

Réseaux de neurones pour approximer la capacité consommée en dimensionnement de lots

David Tremblet¹, Simon Thevenin¹, Alexandre Dolgui¹

IMT Atlantique Nantes

{david.tremblet, simon.thevenin, alexandre.dolgui}@imt-atlantique.fr

Mots-clés : *Lot-sizing, Ordonnancement, Apprentissage profond.*

1 Introduction

La planification de la production et l'ordonnancement sont des pratiques essentielles en gestion de production, et vise à produire à moindre coût tout en respectant les demandes et délais imposés par les clients. Dans la pratique, les problèmes de planification de production sont généralement gérées par des logiciels de gestion des ressources de production ou Material Requirements Planning (MRP). Cependant, ces dispositifs se limitent à un calcul des besoins sans prendre en compte les ressources limitées dédiées à la production. Ainsi, il se peut que l'atelier ne puisse pas suivre fidèlement un plan de production optimal en raison de trop grandes quantités à produire, excédant la capacité disponible pour une période donnée. Ce n'est qu'avec l'avènement du MRP2 (Manufacturing Resources Planning 2) que la capacité disponible à chaque période du plan a été intégrée. Malgré les améliorations apportées par le MRP2, la consommation de la capacité demeure difficile à déterminer en raison de la complexité de l'atelier et des incertitudes rencontrées pendant la production. Les quantités à produire doivent alors être ajustées manuellement pour permettre l'obtention d'un plan réalisable, ce qui demande un effort supplémentaire qui dégrade généralement la qualité du plan.

Certains auteurs ont suggéré des approches intégrées pour la planification et ordonnancement de la production ([3, 8]), qui inclut une représentation de la capacité fidèle à l'ordonnancement fait sur l'atelier de production. Cependant, ces approches nécessitent l'intégration de contraintes liées à l'ordonnancement de l'atelier, ce qui peut compliquer la résolution lorsque l'atelier de production en question est complexe à intégrer. L'objectif principale de ce type de problème est alors d'améliorer ce système en déterminant une valeur appropriée pour les contraintes de capacité, permettant ainsi de trouver un plan de production réalisable offrant le coût le plus faible.

2 Approche de résolution

Nous proposons ainsi une approche basée sur l'apprentissage de contraintes [4, 7], et qui vise à apprendre les contraintes liées à la consommation de capacité pour les remplacer par un modèle d'apprentissage supervisé. Pour se faire, nous entraînons un modèle d'apprentissage automatique à prédire la date de fin au plus tôt des problèmes d'ordonnancement lié à l'atelier de production à partir des quantités à produire. Le modèle entraîné est ensuite traduit en un ensemble de variables et de contraintes qui seront intégrés dans le problème de dimensionnement de lots, de manière à pouvoir exploiter les prédictions du modèle au travers des variables de décision du problème. Pour effectuer cet apprentissage de contraintes dans le modèle de planification, nous proposons une structure de réseau de neurones spécifique, qui permet une meilleure traduction de ces réseaux en programme linéaire.

2.1 Réseaux de neurones convexes

Pour prédire efficacement la consommation de la capacité, nous avons comparé différentes architectures de réseaux de neurones. Les types de réseaux couramment utilisés en apprentissage de contraintes sont les réseaux de neurones à propagation avant. La fonction d'activation majoritairement utilisée est la fonction *ReLU* ($f(x) = \max(0, x)$), qui s'intègre facilement dans les modèles mathématiques à l'aide de variables et de contraintes linéaires [5, 2]. Cependant, ce type d'architecture nécessite un nombre important de variables binaires pour pouvoir être intégré, ce qui complique davantage la résolution de ces modèles.

Pour pallier à cette problématique, nous considérons des réseaux de neurones convexes [1] couplés à la fonction d'activation *Maxout* [6], une extension de la fonction *ReLU* qui retourne la valeur la plus élevée parmi toutes les valeurs d'entrée. Ce type d'architecture permet une intégration sans variables binaires qui offre de meilleures prédictions que d'autres modèles basées sur la fonction *ReLU*.

2.2 Expérimentations

Nous avons choisi de comparer notre approche avec plusieurs modèles mathématiques de la littérature et sur plusieurs instances de dimensionnement de lots générées aléatoirement, en faisant varier différents paramètres, dont la taille de l'ordonnancement (6 jobs et 6 machines, 10 jobs et 10 machines, et 20 jobs et 5 machines), le nombre de périodes et le coût de lancement des produits. Notre modèle mathématique avec réseaux de neurones intégrés arrive à trouver des solutions de meilleure qualité pour les moyennes et grandes instances, tout en proposant un taux de faisabilité de 100%. Également, les méthodes de relaxation lagrangienne généralement appliquées aux problèmes de dimensionnement de lots restent valides, et sont également utilisées pour accélérer la résolution de nos modèles.

Remerciements

Ce travail a été réalisé dans le cadre du projet ASSISTANT financé par la Commission européenne, sous le numéro de subvention 101000165, H2020 - ICT-38-2020. Les auteurs tiennent également à remercier la région Pays de la Loire pour son soutien financier.

Références

- [1] Brandon AMOS et al. *Input Convex Neural Networks*. 2016.
- [2] Ross ANDERSON et al. "Strong mixed-integer programming formulations for trained neural networks". In : *Mathematical Programming* 183.1-2 (fév. 2020), p. 3-39.
- [3] Stéphane DAUZÈRE-PÉRES et Jean-Bernard LASSERRE. *An Integrated Approach in Production Planning and Scheduling*. Springer Berlin Heidelberg, 1994.
- [4] Adejuyigbe O. FAJEMISIN et al. "Optimization with constraint learning : A framework and survey". In : *European Journal of Operational Research* (mai 2023).
- [5] Matteo FISCHETTI et Jason JO. "Deep neural networks and mixed integer linear optimization". In : *Constraints* 23.3 (2018), p. 296-309. ISSN : 1383-7133.
- [6] Ian GOODFELLOW et al. "Maxout Networks". In : *Proceedings of the 30th International Conference on Machine Learning*. 2013.
- [7] Donato MARAGNO et al. "Mixed-Integer Optimization with Constraint Learning". In : *Operations Research* (déc. 2023). ISSN : 1526-5463.
- [8] Cathy WOLOSEWICZ et al. "A Lagrangian heuristic for an integrated lot-sizing and fixed scheduling problem". In : *European Journal of Operational Research* 244.1 (2015), p. 3-12.