

# APPLICATION DES RESEAUX BAYESIENS DANS LA PREVISION DE LA CONSOMMATION ELECTRIQUE DES APPAREILS ELECTROMENAGERS

Kaoula Ghribi<sup>1</sup>, Dhafer Malouche<sup>3</sup>, Javier Gil-Quijano<sup>2</sup>, Sylvie Sevestre Ghalila<sup>4</sup> & Zahia Guessoum<sup>5</sup>

<sup>1</sup> CEA, LIST, Laboratoire d'Analyse de Données et Intelligence des Systèmes, 91400 Gif-sur-Yvette, FRANCE

Mail : [Kaoula.GHRIBI@cea.fr](mailto:Kaoula.GHRIBI@cea.fr)

<sup>2</sup> CEA, DRT, DPACA, 13108 Saint Paul Lez Durance, FRANCE

Mail : [Jesus-Javier.GILOQUIJANO@cea.fr](mailto:Jesus-Javier.GILOQUIJANO@cea.fr)

<sup>3</sup> U2S, ENIT, 1002 Tunis, TUNISIE

Mail : [dhafer.malouche@me.com](mailto:dhafer.malouche@me.com)

<sup>4</sup> CEA, LinkLab, 2083 Ariana, TUNISIE

Mail : [Sylvie.SEVESTRE-GHALILA@cea.fr](mailto:Sylvie.SEVESTRE-GHALILA@cea.fr)

<sup>5</sup> LIP6, UPMC, 75015 Paris, FRANCE

Mail : [zahia.guessoum@lip6.fr](mailto:zahia.guessoum@lip6.fr)

**Résumé.** Dans cet article, on s'intéresse à la prévision à court terme de la consommation électrique des appareils électroménagers, précisément à l'approximation de la quantité d'électricité consommée par chaque appareil dans un horizon temporel de quelques heures.

On propose un modèle de prévision basé sur la modélisation graphique et qui exploite en plus de l'historique des activités des appareils électroménagers, les interdépendances entre les utilisations de ces appareils et la nature du comportement des habitants.

Les résultats du test du modèle proposé ont montré une coïncidence significative entre la prévision et la réalité : un taux de bon classement de l'ordre de 90%, ce que nous permet de qualifier le modèle proposé par prometteur.

**Mots-clés.** Prévision, consommation électrique, appareils électroménagers, réseaux bayésiens, inférence, inter-interdépendances.

**Abstract.** In this paper, we deal with the short term prediction of the power consumption of domestic appliances. We go further than the prediction of on/off activities of appliances to the prediction of a bounded interval of consumed power. The short term prediction of appliances consumptions is an unavoidable problem to solve when constructing optimal schedules of appliances' consumptions. For reliable predictions, the appliances inter-dependencies and the cyclic characteristic of appliances activities should definitely be considered. Short term prediction is performed in the current work using graphical modeling dependencies between appliances in a particular period of time. Obtained dependencies and short time history of appliances states are then used to infer future appliances states. We demonstrate through testing on real-world data that our model provides a promising result, nearly 90% of correct rate of classification.

**Keywords.** Prediction, home appliances power consumption, bayesian network, inference, inter-dependencies.

## 1 Introduction

Un des plus grands défis de ce siècle est de faire face au problème de l'émission des gaz à effet de serre et son influence sur le changement climatique. Ce problème peut être atténué considérablement en ralentissant la croissance continue de la demande en électricité et en introduisant à grande échelle des sources d'énergie renouvelables. On s'intéresse dans cet article à l'efficacité de la demande en électricité dans la maison.

L'augmentation de l'efficacité de la demande en électricité dans la maison revient à augmenter l'efficacité de l'utilisation des appareils électriques domestiques.

L'augmentation de l'efficacité d'utilisation des appareils électriques consiste à chercher une

configuration réalisable qui minimise la quantité d'électricité consommée dans un horizon temporel prédéfini en respectant le confort de l'habitant: les plannings de consommation.

Le problème de construction des plannings optimaux de consommation a été traité dans plusieurs travaux [1-2]. Ce problème est toujours associé à une prévision des prix futurs d'électricité et de la consommation future des appareils électroménagers. On s'intéresse, dans cet article, à l'application de la modélisation graphique dans la prévision « directe » de la consommation électrique des appareils électroménagers.

La prévision de la consommation des appareils électroménagers a été peu abordée directement: la plupart des travaux existants prévoient les activités On/Off des appareils et approximativement par la suite, en multipliant par la valeur moyenne de la consommation de chaque appareil, les quantités d'électricité consommées.

La prévision des consommations des appareils électroménagers dans la maison est fortement liée aux comportements de l'habitant de la maison. Pour cela, plusieurs travaux dans la littérature ont abordé la prévision des activités des appareils électriques en la couplant aux résultats de la localisation de l'habitant [3]. Cette méthode est prouvée d'être peu efficace en présence de plusieurs habitants.

D'autres travaux lient la prévision des activités des appareils à la recherche des interdépendances entre les utilisations de ces appareils. Parmi les approches utilisées pour la recherche de ces interdépendances, on trouve les règles des associations [4-5] et la modélisation graphique.

Les chaînes de Markov et les réseaux bayésiens sont deux familles de modèles graphiques qui ont été utilisées dans [6-7] pour modéliser les interdépendances entre les activités des appareils électroménagers. Aucun de ces travaux n'a comme objectif la prévision des quantités d'énergie consommées individuellement par les appareils électriques.

Les auteurs de [6] visent la désagrégation de la consommation totale de la maison en des consommations individuelles des appareils, alors que les auteurs de [7] cherchent à prévoir les activités des appareils électroménagers et non pas les quantités d'énergie.

Dans le présent travail, on vise dans un premier temps, la modélisation par des réseaux bayésiens des interdépendances temporelles entre les utilisations des appareils électroménagers et leurs dépendances avec les données de la météo et dans un deuxième temps à l'exploitation des méthodes exactes de calcul probabiliste dans la prévision des consommations individuelles des appareils électroménagers dans un horizon de temps de 6 heures.

Le reste de l'article est organisé comme suit: On détaille les prétraitements effectués sur les données dans la section 2 puis on formalise notre problème et on présente notre modèle de prévision dans la section 3. Une description théorique de l'algorithme de prévision est donnée dans la section 4. Nos résultats sont présentés dans la section 5.

## **2 Prétraitement des données**

Notre travail a été effectué sur une base de données réelles: la base de données Smart\* [8], qui est un ensemble d'enregistrements temporelles des consommations électriques des appareils électroménagers collectées à partir d'une installation de 'monitoring' électrique déployée à l'université de Massachusetts, en plus des données environnementales d'une station météo proche.

Le nombre d'appareils 'surveillé' dans cette installation est de l'ordre d'une trentaine. On considère uniquement la température et l'humidité comme des données environnementales.

La fréquence d'utilisation et la variabilité des niveaux d'énergie varient considérablement d'un appareil à un autre dans la base de données initiale (Fig. 1).

Afin d'homogénéiser la représentation des variables mises en jeu dans l'estimation de notre réseau bayésien et pour des raisons méthodologiques, on transforme les données de la base de données

<sup>1</sup>Une structure chordale est un réseau bayésien sans V-structure.

smart\* en des données catégoriques en les discrétisant par quintile.

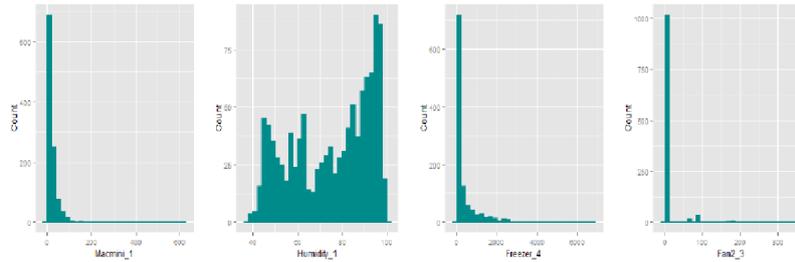


Fig. 1 : Exemple des histogrammes des appareils électriques de la base de données initiale

Puisque notre objectif est de prévoir les consommations électriques dans un horizon de temps de 6 heures, on divise les enregistrements journaliers de chaque appareil en quatre ensembles qui correspondent aux quatre plages horaires de la journée: 00h-6h, 6h-12h, 12h-18h, 18h-00h. De cette manière, chaque consommation d'un appareil X pendant une journée  $d$  sera représentée par quatre variables qui correspondent à des plages horaires différentes.

### 3 Formalisation du problème

Etant donné, qu'il a été prouvé que le comportement humain dans la maison est cyclique à l'échelle hebdomadaire [9], les activités de la consommation électrique sont par conséquent cycliques à la même échelle temporelle. De ce fait, et afin de traduire cette cyclicité dans notre modèle de prévision, on estime par apprentissage pour chaque semaine un réseau bayésien qui modélise les dépendances et indépendances entre les variables de la même semaine.

Un réseau bayésien est une structure orientée acyclique paramétrée par les probabilités de différentes configurations possibles et caractérisée par une propriété qui relie la distribution multi-variée aux distributions uni-variées (conditionnelles).

Il existe deux grandes familles d'approches pour l'apprentissage de la structure du réseau bayésien : les approches basées sur les contraintes et les approches basées sur la maximisation d'un score [10-11]. On combine dans notre travail les deux approches en intégrant dans la structure apprise les arêtes les plus fiables des deux approches.

L'apprentissage des paramètres de la structure dans le cas où les variables sont discrètes consiste à un calcul des probabilités conditionnelles des différentes combinaisons possibles qui peuvent être prises par une variable et ses parents dans la structure.

Pour prévoir la consommation électrique d'un appareil X dans la  $i^{\text{ème}}$  plage horaire de la journée d'une semaine  $n$ , on se base sur le réseau bayésien caractérisant la semaine  $n-1$  et l'historique proche de la consommation de tous les appareils de la maison (les observations de la  $(i-1)^{\text{ème}}$  plage horaire de la journée) et on applique les algorithmes de révision des croyances (*Belief Update*) [12].

La révision des croyances consiste à entrer comme « évidence » dans le réseau bayésien les observations de la  $(i-1)^{\text{ème}}$  plage horaire de la journée et de recalculer les probabilités des différentes combinaisons possibles (voir section suivante).

### 4 Outils théoriques: Belief Update

Un réseau bayésien sur un ensemble fini de variables aléatoires  $X$  est un modèle graphique caractérisé par une propriété qui relie la distribution multi-variée aux distributions uni-variées.

Dans cet article, on s'intéresse qu'à des variables catégoriques, dans ce cas la distribution conditionnelle de chaque variable est décrite par un tableau contenant les probabilités des configurations possibles.

La prévision par le moyen des réseaux bayésiens consiste à réaliser des inférences bayésiennes pour déduire l'état d'une variable non observée dans le présent (variable de réponse) à partir d'un

<sup>1</sup>Une structure chordale est un réseau bayésien sans V-structure.

ensemble des variables observées avant ou à l'instant de la prévision, en exploitant les indépendances conditionnelles modélisées dans la structure bayésienne.

Déduire l'état d'une variable revient à calculer les probabilités de tous les états que cette variable peut prendre et déterminer l'état ayant la plus grande probabilité de réalisation.

La prévision se déroule en deux étapes: l'insertion des évidences (états de variables observées) dans le réseau bayésien et la propagation de l'effet de ces évidences sur le reste des variables et en particulier sur la variable de réponse.

L'algorithme de propagation consiste à échanger des messages entre les nœuds adjacents de la structure du réseau bayésien afin de mettre à jour les tableaux de probabilités.

Ci-dessous la description de cet algorithme selon Cowell et al dans [13].

L'efficacité de l'algorithme de propagation dépend principalement de la structure sur laquelle l'algorithme est exécuté. Intuitivement, la structure requise doit être modulaire. Les auteurs de [20] confirment que la structure optimale en termes de complexité de calcul pour la réalisation des inférences exactes est la structure arbre de jonction.

#### 4.1 Compilation du graphe initiale en arbre de jonction

La compilation de la structure initiale du réseau bayésien estimé auparavant consiste à la transformer en une nouvelle structure plus adaptée à l'application des échanges de messages entre les nœuds. Elle se déroule en deux étapes : la moralisation et la triangulation. La moralisation transforme le graphe initial en un graphe non orienté en joignant les nœuds ayant des fils en commun dans le graphe initial et en supprimant les directions des arêtes.

Un nouveau graphe de dépendance est obtenu après la moralisation. Chaque clique du nouveau graphe est associée à une fonction à valeurs dans  $\mathbb{R}$  appelée potentiel. Le potentiel est le produit des distributions conditionnelles de tous les nœuds formant la clique.

La triangulation (autrement le fill-In) consiste à ajouter des arêtes entre les nœuds du graphe moralisé afin d'obtenir une structure chordale<sup>1</sup>.

Trouver la triangulation optimale est un problème non déterministe. En conséquence, la seule façon de trianguler un graphe moralisé est d'utiliser des heuristiques.

Après la triangulation, on n'est plus intéressé par les nœuds du graphe, mais par ses cliques. La triangulation peut conduire à des cliques sans potentiel associé. Pour chacun de ces cliques on associe un potentiel égal à 1. La distribution multi variée du graphe obtenu s'écrit sous la forme suivante :

$$p(X_{IV}) = \prod_{j=1}^T \psi_{C_j}(X_{ic_j})$$

Avec  $X_V$  l'ensemble des variables aléatoires du modèle,  $\psi_{C_j}(X_{ic_j})$  est le potentiel de la clique  $C_j$  et  $T$  est le nombre de cliques dans le graphe triangulé.

L'arbre de jonction est un arbre avec la propriété suivante: pour chaque paire de cliques  $A$  et  $B$  avec une intersection  $S$ , Tous les chemins entre  $A$  et  $B$  contiennent  $S$  [14].

La construction de l'arbre de jonction sur les cliques d'un graphe triangulé consiste à :

- La construction d'un arbre couvrant de poids maximal (le poids dans ce cas est le nombre de variables de l'intersection des cliques adjacentes).
- Etiqueter les arêtes de l'arbre obtenu: chaque arête liant deux cliques est marquée par leur intersection (l'ensemble de séparation).
- Associer à chaque ensemble de séparation un potentiel égal à 1.
- Associer à chaque clique du graphe obtenu son potentiel qui a été calculé dans l'étape

<sup>1</sup>Une structure chordale est un réseau bayésien sans V-structure.

triangulation.

## 4.2 Algorithme de propagation

L'algorithme de propagation est un algorithme itératif d'échange des messages entre nœuds adjacents d'un graphe. Son application sur la structure arbre de jonction converge vers un point où les potentiels des nœuds de l'arbre, qui étaient initialement les cliques du graphe triangulé, deviennent égaux aux distributions marginales des nœuds formant ces cliques.

Le nombre de messages envoyés avant d'atteindre cet équilibre est un paramètre à optimiser.

Entre deux nœuds adjacents de l'arbre de jonction la propagation de la mise à jour se déroule comme suit:

Soient A et B deux nœuds de l'arbre,  $\psi(A)$  et  $\psi(B)$  sont les deux potentiels associés respectivement aux nœuds A et B. A et B sont séparés dans l'arbre de jonction par leur intersection S qui a un potentiel  $\psi(S)$  (voir Fig. 2).

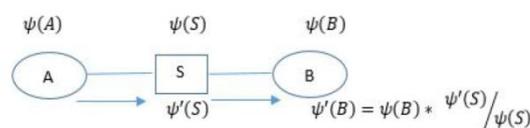


Fig. 2 : Le passage de messages entre les nœuds adjacents de l'arbre de jonction

A chaque fois qu'une mise à jour est détectée dans A.

1.  $\psi(A)$  est réévalué et envoyé à S.
2. Une nouvelle valeur de  $\psi'(S)$  est calculée en marginalisant la nouvelle  $\psi(A)$  sur les nœuds formant S et envoyé à B.
3. Une nouvelle valeur de  $\psi(B)$  est calculée en multipliant l'ancienne valeur de  $\psi(B)$  par le rapport  $\psi'(S)/\psi(S)$ .

A chaque modification des tableaux de probabilités du graphe initial, suite à des nouvelles observations, l'algorithme de propagation déclenche la recherche du nœud mis à jour dans l'arbre de jonction correspond avant de propager l'information comme expliqué ci-dessus.

## 5 Résultats

En appliquant l'algorithme de propagation des mises à jour des probabilités sur notre réseau bayésien (Fig. 3), on remarque une coïncidence significative entre les valeurs prédites et les valeurs réelles.

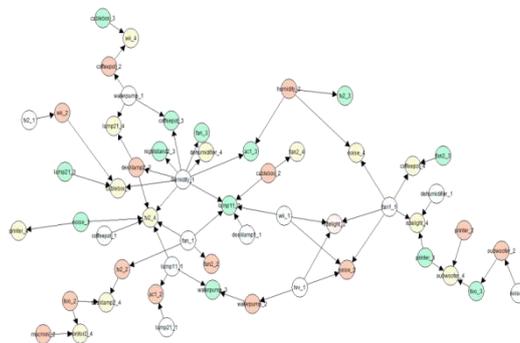


Fig. 3 : Exemple d'un réseau bayésien modélisant les dépendances entre les usages des appareils électroménagers

Ci-dessous quelques tableaux de contingence dénombrant l'effectif correspond aux croisements des

<sup>1</sup>Une structure chordale est un réseau bayésien sans V-structure.

états prédit et réel (i.e. les intervalles d'énergie consommée prédits et réels) pour un ensemble de variables (appareils électriques/plages horaires).

Prediction		prediction	
0	0	0	0
(0,66]	1	(0,2]	4
0	47	(2,3]	7
[1]	"lamp11_1"	(3,4]	1
[1]	0.9791667	(4,26]	12
		0	24
		[1]	"nightstand2_3"
		[1]	0.5
prediction			
	(1.3e+03,6.48e+03]	(6.48e+03,8.06e+03]	
(1.3e+03,6.48e+03]	5	4	
(6.48e+03,8.06e+03]	6	7	
(8.06e+03,9.1e+03]	4	8	
(9.1e+03,1.67e+04]	5	9	
[0,1.3e+03]	0	0	
[1]	"dehumidifier_4"		
[1]	0.25		

Fig. 4. Exemple des tableaux de contingence

On remarque que le taux de bon classement varie en fonction du nombre de catégories prises par les variables : ce taux est nettement faible lorsque les variables prennent plusieurs catégories. Le taux total de bon classement est proche de 90%, ce qui nous permet de décrire notre modèle par prometteur. La discrétisation de variables simplifie beaucoup le processus de la propagation des mises à jour, mais elle contribue, en parallèle, à une perte de précision. L'objectif de notre prochain travail est d'intégrer dans notre modèle de prévision des variables continues.

## Bibliographie

- [1] A. Mishra, D. Irwin, P. Shenoy, J. Kurose, T. Zhu, SmartCharge: cutting the electricity bill in smart homes with energy storage in e-Energy '12 Proceedings of the 3rd International Conference on Future Energy Systems.
- [2] P. Du, N. Lu, Appliance Commitment for Household Load Scheduling in Smart Grid, IEEE Transactions on (Volume: 2 , Issue: 2 ), May 2011.
- [3] J. Gil-Quijano, N. Sabouret, Prediction of humans' activity for learning the behaviors of electrical appliances in an intelligent ambient environment in International Conference on Web Intelligence and Intelligent Agent Technology, 2010.
- [4] S. Rollins, N. Banerjee, Using rule mining to understand appliance energy consumption patterns in IEEE International Conference on Pervasive Computing and Communications (PerCom), 2014.
- [5] Y.C. Chen , W.C. Peng ; W.C Lee, A novel system for extracting useful correlation in smart home environment in 13th International Conference on Data Mining Workshops (ICDMW), 2013.
- [6] Academia Sinica, Patent US20110307200, Recognizing multiple appliance operating states using circuit level electrical information, December 2011.
- [7] N.C. Truaong, L. Tran-Thanh, E. Costanza, S.D. Ramchurn, Activity Prediction for Agent-based Home Energy Management in Agent Technologies for Energy Systems (ATES), May 2013.
- [8] S. Barker, A. Mishra, D. Irwin, E. Cecchet, P. Shenoy, and J. Albrecht. Smart\*: An Open Data Set and Tools for Enabling Research in Sustainable Homes. In SustKDD, August 2012.
- [9] M.C. Gonzalez, C.A. Hidalgo, A.L. Barabasi, Understanding individual human mobility patterns in Nature, June 2008.
- [10] P. Spirtes, c. Glymour, R. Scheines, Causation, Prediction and Search in the MIT Press, 2000.
- [11] D. Chikering, Optimal Structure Identification with Greedy Search in Journal of Machine Learning Search, 2002.
- [12] S. L. Lauritzen, D.J. Spiegelhalter, Local Computations with Probabilities on Graphical Structures and their application to Expert Systems in Journal of the Royal Statistical Society, 1988.
- [13] F.V. Jensen , F. Jensen, Optimal Junction tree in UAI'94 Proceedings of the Tenth international conference on Uncertainty in artificial intelligence, 1994.
- [14] R.G Cowell, P. Dawid, S.L Lauritzen, D.J. Spiegelhalter, Probabilistic Networks and Expert Systems: Exact Computational Methods for Bayesian Networks, Springer, 1999.

<sup>1</sup>Une structure chordale est un réseau bayésien sans V-structure.