



Université Claude Bernard



Lyon 1

DIPLÔME NATIONAL DE DOCTORAT

(Arrêté du 25 mai 2016)

Date de la soutenance : **09 septembre 2021**

Nom de famille et prénom de l'auteur : **Madame LABIADH Mouna**

Titre de la thèse : *Méthodologie de construction de modèles adaptatifs de simulation de la consommation énergétique des bâtiments*

Résumé



La modélisation prédictive au sein des bâtiments est essentielle pour le contrôle intelligent, la coordination et la planification efficaces des réseaux d'énergie. L'un des moyens de modélisation prédictive utilise l'apprentissage automatique [1,2]. En plus de leur bonne performance, ces approches sont rapides et permettent une intégration facile du bâtiment dans des environnements intelligents [3]. Cependant, un modèle d'apprentissage précis s'appuie essentiellement sur la disponibilité des données historiques en quantité suffisante, notamment quand l'apprentissage profond est utilisé [4,5,6].

Dans le domaine d'énergie des bâtiments, les données historiques ne sont pas disponibles pour l'entraînement, notamment dans le cas des bâtiments nouvellement construits et nouvellement rénovés. Avec les améliorations de leur efficacité énergétique, la modélisation prédictive de leur consommation énergétique ne peut plus être basée sur leurs données historiques. En outre, il est fréquent d'évaluer l'efficacité énergétique des bâtiments avant leur construction ou rénovation. Dans de tels cas, on dispose uniquement d'une description contextuelle du bâtiment futur et de sa conception.

Cette thèse s'intéresse à la tâche de modélisation prédictive de la consommation énergétique des bâtiments quand aucune donnée historique n'est disponible. Pour cela, des données collectées à partir de plusieurs différents bâtiments sources sont exploitées. Ceci est de plus en plus pertinent compte tenu la croissance des initiatives de données ouvertes dans plusieurs secteurs, dont celui de l'énergie des bâtiments.

Ainsi, l'idée est de transférer la connaissance entre les modèles de bâtiments. Peu de travaux de recherche sont menés à l'intersection des domaines de modélisation de l'énergie des bâtiments et le transfert d'apprentissage. Le traitement de données multi-sources constitue un défi majeur, vu l'écart de concept qui peut exister entre les différentes sources et aussi entre chaque source et cible [7]. Par conséquent, les modèles entraînés sur des données combinées de sources distinctes, peuvent interférer l'un avec l'autre durant l'entraînement et donc généraliser mal lorsqu'ils sont appliqués à des *nouveaux* domaines cibles *non vus au préalable* [8,9]. Ce phénomène est dénommé le transfert négatif [10]. Plus précisément, dans le contexte de la modélisation de l'énergétique des bâtiments, la consommation dépend fortement de certains facteurs contextuels, comme la typologie du bâtiment (résidentiel, industriel ou commercial), la forme et l'âge [11]. Combiner des données énergétiques provenant de bâtiments sources distincts est donc contre-productif et impactera négativement la performance cible dans le bâtiment cible.

Les approches proposées pour lever les défis susmentionnés relèvent du domaine de transfert d'apprentissage, et plus précisément de ces deux sous-domaines: *adaptation de domaine*, et *généralisation de domaine*. L'adaptation de domaine [12,13] utilise des données sources étiquetées, et des données cibles peu étiquetées ou non étiquetées, afin de construire un modèle précis pour le domaine cible. La généralisation de domaine [14,15] n'a pas besoin de données dans le domaine cible, et utilise plusieurs domaines sources.

Ce travail se situe quelque part entre les deux domaines d'adaptation multi-source de domaine et de généralisation de domaine. L'idée principale est de construire des modèles prédictifs précis qui donnent de bons résultats sur des *nouveaux* domaines cibles *non vus au préalable*. Ceci à travers la *recommandation des domaines sources*.

Ainsi, une méthodologie adaptative aux requêtes des utilisateurs est développée pour la modélisation prédictive entre bâtiments. Le premier processus est responsable de la recommandation de données d'apprentissage pertinentes vis-à-vis un bâtiment cible, seulement en utilisant une description contextuelle minimale sur ce dernier (métadonnées). La description contextuelle est modélisée en tant que requête utilisateur.

Conventionnellement, les mesures de similarité qui sont utilisées pour la sélection de domaines sources sont basées sur le calcul de la divergence entre la distribution des données provenant du domaine source et les données provenant du domaine cible [16,17,18]. Cependant, ceci ne convient pas à notre cas à cause de l'*indisponibilité* de données dans le domaine cible durant l'entraînement.

Pour cela, notre premier processus vise à apprendre un espace de représentations, dans lequel la recommandation de bâtiments sources est faite en calculant la distance entre leurs représentations apprises de leurs métadonnées. Ainsi, l'apprentissage profond de métrique de similarité est utilisé, pour que les métadonnées des bâtiments similaires avec des profils de consommation énergétique similaires sont projetés proches l'un de l'autre, et les métadonnées des bâtiments dissimilaires sont projetés loin l'un de l'autre. L'apprentissage de similarité est réalisé en utilisant un réseau Siamese [19,20].

En d'autres termes, la similarité entre les représentations de bâtiments doit refléter la similarité entre leurs données de consommation énergétique, en utilisant *uniquement* leurs métadonnées pour la calculer en phase d'inférence. L'apprentissage de similarité a été proposé dans le contexte d'adaptation de domaine [21]. Cependant, il suppose que des données non supervisées du domaine cible sont accessibles durant l'entraînement. La sélection de domaines sources par utilisation des métadonnées du domaine cible, plutôt que ses données, reste à explorer.

Le second processus est responsable de l'entraînement de modèles prédictifs de la consommation énergétique du bâtiment cible, en utilisant les données d'apprentissage recommandées par le processus précédent. Plusieurs algorithmes ont été proposés dans ce contexte [22,23,24], à savoir les réseaux de neurones artificiels [25,26] et les machines à vecteurs de support (ou séparateurs à vaste marge) [27,28]. Conventionnellement, la modélisation énergétique prédictive requiert *plusieurs mois à plusieurs années* de données sur le bâtiment cible à modéliser, notamment les données historiques de consommation énergétique, les données météorologiques et les données d'occupation, pour pouvoir construire un modèle prédictif précis. Un modèle prédictif est donc entraîné et évalué sur le même bâtiment. Notre approche va au-delà de telles méthodes, et propose de transférer l'apprentissage à travers les bâtiments similaires.

Discutablement, il n'y a pas un seul modèle ou algorithme qui donne les meilleurs résultats indépendamment du cas de test. Cela s'explique par le théorème de "*No Free Lunch*" (se traduit par "pas de déjeuner gratuit") [29]. Ainsi, un framework d'apprentissage ensembliste est utilisé dans le second processus proposé. Ceci permet de combiner les prédictions de plusieurs algorithmes d'apprentissage. L'apprentissage ensembliste assure généralement de meilleurs résultats en comparant avec un seul modèle contributif.

L'implémentation de la méthodologie est basée sur les *microservices*. Les processus *indépendants* sont, par conséquent, modélisés en tant que microservices à but unique et à source de données séparée. Dans le contexte de ce travail, les données relatives à la consommation énergétique sont collectées depuis de nombreuses sources de données différentes, comme les données ouvertes ou les résultats de simulation. Pour l'intégration efficace de ces données, une vue globale unifiée est utilisée. Notamment, les métadonnées des bâtiments (leurs descriptions contextuelles) sont intégrées à travers les ontologies. On étend dans ce but l'ontologie ThinkHome [30] pour décrire la conception des bâtiments, leurs paramètres thermo-physiques, et contenir des informations sur leur occupation. Les séries temporelles historiques sont, quant à elles, intégrées dans des dépôts de données spécifiques, et référencées à leur bâtiment correspondant depuis la vue unifiée de métadonnées.

Les évaluations expérimentales de la méthodologie valident son efficacité et son applicabilité à la tâche de modélisation énergétique des bâtiments. Pour la modélisation prédictive des bâtiments, plusieurs algorithmes d'apprentissage sont évalués et combinés, notamment les machines à vecteurs de support (SVM), le Perceptron multicouche (MLP), les réseaux de neurones

convolutionnels (CNN), les réseaux de neurones récurrents (RNN) (notamment en utilisant le mécanisme d'attention), et une combinaison du CNN et du RNN.

En outre, vu le caractère générique de sa conception, la méthodologie proposée peut être réutilisée dans d'autres applications dans divers secteurs.

Références

- [1] Seyedzadeh, S., Rahimian, F. P., Glesk, I., & Roper, M. (2018). Machine learning for estimation of building energy consumption and performance: a review. *Visualization in Engineering*, 6(1), 1-20.
- [2] Bourdeau, M., qiang Zhai, X., Nefzaoui, E., Guo, X., & Chatellier, P. (2019). Modeling and forecasting building energy consumption: A review of data-driven techniques. *Sustainable Cities and Society*, 48, 101533.
- [3] Apanaviciene, R., Vanagas, A., & Fokaides, P. A. (2020). Smart building integration into a smart city (SBISC): Development of a new evaluation framework. *Energies*, 13(9), 2190.
- [4] Runge, J., & Zmeureanu, R. (2019). Forecasting energy use in buildings using artificial neural networks: A review. *Energies*, 12(17), 3254.
- [5] Li, C., Ding, Z., Zhao, D., Yi, J., & Zhang, G. (2017). Building energy consumption prediction: An extreme deep learning approach. *Energies*, 10(10), 1525.
- [6] Mocanu, E., Nguyen, P. H., Gibescu, M., & Kling, W. L. (2016). Deep learning for estimating building energy consumption. *Sustainable Energy, Grids and Networks*, 6, 91-99.
- [7] Storkey, A. J., & Sugiyama, M. (2007). Mixture regression for covariate shift. *Advances in neural information processing systems*, 19, 1337.
- [8] Zhao, S., Li, B., Xu, P., & Keutzer, K. (2020). Multi-source domain adaptation in the deep learning era: A systematic survey. *arXiv preprint arXiv:2002.12169*.
- [9] Riemer, M., Cases, I., Ajemian, R., Liu, M., Rish, I., Tu, Y., & Tesauro, G. (2018). Learning to learn without forgetting by maximizing transfer and minimizing interference. *arXiv preprint arXiv:1810.11910*.
- [10] Wang, Z., Dai, Z., Póczos, B., & Carbonell, J. (2019). Characterizing and avoiding negative transfer. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 11293-11302).
- [11] Won, C., No, S., & Alhadidi, Q. (2019). Factors affecting energy performance of large-scale office buildings: Analysis of benchmarking data from New York City and Chicago. *Energies*, 12(24), 4783.
- [12] Bousmalis, K., Trigeorgis, G., Silberman, N., Krishnan, D., & Erhan, D. (2016). Domain separation networks. *Advances in neural information processing systems*, 29, 343-351.
- [13] Rozantsev, A., Salzmann, M., & Fua, P. (2018). Beyond sharing weights for deep domain adaptation. *IEEE transactions on pattern analysis and machine intelligence*, 41(4), 801-814.

- [14] Blanchard, G., Lee, G., & Scott, C. (2011). Generalizing from several related classification tasks to a new unlabeled sample. *Advances in neural information processing systems*, 24, 2178-2186.
- [15] Muandet, K., Balduzzi, D., & Schölkopf, B. (2013, February). Domain generalization via invariant feature representation. In *International Conference on Machine Learning* (pp. 10-18). PMLR.
- [16] Duan, L., Xu, D., & Chang, S. F. (2012, June). Exploiting web images for event recognition in consumer videos: A multiple source domain adaptation approach. In *2012 IEEE Conference on computer vision and pattern recognition* (pp. 1338-1345). IEEE.
- [17] Chattopadhyay, R., Sun, Q., Fan, W., Davidson, I., Panchanathan, S., & Ye, J. (2012). Multisource domain adaptation and its application to early detection of fatigue. *ACM Transactions on Knowledge Discovery from Data (TKDD)*, 6(4), 1-26.
- [18] Ruder, S., Ghaffari, P., & Breslin, J. G. (2017). Data selection strategies for multi-domain sentiment analysis. *arXiv preprint arXiv:1702.02426*.
- [19] Bromley, J., Bentz, J. W., Bottou, L., Guyon, I., LeCun, Y., Moore, C., ... & Shah, R. (1993). Signature verification using a "siamese" time delay neural network. *International Journal of Pattern Recognition and Artificial Intelligence*, 7(04), 669-688.
- [20] Melekhov, I., Kannala, J., & Rahtu, E. (2016, December). Siamese network features for image matching. In *2016 23rd International Conference on Pattern Recognition (ICPR)* (pp. 378-383). IEEE.
- [21] Pinheiro, P. O. (2018). Unsupervised domain adaptation with similarity learning. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 8004-8013).
- [22] Kaytez, F., Taplamacioglu, M. C., Cam, E., & Hardalac, F. (2015). Forecasting electricity consumption: A comparison of regression analysis, neural networks and least squares support vector machines. *International Journal of Electrical Power & Energy Systems*, 67, 431-438.
- [23] Seyedzadeh, S., Rahimian, F. P., Glesk, I., & Roper, M. (2018). Machine learning for estimation of building energy consumption and performance: a review. *Visualization in Engineering*, 6(1), 1-20.
- [24] Runge, J., & Zmeureanu, R. (2019). Forecasting energy use in buildings using artificial neural networks: A review. *Energies*, 12(17), 3254.
- [25] Ferlito, S., Atrigna, M., Graditi, G., De Vito, S., Salvato, M., Buonanno, A., & Di Francia, G. (2015, February). Predictive models for building's energy consumption: An Artificial Neural Network (ANN) approach. In *2015 xviii aisem annual conference* (pp. 1-4). IEEE.
- [26] Biswas, M. R., Robinson, M. D., & Fumo, N. (2016). Prediction of residential building energy consumption: A neural network approach. *Energy*, 117, 84-92.
- [27] Li, Q., Ren, P., & Meng, Q. (2010, June). Prediction model of annual energy consumption of residential buildings. In *2010 international conference on advances in energy engineering* (pp. 223-226). IEEE.
- [28] Jain, R. K., Smith, K. M., Culligan, P. J., & Taylor, J. E. (2014). Forecasting energy consumption of multi-family residential buildings using support vector regression: Investigating the impact of temporal and spatial monitoring granularity on performance accuracy. *Applied Energy*, 123, 168-178.
- [29] Wolpert, D. H. (1996). The lack of a priori distinctions between learning algorithms. *Neural computation*, 8(7), 1341-1390.
- [30] Reinisch, C., Kofler, M., Iglesias, F., & Kastner, W. (2011). Thinkhome energy efficiency in future smart homes. *EURASIP Journal on Embedded Systems*, 2011, 1-18.

