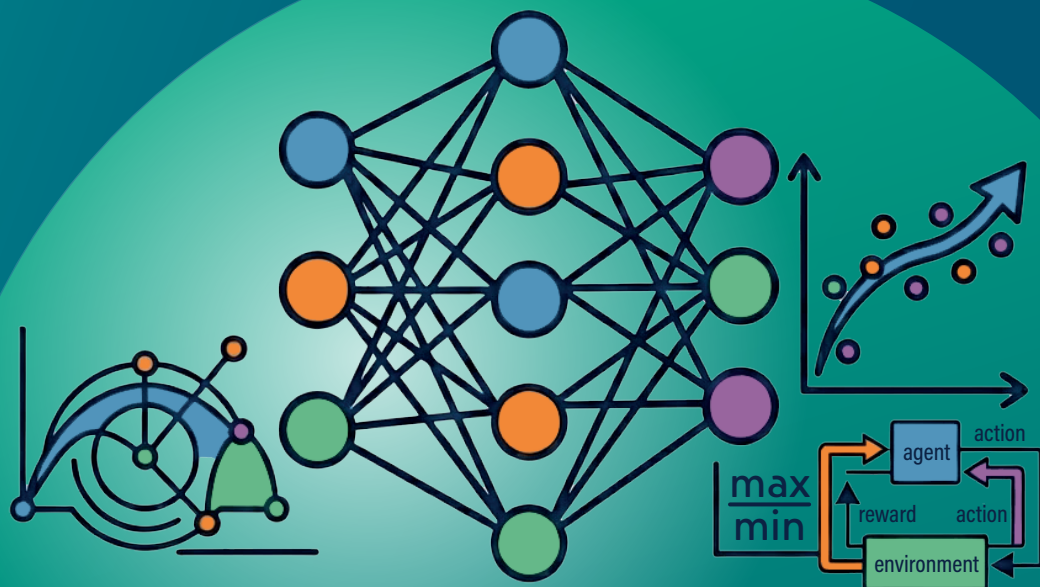


# « ON THE ROAD » !


## UN PEU DE ROADÉF POUR LA ROUTE

SOCIÉTÉ FRANÇAISE DE RECHERCHE OPÉRATIONNELLE ET D'AIDE À LA DÉCISION



NEWS REPORTAGE

DecisionBrain (p. 2)



# ROADÉF

SOCIÉTÉ FRANÇAISE DE RECHERCHE OPÉRATIONNELLE ET D'AIDE À LA DÉCISION



DÉCEMBRE 2025

# ROADDEF



Écrire à l'ensemble du bureau :  
**bureau@roadef.org**

ou individuellement à

**Président** : **Frédéric Meunier**, Cermics-ENPC : [president@roadef.org](mailto:president@roadef.org), [frederic.meunier@enpc.fr](mailto:frederic.meunier@enpc.fr)

**Trésorière** : **Paola Pellegrini**, Université Gustave Eiffel: [tresorier@roadef.org](mailto:tresorier@roadef.org), [paola.pellegrini@univ-eiffel.fr](mailto:paola.pellegrini@univ-eiffel.fr)

**Secrétaire** : **Lilia Zaourar**, CEA : [secretaire@roadef.org](mailto:secretaire@roadef.org), [lilia.zaourar@cea.fr](mailto:lilia.zaourar@cea.fr)

**Vice-Président 1 (Bulletin)** : **Nawal Benabbou**, LIP6-Sorbonne Université : [bulletin@roadef.org](mailto:bulletin@roadef.org), [nawal.benabbou@lip6.fr](mailto:nawal.benabbou@lip6.fr)

**Vice-Président 2 (Site Web)** : **Sohaib Afifi**, LGI2A-Université d'Artois, [webmaster@roadef.org](mailto:webmaster@roadef.org), [sohaib.lafifi@univ-artois.fr](mailto:sohaib.lafifi@univ-artois.fr)

**Vice-Présidente 3 (Relations Industrielles et Internationales)** : **Boris Detienne**, Institut de Mathématiques de Bordeaux : [relations@roadef.org](mailto:relations@roadef.org), [boris.detienne@math.u-bordeaux.fr](mailto:boris.detienne@math.u-bordeaux.fr)

**Vice-Présidente 4 (Communication)** : **Cécile Rottner**, EDF R&D : [communication@roadef.org](mailto:communication@roadef.org), [cecile.rottner@edf.fr](mailto:cecile.rottner@edf.fr)

**Chargé de mission à la promotion de la RO/AD** : **Nancy Perrot**, Orange : [promotion\\_road@roadef.org](mailto:promotion_road@roadef.org), [nancy.perrot@orange.com](mailto:nancy.perrot@orange.com)

**Chargé des prix** : **Maxime Ogier**, Centrale Lille : [prix@roadef.org](mailto:prix@roadef.org), [maxime.ogier@centralelille.fr](mailto:maxime.ogier@centralelille.fr)

---

Éditeur : **Nabil Absi**, Département 3EA, INP - ENSEEIHT, Toulouse - France / **Siège social** : Institut Henri Poincaré, 11, rue Pierre et Marie Curie, 75231 Paris Cedex 05 / **Publication** : Nawal Benabbou, Sorbonne Université / **Langues officielles** : français et anglais

Site web : **roadef.org**

# ON THE ROAD



## éditorial

par Nabil Absi

De l'instance à l'impact...

Chères et chers membres de la communauté ROADEF,

ce nouveau numéro met en lumière une chaîne complète qui nous est chère : partir de problèmes bien posés, disposer de jeux d'instances pertinents, choisir les bonnes stratégies de résolution, et aller jusqu'à des solutions réellement utilisables. C'est précisément ce que racontent les trois rubriques qui structurent le cœur de cette édition.

Côté repORtage, l'éclairage proposé par DecisionBrain rappelle avec force que la valeur de la recherche opérationnelle se joue aussi dans l'« après-modèle » : l'outillage, l'intégration dans des processus, la robustesse, et l'appropriation par les utilisateurs. On y retrouve une vision très concrète de ce qui transforme une bonne idée algorithmique en décision mieux prise, au bon moment.

Avec rADicalement ROAD, l'article traite de l'apprentissage supervisé pour la recherche opérationnelle. Il apporte un angle complémentaire, comment apprendre à mieux décider, de la façon de résoudre. Choix de formulations, paramétrage, stratégies de recherche, sélection de méthodes, autant de décisions « méta » qui conditionnent la performance, et pour lesquelles l'apprentissage supervisé peut devenir un véritable accélérateur, sans renoncer à la rigueur des modèles.

Enfin, la rubrique hORs-les-murs propose un triptyque particulièrement utile autour de la génération d'instances : une mise en perspective du rôle scientifique des générateurs (« fabriquer des instances, générer du savoir »), puis deux contributions très opérationnelles avec un générateur open source dédié au Service Network Design et le générateur REQreate. En filigrane, un message simple : l'évaluation crédible, la comparaison, la reproductibilité et

le transfert vers l'industrie commencent souvent par ces briques d'outillage discrètes, mais décisives.

Le reste du bulletin prolonge cette dynamique : nouvelles de la vie du GDR ROD, retours sur nos événements (congrès, JFRO), et l'actualité de la communauté (prix, challenge, Indus'RO, événements soutenus), sans oublier la citRONnADE pour le plaisir de chercher.

Nous vous donnons rendez-vous au congrès ROADEF 2026 à Tours, du 24 au 26 février 2026, pour poursuivre ces échanges entre méthodes, outils et usages. Ce sera également l'occasion de passer la main au nouveau bureau, qui sera présidé par Frédéric Meunier.

Bonne lecture à toutes et tous !

## Sommaire

2	<b>repORtage</b> DecisionBrain..... p.2	17	<b>Vie du GDR ROD</b> Odile Bellenguez, Nadia Brauner, Pierre Fouilhoux et Michaël Poss .....p. 13	23	<b>ActuROAD</b> Prix du Master 2024 .....p. 19 Prix du meilleur article étudiant 2025 . p. 19 Prochain challenge ROADEF/EURO .... p. 20 Prix Indus'RO ..... p. 20 Derniers événements soutenus ou sponsORisés par la ROADEF..... p. 21
6	<b>rADicalement ROAD</b> L'apprentissage supervisé pour la recherche opérationnelle ..... p.6	20	<b>Bilan Congrès de la ROADEF</b> ..... p. 15	25	<b>citRONnADE</b> ..... p. 23
13	<b>hORs-les-murs</b> Fabriquer des instances, générer du savoir .....p. 10 Un générateur open-source pour des instances réalistes de Service Network Design .....p. 10 Le générateur REQreate..... p. 11	22	<b>Compte-rendu des JFRO</b> .....p. 17		



## La société DecisionBrain : RO et IA au service de l'excellence opérationnelle

Fondée en décembre 2012 par deux anciens employés d'ILOG et d'IBM, Filippo Focacci et Daniel Godard, la société **DecisionBrain** a pour objectif de devenir un acteur de premier plan dans la mise en place d'applications d'aide à la décision pour la planification et l'ordonnancement.

Notre cœur d'activité est la conception, la réalisation et la maintenance d'applications, combinant Recherche Opérationnelle (RO) et Intelligence Artificielle (IA), permettant à nos clients d'améliorer leurs opérations. Pour y parvenir, nous avons développé **DB Gene**, une plateforme logicielle *low-code* spécifiquement conçue pour construire de telles applications. Cette plateforme, également commercialisée par IBM sous le nom d'IBM Decision Optimization Center (DOC), nous permet de livrer des projets sous forme d'applications web facilement déployables sur le Cloud.

Notre savoir-faire couvre de nombreux domaines tels que la planification de la production et de la chaîne d'approvisionnement, la planification des effectifs ou encore la planification de la maintenance d'équipements.

La société comprend aujourd'hui une soixantaine de collaborateurs aux compétences techniques et scientifiques pointues, dont une douzaine de docteurs (PhD) en RO et IA en Europe. Un nombre important de nos collaborateurs participent directement à nos activités de R&D. Nos bureaux sont situés en France, à **Paris** et à **Montpellier**, et en Italie à **Bologne**. Nous avons également une présence aux **États-Unis**, à **Hong Kong** et au **Brésil**.

## La plateforme DB Gene : industrialiser des algorithmes en applications métier

Un défi récurrent en aide à la décision est le passage du prototype algorithmique à une application métier concrète et adoptée par les équipes opérationnelles. De nombreux modèles, bien que

performants sur le plan scientifique, peinent à être industrialisés, faute de pouvoir convaincre les décideurs ou d'être facilement exploitables sur le terrain. C'est précisément pour adresser cette problématique de « mise en production » que DecisionBrain a conçu **DB Gene**, une plateforme destinée à transformer les modèles en applications professionnelles complètes.

### De la « boîte noire » à l'outil d'aide à la décision interactif

DB Gene est une plateforme *low-code* qui transforme un modèle d'optimisation (MILP, CP, heuristique...) ou de Machine Learning, souvent perçu comme une « boîte noire », en une application interactive, sans nécessiter de compétences avancées en développement web. Quelques étapes suffisent pour créer une interface que les équipes métier peuvent comprendre, manipuler et exploiter au quotidien pour prendre de meilleures décisions.

Prenons l'exemple d'un modèle d'optimisation de tournées de véhicules. Au lieu de présenter des fichiers de sortie bruts, DB Gene permet de configurer une application où l'utilisateur peut :

1. **Visualiser la solution** sur une carte interactive et des tableaux de bord clairs (KPIs : coût total, km parcourus, taux de service...).
2. **Créer et gérer des scénarios** pour explorer des hypothèses « what-if » : que se passe-t-il

si un véhicule tombe en panne ? Ou si une commande client devient prioritaire ?

3. **Comparer les scénarios** visuellement pour mesurer l'impact de chaque décision et justifier les choix opérationnels.

### Une plateforme complète pensée pour la collaboration

La plateforme prend en charge les aspects fondamentaux mais chronophages du développement, permettant aux équipes RO et IA de se concentrer sur leur cœur de métier : l'algorithmique. En fournissant des outils adaptés à chaque profil, elle facilite la collaboration entre les dépositaires du savoir métier, les scientifiques et l'IT. DB Gene fournit nativement :

- **La gestion des données** : Import, édition et validation des données d'entrée.
- **Des composants graphiques prêts à l'emploi** : Tableaux, Gantt, cartes, graphiques pour une visualisation intuitive des résultats.
- **Une gestion robuste des processus** : Orchestration de workflows (lancement des solveurs, enchaînement des tâches).
- **L'administration des utilisateurs** : Gestion fine des droits et des permissions pour sécuriser l'accès.
- **Un déploiement flexible** : Mise en production qui peut s'adapter à une montée en charge sur n'importe quel Cloud Kubernetes.

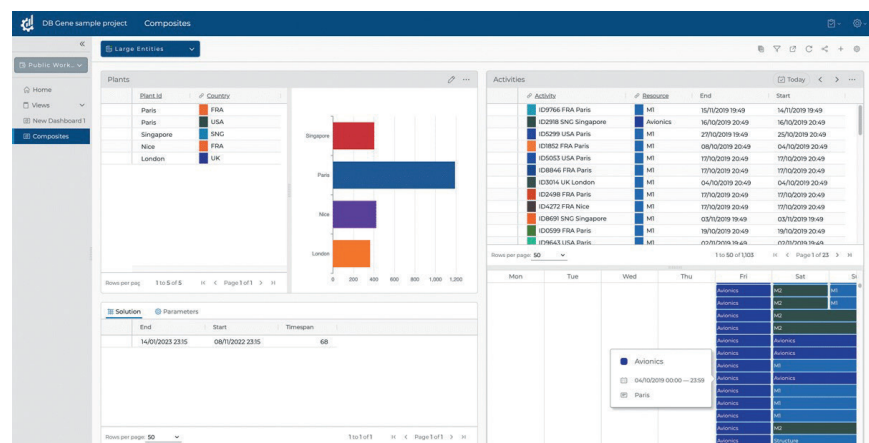


Figure 1 : Exemple d'interface utilisateur (UI) dans DB Gene



Figure 2 : Exemple d'interface utilisateur (UI) dans DB Gene

Cette capacité à transformer rapidement une idée en un outil déployable favorise l'adhésion des décideurs et renforce la crédibilité des équipes de RO et IA. Plus qu'une boîte à outils, DB Gene agit ainsi comme un catalyseur pour l'application industrielle des avancées de notre discipline.

## Zoom sur projets

Nous présentons deux exemples de projets d'aide à la décision réalisés avec la plateforme DB Gene : le premier projet (OPTIMA) porte sur la planification stratégique de la maintenance dans le transport aérien ; le deuxième sur la planification opérationnelle de la main-d'œuvre pour le nettoyage en aéroport.

### Planification stratégique de la maintenance des moteurs d'avion (OPTIMA)

La planification de la maintenance des moteurs d'avion est un problème stratégique à fort impact financier. Les opérations de maintenance de moteurs sont longues (de 3 à 9 mois), coûteuses (jusqu'à 12 millions de dollars), et immobilisent ces équipements. De plus, les compagnies aériennes ayant fréquemment recours à la location (*leasing*) de leurs moteurs, la gestion des flottes est aussi contrainte par les clauses spécifiques des contrats de location.

Face à ce problème, de nombreuses compagnies aériennes opèrent en suivant une approche réactive consistant à planifier les visites des moteurs en atelier à court terme. Cependant, cette approche ne permet pas d'anticiper les pics de charge dans les ateliers de maintenance, ce qui peut générer des engorgements, des pénuries de moteurs de rechange et, *in fine*, l'immobilisation coûteuse d'avions au sol.

Pour répondre à cette problématique, nous avons conçu, en collaboration avec PA Consulting et TGIS Aviation, l'application OPTIMA. Cette application change radicalement de paradigme : la flotte de moteurs n'est plus vue comme une somme de pièces détachées dont la maintenance est opérée en réaction au besoin à court terme, mais comme un système unique et interdépendant, dont la maintenance est planifiée sur un horizon de vingt ans.

OPTIMA repose sur des modèles d'optimisation mathématique (PLNE, heuristiques). Ces modèles intègrent de nombreuses contraintes : cycle de vie des pièces, clauses contractuelles de *leasing*, plans de vol, aléas techniques et introduction de nouveaux appareils. L'application permet aux planificateurs d'analyser et de simuler des scénarios « *what-if* » pour arbitrer des choix stratégiques (e.g. faut-il envoyer un moteur en révision anticipée pour respecter une clause de *leasing*, ou attendre et payer une compensation pour assurer la disponibilité en haute saison ?).

La solution s'adapte aussi bien aux flottes de quelques dizaines d'avions qu'à celles qui en comptent plusieurs centaines, et gère autant les anciennes générations de moteurs que les nouvelles. Les résultats constatés chez plusieurs compagnies aériennes montrent une réduction de 10 à 20 % des coûts de maintenance et de *leasing*, estimée entre 1 et 2 millions de dollars par avion sur son cycle de vie, tout en assurant une meilleure disponibilité de la flotte.

### Planification dynamique des équipes de nettoyage en aéroport

Un acteur mondial du *facility management*, responsable de la propreté de plusieurs grands aéroports a collaboré avec DecisionBrain. Auparavant, la planification des équipes de nettoyage reposait sur des plannings élaborés manuellement. Or les aléas (vols retardés, afflux imprévus de passagers, urgences) forçaient les superviseurs à redéfinir régulièrement les opérations des agents, et la communication entre superviseurs et agents reposant essentiellement sur des appels, les agents manquaient de visibilité sur le terrain.

Afin de remplacer cette planification manuelle et d'en éviter les écueils, DecisionBrain a co-construit avec l'entreprise cliente une application sur mesure de planification dynamique en temps réel des équipes de nettoyage. L'application prend en compte des données en continu (horaires de vol, capteurs d'affluence...). Un moteur d'optimisation, résolvant un problème d'affectation et de réordonnement dynamique, réaffecte les tâches aux agents en cas de perturbation ou d'urgence, en fonction des priorités et de la localisation des équipes. Par ailleurs, l'application fournit des interfaces adaptées à

chaque profil : managers (stratégie), superviseurs (pilotage temps réel sur tablette) et agents (réception des missions sur mobile).

Les gains principaux sont une forte réduction de la charge de planification manuelle et une gestion standardisée des urgences. Les superviseurs bénéficient d'une visibilité complète sur la progression des tâches, leur permettant d'anticiper plutôt que de réagir. Les agents reçoivent des priorités claires et actualisées, améliorant l'efficacité du service. L'entreprise cliente envisage désormais le déploiement de la solution dans d'autres aéroports, mais aussi dans d'autres secteurs exigeants comme la logistique ou la gestion de grands immeubles de bureaux.

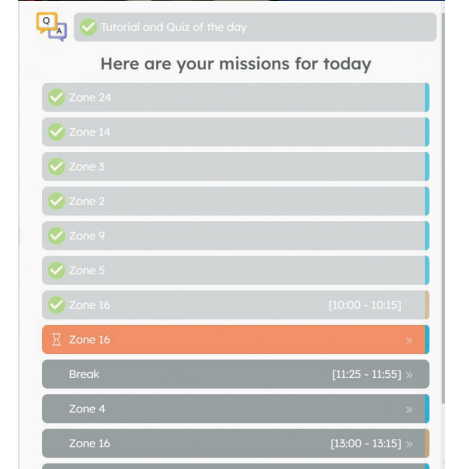



Figure 3 : Agent utilisant l'application sur le terrain

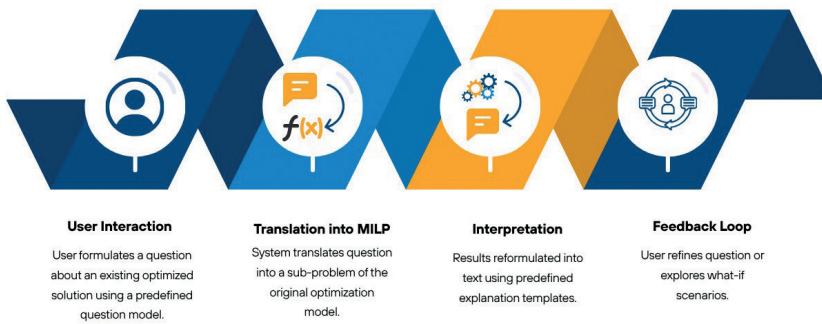


Figure 4 : Framework de génération d'explications de solutions

## La Recherche à DecisionBrain

En parallèle du développement des applications d'aide à la décision DB Gene pour ses clients, DecisionBrain mène également divers travaux de recherche, notamment à travers des collaborations universitaires, des thèses doctorales et des projets postdoctoraux. Nous en présentons deux : la génération d'explications pour les personnes décisionnaires utilisant des outils d'aide à la décision ; l'amélioration de la réoptimisation grâce au Machine Learning pour adapter des solutions devenues caduques après perturbations. Ces travaux visent à rendre les outils d'optimisation plus transparents, réactifs et adaptables, en alignant performance technique et compréhension humaine.

### Explications en optimisation combinatoire

Les outils d'aide à la décision développés par DecisionBrain reposent entre autres sur des techniques d'optimisation combinatoire, comme la programmation linéaire mixte, la programmation par contraintes, ou des méthodes heuristiques. Bien que ces techniques permettent d'obtenir des solutions satisfaisantes, leur complexité et celle des problèmes d'optimisation traités peuvent rendre certaines parties des solutions obtenues difficiles à interpréter, même pour des expertes et experts. Or, lorsque des solutions sont perçues comme contre-intuitives de la part des utilisateurs et utilisatrices, cela peut entraver l'adoption voire même éroder la confiance accordée dans les outils d'aide à la décision. Une piste prometteuse pour surmonter cette difficulté est le développement de techniques d'explication du contenu des solutions.

À DecisionBrain, nous développons un framework de génération d'explications pour des problèmes d'optimisation combinatoire : (i) une question portant sur une solution existante d'un problème d'optimisation est formulée par l'utilisateur ou l'utilisatrice à l'aide d'un modèle de phrase (e.g. « Pourquoi un certain technicien ne réalise pas une certaine tâche dans sa tournée ? », « Comment faire pour qu'il la réalise ? ») ; (ii) cette question est traduite en un calcul basé sur la résolution d'un sous-problème du problème initial ; (iii) le résultat est reformulé en explication accessible à l'aide de textes prédéfinis ; (iv) l'utilisateur ou l'utilisatrice peut raffiner sa question et explorer des scénarios « *what-if* » pour renforcer encore davantage sa compréhension de la solution. Ce framework a été testé dans le cas d'un problème de planification de personnel mobile, permettant aux utilisateurs et utilisatrices de poser des questions à partir d'une trentaine de modèles de question et d'obtenir des explications en moins de 15 secondes dans la plupart des cas.

### Machine Learning pour la réoptimisation

La résolution de problèmes d'optimisation difficiles peut prendre des dizaines de minutes voire des heures. Cependant, une solution optimale peut finalement devenir obsolète en cas de perturbation survenant peu de temps avant son exécution (e.g. une panne de machine). Dans une telle situation, les personnes décisionnaires ont besoin d'une nouvelle solution qui : (a) tienne compte de la perturbation ; (b) soit calculée rapidement (par exemple, quelques secondes ou minutes) ; (c) reste proche de la solution initiale, avant perturbation, pour limiter les bouleversements. Les méthodes générant une solution révisée satisfaisant autant que possible ces trois critères relèvent du domaine de la réoptimisation.

À DecisionBrain, nous travaillons actuellement sur une approche « *fix-and-optimize* », s'appuyant sur de la programmation linéaire mixte et du *Machine Learning*, visant à réoptimiser efficacement les solutions de *Lot Sizing*. Les prédictions d'un modèle de *Graph Neural Network* (GNN) sont utilisées pour fixer des variables de décision du problème original, réduisant et concentrant l'ensemble des solutions faisables autour de la solution originale, et permettant d'accélérer la résolution et l'obtention d'une solution révisée adaptée.

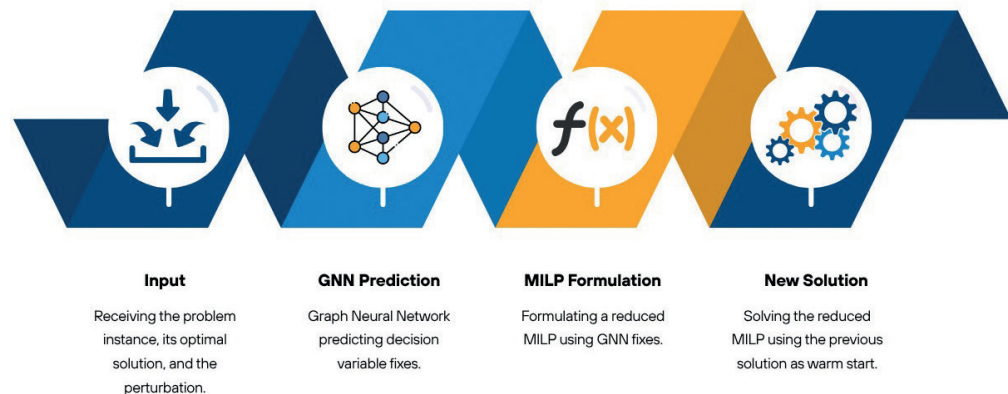


Figure 5 : Approche « *fix-and-optimize* » pour la réoptimisation de solutions utilisant les prédictions d'un GNN

Ces recherches sont en cours et font l'objet de développements actifs, avec pour objectif de valider et renforcer cette approche dans des contextes industriels.

## ET L'IA GÉNÉRATIVE DANS TOUT CELA ?

Nous partageons ici notre vision et notre expérience de l'usage de l'IA Générative (GenAI). Plus précisément, nous décrivons comment nous utilisons ou comptons utiliser la GenAI à différentes étapes de nos projets.

Une première utilisation est la conversion de fichiers des utilisateurs en un modèle de données entité-relation au format JDL, le format de modélisation de données utilisé par nos applications DB Gene. Un convertisseur utilisant de la GenAI prend en entrée des contenus hétérogènes (e.g. fichier csv, texte, image, audio), les normalise, puis produit en sortie une première proposition de modèle de données. Un second module reprend le modèle de données et le valide en appliquant des relances ciblées en cas d'erreur, de sorte à aboutir à un modèle JDL exploitable par une application DB Gene. Une deuxième utilisation est, pour un projet donné, la constitution et l'exploitation d'une base de connaissances regroupant la documentation non structurée, les tickets de suivi de projet (JIRA) et le code source. Les documents et les tickets servent à définir le contexte du projet ; le code sert de source d'autorité pour lever les ambiguïtés et gérer l'obsolescence de la documentation. L'objectif ici est de répondre rapidement aux questions des clients avec des contenus sourcés (documentation ou tickets).

Une troisième utilisation est l'analyse des données du projet (données d'entrée, données de sortie, scénarios « *what-if* »). Pour cela, nous avons développé un agent capable d'organiser les données du projet en un graphe (en s'appuyant sur le modèle JDL) et, étant une question en langage naturel, d'identifier les parties en lien avec cette question. En termes d'analyse de données, cette identification se traduit en jointures de tables de données, qui sont ensuite utilisées pour réaliser des analyses statistiques simples (tableaux, agrégations, visualisations). L'objectif est de permettre à l'utilisateur de mieux comprendre les données du projet, leurs interactions, suivant un mode conversationnel.

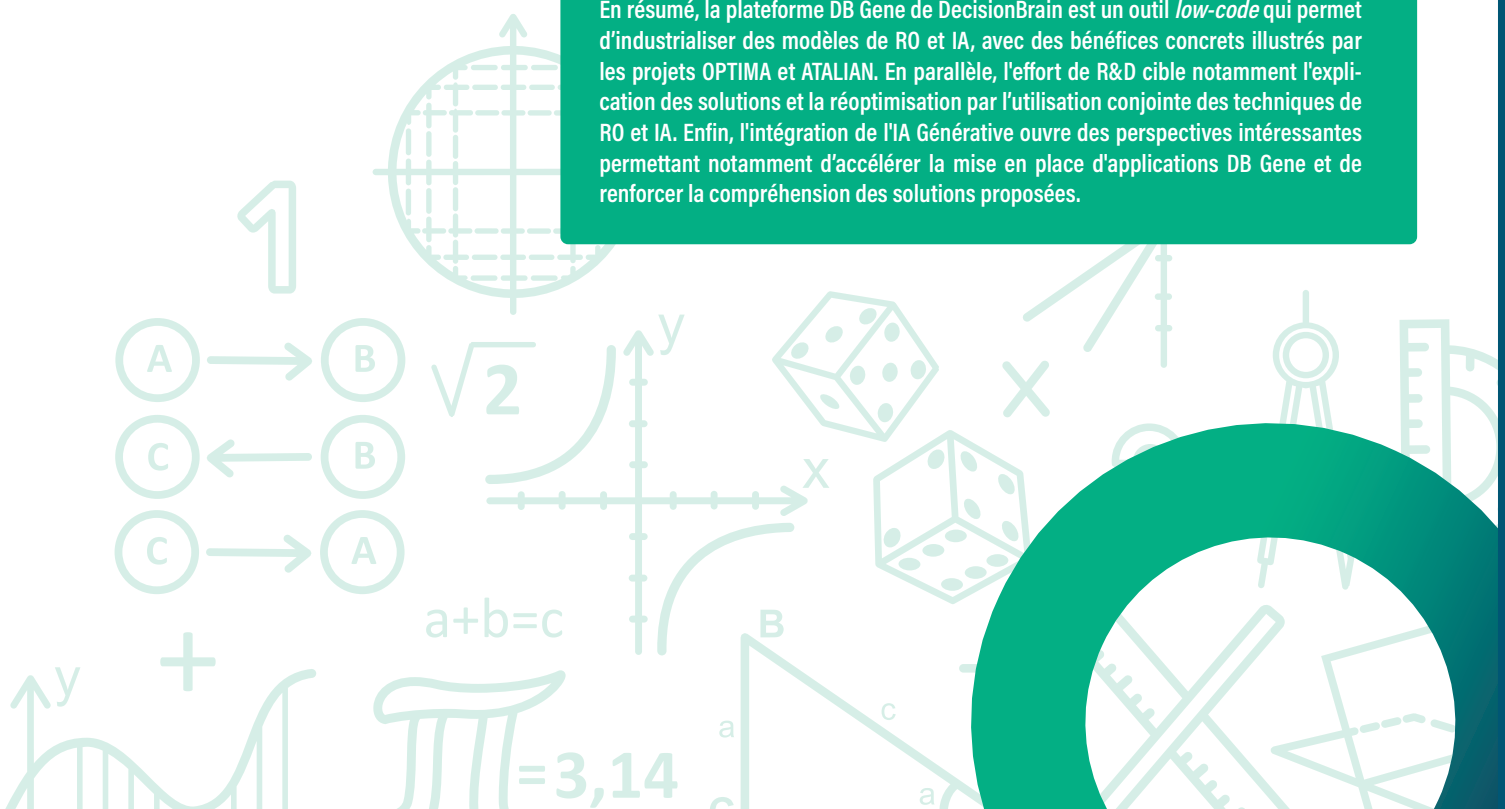
Une quatrième utilisation est le contrôle de la cohérence et de la qualité des données d'entrée et de sortie. Nous travaillons sur un prototype d'agent qui à partir d'énoncés en langage naturel génère un ensemble de règles métiers (Drools) utilisé pour alerter l'utilisateur en cas d'incohérence et/ou de non-respect de contraintes.

Une cinquième et dernière utilisation, en lien avec les travaux de recherche présentés précédemment, est l'explication de solutions. Prenons l'exemple d'un utilisateur métier qui demande : « Pourquoi avoir affecté la ressource A à cette tâche plutôt que B ? ». L'ambition est de développer un agent capable de construire un scénario « B à la place de A », de relancer l'optimisation, de comparer les indicateurs de performances (KPIs) des solutions obtenues, et d'en déduire une réponse à la question de l'utilisateur, dont la véracité et la traçabilité soient garanties par les différentes étapes de ce processus. À terme, nous pourrions même envisager des agents spécialisés, adaptés à chaque application DB Gene (LoRA), capables de répondre directement à des questions « pourquoi » fréquentes sans passer par la création de scénarios « *what-if* » et l'optimisation.

Ainsi, via ces différentes utilisations, la GenAI permet d'accélérer la mise en place d'applications DB Gene, de donner la possibilité à des profils non-techniques de contribuer directement au projet et de renforcer la compréhension par les utilisateurs des solutions calculées, tout en préservant le cadre de fonctionnement de DB Gene, (modèle de données JDL, solveurs...).

## CONCLUSION

En résumé, la plateforme DB Gene de DecisionBrain est un outil *low-code* qui permet d'industrialiser des modèles de RO et IA, avec des bénéfices concrets illustrés par les projets OPTIMA et ATALIAN. En parallèle, l'effort de R&D cible notamment l'explication des solutions et la réoptimisation par l'utilisation conjointe des techniques de RO et IA. Enfin, l'intégration de l'IA Générative ouvre des perspectives intéressantes permettant notamment d'accélérer la mise en place d'applications DB Gene et de renforcer la compréhension des solutions proposées.





# L'apprentissage supervisé pour la recherche opérationnelle

..... Par Zacharie Ales

De nombreuses décisions peuvent améliorer la résolution de problèmes d'optimisation combinatoire : la formulation considérée, l'algorithme de résolution, les paramètres de cet algorithme (e.g., voisinages considérés, stratégies de branchement, gestion des symétries, heuristique primale), etc. Ces choix peuvent être guidés par l'expérience de l'utilisateur, les travaux de l'état de l'art ou, par défaut, faute de temps, d'intuition ou de résultats concluants. Par exemple, la majorité des nombreux paramètres de solveurs tels que SCIP, CPLEX ou Gurobi sont généralement laissés à leur valeur par défaut. L'apprentissage automatique (ML) offre un ensemble de méthodes qui peuvent aider à effectuer ces choix. Ce domaine a permis d'atteindre d'impressionnantes performances ces dernières années en reconnaissance d'images ou en traitement du langage naturel, et un intérêt grandissant est dédié à leur utilisation pour la résolution de problèmes d'optimisation.

Considérons par exemple un fournisseur d'énergie qui doit quotidiennement acheter des matières premières pour alimenter ses installations afin de répondre à la demande de ses clients. Ce fournisseur résout ainsi chaque jour une instance d'un problème d'optimisation dont une partie des données varie d'un jour à l'autre (e.g., le prix des matières premières et les demandes des clients) tandis que les autres restent identiques (e.g., installations disponibles et contraintes qui en découlent). Les instances de ce problème précédemment résolues par l'entreprise constituent un ensemble de données qu'il est généralement difficile d'exploiter par des méthodes issues de la recherche opérationnelle classique mais qui se prête tout à fait à des approches issues du ML.

Cet article a pour objectif de donner un très rapide aperçu de ce qu'est le ML et de présenter des exemples de contextes dans lesquels le ML a été utilisé afin d'améliorer la résolution de problèmes d'optimisation combinatoire. De plus amples détails peuvent être trouvés dans les deux *surveys* suivantes [3, 31] ainsi que sur ce site [29] qui référence un grand nombre de travaux triés par problème considéré.

## QU'EST-CE QUE LE ML ?

De manière très générale, le ML consiste à apprendre à réaliser une tâche à partir d'un ensemble fini de données potentiellement bruitées. Les deux champs de recherche du ML les plus souvent considérés pour aider à la résolution de problèmes combinatoires sont l'apprentissage supervisé et l'apprentissage par renforcement.

### Apprentissage supervisé

En apprentissage supervisé, une donnée est représentée par un couple  $(x, y)$  tel que  $x \in R^m$  est un vecteur de caractéristiques et  $y \in K$  correspond à une valeur associée que l'on souhaite apprendre à prédire à partir de  $x$ . Lorsque  $y$  correspond à une valeur numérique, on fait face à un problème de *régression*, tandis que si  $y$  prend ses valeurs dans un ensemble discret, on parle de *classification supervisée* (chaque valeur possible de  $y$  correspondant à une classe). Un *jeu de données*  $D = \{(x_i, y_i)\}_{i=1}^n$  est constitué d'un ensemble de données. Voici deux exemples de jeux de données classiques en ML :

- *MNIST* contient  $n = 70000$  données telles que  $x \in R^{784}$  correspond aux pixels d'une image représentant un chiffre manuscrit et  $y \in \{0, 1, \dots, 9\}$  correspond au chiffre représenté sur l'image ;
  - *iris* contient  $n = 150$  données telles que  $x \in R^4$  correspond à des mesures d'une fleur (dimensions des sépales et des pétales) et  $y$  à son espèce.
- L'objectif de l'apprentissage supervisé est d'apprendre une fonction ou *modèle*  $f: R^m \rightarrow K$  telle que pour chaque donnée  $(x, y)$ , la prédiction  $f(x)$  soit aussi proche que possible de  $y$ . La proximité entre  $y$  et  $f(x)$  est estimée par une fonction de perte  $\ell: K \times K \rightarrow R$ .

On considère que  $x$  et  $y$  sont des variables aléatoires suivant une loi jointe  $P$  et on cherche à optimiser  $\ell$  sur une famille de modèles  $F = \{f_\theta: \theta \in R^p\}$ . Le problème de l'apprentissage supervisé s'écrit donc ainsi :

$$\min_{\theta \in R^p} E_{x, y \sim P} (\ell(y, f_\theta(x))) \quad (1)$$

En pratique, la loi jointe  $P$  étant inconnue, on approxime (1) en minimisant le risque empirique sur un sous-ensemble d'entraînement  $D_e \subset D$  :

$$\min_{\theta \in R^p} \frac{1}{|D_e|} \sum_{i=1}^{|D_e|} \ell(y_i, f_\theta(x_i)) \quad (2)$$

Un des principaux choix à réaliser pour la résolution de (2) est la famille de modèles  $F$  considérée. Il en existe différentes classiquement utilisées (arbres de décisions, forêts aléatoires, SVM...) mais actuellement ce sont généralement les réseaux de neurones qui fournissent les meilleures performances. Un réseau de neurones est typiquement composé d'une succession de *couches* de neurones. Une couche réalise une transformation linéaire  $Az+b$  sur son entrée  $z$  et applique ensuite une fonction non-linéaire  $\sigma(Az+b)$ . Un exemple de fonction couramment utilisée est  $\text{ReLU}(x) = \max(0, x)$ . La première couche du réseau prend en entrée le vecteur de caractéristiques  $x$  tandis que les couches suivantes prennent comme entrée la sortie de la couche précédente. Pour une tâche de classification, la dernière couche du réseau aura  $K$  neurones. Le réseau prédira la classe dont le neurone retourne la valeur la plus élevée. Les paramètres du réseau sont les coefficients  $A$  et  $b$  des différentes couches qui sont initialisés aléatoirement et appris itérativement par rétropropagation en utilisant l'algorithme du gradient stochastique.

Pour permettre la prise en compte de différents types de données, de nombreuses familles de réseaux de neurones ont été définies :

- les réseaux de neurones en graphes (GNN) qui prennent en entrée des graphes ;
- les réseaux de neurones convolutionnels (CNN) qui prennent en entrée des images ;
- les transformers qui permettent la prise en compte de données séquentielles telles que les séries temporelles ou le texte en langage naturel.

### Généralisation

La minimisation de (2) peut entraîner un phénomène courant en ML appelé le *surapprentissage*. Cela signifie que le modèle a de bonnes performances sur les données d'entraînement  $D_e$  mais des performances de moindre qualité sur d'autres données issues de  $P$ . En d'autres termes, une faible valeur de (2) ne se traduit pas par une faible valeur de (1). On dit alors que le modèle ne *généralise* pas aux données en dehors de l'ensemble d'entraînement.

Pour éviter le surapprentissage, différentes techniques sont utilisées. La qualité d'un modèle n'est par exemple pas évaluée sur les données d'entraînement  $D_e$  mais sur des données de test

$D_t \subset D \setminus D_e$ . Des termes de régularisation peuvent également être incorporés à la fonction de perte  $\mathcal{L}$  afin de privilégier la simplicité des modèles.

### Apprentissage par renforcement

L'apprentissage par renforcement (RL) a pour objectif de déterminer une *politique* de décision optimale dans un environnement incertain. À chaque étape, un agent reçoit un *état* de l'environnement et choisit une *action* selon sa politique. Cette action l'emmène dans un nouvel état et lui fournit une *récompense*. Le modèle explicite du système étant inconnu, le RL interagit avec l'environnement afin d'optimiser sa politique.

Le RL peut par exemple permettre de modéliser un problème de la maintenance prédictive d'un ensemble de machines. L'incertitude de l'environnement venant ici du fait que l'on ne sait pas quand une machine tombera en panne.

### Le processus de décision markovien (MDP)

Le RL repose généralement sur un MDP  $(S, A, P, R, \gamma)$  dans lequel :

- $S$  est l'ensemble des *états* du système (e.g., : état estimé de la qualité des machines) ;
- $A$  est l'ensemble des *actions* possibles dans chaque état (e.g., : réaliser une maintenance sur une machine ou ne rien faire) ;
- $P(s'|s, a)$  est la *probabilité de transition* vers un nouvel état  $s'$  lorsque l'action  $a$  est réalisée dans l'état  $s$  (e.g., : une des machines tombe en panne) ;
- $R(s, a)$  est la *récompense* immédiate obtenue en prenant l'action  $a$  dans l'état  $s$  (e.g., : perte due à une maintenance ou à une machine tombant en panne) ;
- $\gamma \in [0, 1]$  est le *facteur d'actualisation*, qui pondère les récompenses futures.

La fonction de récompense  $R$  peut par exemple prendre les valeurs d'un expert connu dont on souhaite reproduire le comportement. On parle dans ce cas d'apprentissage par imitation (IL). Lorsqu'on ne dispose pas d'expert, ou que l'on souhaite trouver des stratégies originales et potentiellement meilleures que celles d'un expert connu, la fonction  $R$  est estimée par l'utilisateur.

Étant donné un MDP, l'objectif du RL consiste à trouver une politique optimale  $\pi^*(s)$  maximisant la fonction de valeur :

$$V^\pi(s) = E[\sum_{t=0}^{\infty} \gamma^t R(s_t, a_t) | s_0 = s].$$

Cette fonction de valeur suit l'équation de Bellman et le problème peut donc être formulé par programmation dynamique. La difficulté vient du fait que les modèles de transition  $P$  et les récompenses réelles ne sont pas explicitement connus.

L'agent apprend la dynamique de l'environnement par essai-erreur, en interagissant directement avec l'environnement et en ajustant progressivement sa politique à partir des récompenses observées. Il est toutefois confronté à un dilemme fondamental d'exploration-exploitation : doit-il choisir des actions nouvelles afin d'améliorer sa connaissance de l'environnement (*exploration*), ou au contraire privilégier les actions déjà identifiées comme performantes (*exploitation*) pour maximiser la récompense immédiate ?

## EXEMPLES D'UTILISATION DU ML POUR RÉSOUDRE DES PROBLÈMES DE RO

[3] identifie deux principaux types d'utilisations du ML pour aider à résoudre des problèmes de RO :

- **Cas 1** : *expertise existante mais coûteuse* : remplacer le calcul de décisions que l'on sait faire de manière coûteuse par un algorithme rapide ;
- **Cas 2** : *manque d'expertise* : prendre des décisions que l'on ne saurait pas prendre.

Ces deux approches ont été explorées pour l'identification de stratégies de branchement.

### Stratégie de branchement d'un branch-and-bound (B&B)

À chaque itération de l'algorithme du B&B, une variable dont la valeur de la relaxation linéaire est fractionnaire doit être sélectionnée afin de brancher dessus. Ce choix a un très grand impact sur la taille de l'arbre obtenu et donc sur le temps de résolution. Une heuristique efficace mais coûteuse pour résoudre ce problème est la *strong branching*. Elle consiste à calculer l'ensemble des relaxations linéaires obtenues en branchant sur chaque variable fractionnaire et à sélectionner celle qui permet la meilleure réduction du gap. Cette approche, bien qu'efficace en termes de taille des arbres obtenus, est trop coûteuse en temps de calcul pour être considérée en pratique. En revanche, elle se prête tout à fait à l'apprentissage par imitation (cas 1).

Un des principaux travaux dans cette voie est celui de Gass et al. [13]. Il introduit un algorithme d'IL permettant de prédire la solution du strong branching en une fraction de son temps de calcul. Les auteurs ont ainsi appris, pour différentes familles d'instances d'un même problème, des stratégies de branchement fournissant de meilleures performances que celles du solveur SCIP.

Bien que l'apprentissage par imitation fournisse de bonnes performances, on peut néanmoins se demander s'il serait possible de trouver des stratégies de branchement qui soient meilleures que celle du strong branching (cas 2). Ainsi, différents travaux ont utilisé du RL pour cette tâche en utilisant une formulation proche de celle d'un MDP [12, 24, 25], mais fournissant des résultats moins bons que l'IL. Afin d'améliorer ces performances, [27] introduit pour la première fois un véritable MDP pour ce problème. Des résultats préliminaires récents basés sur ce MDP montrent des performances compétitives, voire meilleures que celles de l'IL, permettant l'obtention de stratégies significativement différentes de celles du strong branching.

Afin d'utiliser un modèle de ML, il est nécessaire de déterminer les données qui seront fournies en entrée et la façon dont elles seront traitées.

L'approche la plus évidente pour représenter un MILP consiste à créer un vecteur de taille fixe qui le décrit. Ainsi, un des premiers travaux pour l'apprentissage de stratégie de branchement considère pour chaque variable un vecteur de taille 72 [19] contenant notamment : la valeur du coefficient associé dans l'objectif, la distance de sa valeur fractionnaire aux entiers inférieur et supérieur, le ratio moyen entre

la valeur du coefficient dans les contraintes et leur second membre...

Une des principales contributions de [13] a été de proposer une représentation d'un MILP sous la forme d'un graphe biparti dans lequel un sommet est associé à chaque variable et à chaque contrainte. Pour tout coefficient  $a_{ij}$  non nul de la matrice des contraintes, une arête de poids  $a_{ij}$  est créée entre les deux sommets correspondants. Ce graphe constitue ensuite l'entrée d'un GNN. Cette représentation a les avantages d'être invariante par permutation des contraintes ou des variables dans le modèle, d'être rapide à calculer, et de pouvoir s'appliquer quelle que soit la taille du MILP considéré. Ainsi, elle a été utilisée par la suite pour l'apprentissage de différentes tâches relatives aux MILP.

### Génération de coupes

La génération de coupes renforce la relaxation linéaire de noeuds du B&B afin de réduire la taille de l'arbre de recherche. L'ajout de coupes n'est cependant pas toujours bénéfique car il augmente la taille du problème et donc le temps de résolution des relaxations linéaires considérées dans la suite de l'arbre. Contrairement au strong branching pour la sélection de variables, il n'existe pas d'expert connu permettant de déterminer efficacement quand et quelles coupes ajouter. Ainsi, les approches de ML pour ce problème s'intéressent généralement à ajouter des coupes qui vont maximiser la réduction du gap ou à déterminer s'il faut ou non ajouter des coupes.

Un des premiers travaux dans ce contexte était dédié au renforcement de la relaxation SDP de problèmes quadratiques non-convexes [1]. Afin d'identifier les coupes les plus intéressantes à ajouter, un réseau de neurones apprend à prédire la valeur de la relaxation SDP obtenue lorsqu'on les ajoute. On peut également citer [28] qui considère une approche par renforcement permettant d'améliorer les performances de SCIP sur des classes d'instances de petite taille.

Dans [4], des forêts aléatoires sont utilisées pour déterminer s'il faut générer des coupes uniquement à la racine ou à tous les noeuds du B&B. [16] utilise un SVM pour déterminer si des coupes de Benders doivent être ajoutées ou non. Le modèle utilisé a pour objectif de prédire quelles coupes seront serrées à l'optimum ou permettront d'améliorer significativement la valeur de la relaxation.

Un état des lieux plus exhaustif sur ce sujet peut être trouvé dans [9].

### Configuration ou choix d'algorithmes

Il n'est pas toujours aisé de déterminer le meilleur algorithme à utiliser ou sa meilleure configuration pour résoudre un problème donné. Différents travaux s'intéressent à apprendre ce type de décisions. Une des premières approches dans cette direction avait pour but de déterminer s'il fallait ou non appliquer une décomposition de Dantzig-Wolfe à un MILP [21]. Dans [7], les auteurs s'intéressent à déterminer si des termes quadratiques doivent être linéarisés ou non. La qualité des résultats obtenus a permis l'incorporation de ce modèle dans la version 12.10 de CPLEX.

[17] utilise des chaînes de Markov pour déterminer quelles composantes utiliser dans une métaheuristique tandis que [15] s'intéresse plus généralement à apprendre la configuration d'un solveur.

Pour l'algorithme du simplexe, on peut par exemple citer [14] qui apprend à choisir quelle variable faire entrer en base et [5] qui détermine quelle méthode de conditionnement utiliser pour limiter la propagation d'erreurs.

### Prédire une solution

L'obtention d'une solution optimale  $y$  d'une instance  $x$  d'un problème d'optimisation combinatoire peut se représenter ainsi :

$$\min_{y \in Y(x)} f^0(y, x)$$

où  $Y(x)$  est l'ensemble des solutions réalisables de l'instance  $x$  et  $f^0$  correspond à la valeur de l'objectif de la solution  $y$ .

Supposons que, comme le fournisseur d'énergie considéré en introduction, on souhaite pouvoir résoudre efficacement des instances similaires provenant d'un ensemble  $X$ . Les approches classiques de RO définiront généralement un algorithme capable de résoudre n'importe quelle instance  $x \in X$  sans tenir compte de potentiels liens entre  $x$  et les autres instances de  $X$ . En machine learning, on considérera au contraire que les instances de  $X$  sont la réalisation d'une même variable aléatoire  $X$ . Étant donné un ensemble d'entraînement  $\{(x_i, y_i)\}_{i=1}^n$  d'instances déjà résolues, l'identification d'une solution peut se modéliser par un problème d'apprentissage supervisé. L'objectif est alors d'identifier une politique  $\pi: x \in X \rightarrow Y(x)$  minimisant le risque empirique

$$\min_{\pi \in \Pi} \frac{1}{n} \sum_{i=1}^n \ell(\pi(x_i), y_i)$$

où  $\Pi$  est l'ensemble des politiques considérées et  $\ell$  une fonction de perte quantifiant la différence entre les solutions.

Diverses familles de modèles  $\Pi$  ont été considérées pour résoudre (4) : des arbres de décisions [6], des GNN pour des problèmes d'affectation quadratique [22], des mécanismes d'attention [20], des architectures dédiées de réseaux de neurones [30], ...

La prédiction directe de solutions de problèmes combinatoires fournit cependant des résultats qui sont dans la plupart des cas peu compétitifs par rapport aux algorithmes de l'état de l'art. Pour pallier cela, certaines approches considèrent des objectifs moins ambitieux. Dans [10], seule une affectation partielle des variables d'un modèle est réalisée, qui sera ensuite complétée en résolvant un MILP. [26] apprend à décomposer le problème en plusieurs sous-problèmes résolus également par MILP. [8] détermine quelles heuristiques primales de solveurs utiliser et dans quel ordre afin d'obtenir les meilleures solutions. Enfin, [16] prédit itérativement la ville suivante à visiter afin de construire une solution de TSP.

Une autre approche considérée pour contourner la difficulté de prédire directement une solution est l'optimisation combinatoire augmentée par apprentissage automatique (COAML). Dans ce contexte, un réseau de neurones prédit un vecteur  $\alpha$  qui sera utilisé comme entrée d'un problème combinatoire plus simple calculant une solution du problème initial [11]. Par exemple, pour résoudre un problème ayant une fonction objectif non-linéaire complexe,  $\alpha$  peut

correspondre aux coefficients d'un objectif linéaire qui sera plus aisé à optimiser. Ainsi, après prédiction de  $\alpha$  par le réseau de neurones, une solution sera obtenue en résolvant :

$$\max_{y \in Y(x)} \alpha^T y$$

Une idée clé du COAML est que la résolution de ce problème plus simple est considérée comme une couche du réseau de neurones. Ceci permet d'entraîner le réseau à prendre les meilleures décisions au sens de l'objectif du problème initial sans nécessiter de réaliser séparément l'apprentissage de  $\alpha$  et l'optimisation de la solution. Cependant, la résolution de problèmes combinatoires n'est généralement pas différentiable, ce qui empêche de rétro-propager les gradients à travers cette dernière couche du réseau. Pour pallier cela, il est donc parfois nécessaire d'en considérer une approximation.

COAML a par exemple été appliqué à un problème d'ordonnancement de véhicules stochastique [23]. Dans ce contexte, la couche combinatoire du réseau était une version déterministe et polynomiale du problème d'ordonnancement dont les paramètres  $\alpha$  étaient déterminés par les couches précédentes. Une approche similaire utilisant des GNN a permis de gagner le challenge EURO-NeurIPS dédié à la résolution d'un problème de vehicle routing dynamique [2].

### Perspectives

Le ML a été utilisé dans de nombreux contextes pour aider à résoudre des problèmes d'optimisation combinatoires et tout porte à croire que les activités de recherche combinant ces deux domaines continueront de se développer dans les prochaines années. Pour certaines tâches, les résultats obtenus ont permis des améliorations significatives des performances (e.g, choix de linéariser ou non un problème quadratique dans CPLEX). Pour d'autres, les résultats sont encourageants mais pas encore suffisants pour en démocratiser leur utilisation. C'est par exemple le cas des stratégies de branchement ou de la génération de coupes qui donnent de bonnes performances pour des jeux de données fixés mais ne généralisent pas encore à tous types d'instances et toutes tailles de problèmes.

En pratique, le choix des caractéristiques, du modèle, de la fonction de perte, ou de l'algorithme utilisé pour réaliser l'apprentissage peuvent avoir un impact déterminant sur les performances d'une méthode de ML. Cependant, il s'avère souvent ardu d'identifier l'approche la plus appropriée pour une tâche étant donné l'étendue des méthodes existantes et la richesse des travaux publiés. En effet, la conférence AAAI, l'une des plus prestigieuses du domaine de l'intelligence artificielle, a par exemple reçu cette année plus de 29 000 soumissions..

Les perspectives dans ce domaine sont nombreuses. Le ML pourrait tout d'abord être utilisé pour de nouvelles tâches liées à des problèmes d'optimisation combinatoire. Pour les tâches existantes, la définition de nouvelles représentations de l'état ou de nouvelles architectures de réseaux de neurones pourraient améliorer les performances, comme ce fut le cas des graphes bipartis introduits dans [13] pour la représentation de MILPs. On peut également envisager d'utiliser des modèles interprétables tels que les arbres de décision qui, par leur simplicité, pourraient permettre d'obtenir des connaissances expertes sur des problématiques où ces dernières sont manquantes. Enfin, nous nous sommes concentrés dans cet article sur l'utilisation du ML



$$\sin a = \frac{a}{c}$$

$$\sqrt{x}$$

pour résoudre des problèmes de RO, mais de nombreux travaux sont également dédiés à modéliser et résoudre des problèmes de ML par le biais d'approches issues de la RO.

En conclusion, le ML fournit un ensemble d'outils complémentaires à ceux de la RO qui, par la prise en compte de données, peuvent nous permettre de prendre de meilleures décisions.

## BIBLIOGRAPHIE

- [1] Radu Baltean-Lugojan, Pierre Bonami, Ruth Misener, and Andrea Tramontani. Scoring positive semidefinite cutting planes for quadratic optimization via trained neural networks. pre-print: [http://www.optimization-online.org/DB\\_HTML/2018/11/6943.html](http://www.optimization-online.org/DB_HTML/2018/11/6943.html), 2019.
- [2] Léo Baty, Kai Jungel, Patrick S Klein, Axel Parmentier, and Maximilian Schiffer. Combinatorial optimization-enriched machine learning to solve the dynamic vehicle routing problem with time windows. *Transportation Science*, 58(4):708–725, 2024.
- [3] 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.
- [4] Timo Berthold, Matteo Francobaldi, and Gregor Hendel. Learning to use local cuts. *Mathematical Programming Computation*, pages 1–14, 2025.
- [5] Timo Berthold and Gregor Hendel. Learning to scale mixed-integer programs. In *Proceedings of the AAAI Conference on Artificial Intelligence*, volume 35, pages 3661–3668, 2021.
- [6] Dimitris Bertsimas and Bartolomeo Stellato. The voice of optimization. *Machine Learning*, 110(2):249–277, 2021.
- [7] Pierre Bonami, Andrea Lodi, and Giulia Zarpellon. Learning a classification of mixed-integer quadratic programming problems. In *International conference on the integration of constraint programming, artificial intelligence, and operations research*, pages 595–604. Springer, 2018.
- [8] Antonia Chmiela, Elias Khalil, Ambros Gleixner, Andrea Lodi, and Sebastian Pokutta. Learning to schedule heuristics in branch and bound. *Advances in Neural Information Processing Systems*, 34:24235–24246, 2021.
- [9] Arnaud Deza and Elias B Khalil. Machine learning for cutting planes in integer programming: A survey. *arXiv preprint arXiv:2302.09166*, 2023.
- [10] Jian-Ya Ding, Chao Zhang, Lei Shen, Shengyin Li, Bing Wang, Yinghui Xu, and Le Song. Accelerating primal solution findings for mixed integer programs based on solution prediction. In *Proceedings of the aaai conference on artificial intelligence*, volume 34, pages 1452–1459, 2020.
- [11] Adam N Elmachtoub and Paul Grigas. Smart “predict, then optimize”. *Management Science*, 68(1):9–26, 2022.
- [12] Marc Etheve, Zacharie Ales, Côme Bissuel, Olivier Juan, and Safia Kedad-Sidhoum. Reinforcement learning for variable selection in a branch and bound algorithm. In *International conference on integration of constraint programming, artificial intelligence, and operations research*, pages 176–185. Springer, 2020.
- [13] Maxime Gasse, Didier Chételat, Nicola Ferroni, Laurent Charlin, and Andrea Lodi. Exact combinatorial optimization with graph convolutional neural networks. *Advances in neural information processing systems*, 32, 2019.
- [14] Gregor Hendel, Matthias Miltenberger, and Jakob Witzig. Adaptive algorithmic behavior for solving mixed integer programs using bandit algorithms. In *Operations Research Proceedings 2018: Selected Papers of the Annual International Conference of the German Operations Research Society (GOR)*, Brussels, Belgium, September 12–14, 2018, pages 513–519. Springer, 2019.
- [15] Gabriele Iomazzo, Claudia D'Ambrosio, Antonio Frangioni, and Leo Liberti. Algorithm configuration problem. In *Encyclopedia of Optimization*, pages 1–8. Springer, 2022.
- [16] Huiwen Jia and Siqian Shen. Benders cut classification via support vector machines for solving two-stage stochastic programs. *INFORMS Journal on Optimization*, 3(3):278–297, 2021.
- [17] Daniel Karapetyan, Abraham P Punnen, and Andrew J Parkes. Markov chain methods for the bipartite boolean quadratic programming problem. *European Journal of Operational Research*, 260(2):494–506, 2017.
- [18] Elias Khalil, Hanjun Dai, Yuyu Zhang, Bistra Dilikina, and Le Song. Learning combinatorial optimization algorithms over graphs. *Advances in neural information processing systems*, 30, 2017.
- [19] Elias Khalil, Pierre Le Bodic, Le Song, George Nemhauser, and Bistra Dilikina. Learning to branch in mixed integer programming. In *Proceedings of the AAAI conference on artificial intelligence*, volume 30, 2016.
- [20] Wouter Kool, Herke Van Hoof, and Max Welling. Attention, learn to solve routing problems! *arXiv preprint arXiv:1803.08475*, 2018.
- [21] Markus Kruber, Marco E Lübbecke, and Axel Parmentier. Learning when to use a decomposition. In *International conference on AI and OR techniques in constraint programming for combinatorial optimization problems*, pages 202–210. Springer, 2017.
- [22] Alex Nowak, Soledad Villar, Afonso S Bandeira, and Joan Bruna. Revised note on learning quadratic assignment with graph neural networks. In *2018 IEEE Data Science Workshop (DSW)*, pages 1–5. IEEE, 2018.
- [23] Axel Parmentier. Learning to approximate industrial problems by operations research classic problems. *Operations Research*, 70(1):606–623, 2022.
- [24] Christopher WF Parsonson, Alexandre Laterre, and Thomas D Barrett. Reinforcement learning for branch-and-bound optimisation using retrospective trajectories. In *Proceedings of the AAAI Conference on Artificial Intelligence*, volume 37, pages 4061–4069, 2023.
- [25] Lara Scavuzzo, Karen Aardal, Andrea Lodi, and Neil Yorke-Smith. Machine learning augmented branch and bound for mixed integer linear programming. *Mathematical Programming*, pages 1–44, 2024.
- [26] Jialin Song, Yisong Yue, Bistra Dilikina, et al. A general large neighborhood search framework for solving integer linear programs. *Advances in Neural Information Processing Systems*, 33:20012–20023, 2020.
- [27] Paul STRANG, ALES Zacharie, Côme Bissuel, Safia Kedad-Sidhoum, Olivier Juan, and Emmanuel Rachelson. A markov decision process for variable selection in branch and bound.
- [28] Yunhao Tang, Shipra Agrawal, and Yuri Faenza. Reinforcement learning for integer programming: Learning to cut. In *International conference on machine learning*, pages 9367–9376. PMLR, 2020.
- [29] Thinklab-SJTU. Awesome machine learning for combinatorial optimization (awesome-ml4co), 2025. Consulté le 29 octobre 2025.
- [30] Oriol Vinyals, Meire Fortunato, and Navdeep Jaitly. Pointer networks. *Advances in neural information processing systems*, 28, 2015.
- [31] Jiayi Zhang, Chang Liu, Xijun Li, Hui-Ling Zhen, Mingxuan Yuan, Yawen Li, and Junchi Yan. A survey for solving mixed integer programming via machine learning. *Neurocomputing*, 519:205–217, 2023.

## hORs-les-murs



# Fabriquer des instances, générer du savoir

La création de générateurs d'instances fait depuis longtemps partie des pratiques de la recherche opérationnelle. Elle répond au besoin de disposer de jeux de données contrôlés, reproductibles et permettant d'évaluer nos formidables algorithmes. Ces générateurs permettent de tester les algorithmes dans des contextes variés, de mesurer leur robustesse et d'assurer la comparabilité des résultats.

Concevoir un générateur, c'est aussi interroger la structure même du problème étudié : quelles hypothèses retenir, quels paramètres faire varier, et comment refléter la diversité des situations réelles sans perdre la rigueur expérimentale. En ce sens, la génération d'instances constitue autant une démarche méthodologique qu'une contribution au service d'une recherche ouverte.

Deux exemples récents illustrent cette approche : le générateur pour le Service Network Design développé par **Louis Bonnet** au LAAS de Toulouse, et **REQreate**, outil pour les problèmes de transport à la demande conçu par **Michell Queiroz** à l'Université d'Anvers, avec la collaboration de Kenneth Sorensen et Flavien Lucas.

## Un générateur open-source pour des instances réalistes de Service Network Design

..... Par Louis Bonnet

Dans sa thèse au LAAS de Toulouse, Louis Bonnet s'attaque à un problème majeur de la logistique moderne : comment concevoir et résoudre des réseaux de livraison à très grande échelle. Alors que la littérature se limite à quelques centaines de commandes, Louis explore des cas de 10 000 à 20 000 commandes. Pour cela, il a développé un générateur d'instances inédit, capable de produire des scénarios réalistes et modulables.

**On The ROAD** : *Peux-tu nous expliquer pourquoi tu as choisi de créer un générateur d'instances ?*

**Louis Bonnet** : Mon travail porte sur le *Service Network Design*, qui consiste à organiser la livraison de milliers de commandes dans un réseau logistique complexe. Dans la littérature, on travaille le plus souvent avec des instances de quelques dizaines ou centaines de commandes. J'ai voulu étudier des cas beaucoup plus grands, proches de ce que rencontrent les grands logisticiens.

Plutôt que d'adapter artificiellement les instances existantes, j'ai décidé de créer un générateur spécifique. Les instances existantes ne

prenaient généralement pas en compte la structure des réseaux, et étaient limitées en nombre de commodités. Grâce à mon générateur, je peux créer des réseaux plus grands et gérer des milliers de commodités, en restant fidèle aux contraintes et aux pratiques industrielles. Cela permet de tester des méthodes de résolution sur des instances réalistes et de mieux comprendre les difficultés rencontrées par les transporteurs.

**On The ROAD** : *Comment gères-tu le niveau de difficulté des instances ?*

**L. B.** : Pour contrôler la difficulté des instances, je joue sur différents paramètres :

le ratio entre demande et capacité des arcs, le coût fixe pour ouvrir un arc versus le coût unitaire pour transporter une commodité, ou encore la structure temporelle et spatiale des livraisons. Ces réglages permettent de produire des instances réalistes, mais suffisamment complexes pour tester les algorithmes. Je me suis inspiré de données anonymisées et de métriques publiées dans la littérature sur des réseaux logistiques qui permettent de les caractériser. L'objectif n'était pas de reproduire exactement un réseau particulier, mais de refléter la distribution spatiale et temporelle des commandes, les tailles des flottes et la structure des réseaux, notamment le modèle

très répandu en logistique de *hub-and-spoke*. Bien sûr, ce choix introduit un biais, car tous les réseaux ne suivent pas ce modèle. Mais le générateur est modulable : on peut ajuster le nombre de hubs, la densité des arcs, ou encore la concentration des commandes pour tester différents scénarios et réduire les biais selon les besoins de la recherche.

**On The ROAD : Combien d'instances as-tu générées et comment comptes-tu les partager avec la communauté ?**

**L. B. :** Pour la partie computationnelle de mon papier, j'ai généré environ 200 réseaux physiques. Chaque réseau peut produire plusieurs jeux de demandes, ce qui multiplie naturellement le nombre d'instances possibles. On limite volontairement le nombre total d'instance pour maîtriser le temps de résolution total, tout en essayant de couvrir un large spectre de cas pertinents.

**On The ROAD : Quelle place ce travail occupe-t-il dans ta thèse ?**

**L. B. :** Le générateur constitue une contribution à part entière de ma thèse. Il permet d'avoir un regard critique sur les instances existantes et de proposer des ressources nouvelles et réutilisables pour la communauté. Travailler dessus m'a aussi permis de réfléchir à chaque hypothèse du problème, d'anticiper des variantes, et de mieux comprendre la complexité des réseaux logistiques.

**On The ROAD : Comment comptes-tu diffuser ces travaux ?**

**L. B. :** Tout d'abord, le générateur sera disponible sur GitHub, accompagné d'instances représentatives. Nous prévoyons aussi une version sur Zenodo, qui est citable et évolutive. L'objectif est que d'autres chercheurs puissent adapter le générateur à leurs besoins, créer de nouvelles instances, et reproduire les expériences. C'est un point central pour améliorer

la reproductibilité et la comparabilité des recherches.

Un article associé à ce projet a aussi été soumis à un journal. L'idée est de viser à la fois un article scientifique, un dépôt citable pour le code et les instances, et éventuellement une plateforme permettant aux chercheurs de générer des instances adaptées à leurs propres besoins.

**On The ROAD : Pour conclure, quels conseils donnerais-tu à d'autres doctorants ?**

Mon principal conseil serait de ne pas hésiter à créer leurs propres instances, même si cela prend du temps. C'est très formateur : ça permet de mieux comprendre le problème, de critiquer les méthodes existantes et de produire des contributions concrètes pour la communauté scientifique. Avec un générateur modulable, on peut aussi anticiper les besoins futurs et répondre à des problématiques qui n'existent pas encore au moment de la thèse.

# Le générateur REQreate

..... Par **Michell Queiroz**

**Michell Queiroz est chercheur avec une formation en Recherche Opérationnelle, ayant travaillé sur des problèmes allant de la coloration de graphes au transport à la demande. Il revient sur le générateur REQreate.**

L'idée de REQreate est née d'un besoin pratique. En travaillant sur des problèmes de transport, mon directeur de thèse Kenneth Sörensen a constaté un manque de générateurs d'instances standardisés et flexibles capables de refléter la complexité et la nature évolutive des scénarios réels. Cela m'a conduit à créer un outil (utilisant des données ouvertes et des outils open source) qui pourrait servir la communauté et s'adapter aux besoins futurs de la recherche. Flavien Lucas a ensuite rejoint le projet et y a contribué. Les problèmes de transport à la demande évoluent constamment avec de nouvelles contraintes et sources de données. Les problèmes pour lesquels REQreate a été conçu vont du Dial-a-Ride Problem (DARP), où une flotte de véhicules doit transporter des utilisateurs entre des points d'origine et de destination prédéfinis, à des formulations

plus récentes comme le On-Demand Bus Routing Problem (ODBRP). Dans ce dernier cas, les demandes (qui peuvent apparaître de façon dynamique) sont attribuées à des bus flexibles : contrairement au service porte-à-porte du DARP, les passagers sont pris en charge et déposés à des arrêts situés à une distance de marche raisonnable de leur demande.

L'outil permet aux chercheurs de générer des instances basées sur des réseaux urbains réels plutôt que sur des grilles artificielles, et supporte des schémas de demande variés comme une demande plus élevée dans les centres-villes. Construit avec des outils accessibles publiquement tels qu'OpenStreet-Maps et OSMnx, REQreate est conçu pour être adaptable, permettant la création de nouvelles instances au fur et à mesure de l'évolution du domaine, que ce soit pour le transport de per-

sonnes ou potentiellement de marchandises si l'outil est personnalisé.

Bien que l'outil ne classe pas explicitement les instances selon leur difficulté, il permet d'ajuster des propriétés qui influencent indirectement la complexité de l'optimisation. Les instances peuvent être personnalisées concernant le nombre de demandes, le degré de dynamisme (lié à l'intervalle de temps pendant lequel les demandes apparaissent), le niveau d'urgence (correspondant au délai entre l'apparition d'une demande et son heure limite de service), ou la dispersion spatiale (mesurée notamment par la distance moyenne entre les demandes). Les données utilisées sont anonymisées, bien que certains biais subsistent, tels que la dépendance aux temps de trajet moyens. REQreate est hébergé sur GitHub <sup>[1]</sup> pour en faciliter l'accès, et son développement ainsi que son application ont

[1] <https://github.com/michellqueiroz-ua/instance-generator>

été présentés dans une thèse et publiés dans EJOR [2], soulignant son potentiel pour la communauté de la recherche opérationnelle.

La génération d'une instance commence par la délimitation d'une zone géographique, à l'intérieur de laquelle un graphe est construit à partir des données OpenStreetMap (OSM). Ce graphe, obtenu grâce aux bibliothèques OSMnx et NetworkX, représente un réseau urbain réel et intègre des estimations de temps de trajet selon le mode de transport, que ce soit en voiture, en bus ou à pied. Les instances peuvent ensuite être personnalisées via des propriétés telles que le nombre

de demandes, le degré de dynamisme, le niveau d'urgence ou la dispersion spatiale.

Le réalisme des instances est renforcé par l'intégration des Points d'Intérêt (POI), représentant des lieux susceptibles de générer de la demande de mobilité, tels que des commerces, restaurants, cinémas ou zones d'emploi. Ce mécanisme permet de moduler la demande en fonction de différents contextes temporels, comme les flux domicile-travail aux heures de pointe en semaine ou les déplacements de loisirs durant le week-end.

REQreate a déjà été utilisé dans plusieurs études pour générer des instances adap-

tées à des contextes spécifiques. Parmi les exemples, on trouve des tournées de bus électriques nécessitant des visites régulières aux stations de recharge [3], des scénarios multimodaux combinant des bus flexibles avec des réseaux rapides à horaires fixes comme le métro ou le tramway [4], ainsi que des cas périurbains où les bus desservent des zones peu connectées en les reliant à des pôles de transport [5]. L'utilisation de données réelles permet ainsi d'explorer des problèmes de transport de plus en plus complexes, en cohérence avec les défis actuels de la mobilité.

## POUR CONCLURE, QUELQUES CONSEILS AVANT DE VOUS LANCER...

### 1. Assurez la variété, la réalisabilité et la difficulté adéquate

Veillez à ce que vos instances soient **réalisables** et présentent le **niveau de difficulté souhaité**. Les instances trop simples ne résisteront pas longtemps aux assauts des chercheurs opérationnels. Les instances conçues pour être difficiles perdent souvent en réalisme.

### 2. Respectez l'éthique, le contexte et limitez les biais

Anonymisez les données réelles utilisées pour garantir la **confidentialité**. Prenez en compte les **différences légales, sociales et culturelles** afin que vos résultats soient applicables dans divers contextes. Identifiez et réduisez les **biais potentiels** liés à des données incomplètes ou des hypothèses implicites.

### 3. Favorisez la réutilisabilité et l'adaptabilité

Concevez vos instances de manière à ce qu'elles puissent être facilement **réutilisées, adaptées** ou **étendues** par d'autres chercheurs. Offrez ainsi la possibilité d'explorer de nouveaux scénarios, de tester des variantes et

de faire évoluer les expérimentations sans repartir de zéro. Pensez vous-mêmes à étendre des instances existantes plutôt que d'en créer de nouvelles ex nihilo.

### 4. Garantisiez la reproductibilité

Documentez intégralement votre **méthodologie de génération (jusqu'aux fameuses règles d'arrondi !)**, indiquez clairement vos **sources de données**, vérifiez systématiquement l'absence de biais. Cette transparence est essentielle pour que vos expériences soient **reproductibles** et que vos résultats puissent être **validés** par la communauté scientifique.

### 5. Ne sous-estimez pas le temps nécessaire à la génération d'instances

Prévoyez le temps requis pour faire les bons **choix conceptuels, programmer, paramétrer**, puis **diffuser et maintenir** vos instances. N'oubliez pas non plus la rançon du succès : interagir avec une communauté de chercheurs qui auront toujours une question inattendue à vous poser.

[2] Queiroz, M., Lucas, F., & Sørensen, K. (2024). Instance generation tool for on-demand transportation problems. *European Journal of Operational Research*, 317(3), 696-717.

[3] Lian, Y., Lucas, F., & Sørensen, K. (2023). The electric on-demand bus routing problem with partial charging and nonlinear function. *Transportation Research Part C: Emerging Technologies*, 157, 104368.

[4] Melis, L., Queiroz, M., & Sørensen, K. (2024). The integrated on-demand bus routing problem: Combining on-demand buses with a high-frequency fixed line public transport network. *Computers & Operations Research*, 164, 106554.

[5] Galarza Montenegro, B. D., Sørensen, K., & Vansteenwegen, P. (2025). The real-time dynamic online feeder service with a maximum headway at mandatory stops. *Transportmetrica A: Transport Science*, 21(1), 2227738.

# Vie du GDR ROD

..... Par Odile Bellenguez, Nadia Brauner, Pierre Fouilhoux et Michaël Poss



<http://gdrrod.grenoble-inp.fr>

## Nouvelle structuration du GDR ROD

L'année 2025 a été marquée par la demande de renouvellement du GDR ROD (changement de direction, évolution de la structuration, rédaction du dossier de renouvellement). Christian Artigues, que nous remercions chaleureusement, a quitté la direction du GDR. Il est remplacé par Nadia Brauner, Professeure à l'Université Grenoble Alpes et au laboratoire G-SCOP. Pierre Fouilhoux (Professeur à l'université Sorbonne Paris Nord - LIPN) reste directeur adjoint et s'occupe en particulier du budget qui est hébergé dans son laboratoire. Odile Bellenguez (Professeure IMT Atlantique - LS2N) et Michaël Poss (Directeur de Recherche CNRS - LIRMM) rejoignent l'équipe de direction. Ils sont accompagnés de jeunes chercheur·e·s et doctorant·e·s (Ayse Nur Arslan), relations industrielles (Aziz Moukrim, Claude Le Pape), relations internationales (Frédéric Semet, Marc Sevaux).

A l'occasion du renouvellement et suite au travail de rédaction d'une prospective, les axes et groupes de travail (et leurs responsables ont évolués). Les sept axes disciplinaires sont :

- Programmation Mathématique et par Contraintes (PMC)
- Complexité, Approximation et Graphes pour la Décision et l'Optimisation (CAGDO)
- Décision, Incertitude, Multi-objectif (DIM)
- Ordonnancement et Planification (OP)
- Réseaux, Énergie, Services, Transport (REST)
- RO, Données et Apprentissage (RODA)
- RO & Enjeux environnementaux, sociétaux et éthiques

Un axe de Veille Scientifique et Actions Transverses (VSAT) permet d'accueillir de nouveaux groupes de travail hors des axes existants. Pour l'instant, il contient le groupe de travail sur la Recherche Opérationnelle Quantique (ROQ).

## Animation scientifique

La journée nationale du GDR ROD a eu lieu à Champs-sur-Marne, dans l'école des Ponts le 27 février pendant la conférence Roadef. L'assemblée générale du GDR a permis en particulier des échanges avec Olivier Serre, directeur adjoint scientifique du CNRS Sciences Informatiques qui a répondu aux questions de la communauté suite

à sa présentation. Cette réunion a été suivie d'une présentation à la communauté du travail de prospective effectué qui a mené au dossier de renouvellement et à la nouvelle structuration. Le GDR ROD a également participé à la constitution du programme de la conférence à travers les sessions scientifiques organisées par les axes et groupes de travail.

Les groupes de travail ont organisé une ou plusieurs journées annuelles ou thématiques : ATOM à Calais (Applications et Théorie de l'Optimisation Multiobjectif) -- COSMOS à Paris (Contrôle et Optimisation Stochastique, Modélisation et Simulation) -- TADJ à Paris (Théorie Algorithmique de la Décision et des Jeux, deux journées dont une sur l'explicabilité via le prisme de la décision algorithmique et des jeux, commun avec le GDR RADIA) -- REST à Chatillon (Réseaux, Énergie, Services, Transport) -- AGAPE à Grenoble (Algorithmique à Garantie de Performance), Scale à Lyon (Scheduling for Computing Architecture and Low Energy, deux journées sur prise en compte de l'énergie dans les algo de batch scheduling et Ordonnancement avec ressources variables, énergie, efficacité, sobriété) -- ROSA à Nantes (RO et Santé), CAGDO (Complexité, Approximation et Graphes pour la Décision et l'Optimisation, JGA - Journées de Géométrie Algorithmique à Roscoff en Bretagne) et JFRO (45<sup>e</sup> Journée Francilienne de Recherche Opérationnelle sur des problèmes de coloration de graphes à Paris) -- POC (journées Polyèdres et Optimisation Combinatoire, JPOC14 à Caen).

Le GDR ROD a soutenu l'organisation par la communauté de manifestations internationales ou nationales liées à la Recherche Opérationnelle : Conférence JuliaCon Local (2-3 octobre à Paris) -- Symposium Technological, systems, sustainability and safety (TS3, 15-16 octobre à Paris) -- International Workshop on Planning & Scheduling for Space (IWSS 2025, 28-30 avril à Toulouse) -- European Mixed Integer Programming Workshop (EUROMIP, 1-3 juillet à Clermont-Ferrand) -- XVII conference on stochastic programming, (28 juillet - 01 août, École des ponts) -- CIGI-QUALIT2-MOSIM, (8-10 juillet, Troyes) -- International Joint Conference on Theoretical Computer Science, Frontier of Algorithmic Wisdom (IJTCS-FAW, 30 juin - 02 juillet à Paris).

## Actions interdisciplinaires ou vers le public

Des actions interdisciplinaires autour de l'éthique, de l'environnement et de la société ont émergé ces dernières années et s'intensifient avec l'organisation d'une journée sur l'aide à la décision (sur les aspects de responsabilité sociale et d'impact éco-

nomique, social ou politique des outils d'aide à la décision) et la participation du GDR ROD aux Green Days, aux JRAF (journées de recherche en apprentissage frugale) et à l'école IA2 du GDR RADIA sur les limites planétaires. Notons également des articles sur des enjeux sociétaux comme : *Estimating the Electoral Consequences of Legislative Redistricting in France* par Evaripidis Bampis, Thomas Ehrhard, Bruno Escoffier, Claire Mathieu, Fanny Pascual, David Saulpic.

Les articles de vulgarisation suivants ont été proposés par des membres du GDR : *Comment découper le gâteau ? Ou la répartition équitable de ressources* par Nadia Brauner et Pierre Fouilhoux dans la revue Interstices - et deux articles d'optimisation quantique dans un numéro spécial de la revue PROGRAMMEZ : *Sécuriser mon réseau informatique avec l'informatique quantique : comparaison des solutions Dwave, Qiskit et Pasqal* par Ali Abbassi, Yann Dujardin, Philippe Lacomme, Caroline Prodhon et QAOA : *une nouvelle manière de chercher des bonnes solutions et de les trouver* par Philippe Lacomme, Gérard Fleury, Eric Bourreau, Martin Bonbardelli, Marc Sevaux. Michaël Poss a également été interviewé par le journal du CNRS sur son métier de chercheur en optimisation.

## Écoles et tutoriels

Les membres du GDR ROD ont organisé plusieurs écoles ou semaines de formation : Modern Optimization Methods and Models in Algorithm Design (MoMA), (23-28 novembre à Aussois, co-organisé par les GT CoA et Graphes du GDR IFM, GT AGaPe de l'axe CAGDO, et le GT GOTHa de l'axe OP) -- École Génération de colonnes (Axe PMC) -- École IA2 sur IA et limites planétaires (13-17 octobre, Aussois avec les GDR RADIA, MADICS et le GDRS Ecoinfo) -- Summer/Winter Institute (ESWI) on Lot Sizing (14-25 April à Gardanne), École Revolutionizing Problem-Solving with Quantum and Metaheuristic Technique (10-12 décembre, en Allemagne co-organisée par le GT ROQ).

Le GDR ROD a organisé deux tutoriels lors de la conférence Roadef. Ces tutoriels permettent aux chercheuses et chercheurs du GDR d'avoir une présentation synthétique sur un domaine particulier par une experte ou un expert : une approche générale mêlant optimisation et élicitation incrémentale de préférences pour la résolution de problèmes multi-objectifs par Nawal Benabbou (LIP6, Sorbonne Université, Paris) et un tutoriel méthodologique sur la recherche reproductible : bonnes pratiques pour une science transparente par Arnaud Legrand (CNRS - LIG, Grenoble).



# Congrès de la ROADEF

## Un bilan du 26<sup>e</sup> congrès de la ROADEF du 26 au 28 février 2025 à Champs-sur-Marne

..... Pour le comité d'organisation, Axel Parmentier



### Bilan de la 26<sup>e</sup> édition de la conférence ROADEF 2025

Les 26, 27 et 28 février 2025, le 26<sup>ème</sup> congrès de la ROADEF a réuni pendant trois jours une bonne partie de la communauté française de la recherche opérationnelle et d'aide à la décision à Champs-sur-Marne, dans les locaux de l'École nationale des ponts et chaussées. Comme toujours, ce furent trois jours chaleureux et riches en échanges scientifiques et humains.

Avec 600 participants et 320 présentations réparties sur 57 sessions spécialisées, le congrès ROADEF a une nouvelle fois confirmé son statut d'événement majeur de la recherche opérationnelle et d'aide à la décision en France. Les thèmes des sessions étaient d'une diversité remarquable. La plupart étaient classiques, comme « Optimisation Combinatoire et Programmation en Nombres Entiers » ou « Problème de logistique urbaine ». Mais des thèmes plus originaux, explorant parfois des perspectives dépassant le cadre habituel de la discipline, étaient également proposés, comme par exemple « Sur les meilleures pratiques de programmation en RO et leur lien avec la théorie », « RO et enseignement » ou « Ordonnement et durabilité ». Cette variété thématique démontre sans aucun doute la formidable vitalité de cette discipline scientifique dans notre pays.

Outre les sessions thématiques, quatre conférences plénières ont également rythmé le congrès. Ce dernier a d'ailleurs débuté par une conférence plénière, donnée par Maximilian Schiffer, soulignant l'apport considérable du machine learning aux méthodes de la recherche opérationnelle, en particulier aux problèmes tirés par les données, contextuels ou dynamiques. Le même jour, une deuxième conférence plénière, donnée par Christian Artigues, a abordé les modèles et algorithmes pour les problèmes d'ordonnement sous incertitudes. Les questions de « online stochastic matching », particulièrement importantes pour des applications allant de la supply chain aux programmes d'échanges de reins, ont été discutées lors de la troisième conférence plénière du congrès, donnée par Ana Busic. Enfin, la dernière journée du congrès a débuté par la conférence plénière de Xavier Allamigeon, qui traitait de bornes de complexités pour les méthodes de points intérieurs pour la programmation linéaire.

Parmi les autres éléments qui ont participé au succès de cette édition, on peut souligner la tenue de deux tutoriels d'une heure chacun. Un tutoriel, donné par Arnaud Legrand, abordait le sujet très actuel de la science reproductible. L'autre tutoriel, donné par Nawal Benabbou, portait sur des problèmes multi-objectifs dans lesquels les préférences du décideur sont intégrées à la méthodologie de résolution. Les

retours d'expérience des industriels ont complété le paysage et ont démontré une fois de plus la fécondité des interactions entre les mondes académique et industriel de la recherche opérationnelle.

Le congrès ROADEF, c'est aussi le moment où sont annoncés les résultats de plusieurs prix qui ponctuent la vie de la communauté de la recherche opérationnelle et d'aide à la décision. Ainsi, cette année, cela a été le cas pour trois prix, à savoir celui du meilleur article étudiant, celui du mémoire de master et celui de la meilleure thèse en transport et logistique. Notons d'ailleurs que contrairement aux deux premiers, ce dernier prix n'est pas décerné par l'association ROADEF, mais par le groupe de travail en transport et logistique du GDR ROD.

Enfin, en tant qu'organisateur de cet événement, nous tenons à remercier toutes les personnes qui ont participé à son succès, les sponsors industriels de cette édition (Hexaly, RTE, Air France, Artelys, Fico, Gurobi, Total Énergies, DecisionBrain, Engie, Saint Gobain, Savoye, Eurodécision et Renault Digital), l'École nationale des ponts et chaussées pour la mise à disposition des locaux et enfin le GDR ROD, qui a contribué comme chaque année à la qualité du congrès en fournissant une contribution majeure au programme scientifique via ses sessions et tutoriels.

Nous souhaitons un grand succès à la 27<sup>e</sup> édition du congrès de la ROADEF !



## Le congrès ROADEF 2026 à Tours Soyez nombreux !



**ROADEF** 27ème Congrès Annuel de la Société Française  
de Recherche Opérationnelle et d'Aide à la Décision  
**TOURS du 24 au 26 février 2026**



Le Laboratoire d'Informatique Fondamentale et Appliquée de Tours (LIFAT) et l'Université de Tours organisent la 27<sup>e</sup> édition du congrès annuel de la Société Française de Recherche Opérationnelle et d'Aide à la Décision - ROADEF 2026.

Le congrès de la ROADEF est la plus grande manifestation francophone qui vise à réunir des chercheurs en Optimisation Combinatoire, Recherche Opérationnelle et Génie Industriel. Son objectif est de favoriser les échanges et les collaborations entre chercheurs et industriels, mais aussi de participer à la formation des jeunes chercheurs, qui sont fortement encouragés à présenter leurs travaux.

Le prochain congrès ROADEF aura 24 au 26 février 2026 sur le site des 2 Lions de l'Université de Tours.

LE PROGRAMME SCIENTIFIQUE EST TRÈS RICHE :

- des sessions plénières,
- des tutoriels en sessions semi-plénières,
- des sessions de présentation des travaux scientifiques,
- des sessions retours d'expérience industrielle,
- le prix du Meilleur Article Étudiant,
- le prix du Mémoire de Master en RO/AD,
- l'assemblée générale de la ROADEF,
- et la réunion annuelle du GDR ROD.

**AU PLAISIR DE VOUS RENCONTRER  
À TOURS !**

# Compte rendu de la première Journée Francilienne de Recherche Opérationnelle organisée en partenariat avec AIRO (Associazione Italiana di Ricerca Operativa)



<https://www.roadef.org/jfro/index.php>

Comité d'organisation :  
Nawal BENABBOU, Diego DELLE DONNE,  
Emiliano LANCINI, Alessandro MADDALONI

Cette édition des journées Franciliennes de Recherche Opérationnelle s'est déroulée le Mardi 26 Novembre 2024, à Sorbonne Université, 4 Place Jussieu 75005 Paris, LIP6, room 25-26-105. La journée avait pour thème « Optimisation boîte noire ». Elle a accueilli 20 participants. 8 orateurs ont accepté de faire un exposé.

- **Tutorial: Black-box optimization in theory and practice présenté par Carola Doerr.** *Résumé* : Many real-world optimization challenges are significantly harder than the scenarios that can be rigorously analyzed by mathematical means. In addition, practitioners often lack time and resources to develop problem-specific solution strategies; they therefore need to rely on general-purpose optimization heuristics such as local search variants, evolutionary and genetic algorithms, Bayesian optimization techniques, and similar. Unfortunately, practitioners often choose and apply these algorithms without much guidance from the scientific community. With this presentation, we will discuss how (theoretical and empirical) research can be used to develop more principled usage of optimization heuristics, whether involving manual or purely data-driven selection strategies.
- **Black-box optimization with hidden constraints présenté par Delphine Sinoquet.** *Résumé* : Real industrial studies often give rise to optimization problems involving time-consuming complex simulators that can produce some failures or instabilities for some input sets: for instance, convergence issues of the numerical scheme of partial derivative equations. The set of inputs corresponding to failures is often not known a priori and corresponds to a hidden constraint, also called a crash constraint. Since the observation of a simulation failure might be as costly as a feasible simulation, we seek to learn the feasible region to guide the optimization process in areas without simulation failures. Therefore, we propose to couple some black-box optimization methods with a Gaussian process classifier active learning method to learn the crash domain. Several coupling strategies are proposed and compared in terms of accuracy of the solution and budget of (crashed) simulations. At last, an application of the developed approach for wind turbine reliable design is presented. Joint work with Morgane Menz and Miguel Munoz Zuniga.
- **Bayesian Quality Diversity approaches for constrained optimization problems with mixed variables présenté par Brevault Loïc.** *Résumé* : Complex engineering design problems, such as those involved in aerospace, civil, or energy engineering, require the use of numerically costly simulation codes in order to predict the behavior and performance of the system to be designed. To perform the design of the systems, these codes are often embedded into an optimization process to provide the best design while satisfying the design constraints. Recently, new approaches, called Quality-Diversity, have been proposed in order to enhance the exploration of the design space and to provide a set of optimal diversified solutions with respect to some feature functions. These functions are interesting to assess trade-offs. Furthermore, complex engineering design problems often involve mixed continuous, discrete, and categorical design variables allowing to take into account technological choices in the optimization problem. This talk will discuss Quality-Diversity methodologies based on mixed continuous, discrete and categorical Bayesian optimization strategy. These approaches allow to reduce the computational cost with respect to classical Quality - Diversity approaches while dealing with discrete choices and constraints. The performance of the methods will be discussed on a benchmark of analytical problems as well as on an industrial design optimization problem dealing with aerospace systems.
- **Random subspace approaches in derivative-free optimization présenté par Clément Royer.** *Résumé* : Derivative-free algorithms seek the minimum of a given function based only on function values queried at appropriate points. Although these methods are widely used in practice, their performance is known to worsen as the problem dimension increases. Recent advances in developing randomized derivative-free techniques have tackled this issue by working in low-dimensional subspaces that are drawn at random in an iterative fashion. The connection between the dimension of these random subspaces and the algorithmic guarantees has yet to be fully understood. This talk will review several strategies to select random subspaces within a derivative-free algorithm. We will explain how probabilistic convergence rates can be obtained for such a method, then provide numerical evidence that using low-dimensional random subspaces leads to the best practical performance.
- **Black Box Optimization problems in automotive design présenté par Laurent Genest.** *Résumé* : The design of an automotive vehicle is a complex engineering problem involving various disciplines such as occupant safety,

acoustic quality, vehicle weight, and aerodynamics. Stellantis tackles these complexities through multidisciplinary Black Box Optimization studies based on costly numerical simulations conducted throughout the design cycle. This presentation will illustrate the engineering challenges with examples, showcase the state-of-the-art algorithms employed by Stellantis, and discuss emerging challenges such as high dimensionality, increased number of constraints, and the integration of Deep Learning-based surrogates.

- **A trust-region framework for derivative-free mixed-integer optimization présenté par Juan José Torres Figueroa.** *Résumé* : In this talk we will discuss the development of a framework for the optimization of black-box mixed-integer functions subject to bound constraints. This methodology is based on the use of tailored surrogate approximations of the unknown objective function, in combination with a trust-region method. Such surrogate models adapt the concept of fully-linear and fully quadratic models into the mixed-integer setting. We also describe the different challenges faced on the mixed-integer derivative-free optimization such as the definition of a proper mixed-integer minimizer and the required conditions to guarantee algorithmic convergence. Finally, we present potential improvements to our method that will enable it to reuse previous function calls more efficiently. Joint work with Giacomo Nannicini, Emiliano Traversi and Roberto Wolfler Calvo.

- **Optimisation de fonctions boîtes noires avec Hexaly présenté par Emeline Tenaud.** *Résumé* : Dans les problèmes d'optimisation de fonctions boîtes noires, la forme exacte de la fonction objective et des contraintes n'est pas connue, et chaque évaluation d'une nouvelle solution est coûteuse en termes de temps ou de mémoire. Le solveur Hexaly propose une approche d'optimisation de ces problèmes basée sur des modèles de fonctions de base radiale (RBF), permettant de réduire le nombre d'évaluations en choisissant judicieusement les points à évaluer. L'algorithme, combinant des phases d'exploration et d'intensification, optimise ainsi le budget limité d'évaluation. Hexaly intègre également des contraintes analytiques et boîtes noires, souvent présentes dans les applications industrielles, et offre la possibilité d'optimiser plusieurs objectifs boîte noire. Les résultats obtenus sont comparables à ceux d'autres solveurs spécialisés comme RBFOpt et NOMAD, illustrant l'efficacité d'Hexaly dans des cas d'applications réels.

- **How can I use Artelys Knitro, a derivative based nonlinear optimization solver, to efficiently solve black-box models? présenté par Maxime Dufour.** *Résumé* : Artelys Knitro is a derivative based nonlinear optimization solver. In this talk, we will highlight how such solvers can prove to be particularly efficient on black box models relying on several key features and algorithms. This presentation explores the techniques employed by Knitro to address Black Box & Derivative Free Optimization (BBO-DFO) challenges, including adaptive tuning and finite-difference methods for gradient estimation, enabling optimization where derivatives are unavailable or costly to compute. Practical results on the black box optimization competition will illustrate the solver's capabilities, demonstrating how Artelys Knitro enables efficient and accurate optimization in unknown nonlinear (potentially non-differentiable) landscapes.

Les transparents des exposés de cette journée sont en ligne sur le site des JFRO.

## Compte rendu de la 45<sup>e</sup> Journée Francilienne de Recherche Opérationnelle

La 45<sup>e</sup> Journée Francilienne de Recherche Opérationnelle (JFRO) s'est tenue le mercredi 4 juin 2025 à l'Université Paris Dauphine et portait sur le thème de la *coloration de graphes*. Fidèle à sa vocation, cette journée a rassemblé des chercheuses et chercheurs en recherche opérationnelle de la région parisienne, favorisant les échanges scientifiques dans un cadre convivial. L'événement a réuni 27 participants, en plus des 5 intervenants.

La matinée a débuté par un tutoriel proposé par Pierre Charbit (IRIF), suivi de quatre exposés de recherche donnés par Michael Lampis (LAMSADE), Pierre Aboulker (ENS), Ararat Harutyunyan (LAMSADE) et Thomas Bellitto (LIP6).

- **Tutorial: "Chromatic Number and Structure: An Introduction" présenté par Pierre Charbit.** *Résumé* : The Four Color Conjecture regarding planar graphs, proposed in 1852, is often regarded as one of the historically foundational problems in graph theory. From this conjecture, the notion of the chromatic number of a graph has become as arguably the most studied graph invariant in the field. In this introductory talk, I will present classical results and constructions related to the concept of chromatic number, with a focus on structural aspects. The central question I will address can be summarized as: "What does a large chromatic number reveal about the structure of a graph?"

- **Structural Parameters and Fine-Grained Complexity for Coloring présenté par Michail Lampis.** *Résumé* : We review a number of results from the last few years which attempt to give precise (fine-grained) upper and lower bounds on the complexity of the Coloring problem, when measured as a function of the structure of the input graph. In order to obtain such a measure we will rely on graph-theoretic parameters, such as treewidth and its many variants, while the lower bounds will be based on fine-grained hypotheses, such as the (S) ETH. If time permits, we will also discuss how these results can be extended to more general problems, such as List Coloring and Defective Coloring. No prior knowledge of parameterized or fine-grained complexity will be assumed, the focus will be on giving an accessible self-contained exposition.

- **Clique number of tournaments présenté par Pierre Aboulker.** *Résumé* : The dichromatic number of a digraph is the minimum integer  $k$  such that the vertex set of  $D$  can be partitioned into  $k$  acyclic subdigraphs. It is easy to see that the chromatic number of a graph  $G$  is equivalent to the dichromatic number of the digraph obtained from  $G$  by replacing each edge with a digon (two anti-parallel arcs). Based on this simple observation, many theorems concerning the chromatic number of undirected graphs have been generalized to digraphs via the dichromatic number. However, no concept analogous to the clique number for digraphs has been available. The purpose of this presentation is to explore such a concept and its relationship with the dichromatic number, mirroring the relationship between the clique number and the chromatic number in undirected graphs. We will focus, in particular, on studying the notion of Chi-boundedness.

- **Probabilistic methods in colorings présenté par Ararat Harutyunyan.** *Résumé* : I will discuss various probabilistic tools/techniques (mostly from concentration) that are quite useful in many graph partitioning problems through the lens of a particular result in graph coloring, namely, the fact that triangle-free graphs require much fewer colors than the trivial bound of  $d+1$ , where  $d$  is the maximum degree. The goal of the talk is as much to give an idea on such results as to discuss under which settings these tools can be applied to obtain useful graph decompositions that could be helpful for various problems.


- **The smallest 5-chromatic tournament présenté par Thomas Bellitto.** *Résumé* : A coloring of a digraph is a partition of its vertex set such that each class induces a digraph with no directed cycles. A digraph is  $k$ -chromatic if  $k$  is the minimum number of classes in such partition, and a digraph is oriented if there is at most one arc between each pair of vertices. Clearly, the smallest  $k$ -chromatic digraph is the complete digraph on  $k$  vertices, but determining the order of the smallest  $k$ -chromatic oriented graphs is a challenging problem. It is known that the smallest 2-, 3- and 4-chromatic oriented graphs have 3, 7 and 11 vertices, respectively. In 1994, Neumann-Lara conjectured that the smallest 5-chromatic oriented graph has 17 vertices. We solve this conjecture and show that the answer is actually 19.

# ActuROAD

## Prix du Master 2024

..... Par Maxime Ogier

Comme chaque année, une session du congrès ROADEF 2025 a été dédiée aux présentations des finalistes du Prix de Mémoire de Master de la ROADEF, édition 2024. Cette distinction met en lumière le travail remarquable d'étudiants en deuxième année de master, dont les mémoires contribuent aux avancées des méthodes et applications en recherche opérationnelle et en aide à la décision. Le jury, composé d'experts issus du monde académique et industriel, a souligné l'excellente qualité des travaux soumis l'année dernière. Parmi 16 candidats, 6 ont été sélectionnés pour la phase finale.



Deux prix ont été décernés. Le prix pour les contributions théoriques a été décerné à **Jules Bouton Popper**, pour son mémoire intitulé « Comment rendre un graphe temporel connecté ? ». Le prix pour les applications en recherche opérationnelle et aide à la décision a été décerné à **Gorazd Dimitrov**, pour son mémoire intitulé « Decision Aiding Under Uncertainty for Optimization of Roaming Strategies ». Un grand bravo également aux autres finalistes : **Xiaoyu Chen**, **Francis Durand**, **Benoît Duval** et **Rita Safi**.

La ROADEF tient à remercier chaleureusement les membres du jury pour leur engagement : **Murat Afsar**, **Ayse Nur Arslan**, **Amal Benhamiche**, **Arwa Khanoussi**, **Maxime Ogier**, **Slawomir Pietrasz**, **Cléopée Robin**, **Élodie Suzanne**, et **Marina Vinot**. Leur travail permet à cette compétition de valoriser l'excellence et la créativité des jeunes talents en recherche opérationnelle.

L'édition 2025, présidée par Emiliano Traversi, s'annonce prometteuse, avec 18 candidats en lice. Rendez-vous au congrès 2026 pour découvrir les présentations des finalistes et les lauréats !



### Prix du meilleur article étudiant 2025

Par Maxime Ogier

Comme chaque année, une session du congrès ROADEF 2025 a été dédiée aux présentations des finalistes du Prix du meilleur article étudiant de la conférence ROADEF, édition 2025. Cette distinction met en lumière le travail remarquable d'étudiants en thèse et de jeunes docteurs sur une contribution académique et/ou industrielle originale. Le jury, composé d'experts issus du monde académique et industriel, a souligné l'excellente qualité des travaux soumis l'année dernière. Parmi 16 candidats, 6 ont été sélectionnés pour la phase finale.

Deux prix ont été décernés à Luca Brunod Indrigo, pour son article intitulé « Resource leveling for scheduling problems: some complexity and approximation results », et à Louis Fourcade, pour son article intitulé « Combining Lagrangian relaxation and a two-set column generation model for integrated railway freight planning ». Un grand bravo également aux autres finalistes : Florent Cabret, Patxi Flambard, Maria Laura Santoni, et Victor Spitzer.

La ROADEF tient à remercier chaleureusement les membres du jury pour leur engagement : **Nadjet Bourdache**, **Renaud Chicoisne**, **Yann Dujardin**, **Florian Fontan**, **Guillaume Massonnet**, **Maxime Ogier**, et **Cécile Rottner**.

L'édition 2026 sera présidée par Sana Belmokhtar-Berraf. Rendez-vous au congrès 2026 pour découvrir les présentations des finalistes et les lauréats !

## Prochain Challenge ROADEF/EURO

Par Nancy Perrot et Cécile Rottner

Le Challenge ROADEF/EURO 2026 est proposé par Orange. Le sujet est intitulé "Adaptive Segment Routing — Keep the Flow!" et porte sur l'ingénierie de trafic (Traffic Engineering) dans les grands réseaux de télécommunication.

L'objectif principal est de concevoir un algorithme d'optimisation pour calculer un schéma de routage performant sur une période de temps donnée. Une des difficultés de ce problème réside dans la contrainte de résilience : le routage proposé doit maintenir une charge réseau acceptable même en cas de panne d'un équipement ou d'une liaison.

Pour résoudre ce problème, les participants pourront agir sur différents paramètres, comme la modification des poids des liens du réseau ou l'insertion de points de passage (waypoints). Le Challenge s'appuie sur des données réalistes de réseaux à grande échelle.

Toutes les informations sur le Challenge sont disponibles sur <https://roadef.org/challenge/2026/en/index.php>

## Prix Indus'RO 2025

Par Nancy Perrot et Cécile Rottner

Le 10 juin dernier, la ROADEF a organisé une soirée événementielle autour de la finale du « Prix Indus'RO » au CNAM à Paris. L'objectif du prix est de valoriser un projet industriel mettant en œuvre des techniques avancées de recherche opérationnelle ou d'aide à la décision en entreprise, en réunissant industriels, académiques et décideurs autour d'un cocktail puis d'une présentation des projets des finalistes et enfin d'un vote du public pour consacrer le projet gagnant. Félicitations à l'équipe de RTE qui remporte le prix avec le projet NAZA !

Ce projet vise à intégrer efficacement les productions renouvelables dans des zones du réseau électrique déjà fortement sollicitées, en intégrant des techniques d'optimisation dans un contrôleur temps-réel.

Bravo également aux autres finalistes : Orange et Renault, avec respectivement le projet ONO (Orange Network Optimizer), pour la gestion des grands réseaux d'interconnexion Internet et OptimRoute, permettant de simuler et optimiser la gestion des itinéraires de transport des pièces entre fournisseurs et usines.



Les finalistes (Orange, RTE et Renault)



Présentation de RTE sur le système NAZA



Le cocktail

# Résultats des élections du bureau 2026-2028

À l'issue du vote en ligne, qui s'est tenu du 26 juin  
au 14 juillet 2025, l'unique liste présentée a été élue.  
Sur **148 votes** exprimés, **142 étaient favorables**  
**(95,9 %)** et 6 étaient blancs (4,1 %).



**Le nouveau bureau** prendra ses fonctions lors de l'AG du prochain congrès, le 25 février 2026. Il est composé de : **Frédéric Meunier** (École nationale des ponts et chaussées), président ; **Paola Pellegrini** (Université Gustave Eiffel), trésorière ; **Lilia Zaourar** (CEA) : secrétaire ; **Nawal Benabbou** (Sorbonne Université) : vice-présidente « bulletin » ; **Sohaib Afifi** (Université d'Artois) : vice-président « web » ; **Boris Detienne** (Université de Bordeaux) : vice-président « relations industrielles et internationales » ; **Cécile Rottner** (EDF R&D) : vice-présidente « communication » ; **Nancy Perrot** (Orange) : chargée de mission « promotion RO/AD » ; **Maxime Ogier** (Centrale Lille) : chargé de mission « prix ».

Derniers événements soutenus et sponsorisés par la ROADEF

IWPSS 2025

*Dataquitaine*

*JPOC*

CIE 2025

Julia days

Tutoriels ICSP 2025

journée Aide à la Décision

JFRO

# citROnnADe


## Énigme



Par Denis Cornaz

Situé à un embranchement de trois chemins, on cherche le bon. Chaque chemin a son gardien, l'un dit toujours la vérité, l'un ment toujours, et le dernier répond aléatoirement. On ne sait pas qui est qui. On ne peut s'adresser qu'à un gardien et ne lui poser que deux questions admettant des réponses oui/non.

Quelles questions poser pour trouver le bon chemin ?



## Solution Énigme

(Bulletin OnTheROAD n°46)



D'après Denis Cornaz

Le triangle rectangle avec hypoténuse=6 et grand côté= $b$  (base du rectangle  $BB''C''$ ) est semblable à celui avec hypoténuse= $d$  (diamètre du cercle) et grand côté=6, d'où  $6/b = d/6$ . Il s'ensuit que l'aire vaut 18.

# Devenir (ou rester) membre de la ROADEF

**Vous ADOREZ la ROADEF  
et souhaitez soutenir des actions ?**

## Rejoignez nous !

ADhérents un jour, ADhérent toujours ? Êtes-vous à jour ?

Bénéficiez d'un tarif préférentiel pour assister au congrès annuel, recevez la lettre d'information et bien sûr, « On the ROAD », prenez part aux décisions via votre vote (en AG ou à tout autre moment démocratique de la ROADEF), abonnez-vous à 4'OR à un tarif avantageux...

Suivez toute l'actu ROAD en France et au-delà : faites vivre la ROADEF !

- ▶ Adhésion « étudiant » : **15 €/an**
- ▶ Adhésion « individuelle » : **30 €/an**
- ▶ Adhésion « partenaire » : **800 €/an**  
(nombre illimité de membres et affichage logo)

Retrouvez toutes les infORmations sur votre prochaine  
(ré)ADhésion sur [roadef.org](http://roadef.org).

### ROADEF : LE BULLETIN

Bulletin de la société française de Recherche Opérationnelle et d'Aide à la Décision  
Association de loi 1901

Procédure technique de soumission : contacter Nawal Benabbou (vpresident1@roadef.org).  
Comité de rédaction : N. Absi, S. Affi, N. Benabbou, A. Lambert, F. Meunier, M. Ogier, N. Perrot, O. Péton, C. Rottner.  
Production du Bulletin : N. Benabbou.  
Mise en page : maogani

Ce numéro a été tiré à 200 exemplaires. Les bulletins sont disponibles sur le site de la ROADEF.



amanora  
technologies

Artelys  
SOLUTIONS EN OPTIMISATION

Cédric  
le cnam

DecisionBrain™  
Smarter Decisions. Better Results.

DGA

edf

EURODECISION  
ALGORITHMS FOR BUSINESS

G-SCOP  
SCIENCES POUR LA CONCEPTION,  
L'OPTIMISATION ET LA PRODUCTION

heudiasyc

LAAS  
CNRS

LAMSADE  
UMR CNRS 7243  
Laboratoire d'analyse et modification de systèmes pour l'aide à la décision

LARIS

LIFAT EA 63 00  
LABORATOIRE D'INFORMATIQUE FONDAMENTALE ET APPLIQUÉE DE TOURS

LIMOS

Lip6

LS2N LABORATOIRE  
DES SCIENCES  
DU NUMÉRIQUE  
DE NANTES

orange™

hexaly

Rte Le réseau  
de transport  
d'électricité

SIAPARTNERS

TotalEnergies

IMT Mines Albi  
École Mines-Télécom

sopra  
steria

Toute l'actualité de la ROADEF et de ses partenaires se trouve sur Facebook, Twitter, LinkedIn et YouTube



YouTube

ROADEF

SOCIÉTÉ FRANÇAISE DE RECHERCHE OPÉRATIONNELLE  
ET D'AIDE À LA DÉCISION