

الجمهورية الشعبية الديمقراطية الجزائرية
République Algérienne Démocratique et Populaire
وزارة التعليم العالي و البحث العلمي
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
المدرسة العليا للإعلام الآلي 08 ماي 5491. بسيدي بلعباس
École Supérieure en Informatique
-08 Mai 1945- Sidi Bel Abbès



THESIS

To obtain the diploma of **State engineer**
Field: **Computer Science**
Specialty: **Systèmes d'Information et Web (SIW)**

Theme

**Optimizing Federated Learning Advancements in
Model Aggregation and Client Selection**

Presented by:
Amira MEKKI

Submission Date: **Sept, 2024**
In front of the jury composed of:

Mr. BENDAOU Fayssal

Mr. OUCHANI Samir

Mr. BENSLIMANE Sidi Mohammed

Mr. MALKI Abdelhamid

President

Supervisor

Co-Supervisor

Examiner

Academic Year : 2023/2024

Abstract

Over the past few years, Federated Learning (FL) has emerged as a promising solution for distributed machine learning across decentralized devices. Its ability to maintain data privacy while enabling collaborative learning has made it especially relevant in fields where data confidentiality is paramount. However, the performance of traditional FL algorithms, like FedAvg, is often hindered in dynamic, heterogeneous environments. To address these challenges, recent advancements have introduced Reinforcement Learning (RL) techniques to optimize the client selection process in FL. In this graduation thesis, we propose the FLCS_DQN framework, which integrates Double Deep Q-learning (DDQL) to improve client selection efficiency and overall model performance in FL. Our architecture spans three layers Edge, Fog, and Cloud with an RL module for intelligent client selection. Through comprehensive experimental evaluations, we compare the performance of FLCS_DQN, demonstrating significant improvements in model convergence and accuracy. Results show that our framework achieves faster convergence, reducing the required FL rounds by up to 80%, and enhances global model accuracy.

Keywords— Federated Learning, Machine Learning, Reinforcement Learning, Model Aggregation, Client Selection.

ملخص

على مدى السنوات على مدى السنوات الأخيرة، أصبح التعلم الفيدرالي حلاً واعدًا للتعلم الآلي الموزع عبر الأجهزة اللامركزية. تكمن أهميته في قدرته على الحفاظ على خصوصية البيانات مع تمكين التعلم التعاوني، مما يجعله ذا صلة خاصة في المجالات التي تكون فيها حماية البيانات أمراً بالغ الأهمية. ومع ذلك، فإن أداء الخوارزميات الفيدرالية التقليدية مثل FedAvg يظل محدوداً في البيئات الديناميكية وغير المتجانسة. للتغلب على هذه التحديات، تم دمج تقنيات التعلم المعزز حديثاً لتحسين عملية اختيار العملاء في إطار التعلم الفيدرالي. في هذا المشروع، نقترح FLCS_DQN، الذي يدمج خوارزمية التعلم المعزز العميق المزدوج DDQL لتحسين كفاءة اختيار العملاء وأداء النموذج في التعلم الفيدرالي. تمتد بنية نظامنا عبر ثلاث طبقات – الحافة (Edge)، الضباب (Fog)، والسحابة (Cloud) – وتستخدم نماذج تعلم عميق خاصة بالمجال للتدريب المحلي، مع وحدة للتعلم المعزز لاختيار العملاء بذكاء في الطبقة السحابية. من خلال تقييمات تجريبية شاملة، نقارن أداء FLCS_DQN مع الأساليب الفيدرالية التقليدية، ونظهر تحسينات كبيرة في سرعة التوافق ودقة النموذج، خصوصاً في البيئات غير المتجانسة. أظهرت النتائج أن إطار عملنا يحقق توافقاً أسرع، مما يقلل من عدد دورات التعلم الفيدرالي المطلوبة بنسبة تصل إلى 80%، مع تحسين دقة النموذج العالمي في سيناريوهات متعددة.

التعلم الفيدرالي، التعلم الآلي، التعلم المعزز، تجميع النماذج، اختيار العملاء

Résumé

Au cours des dernières années, l'apprentissage fédéré s'est imposé comme une solution prometteuse pour l'apprentissage automatique distribué sur des dispositifs décentralisés. Sa capacité à préserver la confidentialité des données tout en permettant un apprentissage collaboratif le rend particulièrement pertinent dans les domaines où la protection des données est cruciale. Cependant, les performances des algorithmes FL traditionnels, tels que FedAvg, sont souvent limitées dans des environnements dynamiques et hétérogènes. Pour surmonter ces défis, les avancées récentes ont introduit des techniques de renforcement afin d'optimiser le processus de sélection des clients dans le cadre du FL. Dans ce mémoire, nous proposons FLCS_DQN, qui intègre l'algorithme Double Deep Q-learning pour améliorer l'efficacité de la sélection des clients et les performances globales du modèle dans le FL. Notre architecture s'étend sur trois couches — Edge, Fog et Cloud — et utilise des modèles de deep learning spécifiques au domaine pour l'entraînement local, avec un module RL pour la sélection intelligente des clients au niveau de la couche Cloud. À travers des évaluations expérimentales approfondies, nous comparons les performances de FLCS_DQN avec les approches FL standards, démontrant des améliorations significatives en termes de convergence du modèle. Les résultats montrent que notre contribution permet une convergence plus rapide, réduisant jusqu'à 80% les cycles d'apprentissage fédéré nécessaires, tout en améliorant la précision du modèle global.

Mots-clés— Apprentissage fédéré, Apprentissage automatique, Apprentissage par renforcement, Agrégation de modèles, Sélection des clients.
