



HAL
open science

Apprentissage machine par transfert appliqué à la surveillance non-intrusive des charges électriques

Yacine Belguermi, Patrice Wira, Gilles Hermann

► To cite this version:

Yacine Belguermi, Patrice Wira, Gilles Hermann. Apprentissage machine par transfert appliqué à la surveillance non-intrusive des charges électriques. Congrès National de la Recherche des IUT, Université de Haute-Alsace (UHA) Mulhouse - Colmar [Université de Haute-Alsace (UHA)], Mar 2024, Mulhouse, France. hal-04619715

HAL Id: hal-04619715

<https://hal.science/hal-04619715v1>

Submitted on 21 Jun 2024

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Apprentissage machine par transfert appliqué à la surveillance non-intrusive des charges électriques

Yacine Belguermi¹

yacine.belguermi@uha.fr

Patrice Wira¹

patrice.wira@uha.fr

Gilles Hermann¹

gilles.hermann@uha.fr

¹ IUT de Mulhouse, Université de Haute Alsace
Institut de Recherche en Informatique, Mathématiques, Automatique et Signal, UR 7499

THÈMES – *Énergie - Environnement - Informatique*

RÉSUMÉ – *L'optimisation de la consommation d'énergie est un objectif crucial pour notre société. L'une des méthodes pour y parvenir est la surveillance non-intrusive des charges électriques. Cette approche aide les utilisateurs et les systèmes de gestion à surveiller efficacement leurs réseaux électriques afin de prendre des mesures pour minimiser la consommation d'énergie. Dans ce contexte, nous avons développé un réseau neuronal hybride combinant des réseaux neuronaux convolutifs et des couches récurrentes pour la désagrégation de 11 appareils électriques les plus utilisés d'une base de données de référence. Cet apprentissage a nécessité une grande quantité de données et un temps de calcul conséquent. L'objectif de ce travail est de transférer l'apprentissage obtenu vers d'autres bases de données, limitées en termes de quantité, ce qui permet un apprentissage plus rapide. Des résultats prometteurs ont été obtenus grâce à des techniques d'affinement, indiquant l'efficacité de transfert d'apprentissage avec les réseaux de neurones pour cette tâche spécifique.*

MOTS-CLÉS – *NILM, réseaux de neurones, énergie, apprentissage par transfert.*

1 Surveillance non intrusive des charges électriques

D'après l'étude menée dans [1], un retour continu sur la consommation énergétique de chaque appareil dans un bâtiment permet d'économiser jusqu'à 23% de la consommation totale. Ainsi, la surveillance continue de la consommation des appareils électriques est un aspect qui suscite une attention particulière depuis quelques années [2].

1.1 Complexité de la désagrégation énergétique

La surveillance des charges électriques vise à mesurer la consommation électrique de chaque appareil afin d'optimiser la consommation totale. Cependant, l'installation intrusive des compteurs individuels pour chaque appareil électrique pose des défis en raison des coûts plus élevés et de la complexité de l'installation [2]. Généralement, un bâtiment ne contient qu'un compteur qui mesure la consommation totale ($P(t)$) car c'est un dispositif moins coûteux. Comme le montre l'équation 1, $P(t)$ est la somme des consommations inconnues des appareils individuels $p_i(t)$ parmi N appareils auxquelles s'ajoute une erreur de mesure $\varepsilon(t)$ [3].

$$P(t) = \sum_{i=1}^N p_i(t) + \varepsilon(t) \quad (1)$$

En considérant un compteur unique mesurant la consommation totale, inverser l'équation 1 n'est pas possible analytiquement. Donc, nous avons besoin de méthodes plus sophistiquées pour décomposer le signal total et retrouver les consommations individuelles. Ce processus est appelé la désagrégation énergétique [3].

1.2 La désagrégation énergétique par l'apprentissage machine

L'apprentissage machine est une branche de l'intelligence artificielle largement utilisée dans le domaine de la surveillance non intrusive des charges. Les réseaux neuronaux sont les modèles les plus performants pour la désagrégation des signaux énergétiques [2]. L'idée sous-jacente à l'apprentissage des réseaux neuronaux sur un ensemble de données consiste à collecter le signal principal et à installer des sous-compteurs pour recueillir les consommations électriques de chaque appareil. Après la collecte d'un ensemble de données, le réseau neuronal est entraîné dans un cadre supervisé pour décomposer le signal principal. Cependant, un inconvénient majeur concerne la collecte de données : les réseaux neuronaux nécessitent de grands ensembles de données qui exigent des durées de surveillance prolongées. Bien qu'efficace, cette technique est difficile à déployer.

2 Le transfert d'apprentissage

Le transfert d'apprentissage consiste à appliquer les connaissances acquises dans un domaine à l'amélioration de l'apprentissage dans un domaine connexe. Pour surmonter le besoin d'un vaste ensemble de données pour construire un modèle robuste, l'apprentissage par transfert devient essentiel. Cette méthode permet à un réseau de neurones d'apprendre plus efficacement en utilisant des quantités limitées de données. Le transfert de connaissances se révèle particulièrement bénéfique dans la surveillance non intrusive des charges, compte tenu de la diversité des ensembles de données qui englobent généralement différentes machines électriques. L'apprentissage par transfert permet de déployer plus rapidement une solution et réduire le temps d'apprentissage.

Dans cette étude, nous présentons une expérimentation portant sur le transfert d'apprentissage d'un réseau neuronal préalablement entraîné sur une base de données de référence vers une autre base avec une courte durée de collecte. La phase initiale d'apprentissage, qui établit les bases des connaissances à transférer, a été réalisée dans un travail précédent [3]. Dans cette phase, nous avons développé un réseau neuronal à double canal composé de couches convolutives et de couches de mémoires à long et court terme [3] entraîné sur la base de données AMPds2. Ce type de réseaux est connu pour son efficacité dans le traitement du signal.

2.1 Bases de données

Le travail présenté dans [3] repose sur un vaste ensemble de données appelé AMPds2, s'étalant sur une période de 2 ans et comprenant le suivi de 20 charges, échantillonnées à une fréquence de 1 minute. La liste des charges désagrégées est disponible dans [3]. Comme l'objectif est de transférer l'apprentissage de AMPds2 vers un ensemble de données plus petit, nous avons choisi la base de données ECO [3] qui est un ensemble de données plus restreint. Nous considérons 10 charges de l'ensemble de données ECO qui bénéficient d'un suivi plus important, à savoir : le lave-vaisselle (LV), l'extracteur d'air (EXA), le réfrigérateur (REF), la bouilloire (BIL), le congélateur (CON), la télévision (TEL), la tablette (TAB), la console (CSL), la lampe (LAM) et la stéréo (STR). Les principales différences entre les deux bases de données (AMPds2 et ECO) peuvent être résumées respectivement en : emplacement (Canada et Suisse), système de distribution (monophasé et triphasé) et période d'échantillonnage (60s et 1s) [3].

2.2 Tests et résultats

Nous avons affiné le réseau neuronal obtenu lors de la première phase en utilisant un taux d'apprentissage de 5×10^{-5} pendant 50 époques. Nous avons utilisé aléatoirement 20% de l'ensemble de données ECO pour l'affinement et un

	Modèle	LV	EXA	REF	BIL	CON	TEL	TAB	CSL	LMP	STR	Total
EMA	Transféré	6,55	1,01	7,70	6,25	5,95	5,40	1,32	8,39	9,23	3,83	5,56
	Entraîné	16,1	1,43	8,34	6,18	7,67	8,25	1,13	11,60	9,96	3,95	7,47
PD	Transféré	79,67	43,54	82,91	47,09	87,78	93,40	40,35	92,68	83,88	88,37	87,02
	Entraîné	49,77	20,08	81,48	48,48	84,27	89,83	49,20	89,88	82,60	87,99	82,58

TABLE 1 – Résultats des deux modèles sur l'ensemble de test d'ECO

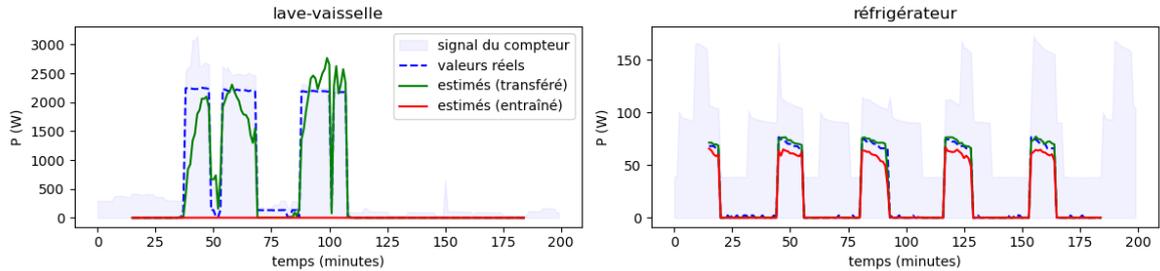


FIGURE 1 – Performance de désagrégation des deux modèles sur l'ensemble de test par rapport au signal agrégé et aux valeurs réelles

autre 20% pour les tests. Les métriques utilisés pour évaluer la correspondance des résultats avec les valeurs réelles sont l'Erreur Moyenne Absolue (EMA) et la Précision de la Désagrégation (PD) [3]. Pour valider nos résultats, nous avons entraîné un autre modèle avec la même architecture sans passer par le transfert d'apprentissage. La Table 1 présente les résultats de l'entraînement des deux modèles : le modèle appris à partir d'AMPds2 puis affiné sur ECO (transféré) et le modèle entraîné classiquement sur ECO (entraîné). Les titres des colonnes représentent les abréviations des appareils choisis, et la dernière colonne montre les résultats globaux.

Les résultats du Tableau 1 indiquent que l'affinement est plus performant que l'entraînement classique, avec une précision globale de 87,02% contre 82,58%. À l'exception de la bouilloire et de la tablette qui sont utilisées rarement, la version pré-entraînée est toujours plus performante. L'amélioration remarquable se trouve au niveau du lave-vaisselle avec environ une augmentation de +30% de précision obtenue. Cela s'explique par le fait que l'appareil du lave-vaisselle est fortement présent dans la base de données d'origine [3]. Pour les autres appareils, on trouve des améliorations variées en raisons des taux d'utilisation et des similitudes entre les appareils des deux bases de données [3]. La Figure 1 montre les désagrégations des réseaux de neurones pour des scénarios réels sur le réfrigérateur et le lave-vaisselle. Nous pouvons observer les meilleures performances du modèle affiné (transféré). Selon les résultats, nous avons confirmé que l'apprentissage par transfert est très prometteur pour une telle tâche.

3 Conclusions

En conclusion, notre travail a démontré le potentiel et l'efficacité de l'apprentissage par transfert dans le contexte de la surveillance non intrusive des charges. Nous avons commencé par entraîner un réseau de neurones avec des couches convolutives et des couches récurrentes sur l'ensemble de données AMPds2. Ensuite, nous avons transféré l'apprentissage vers l'ensemble de données ECO sur 10 appareils, surpassant tout travail antérieur, et atteint une précision de 87,02% en n'utilisant que peu de données d'ECO pour l'apprentissage. En comparaison, l'apprentissage classique avec les mêmes jeux de données a abouti à une précision de 82,53%, démontrant ainsi l'importance de l'apprentissage par transfert.

Références

- [1] Paolo Zangheri, Tiago Serrenho, and Paolo Bertoldi. Energy savings from feedback systems : A meta-studies' review. *Energies*, 12(19), 2019.
- [2] Maria Kaselimi, Eftychios Protopapadakis, Athanasios Voulodimos, Nikolaos Doulamis, and Anastasios Doulamis. Towards trustworthy energy disaggregation : A review of challenges, methods, and perspectives for non-intrusive load monitoring. *Sensors*, 22(15), 2022.
- [3] Yacine Belguermi, Patrice Wira, and Gilles Hermann. Investigating learning transferability and deployment for neural nilm strategies. In *Upper Rhine Artificial Intelligence Symposium (URAI 2023)*, Mulhouse, France, 2023.