow [0, 1]$, mesurant le degré de satisfaction entre deux variables x_i and x_j (tableau 1). Une valeur proche de 1 indique une satisfaction élevée. Ces contraintes reposent sur des relations spatiales floues (Vanegas et al., 2012) modélisées par EvSOntology, quantifiant des relations comme la topologie ou le parallélisme. À l'exception du parallélisme, prenant en compte le paysage et l'orientation, les autres relations sont modélisées par des paysages flous définissant des zones de satisfaction imprécises par rapport à l'objet de référence. Une fonction d'appartenance floue calcule la moyenne du degré de satisfaction sur les pixels de l'objet cible.

Relations spatiales	Degré de satisfaction
"a st proche de b"	$\mu_{\text{proche}}(a, b) = \frac{1}{ a } \sum_{q \in a} \gamma_b^{\text{proche}}(q)$ - $\gamma_b^{\text{proche}}(q)$ est la fonction d'appartenance qui mesure la proximité du pixel q de "a" à "b", $ a $: nombre total de pixels dans la région de "a".
"a adjacent à b"	$\mu_{\text{adjacent}}(a, b) = \mu_{\text{int}}(\delta_\nu(a), b)$ - $\delta_\nu(a)$ est la dilatation morphologique floue de "a", qui étend les limites de "a", μ_{int} mesure l'intersection entre les régions $\delta_\nu(a)$ et "b".
"a est parallèle à b"	$\mu_{\text{parallèle}}(a, b) = 1 - \theta_a - \theta_b $ - θ_a et θ_b sont les angles d'orientation de "a" et "b".
relation d'alignement	$\mu_{\text{alignement}}(G) = \frac{1}{ G } \sum_{i \in G} \gamma_{\text{aligné}}(d_i)$ - d_i : la distance ou l'angle entre i et la ligne d'alignement attendue.

TAB. 1 – Relations spatiales et leurs degré de satisfaction respectifs.

3.4.2 Résolution hybride CSP-PSO

Nous proposons une approche hybride intégrée qui combine les atouts des algorithmes CSP, PSO, et du backjumping adaptatif. Le processus comprend les étapes suivantes :

1. Initialisation du PSO : commence par initialiser l'algorithme PSO, où chaque particule représente une solution potentielle, en assignant les variables X à des valeurs dans leurs domaines respectifs $D(x_i)$. Plus précisément, chaque particule représente une configuration possible des variables du CSP, correspondant à une affectation complète des valeurs aux variables. Elle n'est considérée comme solution finale que lorsqu'elle a été optimisée pour satisfaire les contraintes.

2. Intégration FAC-3 : Avant de faire évoluer les particules, l'algorithme FAC-3 est appliqué localement pour réduire les domaines de variables en éliminant les incohérences. Pour chaque

contrainte C_i entre les variables (x_i, x_j) , nous ajustons le domaine pour garantir que toutes les valeurs respectent C_i :

$$D(x_i) \leftarrow D(x_i) \setminus \{v \in D(x_i) \mid \forall u \in D(x_j), \neg C(x_i, x_j)\}$$

Cela affine l'espace de recherche pour chaque particule.

3. Exploration globale avec PSO : PSO explore l'ensemble de l'espace des solutions, ajustant la position et la vitesse de chaque particule selon sa meilleure solution locale et la meilleure solution globale de l'essaim. Les mises à jour s'effectuent comme suit :

$$v_{i(t+1)} = w \cdot v_{i(t)} + c_1 \cdot r_1 \cdot (p_{best,i} - x_{i(t)}) + c_2 \cdot r_2 \cdot (g_{best} - x_{i(t)})$$

$$x_{i(t+1)} = x_{i(t)} + v_{i(t+1)}$$

où : $v_i(t)$ est la vitesse de la particule i à l'instant t ; $p_{best,i}$ est la meilleure position précédemment trouvée par la particule i ; g_{best} est la meilleure position globale trouvée par l'essaim; r_1 et r_2 sont des variables aléatoires; w , c_1 , et c_2 sont des coefficients d'inertie et d'accélération. Ce processus permet aux particules d'explorer l'espace de recherche, guidées par leurs positions passées et les solutions optimales identifiées par l'essaim. PSO minimise une fonction de coût qui mesure progressivement les violations de contraintes, exprimée comme suit :

$$f(\mathbf{x}) = \sum_{C_i \in C} \delta(C_i(\mathbf{x}))$$

où $\delta(C_i(\mathbf{x}))$ représente le degré de violation de la contrainte C_i , prenant une valeur entre 0 (satisfait) et 1 (violé). Bien que PSO fournisse une exploration globale, les particules peuvent se retrouver piégées dans des solutions sous-optimales où certaines contraintes sont violées. Pour y remédier, l'algorithme backjumping est utilisé afin d'affiner les solutions et d'échapper aux minima locaux.

4. Amélioration locale avec backjumping : Backjumping améliore la recherche en permettant à l'algorithme de revenir directement à la source du conflit, évitant l'exploration inutile de sous-espaces déjà exclus, contrairement au backtracking classique. Le processus de backjumping se déroule comme suit :

1. *Détection du conflit* : si une particule rencontre une solution où une contrainte floue C_i est violée, cela indique un conflit;
2. *Retour à la variable en conflit* : au lieu de réinitialiser la variable précédente, l'algorithme revient à la variable en conflit x_k et réajuste ses valeurs;
3. *Correction locale* : seules les variables impliquées dans la violation sont réajustées, réduisant le temps de calcul et améliorant l'efficacité de la recherche.

Cette approche améliore la convergence en limitant l'exploration des zones de l'espace de recherche nécessitant des ajustements, améliorant ainsi l'efficacité de la recherche.

4 Application illustrative

Cet exemple simplifié illustre notre approche en la mettant en pratique pour détecter l'objet "aéroport". Nous le modélisons grâce à *EvSOntology*, puis nous définissons et traduisons les contraintes en règles SWRL, en nous concentrant que sur les contraintes spatiales. Enfin, la méthode hybride est appliquée pour résoudre le problème.

Modélisation ontologique de l'aéroport. Dans cet exemple, "Aéroport" est une classe de *EvSontology* et est composée des objets simples suivants : zone-verte, surfaces-concrètes regroupant les objets parkings et/ou pistes, et bâtiments regroupant les objets terminal, hangars et tours de contrôle. Les instances de chaque classe correspondent aux régions obtenues lors de la segmentation des images satellitaires.

Réseau de contrainte et règles SWRL. Le CSP flou correspondant est formulé comme suit :

- $X = \{x_T : *, x_B : *, x_R : *, x_{GA} : *\}$, où x_T : Terminal, x_B : Bâtiment, x_R : Piste, x_{GA} : Zone-verte ;
- $C = \{C_{direction}, C_{adjacent}, C_{proche}, C_{entourer1}, C_{entourer2}\}$, où $\langle C_{direction} = \mu_{direction}^{45^\circ}, \{x_B, x_R\}\rangle, \langle C_{adjacent} = \mu_{adjacent}, \{x_T, x_R\}\rangle, \langle C_{proche} = \mu_{proche}, \{x_B, x_T\}\rangle, \langle C_{entourer1} = \mu_{entourer1}, \{x_{GA}, x_T\}\rangle, \langle C_{entourer2} = \mu_{entourer2}, \{x_{GA}, x_R\}\rangle$;
- $D = \{D_T, D_B, D_R, D_{GA}\}$, où D_i représente les candidats possibles pour x_i .

Soit les domaines initiaux et les deux contraintes de l'exemple (tableau 2). Tableau 3 presente

Domaines initiaux	Zone-verte (GA) : {R1}	Cont.							
	Bâtiment (B) : {R3, R6} Terminal (T) : {R2, R5}	entourer				adjacent			
		Objet 1	R1	R1	R1	R1	R2	R3	R6
	Piste (R) : {R4, R7}	Objet 2	R2	R3	R5	R6	R4	R7	R4

TAB. 2 – Domaines initiaux et contraintes spatiales.

les règles intégrant les propriétés des objets, les relations spatiales et les contraintes, formalisées dans l'ontologie grâce à SWRL. La contrainte "entourer" est basée sur les règles $R1$ et $R2$, tandis que "adjacent" est basée sur $R3$ et $R4$. $R5$ met à jour l'ontologie et peut être interprété comme suit : si un bâtiment a une hauteur moyenne ET a une forme verticale ET est proche d'une piste à une distance de 500 m ET est loin d'autres bâtiments ET est dans une direction de 45 degrés par rapport à la piste ALORS c'est une tour de contrôle et est ajouté comme une nouvelle sous-classe de bâtiment.

Résolution du CSP. Chaque particule PSO représente une combinaison possible de variables dans leurs domaines. Le FAC-3 réduit ces domaines en éliminant la valeur $R5$ (voir tableau 4). Par conséquent, la particule 3 n'est plus valide et sera rejetée.

Calcul du coût pour chaque particule : Les particules évoluent ajustant leur position et vitesse selon les meilleures solutions locales et globales, puis sont évaluées en fonction des deux contraintes (tableau 2). Les évaluations sont présentés dans tableau 5.

Évaluation des particules : Après plusieurs itérations du PSO, les particules convergent vers les meilleures solutions possibles (tableau 6). Backjumping n'a détecté aucun conflit.

5 Conclusion and travaux futurs

Ce travail propose une approche hybride combinant ontologie et CSP pour la reconnaissance d'objets complexes dans des images satellitaires à haute résolution. L'objectif est de modéliser

Ontologie et satisfaction de contraintes pour la reconnaissance d'objets

Règle	Description
R1	Si un objet est de type <i>Bâtiment</i> et est entouré d'un objet de type <i>Zone-verte</i> , alors il peut appartenir à l'objet complexe <i>Aéroport</i> . $Building(?b) \wedge GreenArea(?ga) \wedge isSurrounded(?b, ?ga) \rightarrow Airport(?b)$
R2	Si un objet <i>Bâtiment</i> est un <i>Terminal</i> et est entouré par une <i>Zone-verte</i> , alors ils peuvent composer l'objet complexe <i>Aéroport</i> . $Building(?b) \wedge Terminal(?b) \wedge GreenArea(?ga) \wedge isSurrounded(?b, ?ga) \rightarrow Airport(?b)$
R3	Si un objet est un <i>Bâtiment</i> , est entouré par une <i>Zone-verte</i> , et est adjacent à une <i>Piste</i> , alors il est certain qu'il compose l'objet complexe <i>Aéroport</i> . $Building(?b) \wedge GreenArea(?ga) \wedge isSurrounded(?b, ?ga) \wedge Runway(?r) \wedge isAdjacent(?b, ?r) \rightarrow Airport(?b)$
R4	Si un objet de type <i>Bâtiment</i> est un <i>Terminal</i> , est entouré par une <i>Zone-verte</i> , et est adjacent à une <i>Piste</i> , alors il est certain qu'il compose l'objet complexe <i>Aéroport</i> . $Building(?b) \wedge Terminal(?b) \wedge GreenArea(?ga) \wedge isSurrounded(?b, ?ga) \wedge Runway(?r) \wedge isAdjacent(?b, ?r) \rightarrow Airport(?b)$
R5	Si un objet est de type <i>Bâtiment</i> , a une taille moyenne, a une forme verticale, est proche d'une <i>Piste</i> à une distance de 500 mètres, est loin d'autres <i>Bâtiments</i> et est dans une direction de 45° par rapport à la piste, alors c'est une <i>Tour de contrôle</i> . $Building(?b) \wedge hasSize(?b, "medium") \wedge hasShape(?b, "vertical") \wedge Runway(?r) \wedge isNear(?b, ?r, 500) \wedge isfar(?b, true) \wedge isInDirection(?b, ?r, 45) \rightarrow ControlTower(?b)$

TAB. 3 – Règles SWRL.

Particules initiales	Domaines après FAC-3
P1 : $x_{GA} = R1, x_R = R2, x_B = R4$	Zone-verte : {R1}
P2 : $x_{GA} = R1, x_B = R3, x_B = R7$	Terminal : {R2}
P3 : $x_{GA} = R1, x_B = R5, x_B = R7$	Bâtiment : {R3, R6}
P4 : $x_{GA} = R1, x_B = R6, x_B = R4$	Piste : {R4, R7}

TAB. 4 – Particules initiales et domaines après FAC-3.

les relations spatiales et contextuelles entre les objets à l'aide d'une ontologie évolutive, tout en utilisant le CSP pour résoudre les contraintes associées. L'ontologie structure les objets à différents niveaux d'abstraction, facilitant la reconnaissance d'objets nouveaux ou mal définis. Cependant, elle ne gère pas des contraintes complexes, telles que les relations spatiales strictes ou les interactions entre objets. Pour surmonter ces limites, nous intégrons le CSP pour formaliser et résoudre ces contraintes. FAC-3 réduit l'espace de recherche, tandis que PSO évite les minima locaux et améliore l'efficacité du processus de reconnaissance. Certaines limites subsistent, notamment concernant la gestion des contraintes complexes et des relations multi-variables. Bien que notre méthode puisse intégrer de nouvelles données dans l'ontologie, des outils supplémentaires sont nécessaires pour traiter des cas plus complexes de manière plus efficace. Pour les travaux futurs, nous prévoyons d'enrichir l'ontologie afin d'inclure non seulement des objets urbains, mais également d'autres objets complexes en télédétection. Nous envisageons d'intégrer un raisonnement temporel pour mieux gérer et interpréter les changements spatio-temporels. Enfin, des expérimentations plus approfondies seront menées pour démontrer la

	Particule 1	Particule 2	Particule 4
Certitude_Entourer	0.9	0.8	0.9
Certitude_Adjacent	0.9	0.9	0.7
Coût	0.2	0.3	0.4

TAB. 5 – Évaluation des particules basée sur le calcul de fitness.

Domaines		Solutions finales			
Zone-verte : {R1}	Particule	Val. GA	Val. Bâtiment	Val. Piste	Fitness
Terminal : {R2}	P1	R1	R2	R4	0.1
Bâtiment : {R6}	P2	R1	R3	R7	0.2
Piste : {R4, R7}	P4	R1	R6	R4	0.3

TAB. 6 – Domaines après itérations et solutions finales.

robustesse et la scalabilité de notre approche hybride dans divers scénarios et avec des jeux de données variés.

Références

- Amini, M. M., T. Coudert, E. Vareilles, et M. Aldanondo (2021). Integration of ontologies and constraint satisfaction problems for product configuration. In *2021 International Conference on Industrial Engineering and Engineering Management (IEEM)*, pp. 578–582. IEEE.
- Åstrand, M., M. Johansson, et A. Zanarini (2020). Underground mine scheduling of mobile machines using constraint propagation and neighborhood search. *Computers & Operations Research* 23, 13–36.
- Ayadi, Z., W. Boulila, et I. R. Farah (2023). Modeling complex object changes in satellite image time-series. *Procedia Computer Science* 225, 2467–2476.
- Blaschke, T., G. J. Hay, M. Kelly, S. Lang, P. Hofmann, E. Addink, R. Q. Feitosa, F. Van der Meer, F. Van Coillie, et al. (2014). Geographic object-based image analysis—towards a new paradigm. *International Society for Photogrammetry & Remote Sensing* 87, 180–191.
- Ennouri, K., S. Smaoui, et M. A. Triki (2021). Detection of urban and environmental changes via remote sensing. *Circular Economy and Sustainability* 1(4), 1423–1437.
- Gao, Y., Y. Wang, Y. Zhang, Z. Li, C. Chen, et H. Feng (2024). Feature super-resolution fusion with cross-scale distillation for small object detection in optical remote sensing images. *IEEE Geoscience and Remote Sensing Letters* 159, 26–29.
- Goodarzian, F., S. F. Wamba, K. Mathiyazhagan, et A. Taghipour (2021). A new bi-objective green medicine supply chain network design under fuzzy environment : Hybrid metaheuristic algorithms. *Computers & industrial engineering* 160, 107535.

- Li, Y., S. Ouyang, et Y. Zhang (2022). Combining deep learning and ontology reasoning for remote sensing image semantic segmentation. *Knowledge-based system* 36, 10–46.
- Nanivadekar, S. S. et U. D. Kolekar (2022). A hybrid optimization model for resource allocation in ofdm-based cognitive radio system. *Evolutionary Intelligence* 15(2), 825–836.
- Nasri, B., H. Nefzi, et M. Farah (2018). Towards a hybrid approach for remote sensing ontology construction. In *2018 4th International Conference on Advanced Technologies for Signal and Image Processing (ATSIP)*, pp. 1–5. IEEE.
- Ruffini, M., J. Vucinic, S. de Givry, G. Katsirelos, S. Barbe, et T. Schiex (2019). Guaranteed diversity & quality for the weighted constraint satisfaction problem. In *2019 IEEE 31st international conference on tools with artificial intelligence (ICTAI)*, pp. 18–25. IEEE.
- Ruiz-Sarmiento, J.-R., C. Galindo, et J. Gonzalez-Jimenez (2015). Scene object recognition for mobile robots through semantic knowledge and probabilistic graphical models. *Expert Systems with Applications* 42(22), 8805–8816.
- Vanegas, M. C., I. Bloch, et J. Inglada (2012). Alignment and parallelism for the description of high-resolution images. *IEEE Transaction on Geoscience & remote sensing* 51(6), 42–57.
- Vanegas, M. C., I. Bloch, et J. Inglada (2016). Fuzzy constraint satisfaction problem for model-based image interpretation. *Fuzzy Sets and Systems* 286, 1–29.
- Xue, Z., Z. Chen, T. Ji, M. Li, et Q. Wu (2019). Estimation of low frequency oscillation parameters using singular value decomposition combined group search optimizer. *Electric Power Components and Systems* 47(3), 275–287.
- Zhang, Y., Y. Yuan, Y. Feng, et X. Lu (2019). Hierarchical and robust convolutional neural network for very high-resolution remote sensing object detection. *IEEE Transaction on Geosciences and Remote Sensing* 57(8), 35–48.
- Zhang, Z., S. Mei, M. Ma, et Z. Han (2024). Adaptive composite feature generation for object detection in remote sensing images. *Transactions on Geoscience & remote sensing* 159, 16–19.

Summary

With increasing urbanization and the complexity of modern infrastructures, recognizing complex objects in high and very high spatial resolution satellite images has become a major challenge, especially in urban environments. Deep learning-based methods, while powerful, often require large annotated datasets and struggle to model the complex spatial and contextual relationships between urban objects. This paper proposes a dual-level hybrid approach that integrates evolving ontologies with Constraint Satisfaction Problems (CSP) to model complex objects, while improving their resolution efficiency through a method combining FAC-3, back-jumping and particle swarm optimization (PSO). The main objective is to improve complex object recognition by simultaneously modeling spatial and semantic relationships while optimizing the exploration of possible solutions. CSP captures spatial constraints, FAC-3 reduces the search space, and PSO avoids local minima, enhancing overall search efficiency. The formalization of the ontology, CSPs and their translation into SWRL rules, as well as their use, are detailed. Finally, an illustrative application of complex urban object recognition is presented.