

# Apprentissage automatique de contraintes pour des problèmes de planification de production

David Tremblet<sup>1</sup>, Simon Thevenin<sup>1</sup>, Alexandre Dolgui<sup>1</sup>

IMT Atlantique, LS2N-CNRS, La Chantrerie, 4 Rue Alfred Kastler, B.P. 20722, 44307 Nantes,  
France

david.tremblet@imt-atlantique.fr

**Mots-clés :** *Lot-Sizing, Machine Learning, Ordonnancement*

## 1 Introduction

Les outils de machine learning connaissent un véritable engouement depuis le début des années 2010, offrant des approches de prédictions efficaces au profit de l'intelligence artificielle et de l'analyse statistique. Ces mêmes méthodes de prédictions ont également suscité l'intérêt de la communauté de recherche opérationnelle pour la prise de décision basée sur de l'analyse prédictive exploitant des historiques et des jeux de données massifs. Une des principales forces de la régression, et de l'apprentissage machine en général, est de pouvoir de capturer des tendances non linéaires permettant d'apprendre des valeurs impliquées dans des contraintes qui demeurent très difficile à prédire en temps normal. L'objectif de cette étude est de mettre à profit la puissance de ces modèles de prédiction pour alimenter un programme linéaire avec des informations difficiles à exprimer en programmation linéaire et qui viendront améliorer la précision et la rapidité de résolution. Dans le cas qui nous intéresse, nous souhaitons savoir si cette approche mêlant apprentissage machine et programmation linéaire saurait profiter à des problèmes de planification de la production à capacité limitée.

Pour ce type de problème, l'élaboration d'un plan de production adéquate est généralement assurée par des outils de management des ressources de production ou *Material Requirements Planning* (MRP). Cependant, ces dispositifs ne reposent que sur un calcul des besoins et ne tiennent compte des ressources limitées dédiées à la production. Il faut attendre l'arrivée du MRP2 (*Manufacturing Resources Planning 2*) pour permettre la prise en compte de la capacité disponible à chaque période du plan. Néanmoins, malgré les améliorations apportées par le MRP2, la consommation de la capacité reste difficile à déterminer, car très dépendante du types de tâche à effectuer, des quantités à produire pour la période et des incertitudes rencontrées lors de la production. Ainsi, il est possible que l'atelier ne puisse pas suivre fidèlement un plan de production optimal pour le problème de planification car la quantité de tâches à effectuer pour répondre à la demande dépasserait la capacité disponible pour une période donnée. Certains auteurs ont proposé des modèles incluant le problème d'ordonnancement et problème de lot-sizing (SEEANNER et MEYR 2012, DAUZÈRE-PÉRES et LASSERRE 1994), mais les modèles présentés ne permettent de résoudre que des instances de petites tailles ou se basant sur des horizons très restreints. L'objectif sera alors d'améliorer ce système en déterminant une valeur appropriée pour la contrainte de capacité qui permettrait de trouver le plan de production le plus efficace possible.

## 2 Description du problème et de la méthode

Nous considérons dans cette étude un problème de détermination de lots (ou *lot-sizing*) avec contraintes de capacité (STEFAN VOSS 2006). On cherche à déterminer un plan de production, divisé en  $T$  périodes, dans lequel les moyens de production (ressources) nécessaires à la

production pour toute période  $t \in T$  sont limitées par une contrainte de capacité. L'objectif sera de trouver le plan optimal qui minimise les coûts de production (incluant des coûts d'installation, de fabrication, de retard, et d'inventaire). Dans le cas de cette étude, la vérification d'un tel plan de production pour une période  $t \in T$  s'apparente à un problème d'ateliers à cheminements multiples (Flexible Job-Shop Scheduling Problem).

Dans ce travail, nous cherchons donc à savoir s'il est possible d'entraîner un modèle d'apprentissage machine afin de prédire une valeur appropriée pour la consommation de capacité du problème de lot-sizing à partir d'un historique de production ou de la génération de celui-ci. Une des difficultés de ce problème est que cette même consommation est directement liée aux valeurs affectées à chacune des variables du programme linéaire. Une production conséquente pour une période donnée nécessite une quantité de ressource importante pour cette même période et inversement. Autrement dit, pour garantir l'obtention d'une consommation de ressource la plus précise possible, nous souhaitons intégrer le modèle entraîné dans le programme linéaire destiné à résoudre le problème de planification.

Ainsi, une fois le modèle de prédiction entraîné, nous souhaitons le transformer en un programme linéaire (BIGGS et HARISS 2017, FISCHETTI et JO 2018), qui pourra ensuite être ajouté au problème de lot-sizing. Les valeurs de la consommation de la capacité seront alors générées à chaque nouvelle affectation des variables de décision.

Cette nouvelle approche basée sur de l'apprentissage machine se résume ainsi :

1. Générer des exemples de consommation de capacité pour chaque période en résolvant des problèmes d'ordonnancement correspondant à la production pour une période.
2. Entraînement d'un modèle d'apprentissage machine (Random Forest, Réseaux de neurones...) afin de prédire une valeur pour la consommation de capacité et traduction de ce modèle en MILP.
3. Résolution du problème de lot-sizing couplé aux contraintes apportées par le modèle entraîné et vérification du plan optimal obtenu.

Pour l'apprentissage des modèles de prédiction, les attributs qui serviront à la prédiction devront être choisis méticuleusement, et au moins un de ces attributs doit dépendre des variables du modèle MILP. Les méthodes envisagées pour cette étude sont les réseaux de neurones (DNN) et le Random Forest (RF).

## Remerciements

Ce travail a été réalisé dans le cadre du projet ASSISTANT (<https://assistant-project.eu/>) financé par la Commission européenne, sous le numéro de subvention 101000165, H2020 - ICT-38-2020, Intelligence artificielle pour l'industrie. Les auteurs tiennent également à remercier la région Pays de la Loire pour son soutien financier.

## Références

- BIGGS, Max et Rim HARISS (2017). « Optimizing Objective Functions Determined from Random Forests ». In : *SSRN Electronic Journal*.
- DAUZÈRE-PÉRES, Stéphane et Jean-Bernard LASSERRE (1994). *An Integrated Approach in Production Planning and Scheduling*. Springer Berlin Heidelberg.
- FISCHETTI, Matteo et Jason JO (avr. 2018). « Deep neural networks and mixed integer linear optimization ». In : *Constraints* 23.3, p. 296-309. ISSN : 1383-7133.
- SEEANNER, Florian et Herbert MEYR (mai 2012). « Multi-stage simultaneous lot-sizing and scheduling for flow line production ». In : *OR Spectrum* 35.1, p. 33-73.
- STEFAN VOSS, David L. Woodruff (jan. 2006). *Introduction to Computational Optimization Models for Production Planning in a Supply Chain*. Springer Berlin Heidelberg. 272 p. ISBN : 3540298789.