

Optimisation par PSO avec utilisation du dominating vertex set pour le paramétrage des couches cachées d'un MLP

Ines Hadjadji*, Nour Elislem Karabadji**
Hassina Seridi* Naouel Manaa* Wajdi Dhifli***

*LabGed, Université Badji Mokhtar Annaba, Annaba, Algérie
{ines.hadjadji; naouel.manaa}@univ-annaba.dz
seridi@labged.net

**École nationale supérieure de technologie et d'ingénierie, 23005 Annaba, Algérie
n.karabadji@ensti-annaba.dz

***CANTHER, University of Lille, CNRS UMR 1277, Inserm U9020, 59045 Lille, France
wajdi.dhifli@univ-lille.fr

1 Introduction

Le nombre de neurones utilisés dans un réseau de neurones artificiels impacte significativement son efficacité et nécessite un équilibre délicat pour éviter des approximations inadéquates ou des surajustements. Pour une analyse approfondie du problème, une étude menée par (Abdolrasol et al., 2021) a été appréhendée car présentant diverses techniques d'optimisation des réseaux neuronaux artificiels. Dans cet article, nous présentons une nouvelle méthode qui vise à réduire le nombre de neurones et de couches, tout en maximisant la précision du modèle.

2 Méthodologie

L'approche proposée optimise l'architecture d'un perceptron multicouche (MLP) en utilisant le Dominating Set (DS) rehaussé d'une optimisation par le PSO. Dans ce contexte, un graphe de corrélation est construit sur les attributs du jeu de données. Un seuil de filtrage est utilisé pour supprimer les liens de faibles corrélations puis le DS est calculé sur ce graphe filtré. Chaque noeud de ce DS représentera un neurone dans la première couche cachée. L'ensemble des noeuds du DS est retiré du graphe de corrélation initial et un nouveau DS est calculé pour construire la couche cachée suivante. Ce processus est répété itérativement, le nombre de couches cachées qui sera précisé par la particule de notre optimisation PSO.

La phase d'encodage et de décodage : Chaque particule du PSO encode $k + 1$ valeurs réelles. La première valeur est le nombre de couches cachées k , tandis que les k valeurs suivantes représentent les seuils à appliquer sur les graphes de corrélations pour construire les k couches cachées. La phase de décodage implique la conversion des valeurs réelles codées dans chaque particule en hyperparamètres spécifiques du modèle MLP en utilisant les graphes et le DS comme mentionné précédemment.

Évaluation des particules : À chaque itération, les particules sont évaluées en fonction de leur capacité à construire un MLP précis (un *coût* minimal) avec une *structure* minimale (en terme du nombre de noeuds). La fonction de fitness est : $Fitness(p) = \alpha * \text{coût}(MLP) + \beta * \text{structure}(MLP)$, où α et β sont des facteurs décidés empiriquement.

3 Expérimentations

Notre approche a été évaluée sur 20 bases UCI (Kelly et al.) avec une validation croisée à 10 plis. Les bases de données utilisées sont : Adult (AD), Amphibians (AGCN), Amphibians_GCN (AGF), breast-cancer-wisconsin (WDBC), breast-cancer-wisconsin-wpbc (WPBC), CompanyBankruptcyPrediction (CBP), divorce (Di), DryBean (DB), heartDisease (HDH), Iranian Churn (IC), Libras Movement (LM), ozone (Oz), paerkinsons (Pa), RefractiveErrorsDataSet (Re), sonar (So), statlog-landsat-satellite (SLS), student mat (SM), ultrasonic flowermeter diagnostics MeterC (UFDC), Waveform (Wa), Z-Alizadehsanidataset (ZAS). Les architectures simplifiées du MLP obtenues, comparées à trois architectures standards, ont montré une amélioration significative du taux de bon classement sur 12 ensembles de données (voir la figure 1), démontrant la compétitivité de notre approche.

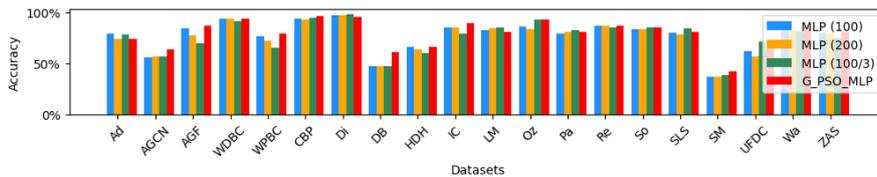


FIG. 1 – Comparaison des performances en terme de taux de bonne classification (accuracy) entre notre approche et trois architectures de MLP standard.

4 Conclusion

Nous avons proposé une approche visant à améliorer la construction des couches cachées du MLP. En intégrant le PSO et le DS, notre approche permet le réglage automatique des couches cachées du MLP, optimisant ainsi la structure du réseau MLP. Cette méthode offre une architecture simplifiée pour le MLP, tout en améliorant ses performances de classification.

Références

Abdolrasol, M. G., S. S. Hussain, T. S. Ustun, M. R. Sarker, M. A. Hannan, R. Mohamed, J. A. Ali, S. Mekhilef, et A. Milad (2021). Artificial neural networks based optimization techniques : A review. *Electronics* 10(21), 2689.

Kelly, M., R. Longjohn, et K. Nottingham. The UCI Machine Learning Repository. <https://archive.ics.uci.edu>.