

Pour une Meilleure Estimation de la Qualité Perçue par l'Usager

Lamine Amour¹ Sami Souihi¹ Abdelhamid Mellouk¹

lamine.amour@u-pec.fr sami.souihi@u-pec.fr mellouk@u-pec.fr

¹ IUT Créteil-Vitry, Université Paris Est Créteil,
Laboratoire Images, Signaux et Systèmes Intelligents (LISSI) - EA 3956

THÈMES – *Informatique, Imagerie, Communication.*

RÉSUMÉ – *Pour garantir un meilleur service, les acteurs de l'Internet se sont intéressés ces dernières années à une nouvelle idée qui consiste à intégrer le ressenti réel de l'utilisateur dans la boucle de contrôle des différents services proposés. En d'autres termes, il s'agit d'évoluer la gestion du réseau en migrant d'une vue "centrée réseau", où l'on se contentait uniquement des paramètres issus du réseau lui-même, vers une vue "centrée utilisateur" en considérant l'ensemble des facteurs, endogènes ou exogènes, pouvant impacter la perception par l'utilisateur (Qualité de l'Expérience: QdE). L'objectif est celui d'enclencher des actions spécifiques correctrices suite à l'arrivée d'événements imprévisibles ou non souhaités comme une QoS insatisfaisante, un retour d'expérience négatif ou encore des dysfonctionnements des éléments du réseau. Le présent article détaille la première étape de la mise en œuvre d'une telle gestion. Il présente une nouvelle heuristique pour améliorer la construction d'un modèle objectif et non intrusif de prédiction de la QdE usagers. L'idée maîtresse défendue ici consiste à sélectionner les meilleurs facteurs impactant la QdE en utilisant la corrélation de Pearson et la technique de retour arrière (backjumping). Ces facteurs ainsi sélectionnés optimisent la prédiction de la QdE obtenue en utilisant les méthodes d'apprentissage automatique. Une campagne subjective de tests préliminaires pour le service vidéo nous a permis de vérifier que l'heuristique proposée améliore les performances d'estimation d'au moins 10% avec un taux de corrélation qui dépasse les 90%.*

MOTS-CLÉS – *Qualité de l'Expérience, Apprentissage Automatique, Corrélation de Pearson*

Justification

- $(1-ABS(r(F_{test}, F_{select})))$ représente l'impact (interaction/répulsion) entre les facteurs.
- $r(ABS(F_{test}, MOS))$ représente l'interaction entre le facteur et le score MOS.

Le principe de notre heuristique consiste alors à utiliser la fonction d'utilité ($f_benefit$) pour classer tous les facteurs candidats (F_{test}) dans une file et les tester, un par un, en étudiant leur impact sur l'amélioration de l'estimation de la QdE usager.

4 Évaluation de l'heuristique de sélection des facteurs impactant la QdE

Pour évaluer notre heuristique, nous avons commencé par construire une base de données collectée lors d'une campagne de test [1]. Ensuite, nous avons choisi trois méthodes d'apprentissage automatique qui sont : les réseaux de neurones (RNN), les machines à vecteurs de support (SVM) et les forêts d'arbres décisionnels (RF). Cette évaluation est effectuée avec l'outil "R software"¹. Le processus d'évaluation est présenté comme suit :

1/ Construction la matrice de corrélation avec l'ensemble des paramètres vidéos (Figure (1)).

2/ Initialisation des variables de l'heuristique :

- $F_{select} = \{f_{FR}\}$ (facteur ayant la grande corrélation avec le MOS initialement),

- $F_{test} = f_{Resol}$ (facteur avec la meilleure valeur ajoutée),

- $F_{rest} = \{f_{CT}, f_{MVT}, f_{Resol}, f_{Cach}, f_{Size}, f_{BR}, f_{FL},$

$f_{AR}, f_{AL}, f_{ABuff}\}$.

3/ Sélection des facteurs avec l'heuristique de Backjumping en suivant la démarche détaillée dans la Figure (2).

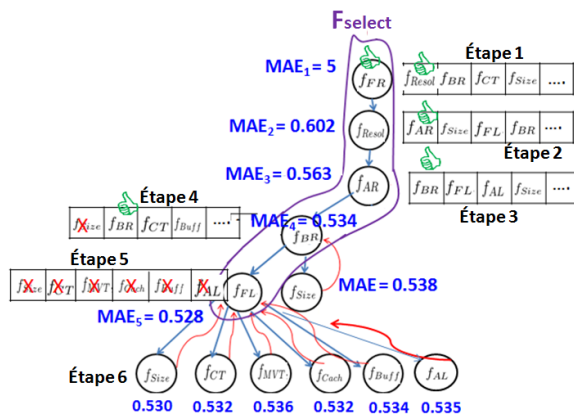


FIGURE 3 – Étapes de sélection des meilleurs facteurs.

La Figure (3) résume l'exécution du processus de sélection des meilleurs facteurs en utilisant la base de données collectée [1], où le MAE représente l'erreur absolue moyenne.

1. <https://www.r-project.org/>

Dans les premières étapes de notre méthode (étapes 1, 2 et 3), à chaque fois, le facteur ayant la plus grande valeur ajoutée ($f_benefit$) améliore la performance de prédiction. Donc, chaque facteur sera sélectionné et ajouté successivement à F_{select} . Dans les deux étapes (4) et (5), le premier facteur classifié ne donne plus de bon résultat. C'est pourquoi, en utilisant la technique de backjumping, le facteur suivant est sélectionné. Dans l'étape 6, aucun facteur candidat ne donne un taux d'erreur plus faible que l'étape précédente (MAE_5 qui égale à 0.528 avec la méthode RF qui utilise $n = 100$ arbres décisionnels).

À la fin du processus de sélection, notre heuristique a sélectionné cinq facteurs ($f_{Resol}, f_{FR}, f_{FL}, f_{BR}$ et f_{AR}) et la meilleure méthode (M) résultante est RF avec 100 arbres décisionnels et une MAE égale à 0.528. Pour confirmer les performances de notre heuristique, nous avons réalisé une comparaison en variant le nombre de facteurs en entrée du modèle supervisé (méthode RF avec $n=100$). Dans cette comparaison trois cas de figures sont testés comme indiqué dans le Tableau (1). Les résultats obtenus sont exprimés en terme de MAE et de taux de corrélation (r).

Configuration	Nombre	MAE	r
Tous les facteurs	11	0.586	0.89
Choix aléatoire	5	0.591	0.87
Proposition	5	0.528	0.90

TABLE 1 – Tableau comparatif de l'impact des facteurs

D'après le Tableau (1), nous déduisons que le modèle de prédiction utilisant nos facteurs sélectionnés est le meilleur en terme de MAE et en terme de taux de corrélation. En effet, notre heuristique (*Proposition*) améliore l'estimation par rapport au modèle utilisant tous les facteurs de 10% et par rapport au modèle utilisant cinq paramètres choisis aléatoirement de 13%. En outre, elle permet d'avoir un taux de corrélation qui dépasse les 90%, ce qui peut être considéré comme un bon résultat d'estimation de la QdE pour le service vidéo.

5 Conclusion

Dans cet article, nous avons présenté une heuristique qui permet d'améliorer la construction des modèles d'apprentissage supervisé d'estimation de la QdE en termes du score subjectif MOS. Cette heuristique combine l'utilisation de la corrélation de Pearson et la technique retour arrière. Les résultats de l'évaluation indiquent qu'une présélection des entrées des modèles d'apprentissage supervisés assurent un gain d'au moins de 10% lors de l'estimation de la QdE pour le service vidéo.

Références

- [1] Lamine Amour, and Sami Souihi, and Mellouk Abdelhamid, *Dataset video parameters (VLC indicators)*. Access : [\scriptstylehttps://github.com/Lamyne/ QoE-Dataset-VLC-Indicators-QoS](https://github.com/Lamyne/ QoE-Dataset-VLC-Indicators-QoS)