

Aide à la Décision pour la Tarification Dynamique dans le Transport

Hajer Ben Fekih¹, Tristan Cazenave¹, A. Ridha Mahjoub¹, Mohamed Ould Lemine²

1. Laboratoire LAMSADE, UMR CNRS 7024, Université Paris-Dauphine
Place du Maréchal de Lattre de Tassigny, 75775 Paris Cedex 16, France

Email : prénom.nom@lamsade.dauphine.fr

2. Alis International, 16 rue Mederic 75017 Paris, France

Email : mohamed.ould@alis-intl.com

Mots-clés : Transport, Tarification dynamique, Machine learning, Optimisation

1 Introduction

Aujourd'hui le mode de tarification traditionnel des services de transport de marchandises n'est plus viable et présente une problématique capitale. En effet, les méthodes de tarification utilisées actuellement présentent des limites considérables et ne répondent plus aux exigences accrues des acteurs intervenant dans le transport. Le défaut majeur de cette méthode est qu'elle est très consommatrice en ressources humaines et en temps d'échange. Par conséquent, elle est loin d'être applicable pour un nombre d'expéditions très élevé. De plus, cette méthode fixe les prix de transport sur une durée relativement importante, d'une année ou voire même de deux années.

Or, actuellement de nombreux facteurs influencent le prix du transport, impliquant une volatilité importante des tarifs et entraînant un besoin de tarification dynamique [1]. Ces facteurs peuvent correspondre, par exemple, à l'escalade des prix du pétrole et au déséquilibre entre l'offre et la demande. Ainsi, le besoin d'outils optimaux et efficaces pour la tarification dynamique devient primordial pour les clients et les transporteurs.

Le problème de la tarification consistant à définir le prix d'un produit ou d'un service de manière statique ou dynamique selon plusieurs critères et objectifs à optimiser, nous considérons plutôt son aspect dynamique. La *tarification dynamique (dynamic pricing)* est définie comme l'ajustement dynamique des prix en fonction de la valeur que les clients attribuent à un produit ou à un service à un moment donné, selon l'évolution du marché. Dans ces travaux de recherche, nous nous intéressons en particulier au problème de la *tarification dynamique juste (dynamic fair pricing)* des services de transport.

Ces dernières années, le problème de tarification a reçu beaucoup d'attention et en particulier la tarification dynamique qui s'avère très intéressante dans un contexte volatil et fortement concurrentiel. La tarification dynamique a été d'abord utilisée dans la tarification du transport aérien, connue sous le nom de *gestion des revenus (Yield management)*[2]. Cette technique de tarification s'est rapidement étendue sur plusieurs autres domaines tels que les télécommunications, énergie, systèmes informatiques, e-commerce[3-6], etc. Ainsi, plusieurs techniques de modélisation et de résolution ont été proposées, telles que la programmation dynamique, la programmation mixte en nombre entiers, la théorie des jeux et la programmation bi-niveaux. Néanmoins, dans le domaine de transport de marchandises, la tarification dynamique n'a pas encore été exploitée ou étudiée.

Nos algorithmes se basent principalement sur des méthodes *d'apprentissage automatique (Machine Learning)* et *d'optimisation* [7]. Les avancées récentes dans le domaine de l'intelligence artificielle (IA) nous permettront de prédire avec plus de précision et plus rapidement l'évolution des prix à travers de modèles capables d'expliquer les données récoltées. Le machine Learning va plus loin en prédiction des règles, et permet potentiellement de prédire de nouvelles données (*predictive analytics*), voire finalement de prendre des décisions à partir de nouvelles données et du modèle établi. La prise en considération des données historiques et l'intégration des données réelles en provenance des chargeurs et des transporteurs dans une unique base de données est un avantage très important, permettant de tester les approches utilisées par des cas réels et accélérera le processus d'apprentissage et d'amélioration.

2 Approche de modélisation

1. Définition du problème

En considérant un historique de données de transport, pour chaque demande de transport s_t qui arrive à l'instant t , l'algorithme doit pouvoir :

assigner cette demande à une classe forfaitaire selon les critères de classification,

estimer le prix juste de la prestation, et

apprendre des retours de l'environnement après chaque action afin d'améliorer la précision de l'estimation.

L'algorithme d'apprentissage a pour but la prédiction du prix exacte (ou juste) en apprenant à chaque itération.

L'algorithme proposé se base sur la logique de q-learning. (figure 1)




Figure 1: approche de Q-learning

2. Processus de tarification :

Le processus de tarification est déclenché par l'arrivée d'une demande de tarification, notée X_i . Suite à cette demande, le système doit pouvoir identifier les facteurs externes pertinents, notés F_i et les récupérer en temps réel. L'ensemble des données récoltées (X_i et F_i) permet d'affecter la demande à une classe et ainsi de récupérer la fonction d'estimation appropriée. Ce qui permet, à travers une fonction d'estimation, de proposer un prix p_i . L'application de ce prix engendra un retour des agents de l'environnement, qui sont principalement pour notre contexte des chargeurs et des transporteurs. Le retour peut être une récompense, qui permet de confirmer la justesse de la fonction d'approximation, ou une pénalité, qui permet quant à elle de corriger la fonction d'estimation dans un sens ou dans un autre. Un indice de *fairness* sera également généré permettant ainsi une évaluation de la justesse de tarification. Cet apprentissage et retour sur expérience est assuré par des boucles de feedback et constitue un élément essentiel et critique de l'évolution de l'algorithme. La figure 2 présente une cartographie du processus de tarification adopté.

Nous avons proposé l'approche de modélisation suivante en quatre modules :

1. Récupération des facteurs externes pertinents
2. Classification de la demande
3. Proposition de prix
4. Application du prix et évaluation des retours
- 5.

3. Etats du système

Nous définissons un état comme étant l'ensemble des critères dont dépend le prix, et qui permettent de l'affecter à une classe tarifaire. Donc, un état dépend de la demande de prestation, représentée par le vecteur $X_i = (x_{i1}, x_{i2}, \dots, x_{in})$, et les facteurs externes, représentés par le vecteur $F_i = (F_{i1}, F_{i2}, \dots, F_{ip})$, où n et p sont respectivement le nombre des critères de la demande de prestation et le nombre des facteurs externes renseignés. Les critères de la demande de prestation peuvent être à titre d'exemple, le poids, le volume et la distance. Quant aux facteurs externes, nous pouvons citer à titre d'exemple les métriques suivantes : le prix de fuel, la saisonnalité, la capacité disponible, etc.

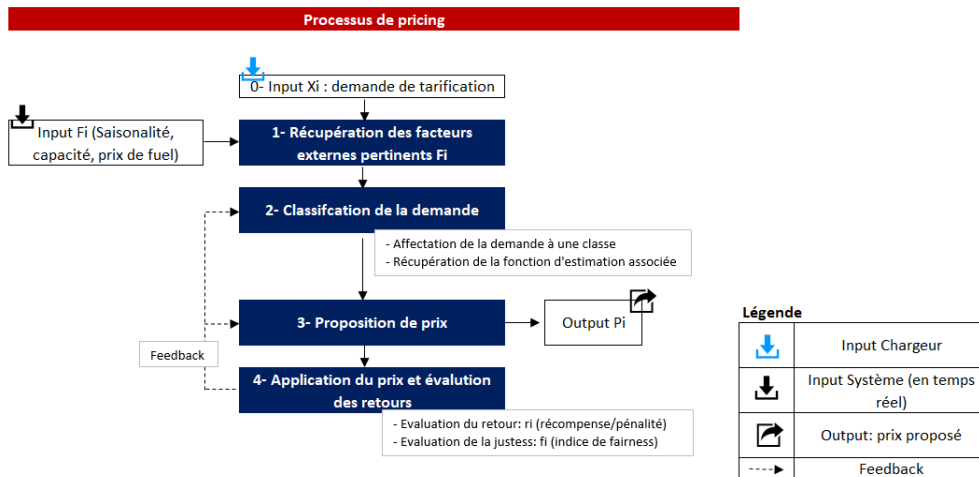


Figure 2: Approche de modélisation

4. Actions (Prix proposés)

Une action présente dans notre contexte un prix proposé aux deux parties : le chargeur et le transporteur. Nous pouvons considérer l'ensemble des actions comme un ensemble continu ou discret. Dans le premier cas, le prix proposé, noté par p_i , sera considéré comme une variable continue. Dans le deuxième cas, une discrétisation de l'ensemble des valeurs sera proposée qui dépend bien évidemment du pas de discrétisation.

5. Fonction d'approximation

Nous proposons un réseau de neurones pour approximation de la politique de prix. Le réseau de neurones utilisé contient trois couches, tel que présenté dans la figure 3.




Figure 3: Premier réseau de neurones implémenté

La méthodologie adoptée est la suivante :

1. Load data
2. Split data for training and validation :

Une permutation aléatoire (trainpart=0.6, validatepart=0.2, testpart=0.2) Scaling (MIN MAX scaling)

3. Create Keras model
4. Fit/Train Keras model
5. Results

6. Fairness

La notion de fairness est définie dans ce contexte comme un indice d'acceptation de deux parties : chargeur (acheteur) et transporteur (vendeur). Cet indice va permettre à l'algorithme de corriger son estimation dans les itérations suivantes de la même classe.

7. Récompense

Une récompense est une évaluation quantitative du prix proposé par l'algorithme. La définition de la fonction de récompense est sensible et critique puisqu'elle influe directement sur le mode d'apprentissage. Le calcul de la récompense, ou la pénalité, dépend de l'objectif à optimiser et l'évaluation de la fairness.

Algorithme d'apprentissage

Initialisation de la fonction d'approximation

$Z_i = Z_0$

while $i < \text{nb_iterations}$ **do**

$p_i = \text{estimator.predict}(Z_i)$ {reseau de neurones}

 Appliquer p_i {proposer le prix p_i }

 Calculer l'indice de fairness f_i

 Calculer la récompense r_i

 Mettre à jour la fonction d'apprentissage

$Z_i = Z_{i+1}$


end while

3 Résultats

Nous avons testé notre algorithme sur des données réelles.

Sur certains ensembles de tests, le tarif estimé peut atteindre 30% d'écart par rapport au prix réel.

Nous remarquons que le type de la fonction d'approximation a une influence directe sur la précision de la tarification et que le pattern de tarification diffère d'un ensemble d'expédition à un autre.



Ensemble	% d'écart (moyenne)
Ensemble d'entraînement	31.33 %
Ensemble de validation	29.52 %
Ensemble de test	30.46 %

Metric/set	Mean Squared Error: MSE (unscaled)	Mean Absolute Error: MAE (unscaled)	Mean Absolute Error: MAE (scaled)
Train set	0.0436	0.1718	10.15750605
Validation set	0.0494	0.1911	10.51783702

4 Références

- [1]: Thijs Boonekamp, J Gromicho, W Dullaert, and B Radstaak. Air cargo revenue management, Vrije Universiteit, Amsterdam, 2013.
- [2]: Kalyan T Talluri and Garrett J Van Ryzin. The theory and practice of revenue management, volume 68. Springer Science & Business Media, 2006.
- [3]: Schwind, Michael. Dynamic Pricing and Automated Resource, Allocation. Springer Berlin Heidelberg, 2007.
- [4]: Fampa, M., et al. "Bilevel optimization applied to strategic pricing in competitive electricity markets." Computational Optimization and Applications 39.2 (2008): 121-142, 2008.
- [5]: Msigwa, Robert Ebihart, et al. "A smoothing approach for solving transportation problem with road toll pricing and capacity expansions." Journal of Inequalities and Applications 2015.1 : 237, 2015.
- [6]: AMBRA, Tomas, CARIS, An, et MACHARIS, Cathy. Towards freight transport system unification: Reviewing and combining the advancements in the physical internet and synchromodal transport research. International Journal of Production Research, 2019, vol. 57, no 6, p. 1606-1623, 2019.
- [7]: TensorFlow for Deep Learning: From Linear Regression to Reinforcement Learning, Bharath Ramsundar, Reza Bosagh Zadeh, "O'Reilly Media, Inc.", 1 mars 2018 - 256 pages, 2018.