

## Une plateforme d'apprentissage fédéré pour IoT : Application à l'industrie 4.0

Hamza SAFRI, Mohamed Mehdi KANDI, Youssef MILOUDI, Christophe BORTOLASO, Denis TRYSTRAM, Frédéric DESPREZ

Les entreprises industrielles adoptent plusieurs stratégies de maintenance des équipements, en fonction de leur budget, des ressources humaines disponibles et de leur niveau d'expertise. Si la réparation de l'équipement est effectuée après la panne, l'état du processus industriel peut se dégrader ou s'arrêter pendant un certain temps. C'est pourquoi les entreprises adoptent aujourd'hui des stratégies de maintenance basées sur des mesures de l'équipement, telles que la durée de vie restante, ou sur l'analyse des données de fonctionnement collectées, telles que l'intensité et la température, afin d'anticiper les défaillances et de planifier les actions de maintenance.

L'industrie 4.0, qui représente la quatrième révolution du secteur industriel, a permis aux fournisseurs et fabricants d'introduire des technologies et des concepts, principalement l'Internet des objets (IoT), l'informatique en nuage et l'analyse de données, afin de vérifier l'état des équipements et de détecter les potentiels défauts. Cette approche est appelée "maintenance prédictive". Généralement, la dégradation des équipements se produit souvent de manière progressive entre l'état normal et l'état défaillant. La maintenance prédictive évalue les conditions réelles et leurs évolutions afin de prédire durant le processus de dégradation, si des actions de maintenance doivent être prises avant la panne. Cette stratégie repose sur le déploiement de capteurs connectés au niveau des équipements pour collecter un ensemble de mesures. Ces dernières sont par la suite utilisées par des modèles pour prédire l'état future de l'équipement. Dans ce contexte, des études[1] ont montré que les entreprises ayant adoptés une stratégie prédictive pouvaient réduire les coûts de maintenance de 30 % et les états d'arrêt de 70 %.

Néanmoins, le déploiement des modèles de la maintenance prédictive à l'échelle industrielle soulève encore de nombreuses questions relatives à la confiance des données de capteurs, aux algorithmes nécessaires pour détecter des anomalies et prédire des pannes, au passage à l'échelle de ces systèmes en termes de volume et l'hétérogénéité des équipements nécessaire pour avoir les données qui décrivent suffisamment le processus de dégradation. En plus, le nombre de modèles augmente avec le nombre des équipements, ce qui complique la gestion et le déploiement de ces modèles. Dans cette optique, nous trouvons plusieurs approches permettant d'agrèger les modèles des équipements en un seul modèle générique.

L'apprentissage fédéré (FL)[2] a été proposé pour la première fois par Google en 2016 pour prédire la saisie de texte des utilisateurs sur des dizaines de milliers d'appareils Android tout en agrègent ces modèles en un seul et en conservant les données sur les appareils. Dans cette approche, un serveur central distribue un modèle entraîné à des participants. Chaque participant forme un autre modèle sur des données disponibles localement. Ces modèles sont ensuite renvoyés au serveur central, où ils sont moyennés pour produire un nouveau modèle. Ce nouveau modèle fait désormais office de modèle principal et il est à nouveau distribué aux participants.

Notre travail se focalise d'abord sur le problème de la gestion et l'orchestration de l'apprentissage fédéré dans les environnements IoT. Pour cela, Nous proposons une architecture et un Framework IoT générique pour FL qui intègre des composants capables de gérer les participants et d'orchestrer les tâches fédérées telles que l'entraînement, l'agrégation et l'évaluation du modèle global.

Ensuite, nous nous intéressons au problème de l'agrégation des modèles traditionnels d'apprentissage automatique dans le contexte FL. Pour cela, nous proposons une méthode d'agrégation basée sur l'empilement qui consiste à entraîner des méta-modèles pour combiner les prédictions d'un ensemble de modèles de base. Cette méthode est intégrée dans le Framework implémenté dans le contexte de ce travail et tester sur des données réelles provenant des convoyeurs de plusieurs aéroports.

[1] R. Berger, "Predictive maintenance-Is the timing right for predictive maintenance in the manufacturing sector?," *Rol. Berger*, no. november, 2015.

[2] H. B. McMahan, E. Moore, D. Ramage, S. Hampson, and B. A. y Arcas, "Federated Learning of Deep Networks using Model Averaging," *Arxiv*, 2016.