

## SUJET DE STAGE M2 : AUTO-ENCODEURS EXPLICABLES POUR LE NILM

SAÏD LADJAL ET FRANÇOIS ROUEFF (IPP/TÉLÉCOM PARIS AVEC TOTAL)

### 1. CONTEXTE DU STAGE

Le stage se déroulera au choix du candidat dans les locaux de l'entreprise TOTAL ou bien à Télécom Paris. Il peut donner lieu à la poursuite en thèse CIFRE. La durée du stage est de 5 à six mois débutant en Avril. (SEE ENGLISH version below )

### 2. INTRODUCTION

Le NILM (pour *Non-intrusive load monitoring*) désigne toutes les techniques qui permettent de déduire, à partir de la consommation globale d'un foyer, une description précise des appareils en cours d'utilisation à chaque instant.

Ces techniques trouvent de multiples applications d'autant que la disponibilité des compteurs linky permet d'entrevoir l'accumulation d'énormes quantités de données relatives à la consommation globales de foyers.

Un exemple d'utilisation de ces techniques est le suivant : l'analyse à grande échelle de ces données (agrégées) combinées à des technique NILM peut permettre au fournisseur d'énergie de construire une prédition fiable des usages des clients et ainsi prévoir des montées en charge de ses points de production ou en au contraire des baisses de charges, lui permettant ainsi de diminuer son exposition aux risques spéculatifs du marché inter-producteurs de l'électricité.

De nombreuses méthodes ont vu le jour dans ce domaine et beaucoup utilisent déjà l'apprentissage profond ([3, 1, 5]). L'objectif de ce stage est de proposer des solutions novatrices aux problèmes du NILM et plus particulièrement dans les domaines de l'explicabilité et dans un contexte non-supervisé (signaux sources non-disponibles dans l'étape d'apprentissage).

### 3. POSITION DU PROBLÈME

La consommation instantanée d'un foyer (exprimée en watt) est désignée par la fonction  $f$  dépendant d'un temps  $t$  (le plus souvent  $t$  est discret de l'ordre d'un échantillon toutes les 5 à dix secondes). Cette consommation est la somme des consommations des différents appareils du foyer. On note  $f_i$  la consommation de l'appareil numéro  $i$ . Le but du NILM est, étant donné  $f$  retrouver les  $f_i$  tels que

$$f(t) = \sum_i f_i(t)$$

Généralement, on ne s'intéresse qu'aux indices  $i$  qui se rapportent à des appareils à grosse consommation tels qu'une machine à laver, bouilloire, lave-vaisselle. . . .

La plupart des méthodes de NILM basées sur des algorithmes d'apprentissage supposent l'existence d'une base de donnée dans laquelle des exemples de  $f$  et des  $f_i$  correspondants sont donnés. Les  $f_i$  étant disponibles pour un petit nombre de gros appareils, l'équation, plus réaliste, que doit résoudre le NILM est

$$(1) \quad f(t) = \sum_{i=1}^N f_i(t) + b(t)$$

où  $N$  est le nombre d'appareils d'intérêt et  $b$  un bruit qui comprend à la fois un bruit de mesure, mais aussi tous les appareils auxquels on ne s'intéresse pas.

#### 4. ÉTAT DE L'ART ET PISTES SCIENTIFIQUES DU STAGE

L'application de réseaux de neurones pour le NILM a déjà été mise en œuvre dans la littérature. Dans [3] les auteurs testent différentes architectures dont des auto-encodeurs, les LSTM et des "rectangles" (un mélange de détection d'activation et de régression d'activation moyenne de l'appareil durant le support temporel). Un autre exemple, plus mûr, d'application des réseaux de neurones est donné dans [4] où les auteurs utilisent une architecture d'auto-encodeur variationnel munie de connexions court-circuit (*skip connections*).

Dans la pratique ces réseaux ont beaucoup de mal à généraliser. Une part du problème réside dans le fait que les bases de données disponibles sont petites (il faut équiper un foyer et ses différents appareils de capteurs durant de longues périodes).

Pour ce stage on se propose d'investiguer la possibilité de rendre explicable des réseaux de neurone. En effet, un réseau explicable aura plus de chances de généraliser à des données non vues durant l'apprentissage.

Nous avons développé à Télécom une nouvelle forme de réseaux d'auto-encodeurs que nous appelons PCA-AE. Ils agissent en organisant l'espace latent de l'auto-encodeur dans un ordre inspiré de celui de l'ACP (PCA en anglais) [6] et voir figure 1. La première dimension est celle qui porte le plus d'informations, la suivante porte moins d'informations et est statistiquement indépendante de la première. Et ainsi de suite.

Une première approche consistera à entraîner ce type d'auto-encodeurs (de manière non supervisée) sur des données agrégées et examiner la corrélations des dimensions latentes avec les différents appareils. La non-linéarité permise par les auto-encodeur alliée à l'organisation obtenue par le PCA-AE permet d'imaginer que les premières dimensions seront reliées (automatiquement) aux appareils les plus consommateurs.

En parallèle, pour pallier au manque de données, on pourra recourir à des simulations. En particulier, en adoptant plusieurs stratégies de simulations on peut sélectionner les architectures qui arrivent à généraliser le mieux entre (entraînement sur un simulateur et test sur un autre simulateur). Là encore, le recourt à des méthodes d'explicabilité permettra de mieux comprendre les raisons de la difficulté à généraliser : est-ce que la signature d'un modèle particulier d'appareil (marque) est trop sur-apprise ? Ou bien le problème vient-il d'une confusion entre appareils différents ?

#### 5. ENGLISH VERSION : CONTEXT OF THE INTERNSHIP

The internship will take place, at the candidate's choice, on the premises of the TOTAL company or at Télécom Paris. This internship can lead to a CIFRE PhD (a PhD shared

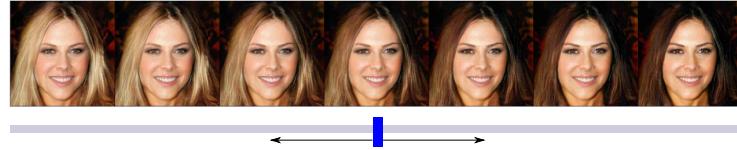


FIGURE 1. L'application du PCAAE de [6] permet de trouver automatiquement une direction dans l'espace latent d'un générateur [2] qui représente la couleur des cheveux

between academia and private company). The duration of the internship is 5 to 6 months, starting in April.

## 6. INTRODUCTION

NILM (for "non-intrusive load monitoring") refers to all the techniques that make it possible to deduce, from the overall consumption of a household, a precise description of the appliances in use at any given time.

These techniques have many applications, especially since the availability of linky meters allows us to foresee the accumulation of enormous quantities of data relating to the overall consumption of households.

An example of the use of these techniques is the following : the large-scale analysis of this data (overall consumption) combined with NILM techniques can allow the energy provider to build a reliable prediction of customer usage and thus predict increases of its production points or, on the contrary, load reductions, thus enabling the producer to reduce its exposure to the speculative risks of the inter-professional speculative market.

Numerous methods have been developed in this area and many are already using deep learning. already use deep learning ([3, 1, 5]). The aim of this internship is to propose innovative solutions to the problems of NILM and more particularly in the fields of explainability in an unsupervised context (source signals not available in the learning stage)

## 7. PROBLEM STATEMENT

The instantaneous consumption of a household (expressed in watts) is designated by the function  $f$  depending on a time  $t$  (most often  $t$  is discrete, with sampling rate of the order of 5 to 10 seconds). This consumption is the sum of the consumption of the different appliances in the household. We note  $f_i$  the consumption of appliance number  $i$ . The aim of NILM is, given  $f$ , to find the  $f_i$  such that

$$f(t) = \sum_i f_i(t)$$

Generally, one is only interested in  $i$  indices that relate to high consumption appliances such as a washing machine, kettle, dishwasher, etc.

Most NILM methods based on learning algorithms assume the existence of a database in which examples of  $f$  and the corresponding  $f_i$  are given. Since the  $f_i$  are available for

a small number of large devices, the more realistic equation that NILM must solve is

$$(2) \quad f(t) = \sum_{i=1}^N f_i(t) + b(t)$$

where  $N$  is the number of devices of interest and  $b$  is a noise that includes both measurement noise and all the devices we are not interested in.

## 8. STATE OF THE ART AND IDEAS TO TACKLE THE PROBLEM

The application of neural networks for NILM has already been demonstrated in the literature. In [3] the authors test different architectures including auto-encoders, LSTMs and "rectangles" (a mixture of activation detection and regression of the average activation of the device during the time). Another, more mature, example of the application of neural networks is given in [4] where the authors use a architecture of variational auto-encoder with skip-connections.

In practice, these networks have a lot of difficulty to generalize. One part of the problem is that the available databases are small (it is necessary to equip a household and its various devices with sensors for long periods).

For this internship we propose to investigate the possibility of making neural networks explainable. Indeed, an explicable network will have more chances to generalize to data not seen during training.

At Télécom we have developed a new form of auto-encoder networks which we call PCA-AE. They operate by organising the latent space of the auto-encoder in an order inspired by that of the PCA (see figure). The first dimension carries the most information, the next carries less information and is statistically independent of the first. And so on.

A first approach would be to train such autoencoders (in an unsupervised way) on aggregate data and examine the correlations of the latent dimensions with the different devices. The non-linearity allowed by the auto-encoders combined with the organisation obtained by the PCA-AE allows us to imagine that the first dimensions will be linked (automatically) to the most consuming devices.

In parallel, to overcome the lack of data, simulations can be used. In particular, by adopting several simulation strategies, it is possible to select the architectures that best generalise between (training on one simulator and testing on another). Here again, the use of explainability methods will allow a better understanding of the reasons for the difficulty in generalising : is the signature of a particular aircraft model (brand) too over-learned ? Or does the problem stem from confusion between different devices ?

## RÉFÉRENCES

- [1] Roberto Bonfigli, Andrea Felicetti, Emanuele Principi, Marco Fagiani, Stefano Squartini, and Francesco Piazza. Denoising autoencoders for non-intrusive load monitoring : Improvements and comparative evaluation. *Energy and Buildings*, 158 :1461–1474, 2018. ISSN 0378-7788. doi : <https://doi.org/10.1016/j.enbuild.2017.11.054>. URL <https://www.sciencedirect.com/science/article/pii/S0378778817314457>.
- [2] Tero Karras, Timo Aila, Samuli Laine, and Jaakko Lehtinen. Progressive growing of gans for improved quality, stability, and variation. In *International Conference on Learning Representations*, 2018.

- [3] Jack Kelly and William Knottenbelt. Neural nilm : Deep neural networks applied to energy disaggregation. In *Proceedings of the 2nd ACM International Conference on Embedded Systems for Energy-Efficient Built Environments*, BuildSys '15, page 55–64, New York, NY, USA, 2015. Association for Computing Machinery. ISBN 9781450339810. doi : 10.1145/2821650.2821672. URL <https://doi.org/10.1145/2821650.2821672>.
- [4] Antoine Langevin, Marc-André Carbonneau, Mohamed Cheriet, and Ghyslain Gagnon. Energy disaggregation using variational autoencoders, 2021.
- [5] David Murray, Lina Stankovic, and Vladimir Stankovic. Explainable nilm networks. In *Proceedings of the 5th International Workshop on Non-Intrusive Load Monitoring*, NILM'20, page 64–69, New York, NY, USA, 2020. Association for Computing Machinery. ISBN 9781450381918. doi : 10.1145/3427771.3427855. URL <https://doi.org/10.1145/3427771.3427855>.
- [6] Chi-Hieu Pham, Saïd Ladjal, and Alasdair Newson. PCAAE : principal component analysis autoencoder for organising the latent space of generative networks. *CoRR, to appear in JMIV*, abs/2006.07827, 2020. URL <https://arxiv.org/abs/2006.07827>.