

**Mai 2026**

**Yasmine CHAIBEN**

# **Adaptive Pods Positioning Solution Based on Reception Context and Vehicle Movement**



**Université  
Gustave Eiffel**



# **Projet Pods4Rail : enjeux et défis du positionnement GNSS**

# Projet Pods4Rail – Développement d'un nouveau système de mobilité

## Lancé en septembre 2023

- Collaboration entre 15 partenaires de 7 pays européens.

## Concept de transport innovant

- Système de mobilité digitalisé et décentralisé.
- Solutions de transport flexibles et autonomes pour les personnes et les marchandises.

## Mobilité à la demande

- Déplacements fluides entre plusieurs modes de transport, notamment le rail et la route.
- Contribution à un réseau de transport plus efficace, intelligent et connecté.

FA7  
**Pods**  
4 RAIL





**ESSENTIELLE  
POUR**



Le suivi en temps réel des pods autonomes



La fiabilité et la sécurité du transport




L'information et l'assistance aux passagers




## ❌ Défis et limitations du GNSS dans différents environnements


Environnement urbain



Environnement végétal




Environnement fermé (Tunnels..)





Pour répondre à ces exigences et garantir des performances optimales dans des environnements variés, la capacité des **algorithmes de positionnement** à s'adapter au contexte devient essentielle.



Le **Machine Learning (ML)** constitue un outil puissant permettant une **classification précise** et une **meilleure adaptation** des algorithmes de positionnement selon le contexte environnemental.



**S'ADAPTER**  
aux environnements  
variés



**AMÉLIORER**  
la précision du  
positionnement



**RENFORCER**  
la robustesse du  
système



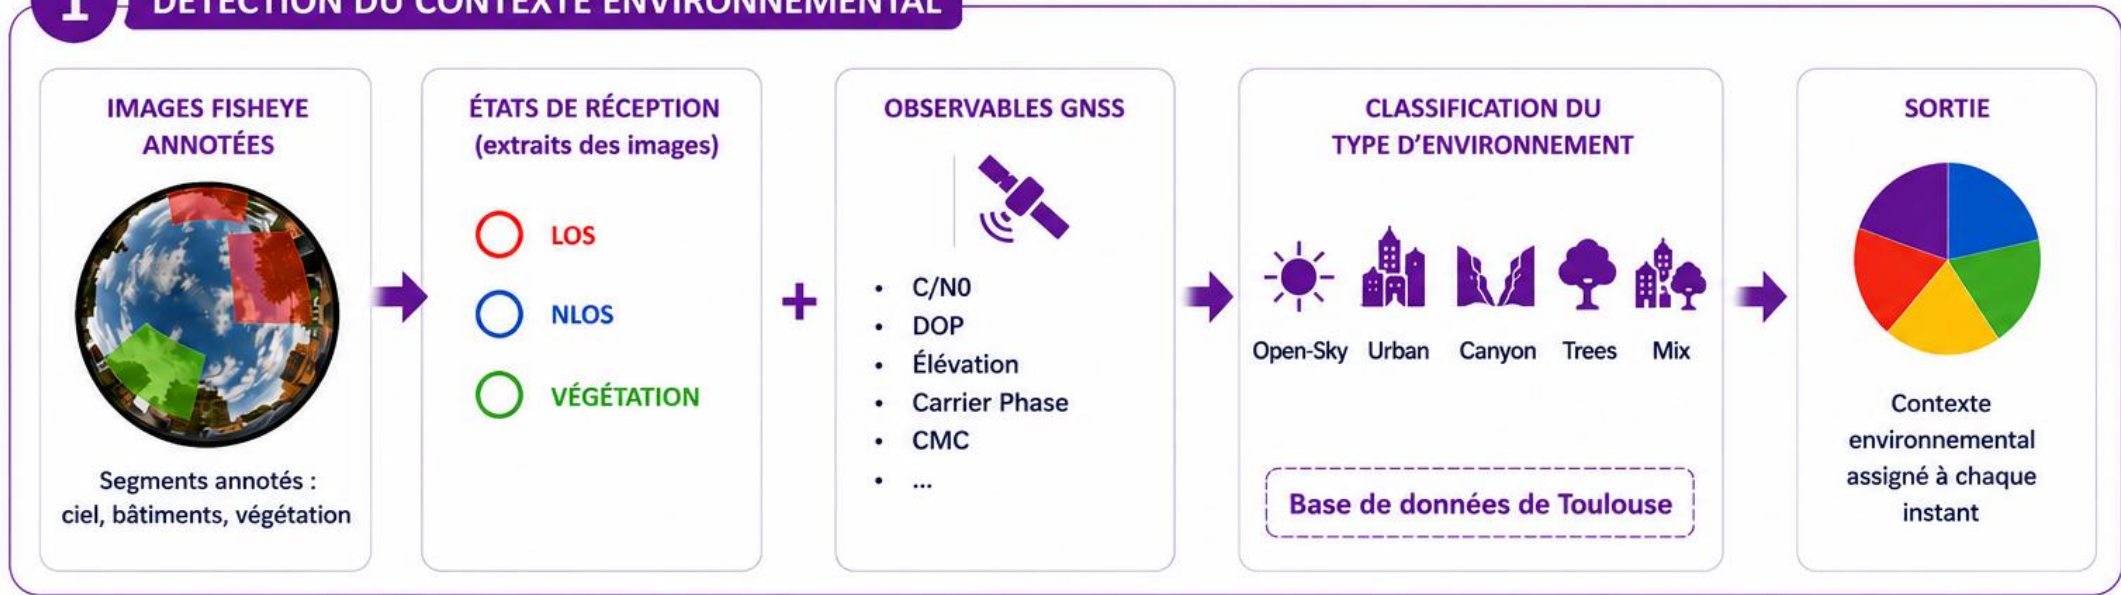
**OPTIMISER**  
les performances  
globales



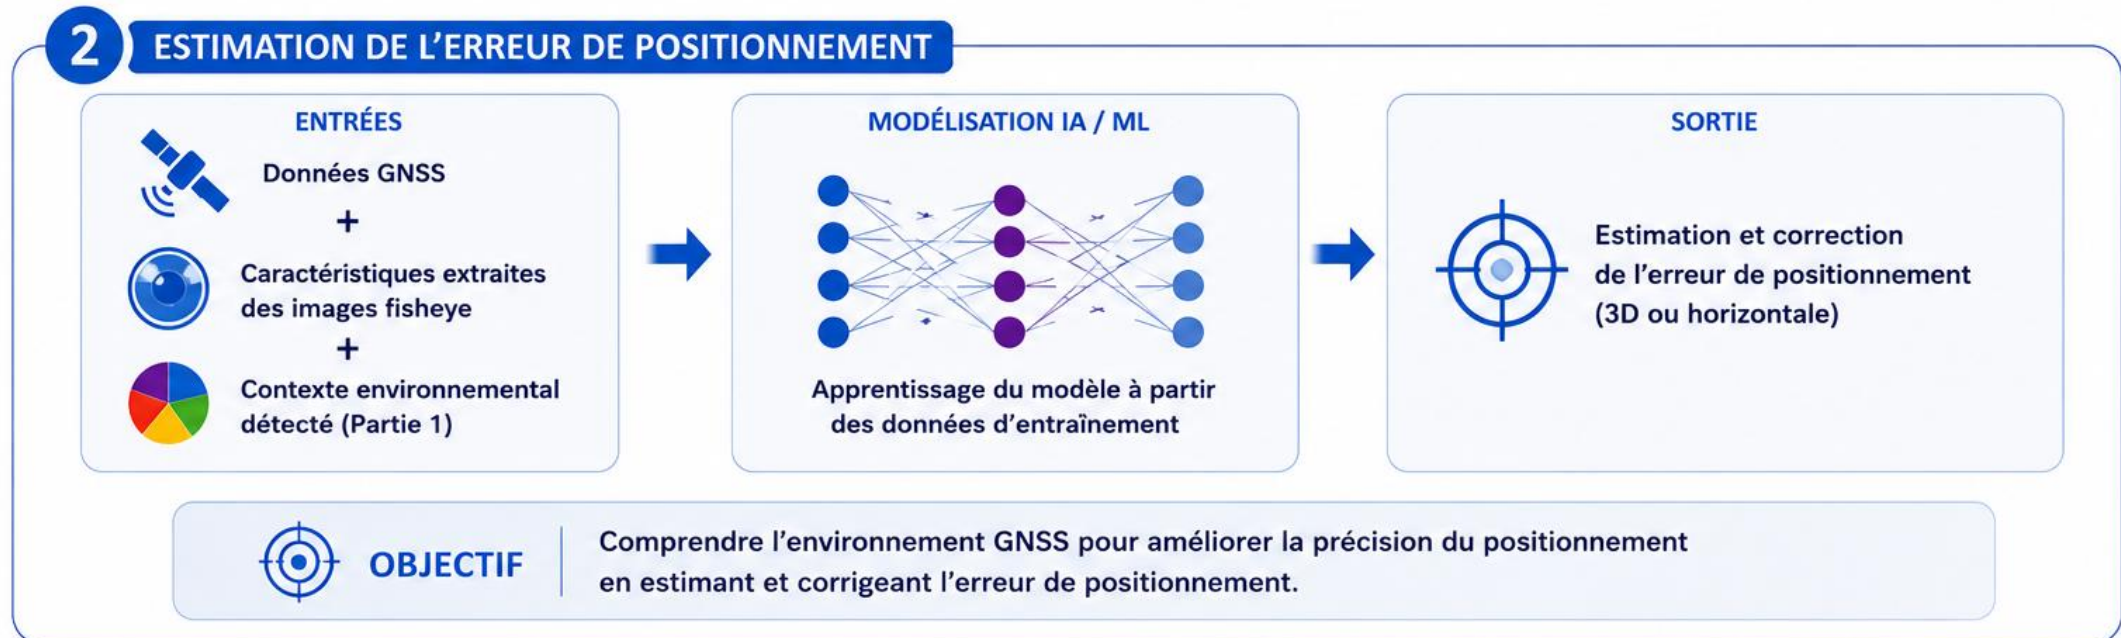
Le **ML** constitue ainsi un **levier clé** pour une localisation intelligente, robuste et performante.

# MÉTHODOLOGIE GLOBALE

## 1 DÉTECTION DU CONTEXTE ENVIRONNEMENTAL



## 2 ESTIMATION DE L'ERREUR DE POSITIONNEMENT



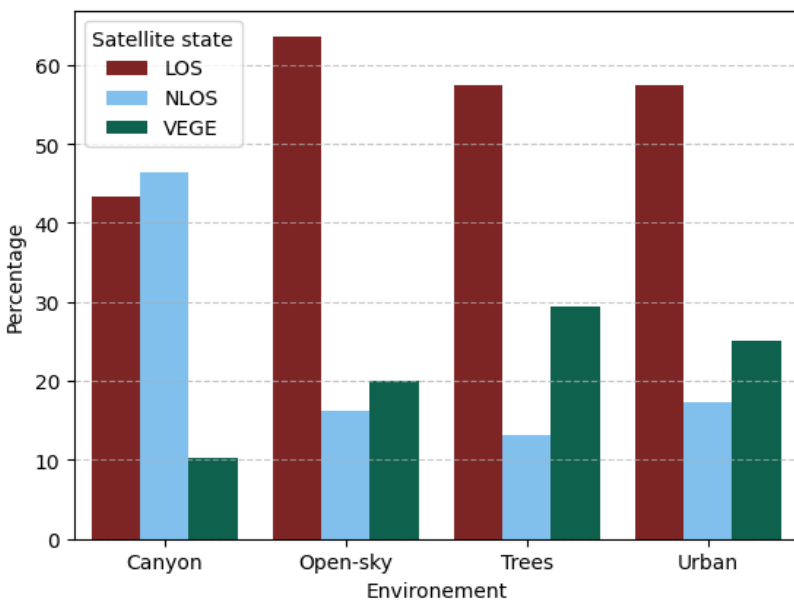
# **PARTIE 1 — Détection de contexte environnemental**

# Dataset

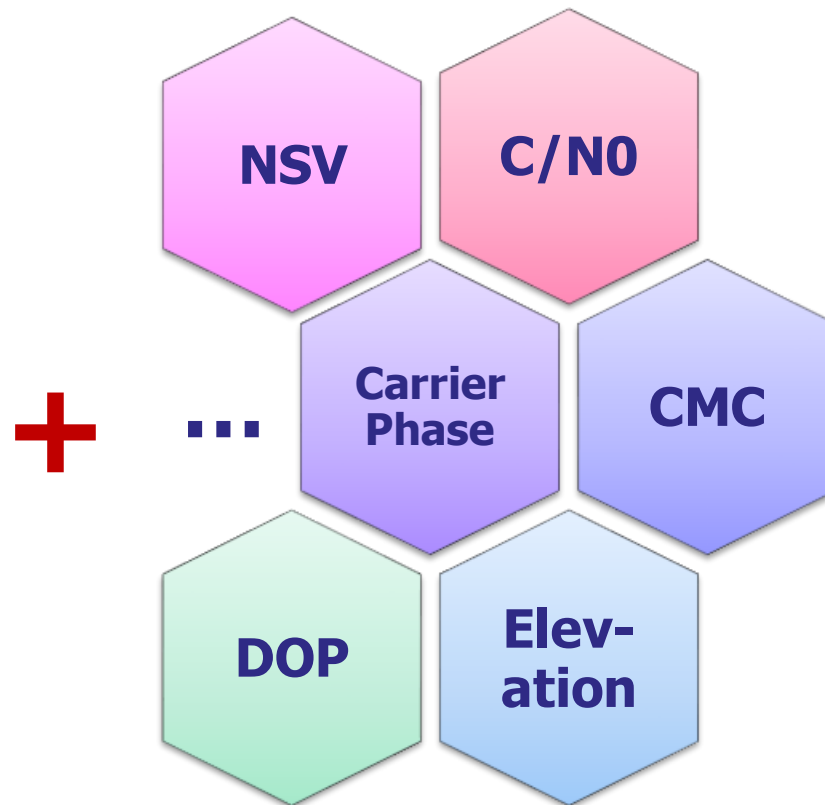
## Satellite states of reception



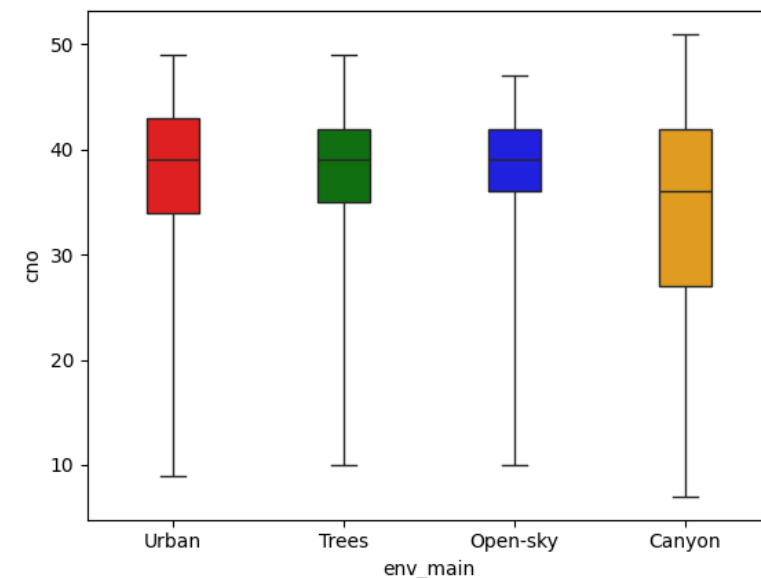
● LOS ● NLOS ● VEGE



## GNSS features

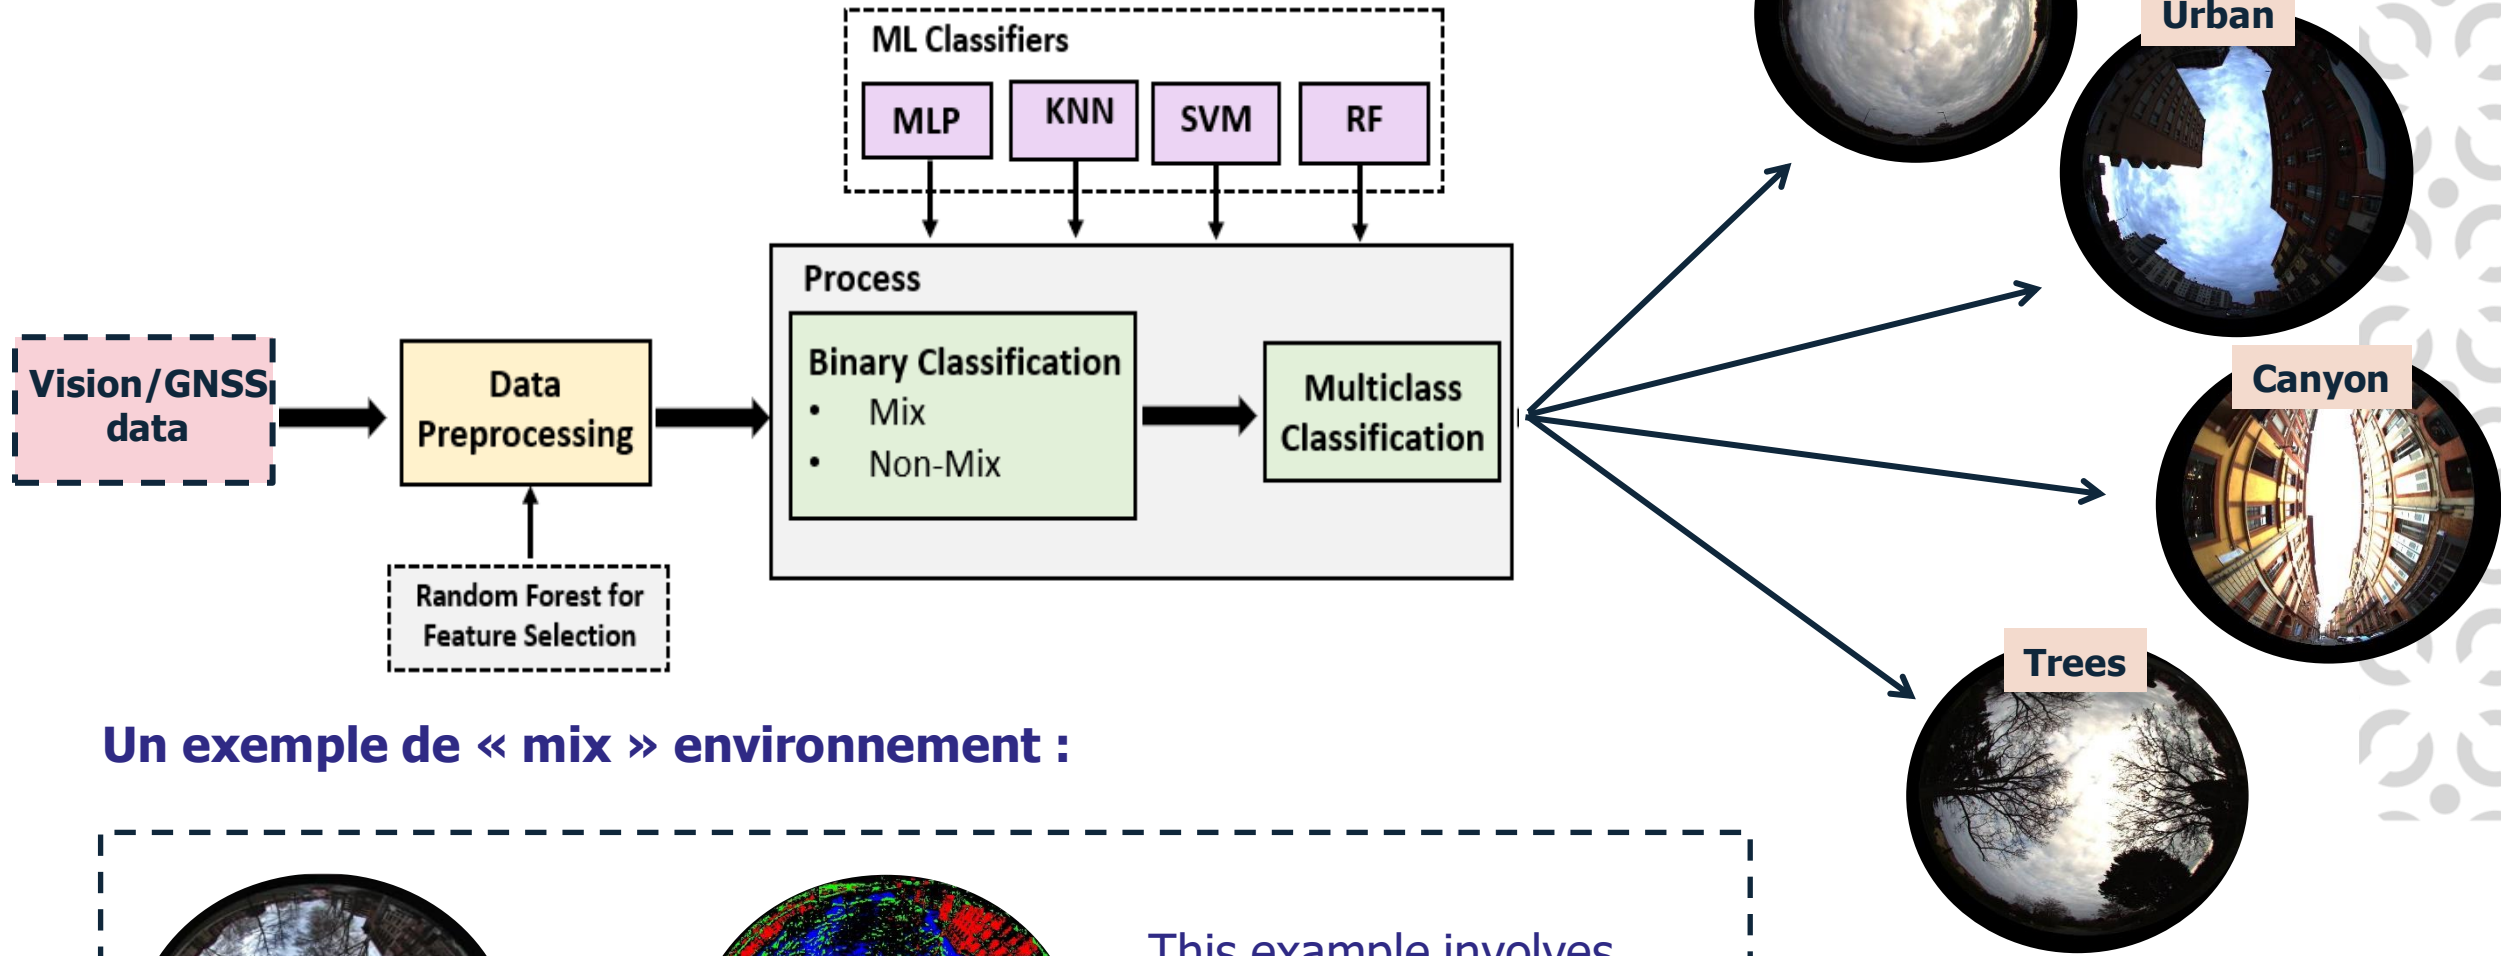


## Impact of context on GNSS performance: On C/N0




F. Feriol, "DATABASE GNSS/IMG Toulouse," *Gitlab*, [https://gitlab.isae-supaero.fr/d.vivet/GNSS\\_based\\_context\\_detection/-/tree/master/Toulouse%20database](https://gitlab.isae-supaero.fr/d.vivet/GNSS_based_context_detection/-/tree/master/Toulouse%20database), Jun.2022.

# Méthodologie proposée

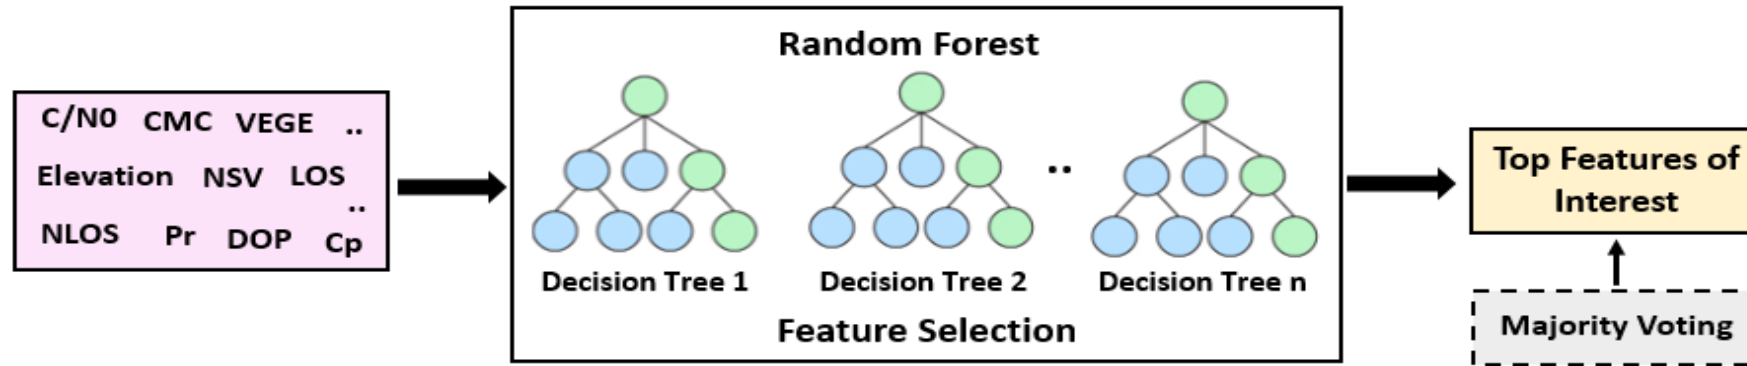


## Un exemple de « mix » environnement :



## Conception du vecteur de caractéristiques : Entrée

- Il est important de définir et d'utiliser un espace de caractéristiques optimal afin de traiter les différentes étapes de classification et d'obtenir les meilleurs résultats.
- La méthode **Random Forest (RF)** a été utilisée pour identifier les caractéristiques les plus pertinentes pour la classification des contextes environnementaux à partir des données GNSS.



Après l'analyse du classement des caractéristiques, nous avons obtenu un vecteur de caractéristiques de 12 dimensions :

$$v(t) = \left[ \text{NSV}_k, \mu_{C/N0,k}, \text{elev}_k, \bar{\text{res}}_k \right]_{k \in \{\text{LOS}, \text{NLOS}, \text{VEGE}\}}$$

•  $\text{NSV}_k$  : nombre de satellites visibles

•  $\text{elev}_k$  : élévation moyenne

$k \in \{\text{LOS}, \text{NLOS}, \text{VEGE}\}$  :

•  $\mu_{C/N0,k}$  : moyenne du C/N0

•  $\bar{\text{res}}_k$  : résidus moyens

types de réception

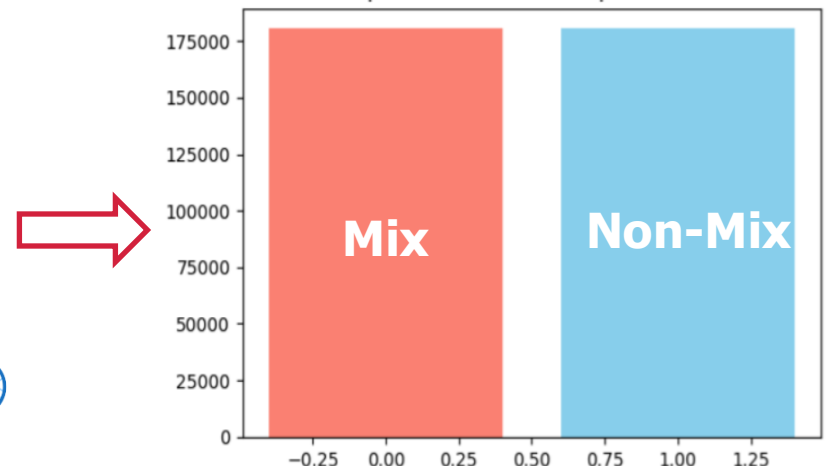
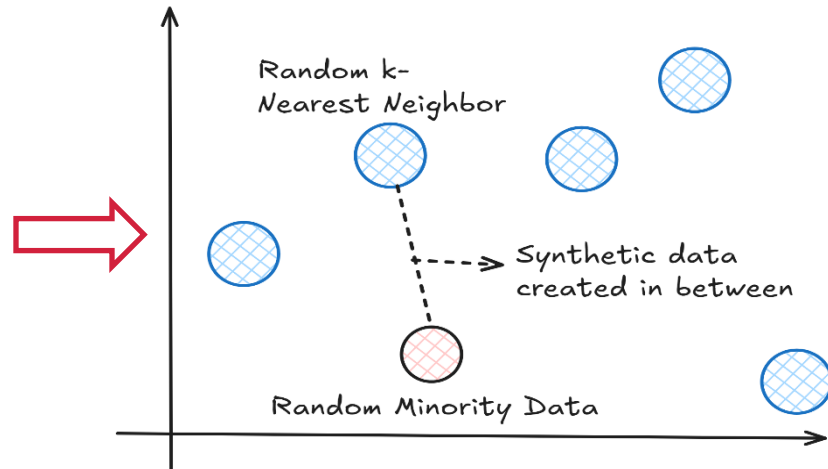
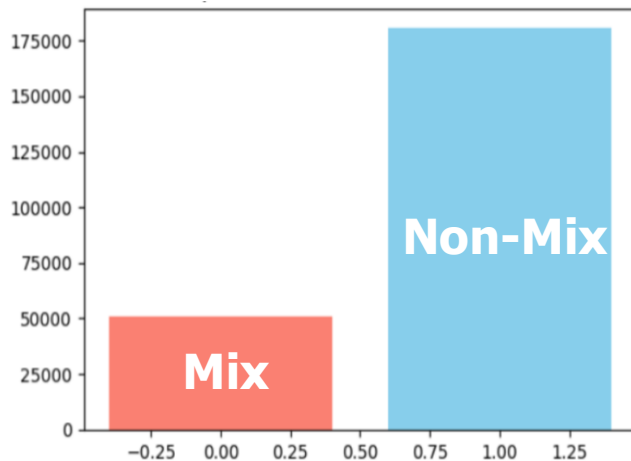
## Class Distribution in the Dataset

Class Type	Sub-Class	Number of Samples
<b>Mix</b>	-	225,543
<b>Non-Mix</b>	Open-Sky	25,455
	Urban	16,943
	Canyon	11,373
	Trees	9,963



La classe **Mix** domine largement la base de données, représentant une grande partie des échantillons ( $\sim 80\%$ ), tandis que les classes **Non-Mix** sont beaucoup moins représentées.

- Afin de traiter ce déséquilibre, la méthode **SMOTE** (*Synthetic Minority Over-sampling Technique*) a été appliquée sur l'ensemble d'entraînement (80 % entraînement et 20 % test)

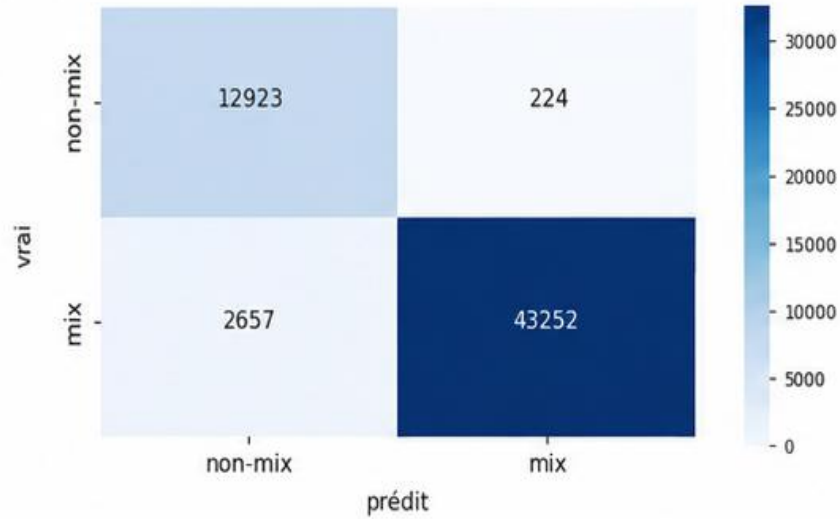


# Evaluation des modèles sur les données de test



Pour la tâche de **classification binaire** (Mix vs. Non-Mix) :

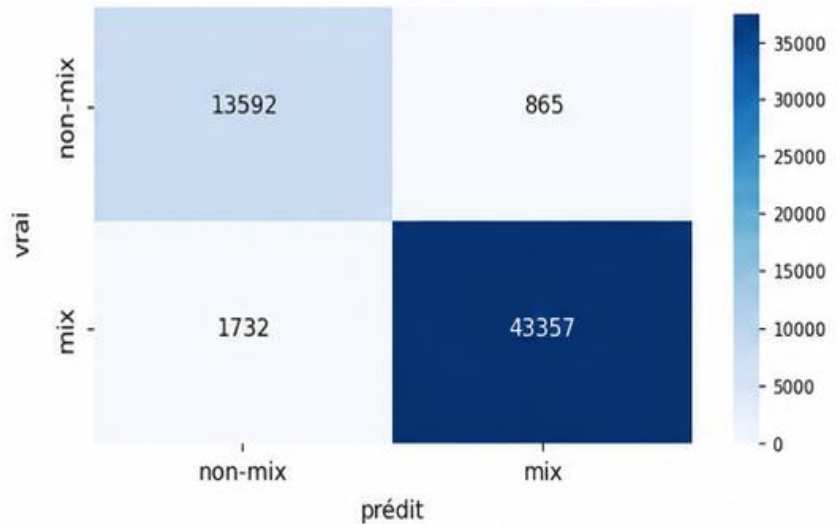
**MLP**  
**96%**  
de précision




**SVM**  
**79%**  
de précision



**KNN**  
**95%**  
de précision



**RF**  
**99%**  
de précision



# Classification multi-classe ; Résultats sur les données de test

Pour la tâche de classification des environnements (Open-Sky, Urban, Canyon et Trees)

## MLP classifieur

Exactitude globale : 99.7%



Classe réelle	Classe prédite					
	Canyon	Open-Sky	Trees	Urban	T%	F%
Canyon	2273	0	0	2	99.9%	0.1%
Open-Sky	0	5091	0	0	100%	0%
Trees	0	0	1992	0	100%	0%
Urban	6	6	0	3377	99.8%	0.2%

## KNN classifieur

Exactitude globale : 98.9%



Classe réelle	Classe prédite					
	Canyon	Open-Sky	Trees	Urban	T%	F%
Canyon	2263	0	0	12	99.4%	0.6%
Open-Sky	0	5080	0	11	99.8%	0.2%
Trees	0	6	1982	4	99.5%	0.5%
Urban	24	8	7	3350	98.8%	1.2%

## SVM classifieur

Exactitude globale : 96.3%



Classe réelle	Classe prédite					
	Canyon	Open-Sky	Trees	Urban	T%	F%
Canyon	2208	0	0	67	97.0%	3.0%
Open-Sky	0	5039	6	46	99.3%	0.7%
Trees	0	11	1971	10	99.4%	0.6%
Urban	195	23	45	3126	91.8%	8.2%

## RF classifieur

Exactitude globale : 99.95%



Classe réelle	Classe prédite					
	Canyon	Open-Sky	Trees	Urban	T%	F%
Canyon	2275	0	0	0	100%	0%
Open-Sky	0	5091	0	0	100%	0%
Trees	0	0	1992	0	100%	0%
Urban	0	0	0	3389	100%	0%

### Observations principales



Les modèles MLP, KNN et surtout RF obtiennent des performances très élevées pour distinguer les différentes catégories (Open-Sky, Urban, Canyon, Trees).



Le modèle SVM présente davantage de confusions entre certaines catégories, notamment avec la classe Urban.



### MEILLEUR MODÈLE : RANDOM FOREST (RF)

- ✓ Exactitude globale la plus élevée : 99.95%
- ✓ Taux de confusion quasi nul
- ✓ Identification complète et robuste des environnements

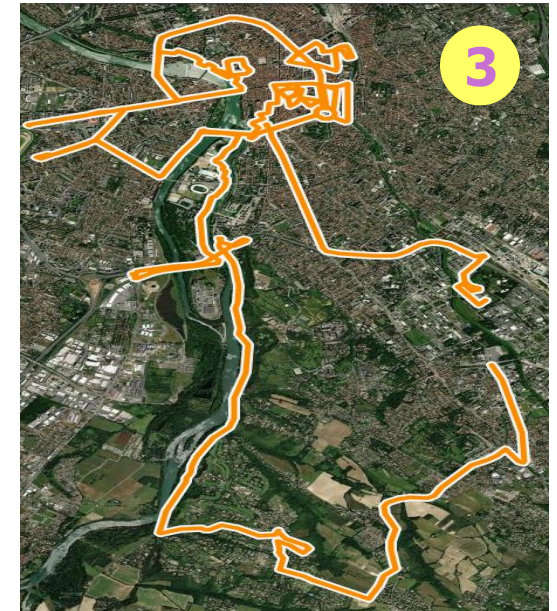

T% : Taux de bonnes prédictions (rappel par classe)

F% : Taux de mauvaises prédictions


Exactitude globale : proportion totale de bonnes prédictions

## **PARTIE 2 — Estimation de l'erreur de positionnement**


# Distribution des erreurs de positionnement GNSS sur les trajectoires de Toulouse :




Répartition (%) des erreurs – Trajectoire 1



Répartition (%) des erreurs – Trajectoire 2

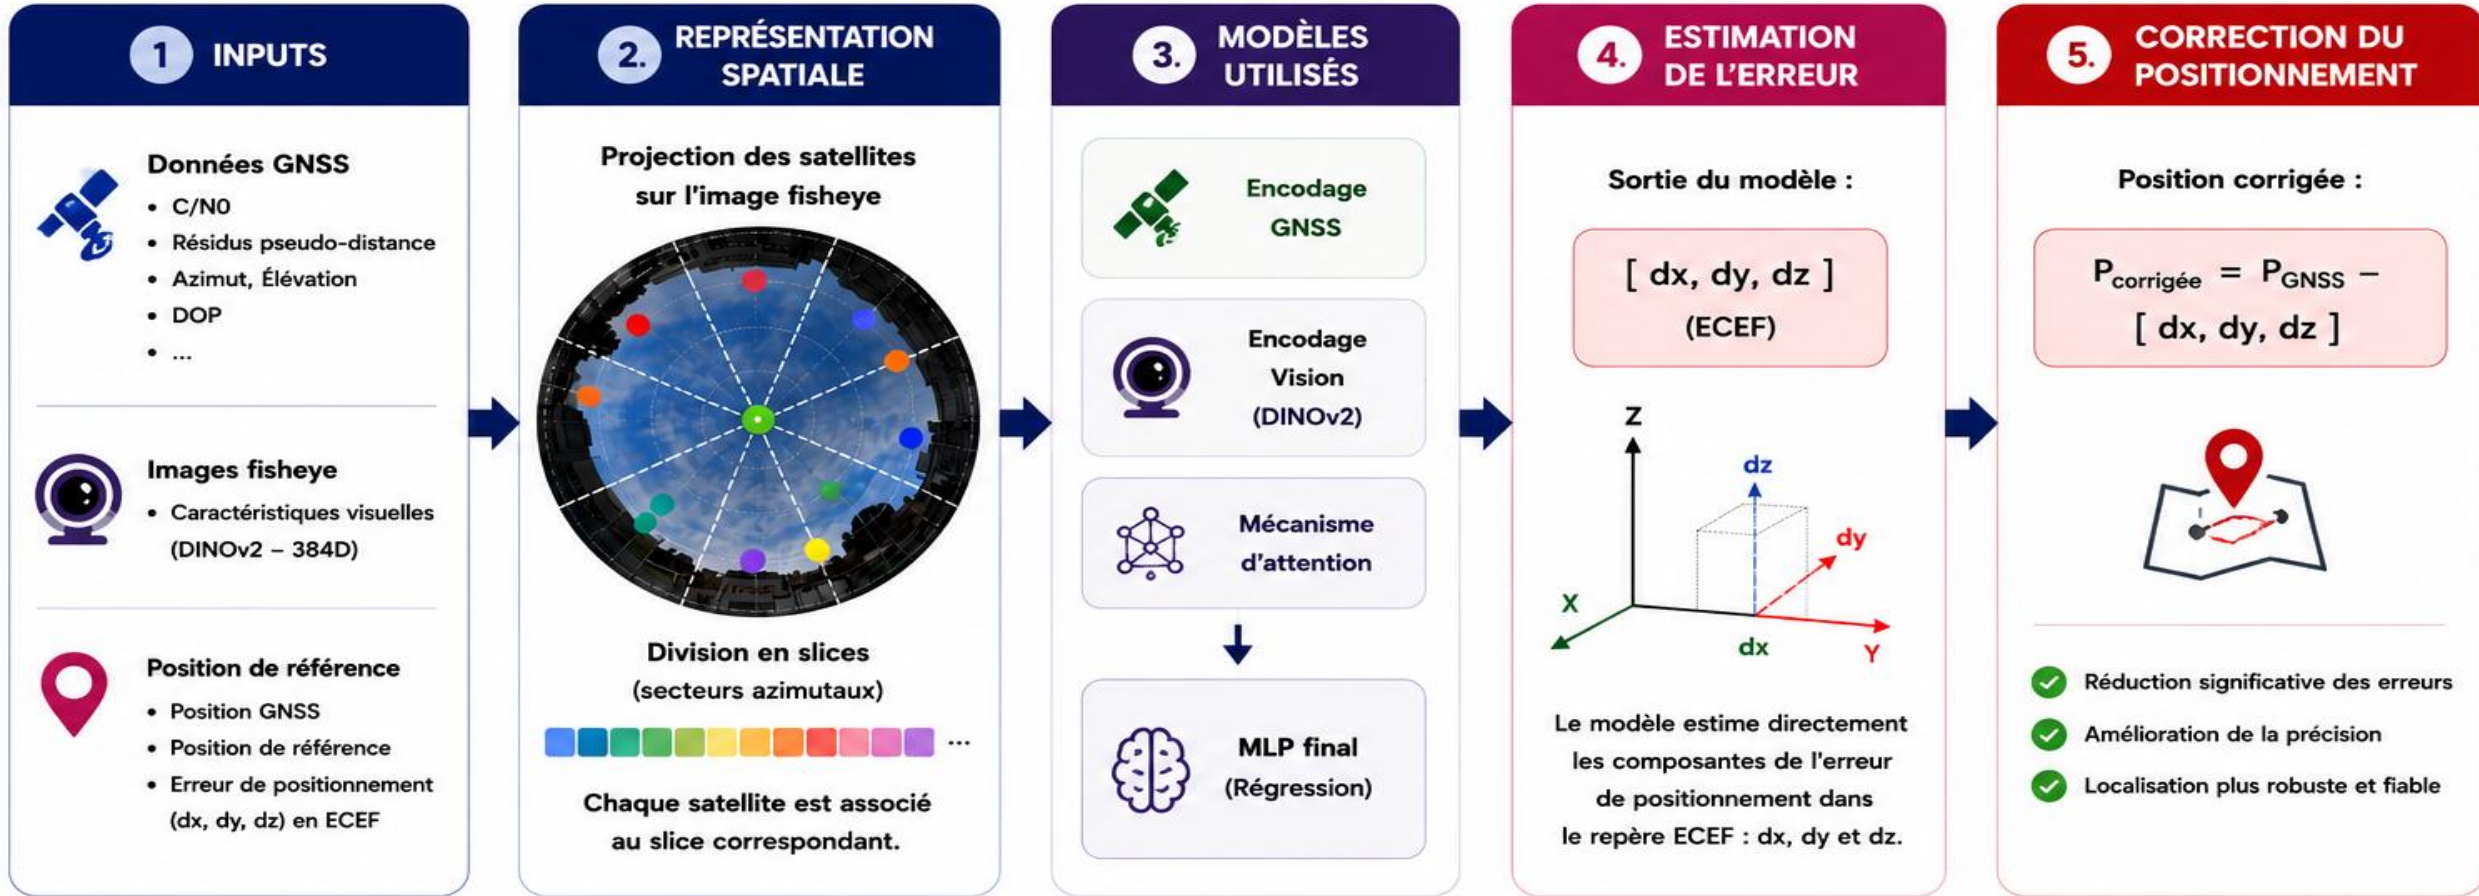


Répartition (%) des erreurs – Trajectoire 3



# PARTIE 2 – ESTIMATION ET CORRECTION DE L'ERREUR DE POSITIONNEMENT

## MÉTHODOLOGIE GLOBALE



**RÉSULTAT ATTENDU**



Estimation précise de l'erreur en ECEF (dx, dy, dz)



Correction efficace de la position GNSS

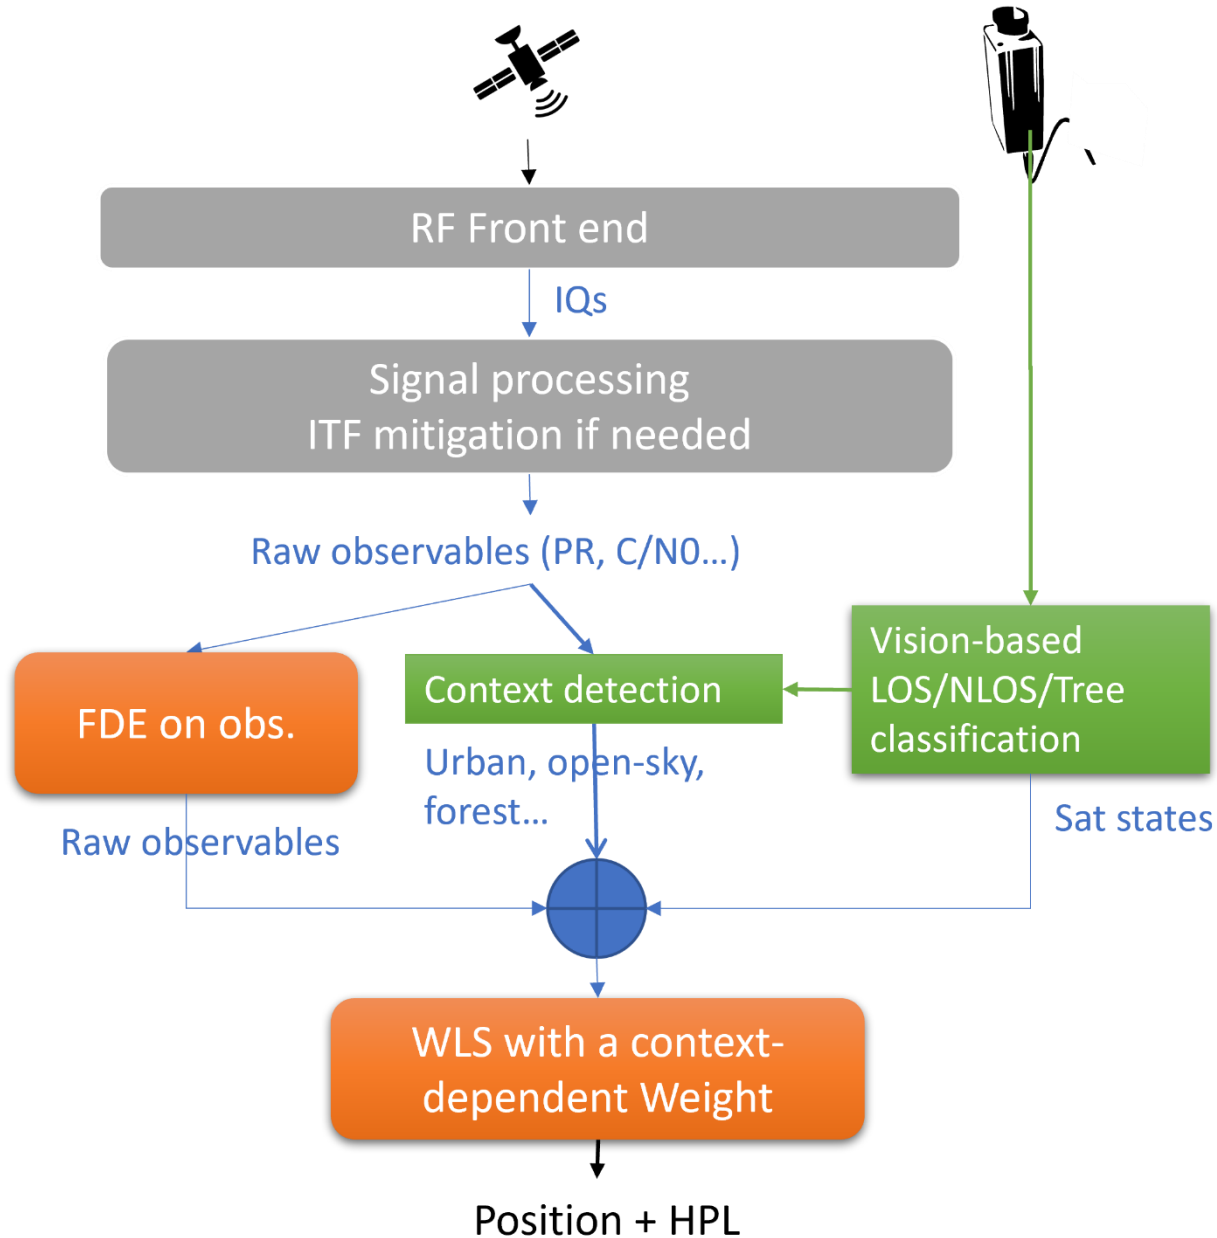


Positionnement plus précis, robuste et continu

The background features a dark blue upper section and a teal lower section. Large, overlapping white and light blue curved shapes are positioned on the right side, creating a modern, abstract design.

## **Conclusion & Perspectives**

# Intégration de la détection de contexte dans une architecture adaptative



## Travaux en cours

- Validation Leave-One-Trajectory-Out
- Tests sur données externes
- Généralisation des modèles

**Merci pour votre attention**

**Yasmine CHAIBEN**

Yasmine.chaiben@univ-eiffel.fr

