

الجمهورية الشعبية الديمقراطية الجزائرية
République Algérienne Démocratique et Populaire
وزارة التعليم العالي والبحث العلمي
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
المدرسة العليا للإعلام الآلي ٠80 ماي ٠5491. بسيدي بلعباس
École Supérieure en Informatique, 08 Mai 1945- Sidi Bel Abbès



Mémoire

En Vue de l'obtention du diplôme de **Master**

Filière:: **Informatique**
Spécialité:: **Intelligence Artificielle et Science de Données**

Optimizing Federated Learning with Deep Reinforcement Learning: Enhanced Strategies for Client Selection and Resource Allocation

Présenté par: **Mohammed Amir Messioud**

Soutenu le: **28 Septembre, 2025**

Devant le jury composé de :

Mme. Dif Nassima
M. Serhane Oussama
M. Abdelhamid Malki
M. Samir Ouchani

Présidente
Examineur
Encadreur
Encadreur

Abstract

Federated Learning (FL) has emerged as a distributed machine learning paradigm that enables multiple decentralized clients to collaboratively train a global model without sharing raw data, preserving privacy and reducing the need for centralized data storage. However, this decentralized nature introduces new challenges, particularly in client selection and resource management, which significantly affect model performance, communication efficiency, and system fairness. Hierarchical Federated Learning (HFL) further extends FL by introducing intermediate aggregation levels (e.g., edge servers), which can improve scalability and reduce communication bottlenecks but also add layers of complexity in resource coordination and scheduling. Various approaches have been proposed to address the challenges of client selection and resource management in Federated Learning. Among these, Deep Reinforcement Learning (DRL) stands out for its ability to adaptively optimize decisions in dynamic, heterogeneous environments. By learning from system feedback, DRL has demonstrated promising potential in improving model performance, fairness, and resource efficiency. This thesis explores the landscape of client selection and model aggregation strategies in both FL and HFL settings, with a focus on DRL-based approaches. Through a comparative analysis of existing techniques, including clustering methods, graph-based models, and multi-objective selection policies, this study aims to shed light on their strengths, limitations, and applicability under various constraints such as non-i.i.d. data, limited computational resources, and variable network conditions. The goal is to contribute toward the development of more robust, efficient, and fair federated learning frameworks tailored for real-world deployment scenarios.

Keywords— Hierarchical Federated Learning, Client Selection, Resource Management, Model Aggregation, Deep Reinforcement Learning

ملخص

لقد ظهر التعلم الفيدرالي (FL) كنموذج جديد في مجال التعلم الآلي الموزع، حيث يمكّن عدداً من العملاء اللامركزيين من تدريب نموذج عالمي بشكل تعاوني من دون مشاركة البيانات النخام، مما يحافظ على الخصوصية ويقلل الحاجة إلى تخزين البيانات في مركز واحد. غير أن هذه الطبيعة اللامركزية تُدخل تحديات جديدة، خصوصاً في اختيار العملاء وإدارة الموارد، وهو ما يؤثر بشكل كبير على أداء النموذج، وكفاءة الاتصال، وعدالة النظام. أما التعلم الفيدرالي الهرمي (HFL) فيوسّع هذا النموذج من خلال إدخال مستويات وسيطة للتجميع (مثل الخوادم الطرفية)، مما يحسن من قابلية التوسع ويقلل من اختناقات الاتصال، لكنه يضيف في المقابل طبقات من التعقيد في تنسيق الموارد وجدولة العمليات.

لقد اقترحت عدة مقاربات للتعامل مع تحديات اختيار العملاء وإدارة الموارد في التعلم الفيدرالي. ومن بين هذه المقاربات، يبرز التعلم بالتعزيز العميق (DRL) لقدرته على تحسين القرارات بشكل تكيفي في بيئات ديناميكية وغير متجانسة. من خلال التعلم من التغذية الراجعة للنظام، أظهر هذا النهج إمكانات واعدة في تحسين أداء النماذج، وتعزيز العدالة، ورفع كفاءة استخدام الموارد.

تستكشف هذه الأطروحة استراتيجيات اختيار العملاء وتجميع النماذج في بيئات FL و HFL، مع التركيز بشكل خاص على المقاربات المعتمدة على DRL. ومن خلال تحليل مقارن للتقنيات الحالية، بما في ذلك أساليب التجميع العنقودي، النماذج المعتمدة على الرسوم البيانية، وسياسات الاختيار متعددة الأهداف، يسعى هذا البحث إلى توضيح نقاط القوة والضعف وإمكانيات التطبيق تحت قيود مختلفة مثل البيانات غير المستقلة وغير المتطابقة (non-IID)، الموارد الحاسوبية المحدودة، وظروف الشبكة المتغيرة. الهدف هو الإسهام في تطوير أطر تعلم فيدرالي أكثر قوة وكفاءة وعدلاً، تكون ملائمة للتطبيقات الواقعية.

الكلمات الرئيسية— التعلم الفيدرالي الهرمي، اختيار العملاء، إدارة الموارد، تجميع النماذج، التعلم بالتعزيز العميق