

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

Léo Baty<sup>1</sup>

École Nationale des Ponts et Chaussées, et Master Parisien de Recherche Opérationnelle (MPRO)  
leo.baty@eleves.enpc.fr

**Mots-clés** : *recherche opérationnelle, apprentissage supervisé, temps-réel, multi-objectifs*

## 1 Introduction

Mon stage de master 2 et de fin d'études s'est déroulé entre le 6 avril et le 1er octobre 2021 à *SNCF Direction Innovation et Recherche*, sous la direction de Hugo Belhomme. Ce stage s'inscrit dans le cadre d'un projet avec Transilien, qui a pour but de fournir un outil d'aide à la décision qui propose des scénarios de replanification lors des perturbations sur le réseau.

### 1.1 Contexte industriel

Le Transilien circule en zones dites **denses**, dans lesquelles la moindre perturbation (incident technique, vitesse, trop de passagers, blocage des portes, etc.) peut se propager et s'amplifier à travers le réseau en très peu de temps. C'est dans ce contexte qu'interviennent les *Gestionnaires du plan de Transport et de l'Information voyageur* (GTI), des opérateurs en centre de contrôle qui prennent des décisions de replanification en temps réel afin de limiter l'impact des perturbations sur le réseau, mais aussi sur les voyageurs.

### 1.2 Le problème de replanification ferroviaire

Une solution du problème, appelée **scénarios de replanification**, correspond à une liste d'actions à appliquer, qui peuvent être des suppressions de trains, suppressions d'arrêts ou ajouts d'arrêts. Lorsque le nombre d'actions admissibles (i.e. applicables dans la situation considérée) est grand, il est impossible d'évaluer tous les scénarios possibles en temps réel. En plus du caractère temps réel, ce qui rend ce problème difficile est son caractère **multi-objectifs**. En effet, on souhaite minimiser les quatre objectifs suivants : objectif voyageur (somme des temps d'attente et de voyage des passagers), durée de la perturbation, nombre d'actions appliquées, et la somme des retards des engins.

### 1.3 Modélisation

Une instance du problème peut se modéliser sous la forme d'un graphe orienté pondéré appelé **graphe événements-activités** : chaque nœud représente un événement, et les arcs représentent les contraintes de distances temporelles entre les événements. Chaque action admissible se traduit par une modification de ce graphe.

L'outil actuel utilise un algorithme d'optimisation afin de parcourir l'espace des solutions, et simule chaque solution parcourue à l'aide d'un simulateur intégré, ce qui permet de mettre à jour de façon itérative un ensemble de solutions courant, qui sera renvoyé à la fin de l'algorithme. Pour l'instant, on a le choix entre deux algorithmes d'optimisation : la **recherche exhaustive** qui parcourt tous les scénarios possibles (inutilisable en temps réel), ou l'**heuristique add**, une heuristique gloutonne qui parcourt un arbre de décisions en pondérant les objectifs, i.e. en transformant le problème en un problème mono-objectif.

## 2 Contributions

L'objectif de mon stage était de s'intéresser à l'utilisation des données d'historiques à disposition afin d'expérimenter des méthodes hybrides entre apprentissage et recherche opérationnelle, afin de déterminer si cela peut aider à l'amélioration des algorithmes d'optimisation de l'outil. Le stage s'est déroulé en trois phases.

La première phase du stage a consisté au traitement et à l'analyse des données d'historiques. Je me suis intéressé en particulier au jeu de données d'historiques de plan de transport, qui contient, pour chaque jour et train Transilien depuis mai 2018, son parcours théorique et ses heures de passage observées à chaque point remarquable de la ligne. Pour les expérimentations, je me suis restreint à la ligne L, et j'ai utilisé ces données afin de générer un jeu d'instances du problème de replanification ferroviaire, que j'ai labellisées en utilisant la recherche exhaustive et en récupérant les fronts de Pareto de chaque instance. Cela m'a permis d'obtenir un jeu de données exploitables à l'aide de méthodes d'apprentissage supervisé comme les réseaux de neurones.

Une fois le jeu de données d'apprentissage créé, je suis passé à la phase suivante : l'exploitation des données. J'ai construit un modèle de **Graph Neural Network** (GNN), un type de réseau de neurones spécifique qui permet de prendre des graphes en entrée. J'ai donc entraîné un modèle GNN sur le jeu de données créé précédemment, en expérimentant diverses architectures afin d'optimiser les performances du modèle sur plusieurs métriques que j'ai définies au préalable. Le modèle final obtenu permet de prédire, pour une instance donnée, les actions admissibles qui sont présentes dans au moins une des solutions du front de Pareto, avec une précision moyenne supérieure à 80%.

Enfin, durant la troisième et dernière phase du stage, j'ai exploité le modèle GNN obtenu en implémentant une heuristique guidée par les prédictions du modèle. Le principe est d'explorer uniquement les scénarios constitués d'actions considérées intéressantes par le GNN, ce qui réduit considérablement le temps d'exécution. Les résultats obtenus sont intéressants : le temps d'exécution est en moyenne du même ordre de grandeur que l'heuristique add, tout en ayant des résultats meilleurs en moyenne :

Objectif	Objectif voyageur	Retard des engins	Durée de la perturbation
Recherche exhaustive	3917.8	6774.9	1205.7
Heuristique add	4025.4	6829	1269.1
Heuristique guidée par GNN	3991.2	6791.7	1264.9

Cette heuristique a l'avantage d'être purement multi-objectifs, car elle n'utilise pas de pondération des objectifs, contrairement à l'heuristique add. De plus, elle possède un potentiel d'amélioration important et pourra potentiellement être améliorée par l'utilisation d'algorithmes guidés par GNN un peu plus sophistiqués.

## Références

- [1] Estelle Altazin. Stabilité et replanification d'un système ferroviaire dense. *PhD thesis*, Mines de Saint-Etienne, 2018.
- [2] Yoshua Bengio, Andrea Lodi, and Antoine Prouvost. Machine learning for combinatorial optimization : a methodological tour d'horizon. *European Journal of Operational Research*, 290(2) :405–421, 2021.