

Industrie 4.0 : Prédiction de consommation réelle par fine-tuning à partir de simulations

Christophe Rodrigues*, Pegah Alizadeh*, Dmitry Bondarenko **

*Léonard de Vinci Pôle Universitaire, Research Center, 92916 Paris La Défense, France
prenom.nom@devinci.fr,

**Hexagon Manufacturing Intelligence, 261 rue de Paris, 93100 Montreuil, France
dmitry.bondarenko@hexagon.com

Dans cette étude, nous nous focalisons sur la prédiction de la puissance consommée par l'usinage. Ce paramètre joue un rôle primordial dans l'évaluation de la productivité et de la qualité de fabrication d'une pièce. En effet, si la puissance est très faible par rapport aux capacités de la machine ou des outils coupants utilisés, le rendement de l'opération peut être augmenté, ou encore l'environnement d'usinage (machines, outils, etc.) peut être changé par moins performant. La puissance est un paramètre central qui reflète le comportement complexe de l'ensemble « machine, outil coupant, pièce » à chaque instant donné et contient l'historique de formation de la pièce. Enfin, la puissance consommée est sensible au choix de la matière pour la pièce, au type de fixation de pièce dans la machine, à l'état et au taux d'usure de la machine et des outils coupants, à la température ambiante, etc. La nature complexe de la puissance d'usinage fait l'objet de campagnes d'essais physiques préparatoires afin d'ajuster les modèles prédictifs existants. L'algorithme de simulation de la puissance proposée dans cet article contourne la partie expérimentale coûteuse et repose sur les données issues de surveillances de l'atelier de production. Les résultats de simulation pourront être utilisés ensuite dans l'optimisation itérative du programme existant ou dans la création de nouvelles pièces.

La puissance utilisée par une machine à commande numérique (CN) a été monitorée précisément. Cependant, l'association à un instant donné d'une instruction du programme et de ces paramètres à la puissance réelle qu'elle a engendré n'était matériellement pas possible dans le cadre de notre étude. Pour ce faire nous avons utilisé l'algorithme DTW afin d'aligner les valeurs de puissances réelles et simulées. La simulation des programmes a été réalisée par la solution logiciel NCSIMUL. Elle permet à l'usineur de vérifier que son programme ne contient pas d'erreur et que tous les paramètres du processus (comme les vitesses, trajectoires...) sont corrects. Ainsi, un ensemble de paramètres de programmes d'usinage, tout comme la puissance, peuvent être calculés à l'aide de modèles théoriques.

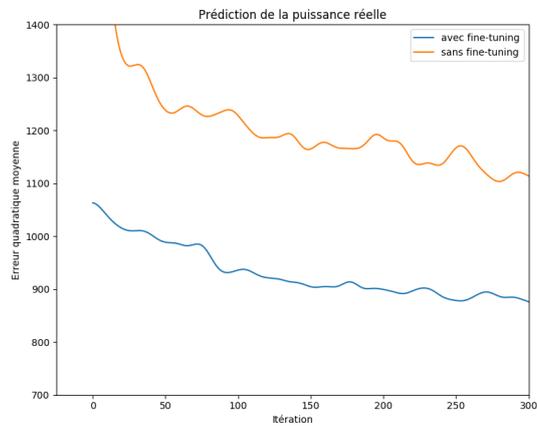
Les progrès récents des techniques d'apprentissage profond ont eu l'effet de mettre en avant l'efficacité de ces approches et par conséquent la valeur potentielle des données industrielles. Néanmoins, il est parfois difficile voir impossible techniquement de les obtenir.

La réutilisation de connaissances ou plus précisément l'adaptation de domaine est activement étudiée depuis notamment (Daumé III, 2007). De nombreux résultats ont été obtenus comme sur la classification d'images (Wang et Deng, 2018). Par exemple, dans le cadre de la classification de textes, le fine-tuning a permis de réduire d'un facteur 100 le nombre d'exemples d'apprentissage nécessaires à précision égale (Howard et Ruder, 2018). Il consiste

Fine-tuning à partir de données simulées

à initialiser une ou plusieurs couches d'un réseau de neurones à l'aide des poids appris sur des données proches par un réseau similaire. Ainsi, nous proposons d'apprendre un premier modèle de prédiction de la puissance simulée et de réutiliser ses poids afin d'initialiser un nouveau modèle de prédiction de la puissance réelle. La Figure ci-dessus illustre l'erreur de prédiction de la puissance avec (en bleu) et sans (en orange) utilisation du fine-tuning avec en abscisse, le nombre d'itérations sur l'ensemble des données d'apprentissage (epoch) et en ordonnée, l'erreur quadratique moyenne (MSE) sur 10 runs. De plus, dans le cas du fine-tuning, 80% d'exemples d'apprentissage en moins sont utilisés. Toutes les couches sont initialisées par les poids du modèle simulé.

Nos résultats expérimentaux sont très encourageants. L'approche permet à partir d'un échantillon de données réelles prélevé au pied de la machine de pouvoir simuler plus finement le comportement de programmes permettant aux usineurs d'anticiper les erreurs. La prochaine étape est de généraliser l'approche et de tester sa robustesse dans des conditions de paramètres variées, avec par exemple des matériaux différents (seul l'acier a été traité pour le moment). Ici notre modèle ne prend en entrée qu'une observation à la fois, indépendamment des autres. L'approche pourrait être améliorée en prenant en entrée une fenêtre de points contigus.



La méthode présentée permet d'améliorer les valeurs de puissance mais ne permet pas d'expliquer des écarts possibles entre machine et simulation. Le fine-tuning des données réelles à partir des données simulées a permis d'obtenir de bons résultats avec moins de données réelles dont la réalisation est onéreuse. Une perspective serait de choisir activement les paramètres à observer sur la machine afin d'en réduire encore le volume.

Ce travail a été financé par le projet FUI LUCID. Nous tenons à remercier Cyril Granger d'UF1 pour la création des données physiques en atelier ainsi que Philippe Rameix d'Hexagon pour son aide à la préparation des données.

Références

- Daumé III, H. (2007). Frustratingly easy domain adaptation. *ACL 2007*.
- Howard, J. et S. Ruder (2018). Fine-tuned language models for text classification. *ACL 2018*.
- Wang, M. et W. Deng (2018). Deep visual domain adaptation : A survey. *Neurocomputing 312*.