

# Replanification ferroviaire en temps réel par résolution hybride IA/RO

Léo Baty

SNCF Direction Innovation & Recherche, département MEV, groupe MOD

Ecole Nationale des Ponts et Chaussées, MPRO

Sous la direction de Hugo Belhomme

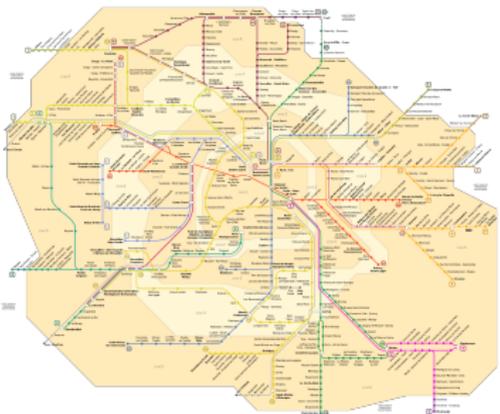


Logo MPRO



# Contexte industriel : Transilien

- Service de transport en commun le plus utilisé en Île-de-France.
- Hybride entre le métro et le train : fréquence élevée proche de Paris, fréquence faible loin de Paris.
- Contexte temps réel



# Plan de transport : solution du problème de planification

Graphe  $G = (\mathcal{E}, \mathcal{A}, w)$  orienté pondéré.

## Noeuds (évènements)

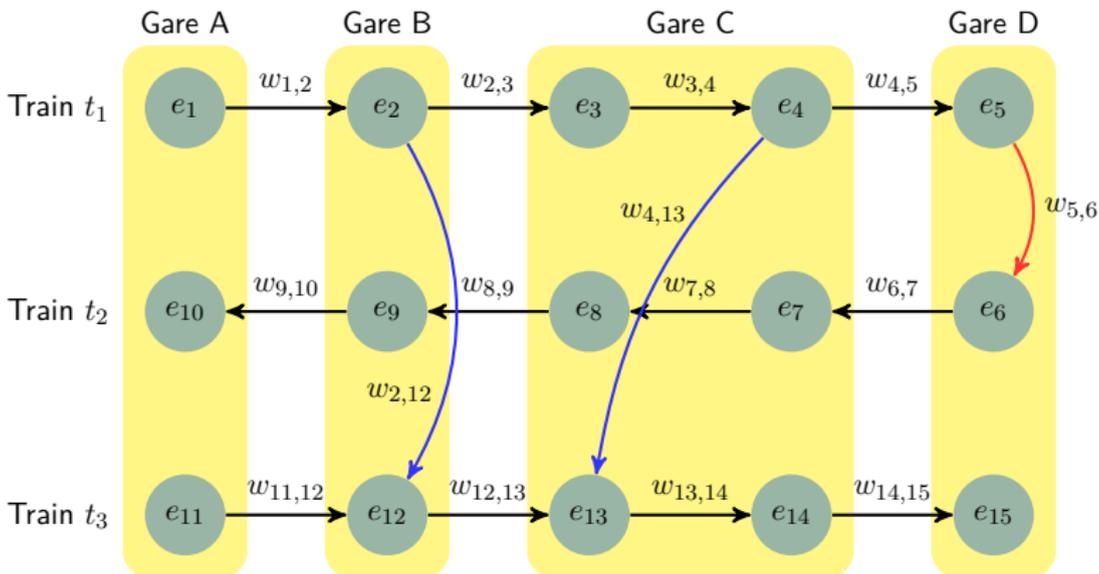
Soit un évènement  $e \in \mathcal{E}$ .

- **Type d'évènement** : terminus origine, terminus destination, arrivée, départ, ou passage.
- **Point remarquable** : lieu.
- **Train** associé.
- **Horaire théorique** : heure prévue.

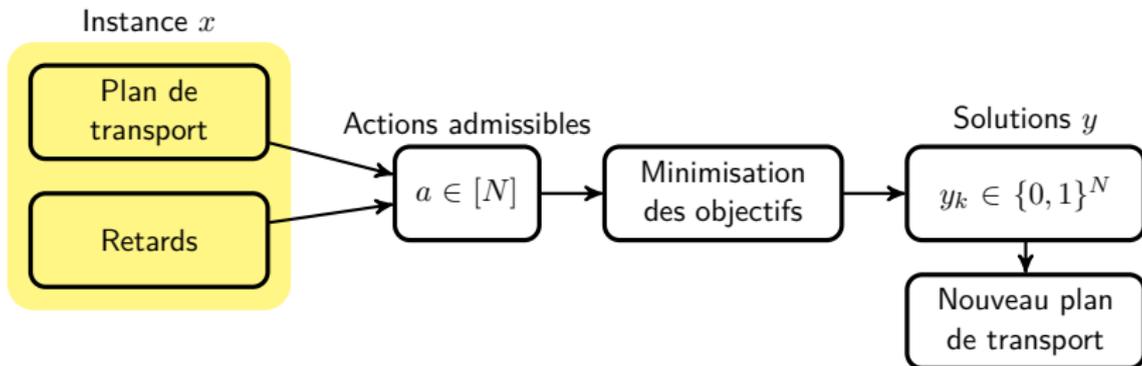
## Types d'arc

- Arc de **parcours**
- Arc de **retournement**
- Arc d'**espacement**

# Exemple de plan de transport



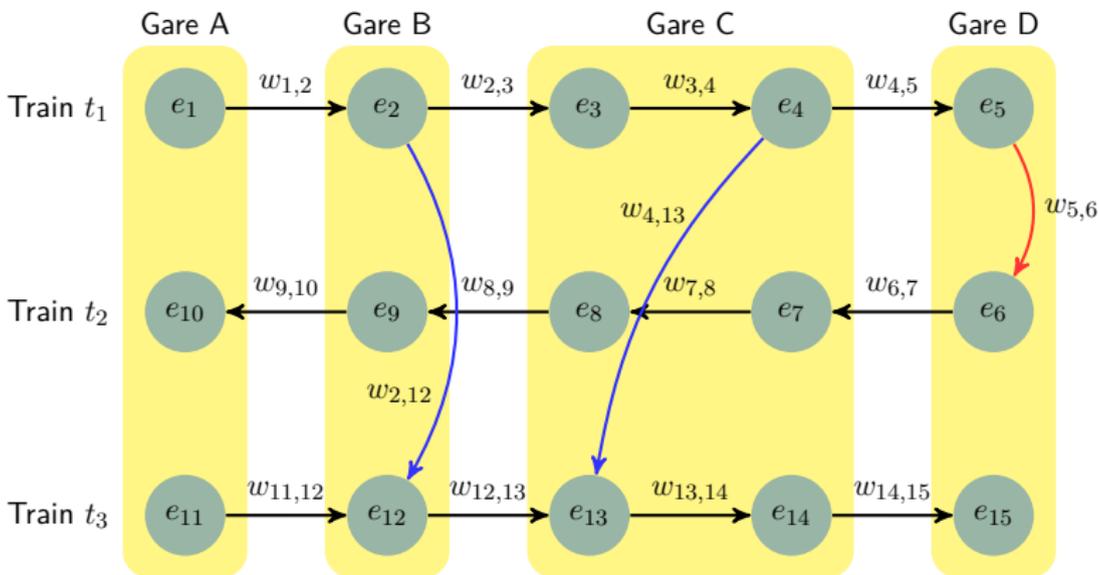
# Le problème de replanification ferroviaire



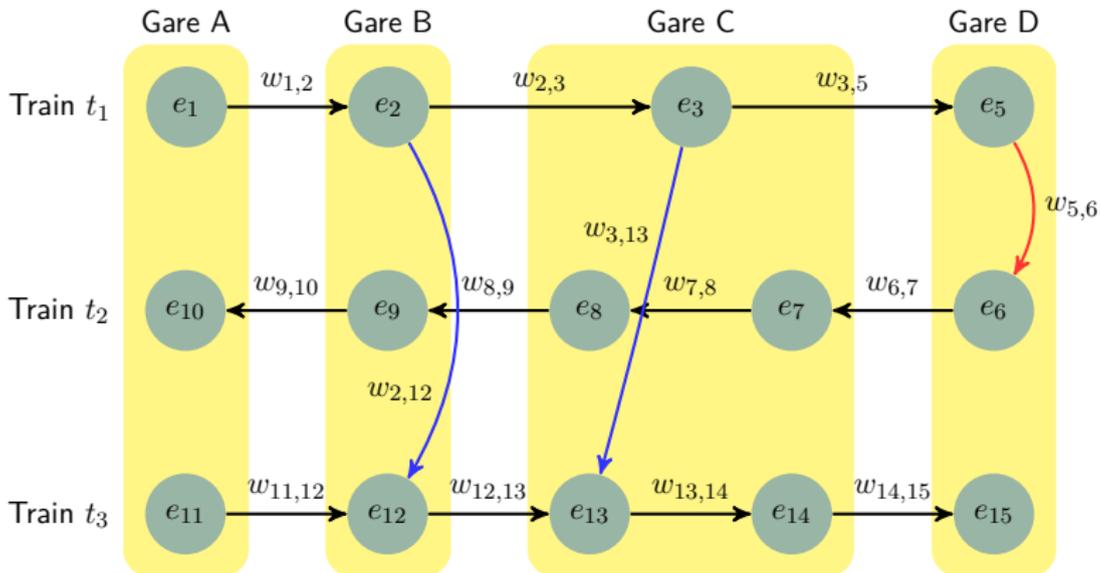
Objectifs à minimiser :

- 1 **Objectif voyageur** : temps d'attente + temps de voyage.
- 2 **Durée de la perturbation** : temps qu'il faut au réseau pour absorber les retards actuels.
- 3 **Nombre d'actions de régulation**.
- 4 **Retard des engins** : somme des retards de chaque engin.

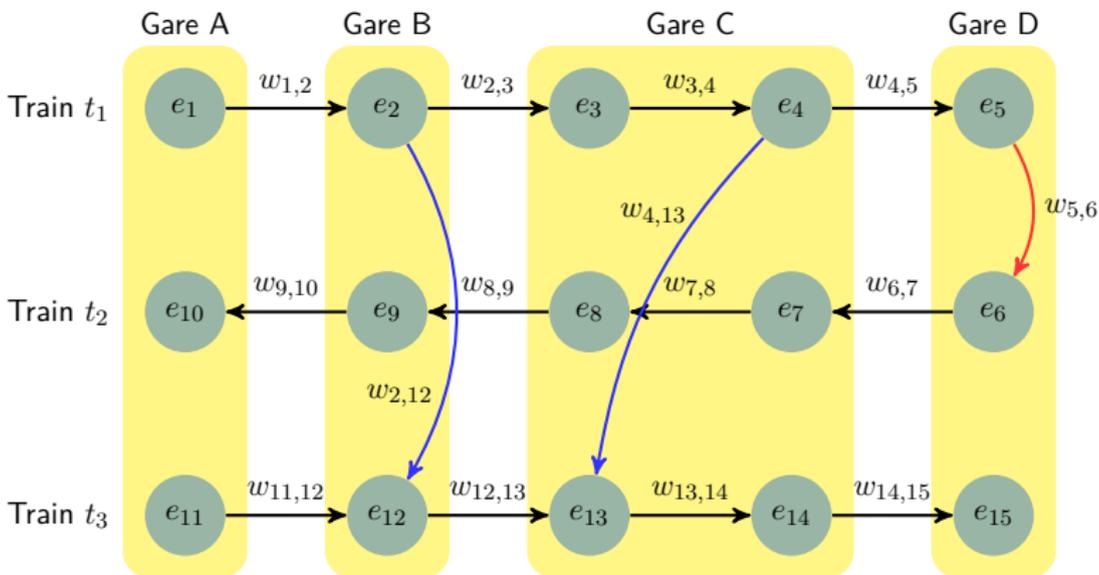
# Exemple



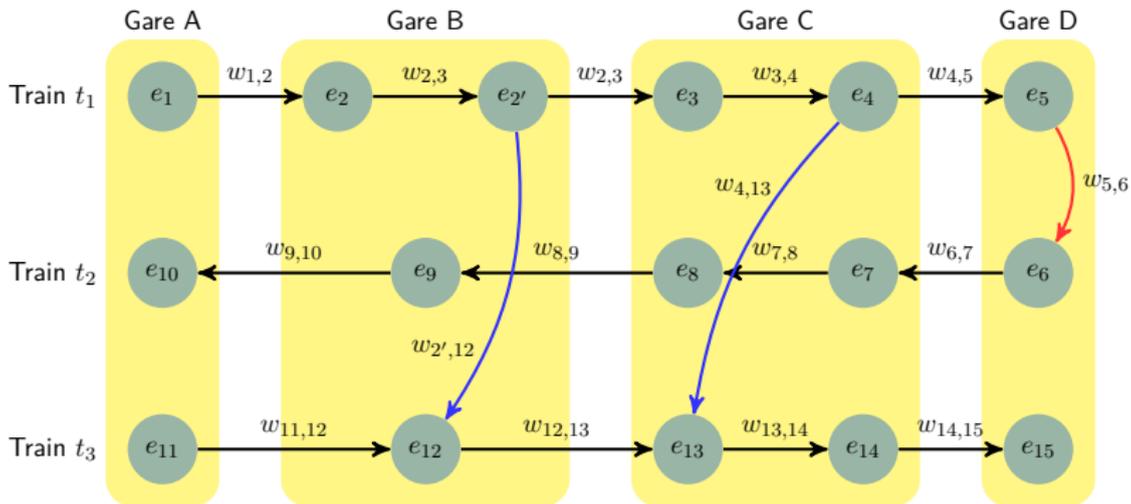
# Exemple : suppression d'arrêt



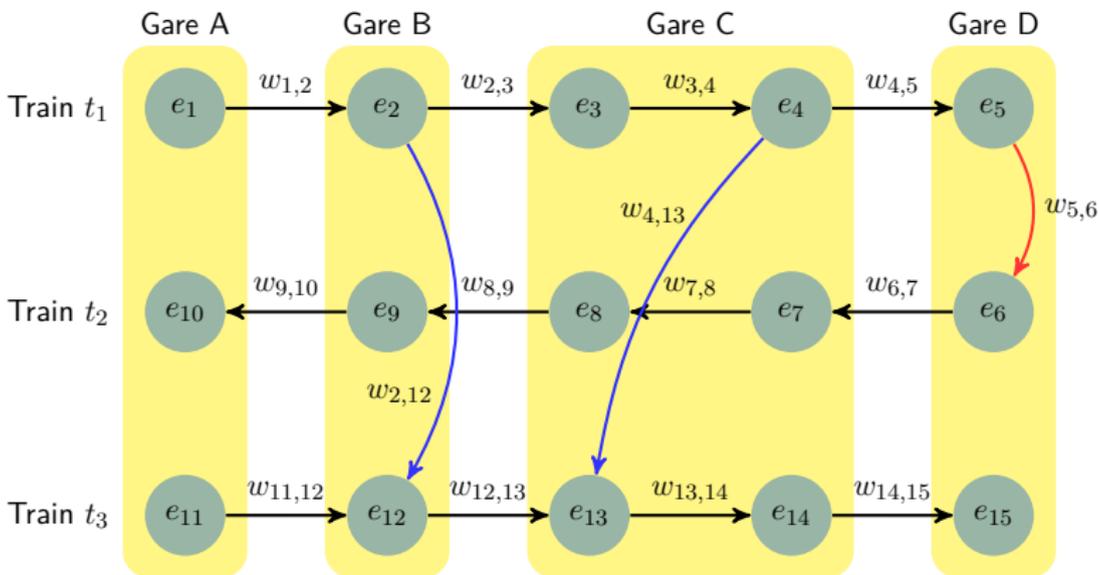
# Exemple : ajout d'arrêt



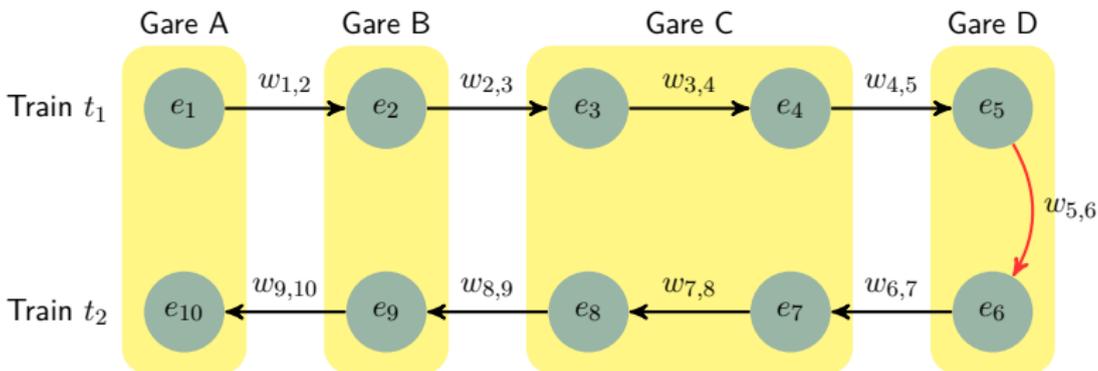
# Exemple : ajout d'arrêt



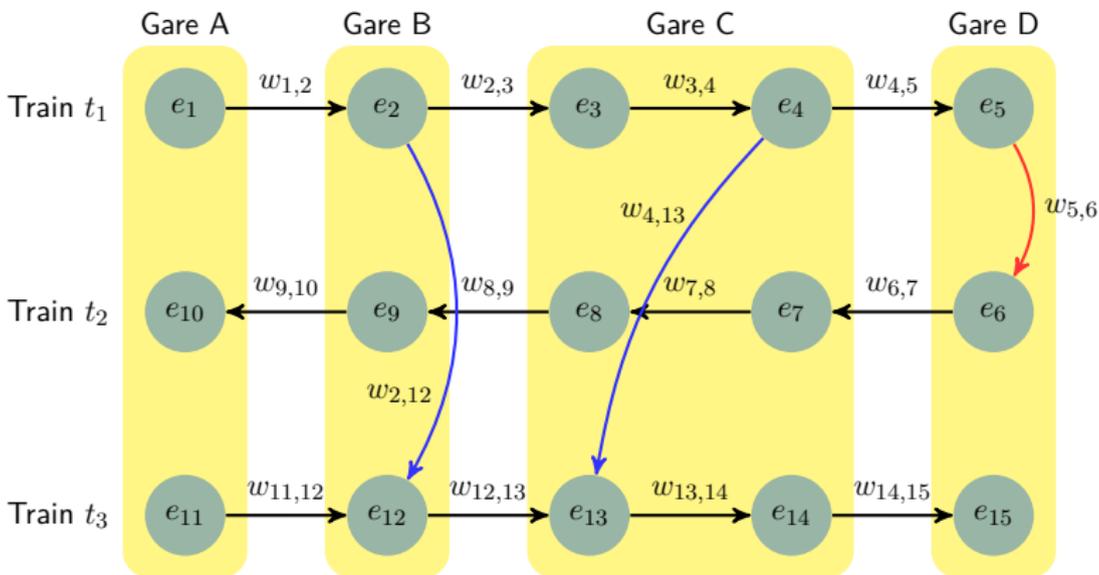
# Exemple : suppression de train



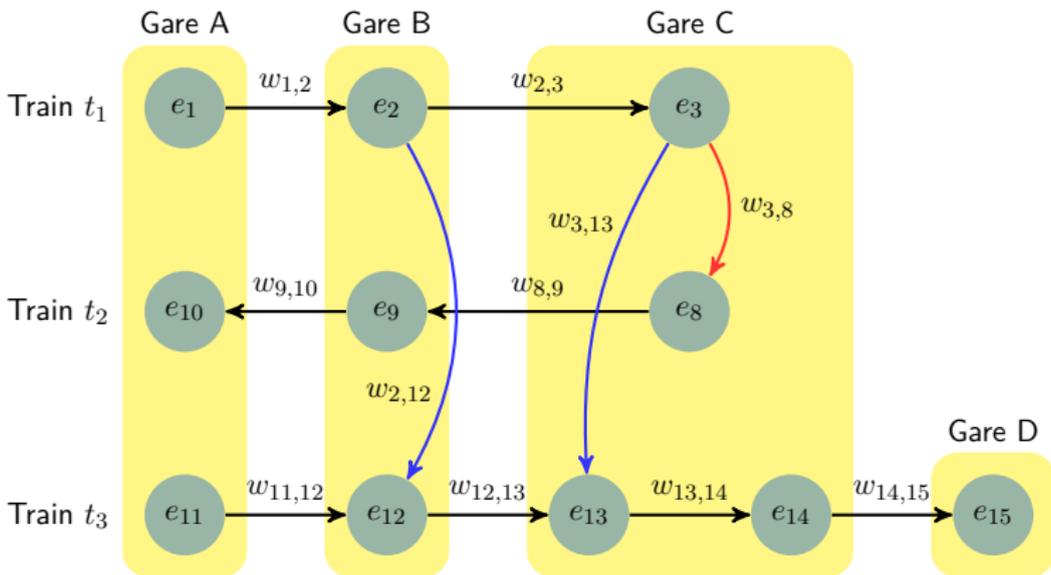
# Exemple : suppression de train



# Exemple : limitation



# Exemple : limitation



# L'outil actuel

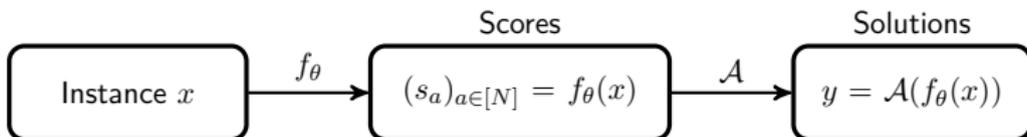
- Gestionnaires du plan de Transport et de l'Information voyageur (GTI)
- Outil d'aide à la décision en cours de développement, deux algorithmes d'optimisation :
  - ➊ **Recherche exhaustive** : parcours des  $2^N$  solutions  
⇒ trop long en temps réel
  - ➋ **Heuristique add** (3 branches) : algorithme glouton  
⇒ utilisé en pratique

# Plan

- 1 Introduction
- 2 Pipeline de résolution
- 3 Apprentissage
- 4 Résultats numériques
- 5 Conclusion

# Pipeline

**Objectif** : mise en place d'approches d'apprentissage automatique dans le but d'enrichir les algorithmes d'optimisation de l'outil.  
Utilisation des jeux de données d'historiques.

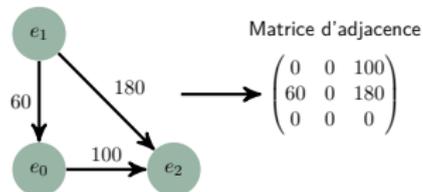
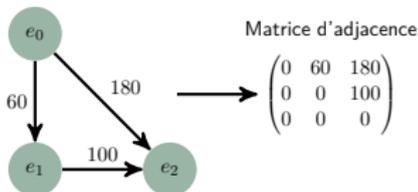


- $f_\theta$  : réseau de neurones,  $\theta \in \mathbb{R}^d$  paramètres à apprendre
- $\mathcal{A}$  : heuristique guidée par les scores

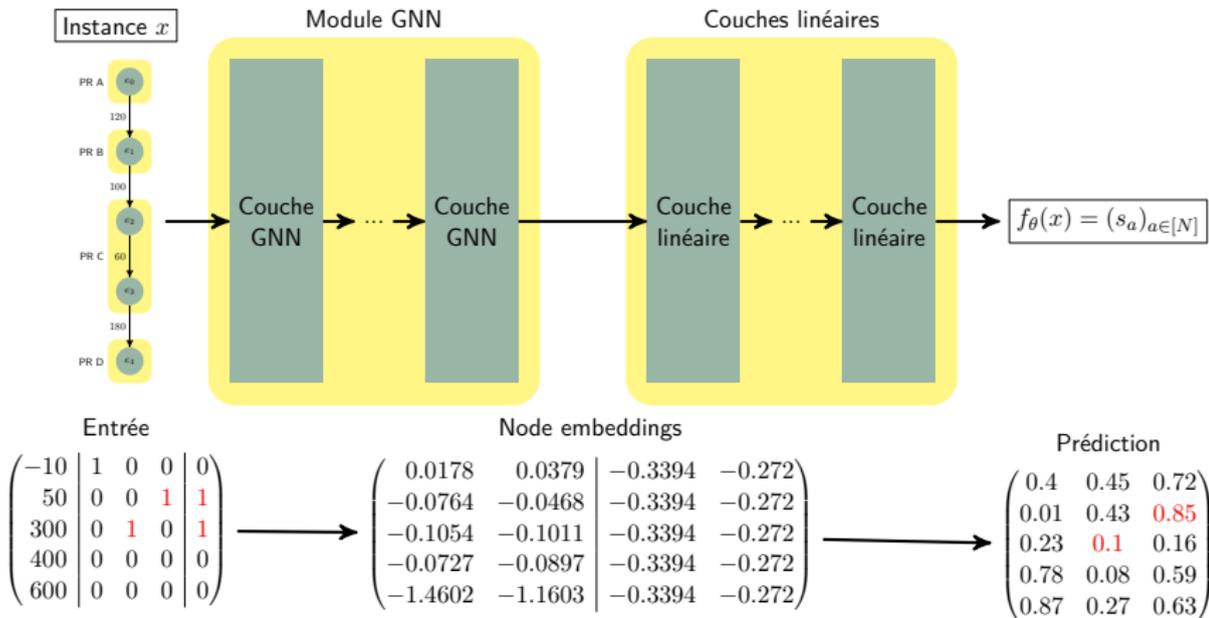
# Réseaux de neurones sur des graphes

Problèmes potentiels des réseaux de neurones classiques (matrice d'adjacence) avec des graphes :

- Information sparse
- Entrées de grande dimension
- Nombre de noeuds variables
- Non-invariance par permutation des sommets :

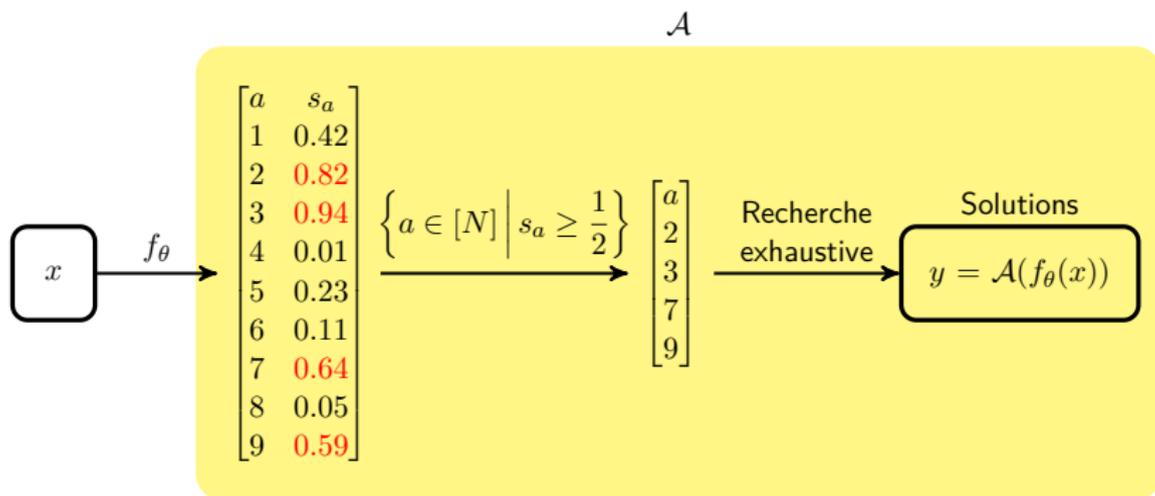


# Graph Neural Network (GNN)



# Heuristique : recherche exhaustive guidée par GNN

Parcours de tous les scénarios composés uniquement d'actions ayant un scores élevé.



⇒ moins de scénarios parcourus, temps d'exécution plus rapide.

- 1 Introduction
- 2 Pipeline de résolution
- 3 Apprentissage
- 4 Résultats numériques
- 5 Conclusion

# Génération d'instances

## Données d'historiques

- Plans de transport depuis mai 2018.
- Pour chaque jour et train : parcours théorique, et heures de passages observées.

## Construction d'un jeu d'instances

- Ligne L
- Uniquement des fenêtres de 2018 - 2019.
- 10 fenêtres par jour de durée 1h.

# Création d'un jeu de données d'apprentissage

## Labélisation des graphes

- On résout chaque instance en *offline* avec la recherche exhaustive  $\Rightarrow$  front de Pareto exact.
- Pour chaque action admissible  $a$ , on définit un label  $c_a$  :

$$c_a = \mathbb{1}_{\{a \text{ appartient à au moins une solution du front de Pareto}\}}$$

## Dataset résultant

- Training/validation/test : 900/100/500 graphes.
- En moyenne, 1000 noeuds et 1500 arcs.
- En moyenne, 140 actions admissibles, et 7 actions admissibles positives (i.e. telles que  $c_a = 1$ ).

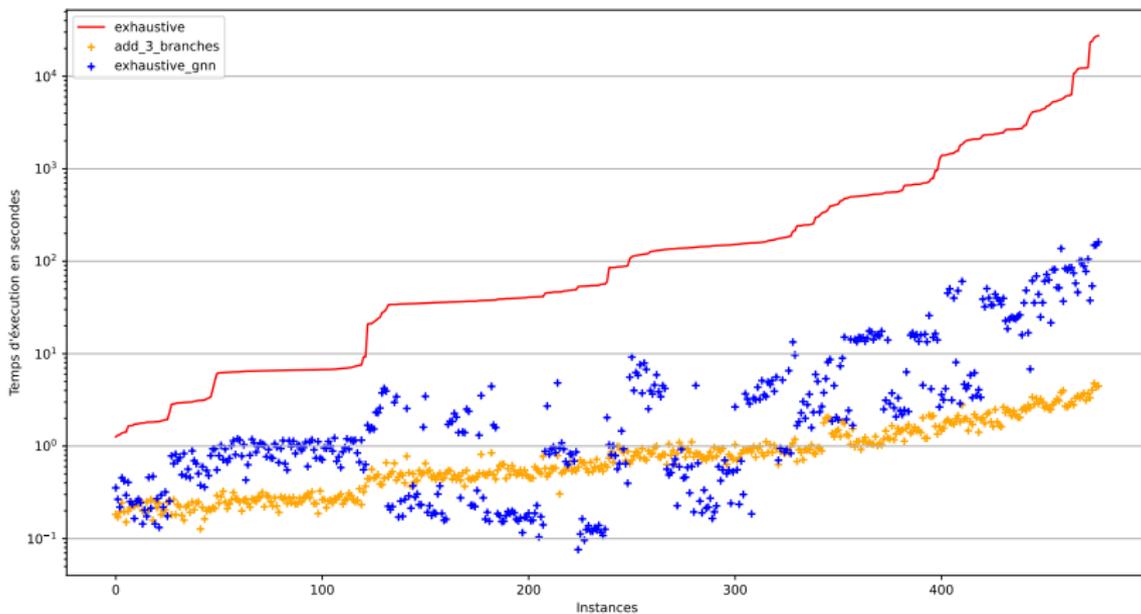
# Apprentissage

- Implémentation en Python avec PyTorch Geometric.
- Exécution sur un serveur distant : 6-12h sur 10 cpu pour chaque modèle.
- Loss : variante de la binary-cross-entropy

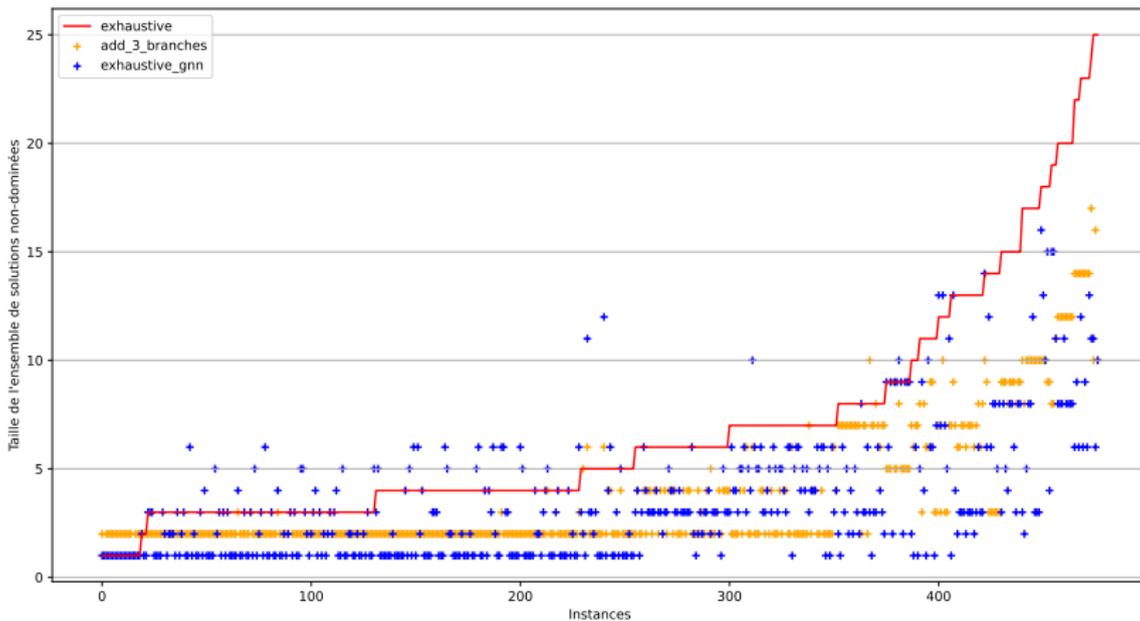
Modèle	Loss	Précision négative	Précision positive
<b>Meilleur modèle</b>	2.47	0.85	0.82

- 1 Introduction
- 2 Pipeline de résolution
- 3 Apprentissage
- 4 Résultats numériques**
- 5 Conclusion

# Temps d'exécution



# Nombre de solutions non-dominées



# Bilan

<b>Objectif</b>	<b>Objectif voyageur</b>	<b>Retard des engins</b>	<b>Durée de la perturbation</b>
<b>Recherche exhaustive</b>	3917.8	6774.9	1205.7
<b>Add 3 branches</b>	4025.4	6829	1269.1
<b>Exhaustive GNN</b>	3991.2	6791.7	1264.9

# Conclusion

## Contributions

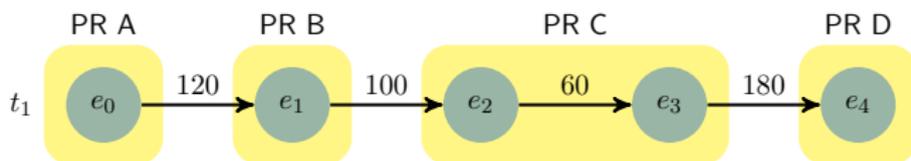
- 1 Génération d'instances labélisées à partir des données d'historique.
- 2 Utilisation des instances pour entraîner un modèle de Graph Neural Network.
- 3 Heuristique utilisant le modèle GNN.

## Perspectives

- Apprentissage structuré et Fenchel-Young loss.
- Amélioration de  $\mathcal{A}$  : métaheuristiques multi-objectifs.
- Utilisation d'autres jeux de données.
- Apprentissage par renforcement avec GNN.

Merci pour votre attention

# Encodage des graphes : exemple



Features d'entrée

$$\begin{pmatrix} -10 & 1 & 0 & 0 & 0 \\ 50 & 0 & 0 & 1 & 1 \\ 300 & 0 & 1 & 0 & 1 \\ 400 & 0 & 0 & 0 & 0 \\ 600 & 0 & 0 & 0 & 0 \end{pmatrix}$$

Arcs

$$\begin{pmatrix} 0 & 1 & 2 & 3 \\ 1 & 2 & 3 & 4 \end{pmatrix}$$

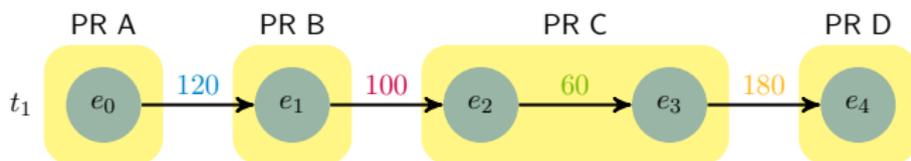
Poids

$$(120 \quad 100 \quad 60 \quad 180)$$

Labels

$$\begin{pmatrix} -1 & -1 & -1 \\ -1 & -1 & 0.5 \\ -1 & 1 & -1 \\ -1 & -1 & -1 \\ -1 & -1 & -1 \end{pmatrix}$$

# Encodage des graphes : exemple



Features d'entrée

$$\begin{pmatrix} -10 & 1 & 0 & 0 & 0 \\ 50 & 0 & 0 & 1 & 1 \\ 300 & 0 & 1 & 0 & 1 \\ 400 & 0 & 0 & 0 & 0 \\ 600 & 0 & 0 & 0 & 0 \end{pmatrix}$$

Arcs

$$\begin{pmatrix} 0 & 1 & 2 & 3 \\ 1 & 2 & 3 & 4 \end{pmatrix}$$

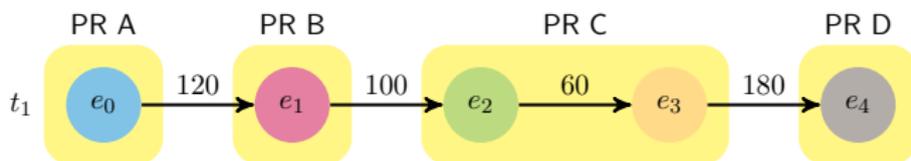
Poids

$$\begin{pmatrix} 120 & 100 & 60 & 180 \end{pmatrix}$$

Labels

$$\begin{pmatrix} -1 & -1 & -1 \\ -1 & -1 & 0.5 \\ -1 & 1 & -1 \\ -1 & -1 & -1 \\ -1 & -1 & -1 \end{pmatrix}$$

# Encodage des graphes : exemple



Features d'entrée

$$\begin{pmatrix} -10 & 1 & 0 & 0 & 0 \\ 50 & 0 & 0 & 1 & 1 \\ 300 & 0 & 1 & 0 & 1 \\ 400 & 0 & 0 & 0 & 0 \\ 600 & 0 & 0 & 0 & 0 \end{pmatrix}$$

Arcs

$$\begin{pmatrix} 0 & 1 & 2 & 3 \\ 1 & 2 & 3 & 4 \end{pmatrix}$$

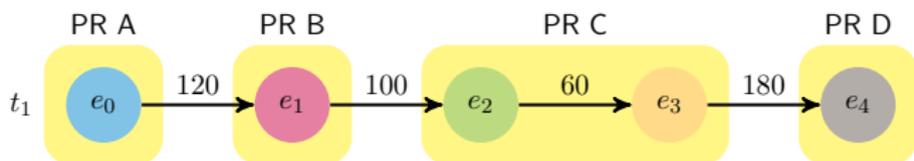
Poids

$$(120 \quad 100 \quad 60 \quad 180)$$

Labels

$$\begin{pmatrix} -1 & -1 & -1 \\ -1 & -1 & 0.5 \\ -1 & 1 & -1 \\ -1 & -1 & -1 \\ -1 & -1 & -1 \end{pmatrix}$$

# Encodage des graphes : exemple



Features d'entrée

$$\begin{pmatrix} -10 & 1 & 0 & 0 & 0 \\ 50 & 0 & 0 & 1 & 1 \\ 300 & 0 & 1 & 0 & 1 \\ 400 & 0 & 0 & 0 & 0 \\ 600 & 0 & 0 & 0 & 0 \end{pmatrix}$$

Arcs

$$\begin{pmatrix} 0 & 1 & 2 & 3 \\ 1 & 2 & 3 & 4 \end{pmatrix}$$

Poids

$$(120 \quad 100 \quad 60 \quad 180)$$

Labels

$$\begin{pmatrix} -1 & -1 & -1 \\ -1 & -1 & 0.5 \\ -1 & 1 & -1 \\ -1 & -1 & -1 \\ -1 & -1 & -1 \end{pmatrix}$$

# Module GNN : notations

Soit  $G = (\mathcal{E}, \mathcal{A}, w)$  en entrée du module GNN.

- $K$  le nombre de couches du GNN
- $d$  : nombre de features par sommet
- $\mathbf{X} \in \mathbb{R}^{|\mathcal{E}| \times d}$  : **features** sur chacun des sommets ( $x_e$  ses lignes).
- $\mathbf{h}_e^{(k)}$  : vecteur de sortie de la couche  $k \in [K]$ , appelé **hidden embedding**
- $\mathbf{z}_e$  : vecteur en sortie du module GNN, appelé **node embedding**.

# Module GNN : les maths

- 1 Pour chaque noeud, initialisation :

$$\mathbf{h}_e^{(0)} = \mathbf{x}_e, \forall e \in \mathcal{E}$$

- 2 Itération  $k \leq K - 1$  : mise à jour de l'**hidden embedding** :

$$\mathbf{h}_e^{(k)} = \text{ReLU} \left( \Theta_1 \mathbf{h}_e^{(k-1)} + \Theta_2 \sum_{f \in \mathcal{N}(e)} w_{f,e} \mathbf{h}_f^{(k-1)} \right), \forall e \in \mathcal{E}$$

$\Theta_1$  et  $\Theta_2$  deux matrices de poids de taille  $d \times d$ , et  
 $\text{ReLU}(x) = \max(x, 0)$ ,  $\forall x \in \mathbb{R}$ .

- 3 Sortie de la dernière couche :

$$\mathbf{z}_e = \mathbf{h}_e^{(K)} = \Theta_1 \mathbf{h}_e^{(K-1)} + \Theta_2 \sum_{f \in \mathcal{N}(e)} w_{f,e} \mathbf{h}_f^{(K-1)}, \forall e \in \mathcal{E}$$

# Concaténation du graph embedding

Le node embedding  $z_e$  pour chaque contient une information locale sur son voisinage.

Graph embedding  $z_G$

$$z_G = \frac{1}{\text{card}(\mathcal{E})} \sum_{e \in \mathcal{E}} z_e$$

Entrée du module de loss :

$$[z_e, z_G], \forall e \in \mathcal{E}$$

# Loss : notations

- $s_e$  : sortie (vecteur de taille 3) de la dernière couche linéaire pour le noeud  $e$ .
- $s_a$  : **sortie** (scalaire) associée à l'action  $a$  (récupéré sur  $s_e$  avec  $e$  associé à  $a$ ).
- $y_a$  : **score** de l'action  $a$ .
- On dit qu'une action admissible est **positive** si elle appartient à au moins une action du front, i.e.  $y_a > 0$ .  
On note  $n^+$  le nombre d'actions admissibles positives.
- Sinon, on dit qu'elle est **négative** ( $y_a = 0$ ).  
On note  $n^-$  le nombre d'actions admissibles positives.

## Module de loss : fonction de loss

$$\forall x \in \mathbb{R}, \sigma(x) = \frac{1}{1 + \exp(-x)} \in [0, 1]$$

### Loss de classification

$$\frac{1}{n} \sum_{a \text{ adm.}} - (\mathbb{1}_{y_a > 0} \log \sigma(s_a) + (1 - \mathbb{1}_{y_a > 0}) \log \sigma(1 - s_a))$$

### Loss de classification séparée

$$p_1 \left( \frac{1}{n^-} \sum_{\substack{a \text{ adm.} \\ \text{t.q. } y_a = 0}} -\log \sigma(1 - s_a) \right) + p_2 \left( \frac{1}{n^+} \sum_{\substack{a \text{ adm.} \\ \text{t.q. } y_a > 0}} -\log \sigma(s_a) \right)$$

# Métriques de performances : précisions

## Précision positive (resp. négative)

Proportion d'actions admissibles *positives* (resp. *négatives*) qui sont bien classifiées par le GNN.

Exemple (actions admissibles en rouge) :

Labels : $y$	$\mathbb{1}_{y>0}$	Prediction : $\sigma(s)$
$\begin{pmatrix} 0 & -1 & -1 \\ -1 & -1 & \mathbf{0.5} \\ -1 & \mathbf{1} & -1 \\ -1 & -1 & -1 \\ -1 & -1 & -1 \end{pmatrix}$	$\begin{pmatrix} 0 & 0 & 0 \\ 0 & 0 & \mathbf{1} \\ 0 & \mathbf{1} & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{pmatrix}$	$\begin{pmatrix} 0.4 & 0.45 & 0.72 \\ 0.01 & 0.43 & \mathbf{0.85} \\ 0.23 & \mathbf{0.1} & 0.16 \\ 0.78 & 0.08 & 0.59 \\ 0.87 & 0.27 & 0.63 \end{pmatrix}$

Précision positive : 0.5

# Métriques de performances : rang du dernier positif

## Rang d'une action $a$

Classement de  $a$  si l'on ordonne les actions par prédictions  $\sigma(s_a)$  décroissantes. Noté  $r_a$ .

## Rang du dernier positif

Rang le plus élevé parmi les actions admissibles positives :

$$\max_{a \text{ adm.}} r_a$$

Exemple (actions admissibles positives en vert) :

1	2	3	4	5	6	7	8	9
0.94	0.82	0.64	0.59	0.42	0.23	0.11	0.05	0.01

Rang du dernier positif : 7

# Métriques de performances : distance linéaire moyenne

## Distance linéaire moyenne

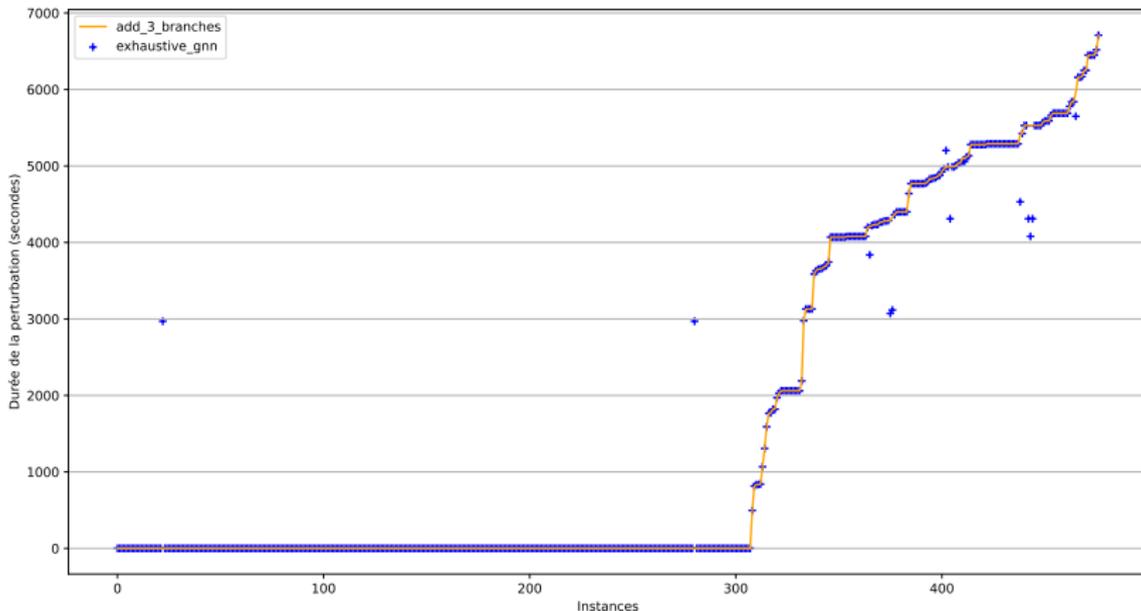
$$\text{DistanceMoyenneLinéaire}(G) = \frac{1}{n^+} \sum_{a \text{ admissible}} \max(n^+ - r_a, 0)$$

Exemple (actions amissibles positives en vert) :

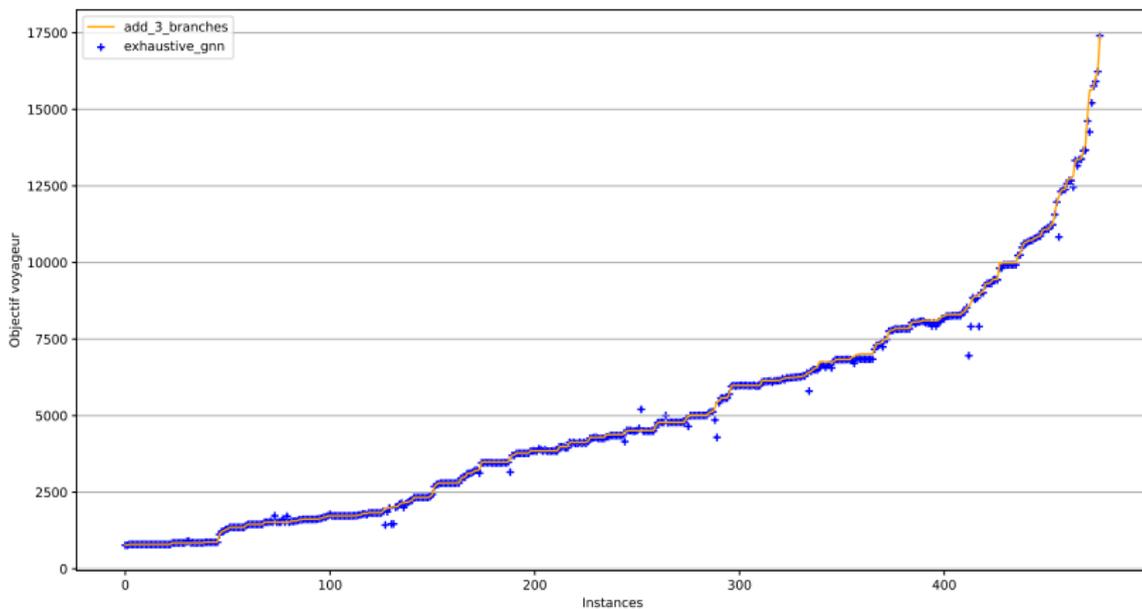
1	2	3	4		5	6	7	8	9
0.94	0.82	0.64	0.59		0.42	0.23	0.11	0.05	0.01

$$\text{Distance linéaire moyenne : } \frac{0 + 0 + 1 + 3}{4} = 1$$

# Objectifs : durée de la perturbation



# Objectifs : objectif voyageur



# Objectifs : Retard des engins

