

Prévision de l'activité économique au Québec et au Canada à l'aide des méthodes *Machine Learning*

PHILIPPE GOULET COULOMBE

MAXIME LEROUX

DALIBOR STEVANOVIC

STÉPHANE SURPRENANT

2020RP-18
RAPPORT DE PROJET

RP

Les rapports de projet sont destinés plus spécifiquement aux partenaires et à un public informé. Ils ne sont ni écrits à des fins de publication dans des revues scientifiques ni destinés à un public spécialisé, mais constituent un médium d'échange entre le monde de la recherche et le monde de la pratique.

Project Reports are specifically targeted to our partners and an informed readership. They are not destined for publication in academic journals nor aimed at a specialized readership, but are rather conceived as a medium of exchange between the research and practice worlds.

Le CIRANO est un organisme sans but lucratif constitué en vertu de la Loi des compagnies du Québec. Le financement de son infrastructure et de ses activités de recherche provient des cotisations de ses organisations-membres, d'une subvention d'infrastructure du gouvernement du Québec, de même que des subventions et mandats obtenus par ses équipes de recherche.

CIRANO is a private non-profit organization incorporated under the Quebec Companies Act. Its infrastructure and research activities are funded through fees paid by member organizations, an infrastructure grant from the government of Quebec, and grants and research mandates obtained by its research teams.

Les partenaires du CIRANO – *CIRANO Partners*

Partenaires corporatifs – *Corporate Partners*

Autorité des marchés financiers
Banque de développement du Canada
Banque du Canada
Banque nationale du Canada
Bell Canada
BMO Groupe financier
Caisse de dépôt et placement du Québec
Énergir
Hydro-Québec
Innovation, Sciences et Développement économique Canada
Intact Corporation Financière
Investissements PSP
Manuvie Canada
Ministère de l'Économie, de la Science et de l'Innovation
Ministère des finances du Québec
Mouvement Desjardins
Power Corporation du Canada
Rio Tinto
Ville de Montréal

Partenaires universitaires – *Academic Partners*

École de technologie supérieure
École nationale d'administration publique
HEC Montréal
Institut national de la recherche scientifique
Polytechnique Montréal
Université Concordia
Université de Montréal
Université de Sherbrooke
Université du Québec
Université du Québec à Montréal
Université Laval
Université McGill

Le CIRANO collabore avec de nombreux centres et chaires de recherche universitaires dont on peut consulter la liste sur son site web. *CIRANO collaborates with many centers and university research chairs; list available on its website.*

© Août 2020. Philippe Goulet Coulombe, Maxime Leroux, Dalibor Stevanovic, Stéphane Surprenant. Tous droits réservés. All rights reserved. Reproduction partielle permise avec citation du document source, incluant la notice ©. Short sections may be quoted without explicit permission, if full credit, including © notice, is given to the source.

Les idées et les opinions émises dans cette publication sont sous l'unique responsabilité des auteurs et ne représentent pas nécessairement les positions du CIRANO ou de ses partenaires. *The observations and viewpoints expressed in this publication are the sole responsibility of the authors; they do not necessarily represent the positions of CIRANO or its partners.*

Prévision de l'activité économique au Québec et au Canada à l'aide des méthodes *Machine Learning*

*Philippe Goulet Coulombe *^{*}, Maxime Leroux [†],*
Dalibor Stevanovic [‡], Stéphane Surprenant [§]

Résumé

Dans ce rapport nous appliquons de nombreuses techniques d'apprentissage automatique (*Machine Learning*) au problème de prévision de l'activité économique au Québec et au Canada. Six groupes de modèles sont considérés : les modèles à facteurs, régressions pénalisées, régressions régularisées par sous-ensembles complets, régressions à vecteurs de support, forêts d'arbres aléatoires et les réseaux de neurones. Tous ces modèles apportent différentes façons de gérer les grands ensembles de données et de générer les formes fonctionnelles hautement complexes. La prédiction de 16 variables macroéconomiques québécoises et canadiennes est évaluée dans un exercice de prévision hors échantillon. Les grands ensembles de données canadiennes et américaines sont considérés. Les résultats indiquent que les méthodes machine learning, combinées avec les grands ensembles de données, ont un bon pouvoir prédictif pour plusieurs variables d'activité réelle comme le PIB, la formation brute de capital fixe et la production industrielle. Les forêts d'arbres aléatoires sont particulièrement résiliantes, suivies des réseaux de neurones. La prévision des variables du marché d'emploi est améliorée par l'utilisation des régressions pénalisées, simples ou par sous-ensembles complets. Les taux d'inflation sont prévisibles avec les forêts aléatoires et les régressions pénalisées. Quant aux mises en chantier et le taux de change USD/CAD, les méthodes machine learning n'arrivent pas à améliorer la prévision ponctuelle, mais affichent des résultats intéressants au niveau de la prévision de la direction future de ces variables.

Mots-clés : Prévision, Macroéconomie, Données massives, Machine Learning

* Economics Department, University of Pennsylvania

† Département des sciences économiques, UQAM

‡ Département des sciences économiques, UQAM, CIRANO

§ Département des sciences économiques, UQAM

Table des matières

1	Introduction	4
1.1	Revue de littérature	5
1.2	Résumé des résultats	7
2	Prévisions macroéconomiques et apprentissage automatique	8
2.1	Cible de prévision	8
2.2	Les environnements <i>pauvre</i> et <i>riche</i> en données	9
2.3	Exercice de prévision	11
2.4	Métriques d'évaluation prédictive	12
2.5	Optimisation de hyperparamètres	12
3	Les modèles de prévision	14
3.1	Régressions Pénalisées	15
3.2	Régression régularisées par sous-ensembles complets	16
3.3	Forêts aléatoires	17
3.4	Forêts aléatoires macroéconomiques	19
3.5	Régression par vecteurs supports	21
3.6	Réseaux de neurones	23
3.7	Combinaison de prévisions	26
4	Application	27
4.1	Variables à prévoir	27
4.2	Ensembles de prédicteurs	28
4.3	Modèles	29
5	Résultats	30
5.1	Performance en termes de l'erreur quadratique moyenne	30
5.1.1	PIB	36
5.1.2	Investissement	36
5.1.3	Consommation	37
5.1.4	Taux de chômage	37
5.1.5	Emploi	37
5.1.6	Mises en chantier	38
5.1.7	Inflation	38
5.1.8	Autres variables canadiennes	39
5.2	Performance en termes de la direction	39

5.2.1	PIB	40
5.2.2	Investissement	40
5.2.3	Consommation	40
5.2.4	Taux de chômage	40
5.2.5	Emploi	40
5.2.6	Mises en chantier	41
5.2.7	Inflation	41
5.2.8	Autres variables canadiennes	41
6	Conclusion	42
A	Prévisibilité	75
B	Prévisions	92

1 Introduction

Traditionnellement, la modélisation macroéconométrique a été guidée par le principe de parcimonie au détriment des modèles nonlinéaires et sur-paramétrés (Swanson et White, 1997; Stock et Watson, 1999; Teräsvirta, 2006). Or, l’accessibilité des données massives et l’avancement des techniques d’apprentissage automatique (Machine Learning ou ML) ont considérablement changé la façon d’approcher le problème de prévision macroéconomique (Kotchoni *et al.*, 2019; Goulet-Coulombe *et al.*, 2019). Par contre, l’arrivée des données massives se résume par un très grand nombre de séries temporelles et non par une hausse de périodes observées. Dans une régression prédictive linéaire, ceci implique un très grand nombre de paramètres inconnus, rendant même leur estimation par les moindres carrés ordinaires (MCO) infaisable. Ce problème est connu dans la littérature sous le nom malédiction de la dimensionnalité (*curse of dimensionality*). De plus, l’accessibilité des algorithmes ML hautement complexes augmente le risque d’une utilisation naïve et de l’interprétation erronée de leurs outputs (Mullainathan et Spiess, 2017). Les méthodes ML s’avèrent particulièrement utiles lorsque nous n’avons pas beaucoup d’information sur la forme ni sur la complexité du vrai modèle. Pour illustrer cette situation, soit y_{t+h} la variable macroéconomique à prévoir h périodes en avance. L’ensemble d’information est donné par Z_t , un vecteur N_Z -dimensionnel de prédicteurs disponibles au temps t . Dénotons par $g^*(Z_t)$ le vrai modèle (inconnu par l’utilisateur) et par $g(Z_t; \theta)$ la forme fonctionnelle spécifiée par l’économètre. À noter que la fonction g peut être paramétrique ou non, et que le vecteur θ collecte tous les paramètres du modèle. De plus, définissons le modèle estimé et sa prévision par $\hat{g}(X_t; \hat{\theta})$ et \hat{y}_{t+h} respectivement. Par conséquent, l’erreur de prévision se décompose comme suit

$$y_{t+h} - \hat{y}_{t+h} = \underbrace{g^*(Z_t) - g(Z_t; \theta)}_{\text{erreur d'approximation}} + \underbrace{g(Z_t; \theta) - \hat{g}(Z_t; \hat{\theta})}_{\text{erreur d'estimation}} + \varepsilon_{t+h}. \quad (1)$$

L’erreur intrinsèque à la prévision, ε_{t+h} , n’est pas réductible. L’erreur d’estimation peut être contrôlée par l’économète en ajoutant plus d’observation et en choisissant des estimateurs plus efficaces. La contribution des méthodes ML est dans la réduction de l’erreur d’approximation en permettant des formes fonctionnelles g très flexibles. Par contre, cette flexibilité vient habituellement avec le risque élevé de sur-ajustement et une régularisation performante doit accompagner le choix de g .

Pour bien fixer les idées, nous empruntons la formulation du problème général de prévision de Hastie *et al.* (2017) :

$$\min_{g \in \mathcal{G}} \left\{ \hat{L}(y_{t+h}, g(Z_t, \theta)) + pen(g; \tau) \right\}, \quad t \in 1, \dots, T. \quad (2)$$

Nous notons au passage que cette formulation du problème de prévision serait également re-

présentative pour des données en coupe transversale, bien que nous nous en servions ici dans le contexte des séries temporelles. Dans tous les cas, cette formulation présente quatre principaux aspects, soit

1. \mathcal{G} est l'espace fonctionnel duquel est tiré la fonction g employée pour former un prévision à partir d'une combinaison de données. Nous sommes en particulier intéressé au degré de non-linéarité permis par le choix d'un espace fonctionnel. Nous notons aussi que g peut être paramétrique ou non-paramétrique.
2. $pen(.,.)$ est une fonction appliquant une pénalité sur g . Plusieurs méthodes nécessitent une forme de régularisation pour contrôler le risque de sur-ajustement dû à la prolifération des paramètres et / ou aux formes complexes de nonlinéarité. En général, il s'agit de la pénalité de type Bridge ou de la réduction de dimension par composantes principales (modèle à facteurs).
3. τ est un vecteur d'hyperparamètres liés aux formes spécifiques de la fonction g et de la pénalité pen . Par exemple, il peut s'agir du λ dans un estimateur de type LASSO ou encore le nombre de retards dans un modèle autorégressif. Le problème consiste à trouver une méthode efficace pour fixer τ .
4. $\hat{L}(.,.)$ est la fonction de perte (*loss function*) qui détermine la prévision optimale. Certains modèles emploient une fonction de perte qui diffère de la norme l_2 lors de l'estimation.

La plupart des algorithmes d'apprentissage automatique supervisé utilisent une combinaison de ces ingrédients. Pour illustrer cette formulation abstraite du problème de prévision, nous pouvons obtenir le modèle de régression linéaire comme un cas particulier. Nous choisissons dans ce cas la fonction de perte quadratique ($\hat{L}(y_{t+h}, g(Z_t)) := E[(y_{t+h} - g(Z_t))^2]$). Nous nous limitons à l'espace des hyperplans et imposons la forme paramétrique suivante : $y_{t+h} = Z_t\beta + e_{t+h}$. Si le nombre des coefficients dans β est assez petit, nous ignorons généralement la pénalité. Dans ce cas, la prévision optimale est $E(y_{t+h}|Z_t) = Z_t\beta$ et les paramètres sont généralement estimés par les moindres carrés ordinaires.

1.1 Revue de littérature

L'apprentissage statistique non supervisé est très utilisé dans la prévision macroéconomique, et ce depuis les travaux de [Stock et Watson \(2002b\)](#). Cette analyse, basée sur la réduction de dimension de l'espace des prédicteurs à l'aide du modèle à facteurs, a été proposée comme solution au problème de malédiction de dimensionnalité. En termes de la problématique présentée ([2](#)), la fonction g est linéaire en Z_t et en θ , la régularisation pen est un modèle à facteurs, les hyperparamètres sont typiquement choisis par un critère d'information et la fonction de coût est quadratique.

Une autre façon de contourner le problème de dimensionnalité consiste à choisir une pénalité permettant une sélection de variables parmi tous les N_Z éléments de Z_t tout en estimant le modèle de régression prédictive linéaire. Les hyperparamètres sont souvent sélectionnés par la validation croisée. Cette famille de modèles apparaît sous l'appellation *Elastic Net* et sera présentée en détails plus loin dans le texte. Plusieurs travaux ont comparé ces techniques dans différents contextes de prévision macroéconomique, et de manière générale, la modélisation factorielle est préférable. Les exercices récents les plus complets sont disponibles dans Giannone *et al.* (2017) et Kotchoni *et al.* (2019).

Dans les deux méthodes précédentes la fonction g est toujours linéaire, tandis que les méthodes ML servent justement à réduire l'erreur d'approximation dans (1) en choisissant les formes fonctionnelles plus flexibles. La littérature sur ces tentatives est beaucoup moins garnie. Les réseaux de neurones (NN), l'approche ML la plus prometteuse dans plusieurs domaines d'application d'intelligence artificielle, ont été peu utilisés pour la prévision macroéconomique puisqu'ils nécessitent l'estimation d'une quantité phénoménale de (hyper)paramètres. Néanmoins, les NNs ont servi à améliorer la prévision de l'inflation et du taux de chômage dans les travaux de Nakamura (2005), Cook et Hall (2017) et Joseph (2019), et des rendements d'actifs dans Gu *et al.* (2019). Plusieurs formes de régularisation sont nécessaires, non seulement pour pénaliser l'estimation des paramètres du modèle, mais aussi pour l'optimisation numérique (Gu *et al.*, 2019).

Une autre forme populaire de g sont les forêts aléatoires (Random Forests ou RF). Il s'agit d'une analyse nonlinéaire et nonparamétrique, basée sur la régression par arbre. Medeiros *et al.* (2019) ont utilisé cette approche pour prévoir l'inflation, tandis que Ng (2014) et Döpke *et al.* (2017) modélisent les probabilités de récession. Goulet-Coulombe (2020) propose de modéliser les changements structurels à l'aide des RFs. Comme c'est une méthode qui tend naturellement vers le sur-ajustement, elle est accompagnée par plusieurs approches de régularisation. Finalement, la régression par vecteurs supports (Support Vector Regression ou SVR) a été populaire surtout dans les problèmes de classification, mais qui est maintenant de plus en plus utilisée pour la prévision des séries temporelles. SVR utilise habituellement une fonction g nonlinéaire et la pénalité de type Ridge. Mais la plus grande différence par rapport aux autres modèles est le changement de la fonction de perte L qui est insensible aux erreurs de prévision dans un intervalle particulier. Sermpinis *et al.* (2014) et Joseph (2019) ont appliqué SVR à la prévision de l'inflation et du taux de chômage, tandis que Colombo et Pelagatti (2020) améliorent grandement la prédition des taux de change.

La plupart de ces travaux ne comparent qu'un nombre restreint de modèles et considèrent la prévision d'un petit groupe de variables à peu d'horizons. Quelques courses de modèles à plus grande échelle ont été réalisées (Kim et Swanson, 2018; Milunovich, 2019; Chen *et al.*, 2019). Une exception est Goulet-Coulombe *et al.* (2019) qui étudient l'importance des quatre propriétés

énumérées dans (2) pour la prévision macroéconomique. Ils concluent que la nonlinéarité de la fonction g , combinée avec la réduction de dimension par le modèle à facteurs, améliorent grandement la capacité des modèles à prévoir les fluctuations cycliques. De plus, la meilleure pratique de sélection des hyperparamètres est la validation croisée standard (de type K-fold), et la fonction de perte quadratique est préférée à celle utilisée par le modèle SVR.

1.2 Résumé des résultats

Nous considérons deux métriques de performance. La première est l'erreur quadratique moyenne. Dans la plupart des cas, les méthodes ML améliorent significativement la capacité prédictive. En moyenne sur toutes les 16 variables cibles considérées, les méthodes ML, lorsque combinées, améliorent la précision prédictive jusqu'à 15% en termes du pseudo- R^2 . L'ajout des données américaines améliorent la capacité prédictive de la plupart des modèles. La performance n'est pas homogène et plusieurs cas spécifiques doivent être considérés afin d'isoler les meilleurs modèles.

En particulier, pour le PIB et ses composantes, les random forests sont les meilleurs en général à court terme, et les réseaux de neurones sont les plus résiliants à long terme. Quant à la production industrielle canadienne, le modèle à facteurs, standard ARDI,BIC, affiche la meilleure performance à court terme, suivi des régressions pénalisées par sous-ensembles complets et réseaux de neurones aux horizons plus longs.

Au niveau du marché d'emploi, les régressions pénalisées, simples ou par sous-ensembles complets, sont en générales les plus résiliantes, suivi des random forests et des réseaux de neurones. Les données américaines ne jouent pas un rôle primordial. Dans le cas des mises en chantier, les grands ensembles de données n'ajoutent pas de contenu prédictif sauf quelques exceptions. Le modèle autorégressif linéaire et nonlinéaire est le meilleur dans le cas du Québec, et des versions de forêts aléatoires s'avèrent efficaces à deux horizons seulement dans le cas canadien. Enfin, les regressions pénalisées et forêts aléatoires performent bien pour prévoir l'inflation. Pour l'inflation canadienne plus spécifiquement, les données américaines apportent un contenu informationnel important.

La deuxième métrique de performance évalue la capacité des modèles à correctement prévoir la direction des variables cibles. Dans le cas des variables réelles, telles que PIB, investissement, consommation et production industrielle, la plupart des modèles affichent une bonne performance. Au niveau du marché d'emploi, les régressions pénalisées sortent généralement gagnantes dans le cas du taux de chômage, tandis que la prévision de la direction de l'emploi semble très facile puisque la majorité des modèles affichent des taux de succès très élevés. Les modèles à facteurs et random forests performent le mieux au niveau de l'inflation.

La situation des mises en chantier et du taux de change est plus intéressante. L'analyse

de prévisibilité par pseudo- R^2 , détaillée dans l'annexe , indiquent que les mises en chantier et le taux de change sont peu prévisible en termes de l'erreur quadratique moyenne. Par contre, l'analyse avec la deuxième métrique de performance indique que les données massives et la nonlinéarité sont des ingrédients clés pour la prévision de la direction des mises en chantier. Au niveau du taux de change, certains modèles prévoient correctement le signe du rendement plus de 60% du temps même à long terme. C'est un bon exemple où les modèles ont un faible pouvoir prédictif au niveau de la prévision ponctuelle, mais ils sont capables de bien prévoir la direction que prendra la variable d'intérêt dans le futur.

2 Prévisions macroéconomiques et apprentissage automatique

Dans cette section nous présentons le cadre d'analyse prédictive qui consiste de plusieurs éléments importants. Il faut définir la cible de prévision et l'ensemble d'information, mais aussi déterminer l'exercice de prévision et les métriques d'évaluation. Les façons d'optimiser les nombreux hyperparamètres seront également discutées.

2.1 Cible de prévision

Nous nous concentrerons sur une approche prédictive *directe*, c'est-à-dire que nous projetons la cible sur l'ensemble d'information et la prévision est faite directement à partir des observations les plus récentes. Ceci est défini par opposition à une approche *itérative* où la structure des modèles est exploitée pour générer récursivement tout le sentier entre y_t et y_{t+h} .¹ Aussi, l'approche directe est la pratique standard en apprentissage automatique.

Nous allons maintenant définir nos cibles de prévision. Soit Y_t , une variable d'intérêt. Si $y_t := \ln Y_t$ est stationnaire en covariance, nous allons prévoir directement son niveau h périodes en avance, y_{t+h} . La plupart du temps, les variables d'intérêt sont considérées intégrées d'ordre 1. Dans ces cas, nous allons prévoir le taux de croissance² :

$$y_t := \ln(Y_t/Y_{t-1}). \quad (3)$$

1. Ceci a comme avantage une plus grande robustesse aux changements structurels au coût de plus petite efficacité si le modèle est inutilement estimé pour chaque choix de h ([Chevillon, 2007](#)). De plus, [Kapetanios et Marcellino \(2006\)](#) ont montré que l'approche directe procure une performance légèrement supérieure, bien qu'elle ne domine pas pour toutes les séries ou toutes les périodes qu'ils ont étudiées.

2. Une autre pratique est de prévoir le taux de croissance *moyen sur l'intervalle de temps* $[t+1, t+h]$, comme dans [Stock et Watson \(2002b\)](#). Nous privilégions la prévision du taux de croissance simple puisque nous travaillons avec les séries trimestrielles, donc moins bruyantes. Nous avons de plus comparé les résultats avec la cible alternative et la performance relative des modèles ne change presque pas.

À titre d'exemple, la figure 1 présente une des variables à prévoir, le taux de croissance du PIB du Québec. Les zones ombragées représentent les périodes de récession telles que déclarées par C.D. Howe.³

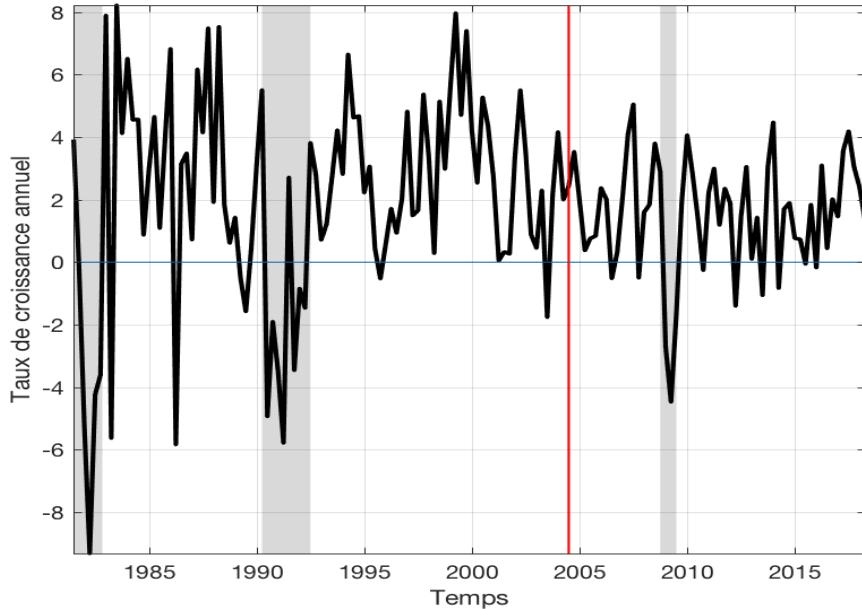


FIGURE 1: Taux de croissance du PIB du Québec

2.2 Les environnements *pauvre* et *riche* en données

Les grands panels de données macroéconomiques sont maintenant monnaie courante. Une des plus populaires est FRED-MD, le panel de données mensuelles américaines construit par McCracken et Ng (2016). Depuis peu, le panel trimestriel est disponible (McCracken et Ng, 2020). Les panels similaires ont été introduits par Fortin-Gagnon *et al.* (2018) pour les données canadiennes. Malheureusement, les performances des méthodes économétriques les plus utilisées se détériorent rapidement avec l'accroissement de la dimension de l'ensemble d'information. Stock et Watson (2002a) ont introduit dans la littérature économétrique l'idée de réduire la dimension de l'ensemble d'information en utilisant seulement quelques composantes principales. Le lecteur peut se référer à Kotchoni *et al.* (2019) pour une synthèse concernant les méthodes de réduction de dimension, de régularisation et d'agrégation de prévisions (*model averaging*).

Bien qu'il y ait beaucoup de variables potentiellement disponibles pour effectuer une prévision, elles ne sont pas toutes pertinentes. Traditionnellement, une sélection des variables est donc effectuée sur la base d'une combinaison d'arguments théoriques, heuristiques ou les résultats présentés dans la littérature empirique. Les méthodes d'apprentissage automatique offrent

3. <https://www.cdhewe.org/turning-points-business-cycles-in-canada-since-1926/19364>

toutefois la possibilité de structurer cette sélection autour de critères statistiques en plus de permettre la digestion de grandes quantités d'information dans le but d'améliorer la prévision. Ainsi, en plus de considérer les effets de traitement liés aux caractéristiques des modèles de prévision, nous allons aussi comparer les performances prédictives dans un contexte pauvre et un contexte riche en données. En particulier, soit H_t^- , l'ensemble pauvre en données constitué uniquement d'un nombre fini de retards de la variable dépendante et soit H_t^+ , l'ensemble riche en données qui inclut à la fois H_t^- et un grand ensemble d'autres variables. Formellement, nous avons

$$H_t^- := \{y_{t-j}\}_{j=0}^{p_y} \text{ et } H_t^+ := [\{y_{t-j}\}_{j=0}^{p_y}, \{X_{t-j}\}_{j=0}^{p_f}] . \quad (4)$$

Nous pouvons donc résumer le cadre de prévision de la façon suivante. Nous allons considérer deux modèles typiques pour la prévision.

1. Le modèle H_t^- est le modèle autorégressif direct (AR) spécifié comme suit :

$$y_{t+h} = c + \rho(L)y_t + e_{t+h}, \quad t \in 1, \dots, T, \quad (5)$$

où $h \geq 1$ est l'horizon de la prévision. Le seul hyperparamètre de ce modèle est p_y , soit l'ordre du polynôme de retard $\rho(L)$.

2. Le modèle H_t^+ (ARDI) ajoute au modèle AR des indices de diffusion suivant [Stock et Watson \(2002b\)](#) :

$$y_{t+h} = c + \rho(L)y_t + \beta(L)F_t + e_{t+h}, \quad t \in \{1, \dots, T\} \quad (6)$$

$$X_t = \Lambda F_t + u_t \quad (7)$$

où F_t est un vecteur de K facteurs statiques consécutifs et $\rho(L)$ et $\beta(L)$ sont des polynômes de retard d'ordre p_y et p_f , respectivement. L'estimation des facteurs est effectuée sur la base de l'analyse par composantes principales (PCA).

Ensuite, l'idée est d'appliquer à chacune de ses formulations des modifications issues de la littérature en apprentissage automatique suivant les quatre facettes mentionnées plus haut. Par exemple, l'hypothèse de linéarité derrière les équations (5) et (6) peut être assouplie en utilisant une classe de fonctions non-linéaires.

L'intérêt d'utiliser le modèle ARDI comme point de référence (*benchmark*) est multiple. En plus d'être un outil très populaire pour la prévision macroéconomique, le modèle offre une façon d'approcher le problème de dimension susmentionné. Bien que nous considérons quatre facettes de l'apprentissage automatique dans ce rapport, il est évident que les deux plus importantes sont la réduction de la dimension ou l'écrasement (selon le cas) et l'ajout de non-linéarités. Il faut mentionner que ces deux traitements vont dans les directions opposées. Le

premier traitement s'attaque aux cas où le ratio entre le nombre d'observations et le nombre de prédicteurs potentiellement intéressants est bas. Le second traitement travaille le plus souvent à introduire des non-linéarités via une expansion de la base (*basis expansion*) d'un espace.

Ces considérations motivent le choix de procéder d'abord à une première compression du nombre de prédicteurs avant d'appliquer les méthodes non-linéaires. Chaque méthode de compression a une justification économique particulière. Nous pouvons travailler à partir de quelques séries suivant le fait qu'un modèle vectoriel autorégressif (VAR) sous forme réduite approxime au premier ordre la dynamique d'un modèle dynamique d'équilibre générale (DSGE). L'utilisation d'un petit nombre de facteurs peut être justifiée sur la base de l'idée qu'un petit nombre de variables latentes sont la source de la dynamique macroéconomique observée. Nous avons choisi la seconde option (soit, le ARDI) puisque sa bonne performance est connue. Donc, la grande majorité de nos modèles non-linéaires postulent implicitement qu'un ensemble limité de variables latentes influent d'une manière flexible sur les cibles.

2.3 Exercice de prévision

La période de test, autrement dit hors échantillon (ou *pseudo-out-of-sample*) est 2004T2 – 2018T1. Les horizons de prévision sont $h = \{1, 2, 4, 6, 8\}$ trimestres en avance. Donc, il y a 56 périodes d'évaluation pour chaque horizon. Les modèles sont estimés récursivement avec la fenêtre grandissante. Il est important de retenir ici l'esprit de l'exercice, tel que présenté à la figure 2. L'objectif est de vérifier la capacité des modèles à faire la prévision hors échantillon. En temps réel, le modèle est utilisé pour prévoir le futur, et l'erreur de prévision sera observée seulement une fois que la cible soit réalisée. Pour approximer cette situation, l'idée est de séparer l'échantillon en deux parties : période d'entraînement et période d'évaluation. Toutes les 56 cibles dans la période d'évaluation sont prévues récursivement en ajoutant la dernière observation à la période d'entraînement lorsqu'elle devient disponible. Par exemple, pour $h = 1$, la première cible est y_{2004T2} étant donnée l'information en 2004T1. Un modèle est spécifié et estimé sur la période d'entraînement, et ensuite la prévision $\hat{y}_{2004T2|2004T1}$ est produite. La prochaine cible est y_{2004T3} , et l'ensemble d'information s'agrandit en ajoutant y_{2004T2} dans la période d'entraînement. Ceci est répété jusqu'à la fin de l'échantillon, pour tous les modèles et pour tous les horizons de prévision.

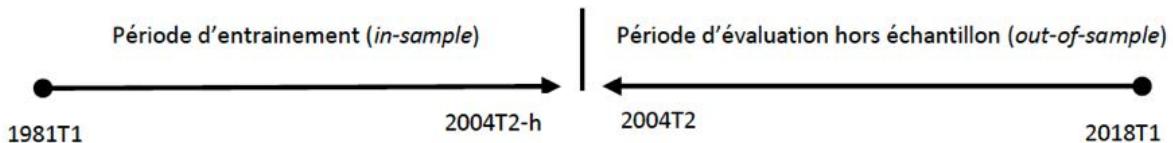


FIGURE 2: Illustration de l'exercice d'évaluation

Comme résultat, on a une erreur de prévision pour chaque période t , horizon h et modèle

$j : \hat{e}_{t,h,j} = y_{t+h} - \hat{y}_{t+h|t,j}$ avec $t = 2004T2, \dots, 2018T1$, $h \in \{1, 2, 4, 6, 8\}$ et $j = 1, \dots, J$, où J est le nombre de modèles.

2.4 Métriques d'évaluation prédictive

La métrique standard dans la littérature est l'erreur quadratique moyenne (EQM) qui est le choix logique lorsque la fonction de perte est quadratique :

$$EQM_{h,j} = \frac{1}{T} \sum_{t=1}^T \hat{e}_{t,h,j}^2. \quad (8)$$

Pour tester la précision prédictive entre deux modèles, la méthode de Diebold et Mariano (1995) (DM) est habituellement utilisée. De plus, nous appliquons l'approche *Model Confidence Set* (MCS) de Hansen *et al.* (2011) afin de sélectionner un groupe de modèles les plus performants.⁴ Finalement, il est intéressant de vérifier la capacité des modèles à bien prévoir la direction que prendra la cible dans l'avenir : est-ce que le PIB québécois augmentera ou diminuera dans h trimestres ? S'il est parfois difficile d'obtenir une bonne performance en termes d'EQM, les modèles peuvent avoir une capacité intéressante à prévoir la direction de la cible (Satchell et Timmermann, 1995). Le test de signe prédictif est proposé par Pesaran et Timmermann (1992).

La statistique du test s'écrit :

$$S_n = \frac{\hat{p} - \hat{p}^*}{\sqrt{\text{Var}(\hat{p}) - \text{Var}(\hat{p}^*)}},$$

où \hat{p} est la proportion des prévisions ayant le bon signe et \hat{p}^* est l'estimé de son espérance. Sous la nulle que le signe de la prévision est indépendant de celui de la cible, on a que $S_n \rightarrow N(0, 1)$. Pratiquement, si un modèle n'a pas de pouvoir prédictif sur la direction de la cible, alors son taux de succès sera proche de 50%.

2.5 Optimisation de hyperparamètres

Tous nos modèles impliquent de choisir des hyperparamètres avant de procéder à l'estimation. Il est opportun de détailler maintenant comment les hyperparamètres sont sélectionnés. Pour illustrer les méthodes, utilisons l'exemple du modèle autorégressif AR (5) où l'ordre p_y est le seul hyperparamètre. Pour fixer p_y , l'approche standard est le critère de sélection, et en

4. Par contre, le nombre de périodes hors échantillon étant petit, la puissance de ces tests peut être affectée.

particulier le *Bayesian Information Criterion* (BIC) :

$$\text{BIC}_i = \log\left(\frac{\text{SCR}_{p_i}}{T}\right) + p_j \frac{\log(T)}{T},$$

où SCR_{p_i} est la somme des carrés des résidus du modèle AR(p_i), et $p_i = \{0, 1, \dots, p_{max}\}$. Comme le premier terme est décroissant en p_i , le deuxième terme permet au BIC de régulariser le sur-ajustement en pénalisant avec le nombre de paramètres à estimer. Il faut noter que cette procédure cache un hyperparamètre de second ordre, p_{max} .

Une autre façon, surtout populaire en apprentissage automatique, est la validation croisée (*cross-validation* ou CV). Tout comme BIC, CV choisit aussi l'ordre optimal p , mais en régularisant via la performance de prévision hors échantillon, tandis que la sélection par BIC est basée uniquement sur la performance dans l'échantillon. La popularité de CV tient aussi à sa simplicité puisqu'elle peut être pratiquée même lorsque le critère d'information n'est pas disponible.

Il existe plusieurs approches CV, mais la plus populaire est basée sur un ré-échantillonnage aléatoire (K-fold) dans la période d'entraînement. Supposons que le nombre de plis (fold) est fixée à 5 (un autre hyperparamètre de second ordre). Ceci revient à séparer la période *in-sample*, de la figure 2, en 5 sous-échantillons de taille égale. Ensuite, 4 sous-échantillons sont utilisés tour à tour pour estimer le modèle p_i de la grille ci-haut (formant la période d'entraînement ou *training set* en langage ML) et un sous-échantillon sert à évaluer la performance hors échantillon avec habituellement EQM comme métrique. L'élément p_i de la grille produisant EQM minimale sera l'estimé de l'ordre optimal p_y .

Bien que la méthode K-fold soit très répandue, elle paraît mal adaptée pour la prévision des séries temporelles pour deux raisons. Premièrement, l'ordre temporel n'est pas respecté lors du choix de K plis et donc les données futures seront éventuellement utilisées pour prévoir le passé. Deuxièmement, les séries temporelles macroéconomiques sont souvent très persistantes et K-fold brisera cette structure, impliquant un potentiel biais dans la sélection de p_y . [Bergmeir et al. \(2018\)](#) montrent que K-fold CV peut être utilisé dans le cadre de l'autorégression tant que les résidus sont non corrélés.

L'alternative au K-fold est d'imiter l'exercice de prévision hors échantillon à l'intérieur même de la période d'entraînement (*pseudo-out-of-sample* ou POOS CV). Ainsi, l'ordre temporelle est respecté et la structure d'autocorrélation reste intacte. Par contre, le nombre d'observations pour évaluer la performance est grandement diminué relativement au K-fold, et surtout en cas de petits échantillons dans les applications typiques en macroéconomie. [Goulet-Coulombe et al. \(2019\)](#) suggèrent que dans ces situations K-fold est préférable justement à cause de la réduction de variance grâce à la plus grande taille des périodes d'évaluation. La figure 3 montre un exemple fictif simple avec moins de périodes dans les ensembles d'entraînement et de validation, ainsi

qu'un horizon de 3 mois, d'où les sauts. Une fois que les hyperparamètres ont été choisis, le modèle est estimé sur tout l'échantillon d'estimation et une prévision est effectuée pour la cible.

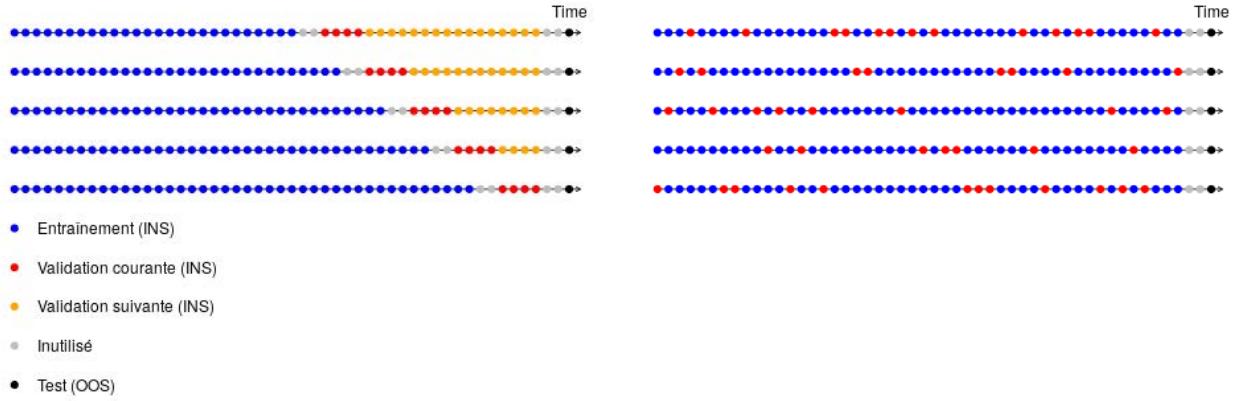


FIGURE 3: Illustration de la validation croisée

Notes : Les figures sont dessinées pour une prévision de 3 mois à l'avance et illustrent comment l'échantillon d'estimation est divisé entre l'ensemble d'entraînement et l'ensemble de validation. L'observation à prévoir dans l'exercice pseudo-hors-échantillon (POOS) est indiquée par un point noir.

Un dernier choix doit être fait par l'utilisateur concernant la fréquence à laquelle les hyperparamètres sont ré-optimisés. Le ré-étalonnage récursif (*rolling-origin recalibration*) consiste à ré-optimiser les hyperparamètres à chaque point dans le temps, alors que la mise à jour récursive (*rolling-origin updating*) consiste à se limiter à mettre à jour l'information d'estimation et d'utiliser le choix d'hyperparamètres initial pour toutes les périodes subséquentes (Tashman, 2000). Pour limiter les temps de calculs, nous effectuons un ré-optimisation des hyperparamètres tous les 8 trimestres au fur et à mesure que l'échantillon d'estimation s'agrandit. Cette approche peut être vue comme un compromis entre ces deux extrêmes.

Dans le présent rapport, tous les hyperparamètres, sauf indication contraire, sont choisis à partir de la validation croisée de type K-fold. Notez aussi que la moyenne des erreurs quadratiques moyennes dans les ensembles de validation est la métrique de performance employée pour comparer les vecteurs d'hyperparamètres.

3 Les modèles de prévision

Dans cette section nous présentons tous les modèles de prévision de façon générique. L'application, les variables cibles et les ensembles de prédicteurs seront présentés dans la section subséquente. Rappelons que les deux modèles de référence sont AR et ARDI tels que décrits dans (5) et (6-7). Les hyperparamètres dans ces modèles sont choisis par BIC. Les prochains groupes de modèles appliqueront différentes composantes dans le cadre de prévision (2) : une

pénalité alternative, des formes fonctionnelles nonlinéaires et une fonction de perte non quadratique.

3.1 Régressions Pénalisées

La régularisation alternative au modèle à facteurs (7) est la régression linéaire pénalisée. Le cadre général est la régression Bridge :

$$\hat{\theta}_{Bridge} = \operatorname{argmin}_{\theta} \left\{ \sum_{t=1}^T \left(y_{t+h} - \sum_{i=1}^{N_Z} \theta_i Z_{it} \right)^2 + \lambda \sum_{i=1}^{N_Z} |\theta_i|^\eta \right\}, \quad \eta > 0, \quad (9)$$

où $\lambda > 0$ est un hyperparamètre contrôlant la force de la régularisation. Deux cas spéciaux sont considérés. Si $\eta = 2$, le problème (9) a une solution analytique donnant lieu à l'estimateur Ridge (Hoerl et Kennard, 1970) :

$$\hat{\theta}_{Ridge} = (Z'Z + \lambda I_{N_Z})^{-1} Z'y, \quad (10)$$

où Z est la matrice $T \times N_Z$ de régresseurs, et y est la variable dépendante exprimée de façon vectorielle. Dans le cas $\eta = 1$, c'est l'estimateur Lasso (Least Absolute Shrinkage Selection Operator) de Tibshirani (1996)

$$\hat{\theta}_{Lasso} = \operatorname{argmin}_{\theta} \left\{ \sum_{t=1}^T \left(y_{t+h} - \sum_{i=1}^{N_Z} \theta_i Z_{it} \right)^2 + \lambda \sum_{i=1}^{N_Z} |\theta_i| \right\}. \quad (11)$$

La particularité de Ridge est d'avoir une solution intérieure et analytique étant donnée λ . Si $\lambda = 0$, (10) se réduit à l'estimateur MCO. Si $\lambda > 0$, Ridge diminuera la valeur des coefficients des variables moins importantes vers zéro. À l'opposé, Lasso estime simultanément la régression prédictive et sélectionne les variables importantes, due à la norme L_1 employée comme pénalité. Autrement dit, le vecteur de coefficients estimés, $\hat{\theta}_{Lasso}$, contiendra des zéros.

En présence de variables corrélées, Lasso a tendance à écarter celles ayant l'influence prédictive moins importante. Ceci implique la sélection de modèle non convergente. Deux alternatives ont été proposées. La première est *Elastic Net* (EN) de Zou et Hastie (2004) :

$$\hat{\theta}_{EN} = \operatorname{argmin}_{\theta} \left\{ \sum_{t=1}^T \left(y_{t+h} - \sum_{i=1}^{N_Z} \theta_i Z_{it} \right)^2 + \lambda \sum_{i=1}^{N_Z} (\alpha |\theta_i| + (1 - \alpha) \theta_i^2) \right\}, \quad (12)$$

avec $\alpha = [0, 1]$. Fixer α à 1 ou 0 génère Lasso ou Ridge respectivement. La deuxième alternative

est *Adaptive Lasso* (AdLasso) de [Zou et Hastie \(2006\)](#) :

$$\hat{\theta}_{AdLasso} = \operatorname{argmin}_{\theta} \left\{ \sum_{t=1}^T \left(y_{t+h} - \sum_{i=1}^{N_Z} \theta_i Z_{it} \right)^2 + \lambda \sum_{i=1}^{N_Z} \psi_i |\theta_i| \right\}, \quad (13)$$

où $\psi_i = \frac{1}{|\tilde{\theta}_i|^{\gamma}}$ sont les poids obtenus au préalable par un estimateur convergent $\tilde{\theta}_i$ et avec $\gamma > 0$. Dans cette application $\tilde{\theta}_i$ sera obtenu par Ridge et nous fixons $\gamma = 1$. Les hyperparamètres λ et α seront déterminés par CV.

3.2 Régression régularisées par sous-ensembles complets

La méthode par sous-ensembles complets (Complete Subset Regressions ou CSR) a été proposée par ([Elliott et al., 2013](#)). C'est une solution au sur-ajustement en présence d'un très grand nombre de prédicteurs. L'idée est de créer des prévisions à partir d'un grand nombre de petits modèles (en prenant des sous-ensembles de prédicteurs) potentiellement biaisés mais ayant une plus petite variance, et construire la prévision finale comme la moyenne de ces prédictions. Formellement, soit L , le cardinal d'un sous-ensemble de prédicteurs d'une grande base de données et soit $X_{t,m}$ le vecteur de L variables du tirage aléatoire $m = 1, \dots, M$. Pour chaque tirage m la prévision est construite à partir d'une régression prédictive

$$y_{t+h} = c + \rho(L)y_t + \beta' X_{t,m} + \epsilon_{t+h,m}. \quad (14)$$

Notez que $X_{t,m} \in X_t \in Z_t$, mais par simplicité de présentation de la méthode supposons ici que $X_t = Z_t$. L'idée de [Elliott et al. \(2013\)](#) est de faire cet exercice pour un (très grand) nombre M de tirages aléatoires et d'utiliser la moyenne des prévisions comme la prévision finale :

$$\hat{y}_{t+h|h,m} = \hat{c}_m + \hat{\rho}(L)_m y_t + \hat{\beta}'_m X_{t,m} \quad (15)$$

$$\hat{y}_{t+h|t} = \frac{1}{M} \sum_{m=1}^M \hat{y}_{t+h|h,m}. \quad (16)$$

Le nombre de tirages devrait être large pour approximer toutes les $\frac{N_Z!}{L!(N_Z-L)!}$ possibilités. Dans le présent rapport, nous considérons deux raffinements des CSR proposés par [Kotchoni et al. \(2019\)](#). Il s'agit de deux versions régularisées de CSR. La première approche (T-CSR) consiste à limiter le nombre de prédicteurs à partir duquel les sous-ensembles sont tirés. Nous imitons la règle du seuil (*hard thresholding*) proposée par [Bai et Ng \(2008\)](#) dans un contexte similaire.

En particulier, nous effectuons les régressions suivantes :

$$y_{t+h} = c + \rho(L)y_t + \beta_i x_{t,i} + \epsilon_{t+h,i}, \quad i \in \{1, \dots, N_Z\} \quad (17)$$

où la cible est projetée sur son passé et sur un prédicteur exogène à la fois. Le sous-ensemble $X_t^* \in X_t$ contient des variables correspondantes aux coefficients ayant la statistique t_{β_i} plus grande qu'une valeur critique t_c : $X_t^* = \{X_{t,i} \in X_t \mid |t_{\beta_i}| > t_c\}$. Après la présélection par (17), la prévision est obtenue en appliquant (15) et (16) à l'ensemble X_t^* . À noter que ce processus est appliqué pour chaque horizon de prévision. La valeur critique t_c est un hyperparamètre qui joue le même rôle de la force de régularisation que λ dans une régression pénalisée.

La deuxième variante régularise CSR au niveau des modèles aléatoires (14). Au lieu d'estimer les coefficients par MCO, ils sont plutôt estimés par Ridge comme dans l'équation (10). De cette façon, si $X_{t,m}$ contient plusieurs prédicteurs très corrélés ou des éléments non pertinents, la partie Ridge en tiendra compte. Pour rendre la procédure numériquement faisable, puisqu'il faut un grand nombre de régressions, le hyperparamètre de Ridge est sélectionné comme dans Hoerl et Kennard (1970) plutôt que par CV. Ce modèle sera nommé CSR-R. Plusieurs hyperparamètres doivent être fixés dans ces deux modèles. Le nombre de prédicteurs dans chaque tirage, L, sera fixé à 10 et à 20. Le nombre de sous-modèles $M = 2000$ et la valeur critique t_c est fixée à 1.65. Enfin, deux retards de la cible sont utilisés dans l'équation (14).

3.3 Forêts aléatoires

Afin de relâcher l'hypothèse de linéarité sous-jacente aux modèles précédents, une façon de faire consiste à se tourner vers les Random Forests (Breiman, 2001), basés sur les arbres de régression (*regression trees*). La figure 4 montre un exemple simple pour illustrer le concept. Supposons deux prédicteurs pour $y(t + h)$: taux de chômage ($X_{1,t}$) et taux d'intérêt ($X_{2,t}$). Premièrement, les observations sont triées par $X_{1,t}$. Celles au-dessous du seuil 7% sont assignées au nœud 1. Celles associées aux plus grandes valeurs du taux de chômage sont ensuite triées par $X_{2,t}$. Les observations satisfaisant $X_{1,t} > 7\%$, $X_{2,t} < 5\%$ remplissent le nœud 2, tandis que les cas $X_{1,t} > 7\%$, $X_{2,t} > 5\%$ se retrouvent dans le nœud 3.

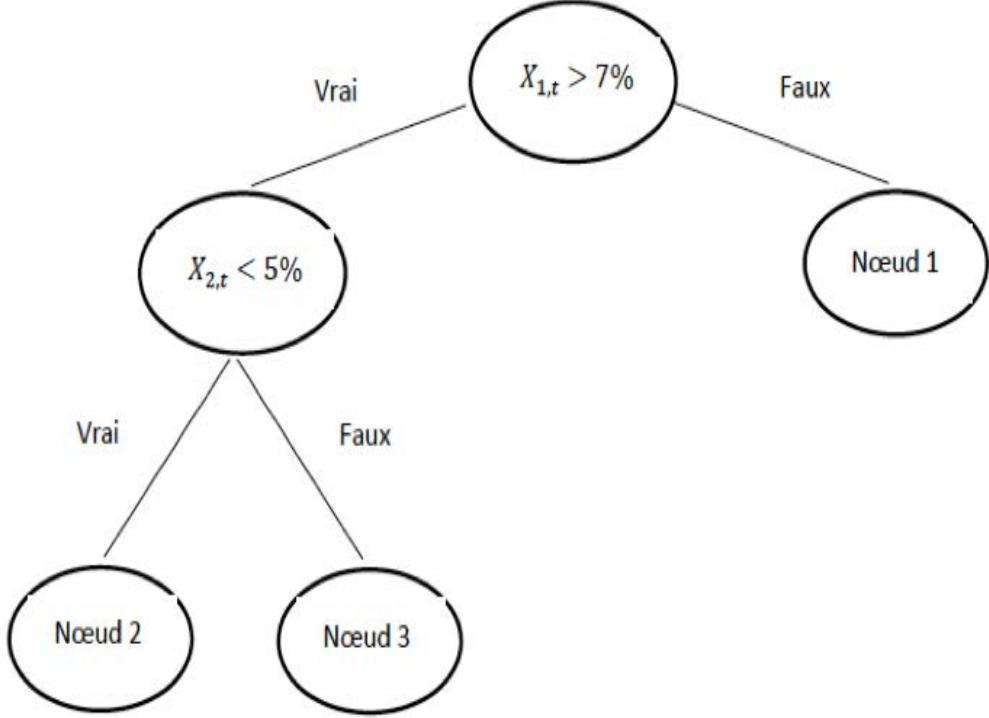


FIGURE 4: Exemple de régression par arbres

Enfin, les prévisions des observations dans chaque partition sont définies comme la moyenne de la variable dépendante parmi les observations de cette partition. Formellement, la prévision d'un arbre avec B nœuds terminaux (partitions) et de profondeur L s'écrit

$$g(X_t) = \sum_{b=1}^B c_b \mathbf{1}_{\{X_t \in P_b(L)\}}, \quad (18)$$

où chaque partition est le produit de jusqu'à L fonctions indicatrices des prédicteurs. La constante associée au nœud b , c_b , est la moyenne de la cible pour les observations incluses dans ce nœud. L'exemple de la figure 4 peut aussi s'écrire comme une régression avec variables binaires

$$g(X_t) = c_1 \mathbf{1}_{\{X_{1,t} < 7\%}\} + c_2 \mathbf{1}_{\{X_{1,t} > 7\%}\} \mathbf{1}_{\{X_{2,t} < 5\%}\} + c_3 \mathbf{1}_{\{X_{1,t} > 7\%}\} \mathbf{1}_{\{X_{2,t} > 5\%}\}.$$

Les prédicteurs et les seuils ici ont été choisis pour illustrer la situation où la prévision d'une cible macroéconomique dépend de l'état du cycle (probabilité de récession plus élevée si taux de chômage $> 7\%$) et de la position de la banque centrale (taux d'intérêt). Le choix des prédicteurs et des seuils est plutôt déterminé en optimisant une métrique d'évaluation de la prévision.

Il est clair de cet exemple que la régression par arbres peut approximer le vrai modèle $g^*(X_t)$ grâce à sa flexibilité et un grand nombre d'interactions possibles entre les prédicteurs. Par contre, cette flexibilité mène directement au sur-ajustement et l'estimation non-paramétrique

requiert beaucoup d'observations. La méthode souvent utilisée pour contrôler le sur-ajustement consiste à combiner les prévisions provenant de beaucoup d'arbres qui sont créés de façon aléatoire (d'où forêt aléatoire). Dans cette application le modèle RF procède en créant beaucoup d'arbres à partir des sous-échantillons aléatoires des observations. Par contre, cet astuce ne peut suffire si les prédicteurs sont très corrélés. Alors, une autre couche de randomisation consiste à choisir au hasard, pour chaque arbre, un sous-ensemble de M_{try} prédicteurs pour créer les branches. La prédiction finale est la moyenne des prévisions de tous les arbres aléatoires.

Plus formellement, la méthode Random Forests sera appliquée aux deux ensembles de prédicteurs : (i) observables $Z_t := [\{y_{t-j}\}_{j=0}^{p_y}, \{X_{t-j}\}_{j=0}^{p_x}]$; (ii) ARDI $Z_t := [\{y_{t-j}\}_{j=0}^{p_y}, \{F_{t-j}\}_{j=0}^{p_f}]$. L'idée derrière les méthodes d'arbres est de créer des régions dans l'espace engendré par Z_t et imposer que la prédiction pour cette zone est la valeur moyenne de la cible pour les observations incluses. Les zones sont raffinées successivement jusqu'à l'atteinte d'une règle d'arrêt. Chaque arbre produit la prévision avec la formule (18).

Plusieurs hyperparamètres sont à spécifier. Nombre d'arbres est généralement fixé à un grand nombre, dans cette application à 1000. M_{try} est fixé à $N/3$, mais pourrait aussi être déterminé par CV. Le nombre minimal d'observations dans chaque noeud terminal est fixé à 5. La profondeur de l'arbre (L) et le nombre de noeuds terminaux (B) sont ainsi implicitement fonction de ces hyperparamètres.

3.4 Forêts aléatoires macroéconomiques

Tel que mentionné plus haut, l'algorithme de l'arbre de régression vise implicitement à construire des variables dichotomiques et les forêts aléatoires offrent une façon astucieuse d'en combiner plusieurs pour réduire la variance de l'erreur de prévision. Par contre, rien ne nous empêche de modifier la prévision que fait un arbre pour les observations dans ses noeuds terminaux. En particulier, nous pourrions désirer utiliser une régression linéaire, plutôt qu'une constante dans les noeuds terminaux. C'est ce que Friedberg *et al.* (2018) et Goulet-Coulombe (2020) ont proposé de faire. La règle employée par les arbres sera donc modifiée :

$$\min_{j \in \mathcal{J}^-, c \in \mathbb{R}} \left[\min_{\beta_1} \sum_{t|S_{j,t} \leq c} (y_t - X_t \beta_1)^2 + \lambda \|\beta_1\|_2^2 + \min_{\beta_2} \sum_{t|S_{j,t} > c} (y_t - X_t \beta_2)^2 + \lambda \|\beta_2\|_2^2 \right] \quad (19)$$

où S_t est l'ensemble de prédicteurs considérés, \mathcal{J} est l'ensemble de leurs indices, $X_t \subseteq S_t$ et $\mathcal{J}^- \subset \mathcal{J}$ est un sous-ensemble sélectionné aléatoirement. Cette formulation est une généralisation de Friedberg *et al.* (2018) où X_t et S_t ne sont pas nécessairement équivalents. Notez que les arbres des forêts aléatoires mentionnées plus haut impose $\lambda = 0$ et $X_t = 1$, c.-à-d. qu'on ne prévoit qu'avec la moyenne dans chaque noeud terminal pour un arbre donné.

Derrière cette modification simple se cache une motivation proprement économique. Dans le contexte de séries temporelles, les noeuds terminaux d'un arbre identifient des périodes à partir des variables qu'il utilise. Il y a ici l'idée d'un modèle aux paramètres changant dans le temps suivant l'évolution de variables d'états, soit

$$\begin{aligned} y_t &= X_t \beta_t + \epsilon_t \\ \beta_t &= F(S_t; \mathbf{c}). \end{aligned} \tag{20}$$

Pour voir comment l'application récursive de (19) est liée au modèle (20), [Goulet-Coulombe \(2020\)](#) note que d'une façon générale, un arbre fournit des poids (*kernel weights*) qui peuvent être employés dans une régression pondérée et pénalisée. Spécifiquement, soit $L_m(x_0)$ un noeud terminal, $|L_m(x_0)|$ le nombre d'observations dans ce noeud et, M , le nombre de noeuds terminaux. Nous alors le problème suivant :

$$\forall t \in \{1, \dots, T\} \quad \beta_t := \underset{\beta}{\operatorname{argmin}} \left\{ \sum_{\tau=1}^T \alpha_t(S_\tau) (Y_\tau - X_\tau \beta_\tau)^2 + \lambda \|\beta_t\|_2^2 \right\} \tag{21}$$

$$\text{où } \alpha_t(x_0) = \frac{1}{M} \sum_{m=1}^M \frac{\mathbb{I}(X_t \in L_m(x_0))}{|L_m(x_0)|}. \tag{22}$$

Cette régression utilise des sous-ensembles d'observations potentiellement différents à chaque période, ce qui revient à dire que les paramètres évoluent dans le temps suivant des changements dans les variables d'états. [Goulet-Coulombe \(2020\)](#) propose ensuite de se pencher sur l'*a priori* implicite derrière cette formulation. Si nous présumons que $\beta_t = 0$, la pénalité Ridge est correct d'un point vue bayésien. Par contre, en macroéconomie, il est plus typique de supposer que $\beta_t = \beta_{t-1} + u_t$ où u_t est un bruit blanc faible. Dit autrement, l'*a priori* en macroéconomie est que les paramètres présentent une évolution lisse (*smooth*). [Goulet-Coulombe \(2020\)](#) exploite cette idée en modifiant légèrement la règle de brachement (*splitting rule*) des arbres (19). On peut penser que (19) impose un poids $w(t, \zeta)$ extrêmement simple de 1 aux observations incluses dans un noeud et de 0 aux observations exclues. Une autre façon de faire est d'inclure partiellement les observations voisines en leur donnant des poids fractionnaires qui diminuent avec l'éloignement. Si nous appelons \mathcal{S} , le sous-ensemble d'observations utilisées par un arbre,

alors les poids sont donnés par :

$$w(t, \zeta) = \begin{cases} 1 & t \in \mathcal{S} \\ \zeta & (\mathcal{S} + 1 \cup \mathcal{S} - 1) \setminus \mathcal{S} \\ \zeta^2 & t \in (\mathcal{S} + 2 \cup \mathcal{S} - 2) \setminus (\mathcal{S} \cup (\mathcal{S} + 1 \cup \mathcal{S} - 1)) \\ 0 & \text{sinon} \end{cases} \quad (23)$$

où $\zeta \in (0, 1)$ est un hyperparamètre. Nous pouvons maintenant réécrire la règle de branchement (19) :

$$\mathcal{S}_1(j, c) := \{t | S_{j,t} \geq c\} \text{ et } \mathcal{S}_2(j, c) := \{t | S_{j,c} > c\} \quad (24)$$

$$\mathcal{S}_i^{RW}(j, c) := \mathcal{S}_i(j, c) \cup [\mathcal{S}_i(j, c) + 1 \cup \mathcal{S}_i(j, c) - 1] \cup [\mathcal{S}_i(j, c) + 2 \cup \mathcal{S}_i(j, c) - 2] \quad (25)$$

$$\begin{aligned} & \min_{j \in \mathcal{J}^-, c \in \mathbb{R}} \left[\min_{\beta_1} \sum_{t \in \mathcal{S}_1^{RW}(j, c)} w(t, \zeta) (y_t - X_t \beta_1)^2 + \lambda \|\beta_1\|_2^2 + \right. \\ & \quad \left. \min_{\beta_2} \sum_{t \in \mathcal{S}_2^{RW}(j, c)} w(t, \zeta) (y_t - X_t \beta_2)^2 + \lambda \|\beta_2\|_2^2 \right]. \end{aligned} \quad (26)$$

Remarquez que nous retrouvons les forêts aléatoires originales si nous construisons les arbres en imposant $X_t = 1$, $\lambda = 0$ et $\zeta = 0$. C'est la formulation que nous appliquons dans le présent rapport.

Selon le choix de X_t , S_t et de l'algorithme de combinaison des arbres que nous choisissons, nous pouvons créer plusieurs versions des forêts aléatoires macroéconomiques. Similairement, la façon de combiner les arbres employées par l'algorithme des forêts aléatoires original n'est pas unique. Plus spécifiquement, les forêts aléatoires essaient d'exploiter des prévisions simples et peu corrélées en utilisant des sous-échantillons aléatoires et des sous-ensembles de prédicteurs pour chaque arbre. Une autre façon de faire est avancée par [Geurts et al. \(2006\)](#), les arbres extrêmement aléatoires (*extremely randomized trees*). Au lieu d'utiliser des sous-échantillons aléatoires, une composante aléatoire est introduite dans la règle de branchement.

3.5 Régression par vecteurs supports

Comme mentionné dans l'introduction, la particularité des régressions par vecteurs supports (*support vector regression* (SVR)) est un changement de la fonction de perte minimisée lors

de l'estimation. Formellement, le problème primal d'un ϵ -SVR est donné par

$$\min_{\gamma} \frac{1}{2} \gamma' \gamma + C \left(\sum_{t=1}^T (\xi_t + \xi_t^*) \right) \quad (27)$$

$$\begin{cases} y_{t+h} - \gamma' \phi(Z_t) - \alpha \leq \bar{\epsilon} + \xi_t \\ \gamma' \phi(Z_t) + \alpha - y_{t+h} \leq \bar{\epsilon} + \xi_t^* \\ \xi_t, \xi_t^* \geq 0 \end{cases}$$

où Z_t est encore notre ensemble de prédicteurs, $\phi : \mathbb{R}^{\dim(Z_t)} \rightarrow \mathbb{R}$, $(C, \bar{\epsilon})$ sont des hyperparamètres et (ξ_t, ξ_t^*) sont des variables d'écart (*slack variables*). Nous obtenons le cas linéaire en imposant que ϕ est la fonction identité.

Définissant les multiplicateurs de Lagrange λ_j, λ_j^* associées aux deux premières contraintes, Smola et Schölkopf (2004) montrent que les poids optimaux and les prévisions optimales sont données par

$$\hat{\gamma} = \sum_{j=1}^T (\lambda_j - \lambda_j^*) \phi(Z_j) \quad (28)$$

$$\hat{E}(y_{t+h}|Z_t) = \hat{c} + \sum_{j=1}^T (\lambda_j - \lambda_j^*) \phi(Z_j) \phi(Z_j) = \hat{c} + \sum_{j=1}^T K(Z_j, Z_t) \quad (29)$$

où $K(Z_j, Z_t)$ est une fonction noyau (*kernel function*). Notez que nous utilisons un noyau gaussien (*gaussian kernel* ou encore *radial basis function kernel*) pour introduire des non-linéarités :

$$K(Z_j, Z_t) := \exp \left(-\frac{\|Z_j - Z_t\|^2}{2\sigma^2} \right), \quad (30)$$

où σ^2 est un hyperparamètre.

Nous pouvons maintenant discuter clairement de la fonction de perte particulière employée par les SVR. Le long des valeurs prédites dans l'échantillon d'estimation, il y a une borne supérieure $\hat{E}(y_{t+h}|Z_t) + \bar{\epsilon}$ et une borne inférieure $\hat{E}(y_{t+h}|Z_t) - \bar{\epsilon}$ qui définissent un tube d'insensibilité. Soit $e_{t+h} := \hat{E}(y_{t+h}|Z_t) - y_{t+h}$ l'erreur de prévision au temps $t + h$, alors nous avons la fonction de perte suivante :

$$L_{\bar{\epsilon}}(e_{t+h}) := \begin{cases} 0 & \text{si } |e_{t+h}| \leq \bar{\epsilon} \\ |e_{t+h}| - \bar{\epsilon} & \text{sinon} \end{cases}. \quad (31)$$

La figure 5 compare les fonctions de perte quadratique et $\bar{\epsilon}$ -insensible. La zone d'insensibilité est déterminée par l'hyperparamètre $\bar{\epsilon}$, tandis que le coût à l'extérieur de cette zone est fonction des variables d'écart.

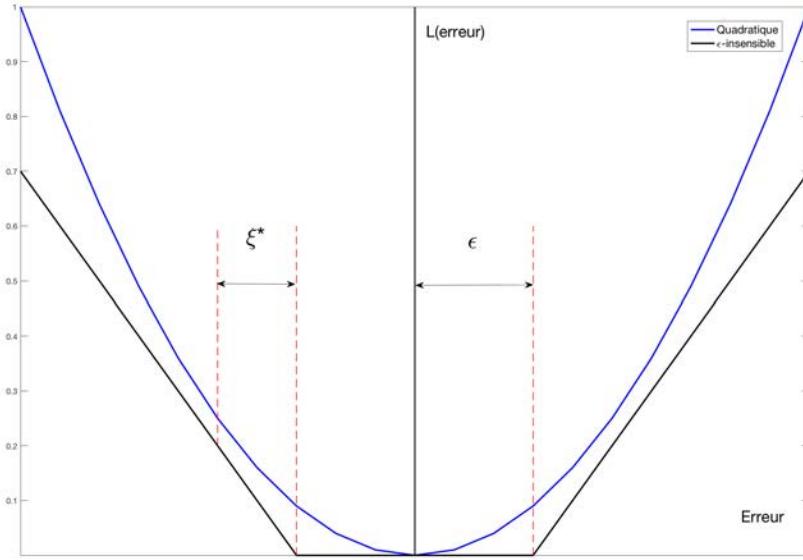


FIGURE 5: Fonction de perte $\bar{\epsilon}$ -insensible

C'est cette insensibilité à une zone autour de la valeur prévue que Smola et Schölkopf (2004) appellent la parcimonie (*sparsity*) du SVR. En effet, seulement une partie des observations contribuent concrètement à la valeur prédite.⁵

3.6 Réseaux de neurones

La dernière classe de modèles considérés sont les réseaux de neurones (*Neural Networks* ou NN). Comme mentionné dans l'introduction, les premières tentatives de prévision macroéconomique avec ces modèles ont été peu fructueuses, probablement en raison de leur structure jadis très simple et le manque de puissance computationnelle et de données (Swanson et White, 1997). De nos jours, ce sont les modèles les plus prometteurs dans la plupart des domaines d'application d'apprentissage automatique. Leur utilisation en prévision macroéconomique est encore très sommaire en raison de manque d'observations puisque ce sont les structures extrêmement paramétrées (des milliers de paramètres à estimer et beaucoup d'hyperparamètres à choisir) et avec fonction objective non-convexe et habituellement nonlinéaire.

Inspirés du fonctionnement du cerveau humain, ceux-ci sont en fait une succession de couches cachées, chacune contenant un certain nombre de neurones. Dans le cas qui nous intéresse, comme démontré dans la figure 6, les neurones entre les couches sont tous inter-reliés.

5. Remarquez que le tube peut être assez large pour exclure toutes les observations, sous quel cas le SVR prévoit la moyenne historique. Ceci se voit en notant (27) revient à minimiser la norme quadratique si $\xi_t, \xi_t^* = 0 \forall t$.

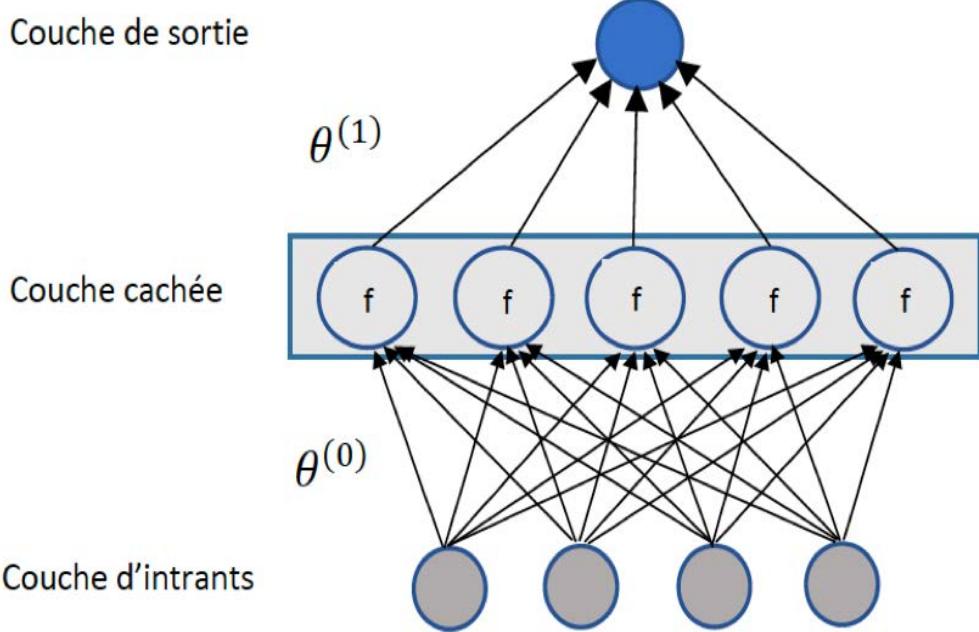


FIGURE 6: Exemple d'un réseau de neurones

Chaque θ représente le poids accordé aux extrants (*output*) de la couche précédente. Ce type de réseaux se nomme perceptron multicouche (*multilayer perceptron*, MLP). Il consiste en une couche d'intrants suivie par une ou plusieurs couches cachées qui transforment les combinaisons linéaires des différents intrants à l'aide d'une fonction d'activation f (souvent nonlinéaire), puis termine avec une couche de sortie qui agrège l'information obtenue des couches précédentes. Par exemple, dans le cas de la figure 6 le NN est représenté par une couche de quatre intrants tous connectés aux cinq neurones de la couche cachée, puis termine par la mise en commun de l'information dans la couche de sortie.

Les réseaux de neurones apprennent à l'aide d'un algorithme de rétropropagation. Cet algorithme permet d'effectuer une mise à jour des poids et des biais du modèle selon les erreurs de prévisions obtenues à la couche finale. Lors de l'initialisation, les poids des modèles sont établis de manière aléatoire et $\hat{y}_{t+h|t}$ est prédit à l'aide de ces poids de départ. Les poids de la couche de sortie sont d'abord mis à jour selon l'erreur de prévision obtenue, puis à leur tour les poids de l'avant-dernière couche ainsi de suite jusqu'au poids de la couche d'intrants. Un cycle de la couche de sortie à la couche d'intrant est appelé cycle d'apprentissage (*epochs*). Le nombre d'epochs constitue un hyperparamètre du réseau, celui-ci sera fixé à un maximum de 1000. Cependant, un critère d'arrêt basé sur la valeur de l'erreur quadratique moyenne sera utilisé afin d'éviter les problèmes de sur-apprentissage.

La fonction d'activation est un morceau important dans l'architecture des NN. Dans cette application c'est ReLU (*Rectified Linear Unit*) soit $\sigma(x) = \max(0, x)$. Celle-ci permet la réduction du nombre de neurones actifs et permet donc une estimation plus rapide (Gu et al., 2019).

Pour écrire formellement la prévision à l'aide du réseau de neurones, soit $M^{(l)}$ le nombre de neurones dans chaque couche $l = 1, \dots, L$, et $z_m^{(l)}$ l'output de chaque neurone m dans la couche l , avec $z^{(l)} = \left(1, z_1^{(l)}, \dots, z_{N^{(l)}}^{(l)}\right)'$. La couche d'intrants est initialisée avec les observations. L'output de couche cachée $l > 0$ est

$$z^{(l)} = \max(0, z^{(l-1)'} \theta^{(l-1)}),$$

et la prévision est obtenue par la couche finale est

$$y_{t+h|t} = z^{(L-1)'} \theta^{(L-1)}.$$

Le nombre de couches cachées et de neurones représente des hyperparamètres importants des NNs. Le nombre de paramètres à estimer augmente très rapidement avec ceux-ci, ce qui augmente considérablement les temps de calcul. Comme dans [Gu et al. \(2019\)](#), une architecture en "pyramide" est souvent privilégiée. Ici, un maximum de trois couches cachées et 32 neurones seront considérés. Pour chaque couche cachée, le nombre de neurones est divisé par deux par rapport aux nombres de la couche précédente. Par exemple, un réseau avec deux couches cachées contiendra respectivement 32 et 16 neurones.

Dans l'application, le choix de la combinaison optimale des hyperparamètres est effectué par validation croisée une seule fois pour chaque horizon sur la période 1981Q1 à 2005Q2-h. Une pénalisation de type LASSO sur la valeur des poids θ est utilisée afin d'éviter les problèmes liés au sur-ajustement. La valeur optimale de λ est sélectionnée par CV.

Le réseau de neurones récurrents (*Recurrent Neural Network* ou RNN) est également considéré. Ces réseaux peuvent conserver de l'information en mémoire. De cette manière, les RNN peuvent profiter de la structure temporelle des données. C'est ce qui les rend différents des réseaux de neurones "feed forward" comme le MLP. En plus de tenir compte des intrants, il prend également ses décisions sur un certain nombre d'états passés (*hidden states*). La prévision est ainsi calculée séquentiellement pour chaque valeur retardée de l'intrant. Ainsi, pour chaque retard cet intrant intermédiaire sert d'intrant supplémentaire pour la prévision des hidden states. Le modèle RNN contient donc autant de hidden states qu'il y a de retards dans les intrants.

En particulier, le réseau de neurones récurrents à mémoire court terme et long terme (*Long Short-Term Memory* ou LSTM) est utilisé [Hochreiter et Schmidhuber \(1997\)](#). Ce qui est intéressant avec l'utilisation de cellules LSTM comparativement aux RNN traditionnels, c'est qu'elles peuvent décider de garder ou non certaines informations passées grâce à des portes (*gates*) ([Chung et al., 2014](#)). La cellule LSTM contient essentiellement trois portes : input gate, output gate et forget gate. Ces portes peuvent apprendre durant l'entraînement quelles sont les informations provenant des états précédents qui sont pertinentes pour les conserver et ceux qu'il faut oublier. L'input gate de son côté fait la mise à jour de l'état actuel de la cellule en y ajoutant de la nouvelle information. La forget gate décide de ce qui est à conserver des états

précédents. Puis, l'output gate renvoie le prochain état qui est la combinaison de la nouvelle information et de l'état précédent. Ce cycle est répété de manière récursive autant de fois qu'il y a de retards dans l'intrant. Comme [Cook et Hall \(2017\)](#), une combinaison des deux types de réseaux est également considérée. Ainsi, la première couche cachée est un réseau de type LSTM, puis les autres couches cachées sont d'architecture MLP. Les hyperparamètres sont aussi les mêmes que pour les autres modèles. De point vue computationnelle, l'algorithme d'apprentissage utilisé est Adam (*adaptive moment estimation algorithm*), avec le taux d'apprentissage fixé à 0.001 et la patience à 5.

Plus formellement, il y aura trois types de réseaux de neurones qui contiennent chacun la même architecture ‘‘pyramidale’’. Il y a les réseaux MLP (Dense) qui sont les réseaux multi-couches interconnectées d’écrit plus haut. Puis, il y a les réseaux récurrent (LSTM) qui tiennent compte de l’aspect temporel des données. Ceux-ci sont constitués de couches cachées LSTM placées une à la suite l’autre. Cependant, ces modèles se terminent par une couche de sortie interconnectée afin de convertir l’output dans le bon format. Finalement le dernier type de réseaux considéré est une combinaison de ces deux derniers (LSTM-Dense). Ainsi, ces réseaux sont constitués dans un premier temps d’une première couche cachée de type LSTM, puis les suivantes sont des couches cachées interconnectées comme celles des MLP.

3.7 Combinaison de prévisions

La littérature en prévision macroéconomique constate depuis longtemps que l’agrégation des prédictions individuelles est une méthode très robuste ([Bates et Granger, 1969](#); [Hendry et Clements, 2004](#)). Il existe bien sûr de nombreuses façons de combiner les prévisions, et plusieurs seront considérées ici.

La simple moyenne (*Equal-Weighted Forecasts* ou AVRG) est la méthode la plus utilisée où les prévisions de J modèles sont combinées à l’aide des poids égaux $\omega_{jt} = 1/J$:

$$\hat{y}_{t+h|t} = \frac{1}{J} \sum_{j=1}^J \hat{y}_{t+h|t}^{(j)}. \quad (32)$$

La moyenne est toutefois sensible aux valeurs extrêmes, alors plusieurs alternatives sont proposées. La première, (*Trimmed Average* ou T-AVRG) enlève les prévisions les plus extrêmes en ordonnant les valeurs des prédictions des plus petites aux plus grandes $(\hat{y}_{t+h|t}^{(1)} \leq \dots \leq \hat{y}_{t+h|t}^{(J)})$. Ensuite, une proportion ν est supprimée des deux côtés :

$$\hat{y}_{t+h|t} = \frac{1}{J(1-2\nu)} \sum_{i=\lceil \nu J \rceil}^{\lfloor (1-\nu)J \rfloor} \hat{y}_{t+h|t}^{(i)}. \quad (33)$$

où $\lceil \nu J \rceil$ est le nombre entier immédiatement supérieur à νJ et $\lfloor (1 - \nu)J \rfloor$ est le nombre entier immédiatement inférieur à $(1 - \nu)J$. ν est un hyperparamètre et sera fixé à 15%.

Une solution plus flexible consiste à produire les poids qui dépendent de la performance historique des modèles (Diebold et Pauly, 1987). Ici, l'approche de Stock et Watson (2004) est utilisée (*Inversely Proportional Average* ou IP-AVRG). Le poids sur la $j^{\text{ième}}$ prévision est

$$\omega_{it} = \frac{m_{it}^{-1}}{\sum_{j=1}^J m_{jt}^{-1}},$$

où m_{jt} est l'erreur quadratique moyenne escomptée du modèle j :

$$m_{it} = \sum_{s=T_0}^{t-h} \rho^{t-h-s} (y_{s+h} - \hat{y}_{s+h|s}^{(i)})^2,$$

et ρ est le facteur d'escompte (hyperparamètre). Ici, deux valeurs seront considérées : $\rho = 1$ et $\rho = 0.8$.

Finalement, la simple médiane peut aussi être utilisée :

$$\hat{y}_{t+h|t} = \text{median} \left(\hat{y}_{t+h|t}^{(i)} \right)_{i=1}^J.$$

4 Application

Nous appliquons les méthodes présentées précédemment à la prévision de l'activité macroéconomique au Québec et au Canada.

4.1 Variables à prévoir

Le tableau 1 résume les variables d'activité économique à prévoir. Le PIB, la consommation et l'investissement sont exprimés en termes réels. Lorsque nécessaire, les séries temporelles ont été désaisonnalisées. Cette liste de 16 cibles contient les variables décrivant plusieurs aspects de l'activité économique qui sont habituellement considérées dans la littérature.

Variables	Canada	Québec	Transformation
Produit intérieur brut	PIB-CA	PIB-QC	Taux de croissance
Formation brute de capital fixe	I-CA	I-QC	Taux de croissance
Consommation finale	C-CA	C-QC	Taux de croissance
Emploi total	EMP-CA	EMP-QC	Taux de croissance
Taux de chômage	CHO-CA	CHO-QC	Première différence
Mises en chantier	HOUS-CA	HOUS-QC	Taux de croissance
Indice des prix à la consommation	IPC-CA	IPC-QC	Taux de croissance
Production industrielle	PI-CA		Taux de croissance
Taux de change US/CA	TC-CA		Taux de croissance

TABLE 1: Liste des variable à prévoir

4.2 Ensembles de prédicteurs

Les données pour cette application proviennent de deux sources. Premièrement, les variables canadiennes sont disponibles dans la grande base de données construite par [Fortin-Gagnon et al. \(2018\)](#) contenant 349 séries temporelles trimestrielles observées entre 1981Q1 et 2019Q1.⁶ Elle est notée X_t^{CA} . Différents secteurs d'activités économiques sont représentés : production, marché immobilier, manufacture, ventes, agrégats monétaires, marché de crédit, taux d'intérêt, commerce international, prix et marché financier.

La deuxième base de données, notée X_t^{US} , contient 248 variables macroéconomiques américaines et provient de [McCracken et Ng \(2020\)](#).⁷ La composition sectorielle est semblable à la base de données canadienne et la même période est couverte. Au total, en enlevant les doublons, il y a 590 candidats prédicteurs exogènes.

Dans cette application nous allons considérer deux ensemble d'information afin de documenter l'importance des données américaines. Le premier ensemble consiste seulement des données canadiennes, $X_t = X_t^{CA}$. Le deuxième combine les deux. Dans les modèles du type ARDI, sans et avec le traitement nonlinéaire, les facteurs sont pris séparément X_t^{CA} et de X_t^{US} . Dans les régressions pénalisées et forêts aléatoires utilisant toutes les observations, $X_t = \{X_t^{CA}, X_t^{US}\}$. En plus, si 4 retards de la cible et des prédicteurs sont considérés, Z_t contiendra 2364 éléments. Il est donc clair que nous sommes dans le contexte de données massives et que la régularisation est nécessaire puisque seulement 149 périodes temporelles sont disponibles.

6. Les données se trouvent ici : http://www.stevanovic.uqam.ca/DS_LCMD.html. La version *LCDMA_Q_November_2019* a été utilisée dans ce travail.

7. Les données se trouvent ici : <https://research.stlouisfed.org/econ/mccracken/fred-databases/>. La version 2019 – 12 a été utilisée.

4.3 Modèles

Nous utiliserons de nombreuses spécifications des modèles de prévision décrits dans la section 3. Le tableau 2 résume tous les modèles employés en précisant les ensembles de prédicteurs et l’algorithme sous-jacents. Le nombre de facteurs, K , est le même pour les deux ensembles de données.

TABLE 2: Modèles de prévision

Modèle	Prédicteurs	Algorithme
Modèles de référence		
AR,BIC	$\{y_{t-j}\}_{j=0}^{p_y=p_y^{BIC}}$	MCO
ARDI,BIC	$\{y_{t-j}\}_{j=0}^{p_y=p_y^{BIC}}, \{F_{t-j}\}_{j=0}^{p_f=p_f^{BIC}}], K^{BIC}$	PCA et MCO
Régressions pénalisées		
Ridge	$\{y_{t-j}\}_{j=0}^{p_y=4}, \{X_{t-j}\}_{j=0}^{p_x=4}$	Ridge, λ par CV
Lasso	$\{y_{t-j}\}_{j=0}^{p_y=4}, \{X_{t-j}\}_{j=0}^{p_x=4}$	Lasso, λ par CV
Elastic-Net	$\{y_{t-j}\}_{j=0}^{p_y=4}, \{X_{t-j}\}_{j=0}^{p_x=4}$	EN, λ, α par CV
Adaptive-Lasso	$\{y_{t-j}\}_{j=0}^{p_y=4}, \{X_{t-j}\}_{j=0}^{p_x=4}$	Lasso, λ par CV
ARDI,Ridge	$\{y_{t-j}\}_{j=0}^{p_y=4}, \{F_{t-j}\}_{j=0}^{p_f=4}], K = 3$	PCA-Ridge, λ par CV
ARDI,Lasso	$\{y_{t-j}\}_{j=0}^{p_y=4}, \{F_{t-j}\}_{j=0}^{p_f=4}], K = 3$	PCA-Lasso, λ par CV
ARDI,Elastic-Net	$\{y_{t-j}\}_{j=0}^{p_y=4}, \{F_{t-j}\}_{j=0}^{p_f=4}], K = 3$	PCA-EN, λ par CV
ARDI,Adaptive-Lasso	$\{y_{t-j}\}_{j=0}^{p_y=4}, \{F_{t-j}\}_{j=0}^{p_f=4}], K = 3$	PCA-Lasso, λ par CV
Ridge-MAF	S_t	PCA-Ridge, λ par CV
LASSO-MAF	S_t	PCA-Lasso, λ par CV
ELAS-MAF	S_t	PCA-EN, λ par CV
Régressions régularisées par sous-ensembles complets		
T-CSR,10	$\{y_{t-j}\}_{j=0}^{p_y=4}, X_t]$	Hard thresholding et MCO
T-CSR,20	$\{y_{t-j}\}_{j=0}^{p_y=4}, X_t]$	Hard thresholding et MCO
CSR-R,10	$\{y_{t-j}\}_{j=0}^{p_y=4}, X_t]$	Ridge, λ par Hoerl et Kennard (1970)
CSR-R,20	$\{y_{t-j}\}_{j=0}^{p_y=4}, X_t]$	Ridge, λ par Hoerl et Kennard (1970)
Régressions à vecteurs de support		
NL-SVRARDI	$\{y_{t-j}\}_{j=0}^{p_y=4}, \{F_{t-j}\}_{j=0}^{p_f=4}], K = 3$	SVR avec noyau RBF, CV
L-SVRARDI	$\{y_{t-j}\}_{j=0}^{p_y=4}, \{F_{t-j}\}_{j=0}^{p_f=4}], K = 3$	SVR avec noyau linéaire, CV
Forêts d’arbres aléatoires		
RFARDI	$\{y_{t-j}\}_{j=0}^{p_y=4}, \{F_{t-j}\}_{j=0}^{p_f=4}], K = 3$	Random Forest
RF-MAF	S_t	Random Forest
RF-CSF	$\{y_{t-j}\}_{j=0}^{p_y=8}, \{F_{t-j}\}_{j=0}^{p_f=8}], K = 5$	Random Forest
RF-X	$\{y_{t-j}\}_{j=0}^{p_y=8}, \{F_{t-j}\}_{j=0}^{p_f=8}], K = 5$	Random Forest
RF-X-CSF	$\{y_{t-j}\}_{j=0}^{p_y=8}, \{F_{t-j}\}_{j=0}^{p_f=8}], K = 5, \{X_{t-j}\}_{j=0}^8$	Random Forest
LLF-CSF	$\{y_{t-j}\}_{j=0}^{p_y=8}, \{F_{t-j}\}_{j=0}^{p_f=8}], K = 5$	Friedberg <i>et al.</i> (2018)
ARERT	S_t	Extremely Randomized Trees dans Goulet-Coulombe (2020). Partie linéaire est AR(2).
ARDIERT	S_t	Extremely Randomized Trees dans Goulet-Coulombe (2020). Partie linéaire est ARDI($p_y = 2, K = 2, p_f = 1$)
EOTB-ERT	S_t	Extremely Randomized Trees and data-driven selection of the linear part. dans Goulet-Coulombe (2020)
ARRF	S_t	Random Forest dans Goulet-Coulombe (2020). Partie linéaire est AR(2).
ARDIRF	S_t	Random Forest dans Goulet-Coulombe (2020). Partie linéaire est ARDI($p_y = 2, K = 2, p_f = 1$)
EOTB-MRF	S_t	Random Forest dans Goulet-Coulombe (2020)
ERT-MAF	S_t	Extremely Randomized Trees dans Goulet-Coulombe (2020)
Réseau de neurones		
LSTM-Dense-AR	$\{y_{t-j}\}_{j=0}^{p_y=4}$	NN avec couches LSTM et MLP
LSTM-AR	$\{y_{t-j}\}_{j=0}^{p_y=4}$	NN avec couches LSTM
Dense-AR	$\{y_{t-j}\}_{j=0}^{p_y=4}$	NN avec couches MLP
LSTM-Dense-ARDI	$\{y_{t-j}\}_{j=0}^{p_y=4}, \{F_{t-j}\}_{j=0}^{p_f=4}], K = 3$	NN avec couches LSTM et MLP
LSTM-ARDI	$\{y_{t-j}\}_{j=0}^{p_y=4}, \{F_{t-j}\}_{j=0}^{p_f=4}], K = 3$	NN avec couches LSTM
Dense-ARDI	$\{y_{t-j}\}_{j=0}^{p_y=4}, \{F_{t-j}\}_{j=0}^{p_f=4}], K = 3$	NN avec couches MLP
LSTM-Dense	$\{y_{t-j}\}_{j=0}^{p_y=4}, \{X_{t-j}\}_{j=0}^{p_x=4}$	NN avec couches LSTM et MLP
LSTM	$\{y_{t-j}\}_{j=0}^{p_y=4}, \{X_{t-j}\}_{j=0}^{p_x=4}$	NN avec couches LSTM
Dense	$\{y_{t-j}\}_{j=0}^{p_y=4}, \{X_{t-j}\}_{j=0}^{p_x=4}$	NN avec couches MLP
Combinaisons de prévisions		
AVRG	Prévisions	Moyenne simple
Médiane	Prévisions	Médiane
T-AVRG,0.1	Prévisions	Moyenne pondérée
T-AVRG,0.2	Prévisions	Moyenne pondérée
IP-AVRG,1	Prévisions	Moyenne pondérée
IP-AVRG,0.95	Prévisions	Moyenne pondérée

5 Résultats

Comme indiqué à la section 2.4, nous allons comparer les modèles selon deux métriques : erreur quadratique moyenne et le test de signe prédictif.

5.1 Performance en termes de l'erreur quadratique moyenne

Analyse agrégée En premier lieu, nous analysons la performance moyenne par groupe de modèles tel que classifié dans le tableau 2. Pour ce faire, soit $R_{t,h,v,m}^2 \equiv 1 - \frac{\hat{e}_{t,h,v,m}^2}{\frac{1}{T} \sum_{t=1}^T (y_{v,t+h} - \bar{y}_{v,h})^2}$ le pseudo- R^2 pour la période t , l'horizon h , la variable à prédire v et le modèle m , avec \bar{y}_v la moyenne historique de la cible v . Comme dans Goulet-Coulombe *et al.* (2019), la régression suivante est effectuée

$$R_{t,h,v,m}^2 = \alpha + \psi_{t,h,v} + u_{t,h,v,m}, \quad (34)$$

où $\psi_{t,h,v}$ contient les effets fixes pour capter l'hétérogénéité propre au temps, variable à prévoir et à l'horizon de prévision. Les coefficients d'intérêt sont dans le vecteur α , une collection de variables indicatrices pour capter la performance de chaque groupe de modèles : régression pénalisées (RP), Régressions régularisées par sous-ensembles complets (CSR), régressions à vecteurs de support (SVR), forêts d'arbres aléatoires (RF), réseaux de neurones (NN) et combinaisons de prévisions (Comb.). Le groupe référence contient les modèles ARD et ARDI.

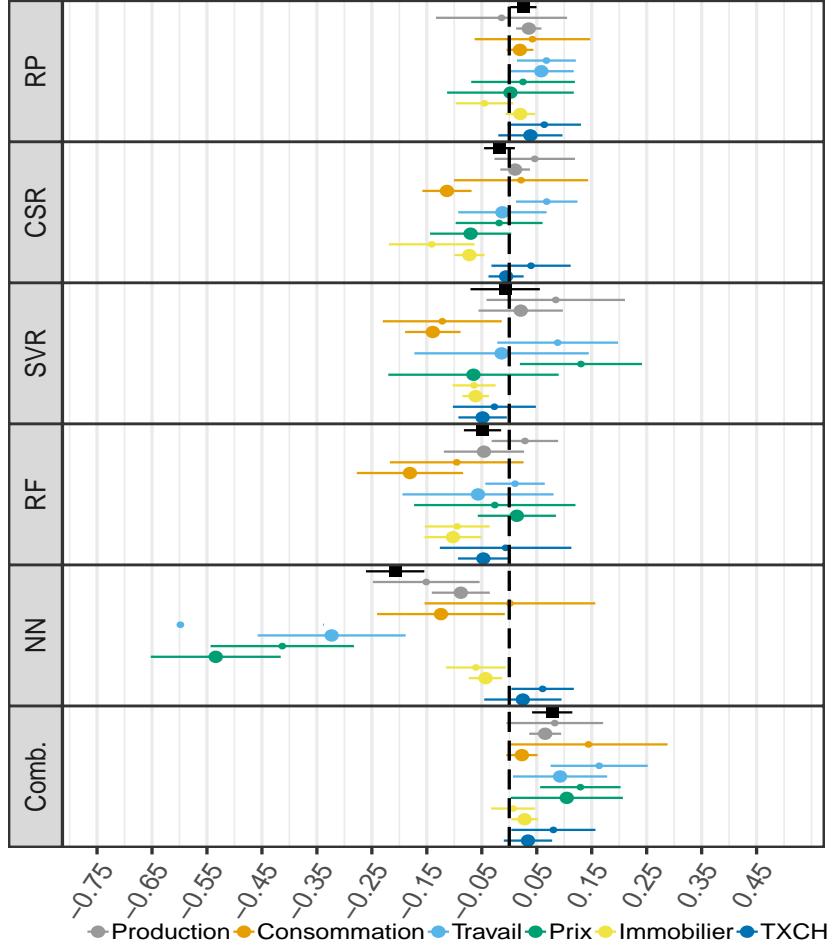
Donc, l'objectif est de tester si les modèles d'un groupe obtiennent une précision prédictive statistiquement différente par rapport au groupe de référence. Autrement dit, H_0 est $\alpha_i = 0$ pour le groupe i . Le signe et la valeur de $\hat{\alpha}_i$ sont aussi d'intérêt. Si par exemple $\hat{\alpha}_{RP} = 0.1$, ceci signifie que le groupe régressions pénalisées améliore le pseudo- R^2 de 10%. Puisque les modèles de référence sont plutôt de nature *économétrique* et que les autres groupes représentent différentes propositions *machine learning*, cette analyse permet aussi d'apprécier la valeur ajoutée de ML dans le contexte de prévision macroéconomique. En particulier, le coefficient $\alpha_{Comb.}$ teste l'effet marginal de la combinaison des prévisions de modèles ML. Il faut mentionner que cette analyse peut être affectée par une mauvaise performance d'un petit nombre de modèles à l'intérieur d'un groupe et donc cacher la capacité prédictive du meilleur modèle individuel. Nous analyserons les modèles individuellement dans les tableaux détaillés plus loin dans cette section.

Nous effectuons une série de régressions comme dans (34) mais avec différents niveaux de granularité afin de tester des hypothèses plus particulières. Les variables à prévoir sont regroupées par catégories suivantes : Production (PIB, Investissement et production industrielle) ; Consommation ; Travail (emploi et taux de chômage) ; Prix (IPC) ; Immobilier (mises en chantier) et TXCH (taux de change). La catégorie comprend les variables canadiennes et québécoises lorsque les deux disponibles. Les horizons sont également regroupés en : court (1 et 2 trimestres en avance) et long (4, 6 et 8 trimestres).

La figure 7 montre les résultats de l'analyse la plus agrégée considérée ici. Les groupes de variables cibles combinent les séries canadiennes et québécoises. Les modèles utilisant deux ensembles de prédicteurs, X_t^{CA} et $\{X_t^{CA}, X_t^{US}\}$, intitulés CAN et CAN+US respectivement, sont aussi combinés. Pour chaque groupe de modèles, la régression (34) est estimée pour chaque paire (catégorie de cibles, groupe d'horizons). Les estimés d'une catégorie de cibles sont indiqués par les couleurs de la légende. La grosseur du point représente le groupe d'horizons : petit pour courts et gros pour longs horizons. Le carré noir au début de chaque groupe de modèles représente l'estimé de la regression combinant toutes les variables cibles et tous les horizons.

Le groupe de régressions pénalisées (RP) affichent des résultats majoritairement positifs. En moyenne sur toutes les variables cibles et tous les horizons (carré noir), l'amélioration est plutôt modeste : 3% en termes de pseudo- R^2 mais dans certains cas cela monte à 7% comme pour la prévision à court terme des variables du marché de travail. Les grands gagnants de cette course sont les combinaisons de prévisions avec une amélioration moyenne de près de 8%, mais avec plusieurs performances à court terme de 15%. Ceci suggère que les modèles machine learning, lorsque combinés, améliorent la prévision des variables canadiennes et québécoises dans cet exercice. Le comportement similaire a été constaté par [Qiu et al. \(2020\)](#) également. Les grands perdants sont les réseaux de neurones (NN). Les résultats pour les régressions par sous-ensembles complets (CSR) et à vecteurs supports (SVR), et pour les forêts aléatoires (RF) affichent beaucoup d'hétérogénéité causant une performance moyenne près de zéro. L'analyse beaucoup plus granulaire sera effectuée plus loin dans cette section pour montrer qu'ils existent des modèles RF et NN qui performent le mieux pour certaines paires de cibles / horizons. Il ne faut pas oublier ici que les modèles de référence sont d'excellents modèles de prévision, en particulier ARDI qui connaît un grand succès depuis les années 2000. La tâche n'est donc pas facile pour les modèles ML.

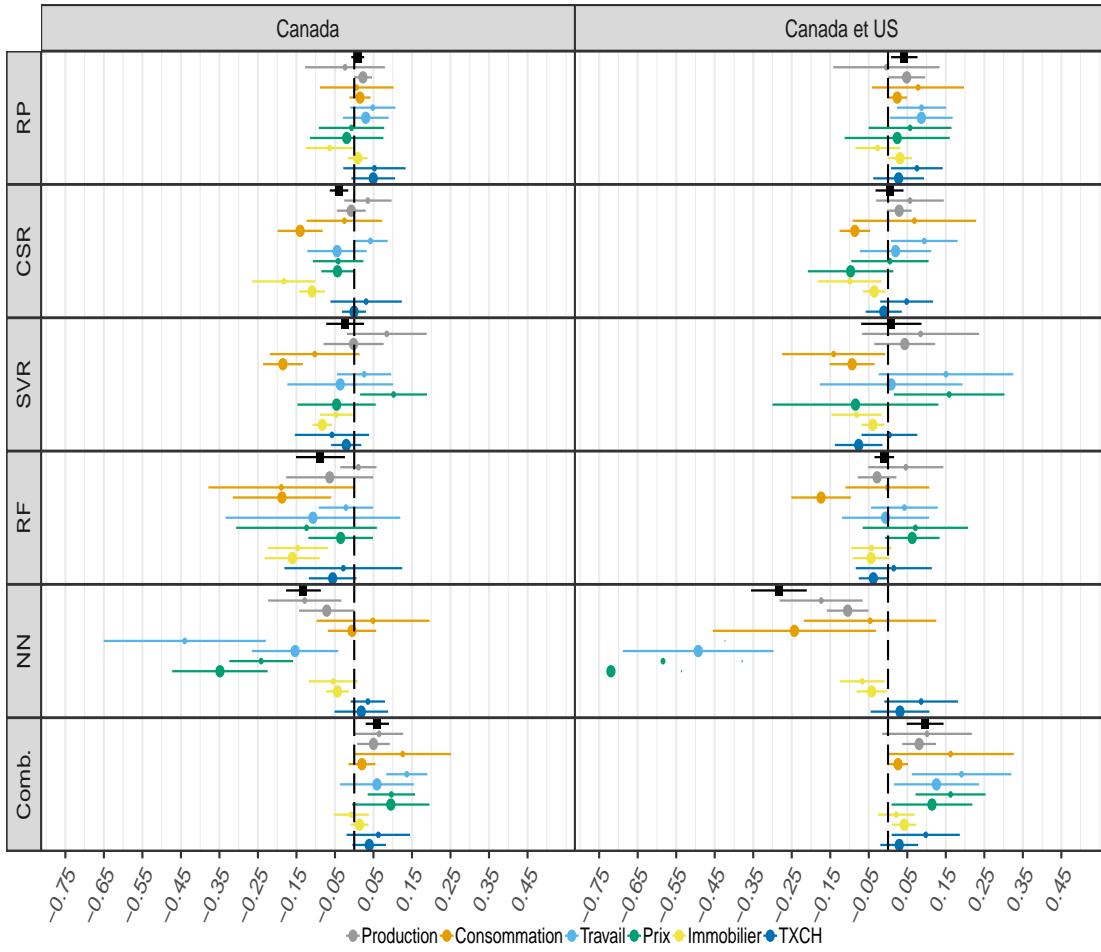
FIGURE 7: Précision prédictive moyenne des groupes de modèles ML



Les coefficients estimés de l'équation (34) sont rapportés pour chaque groupe de modèles, pour chaque paire (catégorie de cibles, groupe d'horizons). Les estimés d'une catégorie de cibles sont indiqués par les couleurs de la légende. La grosseur du point représente le groupe d'horizons : petit pour courts et gros pour longs horizons. Le carré noir représente l'estimé de la régression combinant toutes les variables cibles et tous les horizons. Les écarts-types de niveau 90% sont construits en tenant compte de l'hétéroskedasticité et de l'autocorrélation par la méthode de [Driscoll et Kraay \(1998\)](#).

Nous avons considérés deux ensembles de prédicteurs : canadiens et américains. La figure 8 montre la contribution des données américaines dans la performance prédictive moyenne. Pour ce faire, nous avons effectué les mêmes régressions que pour la figure 7 mais en considérant les deux ensembles d'information séparément. Il est force de constater que l'ajout des variables américaines dans les modèles ML est généralement bénéfique pour la performance prédictive. À titre d'exemple, l'effet marginal sur le pseudo- R^2 de considérer les combinaisons de prévisions passe de 6 à 10% en ajoutant les données US. L'exception est le groupe NN qui voit sa performance moyenne s'améliorer avec le plus petit ensemble de prédicteurs.

FIGURE 8: Précision prédictive moyenne : contribution des données américaines



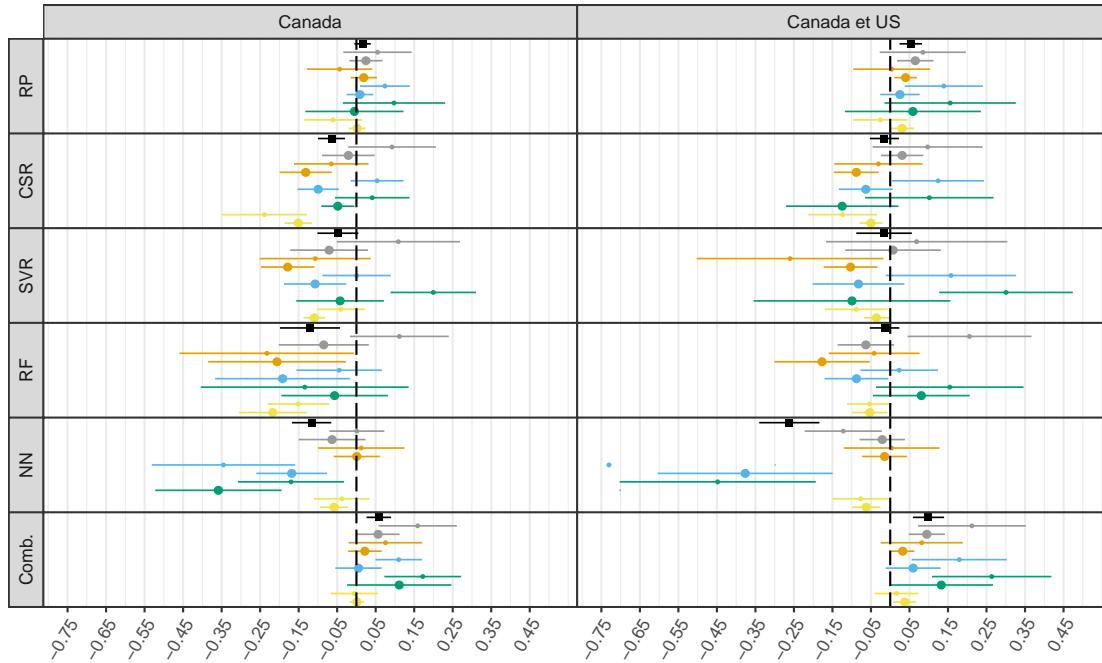
Voir la note en bas de la figure 7. Ici, l'analyse est faite séparément pour les deux ensembles d'information.

La figure 9 désagrège un peu plus l'analyse précédente en comparant la contribution prédictive des données américaines pour la prévision des groupes de variables québécoises, partie 9a, et des groupes de variables canadiennes 9b. Nous ne remarquons pas de grandes différences en moyenne, sauf que dans le cas des variables québécoises plusieurs situations de grandes améliorations sont observées. Notamment, le groupe SVR a un effet marginal de 30% sur le pseudo- R^2 pour IPC et à court terme avec les données américaines, ainsi que les forêts aléatoires sur le PIB dont la précision prédictive s'améliore de 20%.

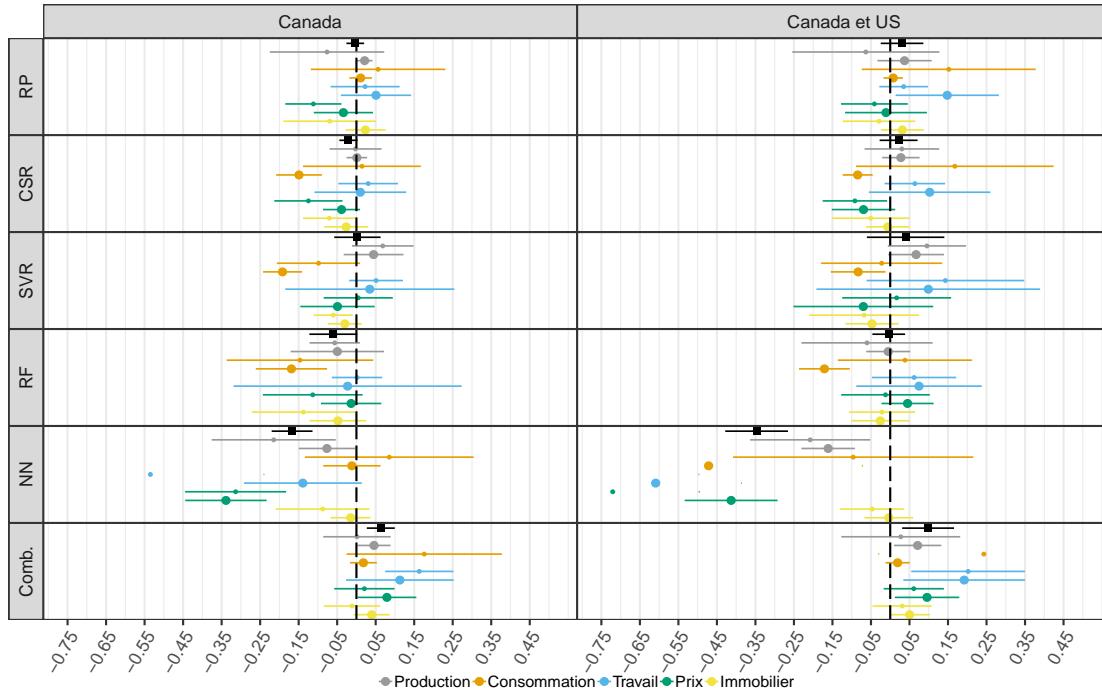
Finalement, la figure 10 compare les résultats agrégés à travers les horizons, panel 10a, et pour les variables québécoises et canadiennes désagrégées par catégorie, panel 10b. Au niveau des horizons, nous remarquons que le groupe des combinaisons de prévisions produit des performances similaires à l'intérieur des horizons de court et de long terme, mais qu'à 1 et 2 trimestres en avance les améliorations atteignent 10%, en moyenne sur toutes 16 variables cibles. Les SVR sont meilleurs à court terme, tandis que les régressions pénalisées se démarquent aux horizons

FIGURE 9: Précision prédictive moyenne : données US avec Québec et Canada

(a) Variables québécoises

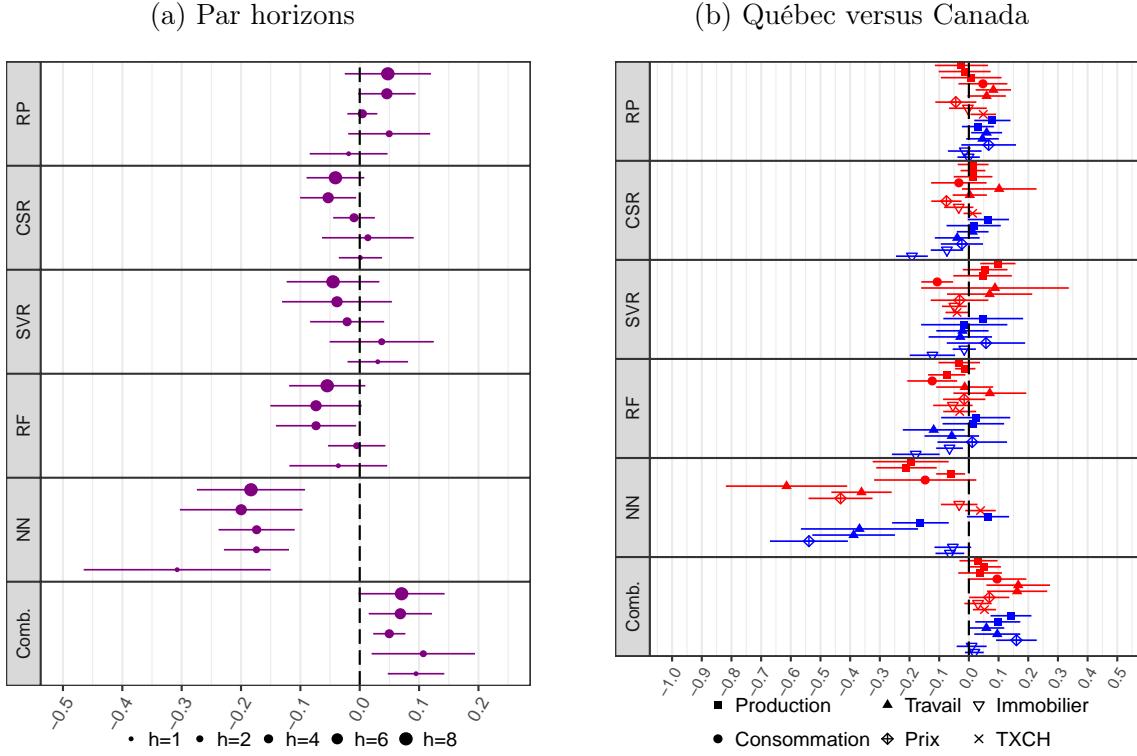


(b) Variables canadiennes



Voir la note en bas de la figure 7 pour la description des estimations. Ici, en plus de considérer les deux ensembles d'information, l'analyse est séparée pour les variables cibles québécoises (panel du haut) et canadiennes (panel du bas).

FIGURE 10: Précision prédictive moyenne : comparaisons agrégées



Voir la note en bas de la figure 7 pour la description des estimations. Le panel gauche montre les résultats par groupe de modèles sur toutes les variables cibles et par horizon. Le panel droit montre les résultats agrégés sur tous les horizons mais désagrégés par variable cible à l'intérieur d'une catégorie, et pour Québec et Canada séparément. Par exemple, pour la catégorie production, les trois carrés rouges représentent PIB, Investissement et production industrielle canadiennes, tandis que les deux carrés bleus représentent PIB et Investissements du Québec.

2, 6 et 8. Lorsqu'on désagrège l'analyse par variable cible, on constate que les améliorations apportées par les groupes RP, CSR, RF, NN et Comb. sont plus importantes pour les variables de production québécoises, tandis que la situation est inverse pour les variables du marché de travail. La prévision de l'inflation au Québec profite plus des méthodes ML que celle du Canada.

Analyse granulaire En deuxième lieu, nous analysons les résultats détaillés sous forme de tableaux montrant la performance prédictive des modèles en termes de la racine carrée de l'erreur quadratique moyenne (*Root Mean Squared Error* ou RMSE). Contrairement à l'analyse précédente, l'objectif est d'identifier les modèles ayant la performance la plus robuste à travers les cibles et les horizons de prévision. Pour simplifier la lecture, RMSE de chaque modèle est divisé par celui du modèle de référence, AR,BIC. Les étoiles indiquent la significativité du test d'équivalence prédictive Diebold-Mariano. Lorsque le ratio est plus petit que 1, cela indique que le modèle fait mieux que la référence autorégressive. Un tableau contient les résultats pour une variable cible et avec deux ensembles de prédicteurs.

5.1.1 PIB

Nous commençons par les résultats sur la prévision du taux de croissance du PIB québécois et canadien. Le tableau 3 montre que plusieurs modèles améliorent grandement la précision prédictive comparativement au modèle de base. Plus spécifiquement, dans le cas de prévision à 1 et 2 trimestres en avance, les versions ARRF et ARERT de macro random forests affichent des améliorations de 32% et 15% respectivement lorsque seulement les données canadiennes sont utilisées. De plus, à $h = 1$, seulement ces deux modèles sont retenus dans MCS, tandis qu'à l'horizon 2 MCS est peuplé de la majorité des randoms forests mais aussi des réseaux de neurones, des régressions régularisées par sous-ensembles complets et toutes les combinaisons de prévisions. Pour les horizons plus éloignés, 1 ans, 6 trimestres et 2 ans, ce sont les différentes versions des réseaux de neurones qui affichent la meilleure performance. Notamment, LSTM-Dense gagne la course pour $h = 4$ avec une amélioration de 10%. Nous remarquons que les modèles gagnants sont meilleurs lorsque seulement les données canadiennes sont considérées. Les résultats sont généralement statistiquement significatifs. Les MCS sont moins bien garnis pour ces horizons.

Le tableau 4 montre les résultats pour le PIB canadien. Nous remarquons immédiatement que les ratios sont en général plus élevés et moins significatifs que dans le cas québécois. Néanmoins, les meilleurs modèles à court sont encore les random forest, ARDIRF avec X_t^{CAN} en particulier, améliorant la prévision de 21% et 12% à 1 et 2 trimestres respectivement. À l'horizon un an, le meilleur modèle est le réseau de neurones récurrent LSTM utilisant les données canadiennes et américaines, avec un ratio de 0.85, suivi de près par la version linéaire du SVRARDI avec données canadiennes. LASSO-MAF et NL-SVRARDI gagnent la course à l'horizon 6 trimestre, et ARRF affiche le meilleur résultats 2 ans en avance. La sélection de modèles par MCS montre que plusieurs procédures sont statistiquement distinctes pour les horizons courts.

5.1.2 Investissement

Une composante importante du PIB est la formation brute de capital fixe. Le tableau 5 indique qu'à l'horizon de 1 trimestre en avance, la meilleure spécification est la variante ARERT de macro random forest, utilisant les données canadiennes et américaines, qui améliorent la précision de 38% comparé à AR,BIC. À titre d'exemple, le même modèle gagne la course avec X_t^{CAN} mais avec un ratio de 0.72. Comme dans le cas du PIB, ARERT et ARRF sont les seuls élus dans le club sélect MCS. Clairement, considérer les données américaines est bénéfique pour la prévision à court terme du taux de croissance de l'investissement au Québec. Les améliorations et l'importance des données américaines s'effritent avec horizons. ARERT gagne encore à 2 trimestres en avance, avec une réduction de 12% de RMSE, tandis que les réseaux de neurones s'avèrent les plus résilients aux autres horizons.

Dans le cas canadien, présenté au tableau 6, la situation est différente. Les variantes de random forests ne sont généralement pas meilleurs que le modèle de référence. Les regressions régularisées par sous-ensembles complets affichent la meilleure performance à court terme, en particulier T-CSR10 avec données canadiennes et américaines qui améliorent la précision de 25% et 3% aux horizons 1 et 2 respectivement. Les réseaux de neurones sont encore les meilleurs à plus long terme, mais les améliorations sont plutôt timides (5% à l'horizon 1 an).

5.1.3 Consommation

Les résultats sont très modestes dans le cas du taux de croissance de la consommation. Les tableaux 7 et 8 montrent les cas québécois et canadien respectivement. Dans le cas du Québec, ARDI,Lasso affiche la meilleure performance 1 trimestre en avance avec données canadiennes seulement, avec une amélioration de la précision prédictive de 8%. Pour les autres horizons, ce sont les réseaux de neurones qui gagnent avec des ratios plus près de 1. La situation est semblable dans le cas canadien, à l'exception qu'à court terme le meilleur modèle est CSR-R10. À l'exception de $h = 1$, la méthode MCS ne permet pas d'identifier un petit nombre de modèles statistiquement meilleurs que la référence.

5.1.4 Taux de chômage

Nous procédons maintenant à l'analyse des deux mesures du marché d'emploi, en commençant par le taux de chômage. Le tableau 9 montre les résultats pour le Québec. Le modèle Lasso utilisant le plus ensemble de données gagne la course à un trimestre, avec un ratio significatif de 0.88, suivi de LSTM-Dense-ARDI qui améliore la prévision de 9% à 2 trimestres en avance. Le même réseau de neurones, mais avec données canadiennes seulement, est le meilleur aux horizons 4 et 6. Ce sont les modèles dans le groupe régressions pénalisées qui sont la plupart du temps sélectionnés dans MCS.

Les améliorations sont plus franches à court terme dans le cas du taux de chômage canadien, tel que présenté au tableau 10. À un trimestre en avance, le meilleur modèle est définitivement EOTB-ERT, une version extrême de forêts aléatoires, qui bonifie la précision de 26% par rapport à la référence autorégressive. Pour les autres horizons, les améliorations sont respectables, autour de 10%, mais généralement non significatives. Les meilleurs modèles sont différentes versions des random forests.

5.1.5 Emploi

La deuxième variable du marché d'emploi et le taux de croissance du nombre d'employés. Le tableau 11 montre qu'à court terme, $h = 1, 2$, ce sont les régressions pénalisées et T-CSR qui gagnent la course avec des améliorations de 13% et 8% par horizon. Le réseau de neurones

Dense-ARDI avec X_t^{CAN} est le meilleur à l'horizon 1 an avec le ratio significatif de 0.91. À plus long terme, les régressions pénalisées sont les plus résiliantes, mais les résultats sont plutôt modestes.

Le tableau 12 dresse le portrait canadien de cette variable. À court terme, deux spécifications de régressions pénalisées avec données canadiennes et américaines affichent la meilleure performance, ARDI, Adaptive-Lasso et Lasso, avec les ratios de 0.80 et 0.88 respectivement pour $h = 1$ et $h = 2$. Un an en avance, c'est la forêt aléatoire extrême EOTB-ERT qui améliore la prévision de 9%, tandis que la forêt aléatoire standard, RF-X, affiche la performance identique à l'horizon $h = 6$. À long terme, les réseaux de neurones Dense-AR et LSTM sont les meilleurs.

5.1.6 Mises en chantier

Le tableau 13 présente les résultats pour le taux de croissance des mises en chantier au Québec. À l'horizon 1 trimestre, aucun modèle n'est pas capable de battre le modèle autorégressif, et à 2 trimestres en avance, seulement le réseau de neurones Dense-AR améliore la prévision de 6%. À noter que ce modèle est seulement une transformation nonlinéaire du modèle AR,BIC, suggérant ainsi que les grands ensembles de données macroéconomiques n'ajoutent pas de pouvoir prédictif pour cette variable. Un avance, c'est encore AR,BIC qui gagne tandis que seulement à long terme, 2 ans, la version ARERT de random forests bat la référence de 9%.

La situation est seulement légèrement différente dans le cas de la cible canadienne. Le tableau 14 montre que seulement les random forests RF-MAF et RF-X améliorent significativement la prévision aux horizons de 2 et 8 trimestres, et ce 8% et 11% respectivement. Comme dans le cas de la consommation, MCS ne permet pas de discriminer à travers les différents groupes de modèles.

5.1.7 Inflation

Au tour des mesures d'inflation maintenant d'être analysées. Le tableau 15 montre le cas québécois. Le taux de croissance de l'IPC est le mieux prédit à court terme par L-SVRARDI et Adaptive-Lasso, suivi de près par RFARDI. À l'horizon d'un an, ARERT et ARDI,BIC sont les meilleurs, mais l'amélioration par rapport au AR,BIC est très mince et non significative. Nous notons seulement une amélioration significative et considérable à l'horizon de 2 an avec les modèles RF-X-CSF et Adaptive-Lasso. Les données américaines ne semblent pas jouer un rôle primordial.

Le tableau 16 présente les résultats pour le taux d'inflation canadien. La situation est semblable, il est en général très difficile de battre la référence autorégressive. Le modèle T-CSR10 avec données canadiennes est plutôt résilient à court terme, mais les meilleurs modèles

sont ARDIERT, ARERT et LLF-CSF qui améliorent l'efficacité de 7, 12 et 12% aux horizons 1, 2 et 8 respectivement. Ceci rappelle les résultats dans [Medeiros et al. \(2019\)](#) qui trouvent que les random forests sont capables de bien prévoir l'inflation américaine. À noter qu'ici, les données américaines apportent un soutien important. En général, ce sont les forêts d'arbres aléatoires qui sont le plus souvent dans les ensembles MCS.

5.1.8 Autres variables canadiennes

Finalement, les tableaux [17](#) et [18](#) présentent les résultats pour le taux de croissance de la production industrielle canadienne et pour le rendement du taux de change US/CA. Le modèle ARDI,BIC affiche la meilleure performance à court terme pour la production industrielle, suivi de T-CSR10 aux horizons $h = 4, 6$. LSTM est le meilleur modèle à long terme. L'ajout des données américaines améliorent la capacité prédictive de la plupart des modèles.

Dans le cas du taux de change, comme attendu, il est difficile de produire des prévisions statistiquement différentes du modèle autorégressif. Les rares exceptions sont quelques réseaux de neurones ($h = 2, 8$), forêts aléatoires ($h = 4$) et Adaptive-Lasso ($h = 6$). Les améliorations sont modestes et il n'y a pas de clair avantage d'utiliser les données américaines.

Les résultats de l'EQM relatif au modèle autorégressif ne disent rien sur la capacité absolue à prévoir une variable puisque le modèle de référence, à l'occurrence AR,BIC, peut être simplement incapable de bien prédire la cible. Une façon de vérifier la prévisibilité consiste à comparer les modèles selon le pseudo- R^2 . Les résultats détaillés sont présentés en annexe [A](#). Notons ici que trois mesures de l'activité économiques sont particulièrement difficiles à prévoir selon ce critère : consommation, emploi et mises en chantier.

Enfin, les figures avec les prévisions réalisées pour toutes les variables sont présentées en annexe [B](#). En général, la plupart des modèles suivent assez bien l'évolution des variables d'activité économique québécoise et canadienne. Parfois, il peut y avoir des projections extrêmes, et Il est donc important de superviser les modèles continument. Il est également une bonne pratique de surveiller la distribution de l'ensemble des prévisions car la dispersion semble corrélée avec le cycle économique.

5.2 Performance en termes de la direction

Une autre mesure de performance a été présentée dans la section [2.4](#) : la capacité à prédire la direction de la cible. Les tableaux suivants montreront les ratios de succès (*Ratio of Correctly Signed Forecasts* ou RCSF) avec les résultats du test de [Pesaran et Timmermann \(1992\)](#). Rappelons qu'une bonne prévision selon ce critère a un RCSF > 0.5, donc un taux de succès supérieur au lancé de la pièce de monnaie. Il faut quand même noter que nous avons seulement 56 périodes hors échantillon, ce qui risque de réduire grandement la puissance du test.

5.2.1 PIB

Les tableaux 19 et 20 montrent les résultats pour le PIB québécois et le PIB canadien respectivement. Les taux de succès sont généralement très élevés, surtout dans le cas canadien, et ils sont significatifs particulièrement à court terme. Random forest de type *local linear forest*, LLF-CSF, prévoit le mieux la direction du PIB québécois à 1 et 2 trimestres (85% du temps), suivi des modèles AR,BIC et T-CSR10 aux plus longs horizons. Dans le cas du PIB canadien, ARDI,BIC et sa variante Lasso domine à court terme, suivi du modèle de référence à long terme.

5.2.2 Investissement

Sans surprise, les résultats sont moins impressionnantes dans le cas des mesures d'investissement. Le taux de croissance de l'investissement est bien plus variable que le taux de croissance du PIB et ceci pourrait affecter la prévision de la direction de changement. Néanmoins, on remarque dans le tableau 21 que plusieurs spécifications des random forests affichent des taux de succès significativement supérieurs à 50% aux horizons 1, 2, et 6 trimestres en avance. C'est LASSO-MAF qui est le grand gagnant à l'horizon de deux ans. Les ratios sont uniformément plus élevés dans le cas de l'investissement canadien, comme indiqué dans le tableau 22. Les meilleurs modèles sont ARDI,BIC, T-CSR10 et L-SVRARDI.

5.2.3 Consommation

La situation de la consommation est particulière. Les taux de succès sont tous très élevés, voir les tableaux 23 et 24. La consommation augmentent presque toujours et de façon très lisse. Donc, il est facile pour les modèles de bien prédire le signe du taux de croissance.

5.2.4 Taux de chômage

Dans le cas du taux de chômage québécois, le tableau 25 affiche les taux de succès plutôt modestes. À court terme, les modèles Lasso et ARDI,Adaptive-Lasso sont les meilleurs, suivi de RF-X-CSF à l'horizon d'un an. Le modèle ARDI,BIC considérant des facteurs américains performe le mieux aux horizons 6 et 8. Les améliorations sont un peu plus fortes et significatives dans le cas du taux de chômage canadien, voir le tableau 26. Les régressions pénalisées sont encore les meilleures à la plupart des horizons.

5.2.5 Emploi

Au niveau de l'emploi, le tableau 27 montre une performance similaire à la consommation, donc très peu de différence entre les modèles et horizons. La situation est un peu plus intéressante.

sante dans le cas canadien, tel que montré dans le tableau 28. Les taux de succès sont proches de 100% et ils sont même significatifs aux horizons courts. Mais comme dans le cas canadien, il est difficile de distinguer un groupe de modèles des plus performants.

5.2.6 Mises en chantier

Le tableau 29 montre les résultats pour les mises en chantier au Québec. Là, il y a quelques modèles qui se distinguent par leur capacité de prévoir le signe du taux de croissance. ARDI,BIC, LLF-CSF, NL-SVRARDI, T-CSR20 et ARERT sortent gagnant à travers les cinq horizons de prévision respectivement. Donc, les données massives et la nonlinéarité sont des ingrédients clés pour la prévision de la direction des mises en chantier. Le portrait est semblable dans le cas canadien, comme présenté au tableau 30. La situation des mises en chantier montre clairement une occasion où les modèles ont un faible pouvoir prédictif au niveau de l'erreur quadratique moyenne (et donc prévision ponctuelle) mais sont capables de bien prévoir la direction que prendra la variable d'intérêt dans le futur.

5.2.7 Inflation

Les ratios de succès sont généralement élevés mais peu significatifs dans le cas de l'inflation québécoise, voir le tableau 31. La séparation entre les modèles est un peu plus clair dans le cas canadien. Le tableau 32 montre que le modèle ARDI,BIC et plusieurs versions des random forests sont les meilleurs à différents horizons.

5.2.8 Autres variables canadiennes

Le tableau 33 présente les résultats dans le cas de la production industrielle. ARDI,Lasso domine à un trimestre en avance, avec un taux de succès de 78%, tandis que Lasso est le meilleur si $h = 2$. T-CSR10 gagne la course à un an en avance, suivi de LSTM-Dense et RF-X-CSF aux horizons 6 et 8.

Enfin, les résultats pour le taux de change sont rapportés au tableau 34. Rappelons qu'il est très difficile de prévoir de façon ponctuelle le rendement du taux de change, alors il est intéressant de voir maintenant si nous avons plus de chance avec sa direction, ([Kotchoni et al., 2019](#)). Pour la plupart des modèles les taux de succès ne sont pas concluants, mais il y a des exceptions. Dense-ARDI à l'horizon 1 trimestre obtient un respectable ratio significatif de 64%, suivi d'un autre réseau de neurones, Dense, qui affiche 62% à 2 trimestres en avance. RF-CSF prévoit le signe 64% du temps un an en avance, tandis que T-CSR10 montre la même performance à l'horizon 6. Même à long terme, deux ans en avance, le réseau de neurones de type LSTM-Dense prévoit bien et significativement 60% du temps.

6 Conclusion

Dans ce rapport nous avons appliqué plusieurs techniques de *Machine Learning* au contexte de prévision de l'activité économique au Québec et au Canada. Six groupes de modèles ont été considérés : les modèles à facteurs, régressions pénalisées, régressions régularisées par sous-ensembles complets, régressions à vecteurs de support, forêts d'arbres aléatoires et les réseaux de neurones. Tous ces modèles apportent différentes façons de gérer les grands ensembles de données et de générer les formes fonctionnelles hautement complexes.

La prédiction de 16 variables macroéconomiques québécoises et canadiennes a été évaluée dans un exercice de prévision hors échantillon. Les grands ensembles de données canadiennes et américaines ont été considérés, totalisant dans certaines applications plusieurs milliers de prédicteurs.

Dans la plupart des cas, les méthodes ML améliorent significativement la capacité prédictive. En moyenne, les méthodes ML, lorsque combinées, améliorent la précision prédictive jusqu'à 15% en termes du pseudo- R^2 . L'ajout des données américaines est bénéfique à la capacité prédictive de la plupart des modèles. Par contre, la performance n'est pas homogène et plusieurs cas spécifiques doivent être considérés afin d'isoler les meilleurs modèles.

En particulier, les résultats indiquent que les méthodes machine learning, combinées avec les grands ensembles de données, ont un bon pouvoir prédictif pour plusieurs variables d'activité réelle comme le PIB, la formation brute de capital fixe et la production industrielle. Les forêts d'arbres aléatoires sont particulièrement résiliantes, suivies des réseaux de neurones. La prévision des variables du marché d'emploi est améliorée par l'utilisation des régressions pénalisées, simples ou par sous-ensembles complets. Les taux d'inflation sont prévisible avec les forêts aléatoires et les régressions pénalisées. Quant aux mises en chantier et le taux de change USD/CAD, les méthodes machine learning n'arrivent pas à améliorer la prévision ponctuelle, mais affichent des résultats intéressants au niveau de la prévision de la direction future de ces variables.

Une extension intéressante à ce travail serait la considération de l'information observée en différentes fréquences. Ceci est très important dans un exercice de *nowcasting* où l'intérêt est de prévoir l'état actuel d'une variable qui est observée avec un retard. C'est le cas notamment avec la plupart des variables d'activité réelle comme le PIB et ses composantes qui sont relâchées avec un trimestre de retard par StatCan. Il serait donc intéressant d'évaluer la contribution des méthodes machine learning au problème de nowcasting avec les fréquences mixtes.

TABLE 3: PIB réel - Québec : RMSE relatifs

Models	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC (RMSE)	0.005	0.005	0.005	0.005	0.005	0.005	0.005	0.005	0.005	0.005
ARDI,BIC	0.96	0.97	0.99	0.99	1.00	0.92	1.02	1.09	1.05	1.04***
Régressions pénalisées										
Ridge	0.93**	0.92**	1.01	1.03	0.99	0.93**	0.92**	1.03	0.96*	1.00
Lasso	0.93***	0.91**	1.02	0.98	0.98	0.95**	0.88**	1.02**	0.97	0.99
Elastic-Net	0.93**	0.91***	1.01*	0.99	0.99	0.93**	0.91***	1.01*	0.99	0.99
Adaptive-Lasso	0.90**	0.92**	1.02	0.98	0.99	0.90*	0.92*	0.99	0.98	0.99
ARDI,Ridge	0.93**	0.91***	1.01*	0.99	0.99	0.93**	0.91**	1.01*	0.99	0.99
ARDI,Lasso	0.93**	0.91***	1.01*	0.99	0.99	0.95**	0.90***	1.01	0.99	0.99
ARDI,Elastic-Net	0.93**	0.91***	1.01*	0.99	0.99	0.93**	0.91***	1.01*	0.99	0.99
ARDI,Adaptive-Lasso	0.88**	0.93**	1.00	1.07	0.97*	0.96	0.96	1.08	0.97	0.97
Ridge-MAF	0.91**	0.89*	0.98	1.03	1.00	0.94**	0.92*	0.99	1.03	1.00
LASSO-MAF	0.92***	0.93	0.99	1.06	0.98	0.93**	0.88***	1.02	1.20*	0.99
ELAS-MAF	0.93**	0.94	1.00	1.00	0.98	0.95*	0.91**	0.99**	0.96	1.07
Régressions régularisées par sous-ensembles complets										
T-CSR10	0.94	0.97	1.01	1.10	1.06*	0.95	1.02	1.00	1.07	1.03
T-CSR20	0.87***	0.89***	1.00	0.99	1.01	0.86***	0.88**	1.02*	0.99	0.99
CSR-R10	0.88***	0.89***	1.00	1.00	1.03**	0.86***	0.88**	1.00	1.00	0.99
CSR-R20	0.94*	0.93**	1.01*	0.98	1.00	0.99	1.00	0.97	1.00	0.99
Régressions à vecteurs de support										
NL-SVRARDI	0.93	0.93	1.00	1.03	1.00	0.94	0.96	0.98	1.02	0.98
L-SVRARDI	0.93	0.88**	1.07	0.99	1.08**	0.98	0.92	1.08*	0.93	1.00
Forêts d'arbres aléatoires										
RFARDI	0.96	0.94	1.09***	1.03	1.06*	0.98	0.93	1.02	1.02	1.00
RF-X	0.94*	0.88*	1.01	0.99	0.98	0.96	0.91*	1.00	0.97	0.97
RF-CSF	0.86*	0.85*	1.02	0.96	1.02	0.80**	0.87*	1.05	1.01	1.09**
RF-MAF	0.93*	0.88*	0.97	0.98	0.98	0.94	0.91*	1.03	1.00	0.96
RF-X-CSF	0.93**	0.88**	0.98	0.98	0.98	0.96	0.92	1.01	0.98	1.00
LLF-CSF	0.83**	0.86	1.06	1.03	1.04	0.86*	0.94	1.12*	1.06	1.14***
ARERT	0.72***	0.85**	1.06*	1.00	1.04	0.73***	0.89*	0.99	0.97	1.06
ARDIERT	0.85***	1.05	1.05	1.10**	1.17**	0.93	1.03	1.07**	1.16	0.99
EOTB-ERT	1.01	1.03	1.09**	1.19**	1.08	0.96	0.91	1.23***	1.12*	1.13**
ARRF	0.68***	0.88**	1.05**	1.00	1.09**	0.74***	0.88**	1.13***	1.00	0.99
ARDIRF	1.03	0.94	1.06	1.22***	1.18*	0.87***	0.94	1.07***	1.17**	1.21**
EOTB-MRF	0.92	0.99	1.03	1.15*	1.08	0.89*	0.94	1.13***	1.19*	1.03
ERT-MAF	0.92*	0.88*	0.98	0.99	0.98	0.92*	0.91*	1.00	0.98	0.98
Réseau de neurones										
LSTM-Dense-AR	0.93***	0.88***	0.98**	0.95***	0.96**	0.93***	0.88***	0.98**	0.95***	0.96**
LSTM-AR	0.94**	0.88***	0.98***	0.95***	0.98	0.94**	0.88***	0.98***	0.95***	0.98
Dense-AR	0.91***	0.88**	1.06**	0.97	1.08**	0.91***	0.88**	1.06**	0.97	1.08**
LSTM-Dense-ARDI	0.88***	0.92***	0.97***	0.95*	0.96**	0.90*	0.85**	1.03*	0.98	1.02
LSTM-ARDI	0.87***	0.88***	0.98	0.97*	1.03	0.95	0.88***	0.99	0.93***	0.99
Dense-ARDI	0.84*	1.00	1.11**	1.13	1.02	1.07	1.19*	1.21**	1.02	1.06
LSTM-Dense	0.88***	1.01	0.94**	0.97	0.97	0.95	0.94*	1.07**	0.97	1.02
LSTM	1.00	0.90**	1.03	1.02	1.10*	0.93**	0.99	1.01	1.00	1.03
Dense	0.94	0.93**	1.04*	1.02	0.99	0.91**	0.90***	1.05***	0.98	1.01
Combinaisons de prévisions										
AVRG	0.87***	0.88**	0.99	0.97	0.98	0.88***	0.89**	1.00	0.98	0.98
Médiane	0.90***	0.89**	0.99	0.97	0.98	0.90***	0.89**	1.00	0.96*	0.98
T-AVRG,0.1	0.88***	0.88**	0.99	0.97	0.98	0.89***	0.89**	1.00	0.97	0.98
T-AVRG,0.2	0.89***	0.88**	0.99	0.97	0.98	0.89***	0.89**	1.00	0.97	0.98
IP-AVRG,1	0.87***	0.88**	0.99	0.97	0.98	0.88***	0.89**	1.00	0.98	0.98
IP-AVRG,0.95	0.87***	0.88**	0.99	0.97	0.98	0.88***	0.89**	1.00	0.98	0.98

Note : La première ligne contient la racine carrée de l'erreur quadratique moyenne du modèle de référence AR,BIC. Les autres éléments sont les ratios de RMSE de chacun des modèles alternatifs sur celui du modèle de référence. La valeur minimale pour chaque horizon est soulignée. Les étoiles indiquent la significativité du test Diebold-Mariano versus le modèle de base avec les niveaux de 1, 5 et 10% pour *, ** et *** respectivement. Les chiffres en caractère gras représentent les modèles faisant partie du Model Confidence Set.

TABLE 4: PIB réel - Canada : RMSE relatifs

Models	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC (RMSE)	0.006	0.007	0.007	0.007	0.007	0.006	0.007	0.007	0.007	0.007
ARDI,BIC	0.84*	0.92	0.97	1.00	1.00	0.85	0.93	0.98	0.99	1.04
Régressions pénalisées										
Ridge	1.00	1.00	0.99	0.99**	1.00	1.02	0.90*	1.01	0.93*	0.97
Lasso	0.98	0.95	0.98	0.95	0.99	0.94*	0.90	0.93	0.93	0.99
Elastic-Net	1.12	0.99	1.00	0.99*	1.00	1.26**	0.99	1.00	0.99*	1.00
Adaptive-Lasso	0.97	0.97	0.99	0.98	0.97	0.95**	0.97*	0.98	0.98	0.96
ARDI,Ridge	0.87	1.01	1.00	0.99	1.00	1.03	0.99	1.00	0.99*	0.99
ARDI,Lasso	0.86	0.99	1.00	0.99*	1.02	0.93*	1.01	1.00	0.98*	1.00
ARDI,Elastic-Net	1.14	1.02	1.00	0.99*	1.00	1.11	1.05	1.00	0.99*	1.00
ARDI,Adaptive-Lasso	0.93*	0.96	1.01	0.98*	1.01	0.85*	0.96	1.00	1.11	0.98
Ridge-MAF	1.01	0.92**	0.95**	0.96	0.98	1.04	0.95*	0.97*	0.96	0.98
LASSO-MAF	1.03	0.99	0.98	0.91	0.97	0.95*	1.00	0.98	0.99	0.98
ELAS-MAF	1.06	0.99	0.97**	0.94	0.96*	1.01	0.99	0.98	0.97**	0.98
Régressions régularisées par sous-ensembles complets										
T-CSR10	0.92*	0.94	0.94	1.02	1.02	0.86	0.93	0.94	0.92	0.99
T-CSR20	0.99	0.98	0.99	1.01*	1.00	0.99	0.95*	0.99	1.00	1.00
CSR-R10	0.98	0.98	0.98	1.01**	1.02**	0.96*	0.96*	0.99	1.01	1.00
CSR-R20	0.89*	0.93*	0.95*	1.00	0.96*	0.91	0.91	0.99	0.99	1.00
Régressions à vecteurs de support										
NL-SVRARDI	0.94*	0.95	0.92	0.95	0.99	0.87*	0.92	0.90	0.90	0.97
L-SVRARDI	0.86*	0.92	0.92*	0.98	0.97	0.98	0.99	1.06**	1.00	1.01
Forêts d'arbres aléatoires										
RFARDI	1.03	0.96**	0.99	0.97	0.98	1.01	0.94	0.95	0.94	1.00
RF-X	1.03	0.96	0.95	0.95	0.98	1.03	0.97	0.98	0.96	0.97
RF-CSF	0.97*	0.94	0.93	0.95	1.00	1.03	0.94	1.04	0.95	0.97
RF-MAF	1.02	0.92*	0.96	0.96	0.99	1.03	0.92*	0.97	0.93	0.99
RF-X-CSF	1.04	0.96	0.96	0.96	0.96	1.04	0.97	0.98	0.96	0.97
LLF-CSF	0.94*	0.96	0.94	0.97	1.00	0.97	0.92**	0.97	0.92	0.98
ARERT	0.92***	1.03	0.99	0.99	0.96	1.03	1.04	1.03	1.00	0.97
ARDIERT	0.84	0.96	1.04	1.07**	1.05**	0.91	1.01	0.97	1.10***	0.97
EOTB-ERT	0.98	0.99	0.94	0.97	1.03	0.94*	0.97	1.03*	1.05	1.08
ARRF	1.09	0.99	1.06**	1.03*	1.01	1.07*	0.99	1.07**	1.01	0.93
ARDIRF	0.79	0.88	1.08	1.07**	1.04*	0.88	1.05	0.97	1.06***	1.03
EOTB-MRF	0.94	0.96	1.01	0.99	1.11***	0.94	0.97	0.98	0.97	1.05
ERT-MAF	1.01	0.94*	0.98	0.96	0.97	1.03	0.95*	0.97	0.96	0.96
Réseau de neurones										
LSTM-Dense-AR	1.13	0.98	0.97**	0.96*	0.98	1.13	0.98	0.97**	0.96*	0.98
LSTM-AR	1.08	0.99	0.97**	0.97*	0.98	1.08	0.99	0.97**	0.97*	0.98
Dense-AR	1.06*	0.97	0.99	1.01	0.99	1.06*	0.97	0.99	1.01	0.99
LSTM-Dense-ARDI	1.11	0.98	0.96**	0.98	0.97	1.00	0.97	0.97	0.99	0.98
LSTM-ARDI	1.09	0.98	0.96**	1.00	1.06	1.10	0.94	0.94	0.95	0.99
Dense-ARDI	1.00	0.92**	1.03	0.94	1.05	1.07	0.89	1.14*	1.12*	1.09
LSTM-Dense	1.23***	1.05	0.97	1.16**	1.06	0.97	1.01	0.97	0.99	1.10*
LSTM	1.13	1.05*	0.99	0.97*	0.98	1.03	0.99	0.89	0.98	1.00
Dense	1.18*	0.97	1.08	1.38	1.37*	2.32**	1.41	1.19	2.55**	1.02
Combinaisons de prévisions										
AVRG	0.93**	0.94**	0.95**	0.96	0.97	0.92**	0.92*	0.95*	0.95	0.97
Médiane	0.98	0.95**	0.96**	0.97	0.98	0.95*	0.93**	0.97*	0.96	0.98
T-AVRG,0.1	0.95**	0.94**	0.96*	0.96	0.98	0.93**	0.93**	0.96*	0.96	0.97
T-AVRG,0.2	0.96	0.95**	0.96*	0.97	0.98	0.95**	0.93**	0.96*	0.96	0.97
IP-AVRG,1	0.92**	0.93**	0.95**	0.97	0.98	0.92**	0.92*	0.96*	0.96	0.97
IP-AVRG,0.95	0.92**	0.93**	0.95**	0.97	0.98	0.93**	0.92*	0.96*	0.96	0.97

TABLE 5: Investissement réel - Québec : RMSE relatifs

Models	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC (RMSE)	0.017	0.019	0.019	0.018	0.019	0.017	0.019	0.019	0.018	0.019
ARDI,BIC	0.92**	0.94**	1.03*	1.00	0.99	1.09	0.98	1.03*	1.03	0.99
Régressions pénalisées										
Ridge	1.04	0.95*	0.99	0.99	0.97**	1.07	0.95*	0.98	0.98	0.96**
Lasso	0.99	0.95*	0.96	0.97	0.97*	1.08	0.94	0.97	1.03	0.95
Elastic-Net	1.04	0.96	0.97	0.99	0.97**	1.04	0.96	0.97	0.99	0.97**
Adaptive-Lasso	0.96	0.94	1.00	1.01	0.97*	0.98	0.96	0.97	0.97	0.96**
ARDI,Ridge	1.02	0.96	0.98	1.00	0.97**	1.23*	0.96	0.97	1.00	0.97**
ARDI,Lasso	1.03	0.96	0.97	0.99**	0.97**	1.24**	0.96	0.98	0.99	0.97**
ARDI,Elastic-Net	1.06	0.96	0.97	0.99	0.97**	1.10*	0.96	0.97	0.99	0.97**
ARDI,Adaptive-Lasso	0.95	0.98	0.97	0.99	0.99	0.96	0.98	0.96	1.00	1.00
Ridge-MAF	1.03	0.93*	0.95*	0.97*	0.95**	1.04	0.94*	0.95*	0.98**	0.96
LASSO-MAF	1.05	0.96	0.96*	0.98**	1.01	1.04	0.95*	0.96*	0.98**	0.99
ELAS-MAF	1.05	0.95*	0.97	0.98**	0.98	1.04	0.95*	0.96*	0.98**	1.01
Régressions régularisées par sous-ensembles complets										
T-CSR10	0.90*	0.99	1.01	1.11*	1.08	0.93*	1.02	1.05	1.07	1.11
T-CSR20	0.96	0.96	0.98	0.98	0.97**	1.00	0.94	0.98	0.98	0.99
CSR-R10	0.94	0.97	0.99	0.99	0.97**	1.00	0.96	0.98	0.98	0.99
CSR-R20	0.98	0.94*	0.97	0.99	0.97	1.09	1.01	0.99	0.98	
Régressions à vecteurs de support										
NL-SVRARDI	0.88**	0.95	0.99	1.03	1.03	0.92**	0.97	1.01	1.00	1.03
L-SVRARDI	0.97	0.94	1.04	1.08**	1.02	1.06	1.03	1.07	1.04	1.04
Forêts d'arbres aléatoires										
RFARDI	0.92*	0.93*	0.98	1.04	1.06*	0.95	0.92*	0.97	1.01	0.99
RF-X	1.02	0.94	0.97	1.01	0.97	1.01	0.95	0.98	1.02	0.99
RF-CSF	0.93	0.91	0.95	0.96	1.01	0.89	0.93	0.99	1.09**	1.08**
RF-MAF	1.02	0.94	0.95	1.01	0.96	0.99	0.93	0.99	1.02	0.97
RF-X-CSF	1.02	0.94	0.96	1.00	0.98	1.01	0.95	0.99	1.02	0.99
LLF-CSF	0.97	0.98	0.94	0.92	0.99	0.90	0.92	0.97	1.09***	1.07**
ARERT	0.72***	0.88**	1.06	0.97	1.03*	0.62***	0.95	1.00	1.00	1.06***
ARDIERT	0.80***	0.98	1.04	1.25**	1.09*	0.76***	0.97	1.03	1.02	1.05*
EOTB-ERT	1.01	1.00	1.04	1.12**	1.10	0.88	0.97	1.06	1.20**	1.13**
ARRF	0.77***	0.91***	1.00	1.07*	1.05*	0.65***	0.92**	1.01	1.04	1.03
ARDIRF	0.88*	1.00	1.04	1.10	1.10**	0.72***	0.95*	1.01	1.10	1.02
EOTB-MRF	1.04	0.98	1.03	1.15***	1.04	0.96	0.96	1.05	1.23**	1.09**
ERT-MAF	1.03	0.93	0.96	0.99	0.95*	1.02	0.94	1.00	1.01	0.97
Réseau de neurones										
LSTM-Dense-AR	0.99	0.93**	0.98*	0.98**	0.96**	0.99	0.93**	0.98*	0.98**	0.96**
LSTM-AR	1.04	0.94**	0.95*	0.99	0.96***	1.04	0.94**	0.95*	0.99	0.96***
Dense-AR	1.03	1.05*	1.03	0.97*	0.97	1.03	1.05*	1.03	0.97*	0.97
LSTM-Dense-ARDI	1.02	0.95*	0.96*	0.99	0.96*	0.98	0.95*	0.94*	1.01	0.95**
LSTM-ARDI	1.04	0.94**	0.95**	1.02	0.99	1.12*	0.96*	0.95*	0.97*	0.96*
Dense-ARDI	1.06	1.09	1.03	1.03	1.15*	1.09	1.06	0.98	1.04	1.02
LSTM-Dense	1.00	1.04	0.98	1.09	1.06	1.48***	1.17**	1.22*	0.96	0.94
LSTM	1.05	0.96	1.03	0.91*	1.08*	1.11*	0.94	1.00	1.01	0.93*
Dense	1.38	1.14*	1.20*	1.67**	1.15*	1.91*	1.77**	1.34**	1.54**	1.37**
Combinaisons de prévisions										
AVRG	0.92	0.93*	0.95**	0.98	0.97*	0.94	0.92*	0.96*	0.99	0.97*
Médiane	0.95	0.94*	0.96*	0.98*	0.97*	0.97	0.94*	0.96*	0.99	0.98*
T-AVRG,0.1	0.93	0.93*	0.96*	0.98*	0.97*	0.95	0.93*	0.96*	0.99	0.97*
T-AVRG,0.2	0.94	0.93*	0.96*	0.98	0.97**	0.96	0.93*	0.96*	0.99	0.97**
IP-AVRG,1	0.92*	0.93*	0.96*	0.97	0.97*	0.91*	0.93*	0.96*	0.99	0.97*
IP-AVRG,0.95	0.92*	0.93*	0.96*	0.97	0.97*	0.91*	0.93*	0.96*	0.99	0.97*

TABLE 6: Investissement réel - Canada : RMSE relatifs

Models	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC (RMSE)	0.020	0.023	0.023	0.023	0.023	0.020	0.023	0.023	0.023	0.023
ARDI,BIC	1.01	1.01	1.00	1.01**	1.04	0.98	1.17**	1.06	1.02	1.07
Régressions pénalisées										
Ridge	1.10*	0.99	1.00	1.00*	0.99	1.09*	1.00	1.00	0.99	0.99
Lasso	1.03	1.00	1.00	1.00	0.99	1.06	1.00	1.02	1.01	1.01
Elastic-Net	1.10*	0.99	1.00	1.00*	0.99	1.10*	0.99	1.00	1.00*	0.99
Adaptive-Lasso	1.03	1.03	1.05**	1.02**	1.01	1.04	1.07*	1.06	1.03	1.02*
ARDI,Ridge	1.06	0.99	1.00	1.00	0.99	1.06	1.03	1.00	1.00	0.99
ARDI,Lasso	1.06	0.99	1.00	1.00	0.99	1.08	0.99	1.01	1.00	1.00
ARDI,Elastic-Net	1.10*	0.99	1.00	1.00*	0.99	1.11*	0.99	1.00	1.00*	0.99
ARDI,Adaptive-Lasso	0.99	1.00	0.99	1.00	1.02	0.94	1.10*	1.09	1.03	1.03
Ridge-MAF	1.07*	0.99	1.01	1.00	1.00	1.09*	1.00	1.00	1.00	1.00
LASSO-MAF	1.11*	0.99	1.00	1.00	1.01	1.11*	0.99	1.00	1.00	1.01
ELAS-MAF	1.11*	0.99	1.00	1.00	1.00	1.11*	0.99	1.00	1.00	1.00
Régressions régularisées par sous-ensembles complets										
T-CSR10	0.87	0.98	1.03	1.09***	1.05*	0.75	0.99	1.07	1.09	1.05
T-CSR20	1.04	0.99	1.01	1.00	0.99	1.03	0.97	1.01	1.00	1.00
CSR-R10	1.05	0.99	1.03	1.00	0.99	1.05	0.97	1.02	1.00	1.01
CSR-R20	0.95	1.00	1.00	1.01	1.02	0.96	1.10***	1.05*	1.07**	1.07*
Régressions à vecteurs de support										
NL-SVRARDI	0.91*	0.97	1.01	1.04**	1.03	0.82	0.98	1.04	1.04	1.02
L-SVRARDI	0.93	1.01	1.04**	1.02	1.01	0.92	0.97	1.00	1.04	1.03
Forêts d'arbres aléatoires										
RFARDI	0.96	1.01	1.08*	1.04**	1.05***	0.97	1.01	1.06	1.03	1.06**
RF-X	1.09**	1.01	1.05*	1.02*	1.01	1.10*	1.02	1.03**	1.01	1.00
RF-CSF	1.04	1.05	1.08	1.07**	1.05***	1.02	1.05	1.17**	1.04**	1.02
RF-MAF	1.07*	1.00	1.05	1.03	1.00	1.07	1.00	1.05	1.03**	0.99
RF-X-CSF	1.09**	1.01	1.06*	1.03*	1.01	1.08*	1.02	1.03*	1.02*	1.00
LLF-CSF	1.00	1.05	1.06	1.07	1.06	0.97	1.03	1.10**	1.05***	1.01
ARERT	1.03	1.01	1.12	1.00	1.04*	0.97	0.97	1.14	1.04***	0.98
ARDIERT	1.11**	1.03	1.15	1.05*	1.10**	1.03	1.08**	1.05	1.04*	1.02
EOTB-ERT	1.12**	1.03	0.99	1.07	1.15**	1.07*	1.01	1.14**	1.11***	1.13***
ARRF	1.02	1.05**	1.27*	1.02	0.99	1.00	1.00	1.26*	1.02*	0.96
ARDIRF	1.22	1.06	1.11	1.06*	1.09**	1.18*	1.15*	1.25**	1.04	1.11
EOTB-MRF	1.09*	1.07	1.16	1.16	1.12***	1.08	0.99	1.06	1.16**	1.06**
ERT-MAF	1.06	0.99	1.04	1.02	1.00	1.08*	1.00	1.03	1.03**	1.02
Réseau de neurones										
LSTM-Dense-AR	0.99	0.99	0.99	1.00	0.98**	0.99	0.99	0.99	1.00	0.98**
LSTM-AR	1.01	1.00	0.99	0.99	0.99	1.01	1.00	0.99	0.99	0.99
Dense-AR	1.05*	1.01	1.00	1.03	0.99*	1.05*	1.01	1.00	1.03	0.99*
LSTM-Dense-ARDI	1.03	1.00	1.01	1.01	0.99	1.05*	1.00	1.02	1.01	1.04
LSTM-ARDI	1.05*	1.00	0.98	1.02	1.01	1.10	0.97	1.06	1.04	1.02
Dense-ARDI	1.04	1.17*	1.06**	1.12**	1.03	1.20**	1.14*	1.03	1.22*	1.23***
LSTM-Dense	1.38*	1.14**	1.20*	1.08	1.08*	1.08**	1.02	1.04	0.98*	1.01
LSTM	1.05	1.03	0.96*	0.99	0.99	1.10*	0.98	0.97*	0.99	0.99
Dense	1.42***	1.41***	1.11	1.18*	1.36***	1.12**	1.02	0.98	0.99	0.99
Combinaisons de prévisions										
AVRG	1.00	0.99	0.99	1.01	1.00	1.00	0.99	1.01	1.01	1.00
Médiane	1.01	0.99	1.00	1.00	0.99	1.02	1.00	1.00	1.01	0.99
T-AVRG,0.1	1.01	0.99	1.00	1.01	1.00	1.01	0.99	1.01	1.01	0.99
T-AVRG,0.2	1.01	0.99	1.00	1.00	0.99	1.02	0.99	1.01	1.01	0.99
IP-AVRG,1	1.00	0.99	1.00	1.01	1.00	0.99	1.00	1.01	1.01	0.99
IP-AVRG,0.95	1.00	0.99	1.00	1.01	1.00	0.99	1.00	1.01	1.01	0.99

TABLE 7: Consommation réelle - Québec : RMSE relatifs

Models	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC (RMSE)	0.004	0.004	0.004	0.004	0.004	0.004	0.004	0.004	0.004	0.004
ARDI,BIC	1.06	0.98	1.01*	1.00	1.01***	1.06	1.00	1.03*	1.00	1.02**
Régressions pénalisées										
Ridge	1.13**	0.98	0.99	0.97**	0.99	1.21	0.98	0.99	0.97**	0.99
Lasso	1.21	0.98	1.00	0.97**	0.99	1.20	1.01	1.01	0.97	0.99
Elastic-Net	1.34**	0.98	0.99	0.97**	0.99	1.02	0.98	0.99	0.97**	0.99
Adaptive-Lasso	0.99	1.02	1.03	1.01	1.00	1.00	1.01	0.99	0.99	1.00
ARDI,Ridge	1.11*	0.98	0.99	0.97**	0.99	0.98	0.98	0.99	0.97**	0.99
ARDI,Lasso	0.92*	0.96	0.99	0.97**	0.99	0.98	0.98	0.99	0.97**	0.99
ARDI,Elastic-Net	1.00	0.98	0.99	0.97**	0.99	0.98	0.98	0.99	0.97**	0.99
ARDI,Adaptive-Lasso	1.09*	0.99	1.06*	0.98	1.00	1.09	1.01	0.98*	0.97	0.97
Ridge-MAF	0.99	1.00	1.01	0.99	1.00	0.98	0.99	1.00	0.98	1.00
LASSO-MAF	1.00	0.98	0.99	1.00	0.99	0.98	0.98	0.99	1.04	0.99
ELAS-MAF	0.98	0.98	0.99	1.00	0.99	0.98	0.98	0.99	0.97*	1.00
Régressions régularisées par sous-ensembles complets										
T-CSR10	1.15**	1.14**	1.18**	1.30***	1.28***	1.12*	1.04	1.16**	1.31**	1.18***
T-CSR20	0.98	1.03	0.99*	0.99*	0.99	0.97	0.99	0.99	0.98***	0.99
CSR-R10	0.98	1.06	0.98	0.99*	1.00	0.97	1.00	0.98*	0.98	1.01
CSR-R20	0.98	0.98	0.99	0.97**	1.03	1.05	1.08	0.99	0.97*	0.96
Régressions à vecteurs de support										
NL-SVRARDI	1.06	1.04	1.08	1.16***	1.12**	1.07*	1.00	1.08*	1.15**	1.07*
L-SVRARDI	1.03	1.11	1.07*	0.99	1.09**	1.27*	1.16*	1.02	0.98	1.01
Forêts d'arbres aléatoires										
RFARDI	0.99	0.99	1.02	1.03	1.06*	1.01	0.97	0.97	1.00	1.02
RF-X	1.01	1.01	1.02	0.97*	1.00	1.00	0.99	1.00	0.98	1.02
RF-CSF	1.06	1.03	1.08	0.99	1.10*	1.07	1.05	1.05	1.04	1.09**
RF-MAF	0.99	1.01	1.06	1.00	1.04	1.01	1.01	1.02	1.01	1.03
RF-X-CSF	1.01	1.02	1.04	0.98	1.01	0.99	1.00	1.01	0.99	1.01
LLF-CSF	1.04	1.43*	1.05	1.07	1.02	1.02	1.02	1.06**	1.09**	1.13***
ARERT	0.96	0.99	1.05**	0.99	1.13***	1.05	0.99	1.10***	0.98	1.14**
ARDIERT	1.64**	1.13*	1.33**	1.46*	1.41**	1.22**	0.97	1.20***	1.07	1.22**
EOTB-ERT	1.09**	1.05	1.05	1.08*	1.11**	1.13**	1.08*	1.05*	1.07*	1.08**
ARRF	1.03	1.00	1.13**	0.97	1.12**	1.02	1.00	1.07**	1.02	1.14**
ARDIRF	1.79*	0.99	1.24*	1.23*	1.34**	1.12*	1.02	1.26*	0.96	1.97*
EOTB-MRF	1.13**	1.11**	1.20*	1.01	1.14*	1.09*	1.07*	1.01	1.06	1.10***
ERT-MAF	1.01	1.00	1.03	0.99	1.02	0.97	1.00	1.02	0.98	1.01
Réseaux de neurones										
LSTM-Dense-AR	0.98	0.97	0.99	0.98	0.99	0.98	0.97	0.99	0.98	0.99
LSTM-AR	0.97	0.97	0.99	0.97	1.00	0.97	0.97	0.99	0.97	1.00
Dense-AR	0.96*	0.95**	1.02	0.98	0.99	0.96*	0.95**	1.02	0.98	0.99
LSTM-Dense-ARDI	0.97	0.98	0.97*	0.97	1.00	1.06	0.99	0.98	0.97	1.03
LSTM-ARDI	1.03	1.01	1.02	1.00	1.00	0.98	0.98	0.99	0.98	1.02
Dense-ARDI	0.99	0.98	0.99	0.95*	1.11	1.01	1.17	1.35**	0.97	1.13***
LSTM-Dense	1.04	1.18	0.97*	0.95*	1.04	1.19	1.00	1.03	0.97	0.98
LSTM	0.97	1.14*	1.09*	1.10	1.00	1.03	1.03	1.00	1.00	1.00
Dense	0.98	0.96	0.97	1.03	0.97	1.00	0.97	1.00	0.98	1.05
Combinaisons de prévisions										
AVRG	0.98	0.97	1.00	0.99	1.00	0.98	0.97*	1.00	0.98	1.01
Médiane	0.98	0.97*	0.99	0.97**	0.99	0.98	0.98	1.00	0.97**	0.99
T-AVRG,0.1	0.98	0.97	1.00	0.97*	1.00	0.98	0.97	1.00	0.98*	1.00
T-AVRG,0.2	0.98	0.97	1.00	0.97*	1.00	0.98	0.97	1.00	0.97**	1.00
IP-AVRG,1	0.98	0.97	1.00	0.98	1.00	0.98	0.97*	1.00	0.98	1.00
IP-AVRG,0.95	0.97	0.97*	1.00	0.98	1.00	0.98	0.97*	1.00	0.98	1.00

TABLE 8: Consommation réelle - Canada : RMSE relatifs

Models	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC (RMSE)	0.003	0.003	0.003							
ARDI,BIC	1.16***	1.14*	1.04*	1.00	1.01	1.18***	1.24*	1.07	1.01	1.01*
Régressions pénalisées										
Ridge	1.12	1.00	1.00	0.98	1.00	1.32*	1.00	1.00	0.98	1.01
Lasso	1.28	1.01	1.00	0.98	1.00	1.19	1.05	1.08	1.00	1.00
Elastic-Net	1.35*	1.00	1.00	0.98	1.00	1.02	1.00	1.00	0.98	1.00
Adaptive-Lasso	0.98	1.05*	1.07	1.02	1.03	0.96	1.07*	1.06	0.99	1.00
ARDI,Ridge	1.21*	1.00	1.00	0.98	1.00	0.99	1.00	1.00	0.98	1.00
ARDI,Lasso	1.01	1.00	1.00	0.98	1.00	1.00	1.00	1.00	0.98	1.00
ARDI,Elastic-Net	1.00	1.00	1.00	0.98	1.00	0.99	1.00	1.00	0.98	1.00
ARDI,Adaptive-Lasso	1.00	1.00	1.04	0.98	1.00	1.14	1.08	1.21	1.00	1.01
Ridge-MAF	1.00	1.01	1.02	1.00	1.00	1.00	1.02	1.02	1.00	1.01
LASSO-MAF	1.02	1.02	1.00	1.01	1.01	0.98	1.01	1.02	0.99	1.01
ELAS-MAF	0.97	1.01	1.01	1.00	0.99	0.99	1.01	1.07**	0.99	1.01
Régressions régularisées par sous-ensembles complets										
T-CSR10	1.13	1.11**	1.25***	1.33***	1.29**	1.11	1.09*	1.14**	1.29***	1.18**
T-CSR20	0.94	1.15**	1.00	0.99	1.00	0.94	0.98	1.00	0.99	1.00
CSR-R10	0.94	1.25***	1.00	0.99	1.02	0.94	0.98	1.00	0.99	1.01
CSR-R20	0.98	1.02	1.00	0.96	1.01	1.13**	1.06	1.00	0.99	1.02
Régressions à vecteurs de support										
NL-SVRARDI	1.04	1.09**	1.13***	1.17***	1.14*	1.03	1.06**	1.09	1.13**	1.10**
L-SVRARDI	1.19**	1.15*	1.03	1.00	1.10*	1.23**	1.14*	1.00	1.02	0.98
Forêts d'arbres aléatoires										
RFARDI	1.09	1.11	1.07	1.08*	1.08*	1.08	1.07*	1.04	1.08**	1.06
RF-X	1.01	1.05	1.03	1.01	1.04	1.02	1.09**	1.08**	1.06***	1.06*
RF-CSF	1.01	1.14*	1.04	1.09	1.07*	1.14**	1.15**	1.11	1.03	1.07
RF-MAF	1.05	1.05	1.06*	1.06	1.06	1.04	1.07**	1.07**	1.15**	1.10*
RF-X-CSF	0.99	1.06*	1.04	1.01	1.05	1.03	1.08**	1.08**	1.06***	1.05**
LLF-CSF	1.12	1.16	1.05	1.07	1.06	1.20**	1.16*	1.09	1.05	1.10**
ARERT	1.10	1.11*	1.08**	1.13**	1.05**	0.97	1.12***	1.04	1.15***	1.06
ARDIERT	1.64*	1.10*	1.21	1.12**	1.28*	1.23**	1.05	1.16**	1.13**	1.13*
EOTB-ERT	1.05	1.19**	0.99	1.09	1.03	1.08**	1.16**	1.11	0.99	1.06
ARRF	1.13	1.05	1.13**	1.27**	1.05	1.08*	1.09**	1.14**	1.33**	1.08**
ARDIRF	1.78*	1.03	1.26**	1.18**	1.22*	1.20**	1.03	1.25**	1.14*	1.14*
EOTB-MRF	1.09**	1.15***	1.04	1.03	1.09**	1.07*	1.03	1.04	1.04	1.18**
ERT-MAF	1.00	1.08*	1.05*	1.02	1.01	1.04	1.05*	1.06*	1.06**	1.01
Réseau de neurones										
LSTM-Dense-AR	0.98	1.00	0.99	0.99	1.01	0.98	1.00	0.99	0.99	1.01
LSTM-AR	1.00	1.03	1.01*	0.99	1.01	1.00	1.03	1.01*	0.99	1.01
Dense-AR	1.10**	1.01	1.02	1.01	0.99	1.10**	1.01	1.02	1.01	0.99
LSTM-Dense-ARDI	1.01	0.98	1.02**	0.98	1.02	0.98	1.00	1.03	1.03	1.00
LSTM-ARDI	1.03	0.98	1.08*	1.03	1.08**	1.00	1.01	1.02	1.03	1.05*
Dense-ARDI	1.13	1.28**	1.03	0.99	0.93	0.97	1.00	1.04	1.13	1.23**
LSTM-Dense	1.04	1.01	1.03	1.09	1.03	1.07	0.97	1.32	0.96	1.00
LSTM	0.95	1.09**	1.00	1.00	1.02	0.98	1.08	1.30***	1.10*	0.99
Dense	1.00	0.99	0.99	1.00	1.01	2.18***	1.65**	1.05	1.91**	2.97*
Combinaisons de prévisions										
AVRG	0.98	1.00	1.01	0.99	1.00	0.96	1.01	1.03	1.00	1.00
Médiane	0.98	1.00	1.00	0.99	1.00	1.00	1.01	1.01	0.99	1.00
T-AVRG,0.1	0.98	1.01	1.01	0.99	1.00	0.98	1.01	1.02	1.00	1.00
T-AVRG,0.2	0.98	1.01	1.01	0.99	1.00	0.99	1.01	1.02	1.00	1.00
IP-AVRG,1	0.98	1.01	1.01	0.99	1.00	0.98	1.01	1.03	1.00	1.01
IP-AVRG,0.95	0.98	1.01	1.01	0.99	1.00	0.98	1.01	1.03	1.00	1.01

TABLE 9: Taux de chômage - Québec : RMSE relatifs

Models	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC (RMSE)	0.299	0.307	0.315	0.300	0.294	0.299	0.307	0.315	0.300	0.294
ARDI,BIC	1.05*	0.98	0.98	1.00	1.00	1.19*	1.04	1.00	1.06	1.03
Régressions pénalisées										
Ridge	0.97	0.99	0.95**	1.00	1.01	1.00	0.95**	0.95**	1.00	1.01
Lasso	<u>0.90</u> *	0.97	0.95**	1.00	1.01	<u>0.88</u> *	0.93*	0.94	0.98	1.00
Elastic-Net	1.00	0.97*	0.95**	1.00	1.01	<u>0.88</u> *	0.97*	0.95**	1.00	1.01
Adaptive-Lasso	0.92*	0.97*	0.98	1.02	1.04*	0.91*	0.96	0.97	1.01	1.04**
ARDI,Ridge	0.95	1.04	0.95**	1.00	1.01	1.00	0.97**	0.96*	1.00	1.01
ARDI,Lasso	0.93	0.99	0.95**	1.00	1.04*	0.97	1.03	0.95**	1.00	1.01
ARDI,Elastic-Net	0.99	1.06	0.95**	1.00	1.01	1.00	1.02	0.95*	1.00	1.01
ARDI,Adaptive-Lasso	0.95	0.96	1.01	1.00	1.01	1.07	1.00	1.72	1.02	1.01
Ridge-MAF	0.95*	0.96*	0.95	0.99	1.01	0.98	0.97**	0.96	1.00	1.01
LASSO-MAF	1.00	0.97	0.95*	1.01	1.02	1.01	0.98	0.95*	1.00	1.02
ELAS-MAF	1.00	0.98	0.93	1.00	1.04**	1.00	0.98	0.95*	1.00	1.02
Régressions régularisées par sous-ensembles complets										
T-CSR10	1.02	0.96	1.09**	1.15*	1.31***	0.94	0.94	1.01	1.57*	1.24***
T-CSR20	1.02	0.98	0.97	1.04**	1.02	1.00	0.98	0.95*	1.02**	1.03*
CSR-R10	0.98	0.99	0.99	1.08**	1.04**	0.96	0.98	0.94	1.02**	1.03**
CSR-R20	0.94	1.02	0.96*	1.00	1.04**	0.98	1.09	0.98	0.97	1.01
Régressions à vecteurs de support										
NL-SVRARDI	0.97	0.92*	1.02	1.08*	1.15***	0.91	0.92	0.98	1.17	1.11**
L-SVRARDI	1.10	1.06	1.06	1.03	1.00	0.95	0.94*	1.10	1.07**	1.02
Forêts d'arbres aléatoires										
RFARDI	1.03	1.00	1.06*	1.08**	1.07*	1.04	1.00	1.07	1.09	1.07
RF-X	0.96	0.98	0.99	1.00	1.03*	1.00	0.99	0.98	1.01	1.03
RF-CSF	0.98	0.97	1.01	1.04	1.02	1.03	0.99	1.02	1.01	1.01
RF-MAF	0.95	0.96	0.98	0.99	1.06**	0.96	0.95**	0.97	0.98	1.02
RF-X-CSF	0.98	0.99	0.95	1.00	1.02	0.98	0.99	0.98	1.00	1.03
LLF-CSF	1.03	0.99	1.08	1.13*	1.05	1.04	0.99	1.02	1.02	1.02
ARERT	0.97	1.05	0.98	1.12**	1.04	1.00	1.05	1.04	1.11**	1.03
ARDIERT	1.24	1.12	1.16**	1.16***	1.25*	1.05	1.06	1.06	1.24***	1.00
EOTB-ERT	1.03	1.07*	1.24	1.10*	1.16**	0.97	1.07	1.05	0.98	1.23***
ARRF	0.95	1.01	0.98	1.13**	1.10*	1.00	1.09***	0.99	1.14***	1.06
ARDIRF	1.18*	1.10	1.05	1.25**	1.16**	1.05	0.98	1.01	1.22***	1.17**
EOTB-MRF	0.95	1.03	1.19	1.11**	1.13*	1.04	1.12*	1.05	1.05	1.22***
ERT-MAF	0.95*	0.95	0.97	1.01	1.03	0.96	0.96*	0.95	1.00	0.99
Réseau de neurones										
LSTM-Dense-AR	1.00	0.96**	0.94*	1.00	1.02**	1.00	0.96**	0.94*	1.00	1.02**
LSTM-AR	1.00	0.98	0.95*	1.00	1.02**	1.00	0.98	0.95*	1.00	1.02**
Dense-AR	1.02	0.98	0.97	1.07***	1.02**	1.02	0.98	0.97	1.07***	1.02**
LSTM-Dense-ARDI	1.04	0.94**	0.93*	0.97	1.07	1.02	0.91*	0.96	0.99	1.02
LSTM-ARDI	1.04	0.98	0.95*	0.99	1.08*	1.03	1.01	0.96	1.05*	1.03
Dense-ARDI	1.02	1.30**	1.24***	1.08**	1.12**	1.07	0.97	0.98	1.02	1.07
LSTM-Dense	1.08*	0.98	1.02	1.05	1.04	1.28**	1.64	1.13	1.26**	1.18***
LSTM	1.08**	0.97	1.03	1.00	1.03*	1.06	1.00	1.14*	1.11*	1.06
Dense	2.93**	1.01	0.94	1.03	1.07*	3.97**	1.64**	1.48***	1.72***	2.32***
Combinaisons de prévisions										
AVRG	0.92**	0.96**	0.96	1.01	1.02	0.94*	0.93**	0.95	0.99	1.01
Médiane	0.94**	0.96**	0.95*	1.00	1.01	0.94*	0.95***	0.95	1.00	1.00
T-AVRG,0.1	0.93*	0.96**	0.96	1.00	1.01	0.93*	0.94**	0.95	0.99	1.01
T-AVRG,0.2	0.94*	0.96**	0.96	1.00	1.01	0.93*	0.95**	0.95	1.00	1.01
IP-AVRG,1	0.93*	0.96**	0.96	1.01	1.02	0.93*	0.94**	0.96	0.99	1.01
IP-AVRG,0.95	0.93*	0.96**	0.96	1.01	1.02	0.93*	0.94**	0.96	0.99	1.01

TABLE 10: Taux de chômage - Canada : RMSE relatifs

Models	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC (RMSE)	0.229	0.252	0.262	0.262	0.258	0.229	0.252	0.262	0.262	0.258
ARDI,BIC	0.93	1.00	1.01	1.00	1.01	0.93	1.12	1.17*	1.10	1.11
Régressions pénalisées										
Ridge	1.08	1.03	1.04	0.99*	1.03	1.11	1.04	0.83	0.99*	1.01
Lasso	0.88**	0.95	1.08*	0.99	0.99	0.84*	0.96	1.04	0.97	1.04
Elastic-Net	1.19	1.02	0.99	0.99*	1.00	1.12	1.02	0.99	0.99	1.00
Adaptive-Lasso	0.86***	0.95**	0.97	0.98	1.01	0.84**	0.97	1.01	1.00	1.00
ARDI,Ridge	1.02	1.00	0.99	0.99*	0.98	0.86**	1.07	0.99	0.99*	0.93
ARDI,Lasso	0.91	0.99	0.99	0.99*	0.98	0.85**	1.04	1.08	0.97*	0.91
ARDI,Elastic-Net	0.90	1.10	0.99	0.99*	1.07	1.19	1.23*	0.99	0.99*	1.00
ARDI,Adaptive-Lasso	0.86**	1.04	1.00	0.95	1.00	0.84*	1.08	1.13	0.95	1.04
Ridge-MAF	0.92*	0.97	0.97	0.96	0.98	1.00	1.00	0.98	0.97	0.99
LASSO-MAF	0.99	0.95**	0.94	0.99	1.00	0.93	0.92*	1.00	0.98*	1.01
ELAS-MAF	0.92*	0.96*	0.99	0.98*	1.00	0.92*	0.93*	0.99	0.98*	1.00
Régressions régularisées par sous-ensembles complets										
T-CSR10	0.89	1.01	0.97	1.04	1.20***	0.81*	0.91	0.93	1.01	1.13**
T-CSR20	1.24	1.07*	0.98	0.99	1.00	1.23	1.03	0.97	0.99	1.01*
CSR-R10	1.16	1.05*	0.98	1.00	1.01***	1.14	1.00	0.95	0.99	1.01**
CSR-R20	0.86*	0.93	0.99	1.00	1.06	1.04	0.99	1.17	1.03	1.00
Régressions à vecteurs de support										
NL-SVRARDI	0.86**	0.94	0.94	0.97	1.08***	0.80*	0.88	0.91	0.95	1.04
L-SVRARDI	1.13	0.96	0.99	1.01	1.04	1.00	1.03	1.04	1.07	1.02
Forêts d'arbres aléatoires										
RFARDI	0.91**	0.94	1.03	1.01	1.02	0.91	0.93	1.02	0.99	1.03
RF-X	0.93*	0.95	0.99	0.94	1.01	0.94	0.97	0.98	0.96	0.98
RF-CSF	0.83**	0.93	1.04	1.01	1.02	0.90**	0.96	1.15	0.99	0.97
RF-MAF	0.92*	0.91	0.92	0.95	1.02	0.93*	0.93	0.90	0.94	1.01
RF-X-CSF	0.91**	0.96	0.99	0.93	0.99	0.92*	0.98	0.98	0.95	0.97
LLF-CSF	0.91**	1.04	1.03	1.01	1.06	0.92**	0.98	1.05	0.99	0.98
ARERT	0.87***	0.90	1.08	1.00	0.97	0.90***	1.04	1.07	1.05	0.97
ARDIERT	0.86*	1.14	1.07	1.10	1.08	0.82**	1.00	0.96	1.11***	0.96
EOTB-ERT	0.97	0.99	0.90	1.10	1.06**	0.74*	1.06	0.92	0.93	1.01
ARRF	0.98	0.91	0.98	1.08	1.05*	0.95	0.98	1.04	1.04	1.03
ARDIRF	0.99	1.03	0.90	1.21	1.11*	0.91**	1.02	1.01	1.07***	1.10*
EOTB-MRF	1.00	1.00	1.02	0.89	0.93	0.96	1.01	0.94	0.99	0.96
ERT-MAF	0.89***	0.93	0.98	0.98	0.99	0.92*	0.95*	0.97	0.97	1.00
Réseau de neurones										
LSTM-Dense-AR	1.09	1.03	0.97	0.97	0.99	1.09	1.03	0.97	0.97	0.99
LSTM-AR	1.12	1.01	0.98	0.98	1.00	1.12	1.01	0.98	0.98	1.00
Dense-AR	0.93**	0.98	1.00	1.01	0.98	0.93**	0.98	1.00	1.01	0.98
LSTM-Dense-ARDI	1.03	1.06	0.97	0.99	1.02	0.87	0.91	1.87	1.01	1.08
LSTM-ARDI	1.17	0.96**	0.98	1.00	1.33	1.25	1.03	1.12	1.00	1.04
Dense-ARDI	0.93	1.14*	0.99	1.07	1.12**	1.65**	1.31*	1.35	1.37	1.17
LSTM-Dense	1.20*	1.27*	0.97	1.39*	1.11	0.99	1.40**	1.06	1.06	0.89
LSTM	1.14	1.25**	1.00	0.99	1.08	1.10	0.99	1.02	1.01	1.00
Dense	1.59***	1.67***	1.37**	1.07	1.51**	1.74**	2.80***	2.02*	1.76***	2.33**
Combinaisons de prévisions										
AVRG	0.84***	0.93**	0.94	0.96	0.98	0.82***	0.90*	0.93	0.95	0.97
Médiane	0.86***	0.95***	0.96	0.96	0.98	0.87***	0.93*	0.96	0.96	0.98
T-AVRG,0.1	0.83***	0.93**	0.95	0.96	0.98	0.83***	0.93*	0.96	0.96	0.97
T-AVRG,0.2	0.84***	0.93**	0.95	0.96	0.98	0.84***	0.93*	0.96	0.96	0.97
IP-AVRG,1	0.85***	0.93**	0.95	0.97	0.98	0.83***	0.93*	0.96	0.96	0.97
IP-AVRG,0.95	0.85***	0.93**	0.95	0.97	0.98	0.83***	0.94*	0.96	0.96	0.97

TABLE 11: Emploi - Québec : RMSE relatifs

Models	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC (RMSE)	0.005	0.005	0.005	0.005	0.005	0.005	0.005	0.005	0.005	0.005
ARDI,BIC	0.97	0.96*	1.00	1.00	1.00	0.97	0.98	1.02	1.04	1.11
Régressions pénalisées										
Ridge	0.91*	0.97	1.00	0.99	0.99	0.92*	0.93**	0.99	0.98	1.00
Lasso	0.91**	0.98	0.99	1.00	0.98	0.91**	0.96	1.01	1.02	1.06**
Elastic-Net	0.91*	0.97	0.99	0.99	0.99	0.91*	0.97	0.99	0.99	0.99
Adaptive-Lasso	0.90**	0.95	0.97	1.04**	1.04**	0.91**	0.97	0.97	1.01	1.05***
ARDI,Ridge	0.91*	0.97	0.99	0.99	1.02	0.91*	0.97	0.99	0.99	0.99
ARDI,Lasso	1.00	0.97	0.99	0.99	1.00	0.91*	0.92**	0.99	0.99	0.98
ARDI,Elastic-Net	0.98	0.97	0.99	0.99	0.99	0.91*	0.97	0.99	0.99	0.99
ARDI,Adaptive-Lasso	0.90**	0.92**	0.98	1.01	1.00	0.95	0.98	1.00	1.01	1.04
Ridge-MAF	0.91**	0.98	1.00	1.00	0.99	0.91*	0.97	0.99	0.99	0.99
LASSO-MAF	0.94	0.98	0.98	1.01	1.00	0.92*	0.97	0.97	1.01	1.00
ELAS-MAF	0.93	0.98	0.97	0.99	0.99	0.92*	0.98	0.97	0.99	0.99
Régressions régularisées par sous-ensembles complets										
T-CSR10	0.99	0.96	1.09	1.04	1.11*	0.94*	0.98	1.06	1.15*	1.09
T-CSR20	0.92**	0.96	1.00	1.03**	1.01	0.87**	0.97	0.99	1.02	0.99
CSR-R10	0.92*	0.96	1.01	1.05***	1.01	0.88**	0.97	1.00	1.02	0.99
CSR-R20	0.93**	0.98	0.99	1.01	1.06	0.93*	1.01	0.99	0.99	1.05
Régressions à vecteurs de support										
NL-SVRARDI	0.97	0.95	1.05	1.00	1.05	0.93**	0.96	1.02	1.06	1.04
L-SVRARDI	0.95*	1.04	1.00	1.02	1.12**	0.90**	1.06	1.04	1.06	1.05
Forêts d'arbres aléatoires										
RFARDI	0.97	1.06*	1.09**	1.06**	1.07**	0.94	1.01	1.06	1.08	1.09**
RF-X	0.93*	1.01	0.99	1.00	1.02	0.92*	1.00	1.02	1.02	1.00
RF-CSF	0.92*	1.03	1.06	1.06	1.04	0.97	1.07	1.10**	1.09*	1.12**
RF-MAF	0.93*	1.04	1.00	1.02	1.05*	0.92*	1.03	1.03	1.03	1.05*
RF-X-CSF	0.93*	1.01	1.00	1.02	1.02	0.91*	1.00	1.03	1.02	1.01
LLF-CSF	0.95	1.06	1.14**	1.10	1.08	0.99	1.08*	1.13**	1.07	1.05
ARERT	1.03	1.02	1.01	1.06*	1.09*	0.96*	1.05	1.02	1.08**	1.06
ARDIERT	1.02	1.21*	1.29**	1.14**	1.04	1.03	1.09*	1.06***	1.23***	1.06*
EOTB-ERT	0.98	1.11	1.22	1.27***	1.24**	0.99	1.11**	1.02	1.18**	1.14**
ARRF	0.96	1.02	1.07	1.06*	1.11**	0.99	1.06*	1.09**	1.11***	1.13**
ARDIRF	0.98	1.14	1.32*	1.24**	1.06	0.96	1.17*	1.04	1.15**	1.07**
EOTB-MRF	1.03	1.09	1.19	1.34***	1.16**	0.98	1.07	1.01	1.24**	1.13*
ERT-MAF	0.92*	1.03	0.98	1.01	1.03	0.91**	1.02	1.01	1.04**	1.04
Réseau de neurones										
LSTM-Dense-AR	0.95	0.98	0.98	1.00	0.99	0.95	0.98	0.98	1.00	0.99
LSTM-AR	0.91*	0.96	0.98	0.99	0.99	0.91*	0.96	0.98	0.99	0.99
Dense-AR	0.95	0.99	1.00	1.01	1.00	0.95	0.99	1.00	1.01	1.00
LSTM-Dense-ARDI	0.91**	0.96	0.98	0.98	1.02	1.01	1.03	0.97	1.00	0.99
LSTM-ARDI	0.94	0.97	0.97	1.03	1.01	0.90*	0.97	1.00	1.03	1.03
Dense-ARDI	1.11*	1.03	0.92*	1.28*	1.06	1.43	1.09	1.21*	1.11	1.53*
LSTM-Dense	1.18	1.04	1.32**	1.04	1.08*	1.31	1.03	1.00	1.07	1.04
LSTM	0.94	0.98	0.99	1.09	1.09**	1.00	0.95*	0.96	1.07*	1.10
Dense	1.51*	1.81**	1.77**	1.87**	1.36***	2.23***	1.94*	1.81*	1.23*	2.95*
Combinaisons de prévisions										
AVRG	0.91**	0.97	1.00	1.01	1.00	0.91**	0.96	1.00	1.02	1.01
Médiane	0.91**	0.98	0.99	0.99	1.00	0.91**	0.97	0.99	1.00	1.00
T-AVRG,0.1	0.91**	0.97	0.99	1.00	1.00	0.90**	0.97	0.99	1.01	1.00
T-AVRG,0.2	0.91**	0.97	0.99	1.00	1.00	0.91**	0.97	0.99	1.01	1.00
IP-AVRG,1	0.91**	0.97	0.99	1.01	1.00	0.91**	0.97	0.99	1.02	1.00
IP-AVRG,0.95	0.91**	0.97	0.99	1.01	1.00	0.91**	0.97	0.99	1.02	1.01

TABLE 12: Emploi - Canada : RMSE relatifs

Models	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC (RMSE)	0.003	0.003	0.004	0.004	0.004	0.003	0.003	0.004	0.004	0.004
ARDI,BIC	1.01	1.07*	1.00	1.00	1.11	1.11	1.00	1.13	1.06	1.05
Régressions pénalisées										
Ridge	1.11	1.02	0.98*	0.96	0.99	0.93	0.89*	0.98*	1.02	0.93*
Lasso	1.03	0.91*	0.98	0.99	0.99	0.95	0.88	1.01	1.00	0.98
Elastic-Net	1.06	1.02	0.98*	0.98	0.98***	1.03	1.02	0.98*	0.98	0.98***
Adaptive-Lasso	0.91*	1.01	1.01	1.04***	1.04***	0.89*	0.99	0.97	0.98	1.02
ARDI,Ridge	1.00	1.06	0.98*	0.98	1.07*	1.26*	1.01	0.98*	0.98	0.98**
ARDI,Lasso	1.03	1.03	0.98*	0.98	0.98***	1.29	1.03	0.98*	0.99	0.98**
ARDI,Elastic-Net	1.13	1.07*	0.98*	0.98	1.02	1.24*	1.02	0.98*	0.98	0.98***
ARDI,Adaptive-Lasso	0.85*	0.95	1.06*	0.99	0.96	0.80**	1.05	1.02	0.97	1.01
Ridge-MAF	0.94	0.97	0.95	0.95	0.96	0.96	0.99	0.96	0.96	0.96
LASSO-MAF	0.96	1.06	0.90	0.99	1.03	0.94	1.06	0.92	0.97	1.02
ELAS-MAF	0.89**	0.95	0.89	0.98	0.96	0.86**	0.99	0.95	0.98	0.99
Régressions régularisées par sous-ensembles complets										
T-CSR10	0.84*	1.02	0.95	1.01	1.07	0.87**	0.97	0.93	1.01	1.10
T-CSR20	0.96	0.96***	0.96*	0.98	1.01	0.95	0.95**	0.96*	0.99	1.01
CSR-R10	0.95	0.95***	0.96	0.97	1.01	0.94	0.95**	0.95	0.99	1.01
CSR-R20	0.91**	0.95*	0.98*	0.96	1.10	1.03	1.00	1.00	1.01	1.00
Régressions à vecteurs de support										
NL-SVRARDI	0.86**	0.98	0.95	0.97	1.01	0.87**	0.93	0.91	0.96	1.01
L-SVRARDI	1.03	1.02	1.02	0.96	1.02	0.96	1.04	1.15**	1.04	0.99
Forêts d'arbres aléatoires										
RFARDI	0.99	1.05**	1.05	1.08***	1.04	0.97	1.01	0.99	1.02	1.03
RF-X	1.04	0.99	0.93	0.92	1.03***	1.06	1.07*	1.01	1.02	1.03***
RF-CSF	0.90*	0.99	0.94	1.00	0.98	1.01	1.08***	1.11	1.06	0.97
RF-MAF	1.03	0.99	0.90	0.93	1.07***	1.05	1.01	0.94	1.02	1.07***
RF-X-CSF	1.02	1.00	0.93	0.94	1.01	1.06	1.07*	1.02	1.02	1.03***
LLF-CSF	0.92*	1.03	0.98	0.99	0.95	0.94	1.00	1.01	1.03	0.95
ARERT	0.97	0.95	0.96	1.00	1.02	0.97	0.96	0.99	1.02	1.02
ARDIERT	1.07	1.25*	1.23	1.16***	1.06*	0.91	1.04	0.99	1.17***	1.03
EOTB-ERT	1.07	1.08**	0.88	1.15***	1.11*	1.19	1.07**	1.02	1.11**	1.05
ARRF	0.96	0.97	1.05	0.96	1.14***	0.96	0.98	1.04*	1.03	1.12***
ARDIRF	1.18*	1.39*	1.32**	1.24***	1.06	0.93	1.09**	1.00	1.20**	1.12***
EOTB-MRF	1.18	1.07**	0.97	1.10	1.03	1.12	1.01	0.99	1.11	1.09
ERT-MAF	1.01	0.98	0.93	0.96	1.01	0.99	1.01	0.96	0.99	1.02
Réseau de neurones										
LSTM-Dense-AR	1.11	1.00	0.94**	0.97*	0.95**	1.11	1.00	0.94**	0.97*	0.95**
LSTM-AR	1.08	1.02	0.96**	0.97*	0.96**	1.08	1.02	0.96**	0.97*	0.96**
Dense-AR	0.93*	0.96**	0.97	1.02	0.94**	0.93*	0.96**	0.97	1.02	0.94**
LSTM-Dense-ARDI	1.12*	1.05	0.96**	0.98	0.98	1.04	1.00	1.02	0.94	1.01
LSTM-ARDI	1.16	1.03	0.97	0.96	0.99	1.05	1.18*	1.02	0.97	1.00
Dense-ARDI	1.23	1.11**	1.05	1.08**	0.97	1.50*	1.23**	0.93	1.16*	1.09**
LSTM-Dense	1.05	1.35***	1.09*	1.18***	1.08*	1.81**	1.13*	2.14*	1.92***	0.96
LSTM	1.19*	1.03	0.97	0.96	0.96	1.04	0.94	1.00	0.98	0.92*
Dense	3.39***	1.66***	1.94*	1.43***	1.07	2.28**	3.19***	2.03**	2.57***	2.65***
Combinaisons de prévisions										
AVRG	0.88**	0.96**	0.94	0.95	0.96	0.89**	0.93	0.96	0.98	0.97
Médiane	0.90**	0.97**	0.96	0.97	0.96	0.90**	0.96*	0.96	0.98	0.97
T-AVRG,0.1	0.88**	0.96**	0.94	0.96	0.97	0.89**	0.95*	0.96	0.98	0.97
T-AVRG,0.2	0.88**	0.96**	0.95	0.96	0.97	0.90**	0.96*	0.97	0.98	0.97
IP-AVRG,1	0.88***	0.96**	0.95	0.96	0.96	0.89**	0.96	0.97	0.99	0.97
IP-AVRG,0.95	0.88***	0.96**	0.95	0.96	0.96	0.89**	0.96	0.97	0.99	0.97

TABLE 13: Mises en chantier - Québec : RMSE relatifs

Models	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC (RMSE)	0.103	0.107	0.110	0.113	0.109	0.103	0.107	0.110	0.113	0.109
ARDI,BIC	1.02	1.01	0.97*	0.98	1.02*	1.09	1.02	1.06	0.99	1.03**
Régressions pénalisées										
Ridge	1.08*	1.03	1.00	0.97*	1.01	1.08*	1.04	1.00	0.97*	1.01
Lasso	1.07*	1.02	1.00	0.97*	1.01	1.07*	1.02	1.00	0.99	1.00
Elastic-Net	1.08*	1.04	1.00	0.97*	1.01	1.08*	1.04	1.00	0.97*	1.01
Adaptive-Lasso	1.07*	1.03	1.00	0.97*	1.00	1.08*	1.03	0.99	0.96**	0.99
ARDI,Ridge	1.09**	1.04	1.00	0.97*	1.01	1.08**	1.04	1.02	0.97*	1.01
ARDI,Lasso	1.05	1.02	1.00	0.97*	1.01	1.05	1.04	1.00	0.97*	1.01
ARDI,Elastic-Net	1.08*	1.04	1.00	0.97*	1.01	1.08*	1.04	1.00	0.97*	1.01
ARDI,Adaptive-Lasso	1.09**	1.07	1.01	0.97*	1.01	1.06	1.06	1.01	0.99	1.00
Ridge-MAF	1.08*	1.02	1.00	0.98*	1.00	1.07*	1.02	1.00	0.97*	1.00
LASSO-MAF	1.08*	1.03	1.01	0.97*	1.00	1.07*	1.03	1.00	0.97*	1.00
ELAS-MAF	1.09**	1.03	1.00	0.97*	1.00	1.08*	1.03	1.00	0.97*	1.00
Régressions régularisées par sous-ensembles complets										
T-CSR10	1.03	1.08*	1.09**	1.13**	1.12**	1.03	1.07	1.05*	1.12***	1.05
T-CSR20	1.15***	1.08	1.01	0.98	1.00	1.15**	1.06	1.02	0.96**	1.00
CSR-R10	1.23***	1.11	1.00	0.99	1.00	1.19***	1.06	1.01	0.96**	1.01
CSR-R20	1.06*	1.03	1.00	0.97*	1.01	1.06*	1.04	1.01	0.97*	1.01
Régressions à vecteurs de support										
NL-SVRARDI	0.99	1.04	1.02	1.06**	1.05*	1.00	1.04	1.01	1.06**	1.01
L-SVRARDI	1.02	1.02	1.00	0.97*	1.00	1.03	1.03	1.00	0.97*	1.00
Forêts d'arbres aléatoires										
RFARDI	1.01	1.02	0.99	0.96	1.01	1.05*	1.02	0.99	0.97	1.02
RF-X	1.07	1.02	0.99	0.97*	1.00	1.06	1.01	0.99	0.98	1.01
RF-CSF	1.10*	1.04	1.01	1.01	1.03*	1.04	0.99	0.98	0.99	1.06***
RF-MAF	1.10*	1.03	0.99	0.99	1.01	1.08*	1.01	0.99	0.99	1.01
RF-X-CSF	1.08*	1.02	0.97	0.97*	1.01	1.07*	1.02	0.98	0.97	1.00
LLF-CSF	1.09**	1.01	1.00	1.02	1.02	1.05	1.00	0.98	0.98	1.04***
ARERT	1.00	1.07*	0.99	1.00	1.00	1.04	1.04	1.00	0.98	0.95*
ARDIERT	1.16*	1.13**	1.22**	1.08	1.00	1.08	1.00	0.99	1.04	1.01
EOTB-ERT	1.21**	1.07	1.04	1.25**	1.29**	1.27***	1.07*	1.10**	1.07	1.03*
ARRF	1.03	1.03	0.99	1.01	1.00	1.03	1.00	1.01	0.98	1.02
ARDIRF	1.04	1.17*	1.11*	1.19	1.06	1.05	1.04	1.03	0.99	1.05
EOTB-MRF	1.25***	1.09**	1.11	1.13**	1.19**	1.22***	1.08	1.05	1.05	1.14***
ERT-MAF	1.10*	1.01	1.00	0.98	1.00	1.10**	1.01	1.00	0.96**	1.01
Réseau de neurones										
LSTM-Dense-AR	1.04	1.04	1.02	0.98	1.01	1.04	1.04	1.02	0.98	1.01
LSTM-AR	1.08*	1.04	0.99	0.97**	1.01	1.08*	1.04	0.99	0.97**	1.01
Dense-AR	1.01	0.94*	0.99	0.99	1.04***	1.01	0.94*	0.99	0.99	1.04***
LSTM-Dense-ARDI	1.05	1.03	1.00	0.97*	1.01*	1.08*	1.05	1.02	0.98	1.02*
LSTM-ARDI	1.02	1.03	1.02	0.97*	1.02**	1.06	1.03	1.01	0.98	1.02
Dense-ARDI	1.02	1.02	1.13**	1.05*	1.07**	1.16***	1.23***	1.24*	1.07*	1.16**
LSTM-Dense	1.12**	1.06	1.03	1.04*	1.01	1.07*	1.00	0.98	0.99	1.03**
LSTM	1.09**	1.09	1.00	0.98*	1.02	1.08*	1.07*	1.02	1.02	1.01
Dense	1.09*	1.11	1.03	1.36	1.03*	1.06	1.04	1.00	1.00	1.01
Combinaisons de prévisions										
AVRG	1.04	1.01	0.98	0.98	1.01	1.04	1.01	0.98	0.97*	1.00
Médiane	1.06	1.02	1.00	0.97*	1.01	1.06*	1.02	1.00	0.97*	1.00
T-AVRG,0.1	1.05	1.02	0.99	0.97*	1.00	1.05	1.01	0.99	0.97**	1.01
T-AVRG,0.2	1.05	1.02	0.99	0.97*	1.00	1.06	1.02	0.99	0.97*	1.01
IP-AVRG,1	1.04	1.01	0.98	0.98	1.01	1.04	1.01	0.98	0.97*	1.00
IP-AVRG,0.95	1.04	1.01	0.98	0.98	1.01	1.04	1.01	0.98	0.97*	1.00

TABLE 14: Mises en chantier - Canada : RMSE relatifs

Models	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC (RMSE)	0.076	0.078	0.080	0.081	0.081	0.076	0.078	0.080	0.081	0.081
ARDI,BIC	1.00	1.01	0.97	0.99	0.99	0.96	1.10	1.00	1.01	0.98
Régressions pénalisées										
Ridge	1.05	1.04	0.99	0.98	0.98	1.05	1.02	0.99	0.98	0.98
Lasso	1.05	1.03	0.99	0.97	0.98	1.04	1.03	0.99	0.98	0.98
Elastic-Net	1.05	1.02	0.99	0.98	0.98	1.05	1.02	0.99	0.98	0.98
Adaptive-Lasso	0.98	0.99	1.00	0.94**	0.94**	0.99	1.00	0.97	0.96	0.96**
ARDI,Ridge	1.08**	1.02	1.01	0.98	0.98	1.05	1.02	0.99	0.98	0.98
ARDI,Lasso	1.12**	1.03	1.01	0.98	0.98	1.05	1.02	0.99	0.98	0.98
ARDI,Elastic-Net	1.05	1.02	0.99	0.98	0.98	1.05	1.03	0.99	0.98	0.98
ARDI,Adaptive-Lasso	1.07**	1.03	0.99	0.98	0.97	1.09***	1.05	0.99	0.97	0.97
Ridge-MAF	1.08	1.00	0.99	0.98	0.98	1.05	1.00	0.99	0.98	0.97
LASSO-MAF	1.05	1.02	0.99	0.98	0.98	1.05	1.02	0.99	0.98	1.04
ELAS-MAF	1.05	1.02	0.99	0.98	0.98	1.05	1.01	0.99	0.98	1.01
Régressions régularisées par sous-ensembles complets										
T-CSR10	0.97	1.06	1.05	1.13**	1.04	1.04	1.05	1.10*	1.09**	1.02
T-CSR20	1.10*	1.01	0.99	0.98	0.97*	1.09*	1.01	0.99	0.97	0.96*
CSR-R10	1.14*	1.02	0.99	0.98	0.98	1.13*	1.00	1.01	0.96*	0.96*
CSR-R20	1.01	1.00	0.99	0.98	0.98	1.04	1.00	1.00	0.98	0.98*
Régressions à vecteurs de support										
NL-SVRARDI	1.01	1.02	1.01	1.04*	1.01	1.08	1.02	1.02	1.04*	1.00
L-SVRARDI	1.07*	1.03	0.99	0.96	1.03	1.07*	1.05	1.04	0.99	1.03
Forêts d'arbres aléatoires										
RFARDI	1.06*	1.02	1.05	1.01	0.99	1.04	1.05	1.05	1.03	0.98
RF-X	1.05	0.98	0.97	0.97*	0.97*	1.04	1.00	0.99	0.96*	0.93**
RF-CSF	1.04	0.98	0.99	0.99	0.96**	1.02	0.93**	0.96	0.98	1.03
RF-MAF	1.08*	0.95	1.01	0.98	0.95**	1.04	0.92*	1.00	0.98	0.94
RF-X-CSF	1.05	0.99	0.97	0.97*	0.96***	1.04	0.99	0.98	0.95**	0.94**
LLF-CSF	1.13**	1.04	0.96	1.00	1.02	1.02	0.96	0.96	0.98	1.03
ARERT	1.12*	0.99	1.01	1.00	1.04*	1.11*	0.96	1.01	0.99	0.97
ARDIERT	1.13	1.30*	1.08	1.15	1.12*	1.28	1.05	0.99	1.13**	1.06
EOTB-ERT	1.01	1.07	1.05	1.02	0.96	1.02	0.97	1.03	1.06	1.07
ARRF	1.11	0.97	0.96	1.03	1.05	1.09	0.99	1.00	1.01	1.09**
ARDIRF	1.39	1.23	1.04	1.09	1.20**	1.18*	1.00	1.00	1.18*	1.21*
EOTB-MRF	0.97	1.01	1.03	1.03	1.05	1.00	0.98	1.03	0.99	0.95
ERT-MAF	1.10*	1.01	0.98	0.99	0.96*	1.05	0.97	0.99	0.98	0.96*
Réseau de neurones										
LSTM-Dense-AR	1.06	1.02	0.98	0.98	0.98	1.06	1.02	0.98	0.98	0.98
LSTM-AR	1.06	1.00	0.98	0.99	0.98	1.06	1.00	0.98	0.99	0.98
Dense-AR	1.05**	1.00	0.99	0.98	0.99	1.05**	1.00	0.99	0.98	0.99
LSTM-Dense-ARDI	1.03	1.04	1.02	1.16	0.99	1.01	0.98	1.03	0.99	0.99
LSTM-ARDI	1.01	0.99	0.94*	1.00	0.98	0.96	1.05	1.02	1.00	0.99
Dense-ARDI	0.98	1.35**	1.01	1.01	1.06*	1.10	1.20**	1.12**	1.03	1.04
LSTM-Dense	1.03	1.03	0.98	0.97	0.99	1.12	0.99	0.99	0.98	1.00
LSTM	1.04	1.02	1.00	0.98	1.06	1.03	1.02	1.00	0.98	0.99
Dense	1.04	1.05	1.00	0.96	0.99	1.00	1.07	1.00	0.99	0.99
Combinaisons de prévisions										
AVRG	1.02	1.00	0.96	0.98*	0.98	1.00	0.99	0.97	0.97*	0.97*
Médiane	1.03	1.00	0.98	0.97*	0.97	1.03	0.99	0.98	0.98	0.97*
T-AVRG,0.1	1.02	1.00	0.97	0.97*	0.97*	1.02	0.99	0.98	0.97*	0.97*
T-AVRG,0.2	1.02	1.00	0.98	0.97*	0.97	1.02	0.99	0.98	0.97*	0.97*
IP-AVRG,1	1.01	1.00	0.96	0.98	0.97*	1.00	0.99	0.97	0.97*	0.97*
IP-AVRG,0.95	1.01	1.00	0.96	0.98*	0.97*	1.00	0.99	0.97	0.97*	0.97*

TABLE 15: IPC - Québec : RMSE relatifs

Models	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC (RMSE)	0.006	0.006	0.005	0.006	0.006	0.006	0.006	0.005	0.006	0.006
ARDI,BIC	1.08**	1.24**	0.97**	1.08	1.25	1.09**	1.33**	0.98	1.10*	1.26
Régressions pénalisées										
Ridge	1.04	1.10***	1.12***	1.01	1.02	1.03	1.06**	1.11***	0.99	1.06*
Lasso	0.96	0.99	1.07**	1.00	0.98	0.96	1.03	1.14*	0.95*	1.09**
Elastic-Net	1.07	1.11***	1.13***	0.99	1.05*	1.07	1.11***	1.13***	0.99	1.05*
Adaptive-Lasso	0.91**	0.94***	1.01	0.91**	0.94**	0.94*	0.95**	1.01	0.92**	0.94**
ARDI,Ridge	1.03	1.12***	1.12***	1.31*	1.02	1.08**	1.11***	1.13***	1.00	1.05*
ARDI,Lasso	1.03	1.04*	1.13***	1.32*	1.06**	1.03	1.10***	1.13***	0.99	1.04*
ARDI,Elastic-Net	1.06	1.12***	1.12***	0.97	1.06*	1.07	1.11***	1.13***	0.99	1.05*
ARDI,Adaptive-Lasso	0.93	1.03	1.09**	1.00	1.08**	0.99	1.02	1.05*	1.00	1.08
Ridge-MAF	1.01	1.05**	1.10***	0.97	1.04*	0.98	1.05**	1.08**	0.97	1.03
LASSO-MAF	1.03	1.09***	1.13***	0.98	1.05*	1.03	1.10***	1.12***	0.97	1.05
ELAS-MAF	1.03	1.09***	1.13***	0.98	1.04	1.02	1.09***	1.14***	0.98	1.03
Régressions régularisées par sous-ensembles complets										
T-CSR10	0.91*	0.98	0.98	1.06	1.12	0.98	0.97	1.01	1.12	1.28
T-CSR20	1.10***	1.19***	1.02	1.03*	1.06	1.09**	1.16***	1.08***	1.00	1.05**
CSR-R10	1.12***	1.19***	1.00	1.03**	1.10	1.11**	1.17***	1.06***	1.00	1.07**
CSR-R20	0.93*	1.05*	1.11**	1.21	1.18	0.98	1.06**	1.25*	1.23	1.24
Régressions à vecteurs de support										
NL-SVRARDI	0.96	0.97	0.97*	1.02	1.12	1.01	0.98	0.98	1.07	1.21
L-SVRARDI	0.99	1.02	1.14**	1.13	1.06	0.90**	1.00	1.16*	1.10	1.11
Forêts d'arbres aléatoires										
RFARDI	0.91*	0.98	1.06	0.98	0.98	0.92*	0.98	1.06*	0.99	0.98
RF-X	0.96	1.00	1.02	0.88***	0.95**	0.93*	0.98	1.00	0.86***	0.93***
RF-CSF	1.08	1.08*	1.12*	0.96	0.94**	0.91*	1.01	1.09	0.99	0.96
RF-MAF	0.98	1.04	1.10*	0.90***	0.98	0.94*	1.02	1.05	0.90***	0.97
RF-X-CSF	0.96	1.00	1.02	0.89***	0.95*	0.94	0.99	1.00	0.89***	0.92**
LLF-CSF	1.09**	1.13**	1.10	1.08	0.98	0.98	1.10*	1.11	1.02	0.96
ARERT	0.99	1.00	1.07	1.15	1.05	0.98	1.03	0.96	1.04	1.01
ARDIERT	1.25	1.26	1.22	1.31	1.41*	0.99	1.04	0.96	0.96	1.21
EOTB-ERT	1.50**	1.43**	1.33***	1.12	1.09*	1.32**	1.20**	1.11*	1.16	1.12*
ARRF	1.17	1.15*	1.04	1.18	1.02	1.06	1.05	1.02	1.09	1.08
ARDIRF	1.05	1.37	1.07	1.41	1.21*	0.96	1.29	0.97	1.02	1.32
EOTB-MRF	1.48**	1.41**	1.31***	1.11	1.04	1.21**	1.21**	1.17**	1.10	1.14*
ERT-MAF	1.00	1.01	1.06*	0.91**	0.97	0.94*	0.99	1.02	0.90***	0.95*
Réseau de neurones										
LSTM-Dense-AR	1.06	1.09***	1.09**	0.99	1.03**	1.06	1.09***	1.09**	0.99	1.03**
LSTM-AR	1.06	1.09**	1.17***	0.97	1.05*	1.06	1.09**	1.17***	0.97	1.05*
Dense-AR	0.96	1.07*	1.12***	0.97	1.03	0.96	1.07*	1.12***	0.97	1.03
LSTM-Dense-ARDI	1.08**	1.21***	1.22***	1.06*	1.21**	1.21***	1.19***	1.53*	1.33*	1.34*
LSTM-ARDI	1.10**	1.12***	1.21***	1.10	1.08***	1.12***	1.14***	1.20***	1.15	1.12***
Dense-ARDI	1.11**	1.17***	1.19***	1.16*	1.13***	1.05	1.26**	1.44***	1.32*	1.08
LSTM-Dense	1.00	1.49**	1.23***	1.22	1.06	1.14*	1.24***	1.29***	1.33*	1.58**
LSTM	1.07	1.14**	1.16**	0.99	1.08**	1.12*	1.20***	1.29***	1.00	1.09**
Dense	1.38**	1.45***	2.10***	1.51**	1.94***	2.07***	2.33**	1.67***	3.88***	1.75***
Combinaisons de prévisions										
AVRG	0.98	1.03	1.05*	0.98	1.01	0.96	1.02	1.05	0.99	1.02
Médiane	0.97	1.03	1.04*	0.97	1.00	0.97	1.03*	1.04	0.95**	1.00
T-AVRG,0.1	0.97	1.03	1.05*	0.97	1.00	0.97	1.03	1.04	0.96	1.01
T-AVRG,0.2	0.97	1.03	1.05*	0.97	1.00	0.97	1.03	1.04	0.96*	1.00
IP-AVRG,1	0.98	1.03	1.04	0.98	1.01	0.96	1.02	1.04	0.97	1.02
IP-AVRG,0.95	0.97	1.03	1.04	0.98	1.01	0.96	1.02	1.04	0.97	1.02

TABLE 16: IPC - CAN : RMSE relatifs

Models	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC (RMSE)	0.005	0.005	0.005	0.006	0.006	0.005	0.005	0.005	0.006	0.006
ARDI,BIC	1.02	1.15**	1.01	1.03	1.17*	1.05	1.19**	1.01	1.05	1.17*
Régressions pénalisées										
Ridge	1.08	1.14***	1.14***	0.93**	1.09**	1.09	1.08	1.13***	0.98	1.08**
Lasso	1.08*	1.02	1.09**	0.98	1.05	1.02	0.98	1.10**	0.94**	1.12**
Elastic-Net	1.22**	1.17***	1.17***	0.96	1.10**	1.22**	1.17***	1.17***	0.96	1.10**
Adaptive-Lasso	0.98	1.00	1.03	0.87***	1.00	1.02	1.02	1.04	0.87***	0.99
ARDI,Ridge	1.06	1.19***	1.14***	0.96*	1.10**	1.08	1.15**	1.17***	0.96	1.10**
ARDI,Lasso	1.05	1.18**	1.14**	1.14	1.26**	1.05	1.12**	1.17***	0.98	1.33**
ARDI,Elastic-Net	1.12*	1.19**	1.14***	1.15	1.09**	1.13*	1.06	1.17***	0.96	1.10**
ARDI,Adaptive-Lasso	0.98	1.09*	0.95	0.89**	1.07*	1.01	1.04	1.06	0.93*	1.09**
Ridge-MAF	1.09*	1.10**	1.10**	0.94**	1.07**	1.03	1.08**	1.07**	0.94**	1.06*
LASSO-MAF	1.11*	1.15***	1.16***	0.94**	1.07*	1.07	1.16***	1.10**	0.94*	1.06
ELAS-MAF	1.12*	1.15***	1.16***	0.92**	1.09**	1.10*	1.15***	1.12**	0.92**	1.07*
Régressions régularisées par sous-ensembles complets										
T-CSR10	0.93	0.99	0.95*	0.98	1.12	0.98	1.01	0.98	0.97	1.24
T-CSR20	1.16**	1.26***	1.04**	1.03*	1.06***	1.16**	1.22***	1.13***	0.98	1.08***
CSR-R10	1.17***	1.24***	1.00	1.04**	1.05*	1.18***	1.23***	1.12***	0.98	1.10***
CSR-R20	1.00	1.10**	1.14**	1.06	1.17**	1.01	1.07	1.18**	1.03	1.15*
Régressions à vecteurs de support										
NL-SVRARDI	0.99	1.01	0.96*	0.98	1.11	1.02	1.02	0.98	0.98	1.18
L-SVRARDI	1.04	1.11*	1.15***	1.00	1.17**	1.01	1.16	1.14**	1.04	1.14*
Forêts d'arbres aléatoires										
RFARDI	0.99	1.00	1.06	0.88***	1.02	1.00	1.01	1.04	0.87***	1.00
RF-X	1.01	1.04	1.05	0.87***	1.00	1.00	1.04	1.05	0.86***	1.00
RF-CSF	1.03	1.06	1.06	0.88***	0.98	0.98	1.00	1.09	0.89**	0.97
RF-MAF	1.04	1.06	1.10**	0.87***	1.00	1.04	1.07	1.08*	0.87***	0.99
RF-X-CSF	0.99	1.04	1.06	0.85***	1.00	1.00	1.03	1.04	0.85***	0.98
LLF-CSF	1.11	1.08	1.00	0.91**	1.01	1.02	1.04	1.10	0.87***	0.95
ARERT	0.96	0.95	0.98	0.90**	1.04	0.94	0.88**	1.01	0.88***	1.11*
ARDIERT	1.13	0.96	1.04	1.00	1.35	0.93**	0.99	1.03	0.96	1.16**
EOTB-ERT	1.54**	1.36**	1.31***	1.23	1.15	1.41**	1.28**	1.17**	1.16	1.22*
ARRF	1.12	1.14*	0.98	0.95	1.10*	1.15	1.03	1.00	0.98	1.06
ARDIRF	1.01	1.07*	1.16*	1.17	1.17**	1.11	0.99	1.07	0.97	1.17*
EOTB-MRF	1.37*	1.31**	1.24**	1.18	1.18*	1.26**	1.36**	1.19***	1.19	1.06
ERT-MAF	1.03	1.04	1.07*	0.87***	1.01	1.00	1.03	1.04	0.88***	1.00
Réseau de neurones										
LSTM-Dense-AR	1.16**	1.19***	1.11***	0.98	1.08***	1.16**	1.19***	1.11***	0.98	1.08***
LSTM-AR	1.16**	1.10**	1.15***	0.94*	1.09**	1.16**	1.10**	1.15***	0.94*	1.09**
Dense-AR	1.09	1.13**	1.14***	1.00	1.01	1.09	1.13**	1.14***	1.00	1.01
LSTM-Dense-ARDI	1.19***	1.27***	1.18***	1.05	1.14***	1.21***	1.29***	1.32**	1.02	1.28*
LSTM-ARDI	1.19**	1.15***	1.18***	0.99	1.13***	1.24***	1.23***	1.21***	0.96	1.20**
Dense-ARDI	1.17**	1.26***	1.27***	1.01	1.29**	1.33**	1.45***	1.26***	0.98	1.36***
LSTM-Dense	1.13*	1.28**	1.22***	1.22***	1.20***	1.17***	1.21***	1.16***	1.08***	1.14***
LSTM	1.14	1.10**	1.16***	0.97	1.00	1.47**	1.07	1.18**	0.92**	1.15***
Dense	1.64***	1.20***	1.96***	1.55***	1.80**	2.27***	2.45***	2.35**	1.51***	1.99***
Combinaisons de prévisions										
AVRG	1.02	1.05	1.06	0.93**	1.03	1.03	1.04	1.06*	0.91***	1.04*
Médiane	1.02	1.05	1.07*	0.91***	1.03	1.02	1.05	1.06*	0.90***	1.03
T-AVRG,0.1	1.01	1.06*	1.05	0.92***	1.04*	1.02	1.04	1.06*	0.91***	1.04*
T-AVRG,0.2	1.02	1.06*	1.06*	0.92***	1.03	1.02	1.04	1.07*	0.91***	1.03
IP-AVRG,1	1.01	1.05	1.04	0.93***	1.04	1.02	1.03	1.06*	0.91***	1.04*
IP-AVRG,0.95	1.01	1.05	1.04	0.93***	1.04*	1.02	1.02	1.05	0.91***	1.04*

TABLE 17: Production industrielle : RMSE relatifs

Models	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC (RMSE)	0.016	0.018	0.019	0.019	0.018	0.016	0.018	0.019	0.019	0.018
ARDI,BIC	0.82**	0.87**	0.87*	0.96	0.99	0.76**	0.79*	0.95	0.99	0.99
Régressions pénalisées										
Ridge	1.08	1.02	0.98	0.93*	1.01	0.82**	0.93	0.97*	0.97*	0.99
Lasso	0.92	0.90*	0.91**	0.92*	0.97	0.85**	0.87*	0.94**	0.98	0.97
Elastic-Net	1.14	1.02	0.97**	0.98	0.99	0.91	1.02	0.97**	0.98	0.99
Adaptive-Lasso	0.92	0.94**	0.90**	0.93*	0.97	0.91*	0.92**	0.90*	0.95	0.97
ARDI,Ridge	0.81**	0.99	0.97*	0.98	1.04	1.08	1.02	0.97**	0.98	0.99
ARDI,Lasso	0.79**	0.99	0.94***	0.97	0.99	1.02	1.00	0.96	0.96*	0.99
ARDI,Elastic-Net	1.08	1.02	0.97**	0.98	0.99	1.08	1.09**	0.97**	0.98	0.99
ARDI,Adaptive-Lasso	0.86***	0.91*	0.91*	0.96	0.95	0.84**	0.95	1.04	0.98	0.93
Ridge-MAF	0.93	0.97*	0.93**	0.94*	0.98	0.98	0.97	0.94**	0.94*	0.98
LASSO-MAF	1.02	1.10	0.90**	0.95*	0.98	0.95	0.98	0.97	0.95*	0.98
ELAS-MAF	1.00	1.05	0.94**	0.98	0.98	0.98	1.01	0.95*	0.96	0.98
Régressions régularisées par sous-ensembles complets										
T-CSR10	0.86**	0.88*	0.89**	0.94	1.02	0.78**	0.87*	0.83*	0.89*	1.00
T-CSR20	1.00	1.01	0.96*	0.99	0.99	1.00	1.00	0.96*	0.99	0.99
CSR-R10	0.98	1.01	0.96*	0.99	0.99	0.98	1.01	0.95**	0.99	0.99
CSR-R20	0.87***	0.89**	0.87**	0.94*	1.00	0.79**	0.91*	0.91**	0.94	0.99
Régressions à vecteurs de support										
NL-SVRARDI	0.89***	0.91*	0.88**	0.92*	0.99	0.82**	0.89*	0.84**	0.89*	0.98
L-SVRARDI	0.82***	0.90**	0.88**	0.94*	0.98	0.80**	0.89	0.88**	0.95	0.97
Forêts d'arbres aléatoires										
RFARDI	0.95	0.92**	0.94*	0.95	0.98	0.92	0.90*	0.91*	0.93	0.99
RF-X	0.99	0.95	0.93*	0.95	0.99	0.98	0.94*	0.94**	0.94	0.98
RF-CSF	0.96	0.93*	0.92	0.93	1.00	0.99	0.96	1.03	0.93	0.96
RF-MAF	0.98	0.95*	0.96	0.95	0.98	1.00	0.94**	0.96	0.94	0.98
RF-X-CSF	0.98	0.94*	0.93*	0.94	1.00	0.97	0.95*	0.94*	0.94	0.98
LLF-CSF	0.95	0.91*	0.92	0.94	0.97	0.95	0.93*	0.90*	0.91	0.96
ARERT	0.93*	1.00	0.99	0.98	0.97	0.94*	1.00	1.04	0.97	0.96
ARDIERT	0.79**	1.03	0.94	1.00	0.99	0.93	1.06	0.93	1.00	0.98
EOTB-ERT	0.91	1.08	1.05	1.05*	1.00	1.06	1.03	0.95	1.04*	1.03
ARRF	0.89**	0.99	1.11	0.99	0.98	0.94*	1.00	0.98	1.03	1.01
ARDIRF	0.76**	0.89*	0.95	0.96	1.01	0.96	1.06	0.95	0.98	1.01
EOTB-MRF	1.08	1.00	1.21	1.02*	0.99	0.95	0.99	0.97	1.02	1.03
ERT-MAF	0.97	0.95*	0.94	0.95	0.98	0.99	0.95*	0.93**	0.93	0.98
Réseau de neurones										
LSTM-Dense-AR	1.12	1.01	0.93**	0.96*	0.99	1.12	1.01	0.93**	0.96*	0.99
LSTM-AR	1.10	1.00	0.96**	0.96*	1.00	1.10	1.00	0.96**	0.96*	1.00
Dense-AR	0.99	1.06	0.99	1.07	1.07**	0.99	1.06	0.99	1.07	1.07**
LSTM-Dense-ARDI	1.11	0.97	0.94*	0.95*	1.01	0.90*	1.01	0.98	0.95*	0.96**
LSTM-ARDI	1.02	0.96	0.96	0.96*	0.98	1.11	1.03	0.94**	0.93**	0.97
Dense-ARDI	1.12	1.04	0.96	1.02	1.12	0.90	1.08*	1.21*	0.98	1.21**
LSTM-Dense	0.99	0.93	0.95	0.88	0.98	1.01	0.93	0.92*	0.99	1.01
LSTM	1.04	0.94	0.91**	0.98	0.98	0.91*	1.01	0.94	0.95	0.92
Dense	1.20*	1.44**	1.20**	1.29**	0.93	1.13	1.29	1.35**	1.14**	2.40***
Combinaisons de prévisions										
AVRG	0.91*	0.94**	0.92**	0.94**	0.97	0.88**	0.93*	0.91**	0.95*	0.98
Médiane	0.94	0.95*	0.92**	0.95*	0.98	0.92*	0.96*	0.93**	0.95*	0.98
T-AVRG,0.1	0.92	0.94**	0.92**	0.94*	0.98	0.90**	0.95*	0.92**	0.94*	0.97
T-AVRG,0.2	0.93	0.95**	0.92**	0.95*	0.98	0.90*	0.95*	0.93**	0.95*	0.98
IP-AVRG,1	0.90**	0.94**	0.92**	0.94*	0.97	0.88**	0.94*	0.91**	0.94*	0.97
IP-AVRG,0.95	0.90**	0.94**	0.92**	0.94*	0.97	0.88**	0.94*	0.91**	0.94*	0.97

TABLE 18: Taux de change - USD/CAD : RMSE relatifs

Models	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC (RMSE)	0.040	0.043	0.042	0.041	0.041	0.040	0.043	0.042	0.041	0.041
ARDI,BIC	1.02	1.00	1.00*	1.00	1.01**	1.07	1.05	0.97*	0.98	1.04**
Régressions pénalisées										
Ridge	1.01	0.94*	0.97	0.99	0.98	1.01	0.99	0.97	0.99	1.00
Lasso	1.01	0.97	0.96**	0.99	0.98*	1.03	0.99	0.97	0.97	1.00
Elastic-Net	1.01	0.94*	0.97	0.99	0.98**	1.01	0.94*	0.97	0.99	0.98**
Adaptive-Lasso	1.01	0.96	0.97*	0.97*	0.98	1.01	0.97	0.98	0.96*	0.97**
ARDI,Ridge	1.02	0.94*	0.97	0.99	0.98**	1.02	0.94*	0.97	0.99	0.98**
ARDI,Lasso	1.05	0.94*	0.95**	0.98	0.98*	1.01	0.94*	0.99	1.00	1.03
ARDI,Elastic-Net	1.01	0.94*	0.97	0.99	0.98**	1.01	0.94*	0.97	0.99	0.98**
ARDI,Adaptive-Lasso	1.02	0.96*	0.97*	0.98	0.98	1.14	1.06	0.99	1.00	1.06**
Ridge-MAF	1.02	0.95*	0.97	0.99	0.98	1.02	0.95*	0.97	0.99	0.98*
LASSO-MAF	1.01	0.94*	0.97	0.99	0.98*	1.01	0.94*	0.97	0.99	0.98*
ELAS-MAF	1.01	0.94*	0.97	0.99	0.98*	1.01	0.95*	0.97	0.99	0.98*
Régressions régularisées par sous-ensembles complets										
T-CSR10	1.10**	0.99	1.03	1.03	1.08*	1.08**	1.02	0.99	1.02	1.07*
T-CSR20	1.01	0.93**	0.96	0.98	0.99**	1.02	0.95*	0.97	0.98	0.99*
CSR-R10	1.02	0.94*	0.97	0.98	0.99	1.02	0.95*	0.97	0.98	0.99
CSR-R20	1.00	0.96*	1.01	1.02	0.99	1.07	0.97	0.99	1.04**	1.05**
Régressions à vecteurs de support										
NL-SVRARDI	1.06**	0.98	1.00	1.00	1.06*	1.05*	0.99	0.99	1.01	1.05*
L-SVRARDI	1.10**	1.00	0.98*	1.00	1.03	1.06*	1.01	1.02	1.06***	1.08***
Forêts d'arbres aléatoires										
RFARDI	1.02	0.98	0.96*	1.00	1.01	1.04	0.98	0.97	0.99	1.02
RF-X	1.01	0.95	0.97	1.01	0.98	1.01	0.96	0.96**	1.00	0.99
RF-CSF	1.04	0.98	0.98	1.07*	1.01	1.05	1.00	1.00	1.07*	1.03
RF-MAF	1.03	0.97	0.96*	1.04*	0.99	1.03	0.96	0.94**	1.02	0.98
RF-X-CSF	1.02	0.96	0.97	1.00	0.99	1.01	0.95	0.96**	0.99	1.00
LLF-CSF	1.02	0.98	0.96**	1.01	1.03	1.04	0.97	0.97*	1.03	1.02
ARERT	0.99	1.00	1.08**	1.19*	1.05*	1.04	1.05	1.03	1.03	1.05*
ARDIERT	1.05	1.15	1.13**	1.06*	1.07*	1.03	1.03	1.11*	1.06*	1.01
EOTB-ERT	1.01	1.02	0.96*	1.04	1.05**	1.05*	1.01	0.96	1.08***	0.97
ARRF	1.05	1.00	1.01	1.16**	1.03*	1.05*	0.99	1.03	1.21**	1.06**
ARDIRF	1.08	1.14	1.08**	1.07**	1.01	1.16	1.14**	1.05	1.06**	1.02
EOTB-MRF	1.05*	1.00	1.02	1.03	1.07**	1.04**	1.04	0.98	1.03	0.99
ERT-MAF	1.03	0.97	0.97*	1.03	0.99	1.03	0.96	0.97	1.02	0.98
Réseau de neurones										
LSTM-Dense-AR	1.00	0.94**	0.97	0.99	0.97**	1.00	0.94**	0.97	0.99	0.97**
LSTM-AR	1.02	0.95**	0.97*	0.98	0.96***	1.02	0.95**	0.97*	0.98	0.96***
Dense-AR	1.08*	1.03	1.02	1.00	0.97	1.08*	1.03	1.02	1.00	0.97
LSTM-Dense-ARDI	1.01	0.94*	0.98	1.00	0.98*	1.00	0.96*	0.97	0.98	0.98**
LSTM-ARDI	1.01	0.95*	0.96*	0.99	0.97***	1.01	0.96	0.96*	0.99	0.97*
Dense-ARDI	1.06	0.95*	0.98	1.04	1.01	1.03	0.93*	0.99	1.05	1.00
LSTM-Dense	1.00	0.96	1.02	1.01	0.99	1.04	0.97	0.99	0.98	0.97***
LSTM	1.01	0.95*	0.97	0.99	0.99	1.03	0.94*	0.95*	0.99	0.98***
Dense	1.05*	0.92**	1.13*	0.99	0.96**	1.01	0.93*	0.98*	0.97	1.00
Combinaisons de prévisions										
AVRG	1.00	0.96	0.97*	1.00	0.98**	1.01	0.97	0.97*	1.00	0.99
Médiane	1.00	0.94*	0.97*	0.99	0.98*	1.01	0.95*	0.97*	0.99	0.99*
T-AVRG,0.1	1.00	0.95*	0.97*	1.00	0.98*	1.01	0.96*	0.97*	0.99	0.99
T-AVRG,0.2	1.00	0.95*	0.97*	0.99	0.98**	1.01	0.96*	0.97*	0.99	0.99
IP-AVRG,1	1.00	0.96	0.97*	1.00	0.98*	1.01	0.97	0.97*	0.99	0.99
IP-AVRG,0.95	1.00	0.96	0.97*	1.00	0.98*	1.01	0.97	0.97*	0.99	0.99

TABLE 19: PIB réel - Québec : RCSF

Modèles	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC	80.36	78.57	80.36	80.36	80.36	80.36	78.57	80.36	80.36	80.36
ARDI,BIC	80.36	76.79	80.36	80.36	80.36	82.14**	76.79	78.57	80.36	80.36
Régressions pénalisées										
Ridge	80.36	80.36	80.36	78.57	80.36	80.36	80.36	78.57	80.36	80.36
Lasso	80.36	80.36	80.36	80.36	80.36	80.36	78.57	80.36	80.36	80.36
Elastic-Net	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36
Adaptive-Lasso	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36
ARDI,Ridge	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36
ARDI,Lasso	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36
ARDI,Elastic-Net	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36
ARDI,Adaptive-Lasso	82.14**	80.36	80.36	75.00	80.36	82.14**	78.57	76.79	80.36	80.36
Ridge-MAF	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36
LASSO-MAF	80.36	80.36	80.36	78.57	80.36	80.36	80.36	80.36	80.36	80.36
ELAS-MAF	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	78.57
Régressions régularisées par sous-ensembles complets										
T-CSR10	82.14**	80.36	80.36	83.93***	78.57	76.79	76.79	80.36	83.93***	78.57
T-CSR20	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36
CSR-R10	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36
CSR-R20	80.36	80.36	80.36	80.36	80.36	80.36	76.79	80.36	80.36	80.36
Régressions à vecteurs de support										
NL-SVRARDI	82.14**	80.36	80.36	80.36	80.36	78.57	78.57	80.36	80.36	80.36
L-SVRARDI	83.93***	80.36	76.79	80.36	80.36	80.36	76.79	82.14**	82.14**	80.36
Forêts d'arbres aléatoires										
RFARDI	80.36	80.36	80.36	80.36	80.36	80.36	78.57	82.14**	82.14**	80.36
RF-X	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36
RF-CSF	83.93***	82.14**	80.36	80.36	80.36	82.14**	80.36	80.36	80.36	80.36
RF-MAF	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36
RF-X-CSF	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36
LLF-CSF	85.71***	83.93***	76.79	76.79	80.36	78.57	80.36	78.57	80.36	80.36
ARERT	82.14**	80.36	80.36	80.36	78.57	80.36	80.36	80.36	80.36	80.36
ARDIERT	80.36	80.36	78.57	80.36	76.79	80.36	80.36	80.36	78.57	78.57
EOTB-ERT	76.79	76.79	80.36	78.57	80.36	71.43	82.14**	78.57	80.36	80.36
ARRF	82.14**	80.36	80.36	78.57	80.36	82.14**	80.36	80.36	78.57	80.36
ARDIRF	80.36	82.14**	78.57	75.00	78.57	80.36	80.36	80.36	80.36	76.79
EOTB-MRF	82.14**	76.79	76.79	78.57	78.57	83.93***	75.00	80.36	80.36	80.36
ERT-MAF	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36
Réseau de neurones										
LSTM-Dense-AR	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36
LSTM-AR	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36
Dense-AR	80.36	82.14**	80.36	80.36	80.36	80.36	82.14**	80.36	80.36	80.36
LSTM-Dense-ARDI	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36
LSTM-ARDI	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36
Dense-ARDI	82.14**	80.36	80.36	82.14**	80.36	80.36	75.00	76.79	80.36	80.36
LSTM-Dense	80.36	78.57	80.36	80.36	80.36	80.36	80.36	80.36	78.57	80.36
LSTM	78.57	80.36	80.36	80.36	78.57	80.36	80.36	80.36	80.36	80.36
Dense	80.36	80.36	80.36	78.57	80.36	80.36	80.36	80.36	80.36	80.36
Combinaisons de prévisions										
AVRG	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36
Médiane	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36
T-AVRG,0.1	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36
T-AVRG,0.2	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36
IP-AVRG,1	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36
IP-AVRG,0.95	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36

Note : Les entrées dans ce tableau représentent les ratios de succès (Success Ratios) de la prévision du signe de la cible, tel que décrit dans la section 2.4. Les étoiles indiquent la significativité du test de Pesaran et Timmermann (1992) avec les niveaux de 1, 5 et 10% pour *, ** et *** respectivement.

TABLE 20: PIB réel - Canada : RCSF

Modèles	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC	91.07***	87.50	87.50	89.29	89.29	91.07***	87.50	87.50	89.29	89.29
ARDI,BIC	94.64***	89.29*	89.29	89.29	89.29	92.86***	91.07***	87.50	85.71	87.50
Régressions pénalisées										
Ridge	91.07***	89.29	89.29	89.29	89.29	91.07***	89.29*	89.29	89.29	89.29
Lasso	91.07***	89.29	89.29	89.29	89.29	91.07***	89.29*	89.29	89.29	87.50
Elastic-Net	89.29	89.29	89.29	89.29	89.29	87.50	89.29	89.29	89.29	89.29
Adaptive-Lasso	91.07***	89.29	89.29	89.29	89.29	91.07***	87.50	89.29	89.29	89.29
ARDI,Ridge	91.07***	89.29*	89.29	89.29	89.29	85.71***	89.29	89.29	89.29	89.29
ARDI,Lasso	92.86***	91.07***	89.29	89.29	89.29	91.07***	83.93	89.29	89.29	89.29
ARDI,Elastic-Net	89.29	87.50	89.29	89.29	89.29	89.29	89.29	89.29	89.29	89.29
ARDI,Adaptive-Lasso	91.07***	89.29*	89.29	89.29	89.29	91.07***	89.29*	85.71	83.93	89.29
Ridge-MAF	89.29	89.29	89.29	89.29	89.29	89.29	89.29	89.29	89.29	89.29
LASSO-MAF	89.29	89.29	89.29	89.29	89.29	91.07***	89.29	89.29	89.29	89.29
ELAS-MAF	89.29	89.29	89.29	89.29	89.29	91.07***	89.29	89.29	89.29	89.29
Régressions régularisées par sous-ensembles complets										
T-CSR10	92.86***	87.50	87.50	87.50	87.50	91.07***	89.29*	87.50	89.29*	89.29
T-CSR20	91.07***	89.29	89.29	89.29	89.29	91.07***	89.29	89.29	89.29	89.29
CSR-R10	91.07***	89.29	89.29	89.29	89.29	91.07***	89.29	89.29	89.29	89.29
CSR-R20	91.07***	89.29*	89.29	89.29	89.29	91.07***	91.07***	89.29	89.29	89.29
Régressions à vecteurs de support										
NL-SVRARDI	91.07***	87.50	89.29	89.29	89.29	91.07***	85.71	89.29	89.29	89.29
L-SVRARDI	92.86***	89.29*	89.29	89.29	91.07***	87.50***	87.50	87.50	89.29	89.29
Forêts d'arbres aléatoires										
RFARDI	89.29*	85.71	87.50	89.29	89.29	89.29*	87.50	87.50	89.29	87.50
RF-X	89.29	89.29	89.29	89.29	89.29	89.29	89.29	89.29	89.29	89.29
RF-CSF	91.07***	87.50	89.29	89.29	89.29	89.29*	89.29	83.93	89.29	89.29
RF-MAF	89.29	89.29	89.29	89.29	89.29	89.29	89.29	89.29	89.29	89.29
RF-X-CSF	89.29	89.29	89.29	89.29	89.29	89.29	89.29	89.29	89.29	89.29
LLF-CSF	89.29***	87.50	89.29	89.29	87.50	89.29*	87.50	89.29	89.29	89.29
ARERT	91.07***	85.71	87.50	89.29	89.29	89.29*	85.71	87.50	89.29	89.29
ARDIERT	92.86***	87.50	89.29*	89.29	87.50	91.07***	87.50	87.50	87.50	89.29
EOTB-ERT	91.07***	89.29	85.71	89.29	87.50	91.07***	89.29	85.71	89.29	85.71
ARRF	89.29*	87.50	87.50	89.29	89.29	89.29*	85.71	85.71	89.29	89.29
ARDIRF	92.86***	89.29*	85.71	87.50	89.29	91.07***	87.50	89.29	89.29	89.29
EOTB-MRF	92.86***	89.29	87.50	89.29	89.29	92.86***	89.29	85.71	89.29	83.93
ERT-MAF	89.29	89.29	87.50	89.29	89.29	89.29	89.29	89.29	89.29	89.29
Réseau de neurones										
LSTM-Dense-AR	89.29	89.29	89.29	89.29	89.29	89.29	89.29	89.29	89.29	89.29
LSTM-AR	87.50	89.29	89.29	89.29	89.29	87.50	89.29	89.29	89.29	89.29
Dense-AR	89.29*	89.29	89.29	89.29	89.29	89.29*	89.29	89.29	89.29	89.29
LSTM-Dense-ARDI	89.29	89.29	89.29	89.29	89.29	89.29***	87.50	89.29	89.29	89.29
LSTM-ARDI	89.29	89.29	89.29	89.29	89.29	85.71	85.71	87.50	89.29	89.29
Dense-ARDI	89.29***	91.07***	89.29	89.29	89.29	87.50**	87.50**	87.50	87.50	87.50
LSTM-Dense	87.50	85.71	89.29	85.71	89.29	89.29*	87.50	89.29	89.29	83.93
LSTM	89.29	89.29	89.29	89.29	87.50	89.29	89.29	85.71	89.29	89.29
Dense	80.36	85.71	82.14	87.50	75.00	76.79	73.21	82.14	66.07	89.29
Combinaisons de prévisions										
AVRG	92.86***	89.29	89.29	89.29	89.29	91.07***	87.50	89.29	89.29	89.29
Médiane	91.07***	89.29	89.29	89.29	89.29	89.29*	89.29	89.29	89.29	89.29
T-AVRG,0.1	91.07***	89.29	89.29	89.29	89.29	91.07***	89.29	89.29	89.29	89.29
T-AVRG,0.2	91.07***	89.29	89.29	89.29	89.29	89.29*	89.29	89.29	89.29	89.29
IP-AVRG,1	92.86***	89.29	89.29	89.29	89.29	91.07***	87.50	89.29	89.29	89.29
IP-AVRG,0.95	92.86***	89.29	89.29	89.29	89.29	91.07***	87.50	89.29	89.29	89.29

TABLE 21: Investissement réel - Québec : RCSF

Modèles	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC	58.93	53.57	55.36	55.36	55.36	58.93	53.57	55.36	55.36	55.36
ARDI,BIC	60.71	55.36	55.36	55.36	55.36	57.14	53.57	55.36	55.36	55.36
Régressions pénalisées										
Ridge	55.36	55.36	55.36	55.36	55.36	55.36	55.36	55.36	55.36	55.36
Lasso	57.14	53.57	55.36	55.36	55.36	55.36	55.36	51.79	51.79	53.57
Elastic-Net	55.36	55.36	55.36	55.36	55.36	55.36	55.36	55.36	55.36	55.36
Adaptive-Lasso	58.93	55.36	55.36	55.36	55.36	57.14	55.36	53.57	55.36	55.36
ARDI,Ridge	62.50*	55.36	55.36	55.36	55.36	58.93	55.36	55.36	55.36	55.36
ARDI,Lasso	62.50*	55.36	55.36	55.36	55.36	53.57	55.36	55.36	55.36	55.36
ARDI,Elastic-Net	55.36	55.36	55.36	55.36	55.36	51.79	55.36	55.36	55.36	55.36
ARDI,Adaptive-Lasso	60.71**	55.36	55.36	55.36	55.36	60.71**	55.36	55.36	57.14	55.36
Ridge-MAF	55.36	55.36	51.79	55.36	55.36	55.36	55.36	55.36	55.36	57.14
LASSO-MAF	55.36	55.36	55.36	55.36	57.14	55.36	55.36	55.36	55.36	62.50**
ELAS-MAF	55.36	55.36	55.36	55.36	55.36	55.36	57.14	55.36	55.36	57.14
Régressions régularisées par sous-ensembles complets										
T-CSR10	67.86***	51.79	53.57	48.21	48.21	64.29**	51.79	46.43	50.00	50.00
T-CSR20	58.93	55.36	55.36	57.14	55.36	55.36	55.36	55.36	57.14	55.36
CSR-R10	58.93	57.14	55.36	55.36	53.57	55.36	55.36	55.36	55.36	55.36
CSR-R20	64.29**	57.14	53.57	57.14	51.79	55.36	55.36	51.79	55.36	51.79
Régressions à vecteurs de support										
NL-SVRARDI	71.43***	53.57	55.36	50.00	50.00	60.71	51.79	51.79	50.00	51.79
L-SVRARDI	66.07**	58.93	51.79	50.00	53.57	58.93	57.14	50.00	48.21	53.57
Forêts d'arbres aléatoires										
RFARDI	66.07**	62.50**	50.00	44.64*	50.00	60.71	53.57	44.64*	46.43	44.64**
RF-X	58.93	55.36	55.36	55.36	55.36	57.14	55.36	55.36	55.36	55.36
RF-CSF	71.43***	62.50*	55.36	55.36	51.79	75.00***	60.71	48.21	44.64	48.21
RF-MAF	60.71**	53.57	51.79	53.57	55.36	57.14	55.36	53.57	53.57	55.36
RF-X-CSF	58.93	55.36	53.57	55.36	55.36	58.93	55.36	57.14	55.36	55.36
LLF-CSF	67.86***	51.79	53.57	64.29**	48.21	73.21***	53.57	46.43*	50.00	53.57
ARERT	67.86***	69.64***	48.21*	60.71	55.36	73.21***	57.14	55.36	53.57	55.36
ARDIERT	71.43***	57.14	46.43	53.57	42.86**	69.64***	57.14	50.00	51.79	51.79
EOTB-ERT	64.29***	58.93	46.43**	51.79	48.21	67.86***	51.79	48.21*	60.71	53.57
ARRF	64.29***	57.14	57.14	51.79	53.57	69.64***	60.71**	55.36	50.00	57.14
ARDIRF	62.50**	60.71	51.79	57.14	46.43**	69.64***	58.93	50.00	51.79	48.21
EOTB-MRF	66.07**	62.50*	51.79	50.00	55.36	60.71	50.00	51.79	48.21	58.93
ERT-MAF	55.36	57.14	51.79	53.57	55.36	57.14	55.36	51.79	55.36	55.36
Réseau de neurones										
LSTM-Dense-AR	53.57	55.36	55.36	55.36	55.36	53.57	55.36	55.36	55.36	55.36
LSTM-AR	55.36	55.36	55.36	55.36	55.36	55.36	55.36	55.36	55.36	55.36
Dense-AR	55.36	53.57	51.79	55.36	55.36	55.36	53.57	51.79	55.36	55.36
LSTM-Dense-ARDI	55.36	55.36	55.36	55.36	51.79	53.57	55.36	53.57	55.36	55.36
LSTM-ARDI	57.14	55.36	55.36	55.36	55.36	55.36	53.57	55.36	55.36	55.36
Dense-ARDI	62.50*	53.57	53.57	51.79	57.14	53.57	55.36	55.36	50.00	50.00
LSTM-Dense	62.50*	51.79	53.57	46.43	48.21	33.93***	46.43	51.79	53.57	53.57
LSTM	60.71	55.36	50.00	55.36	50.00	51.79	51.79	48.21	53.57	53.57
Dense	53.57	42.86*	42.86	48.21	46.43*	58.93	57.14	55.36	51.79	53.57
Combinaisons de prévisions										
AVRG	60.71**	55.36	55.36	55.36	55.36	55.36	55.36	55.36	57.14	55.36
Médiane	58.93	55.36	55.36	57.14	55.36	55.36	55.36	55.36	55.36	55.36
T-AVRG,0.1	58.93	55.36	55.36	57.14	55.36	57.14	55.36	55.36	55.36	55.36
T-AVRG,0.2	58.93	55.36	55.36	55.36	55.36	55.36	55.36	55.36	55.36	55.36
IP-AVRG,1	58.93	55.36	55.36	55.36	55.36	57.14	55.36	55.36	57.14	55.36
IP-AVRG,0.95	58.93	55.36	55.36	55.36	55.36	57.14	55.36	55.36	57.14	55.36

TABLE 22: Investissement réel - Canada : RCSF

Modèles	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC	82.14***	76.79*	71.43	75.00	75.00	82.14***	76.79*	71.43	75.00	75.00
ARDI,BIC	82.14***	73.21	75.00	75.00	71.43	87.50***	75.00	69.64	71.43	71.43
Régressions pénalisées										
Ridge	75.00	75.00	75.00	75.00	75.00	78.57**	75.00	75.00	75.00	75.00
Lasso	82.14***	75.00	75.00	75.00	75.00	78.57**	75.00	71.43	75.00	73.21
Elastic-Net	75.00	75.00	75.00	75.00	75.00	75.00	75.00	75.00	75.00	75.00
Adaptive-Lasso	78.57**	73.21	71.43	75.00	75.00	80.36***	71.43	69.64	71.43	71.43
ARDI,Ridge	82.14***	75.00	75.00	75.00	75.00	78.57**	73.21	75.00	75.00	75.00
ARDI,Lasso	80.36***	75.00	75.00	75.00	75.00	75.00	75.00	73.21	75.00	75.00
ARDI,Elastic-Net	76.79*	75.00	75.00	75.00	75.00	75.00	75.00	75.00	75.00	75.00
ARDI,Adaptive-Lasso	83.93***	75.00	75.00	75.00	67.86	82.14***	73.21	71.43	71.43	69.64
Ridge-MAF	76.79*	75.00	75.00	75.00	75.00	75.00	75.00	75.00	75.00	75.00
LASSO-MAF	75.00	75.00	75.00	75.00	75.00	75.00	75.00	75.00	75.00	73.21
ELAS-MAF	75.00	75.00	75.00	75.00	75.00	75.00	75.00	75.00	75.00	75.00
Régressions régularisées par sous-ensembles complets										
T-CSR10	85.71***	78.57**	66.07	71.43	58.93*	83.93***	76.79**	67.86	69.64	60.71
T-CSR20	76.79*	73.21	75.00	75.00	75.00	78.57**	75.00	73.21	75.00	75.00
CSR-R10	78.57**	73.21	71.43	75.00	75.00	78.57**	75.00	73.21	75.00	75.00
CSR-R20	83.93***	75.00	75.00	71.43	69.64	80.36***	67.86	67.86	64.29	66.07
Régressions à vecteurs de support										
NL-SVRARDI	85.71***	76.79*	75.00	75.00	66.07	83.93***	76.79*	67.86	69.64	66.07
L-SVRARDI	80.36***	75.00	75.00	73.21	75.00	82.14***	76.79*	78.57**	75.00	76.79*
Forêts d'arbres aléatoires										
RFARDI	82.14***	76.79*	73.21	69.64	66.07	85.71***	75.00	66.07	64.29	64.29
RF-X	75.00	73.21	67.86	73.21	75.00	75.00	71.43	71.43	75.00	75.00
RF-CSF	75.00	58.93	58.93	67.86	60.71*	76.79**	67.86	55.36	67.86	67.86
RF-MAF	78.57**	73.21	71.43	71.43	75.00	78.57**	75.00	69.64	73.21	75.00
RF-X-CSF	75.00	71.43	66.07	75.00	75.00	75.00	71.43	67.86	75.00	75.00
LLF-CSF	78.57***	64.29	73.21	67.86	64.29	85.71***	67.86	67.86	69.64	66.07
ARERT	76.79*	66.07	66.07	69.64	69.64	80.36***	73.21	66.07	71.43	73.21
ARDIERT	76.79**	76.79*	71.43	67.86	66.07	78.57***	73.21	67.86	73.21	71.43
EOTB-ERT	78.57**	69.64	76.79*	69.64	57.14	73.21	71.43	55.36**	66.07	58.93
ARRF	78.57**	71.43	60.71	69.64	73.21	83.93***	75.00	60.71*	67.86	71.43
ARDIRF	80.36***	76.79*	66.07	67.86	69.64	78.57***	75.00	64.29	73.21	71.43
EOTB-MRF	76.79*	73.21	73.21	64.29	53.57	78.57**	75.00	66.07	58.93*	66.07
ERT-MAF	80.36***	75.00	66.07	71.43	75.00	75.00	75.00	69.64	75.00	75.00
Réseau de neurones										
LSTM-Dense-AR	82.14***	73.21	75.00	75.00	75.00	82.14***	73.21	75.00	75.00	75.00
LSTM-AR	80.36***	75.00	75.00	75.00	75.00	80.36***	75.00	75.00	75.00	75.00
Dense-AR	82.14***	76.79*	71.43	67.86	75.00	82.14***	76.79*	71.43	67.86	75.00
LSTM-Dense-ARDI	75.00	73.21	75.00	75.00	67.86	76.79*	71.43	71.43	73.21	66.07
LSTM-ARDI	78.57**	75.00	75.00	71.43	69.64	78.57***	76.79*	69.64	64.29	69.64
Dense-ARDI	82.14***	69.64	66.07	67.86	64.29	67.86	62.50	69.64	64.29	57.14
LSTM-Dense	73.21**	75.00*	64.29	69.64	58.93	75.00	76.79*	71.43	75.00	75.00
LSTM	82.14***	67.86	78.57**	75.00	75.00	75.00	75.00	73.21	75.00	75.00
Dense	62.50	64.29	64.29	69.64*	60.71	73.21	71.43	78.57**	75.00	73.21
Combinaisons de prévisions										
AVRG	78.57**	73.21	75.00	75.00	75.00	78.57**	73.21	71.43	75.00	75.00
Médiane	78.57**	75.00	75.00	75.00	75.00	78.57**	75.00	75.00	75.00	75.00
T-AVRG,0.1	78.57**	73.21	75.00	75.00	75.00	78.57**	73.21	75.00	75.00	75.00
T-AVRG,0.2	78.57**	73.21	75.00	75.00	75.00	78.57**	73.21	75.00	75.00	75.00
IP-AVRG,1	78.57**	73.21	75.00	75.00	75.00	78.57**	75.00	71.43	75.00	75.00
IP-AVRG,0.95	78.57**	73.21	75.00	75.00	75.00	78.57**	73.21	71.43	75.00	75.00

TABLE 23: Consommation réelle - Québec : RCSF

Modèles	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64
ARDI,BIC	92.86	94.64	94.64	94.64	94.64	92.86	92.86	94.64	94.64	94.64
Régressions pénalisées										
Ridge	92.86	94.64	94.64	94.64	94.64	91.07	94.64	94.64	94.64	94.64
Lasso	91.07	94.64	94.64	94.64	94.64	91.07	94.64	92.86	94.64	94.64
Elastic-Net	83.93	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64
Adaptive-Lasso	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64
ARDI,Ridge	89.29	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64
ARDI,Lasso	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64
ARDI,Elastic-Net	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64
ARDI,Adaptive-Lasso	92.86	94.64	94.64	94.64	94.64	91.07	94.64	94.64	94.64	94.64***
Ridge-MAF	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64
LASSO-MAF	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64
ELAS-MAF	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64
Régressions régularisées par sous-ensembles complets										
T-CSR10	89.29	89.29	92.86	89.29	85.71	91.07	96.43***	94.64	92.86	91.07
T-CSR20	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64
CSR-R10	94.64	92.86	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64
CSR-R20	94.64	94.64	94.64	94.64	94.64	92.86	92.86	94.64	94.64	94.64
Régressions à vecteurs de support										
NL-SVRARDI	91.07	92.86	94.64	92.86	92.86**	92.86	94.64	94.64	92.86	94.64
L-SVRARDI	92.86	92.86	94.64	94.64	94.64	91.07	91.07	94.64	94.64	94.64
Forêts d'arbres aléatoires										
RFARDI	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64
RF-X	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64
RF-CSF	92.86	91.07	94.64	94.64	92.86	94.64	94.64	94.64	94.64	94.64
RF-MAF	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64
RF-X-CSF	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64
LLF-CSF	94.64	87.50	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64
ARERT	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64
ARDIERT	91.07	92.86	91.07*	87.50	92.86**	91.07	94.64	92.86	94.64	94.64***
EOTB-ERT	94.64	94.64	94.64	94.64	94.64	92.86	94.64	94.64	94.64	94.64
ARRF	94.64	94.64	94.64	94.64	92.86	94.64	94.64	94.64	94.64	92.86
ARDIRF	91.07	94.64	92.86**	89.29	89.29	92.86	94.64	92.86	94.64	89.29
EOTB-MRF	94.64	94.64	91.07	94.64	92.86	92.86	92.86	94.64	94.64	94.64
ERT-MAF	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64
Réseau de neurones										
LSTM-Dense-AR	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64
LSTM-AR	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64
Dense-AR	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64
LSTM-Dense-ARDI	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64
LSTM-ARDI	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64
Dense-ARDI	94.64	94.64	94.64	94.64	94.64	94.64	92.86	91.07*	94.64	94.64
LSTM-Dense	94.64	91.07	94.64	94.64	94.64	94.64	94.64	91.07	94.64	94.64
LSTM	94.64	92.86	94.64	92.86	94.64	94.64	94.64	94.64	94.64	94.64
Dense	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64
Combinaisons de prévisions										
AVRG	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64
Médiane	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64
T-AVRG,0.1	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64
T-AVRG,0.2	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64
IP-AVRG,1	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64
IP-AVRG,0.95	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64

TABLE 24: Consommation réelle - Canada : RCSF

Modèles	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43
ARDI,BIC	94.64	94.64	96.43	96.43	96.43	94.64	92.86	96.43	96.43	96.43
Régressions pénalisées										
Ridge	96.43	96.43	96.43	96.43	96.43	96.43***	96.43	96.43	96.43	96.43
Lasso	98.21***	96.43	96.43	96.43	96.43	98.21***	96.43	96.43	96.43	96.43
Elastic-Net	96.43***	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43
Adaptive-Lasso	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43
ARDI,Ridge	94.64***	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43
ARDI,Lasso	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43
ARDI,Elastic-Net	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43
ARDI,Adaptive-Lasso	94.64	96.43	96.43	96.43	96.43	92.86	94.64	92.86	96.43	92.86
Ridge-MAF	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43
LASSO-MAF	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43
ELAS-MAF	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43
Régressions régularisées par sous-ensembles complets										
T-CSR10	96.43***	94.64	96.43	96.43	94.64	96.43***	94.64	96.43	92.86	94.64
T-CSR20	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43
CSR-R10	96.43	94.64	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43
CSR-R20	96.43	96.43	96.43	96.43	96.43	94.64	96.43	96.43	96.43	96.43
Régressions à vecteurs de support										
NL-SVRARDI	94.64	94.64	96.43	96.43	96.43	96.43***	94.64	96.43	96.43	96.43
L-SVRARDI	96.43***	94.64	96.43	96.43	96.43	94.64	96.43	96.43	96.43	96.43
Forêts d'arbres aléatoires										
RFARDI	94.64	96.43	96.43	96.43	96.43	92.86	94.64	96.43	96.43	96.43
RF-X	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43
RF-CSF	92.86	94.64	96.43	94.64	96.43	94.64	94.64	96.43	96.43	96.43
RF-MAF	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43
RF-X-CSF	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43
LLF-CSF	92.86	94.64	96.43	96.43	96.43	91.07	92.86	96.43	96.43	96.43
ARERT	96.43	94.64	96.43	94.64	96.43	96.43	96.43	96.43	94.64	96.43
ARDIERT	92.86	96.43	96.43	96.43	96.43	92.86	96.43	96.43	96.43	96.43
EOTB-ERT	96.43	94.64	96.43	94.64	96.43	96.43	94.64	96.43	96.43	96.43
ARRF	94.64	96.43	96.43	94.64	96.43	96.43	96.43	96.43	94.64	96.43
ARDIRF	91.07	94.64	92.86	96.43	96.43	92.86**	96.43	92.86	94.64	96.43
EOTB-MRF	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43
ERT-MAF	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43
Réseau de neurones										
LSTM-Dense-AR	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43
LSTM-AR	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43
Dense-AR	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43
LSTM-Dense-ARDI	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43
LSTM-ARDI	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43
Dense-ARDI	92.86	94.64	96.43	96.43	96.43	96.43	94.64	96.43	94.64	96.43
LSTM-Dense	96.43	96.43	96.43	96.43	96.43	92.86	94.64	89.29	96.43	96.43
LSTM	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43
Dense	96.43	96.43	96.43	96.43	96.43	80.36***	87.50	94.64	96.43	87.50*
Combinaisons de prévisions										
AVRG	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43
Médiane	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43
T-AVRG,0.1	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43
T-AVRG,0.2	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43
IP-AVRG,1	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43
IP-AVRG,0.95	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43	96.43

TABLE 25: Taux de chômage - Québec : RCSF

Modèles	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC	53.57	55.36	57.14	64.29	58.93*	53.57	55.36	57.14	64.29	58.93*
ARDI,BIC	58.93	57.14	57.14	60.71	62.50	51.79	53.57	55.36	69.64**	67.86*
Régressions pénalisées										
Ridge	60.71	62.50	60.71	60.71	60.71	58.93*	62.50	60.71	60.71	60.71
Lasso	<u>69.64**</u>	62.50	60.71	60.71	60.71	<u>67.86**</u>	64.29	62.50	64.29	64.29
Elastic-Net	60.71	60.71	60.71	60.71	60.71	67.86*	60.71	60.71	60.71	60.71
Adaptive-Lasso	62.50	60.71	57.14	62.50	60.71	66.07**	62.50	60.71	58.93	53.57
ARDI,Ridge	60.71	62.50	60.71	60.71	60.71	53.57**	60.71	58.93*	60.71	60.71
ARDI,Lasso	67.86**	57.14	60.71	60.71	57.14	60.71	67.86*	60.71	60.71	58.93*
ARDI,Elastic-Net	58.93*	55.36	60.71	60.71	60.71	60.71	60.71	62.50	60.71	60.71
ARDI,Adaptive-Lasso	64.29	<u>69.64**</u>	55.36	60.71	60.71	60.71	60.71	62.50	60.71	64.29
Ridge-MAF	67.86*	64.29	58.93	62.50	62.50	66.07	60.71	60.71	60.71	60.71
LASSO-MAF	60.71	60.71	60.71	<u>55.36**</u>	60.71	<u>57.14*</u>	60.71	60.71	60.71	60.71
ELAS-MAF	60.71	60.71	60.71	57.14	60.71	60.71	55.36**	60.71	60.71	60.71
Régressions régularisées par sous-ensembles complets										
T-CSR10	62.50	60.71	53.57	64.29	64.29	67.86**	67.86*	55.36	62.50	58.93
T-CSR20	39.29**	62.50	55.36	58.93*	62.50	48.21	53.57*	58.93*	60.71	58.93*
CSR-R10	55.36	58.93	46.43	58.93*	60.71	55.36	64.29	62.50	58.93*	60.71
CSR-R20	62.50	58.93	58.93*	60.71	58.93	58.93	57.14	55.36	62.50	62.50
Régressions à vecteurs de support										
NL-SVRARDI	60.71	62.50	58.93	53.57	62.50	60.71	67.86*	62.50	60.71	62.50
L-SVRARDI	60.71	51.79	57.14	60.71	64.29	58.93	64.29	62.50	55.36**	60.71
Forêts d'arbres aléatoires										
RFARDI	51.79	51.79	51.79	51.79	62.50	55.36	58.93	62.50	60.71	57.14
RF-X	66.07**	60.71	60.71	62.50	58.93	62.50	58.93	60.71	58.93	64.29
RF-CSF	60.71	60.71	62.50	58.93	<u>66.07*</u>	51.79	58.93	58.93	64.29	57.14
RF-MAF	62.50	67.86*	64.29	66.07	55.36	60.71	67.86*	57.14	67.86**	62.50
RF-X-CSF	60.71	60.71	<u>69.64**</u>	58.93	57.14	64.29*	64.29	60.71	57.14	60.71
LLF-CSF	51.79	53.57	53.57	58.93	57.14	58.93	57.14	<u>64.29</u>	62.50	66.07*
ARERT	58.93	58.93	66.07*	55.36	60.71	53.57	48.21*	51.79	53.57	66.07
ARDIERT	57.14	51.79	51.79	57.14	62.50	53.57	46.43	53.57	58.93	<u>67.86**</u>
EOTB-ERT	58.93	55.36	60.71	62.50	51.79	62.50	60.71	53.57	51.79	51.79
ARRF	58.93	58.93	57.14	55.36	64.29	57.14	50.00	50.00	50.00	55.36
ARDIRF	55.36	53.57	53.57	51.79	57.14	53.57	50.00	58.93	57.14	51.79
EOTB-MRF	60.71	58.93	58.93	<u>67.86*</u>	60.71	58.93	64.29	55.36	58.93	51.79
ERT-MAF	62.50	64.29	64.29	62.50	62.50	62.50	62.50	60.71	67.86*	67.86*
Réseau de neurones										
LSTM-Dense-AR	64.29	62.50	60.71	62.50	60.71	64.29	62.50	60.71	62.50	60.71
LSTM-AR	62.50	60.71	60.71	60.71	60.71	62.50	60.71	60.71	60.71	60.71
Dense-AR	62.50	53.57**	53.57	51.79	55.36**	62.50	53.57**	53.57	51.79	55.36**
LSTM-Dense-ARDI	58.93	57.14	60.71	62.50	62.50	62.50	67.86*	57.14	60.71	57.14
LSTM-ARDI	57.14	62.50	60.71	62.50	57.14	60.71	53.57	58.93	51.79	60.71
Dense-ARDI	60.71	48.21	53.57	51.79	53.57	53.57	66.07	55.36	58.93	64.29
LSTM-Dense	51.79	58.93	53.57	60.71	57.14	48.21	57.14	58.93	57.14	50.00
LSTM	58.93	53.57	44.64	64.29	51.79*	53.57	53.57	51.79	53.57	50.00
Dense	58.93	57.14	53.57	57.14	51.79	48.21	67.86**	58.93	57.14	57.14
Combinaisons de prévisions										
AVRG	62.50	64.29	57.14	55.36	62.50	60.71	64.29	60.71	64.29	66.07
Médiane	67.86**	66.07	62.50	60.71	60.71	67.86*	66.07	58.93	62.50	60.71
T-AVRG,0.1	66.07*	64.29	57.14	58.93	58.93*	62.50	67.86*	57.14	58.93	62.50
T-AVRG,0.2	66.07*	64.29	58.93	60.71	60.71	64.29	<u>69.64**</u>	58.93	62.50	62.50
IP-AVRG,1	66.07**	62.50	57.14	58.93	62.50	62.50	66.07	58.93	64.29	66.07
IP-AVRG,0.95	66.07**	62.50	57.14	58.93	62.50	62.50	66.07	58.93	64.29	66.07

TABLE 26: Taux de chômage - Canada : RCSF

Modèles	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC	60.71	60.71	64.29***	64.29***	64.29***	60.71	60.71	64.29***	64.29***	64.29***
ARDI,BIC	66.07*	67.86*	57.14	62.50***	67.86	64.29	66.07	55.36*	66.07	60.71
Régressions pénalisées										
Ridge	64.29	58.93***	57.14***	64.29***	60.71	60.71	78.57**	69.64	64.29***	64.29***
Lasso	71.43*	69.64	50.00**	64.29***	64.29	73.21*	78.57**	58.93	58.93***	58.93
Elastic-Net	60.71***	64.29***	64.29***	64.29***	64.29***	64.29***	64.29***	64.29***	62.50***	64.29***
Adaptive-Lasso	71.43	69.64	66.07	66.07**	60.71***	75.00**	69.64	67.86	64.29	64.29
ARDI,Ridge	67.86*	69.64	64.29***	64.29***	66.07	78.57**	66.07	64.29***	64.29***	71.43
ARDI,Lasso	71.43*	69.64	64.29***	64.29***	67.86	75.00**	67.86	60.71**	64.29***	69.64
ARDI,Elastic-Net	76.79**	69.64	64.29***	64.29***	64.29	66.07	71.43	64.29***	64.29***	62.50***
ARDI,Adaptive-Lasso	64.29**	62.50	57.14***	62.50***	62.50*	69.64***	66.07*	66.07	69.64	58.93**
Ridge-MAF	69.64	66.07	62.50**	64.29	64.29***	71.43	64.29***	64.29***	64.29***	64.29***
LASSO-MAF	69.64*	69.64	69.64	66.07**	64.29***	69.64*	73.21**	53.57***	64.29***	64.29***
ELAS-MAF	69.64	73.21	64.29***	64.29***	64.29***	71.43*	69.64**	64.29***	64.29***	64.29***
Régressions régularisées par sous-ensembles complets										
T-CSR10	66.07	64.29	58.93	57.14	44.64*	75.00**	73.21**	62.50	58.93	53.57
T-CSR20	53.57	46.43*	64.29***	64.29***	64.29***	30.36***	58.93	64.29	66.07***	64.29***
CSR-R10	55.36	46.43	64.29**	66.07***	64.29***	33.93*	58.93	57.14*	66.07***	64.29***
CSR-R20	67.86*	67.86	62.50***	64.29**	57.14	69.64*	67.86	58.93**	62.50***	64.29
Régressions à vecteurs de support										
NL-SVRARDI	67.86*	69.64	60.71	58.93	53.57	75.00**	78.57***	58.93	62.50	62.50
L-SVRARDI	66.07	64.29	62.50***	60.71***	62.50	71.43*	71.43	69.64	58.93**	62.50
Forêts d'arbres aléatoires										
RFARDI	64.29	71.43*	51.79	66.07	58.93	71.43*	73.21**	58.93	58.93	60.71
RF-X	71.43	67.86	73.21*	67.86	55.36***	69.64	69.64	66.07	66.07	58.93***
RF-CSF	69.64	64.29	60.71	66.07	57.14	69.64	67.86	50.00	60.71	58.93
RF-MAF	71.43	69.64	67.86	67.86	57.14	69.64	76.79*	62.50	62.50	60.71
RF-X-CSF	73.21*	66.07	73.21*	69.64	60.71**	69.64	71.43	62.50	64.29	66.07
LLF-CSF	73.21**	53.57	58.93	62.50	64.29	69.64*	57.14	67.86	64.29	58.93
ARERT	73.21	67.86	64.29	58.93	64.29	75.00	71.43*	55.36*	51.79*	66.07
ARDIERT	73.21**	71.43	62.50	64.29	62.50	71.43**	62.50	57.14	60.71***	66.07
EOTB-ERT	67.86	60.71	69.64	66.07	53.57	69.64	44.64	71.43	67.86	66.07
ARRF	76.79**	66.07	69.64	55.36	55.36	67.86	64.29	58.93	62.50	48.21**
ARDIRF	71.43**	76.79**	71.43	62.50	64.29	66.07	67.86	67.86	62.50**	57.14
EOTB-MRF	71.43	55.36	69.64	60.71	67.86	66.07	48.21	71.43	64.29	67.86
ERT-MAF	71.43	71.43	66.07	67.86	67.86	71.43	75.00	66.07	60.71	62.50
Réseau de neurones										
LSTM-Dense-AR	69.64	46.43***	64.29***	66.07***	64.29***	69.64	46.43***	64.29***	66.07***	64.29***
LSTM-AR	53.57***	58.93***	60.71***	64.29**	62.50***	53.57***	58.93***	60.71***	64.29**	62.50***
Dense-AR	69.64	66.07	55.36***	58.93***	58.93	69.64	66.07	55.36***	58.93***	58.93
LSTM-Dense-ARDI	67.86*	60.71	62.50***	64.29*	60.71	75.00*	71.43	62.50	58.93	66.07
LSTM-ARDI	62.50	66.07	60.71***	64.29	73.21	66.07	58.93	67.86	60.71	57.14
Dense-ARDI	67.86	64.29	64.29	64.29	60.71	46.43	53.57	64.29	55.36	50.00
LSTM-Dense	55.36	60.71	55.36	51.79	66.07	60.71	55.36	66.07	50.00**	66.07
LSTM	51.79*	62.50	58.93	60.71	57.14*	64.29	66.07	67.86	60.71	58.93
Dense	57.14	51.79	53.57	64.29	51.79	73.21**	66.07**	58.93	58.93	48.21
Combinaisons de prévisions										
AVRG	73.21**	76.79**	67.86	64.29	66.07	75.00**	71.43*	71.43	67.86	64.29
Médiane	75.00**	75.00*	62.50***	62.50***	69.64	75.00**	76.79**	64.29	66.07***	66.07
T-AVRG,0.1	75.00**	75.00*	67.86	64.29	66.07	75.00**	73.21**	73.21	67.86	66.07
T-AVRG,0.2	75.00**	75.00*	66.07	60.71**	64.29	75.00**	78.57**	66.07	62.50***	66.07
IP-AVRG,1	75.00**	76.79**	67.86	66.07	66.07	75.00**	73.21**	69.64	67.86	62.50
IP-AVRG,0.95	76.79***	76.79**	67.86	66.07	66.07	75.00**	73.21**	69.64	67.86	62.50

TABLE 27: Emploi - Québec : RCSF

Modèles	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC	64.29	73.21	73.21	73.21	<u>73.21</u>	73.21	64.29	73.21	73.21	<u>73.21</u>
ARDI,BIC	<u>73.21</u>	73.21	73.21	73.21	73.21	76.79**	71.43	73.21	69.64	66.07
Régressions pénalisées										
Ridge	73.21	73.21	73.21	73.21	73.21	73.21	<u>75.00*</u>	73.21	73.21	73.21
Lasso	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	69.64	69.64
Elastic-Net	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21
Adaptive-Lasso	73.21	73.21	73.21	73.21	73.21	75.00	73.21	73.21	73.21	73.21
ARDI,Ridge	73.21	73.21	73.21	73.21	69.64	73.21	73.21	73.21	73.21	73.21
ARDI,Lasso	71.43	73.21	73.21	73.21	73.21	73.21	<u>75.00*</u>	73.21	73.21	73.21
ARDI,Elastic-Net	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21
ARDI,Adaptive-Lasso	73.21	73.21	73.21	71.43	73.21	71.43	73.21	69.64	69.64	73.21
Ridge-MAF	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21
LASSO-MAF	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21
ELAS-MAF	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21
Régressions régularisées par sous-ensembles complets										
T-CSR10	73.21	71.43	64.29	64.29	62.50	71.43	69.64	64.29	60.71*	64.29
T-CSR20	73.21	<u>73.21</u>	73.21	73.21	73.21	73.21	<u>73.21</u>	73.21	73.21	73.21
CSR-R10	73.21	<u>75.00*</u>	73.21	73.21	73.21	<u>75.00*</u>	73.21	73.21	73.21	73.21
CSR-R20	73.21	73.21	73.21	73.21	71.43	73.21	69.64	73.21	73.21	67.86
Régressions à vecteurs de support										
NL-SVRARDI	73.21	<u>75.00*</u>	69.64	64.29	67.86	71.43	73.21	71.43	64.29	64.29
L-SVRARDI	71.43	73.21	73.21	71.43	60.71	<u>78.57***</u>	66.07	67.86	69.64	64.29
Forêts d'arbres aléatoires										
RFARDI	69.64	69.64	69.64	71.43	67.86	69.64	73.21	73.21	69.64	67.86
RF-X	73.21	73.21	71.43	73.21	73.21	73.21	73.21	73.21	73.21	73.21
RF-CSF	71.43	71.43	69.64	67.86	73.21	73.21	71.43	69.64	69.64	71.43
RF-MAF	73.21	73.21	71.43	73.21	73.21	71.43	71.43	73.21	73.21	73.21
RF-X-CSF	73.21	73.21	69.64	73.21	73.21	73.21	73.21	73.21	73.21	73.21
LLF-CSF	71.43	71.43	66.07	64.29	69.64	71.43	69.64	67.86	66.07	69.64
ARERT	69.64	<u>75.00*</u>	<u>75.00</u>	73.21	<u>75.00*</u>	71.43	73.21	<u>75.00*</u>	73.21	69.64
ARDIERT	67.86	<u>75.00*</u>	64.29	64.29	69.64	73.21	69.64	73.21	67.86	73.21
EOTB-ERT	66.07	66.07	67.86	<u>51.79**</u>	58.93	69.64	69.64	73.21	62.50	69.64
ARRF	69.64	71.43	66.07	73.21	71.43	67.86	75.00	73.21	67.86	71.43
ARDIRF	69.64	<u>75.00</u>	67.86	64.29	67.86	73.21	<u>73.21</u>	69.64	67.86	71.43
EOTB-MRF	60.71*	60.71	62.50	<u>42.86*</u>	64.29	71.43	66.07	69.64	50.00**	67.86
ERT-MAF	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21
Réseau de neurones										
LSTM-Dense-AR	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21
LSTM-AR	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21
Dense-AR	67.86	67.86	73.21	73.21	73.21	67.86	67.86	73.21	73.21	73.21
LSTM-Dense-ARDI	73.21	73.21	73.21	73.21	73.21	73.21	67.86	73.21	73.21	73.21
LSTM-ARDI	73.21	73.21	73.21	73.21	69.64	<u>76.79**</u>	73.21	73.21	69.64	67.86
Dense-ARDI	69.64	71.43	73.21	66.07	<u>60.71*</u>	69.64	73.21	69.64	62.50	58.93
LSTM-Dense	66.07	69.64	51.79	67.86	67.86	71.43	67.86	69.64	62.50	73.21
LSTM	73.21	73.21	66.07	67.86	71.43	66.07	<u>73.21</u>	73.21	71.43	69.64
Dense	51.79	48.21	57.14	50.00	58.93	69.64**	64.29	58.93	66.07	58.93
Combinaisons de prévisions										
AVRG	71.43	<u>73.21</u>	73.21	73.21	73.21	71.43	73.21	73.21	73.21	73.21
Médiane	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21
T-AVRG,0.1	71.43	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21
T-AVRG,0.2	71.43	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21
IP-AVRG,1	71.43	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21
IP-AVRG,0.95	71.43	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21

TABLE 28: Emploi - Canada : RCSF

Modèles	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC	94.64***	92.86	94.64	94.64	94.64	94.64***	92.86	94.64	94.64	94.64
ARDI,BIC	92.86**	91.07	94.64	94.64	91.07	94.64***	94.64***	91.07	92.86	91.07
Régressions pénalisées										
Ridge	91.07***	94.64	94.64	94.64	94.64	94.64***	92.86	94.64	94.64	94.64
Lasso	94.64***	92.86	94.64	94.64	92.86	96.43***	96.43***	94.64	94.64	94.64
Elastic-Net	89.29***	94.64	94.64	94.64	94.64	92.86***	94.64	94.64	94.64	94.64
Adaptive-Lasso	96.43***	94.64	94.64	94.64	94.64	96.43***	89.29	94.64	94.64	94.64
ARDI,Ridge	96.43***	92.86	94.64	94.64	94.64	87.50	94.64	94.64	94.64	94.64
ARDI,Lasso	94.64***	92.86	94.64	94.64	94.64	96.43***	94.64	94.64	94.64	94.64
ARDI,Elastic-Net	92.86	92.86	94.64	94.64	82.14	91.07	94.64	94.64	94.64	94.64
ARDI,Adaptive-Lasso	98.21***	94.64***	92.86	94.64	94.64	98.21***	94.64***	89.29	91.07	92.86
Ridge-MAF	94.64***	94.64	94.64	94.64	94.64	94.64***	94.64	94.64	94.64	94.64
LASSO-MAF	96.43***	94.64	94.64	94.64	94.64	96.43***	94.64	94.64	94.64	91.07
ELAS-MAF	96.43***	94.64	94.64	94.64	94.64	96.43***	94.64	94.64	94.64	94.64
Régressions régularisées par sous-ensembles complets										
T-CSR10	98.21***	94.64***	94.64	89.29	91.07	96.43***	96.43***	94.64***	89.29	85.71
T-CSR20	96.43***	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64
CSR-R10	98.21***	92.86	94.64	94.64	94.64	96.43***	94.64	94.64	94.64	94.64
CSR-R20	96.43***	92.86	94.64	94.64	92.86	94.64***	92.86**	94.64	94.64	87.50***
Régressions à vecteurs de support										
NL-SVRARDI	96.43***	94.64***	94.64	92.86	94.64	96.43***	96.43***	96.43***	92.86	92.86
L-SVRARDI	94.64***	92.86**	94.64	94.64	87.50	94.64***	94.64***	91.07	87.50	91.07
Forêts d'arbres aléatoires										
RFARDI	94.64***	91.07	92.86	92.86	91.07	94.64***	92.86**	91.07	91.07	92.86
RF-X	94.64	92.86	91.07	94.64	94.64	94.64	94.64	94.64	94.64	94.64
RF-CSF	96.43***	91.07	89.29	89.29	94.64	94.64***	94.64	87.50	91.07	94.64
RF-MAF	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64
RF-X-CSF	94.64	92.86	91.07	94.64	94.64	94.64	94.64	94.64	94.64	94.64
LLF-CSF	94.64***	92.86*	87.50	85.71	87.50	94.64***	91.07	91.07	94.64	94.64
ARERT	94.64***	94.64***	94.64	94.64	94.64	94.64***	94.64***	94.64	94.64	94.64
ARDIERT	94.64***	91.07	92.86**	92.86	91.07	96.43***	94.64***	94.64	94.64	94.64
EOTB-ERT	94.64	94.64	91.07***	89.29	94.64	94.64	94.64	94.64	94.64	94.64
ARRF	94.64***	91.07	91.07	94.64	94.64	94.64***	94.64	94.64	94.64	94.64
ARDIRF	92.86***	91.07	89.29	89.29	91.07	96.43***	91.07	92.86	94.64	94.64
EOTB-MRF	94.64	94.64	87.50	83.93***	94.64	94.64	94.64	94.64	91.07	91.07
ERT-MAF	94.64	94.64	92.86	94.64	94.64	96.43***	94.64	94.64	94.64	94.64
Réseau de neurones										
LSTM-Dense-AR	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64
LSTM-AR	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64	94.64
Dense-AR	94.64***	92.86	94.64	92.86	94.64	94.64***	92.86	94.64	92.86	94.64
LSTM-Dense-ARDI	92.86**	91.07	94.64	94.64	94.64	94.64***	94.64	89.29	94.64	92.86
LSTM-ARDI	91.07	94.64	94.64	94.64	94.64	91.07	91.07	89.29	94.64	91.07
Dense-ARDI	92.86**	91.07*	92.86	92.86	94.64	91.07***	87.50	94.64	89.29	91.07
LSTM-Dense	94.64***	87.50	89.29	89.29	94.64	78.57*	92.86	92.86	69.64	94.64
LSTM	92.86	94.64	94.64	94.64	94.64	94.64	92.86	94.64	94.64	94.64
Dense	50.00	75.00***	78.57*	85.71***	89.29***	78.57*	85.71***	91.07***	51.79	66.07
Combinaisons de prévisions										
AVRG	96.43***	92.86	94.64	94.64	94.64	94.64***	92.86	94.64	94.64	94.64
Médiane	94.64***	94.64	94.64	94.64	94.64	94.64***	94.64	94.64	94.64	94.64
T-AVRG,0.1	96.43***	92.86	94.64	94.64	94.64	94.64***	92.86	94.64	94.64	94.64
T-AVRG,0.2	96.43***	94.64	94.64	94.64	94.64	94.64***	92.86	94.64	94.64	94.64
IP-AVRG,1	96.43***	92.86	94.64	94.64	94.64	94.64***	92.86	94.64	94.64	94.64
IP-AVRG,0.95	96.43***	92.86	94.64	94.64	94.64	94.64***	92.86	94.64	94.64	94.64

TABLE 29: Mises en chantier - Québec : RCSF

Modèles	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC	64.29**	57.14	57.14	53.57	46.43	64.29**	57.14	57.14	53.57	46.43
ARDI,BIC	<u>75.00***</u>	53.57	62.50*	48.21	48.21	<u>73.21***</u>	55.36	55.36	48.21	48.21
Régressions pénalisées										
Ridge	46.43	50.00	46.43	55.36	50.00	46.43	46.43	46.43	55.36	50.00
Lasso	46.43	51.79	44.64	53.57	48.21	51.79	53.57	44.64	46.43	46.43
Elastic-Net	46.43	46.43	46.43	55.36	50.00	46.43	46.43	46.43	55.36	50.00
Adaptive-Lasso	51.79	51.79	51.79	55.36	51.79	53.57	51.79	51.79	58.93	57.14
ARDI,Ridge	51.79	44.64	46.43	55.36	50.00	<u>51.79*</u>	46.43	41.07	55.36	50.00
ARDI,Lasso	55.36	50.00	50.00	55.36	50.00	57.14	48.21	46.43	55.36	50.00
ARDI,Elastic-Net	48.21	46.43	46.43	55.36	50.00	46.43	46.43	46.43	55.36	50.00
ARDI,Adaptive-Lasso	50.00	57.14	46.43	55.36	42.86	53.57	46.43	46.43	46.43	51.79
Ridge-MAF	48.21	58.93	42.86	46.43	55.36	46.43	<u>62.50**</u>	48.21	51.79	53.57
LASSO-MAF	46.43	46.43	50.00	46.43	53.57	46.43	46.43	53.57	46.43	53.57
ELAS-MAF	51.79	46.43	53.57	46.43	53.57	44.64	46.43	53.57	46.43	53.57
Régressions régularisées par sous-ensembles complets										
T-CSR10	64.29**	53.57	58.93	46.43	42.86	60.71	48.21	55.36	48.21	50.00
T-CSR20	41.07	57.14	48.21	46.43	58.93	<u>30.36***</u>	48.21	44.64	<u>66.07**</u>	53.57
CSR-R10	37.50**	55.36	48.21	46.43	53.57	<u>32.14***</u>	50.00	50.00	58.93	48.21
CSR-R20	51.79	<u>55.36**</u>	48.21	57.14	46.43	<u>57.14*</u>	50.00	46.43	57.14	50.00
Régressions à vecteurs de support										
NL-SVRARDI	69.64***	44.64	<u>64.29**</u>	50.00	42.86	62.50*	48.21	58.93	42.86	51.79
L-SVRARDI	60.71*	50.00	46.43	46.43	46.43	57.14	46.43	48.21	46.43	48.21
Forêts d'arbres aléatoires										
RFARDI	62.50**	50.00	51.79	55.36	55.36	55.36	51.79	53.57	48.21	46.43
RF-X	55.36	55.36	53.57	58.93	<u>64.29**</u>	53.57	62.50**	58.93	51.79	57.14
RF-CSF	58.93	46.43	53.57	44.64	44.64	<u>66.07**</u>	64.29**	55.36	48.21	50.00
RF-MAF	55.36	53.57	60.71*	53.57	51.79	51.79	60.71	57.14	44.64	51.79
RF-X-CSF	53.57	50.00	53.57	58.93	50.00	50.00	57.14	55.36	55.36	<u>60.71*</u>
LLF-CSF	53.57	<u>69.64***</u>	57.14	51.79	53.57	<u>64.29**</u>	<u>60.71*</u>	<u>60.71*</u>	48.21	51.79
ARERT	57.14	51.79	51.79	50.00	51.79	53.57	62.50*	53.57	50.00	<u>66.07***</u>
ARDIERT	55.36	46.43	55.36	57.14	58.93	<u>67.86***</u>	60.71	58.93	50.00	51.79
EOTB-ERT	51.79	57.14	58.93	<u>33.93**</u>	<u>39.29*</u>	41.07	55.36	48.21	51.79	46.43
ARRF	<u>64.29**</u>	57.14	51.79	<u>60.71</u>	55.36	<u>66.07**</u>	57.14	42.86	<u>62.50*</u>	44.64
ARDIRF	57.14	57.14	53.57	57.14	57.14	55.36	58.93	50.00	<u>66.07**</u>	48.21
EOTB-MRF	48.21	48.21	55.36	41.07	42.86	46.43	48.21	48.21	55.36	42.86
ERT-MAF	46.43	58.93	55.36	48.21	53.57	51.79	<u>66.07**</u>	55.36	48.21	46.43
Réseau de neurones										
LSTM-Dense-AR	58.93*	46.43	50.00	46.43	42.86	58.93*	46.43	50.00	46.43	42.86
LSTM-AR	37.50**	50.00	55.36	46.43	41.07	<u>37.50**</u>	50.00	55.36	46.43	41.07
Dense-AR	57.14	<u>67.86***</u>	57.14	50.00	46.43	57.14	<u>67.86***</u>	57.14	50.00	46.43
LSTM-Dense-ARDI	51.79	57.14	46.43	48.21	41.07	46.43	46.43	51.79	46.43	50.00
LSTM-ARDI	<u>67.86***</u>	53.57	42.86	53.57	<u>35.71**</u>	51.79	58.93	46.43	50.00	44.64
Dense-ARDI	<u>71.43***</u>	58.93	55.36	48.21	51.79	53.57	57.14	51.79	50.00	44.64
LSTM-Dense	46.43	44.64	44.64	44.64	53.57	50.00	<u>64.29**</u>	53.57	50.00	46.43
LSTM	53.57	44.64	48.21	44.64	42.86	53.57	44.64	48.21	39.29	46.43
Dense	50.00	57.14	46.43	41.07	39.29	51.79	46.43	48.21	44.64	51.79
Combinaisons de prévisions										
AVRG	62.50**	57.14	57.14	48.21	50.00	<u>62.50**</u>	64.29**	58.93	53.57	55.36
Médiane	55.36	57.14	51.79	51.79	48.21	<u>58.93*</u>	53.57	44.64	50.00	46.43
T-AVRG,0.1	62.50**	57.14	53.57	46.43	50.00	<u>62.50**</u>	<u>62.50**</u>	57.14	53.57	51.79
T-AVRG,0.2	60.71*	55.36	51.79	53.57	55.36	<u>60.71*</u>	58.93*	57.14	48.21	55.36
IP-AVRG,1	62.50**	58.93	55.36	48.21	50.00	<u>62.50**</u>	<u>66.07**</u>	58.93	53.57	53.57
IP-AVRG,0.95	62.50**	57.14	57.14	48.21	50.00	<u>62.50**</u>	<u>66.07**</u>	57.14	53.57	51.79

TABLE 30: Mises en chantier - Canada : RCSF

Modèles	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC	58.93	53.57	53.57	53.57	37.50**	58.93	53.57	53.57	53.57	37.50**
ARDI,BIC	50.00	37.50	51.79	57.14	58.93	58.93	33.93*	48.21	50.00	57.14
Régressions pénalisées										
Ridge	58.93	55.36	57.14	44.64	57.14	58.93	60.71	57.14	44.64	57.14
Lasso	53.57	50.00*	58.93	55.36	57.14	53.57	55.36	58.93	53.57	57.14
Elastic-Net	58.93	60.71	57.14	44.64	57.14	58.93	60.71	57.14	44.64	57.14
Adaptive-Lasso	46.43	51.79	51.79	64.29**	60.71	44.64	46.43	62.50**	48.21	55.36
ARDI,Ridge	51.79	60.71	48.21*	44.64	57.14	58.93	58.93	57.14	44.64	57.14
ARDI,Lasso	50.00	51.79*	48.21	44.64	57.14	50.00	57.14	55.36	44.64	57.14
ARDI,Elastic-Net	58.93	60.71	57.14	44.64	57.14	58.93	57.14	55.36	44.64	57.14
ARDI,Adaptive-Lasso	51.79	60.71	58.93	42.86	57.14	55.36	67.86**	58.93	55.36	66.07*
Ridge-MAF	41.07*	50.00	48.21	48.21	64.29	50.00	55.36	53.57	55.36	64.29
LASSO-MAF	46.43	60.71	53.57	60.71	60.71	46.43	60.71	53.57	60.71	55.36
ELAS-MAF	46.43	60.71	53.57	60.71	60.71	46.43	58.93	53.57	60.71	60.71
Régressions régularisées par sous-ensembles complets										
T-CSR10	64.29**	53.57	62.50*	51.79	50.00	48.21	48.21	46.43	46.43	46.43
T-CSR20	48.21	50.00	57.14	62.50	60.71	42.86	55.36	60.71	71.43***	58.93*
CSR-R10	51.79	42.86	57.14	66.07*	57.14	32.14**	57.14	51.79*	66.07**	55.36
CSR-R20	50.00	53.57	48.21	44.64	53.57	55.36	44.64	51.79	42.86	53.57
Régressions à vecteurs de support										
NL-SVRARDI	55.36	55.36	55.36	50.00	46.43	48.21	50.00	48.21	42.86	44.64
L-SVRARDI	55.36	46.43	48.21	55.36	46.43	50.00	50.00	48.21	50.00	53.57
Forêts d'arbres aléatoires										
RFARDI	46.43	48.21	51.79	58.93	51.79	55.36	42.86	53.57	53.57	46.43
RF-X	51.79	55.36	58.93	57.14	58.93	55.36	55.36	64.29*	62.50	66.07**
RF-CSF	55.36	44.64	53.57	46.43	44.64	50.00	48.21	53.57	55.36	41.07
RF-MAF	46.43	55.36	44.64	50.00	60.71*	50.00	58.93	44.64	46.43	64.29**
RF-X-CSF	48.21	51.79	58.93	58.93	58.93	60.71	46.43	57.14	62.50	66.07**
LLF-CSF	42.86	46.43	50.00	46.43	41.07	51.79	39.29*	53.57	48.21	37.50**
ARERT	48.21	48.21	41.07	58.93	44.64	55.36	44.64	53.57	58.93	51.79
ARDIERT	60.71	41.07*	51.79	53.57	50.00	50.00	57.14	55.36	51.79	53.57
EOTB-ERT	62.50*	57.14	50.00	53.57	69.64***	58.93	67.86**	58.93	57.14	69.64**
ARRF	50.00	46.43	48.21	51.79	57.14	50.00	48.21	48.21	41.07	41.07
ARDIRF	51.79	48.21	51.79	55.36	35.71**	53.57	57.14	57.14	44.64	50.00
EOTB-MRF	64.29**	50.00	66.07*	51.79	60.71	55.36	60.71	51.79	64.29*	64.29
ERT-MAF	33.93***	48.21	51.79	55.36	57.14	53.57	51.79	44.64	53.57	60.71
Réseau de neurones										
LSTM-Dense-AR	46.43	51.79	57.14	50.00	60.71	46.43	51.79	57.14	50.00	60.71
LSTM-AR	39.29	53.57	42.86	37.50*	39.29**	39.29	53.57	42.86	37.50*	39.29**
Dense-AR	46.43	42.86*	53.57	58.93	46.43	46.43	42.86*	53.57	58.93	46.43
LSTM-Dense-ARDI	50.00	50.00	55.36	55.36	46.43	53.57	50.00	42.86	55.36	48.21
LSTM-ARDI	50.00	51.79	50.00	50.00	53.57	57.14	39.29*	51.79	44.64	53.57
Dense-ARDI	60.71*	44.64	51.79	50.00	55.36	53.57	46.43	55.36	55.36	48.21
LSTM-Dense	53.57	57.14	64.29	51.79	53.57	55.36	53.57	58.93	50.00	55.36
LSTM	55.36	60.71	51.79	51.79	50.00	51.79	50.00*	42.86	41.07	48.21
Dense	58.93	46.43	51.79	51.79	48.21	58.93	53.57	55.36	50.00	50.00
Combinaisons de prévisions										
AVRG	51.79	48.21	51.79	58.93	51.79	58.93	51.79	55.36	58.93	51.79
Médiane	51.79	58.93	57.14	57.14	57.14	48.21	55.36	55.36	50.00	62.50
T-AVRG,0.1	53.57	50.00	53.57	57.14	58.93	55.36	57.14	55.36	62.50	58.93
T-AVRG,0.2	53.57	53.57	55.36	55.36	60.71	51.79	57.14	57.14	60.71	60.71
IP-AVRG,1	51.79	44.64*	51.79	57.14	51.79	55.36	51.79	50.00	62.50	53.57
IP-AVRG,0.95	51.79	44.64*	51.79	57.14	51.79	53.57	51.79	50.00	64.29*	53.57

TABLE 31: IPC - Québec : RCSF

Modèles	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC	<u>76.79</u>	73.21	71.43	73.21	73.21	<u>76.79</u>	<u>73.21</u>	71.43	73.21	<u>73.21</u>
ARDI,BIC	73.21	71.43	71.43	73.21	66.07	75.00*	73.21	69.64	73.21	66.07
Régressions pénalisées										
Ridge	73.21	73.21	<u>75.00*</u>	73.21	73.21	73.21	73.21	73.21	73.21	73.21
Lasso	73.21	73.21	73.21	71.43	73.21	73.21	73.21	71.43	73.21	73.21
Elastic-Net	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21
Adaptive-Lasso	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21
ARDI,Ridge	69.64	73.21	73.21	69.64	<u>75.00*</u>	71.43	73.21	73.21	73.21	73.21
ARDI,Lasso	69.64	73.21	73.21	69.64	73.21	73.21	73.21	73.21	73.21	73.21
ARDI,Elastic-Net	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21
ARDI,Adaptive-Lasso	73.21	73.21	73.21	67.86	73.21	73.21	73.21	71.43	69.64	67.86
Ridge-MAF	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21
LASSO-MAF	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21
ELAS-MAF	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21
Régressions régularisées par sous-ensembles complets										
T-CSR10	73.21	73.21	73.21	<u>75.00</u>	69.64	73.21	73.21	73.21	71.43	66.07
T-CSR20	73.21	73.21	71.43	73.21	71.43	73.21	73.21	73.21	73.21	73.21
CSR-R10	71.43	73.21	69.64	73.21	69.64	73.21	73.21	69.64	73.21	69.64
CSR-R20	71.43	69.64	73.21	69.64	69.64	73.21	67.86	69.64	69.64	67.86
Régressions à vecteurs de support										
NL-SVRARDI	73.21	73.21	71.43	73.21	69.64	73.21	73.21	69.64	73.21	66.07
L-SVRARDI	71.43	73.21	73.21	73.21	69.64	75.00	69.64	71.43	<u>75.00*</u>	71.43
Forêts d'arbres aléatoires										
RFARDI	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21
RF-X	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21
RF-CSF	73.21	73.21	73.21	<u>75.00*</u>	73.21	75.00	73.21	71.43	71.43	73.21
RF-MAF	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21
RF-X-CSF	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21
LLF-CSF	73.21	69.64	73.21	71.43	<u>75.00*</u>	75.00	73.21	73.21	71.43	73.21
ARERT	<u>75.00*</u>	73.21	69.64	67.86	73.21	71.43	73.21	75.00	71.43	73.21
ARDIERT	69.64	73.21	67.86	69.64	<u>64.29</u>	73.21	73.21	73.21	73.21	64.29
EOTB-ERT	64.29	64.29	71.43	62.50	67.86	62.50	69.64	71.43	64.29	69.64
ARRF	69.64	71.43	<u>75.00*</u>	71.43	71.43	73.21	73.21	<u>75.00*</u>	73.21	71.43
ARDIRF	73.21	73.21	71.43	71.43	67.86	73.21	73.21	<u>76.79*</u>	<u>75.00*</u>	62.50
EOTB-MRF	64.29	58.93	71.43	62.50	67.86	62.50	66.07	75.00	66.07	69.64
ERT-MAF	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21
Réseau de neurones										
LSTM-Dense-AR	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21
LSTM-AR	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21
Dense-AR	75.00	71.43	73.21	73.21	73.21	75.00	71.43	73.21	73.21	73.21
LSTM-Dense-ARDI	73.21	73.21	69.64	<u>75.00*</u>	71.43	73.21	73.21	67.86	69.64	69.64
LSTM-ARDI	73.21	73.21	73.21	67.86	<u>75.00*</u>	73.21	73.21	73.21	69.64	71.43
Dense-ARDI	73.21	71.43	69.64	69.64	73.21	66.07	71.43	64.29	71.43	67.86
LSTM-Dense	69.64	67.86	73.21	67.86	71.43	73.21	69.64	67.86	66.07	73.21
LSTM	73.21	<u>75.00*</u>	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21
Dense	67.86	69.64	67.86	62.50	69.64	53.57	69.64	57.14	51.79	58.93
Combinaisons de prévisions										
AVRG	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21
Médiane	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21
T-AVRG,0.1	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21
T-AVRG,0.2	73.21	73.21	73.21	<u>75.00*</u>	73.21	73.21	73.21	73.21	73.21	73.21
IP-AVRG,1	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21
IP-AVRG,0.95	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21	73.21

TABLE 32: IPC - CAN : RCSF

Modèles	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC	82.14**	80.36	78.57	80.36	78.57	82.14**	80.36	78.57	80.36	78.57
ARDI,BIC	83.93***	80.36	76.79	78.57	76.79	85.71***	76.79	76.79	78.57	76.79
Régressions pénalisées										
Ridge	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	78.57	80.36
Lasso	80.36	82.14**	80.36	76.79	80.36	80.36	80.36	80.36	80.36	76.79
Elastic-Net	82.14**	80.36	80.36	80.36	80.36	82.14**	80.36	80.36	80.36	80.36
Adaptive-Lasso	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36
ARDI,Ridge	78.57	78.57	78.57	80.36	80.36	83.93**	80.36**	80.36	80.36	80.36
ARDI,Lasso	78.57	78.57	78.57	75.00	76.79	82.14**	80.36	80.36	80.36	73.21
ARDI,Elastic-Net	80.36	76.79	80.36	75.00	80.36	80.36	80.36**	80.36	80.36	80.36
ARDI,Adaptive-Lasso	80.36	76.79	80.36	76.79	80.36	80.36	80.36	80.36	78.57	78.57
Ridge-MAF	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36
LASSO-MAF	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36
ELAS-MAF	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36
Régressions régularisées par sous-ensembles complets										
T-CSR10	80.36	78.57	78.57	76.79	76.79	78.57	80.36	76.79	76.79	75.00
T-CSR20	80.36	80.36	76.79	80.36	78.57	80.36	80.36	80.36	80.36	80.36
CSR-R10	80.36	80.36	76.79	80.36	76.79	80.36	80.36	78.57	80.36	80.36
CSR-R20	80.36	76.79	73.21	76.79	76.79	78.57	80.36	75.00	76.79	73.21
Régressions à vecteurs de support										
NL-SVRARDI	80.36	80.36	78.57	76.79	76.79	80.36	80.36	76.79	76.79	75.00
L-SVRARDI	73.21	80.36	78.57	71.43	73.21	80.36**	83.93***	75.00	73.21	71.43
Forêts d'arbres aléatoires										
RFARDI	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36
RF-X	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36
RF-CSF	80.36	80.36	80.36	80.36	80.36	80.36	80.36	78.57	75.00	80.36
RF-MAF	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36
RF-X-CSF	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36
LLF-CSF	80.36	78.57	78.57	80.36	80.36	80.36	80.36	80.36	80.36	80.36
ARERT	80.36	82.14**	82.14**	78.57	76.79	82.14**	85.71***	78.57	80.36	75.00
ARDIERT	78.57	82.14**	76.79	78.57	73.21	80.36	83.93***	78.57	75.00	76.79
EOTB-ERT	71.43	67.86	76.79	66.07	82.14***	73.21	71.43	73.21	66.07	75.00
ARRF	82.14**	80.36	80.36	78.57	76.79	82.14**	80.36	78.57	78.57	80.36
ARDIRF	78.57	80.36	76.79	75.00	71.43	83.93***	83.93***	76.79	80.36	76.79
EOTB-MRF	73.21	64.29	71.43	64.29	73.21	75.00	75.00	76.79	60.71	76.79
ERT-MAF	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36
Réseau de neurones										
LSTM-Dense-AR	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36
LSTM-AR	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36
Dense-AR	80.36	80.36	80.36	78.57	80.36	80.36	80.36	80.36	78.57	80.36
LSTM-Dense-ARDI	80.36	80.36	76.79	78.57	75.00	80.36	80.36	71.43	80.36	73.21
LSTM-ARDI	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	73.21
Dense-ARDI	78.57	80.36	78.57	78.57	73.21	80.36	73.21	78.57	78.57	69.64
LSTM-Dense	78.57	80.36	76.79	71.43	69.64	76.79	78.57	82.14	80.36	78.57
LSTM	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36
Dense	67.86	75.00	64.29	69.64	66.07	55.36	41.07**	75.00	69.64	66.07
Combinaisons de prévisions										
AVRG	80.36	80.36	80.36	80.36	78.57	80.36	80.36	80.36	80.36	80.36
Médiane	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36
T-AVRG,0.1	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36
T-AVRG,0.2	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36	80.36
IP-AVRG,1	80.36	80.36	80.36	80.36	78.57	80.36	80.36	80.36	80.36	80.36
IP-AVRG,0.95	80.36	80.36	80.36	80.36	78.57	80.36	80.36	80.36	80.36	80.36

TABLE 33: Production industrielle : RCSF

Modèles	CAN						CAN+US				
	h=1	h=2	h=4	h=6	h=8		h=1	h=2	h=4	h=6	h=8
Modèles de référence											
AR,BIC	69.64**	57.14	64.29	64.29	66.07		69.64**	57.14	64.29	64.29	66.07
ARDI,BIC	73.21***	69.64**	66.07	62.50	66.07		76.79***	69.64**	71.43**	60.71	64.29
Régressions pénalisées											
Ridge	67.86	66.07	64.29	69.64**	64.29		73.21***	69.64*	66.07	64.29	66.07
Lasso	69.64*	69.64*	67.86	66.07	66.07		69.64**	73.21***	64.29	64.29	66.07
Elastic-Net	62.50	66.07	66.07	66.07	66.07		69.64*	66.07	66.07	66.07	66.07
Adaptive-Lasso	75.00***	60.71	64.29	66.07	64.29		75.00***	66.07	66.07	66.07	66.07
ARDI,Ridge	75.00***	66.07	64.29	66.07	66.07		69.64*	67.86	66.07	66.07	66.07
ARDI,Lasso	78.57***	66.07	67.86	66.07	66.07		71.43**	66.07	66.07	66.07	66.07
ARDI,Elastic-Net	67.86	66.07	66.07	66.07	66.07		71.43**	60.71	66.07	66.07	66.07
ARDI,Adaptive-Lasso	69.64*	66.07	67.86**	58.93	60.71		73.21***	64.29	58.93	58.93	62.50
Ridge-MAF	69.64*	66.07	66.07	66.07	66.07		73.21***	66.07	66.07	66.07	66.07
LASSO-MAF	67.86	66.07	71.43**	66.07	66.07		71.43**	62.50	55.36*	64.29	66.07
ELAS-MAF	66.07	66.07	69.64**	64.29	66.07		69.64*	62.50	60.71	66.07	66.07
Régressions régularisées par sous-ensembles complets											
T-CSR10	69.64***	64.29	64.29	60.71	58.93		75.00***	69.64**	73.21***	60.71	57.14
T-CSR20	71.43**	67.86	66.07	66.07	66.07		71.43**	66.07	66.07	66.07	66.07
CSR-R10	69.64**	69.64**	64.29	66.07	66.07		67.86	66.07	66.07	66.07	66.07
CSR-R20	71.43**	67.86	69.64*	64.29	60.71		76.79***	71.43**	66.07	64.29	66.07
Régressions à vecteurs de support											
NL-SVRARDI	69.64**	64.29	66.07	64.29	57.14		71.43***	67.86	69.64*	66.07	60.71
L-SVRARDI	76.79***	66.07	69.64*	66.07	66.07		73.21***	66.07	69.64*	66.07	69.64*
Forêts d'arbres aléatoires											
RFARDI	75.00***	69.64*	62.50	64.29	64.29		75.00***	66.07	67.86	67.86	60.71
RF-X	71.43**	64.29	60.71	66.07	62.50		67.86	64.29	64.29	66.07	66.07
RF-CSF	76.79***	69.64*	58.93	67.86	60.71		69.64*	66.07	51.79	58.93	57.14
RF-MAF	67.86	66.07	53.57	66.07	66.07		69.64*	64.29	55.36	66.07	64.29
RF-X-CSF	67.86	67.86	62.50	66.07	69.64*		69.64*	62.50	60.71	64.29	66.07
LLF-CSF	78.57***	71.43**	66.07	66.07	60.71		73.21***	73.21***	66.07	66.07	58.93
ARERT	73.21***	57.14	60.71	62.50	66.07		73.21***	64.29	58.93	62.50	58.93
ARDIERT	75.00***	62.50	62.50	60.71	69.64**		73.21***	62.50	62.50	58.93	66.07
EOTB-ERT	75.00***	64.29	53.57	62.50	66.07		67.86	58.93	60.71	60.71	64.29
ARRF	73.21***	57.14	60.71	60.71	62.50		67.86*	57.14	60.71	62.50	53.57
ARDIRF	76.79***	71.43**	62.50	66.07	66.07		66.07	62.50	58.93	64.29	57.14
EOTB-MRF	62.50	67.86*	60.71	67.86	53.57**		75.00***	53.57	64.29	58.93	62.50
ERT-MAF	67.86	64.29	53.57	66.07	66.07		67.86	66.07	64.29	69.64**	66.07
Réseau de neurones											
LSTM-Dense-AR	62.50	66.07	66.07	66.07	66.07		62.50	66.07	66.07	66.07	66.07
LSTM-AR	67.86	66.07	66.07	66.07	66.07		67.86	66.07	66.07	66.07	66.07
Dense-AR	71.43**	66.07	62.50	62.50	60.71		71.43**	66.07	62.50	62.50	60.71
LSTM-Dense-ARDI	66.07	66.07	66.07	66.07	66.07		71.43**	66.07	64.29	66.07	66.07
LSTM-ARDI	64.29	60.71	58.93	66.07	66.07		58.93	66.07	66.07	66.07	66.07
Dense-ARDI	67.86	62.50	62.50	66.07	64.29		69.64**	67.86	55.36*	60.71	50.00
LSTM-Dense	64.29	67.86	66.07	71.43**	64.29		73.21***	69.64*	62.50	53.57	66.07
LSTM	71.43**	67.86	66.07	69.64**	66.07		73.21***	67.86	66.07	66.07	62.50
Dense	64.29	60.71	60.71	62.50	62.50		62.50	66.07	64.29	64.29	42.86
Combinaisons de prévisions											
AVRG	73.21***	62.50	66.07	66.07	66.07		76.79***	69.64*	66.07	66.07	66.07
Médiane	71.43**	62.50	66.07	66.07	66.07		69.64*	66.07	66.07	66.07	66.07
T-AVRG,0.1	73.21***	62.50	66.07	66.07	66.07		76.79***	69.64**	66.07	66.07	66.07
T-AVRG,0.2	73.21***	62.50	66.07	66.07	66.07		76.79***	66.07	66.07	66.07	66.07
IP-AVRG,1	73.21***	64.29	66.07	66.07	66.07		76.79***	69.64*	66.07	66.07	66.07
IP-AVRG,0.95	73.21***	64.29	66.07	66.07	66.07		76.79***	71.43**	67.86	66.07	66.07

TABLE 34: Taux de change - USD/CAD : RCSF

Modèles	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC	55.36	39.29*	46.43	44.64	48.21	55.36	39.29*	46.43	44.64	48.21
ARDI,BIC	55.36	41.07	39.29	51.79	33.93**	55.36	51.79	53.57	60.71*	44.64
Régressions pénalisées										
Ridge	53.57	50.00	50.00	50.00	44.64	53.57	48.21	50.00	50.00	33.93**
Lasso	55.36	51.79	50.00	44.64	42.86	51.79	50.00	48.21	51.79	44.64
Elastic-Net	53.57	50.00	50.00	50.00	35.71**	53.57	50.00	50.00	50.00	35.71**
Adaptive-Lasso	48.21	42.86	53.57	58.93	46.43	48.21	41.07	53.57	60.71*	50.00
ARDI,Ridge	48.21	50.00	50.00	50.00	35.71**	53.57	50.00	50.00	50.00	37.50**
ARDI,Lasso	50.00	50.00	51.79	50.00	35.71**	53.57	50.00	50.00	44.64	33.93**
ARDI,Elastic-Net	53.57	50.00	50.00	50.00	35.71**	53.57	50.00	50.00	50.00	35.71**
ARDI,Adaptive-Lasso	51.79	46.43	50.00	48.21	37.50**	44.64	48.21	37.50**	39.29*	37.50*
Ridge-MAF	53.57	48.21	42.86	48.21	48.21	41.07	46.43	42.86	46.43	46.43
LASSO-MAF	46.43	46.43	46.43	46.43	41.07	46.43	46.43	46.43	46.43	44.64
ELAS-MAF	46.43	46.43	46.43	46.43	42.86	46.43	46.43	46.43	46.43	44.64
Régressions régularisées par sous-ensembles complets										
T-CSR10	46.43	46.43	55.36	55.36	50.00	51.79	44.64	57.14	<u>64.29**</u>	44.64
T-CSR20	46.43	55.36	55.36	55.36	46.43	39.29*	50.00	46.43	53.57	46.43
CSR-R10	41.07	44.64	55.36	51.79	48.21	44.64	48.21	51.79	62.50**	44.64
CSR-R20	44.64	41.07	44.64	44.64	37.50**	48.21	41.07	44.64	48.21	35.71**
Régressions à vecteurs de support										
NL-SVRARDI	50.00	50.00	57.14	<u>60.71*</u>	51.79	55.36	46.43	<u>60.71</u>	57.14	42.86
L-SVRARDI	46.43	42.86	55.36	48.21	33.93**	46.43	39.29	53.57	50.00	35.71**
Forêts d'arbres aléatoires										
RFARDI	51.79	50.00	57.14	55.36	39.29	50.00	<u>57.14</u>	55.36	50.00	35.71**
RF-X	51.79	44.64	42.86	44.64	42.86	46.43	53.57	55.36	46.43	46.43
RF-CSF	53.57	55.36	<u>64.29**</u>	35.71**	42.86	48.21	46.43	44.64	48.21	44.64
RF-MAF	50.00	50.00	46.43	37.50*	48.21	53.57	48.21	55.36	46.43	55.36
RF-X-CSF	55.36	46.43	42.86	46.43	48.21	46.43	55.36	55.36	51.79	46.43
LLF-CSF	51.79	53.57	62.50*	51.79	50.00	55.36	53.57	58.93	48.21	44.64
ARERT	57.14	50.00	51.79	44.64	44.64	51.79	46.43	48.21	53.57	48.21
ARDIERT	51.79	44.64	44.64	50.00	48.21	55.36	51.79	44.64	60.71	46.43
EOTB-ERT	51.79	50.00	48.21	35.71**	35.71**	44.64	41.07	46.43	46.43	50.00
ARRF	42.86	42.86	42.86	48.21	50.00	<u>57.14</u>	44.64	50.00	51.79	48.21
ARDIRF	51.79	48.21	42.86	55.36	57.14	44.64	44.64	46.43	53.57	50.00
EOTB-MRF	42.86	42.86	50.00	42.86	35.71**	50.00	44.64	57.14	42.86	44.64
ERT-MAF	53.57	48.21	58.93	39.29	44.64	51.79	46.43	50.00	44.64	<u>57.14</u>
Réseau de neurones										
LSTM-Dense-AR	58.93	44.64	42.86	39.29*	46.43	<u>58.93</u>	44.64	42.86	39.29*	46.43
LSTM-AR	50.00	50.00	51.79	50.00	53.57	50.00	50.00	51.79	50.00	53.57
Dense-AR	48.21	37.50*	57.14	44.64	48.21	48.21	37.50*	57.14	44.64	48.21
LSTM-Dense-ARDI	46.43	48.21	44.64	37.50*	41.07	58.93	51.79	42.86	53.57	50.00
LSTM-ARDI	57.14	51.79	53.57	51.79	44.64	50.00	53.57	50.00	48.21	37.50*
Dense-ARDI	<u>64.29**</u>	48.21	51.79	50.00	48.21	51.79	51.79	41.07	39.29*	53.57
LSTM-Dense	53.57	51.79	50.00	50.00	<u>60.71*</u>	39.29*	48.21	44.64	46.43	57.14
LSTM	53.57	53.57	48.21	42.86	50.00	44.64	42.86	58.93	37.50*	50.00
Dense	41.07	<u>62.50*</u>	44.64	50.00	58.93	50.00	42.86	50.00	57.14	39.29
Combinaisons de prévisions										
AVRG	48.21	37.50*	51.79	46.43	53.57	48.21	44.64	53.57	51.79	42.86
Médiane	50.00	53.57	53.57	48.21	41.07	42.86	46.43	58.93	50.00	<u>35.71**</u>
T-AVRG,0.1	48.21	44.64	50.00	48.21	44.64	48.21	46.43	53.57	51.79	41.07
T-AVRG,0.2	50.00	44.64	48.21	48.21	42.86	44.64	48.21	53.57	51.79	41.07
IP-AVRG,1	48.21	39.29	53.57	48.21	53.57	48.21	44.64	53.57	51.79	42.86
IP-AVRG,0.95	48.21	39.29	53.57	48.21	53.57	48.21	44.64	53.57	51.79	42.86

A Prévisibilité

Le pseudo- R^2 est simplement

$$pseudo - R_{h,j}^2 = 1 - \frac{\sum_t \hat{e}_{t,h,j}^2}{\sum_t (y_{t+h} - \bar{y}_h)^2}, \quad (35)$$

où \bar{y}_h est la moyenne empirique de la cible jusqu'à t . Donc, ceci est proportionnel au ratio de l'EQM du modèle j et l'EQM du modèle prédictif ne contenant que la constante, $y_{t+h} = c + e_{t+h}$. Galbraith (2003) suggère le pseudo- R^2 comme une mesure de prévisibilité d'une variable : si la forme fonctionnelle et l'ensemble d'information, $g(Z_t; \theta)$, n'apportent pas de pouvoir prédictif en termes de l'EQM, c'est-à-dire pseudo- $R^2 < 0$, alors la variable est peu prévisible.

Tableau 35 montre les résultats pour le PIB du Québec. Nous remarquons que les meilleurs modèles de prévisions affichent les pseudo- R^2 bien positifs et significatifs, suggérant que cette cible est prévisible. Par contre, beaucoup de modèles obtiennent les résultats négatifs et ils sont battus par la simple moyenne historique. Ceci n'est pas rare : les agrégats macroéconomiques ne sont pas faciles à prévoir.

Dans le cas du PIB du Canada, les résultats présentés au tableau 36 affichent moins d'entrées négatives que dans le cas québécois, suggérant ainsi qu'en général, le taux de croissance du PIB canadien est plus facile à prévoir. Le constat est semblable pour les mesures d'investissement et le taux de chômage, tel qu'indiqué dans les tableaux 37, 38, 41 et 42.

Deux variables s'avèrent particulièrement difficiles à prévoir puisque la grande majorité des modèles affichent un pseudo- R^2 négatif et les meilleurs modèles n'enregistrent que des petites améliorations par rapport à la prévision avec la moyenne historique. Ce sont les taux de croissance de la consommation et de l'emploi, tel que présentés dans les tableaux 39, 40, 43 et 44. La situation n'est guère meilleure dans le cas des mises en chantier, voir les tableaux 45 et 46.

Les mesures québécoise et canadiennes d'inflation de l'IPC semblent bien prévisible selon le critère du pseudo- R^2 , ainsi que le taux de croissance de la production industrielle canadienne, voir les tableaux 47, 48 et 49. Finalement, comme anticipé, la grande majorité des modèles affichent un pseudo- R^2 proche de zéro dans le cas du taux de change CA/US (tableau 50).

TABLE 35: PIB réel - Québec : Pseudo- R^2

Modèles	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC	-0.20***	-0.31***	-0.12**	0.02*	0.02***	-0.20***	-0.31***	-0.12**	0.02*	0.02***
ARDI,BIC	-0.11	-0.23**	-0.02	-0.01	0.00	-0.03	-0.37**	-0.24	-0.13*	-0.08*
Régressions pénalisées										
Ridge	-0.05***	-0.11***	-0.05**	-0.10	0.03*	-0.04*	-0.10***	-0.10*	0.05	0.01
Lasso	-0.03	-0.09***	-0.07**	0.00	0.04*	-0.08**	-0.01	-0.09***	0.03	0.03
Elastic-Net	-0.05***	-0.08**	-0.05**	-0.01	0.03***	-0.05***	-0.08**	-0.05**	-0.01	0.03***
Adaptive-Lasso	0.02	-0.11**	-0.09**	0.01	0.01	0.04	-0.11	-0.02	0.00	0.02
ARDI,Ridge	-0.05***	-0.08**	-0.05**	-0.01	0.03***	-0.05**	-0.10***	-0.05**	-0.01	0.03***
ARDI,Lasso	-0.05***	-0.08***	-0.05**	-0.01	0.02***	-0.07***	-0.07***	-0.05**	-0.01	0.03***
ARDI,Elastic-Net	-0.05***	-0.08**	-0.05**	-0.01	0.03***	-0.05***	-0.08**	-0.05**	-0.01	0.03***
ARDI,Adaptive-Lasso	0.07	-0.14**	-0.04*	-0.20	0.06*	-0.12	-0.21*	-0.21	0.02	0.05
Ridge-MAF	-0.01	-0.05	0.01	-0.11	0.00	-0.06*	-0.11***	-0.02	-0.11	-0.01
LASSO-MAF	-0.02	-0.13**	-0.02	-0.16*	0.04**	-0.04	-0.02	-0.07	-0.50*	0.01
ELAS-MAF	-0.03**	-0.17***	-0.03**	-0.04	0.03	-0.07**	-0.08**	-0.01	0.05	-0.14
Régressions régularisées par sous-ensembles complets										
T-CSR10	-0.07	-0.22*	-0.06	-0.24	-0.13*	-0.08	-0.36***	-0.03	-0.18	-0.06
T-CSR20	0.10	-0.04	-0.04**	-0.02	-0.01	0.12	-0.01	-0.07**	-0.01	0.02*
CSR-R10	0.07	-0.05	-0.04**	-0.04*	-0.06**	0.11	-0.03	-0.05**	-0.03*	0.03*
CSR-R20	-0.07	-0.14**	-0.06***	0.01	-0.01	-0.18**	-0.30***	<u>0.03</u>	-0.04*	0.02
Régressions à vecteurs de support										
NL-SVRARDI	-0.04	-0.14	-0.04	-0.11	-0.01	-0.06	-0.22**	0.01	-0.09	0.03
L-SVRARDI	-0.04	-0.01	-0.18*	-0.02	-0.17**	-0.16	-0.11	-0.20*	<u>0.10</u>	0.00
Forêts d'arbres aléatoires										
RFARDI	-0.10	-0.15*	-0.23***	-0.11*	-0.12*	-0.15	-0.14	-0.09	-0.08	-0.01
RF-X	-0.07*	-0.02	-0.06	-0.01	0.04	-0.11**	-0.09	-0.04	0.03	0.06
RF-CSF	0.11	0.05	-0.08	0.05	-0.03	0.23	0.00	-0.14	-0.06	-0.18*
RF-MAF	-0.04	-0.02	0.02	0.00	0.03	-0.06	-0.09	-0.10**	-0.03	0.07
RF-X-CSF	-0.05	-0.02	0.00	0.01	0.03	-0.10*	-0.10	-0.05	0.00	0.00
LLF-CSF	0.17	0.03	-0.17	-0.11	-0.09*	0.10	-0.16	-0.31**	-0.17	-0.29***
ARERT	0.38***	<u>0.06</u>	-0.15**	-0.04	-0.09	<u>0.37***</u>	-0.05	-0.02	0.03	-0.12
ARDIERT	0.13**	-0.46**	-0.14	-0.27***	-0.38**	-0.05	-0.40**	-0.18***	-0.39*	0.02
EOTB-ERT	-0.22	-0.38**	-0.23**	-0.47**	-0.17	-0.12	-0.09	-0.57***	-0.30*	-0.27**
ARRF	<u>0.44**</u>	-0.03	-0.15***	-0.04	-0.18**	<u>0.34***</u>	-0.02	-0.33***	-0.05	0.01
ARDIRF	-0.27	-0.15	-0.16	-0.54***	-0.39*	0.10*	-0.15*	-0.19***	-0.43***	-0.47**
EOTB-MRF	-0.02	-0.29**	-0.10	-0.36**	-0.16	0.04	-0.17	-0.31***	-0.47**	-0.06
ERT-MAF	-0.03	-0.01	0.01	-0.02	0.05	-0.01	-0.09	-0.04	0.01	0.05
Réseau de neurones										
LSTM-Dense-AR	-0.04*	-0.01*	0.01	<u>0.06***</u>	<u>0.08***</u>	-0.04*	-0.01*	0.01	0.06***	<u>0.08***</u>
LSTM-AR	-0.07*	-0.02	0.01	<u>0.06***</u>	0.05*	-0.07*	-0.02	0.01	0.06***	0.05*
Dense-AR	0.00	-0.02	-0.16***	0.02	-0.17**	0.00	-0.02	-0.16***	0.02	-0.17**
LSTM-Dense-ARDI	0.08*	-0.11**	0.02	0.06	0.08**	0.04	<u>0.05</u>	-0.10***	0.00	-0.04
LSTM-ARDI	0.10*	-0.02	0.00	0.03	-0.07	-0.08	-0.01	-0.01	0.10**	0.03
Dense-ARDI	0.15	-0.30**	-0.27**	-0.32	-0.03	-0.36*	-0.85**	-0.51**	-0.07	-0.13
LSTM-Dense	0.07	-0.33**	<u>0.09*</u>	0.02	0.06	-0.09	-0.15***	-0.19**	0.03	-0.04
LSTM	-0.19**	-0.06	-0.09	-0.07	-0.21*	-0.04	-0.27**	-0.06	-0.04	-0.06
Dense	-0.07	-0.14***	-0.13**	-0.07	0.02	0.01	-0.07*	-0.15***	0.01	-0.03
Combinaisons de prévisions										
AVRG	0.08	-0.01	-0.01	0.02	0.04	0.08	-0.04	-0.03	0.01	0.05
Médiane	0.04	-0.04	-0.02*	0.02	0.04*	0.02	-0.03	-0.04**	0.04	0.04
T-AVRG,0.1	0.06	-0.03	-0.01	0.02	0.04	0.06	-0.03	-0.04*	0.02	0.04
T-AVRG,0.2	0.05	-0.03	-0.02	0.02	0.04	0.04	-0.03	-0.04**	0.02	0.04
IP-AVRG,1	0.09	-0.02	-0.01	0.02	0.03	0.08	-0.04	-0.03	0.01	0.04
IP-AVRG,0.95	0.09	-0.02	-0.01	0.02	0.03	0.08	-0.05	-0.03	0.01	0.04

Note : Les entrées dans ce tableau représentent le pseudo- R^2 tel que présenté dans l'équation (35). Les étoiles indiquent la significativité du test Diebold-Mariano avec les niveaux de 1, 5 et 10% pour *, ** et *** respectivement.

TABLE 36: PIB réel - Canada : Pseudo- R^2

Modèles	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC	0.20	-0.06	-0.14*	-0.03	0.03	0.20	-0.06	-0.14*	-0.03	0.03
ARDI,BIC	0.44	0.10	0.00	-0.03***	0.03	<u>0.42</u>	0.09	-0.01	-0.01	-0.05
Régressions pénalisées										
Ridge	0.20	-0.05**	-0.03	0.00	0.02	0.17	0.15	-0.07**	0.10*	0.08*
Lasso	0.22	0.04	-0.02	0.07	0.05	0.29	0.15	0.09	0.11	0.05
Elastic-Net	-0.01*	-0.04*	-0.05**	-0.01***	0.03*	-0.27**	-0.04*	-0.05**	-0.01***	0.03*
Adaptive-Lasso	0.24	0.01	-0.03	0.02	0.08	0.28	0.02	-0.02	0.01	0.11
ARDI,Ridge	0.40	-0.07	-0.05**	-0.01***	0.03*	0.15	-0.04*	-0.05**	-0.01***	0.04*
ARDI,Lasso	0.41	-0.04	-0.05**	-0.01***	-0.01	0.30	-0.09	-0.05**	0.02	0.03*
ARDI,Elastic-Net	-0.04**	-0.10**	-0.05**	-0.01***	0.03*	0.01	-0.16*	-0.05**	-0.01***	0.03*
ARDI,Adaptive-Lasso	0.30	0.02	-0.07**	0.02	0.01	0.42	0.03	-0.05	-0.26	0.06
Ridge-MAF	0.17	0.11	0.04	0.05	0.07*	0.13*	0.04	0.00	0.05	0.06
LASSO-MAF	0.15	-0.04	-0.02*	<u>0.15</u>	0.09*	0.28	-0.05*	-0.02*	0.00	0.06*
ELAS-MAF	0.10	-0.04	0.01	0.09	0.09*	0.17	-0.03	-0.02*	0.04**	0.06*
Régressions régularisées par sous-ensembles complets										
T-CSR10	0.32	0.06	0.06	-0.06	-0.01	0.40	0.08	0.07	0.13	0.05
T-CSR20	0.21	-0.01	-0.04*	-0.04***	0.02	0.21*	0.04	-0.05	-0.03**	0.02*
CSR-R10	0.22*	-0.02	-0.02	-0.05***	-0.01	0.27*	0.02	-0.04	-0.04*	0.02*
CSR-R20	0.37	0.08	0.05	-0.02	<u>0.11*</u>	0.34	0.13	-0.05**	-0.01	0.02
Régressions à vecteurs de support										
NL-SVRARDI	0.30	0.05	<u>0.10</u>	0.07	0.05	0.39	0.10	0.14	<u>0.16</u>	0.09
L-SVRARDI	0.41	0.10	0.10	0.01	0.09	0.23	-0.03	-0.19***	-0.03	0.00
Forêts d'arbres aléatoires										
RFARDI	0.14	0.04	-0.04	0.03	0.07	0.18	0.07	0.04	0.10	0.03
RF-X	0.15	0.02	0.04	0.07	0.07	0.15*	0.01	-0.01	0.05	0.08
RF-CSF	0.25	0.06	0.08	0.07	0.02	0.15	0.06	-0.14	0.08	0.09
RF-MAF	0.16	0.11	0.02	0.06	0.04	0.15	0.10	0.00	0.11	0.05
RF-X-CSF	0.12	0.03	0.02	0.06	0.09	0.14*	0.01	-0.01	0.06	0.08
LLF-CSF	0.29	0.02	0.07	0.03	0.03	0.24*	0.11	0.01	0.13	0.06
ARERT	0.32	-0.11	-0.03	-0.01	0.10	0.14	-0.15	-0.12**	-0.02	0.08
ARDIERT	0.44	0.02	-0.14	-0.17***	-0.08*	0.34	-0.07	0.00	-0.24***	0.09
EOTB-ERT	0.23	-0.03	0.07	0.03	-0.04	0.29	0.00	-0.11**	-0.12	-0.13
ARRF	0.05	-0.04	-0.18***	-0.08**	0.02	0.08	-0.04	-0.21**	-0.04	<u>0.15</u>
ARDIRF	<u>0.50</u>	<u>0.19</u>	-0.24*	-0.18**	-0.06	0.37	-0.17	0.00	-0.16***	-0.03
EOTB-MRF	0.29	0.03	-0.09	0.00	-0.21***	0.29	0.00	-0.01	0.03	-0.07
ERT-MAF	0.19	0.07	-0.01	0.06	0.08	0.15	0.04	0.00	0.06	0.10
Réseau de neurones										
LSTM-Dense-AR	-0.03	-0.01	0.00	0.05	0.06	-0.03	-0.01	0.00	0.05	0.06
LSTM-AR	0.06	-0.04**	0.00	0.03	0.07	0.06	-0.04**	0.00	0.03	0.07
Dense-AR	0.09	0.00	-0.04	-0.05	0.05	0.09	0.00	-0.04	-0.05	0.05
LSTM-Dense-ARDI	0.02	-0.01	0.03	0.02	0.08	0.19	0.00	0.00	-0.01	0.07
LSTM-ARDI	0.04	-0.01	0.02	-0.02	-0.10	0.04	0.06	0.06	0.07	0.05
Dense-ARDI	0.20	0.11	-0.13**	0.09	-0.07	0.08	<u>0.16</u>	-0.36*	-0.28*	-0.16
LSTM-Dense	-0.21	-0.16*	0.00	-0.37**	-0.09	0.25	-0.08	0.00	0.00	-0.19
LSTM	-0.02	-0.17***	-0.04	0.04	0.06	0.15	-0.03	<u>0.17</u>	0.02	0.02
Dense	-0.12	0.01	-0.22	-0.96	-0.84*	-3.31**	-1.10	-0.50	-5.67**	-0.01
Combinaisons de prévisions										
AVRG	0.30	0.08	0.05	0.05	0.08	0.32	0.10	0.04	0.07	0.09
Médiane	0.23	0.05	0.02	0.04	0.07	0.27	0.08	0.01	0.05	0.07
T-AVRG,0.1	0.28	0.06	0.03	0.05	0.07	0.30	0.09	0.02	0.06	0.08
T-AVRG,0.2	0.26	0.05	0.02	0.04	0.07	0.28	0.09	0.02	0.05	0.08
IP-AVRG,1	0.31	0.08	0.05	0.04	0.07	0.31	0.10	0.03	0.06	0.09
IP-AVRG,0.95	0.31	0.08	0.05	0.04	0.07	0.31	0.10	0.03	0.06	0.09

TABLE 37: Investissement réel - Québec : Pseudo- R^2

Modèles	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC	0.07	-0.13*	-0.13**	-0.04	0.00	0.07	-0.13*	-0.13**	-0.04	0.00
ARDI,BIC	0.22**	0.01	-0.14*	0.01	-0.02	-0.10	-0.10	-0.15*	-0.05	-0.02
Régressions pénalisées										
Ridge	-0.02	-0.02	-0.06*	0.02*	0.03**	-0.08	-0.02	-0.03	0.04	0.04**
Lasso	0.09	-0.02	0.00	0.07	0.03	-0.09**	0.00	-0.01	-0.06	0.06
Elastic-Net	-0.02	-0.05**	-0.02*	0.02*	0.02**	-0.02	-0.05**	-0.02*	0.02*	0.02**
Adaptive-Lasso	0.14**	0.00	-0.07*	0.00	0.02	0.11*	-0.05	-0.01	0.06	0.03
ARDI,Ridge	0.04	-0.05**	-0.03*	0.01	0.02**	-0.40	-0.05**	-0.02*	0.01	0.02*
ARDI,Lasso	0.01	-0.05**	-0.02	0.03*	0.02**	-0.44*	-0.05**	-0.03**	0.02	0.02**
ARDI,Elastic-Net	-0.05	-0.05**	-0.02*	0.02*	0.02**	-0.12*	-0.05**	-0.02*	0.02*	0.02**
ARDI,Adaptive-Lasso	0.15**	-0.10***	-0.02**	0.03	-0.01	0.13**	-0.08***	0.01	0.01	-0.03*
Ridge-MAF	0.00	0.01	0.02	0.06*	<u>0.06**</u>	-0.01	0.00	0.02	0.05**	0.04
LASSO-MAF	-0.02*	-0.03**	0.01	0.05**	-0.05	-0.02	-0.02*	0.01**	0.05**	-0.01
ELAS-MAF	-0.03*	-0.03*	-0.03	0.05**	0.01	-0.02	-0.03	0.01**	0.05**	-0.06
Régressions régularisées par sous-ensembles complets										
T-CSR10	0.25*	-0.10	-0.09	-0.22*	-0.21	0.20*	-0.17*	-0.18*	-0.14	-0.28*
T-CSR20	0.15**	-0.04*	-0.03	0.05	0.02	0.08	-0.01	-0.03	0.04	-0.01
CSR-R10	0.17*	-0.06	-0.06**	0.03	0.03	0.06	-0.04	-0.04	0.04	-0.03
CSR-R20	0.10	-0.01	-0.01	0.03	0.02	-0.11	-0.15	-0.05	0.02	0.01
Régressions à vecteurs de support										
NL-SVRARDI	0.28**	-0.02	-0.05	-0.05	-0.10	0.21**	-0.07	-0.09	0.00	-0.11
L-SVRARDI	0.12	0.00	-0.16***	-0.15**	-0.08**	-0.05	-0.20	-0.24	-0.08	-0.11*
Forêts d'arbres aléatoires										
RFARDI	0.21***	0.01	-0.03	-0.08	-0.17*	0.16**	<u>0.04</u>	-0.01	-0.01	-0.02
RF-X	0.03	-0.01	-0.01	-0.01	0.02	0.05	-0.03	-0.03	-0.03	-0.02
RF-CSF	0.20**	0.06	0.02	0.08	-0.06	0.27**	0.03	-0.06	-0.17*	-0.21**
RF-MAF	0.03	0.00	0.02	-0.01	0.05	0.08	0.01	-0.05*	-0.04	0.02
RF-X-CSF	0.02	0.00	0.00	0.00	0.00	0.05	-0.02	-0.05	-0.04	-0.02
LLF-CSF	0.12	-0.09	<u>0.05</u>	0.15	-0.03	0.25**	0.04	-0.02	-0.18**	-0.19**
ARERT	<u>0.52***</u>	<u>0.12*</u>	-0.22*	0.07	-0.11*	<u>0.64***</u>	-0.02	-0.08	0.01	-0.17***
ARDIERT	0.40***	-0.10	-0.16	-0.56**	-0.24*	0.47***	-0.06	-0.15*	-0.04	-0.15**
EOTB-ERT	0.05	-0.14*	-0.16*	-0.25**	-0.26	0.27**	-0.06	-0.21**	-0.44**	-0.32***
ARRF	0.45***	0.06*	-0.07	-0.14*	-0.14***	0.61***	0.03	-0.10	-0.08	-0.10*
ARDIRF	0.27*	-0.12	-0.17*	-0.20	-0.25**	0.52***	-0.01	-0.09	-0.21	-0.07
EOTB-MRF	-0.01	-0.10	-0.14	-0.31***	-0.12	0.14	-0.05	-0.20***	-0.50**	-0.23**
ERT-MAF	0.01	0.01	0.00	0.03	0.05*	0.03	-0.01	-0.08**	-0.01	0.02
Réseau de neurones										
LSTM-Dense-AR	0.08	0.01	-0.03	0.05*	0.04*	0.08	0.01	-0.03	0.05*	0.04*
LSTM-AR	-0.01	0.00	0.03	0.03	0.05**	-0.01	0.00	0.03	0.03	0.05**
Dense-AR	0.02	-0.25***	-0.13***	0.06*	0.02	0.02	-0.25***	-0.13***	0.06*	0.02
LSTM-Dense-ARDI	0.03	-0.02	0.01	0.03	0.04	0.11**	-0.03	<u>0.04</u>	-0.01	0.05**
LSTM-ARDI	-0.02	0.01	0.03**	-0.03	-0.02	-0.16**	-0.04	0.02*	0.07**	0.04
Dense-ARDI	-0.05	-0.34***	-0.15**	-0.06	-0.37*	-0.10	-0.28**	-0.04	-0.07	-0.09
LSTM-Dense	0.06	-0.22	-0.05	-0.19	-0.17*	-1.04***	-0.55***	-0.61*	<u>0.08</u>	0.09
LSTM	-0.02	-0.04**	-0.15	<u>0.18*</u>	-0.20**	-0.16	0.00	-0.08	-0.01	<u>0.10*</u>
Dense	-0.78	-0.47***	-0.55**	-1.77**	-0.38*	-2.41*	-2.54**	-0.94***	-1.35**	-0.94**
Combinaisons de prévisions										
AVRG	0.21***	0.03	0.02	0.05	0.02	0.17***	0.04	0.02	0.03	0.02
Médiane	0.15**	0.00	0.00	0.05*	0.02	0.13***	0.01	0.01	0.03	0.01
T-AVRG,0.1	0.19***	0.02	0.01	0.05	0.02	0.16***	0.01	0.01	0.03	0.02
T-AVRG,0.2	0.17***	0.01	0.01	0.05	0.02	0.14***	0.01	0.01	0.03	0.02
IP-AVRG,1	0.22***	0.02	0.02	0.06	0.02	0.23***	0.02	0.01	0.03	0.02
IP-AVRG,0.95	0.22***	0.02	0.02	0.06	0.02	0.23***	0.01	0.01	0.03	0.02

TABLE 38: Investissement réel - Canada : Pseudo- R^2

Modèles	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC	0.18*	-0.04	-0.04	-0.01	0.00	0.18*	-0.04	-0.04	-0.01	0.00
ARDI,BIC	0.17**	-0.05	-0.02	-0.03*	-0.10	0.22	-0.41	-0.15*	-0.05	-0.16
Régressions pénalisées										
Ridge	0.00	-0.02	-0.02	0.00	0.00	0.02	-0.03	-0.02	0.02	0.01
Lasso	0.13***	-0.03	-0.02	-0.01	0.02	0.07*	-0.03	-0.07*	-0.02	-0.03
Elastic-Net	0.00	-0.01	-0.02	0.00	0.00	0.00	-0.01	-0.02	0.00	0.00
Adaptive-Lasso	0.13*	-0.09*	-0.13***	-0.05**	-0.04*	0.11	-0.18	-0.16*	-0.06*	-0.05*
ARDI,Ridge	0.07	-0.01	-0.02	-0.01	0.00	0.07	-0.10*	-0.02	-0.01	0.00
ARDI,Lasso	0.07	-0.01	-0.02	0.00	0.01	0.04**	-0.02	-0.04*	-0.01	-0.01
ARDI,Elastic-Net	0.00	-0.01	-0.02	0.00	0.00	0.00	-0.01	-0.02	0.00	0.00
ARDI,Adaptive-Lasso	0.20**	-0.04*	-0.01	-0.01	-0.04	0.28*	-0.25	-0.23	-0.07*	-0.07
Ridge-MAF	0.05	-0.02	-0.04	-0.01	-0.01	0.02	-0.03	-0.03	-0.01	0.00
LASSO-MAF	-0.01	-0.02	-0.02	-0.01	-0.04*	-0.02	-0.02	-0.02	-0.01	-0.04*
ELAS-MAF	-0.01	-0.02	-0.02	-0.01	0.00	-0.01	-0.02	-0.02	-0.01	0.00
Régressions régularisées par sous-ensembles complets										
T-CSR10	0.37*	0.01	-0.08	-0.19***	-0.12**	0.54*	-0.01	-0.17	-0.19	-0.12
T-CSR20	0.11	-0.02	-0.06	-0.01	0.00	0.13*	0.02	-0.06	-0.01*	-0.02*
CSR-R10	0.09	-0.01	-0.09*	-0.01	0.00	0.10	0.02	-0.07	-0.01	-0.04**
CSR-R20	0.26**	-0.03	-0.02	-0.02	-0.05	0.24*	-0.26**	-0.13**	-0.15**	-0.15*
Régressions à vecteurs de support										
NL-SVRARDI	0.32**	0.02	-0.04	-0.08**	-0.07	0.45*	0.00	-0.11	-0.10	-0.05
L-SVRARDI	0.29*	-0.06*	-0.12**	-0.04	-0.04	0.31*	0.02	-0.02	-0.09	-0.06
Forêts d'arbres aléatoires										
RFARDI	0.25*	-0.06	-0.19**	-0.08**	-0.12***	0.22	-0.05	-0.15	-0.07	-0.14**
RF-X	0.02	-0.05	-0.12**	-0.04*	-0.03*	0.00	-0.08**	-0.09**	-0.03	-0.02
RF-CSF	0.11	-0.13	-0.20*	-0.15**	-0.12***	0.14	-0.14**	-0.40**	-0.10**	-0.04*
RF-MAF	0.06	-0.04	-0.12	-0.06	-0.01	0.06	-0.04	-0.13*	-0.06**	0.00
RF-X-CSF	0.02	-0.06	-0.15**	-0.06*	-0.02	0.03	-0.07**	-0.09**	-0.05*	-0.02
LLF-CSF	0.18	-0.14	-0.15	-0.16	-0.13	0.23*	-0.10	-0.24**	-0.11***	-0.03
ARERT	0.12*	-0.05	-0.29	-0.02	-0.09*	0.22**	0.02	-0.34*	-0.10***	0.03
ARDIERT	-0.01	-0.09	-0.36	-0.10*	-0.23**	0.13	-0.21	-0.14*	-0.09*	-0.05*
EOTB-ERT	-0.04	-0.11	-0.01	-0.15	-0.33**	0.05	-0.06*	-0.32***	-0.23***	-0.29***
ARRF	0.14*	-0.14	-0.64*	-0.05	0.00	0.17*	-0.03	-0.62*	-0.04*	0.06
ARDIRF	-0.22	-0.17	-0.27	-0.12*	-0.21**	-0.14	-0.36	-0.61**	-0.08*	-0.24
EOTB-MRF	0.03	-0.20	-0.38	-0.36	-0.28***	0.05	-0.03	-0.14**	-0.37***	-0.15**
ERT-MAF	0.07	-0.01	-0.11	-0.04	-0.02	0.04	-0.04	-0.09*	-0.07**	-0.04*
Réseau de neurones										
LSTM-Dense-AR	0.20**	-0.01	0.00	-0.01	0.03*	0.20**	-0.01	0.00	-0.01	0.03*
LSTM-AR	0.15*	-0.03	-0.01	0.01	0.01	0.15*	-0.03	-0.01	0.01	0.01
Dense-AR	0.09	-0.05	-0.03	-0.06	0.02	0.09	-0.05	-0.03	-0.06	0.02
LSTM-Dense-ARDI	0.14	-0.03	-0.05	-0.02	0.02	0.09	-0.03	-0.06	-0.03	-0.09
LSTM-ARDI	0.09	-0.03	0.01	-0.05	-0.04	0.00	0.02	-0.15*	-0.08	-0.06
Dense-ARDI	0.11	-0.43*	-0.15***	-0.27**	-0.08	-0.18*	-0.34	-0.08**	-0.50*	-0.54***
LSTM-Dense	-0.56	-0.34*	-0.48**	-0.18	-0.18*	0.04	-0.08	-0.11*	0.03*	-0.03
LSTM	0.09	-0.10	0.05	0.01	0.00	0.00	0.00	0.03	0.01	0.00
Dense	-0.66*	-1.06***	-0.25*	-0.39*	-0.86***	-0.03	-0.07**	0.02	0.02	0.01
Combinaisons de prévisions										
AVRG	0.18**	-0.02	-0.01	-0.02	-0.01	0.18**	-0.02	-0.05**	-0.04	0.00
Médiane	0.16**	-0.02	-0.02	-0.01	0.00	0.15**	-0.03	-0.03*	-0.02*	0.00
T-AVRG,0.1	0.17**	-0.02	-0.02	-0.02	0.00	0.15**	-0.02	-0.05*	-0.03*	0.00
T-AVRG,0.2	0.16**	-0.02	-0.03	-0.01	0.00	0.14**	-0.02	-0.04*	-0.02*	0.00
IP-AVRG,1	0.18**	-0.02	-0.03	-0.02	-0.01	0.20**	-0.03	-0.06**	-0.03	0.00
IP-AVRG,0.95	0.17**	-0.02	-0.03	-0.02	-0.01	0.20**	-0.03	-0.06**	-0.03	0.00

TABLE 39: Consommation réelle - Québec : Pseudo- R^2

Modèles	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC	-0.04	-0.05	-0.04	-0.02	0.00	-0.04	-0.05	-0.04	-0.02	0.00
ARDI,BIC	-0.16*	-0.01	-0.05*	-0.06**	-0.02**	-0.16*	-0.06	-0.09**	-0.06*	-0.04**
Régressions pénalisées										
Ridge	-0.34**	0.00	-0.02	0.00	0.01	-0.53	0.00	-0.01	0.00	0.01
Lasso	-0.52	0.00	-0.02	0.00	0.01	-0.50	-0.08*	-0.06	0.00	0.01
Elastic-Net	-0.85**	0.00	-0.02	0.00	0.01	-0.08	0.00	-0.02	0.00	0.01
Adaptive-Lasso	-0.03	-0.10	-0.08*	-0.10**	-0.01	-0.03	-0.08	0.00	-0.04	0.00
ARDI,Ridge	-0.28*	0.00	-0.02	0.00	0.01	0.00	0.00	-0.02	0.00	0.01
ARDI,Lasso	<u>0.12</u>	0.02	-0.02	0.00	0.01	-0.01	0.00	-0.02	0.00	0.01
ARDI,Elastic-Net	-0.04	0.00	-0.02	0.00	0.01	0.00	0.00	-0.02	0.00	0.01
ARDI,Adaptive-Lasso	-0.23*	-0.03	-0.17*	-0.02	0.01	-0.23*	-0.08	0.01	-0.01	0.06
Ridge-MAF	-0.03	-0.05**	-0.06*	-0.04	-0.01	0.00	-0.02	-0.03**	-0.02	-0.01
LASSO-MAF	-0.03	0.00	-0.01	-0.06	0.01	0.01	0.00	-0.01	-0.15	0.01
ELAS-MAF	0.01	-0.01	-0.01	-0.05	0.01	0.01	0.00	-0.01	0.00	0.01
Régressions régularisées par sous-ensembles complets										
T-CSR10	-0.38**	-0.37**	-0.44**	-0.80***	-0.65***	-0.30**	-0.15	-0.38**	-0.82**	-0.41***
T-CSR20	-0.01	-0.12	0.00	-0.05**	0.01	<u>0.03</u>	-0.04	-0.01	-0.02	0.01
CSR-R10	0.00	-0.18	0.02	-0.04**	-0.01	0.03	-0.06	0.00	-0.03	-0.02
CSR-R20	0.00	0.00	-0.01	0.00	-0.06	-0.15*	-0.24	-0.01	-0.01	<u>0.07</u>
Régressions à vecteurs de support										
NL-SVRARDI	-0.16*	-0.14	-0.19*	-0.44***	-0.26**	-0.20**	-0.05	-0.20*	-0.41**	-0.15*
L-SVRARDI	-0.10	-0.30	-0.17*	-0.04*	-0.19**	-0.69*	-0.42*	-0.08	-0.03	-0.03
Forêts d'arbres aléatoires										
RFARDI	-0.01	-0.03	-0.07	-0.14**	-0.12*	-0.06	0.02	<u>0.03</u>	-0.06	-0.03
RF-X	-0.06	-0.07	-0.07	0.00	-0.01	-0.03	-0.04	-0.03	-0.03	-0.05
RF-CSF	-0.17	-0.11	-0.20*	-0.05	-0.21**	-0.19**	-0.17**	-0.14*	-0.15**	-0.19**
RF-MAF	-0.02	-0.07	-0.15*	-0.06	-0.09	-0.06	-0.08*	-0.06	-0.09**	-0.07
RF-X-CSF	-0.06	-0.10*	-0.11	-0.03	-0.03	-0.01	-0.06	-0.06*	-0.04*	-0.03
LLF-CSF	-0.13	-1.16*	-0.13	-0.22*	-0.04	-0.09*	-0.09**	-0.15**	-0.26***	-0.28***
ARERT	0.04	-0.02	-0.14**	-0.04	-0.28***	-0.14**	-0.02	-0.24***	-0.03	-0.31**
ARDIERT	-1.79**	-0.33**	-0.81**	-1.26*	-1.00**	-0.54**	0.01	-0.48***	-0.23**	-0.48**
EOTB-ERT	-0.23***	-0.15*	-0.13*	-0.25**	-0.24**	-0.33**	-0.22**	-0.14*	-0.21**	-0.17**
ARRF	-0.11	-0.06	-0.32***	0.00	-0.26**	-0.08	-0.05	-0.17**	-0.11*	-0.29**
ARDIRF	-2.33*	-0.03	-0.58**	-0.60*	-0.79**	-0.30**	-0.10	-0.64*	<u>0.01</u>	-2.89*
EOTB-MRF	-0.32**	-0.30***	-0.48*	-0.09	-0.30*	-0.25**	-0.21**	-0.05	-0.20**	-0.22***
ERT-MAF	-0.07	-0.05	-0.10	-0.04	-0.04	0.02	-0.06*	-0.08*	-0.03	-0.02
Réseau de neurones										
LSTM-Dense-AR	0.01	0.00	-0.01	-0.01	0.02	0.01	0.00	-0.01	-0.01	0.02
LSTM-AR	0.03	0.01	-0.01	-0.01	0.00	0.03	0.01	-0.01	-0.01	0.00
Dense-AR	0.03	<u>0.05</u>	-0.07	-0.02	0.02	0.03	<u>0.05</u>	-0.07	-0.02	0.02
LSTM-Dense-ARDI	0.03	-0.01	<u>0.03</u>	-0.01	-0.01	-0.16*	-0.04	0.01	0.00	-0.07
LSTM-ARDI	-0.11*	-0.08**	-0.06**	-0.06	-0.01	0.00	-0.01	-0.01	-0.02	-0.05
Dense-ARDI	-0.01	0.00	-0.01	<u>0.04</u>	-0.24	-0.06	-0.44	-0.86**	0.00	-0.27***
LSTM-Dense	-0.12***	-0.47*	0.03	0.04	-0.08	-0.48	-0.05	-0.09	-0.01	0.03
LSTM	0.02	-0.36**	-0.23**	-0.29*	-0.01	-0.11	-0.11**	-0.04	-0.06	0.00
Dense	-0.01	0.02	0.03	-0.13**	<u>0.05</u>	-0.04	0.01	-0.03	-0.01	-0.10
Combinaisons de prévisions										
AVRG	-0.01	0.01	-0.02	-0.03	-0.01	0.00	0.01	-0.02	-0.02	-0.02
Médiane	0.00	0.02	-0.01	-0.01	0.01	0.01	0.00	-0.02	-0.01	0.01
T-AVRG,0.1	0.01	0.02	-0.03	-0.01	0.00	0.00	0.01	-0.02	-0.02	0.00
T-AVRG,0.2	0.00	0.01	-0.02	-0.01	0.00	0.00	0.00	-0.02	-0.01	0.00
IP-AVRG,1	0.01	0.01	-0.02	-0.03	-0.01	0.00	0.01	-0.02	-0.02	-0.01
IP-AVRG,0.95	0.01	0.02	-0.02	-0.03	-0.01	0.00	0.01	-0.02	-0.02	-0.01

TABLE 40: Consommation réelle - Canada : Pseudo- R^2

Modèles	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC	0.00	0.00	-0.06	0.00	-0.03	0.00	0.00	-0.06	0.00	-0.03
ARDI,BIC	-0.34**	-0.29	-0.09*	-0.04	0.00	-0.38**	-0.53	-0.16	-0.06	-0.01
Régressions pénalisées										
Ridge	-0.24*	-0.01	-0.01	0.00	0.01	-0.72	0.01	-0.01	0.00	0.00
Lasso	-0.63	-0.01	-0.01	0.00	0.01	-0.41	-0.10	-0.17	-0.04	0.02
Elastic-Net	-0.81*	0.01	-0.01	0.00	0.01	-0.04	0.01	-0.01	0.00	0.01
Adaptive-Lasso	0.08	-0.10	-0.15	-0.09	-0.04	0.09	-0.14	-0.14	-0.02	0.01
ARDI,Ridge	-0.47	0.01	-0.01	0.00	0.01	0.02	0.00	-0.01	0.00	0.01
ARDI,Lasso	-0.01	0.01	-0.01	0.00	0.01	0.01	0.01	-0.01	0.00	0.01
ARDI,Elastic-Net	0.00	0.01	-0.01	0.00	0.01	0.02	0.01	-0.01	0.00	0.01
ARDI,Adaptive-Lasso	0.00	0.00	-0.08	0.00	0.01	-0.30	-0.16	-0.47	-0.03	0.00
Ridge-MAF	0.01	-0.03	-0.04	-0.05	0.02	0.01	-0.04	-0.04	-0.05***	-0.01
LASSO-MAF	-0.03	-0.04	-0.01	-0.06	-0.01	0.04	-0.01	-0.04	-0.01*	-0.01
ELAS-MAF	0.07	-0.01	-0.03	-0.03	0.04	0.02	-0.01	-0.16**	-0.01*	-0.01
Régressions régularisées par sous-ensembles complets										
T-CSR10	-0.27	-0.24	-0.58***	-0.83***	-0.65**	-0.23	-0.18	-0.31**	-0.73***	-0.37**
T-CSR20	<u>0.12***</u>	-0.33*	<u>0.01</u>	-0.01	0.00	0.11**	0.04	-0.01	-0.02	0.01
CSR-R10	0.12*	-0.55**	-0.01	-0.02	-0.02	<u>0.13**</u>	0.04	-0.01	-0.02	-0.01
CSR-R20	0.05	-0.03	-0.01	<u>0.05**</u>	-0.01	-0.27	-0.13	-0.01	-0.01	-0.04
Régressions à vecteurs de support										
NL-SVRARDI	-0.08	-0.19	-0.29***	-0.41***	-0.29*	-0.07	-0.13	-0.19	-0.32**	-0.20**
L-SVRARDI	-0.42	-0.32	-0.07	-0.03	-0.20*	-0.51*	-0.29*	-0.01	-0.07*	<u>0.04*</u>
Forêts d'arbres aléatoires										
RFARDI	-0.18	-0.24	-0.15	-0.21*	-0.16	-0.15	-0.15	-0.08	-0.20**	-0.12
RF-X	-0.02	-0.10	-0.06	-0.06	-0.07	-0.04	-0.19*	-0.17*	-0.17***	-0.11*
RF-CSF	-0.02	-0.29	-0.08	-0.24	-0.13	-0.30	-0.31	-0.24*	-0.10	-0.12
RF-MAF	-0.09	-0.09	-0.12*	-0.17**	-0.11	-0.09	-0.15	-0.16**	-0.37***	-0.20*
RF-X-CSF	0.02	-0.11	-0.09	-0.07	-0.09	-0.05	-0.15	-0.16**	-0.16***	-0.09**
LLF-CSF	-0.25	-0.34	-0.10	-0.20*	-0.11	-0.43	-0.34	-0.20	-0.15*	-0.19**
ARERT	-0.20*	-0.23	-0.17**	-0.32***	-0.09**	0.05	-0.24	-0.10	-0.38***	-0.10
ARDIERT	-1.69*	-0.21*	-0.47	-0.31*	-0.61*	-0.52*	-0.10	-0.35**	-0.32**	-0.26
EOTB-ERT	-0.11	-0.41	0.01	-0.23	-0.04	-0.17	-0.35*	-0.24	-0.03	-0.10
ARRF	-0.26	-0.10	-0.28**	-0.66**	-0.09	-0.17	-0.18	-0.31**	-0.84**	-0.15*
ARDIRF	-2.17*	-0.06	-0.60**	-0.43**	-0.47	-0.43*	-0.06	-0.57**	-0.35*	-0.27
EOTB-MRF	-0.19*	-0.32*	-0.08	-0.10	-0.18**	-0.15	-0.07	-0.10	-0.13	-0.38**
ERT-MAF	0.00	-0.16	-0.10*	-0.07	0.00	-0.08	-0.11	-0.13*	-0.16***	-0.01
Réseau de neurones										
LSTM-Dense-AR	0.04**	0.00	0.01	-0.01	0.00	0.04**	0.00	<u>0.01</u>	-0.01	0.00
LSTM-AR	0.00	-0.06	-0.03*	-0.02	-0.01	0.00	-0.06	-0.03*	-0.02	-0.01
Dense-AR	-0.21	-0.02	-0.05	-0.06	0.04	-0.21	-0.02	-0.05	-0.06	0.04
LSTM-Dense-ARDI	-0.02	<u>0.05*</u>	-0.04**	0.01	-0.04	0.04	0.00	-0.06	-0.10*	0.01
LSTM-ARDI	-0.05	0.05	-0.17*	-0.10**	-0.15**	0.00	-0.03	-0.04	-0.11	-0.10*
Dense-ARDI	-0.27	-0.63*	-0.06	-0.03	<u>0.14*</u>	0.06	0.01	-0.08	-0.34*	-0.49*
LSTM-Dense	-0.08*	-0.02	-0.07	-0.23*	-0.05	-0.14	<u>0.06</u>	-0.76	<u>0.05</u>	0.01
LSTM	0.11	-0.19**	-0.01	-0.03*	-0.03	0.05	-0.15	-0.69***	-0.26**	0.03
Dense	0.01	0.02	0.01	-0.04	-0.01	-3.74***	-1.72**	-0.11	-2.79**	-7.72*
Combinaisons de prévisions										
AVRG	0.04	-0.01	-0.03	-0.01	0.02	0.07	-0.01	-0.06	-0.04*	0.01
Médiane	0.04	-0.01	-0.01	-0.01	0.01	0.01	-0.03	-0.02	-0.01	0.01
T-AVRG,0.1	0.05	-0.01	-0.02	-0.02	0.02	0.04	-0.01	-0.05	-0.04*	0.02
T-AVRG,0.2	0.05	-0.01	-0.02	-0.02	0.02	0.03	-0.02	-0.04	-0.03*	0.02
IP-AVRG,1	0.05	-0.01	-0.03	-0.02	0.01	0.05	-0.01	-0.06	-0.04	0.00
IP-AVRG,0.95	0.05	-0.01	-0.03	-0.02	0.02	0.05	-0.01	-0.06	-0.04	0.00

TABLE 41: Taux de chômage - Québec : Pseudo- R^2

Modèles	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC	0.02	-0.04	-0.03	-0.12*	-0.03	0.02	-0.04	-0.03	-0.12*	-0.03
ARDI,BIC	-0.08	-0.01	-0.06*	-0.01	0.03	-0.39*	-0.12	-0.12*	-0.15	-0.02
Régressions pénalisées										
Ridge	0.06	-0.03	-0.01	-0.01	0.01	0.02	0.07	0.00	-0.02	0.01
Lasso	<u>0.19**</u>	0.02	0.00	-0.01	0.01	<u>0.24*</u>	0.09	0.01	0.03	0.03
Elastic-Net	0.01	0.01	0.00	-0.01	0.01	0.23	0.01	0.00	-0.01	0.01
Adaptive-Lasso	0.17*	0.02	-0.07*	-0.06*	-0.05	0.18*	0.04	-0.04	-0.04	-0.06*
ARDI,Ridge	0.10	-0.12	0.00	-0.01	0.01	0.02	0.03	-0.03	-0.01	0.01
ARDI,Lasso	0.14	-0.02	0.00	-0.01	-0.05	0.08	-0.11	0.00	-0.01	0.02
ARDI,Elastic-Net	0.03	-0.18*	0.00	-0.01	0.01	0.01	-0.07	0.00	-0.01	0.01
ARDI,Adaptive-Lasso	0.12	0.03	-0.14	-0.01	0.01	-0.12	-0.04	-2.29	-0.05	0.01
Ridge-MAF	0.11*	0.04	-0.01	0.01	0.01	0.06**	0.03	-0.01	-0.01	0.01
LASSO-MAF	0.01	0.01	0.00	-0.04*	0.00	-0.01	0.01	0.00	-0.01**	0.00
ELAS-MAF	0.02	0.01	<u>0.03</u>	-0.02	-0.05	0.02	0.01	0.00	-0.01**	0.00
Régressions régularisées par sous-ensembles complets										
T-CSR10	-0.03	0.04	-0.32***	-0.34*	-0.66***	0.12	0.09	-0.12	-1.49*	-0.48***
T-CSR20	-0.02	0.00	-0.05	-0.10*	-0.01	0.01	-0.01	0.00	-0.05*	-0.02
CSR-R10	0.04	-0.02	-0.09*	-0.17**	-0.04*	0.09	-0.01	<u>0.03</u>	-0.05**	-0.03*
CSR-R20	0.14	-0.09	-0.03	-0.01	-0.05	0.06	-0.24*	-0.06	<u>0.04</u>	0.02
Régressions à vecteurs de support										
NL-SVRARDI	0.07	<u>0.12</u>	-0.15***	-0.18*	-0.29**	0.19	0.11	-0.06	-0.39	-0.19*
L-SVRARDI	-0.20	-0.17**	-0.26*	-0.08	<u>0.04</u>	0.11	0.08	-0.34*	-0.16**	-0.01
Forêts d'arbres aléatoires										
RFARDI	-0.05	-0.05	-0.25***	-0.18**	-0.10	-0.06	-0.04	-0.27***	-0.20*	-0.11
RF-X	0.10	0.00	-0.08	-0.02	-0.03	0.02	-0.02	-0.07*	-0.03	-0.02
RF-CSF	0.06	0.01	-0.13	-0.09	0.00	-0.05	-0.03	-0.16**	-0.03	0.02
RF-MAF	0.11	0.04	-0.06	0.00	-0.08	0.10	0.06	-0.05	0.03	-0.02
RF-X-CSF	0.05	-0.03	-0.01	-0.01	0.00	0.05	-0.01	-0.06	-0.02	-0.02
LLF-CSF	-0.05	-0.02	-0.29***	-0.29*	-0.06	-0.06	-0.02	-0.14**	-0.05	0.00
ARERT	0.08	-0.14	-0.07	-0.28**	-0.05	0.01	-0.14*	-0.20***	-0.26**	-0.03
ARDIERT	-0.50	-0.32	-0.49***	-0.36***	-0.50*	-0.09	-0.16	-0.26***	-0.56***	0.02
EOTB-ERT	-0.04	-0.20*	-0.72	-0.22*	-0.30**	0.08	-0.18	-0.23***	0.03	-0.47***
ARRF	0.12	-0.06	-0.07	-0.29***	-0.16	0.02	-0.24**	-0.09**	-0.32***	-0.10
ARDIRF	-0.38**	-0.25	-0.22***	-0.58**	-0.31*	-0.08	-0.01	-0.14*	-0.51***	-0.19**
EOTB-MRF	0.11	-0.11	-0.59	-0.24**	-0.23*	-0.07	-0.31*	-0.23**	-0.12	-0.44***
ERT-MAF	0.12	0.05	-0.04	-0.04	-0.03	0.09	0.05	0.00	-0.01	<u>0.04</u>
Réseau de neurones										
LSTM-Dense-AR	0.02	0.04*	0.01	-0.01	-0.02	0.02	0.04*	0.01	-0.01	-0.02
LSTM-AR	0.02	0.00	0.00	-0.01	-0.01	0.02	0.00	0.00	-0.01	-0.01
Dense-AR	-0.02	0.00	-0.05	-0.17***	-0.01	-0.02	0.00	-0.05	-0.17***	-0.01
LSTM-Dense-ARDI	-0.07	0.08**	0.03*	<u>0.04*</u>	-0.10	-0.02	<u>0.14*</u>	-0.02	0.01	-0.01
LSTM-ARDI	-0.07	0.00	0.00	0.00	-0.12	-0.04	-0.07*	-0.03	-0.11**	-0.03
Dense-ARDI	-0.03	-0.75**	-0.70***	-0.18**	-0.22*	-0.13	0.02	-0.06	-0.06	-0.10
LSTM-Dense	-0.15**	0.00	-0.15**	-0.11	-0.04	-0.60**	-1.82	-0.41*	-0.62**	-0.35**
LSTM	-0.16**	0.01	-0.17**	-0.01	-0.03	-0.10	-0.04	-0.44**	-0.24*	-0.08
Dense	-7.44**	-0.06	0.02	-0.09	-0.11	-14.50**	-1.78**	-1.44***	-2.01***	-4.19***
Combinaisons de prévisions										
AVRG	0.17*	0.05	-0.03	-0.03	-0.01	0.13	0.09*	0.00	0.01	0.01
Médiane	0.13*	0.04	0.00	-0.01	0.00	0.12*	0.06**	-0.01	-0.01	0.02
T-AVRG,0.1	0.14*	0.04	-0.02	-0.02	0.00	0.15*	0.08**	-0.01	-0.01	0.02
T-AVRG,0.2	0.13*	0.04*	-0.01	-0.01	0.00	0.14*	0.07**	-0.01	-0.01	0.02
IP-AVRG,1	0.15*	0.05	-0.03	-0.03	-0.01	0.15	0.09*	-0.01	0.01	0.02
IP-AVRG,0.95	0.15*	0.05	-0.03	-0.03	-0.01	0.15	0.09*	-0.02	0.00	0.02

TABLE 42: Taux de chômage - Canada : Pseudo- R^2

Modèles	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC	0.22	0.05	-0.01	-0.04	-0.01	0.22	0.05	-0.01	-0.04	-0.01
ARDI,BIC	0.33	0.04	-0.07	-0.04	-0.02	0.33	-0.19	-0.42*	-0.26	-0.22
Régressions pénalisées										
Ridge	0.08	0.00	-0.12*	-0.02	-0.06	0.03	-0.03	<u>0.28*</u>	-0.02	-0.01
Lasso	0.39	0.14*	-0.20**	-0.02	0.03	0.44	0.13	-0.13	0.01	-0.08
Elastic-Net	-0.11	0.01	-0.02	-0.02	0.01	0.02	0.01	-0.02	-0.03	0.01
Adaptive-Lasso	0.42*	0.13***	0.02	0.00	-0.02	0.44	0.11	-0.05	-0.04	0.02
ARDI,Ridge	0.18	0.04	-0.02	-0.02	0.05	0.43	-0.08	-0.02	-0.02	0.14
ARDI,Lasso	0.35	0.07	-0.02	-0.02	0.06	0.44	-0.03	-0.21*	0.02**	0.18
ARDI,Elastic-Net	0.37	-0.15	-0.02	-0.02	-0.14	-0.12	-0.45	-0.02	-0.02	0.00
ARDI,Adaptive-Lasso	0.42	-0.03	-0.03	0.06	0.00	0.45	-0.11	-0.32	0.06	-0.08
Ridge-MAF	0.33*	0.11**	0.03	0.04	0.04	0.22*	0.05*	0.00	0.02	0.03
LASSO-MAF	0.23**	0.14***	0.08**	-0.03	0.01	0.32*	0.19**	-0.04	-0.01	-0.01
ELAS-MAF	0.33*	0.13***	-0.01	-0.01	0.01	0.34*	0.18**	-0.02	-0.01	0.00
Régressions régularisées par sous-ensembles complets										
T-CSR10	0.38	0.03	0.04	-0.12	-0.42***	0.48	0.22	0.11	-0.06	-0.27*
T-CSR20	-0.21	-0.08**	0.00	-0.03	0.00	-0.18**	-0.01	0.02	-0.03	0.00
CSR-R10	-0.05	-0.06*	0.00	-0.05	-0.02**	-0.01	0.04	0.06**	-0.03	-0.01
CSR-R20	0.41	0.18	-0.01	-0.05*	-0.11	0.16	0.06	-0.42*	-0.10*	0.01
Régressions à vecteurs de support										
NL-SVARDI	0.42	0.16	0.08	0.02	-0.15**	0.50	<u>0.27</u>	0.15	0.05	-0.07
L-SVARDI	0.00	0.11*	-0.02	-0.07**	-0.08	0.22	-0.02	-0.11	-0.19	-0.02
Forêts d'arbres aléatoires										
RFARDI	0.35*	0.15	-0.10	-0.06	-0.02	0.35	0.18	-0.08	-0.02	-0.06
RF-X	0.32*	0.14	-0.02	0.07	-0.01	0.31*	0.10**	0.00	0.04	0.04
RF-CSF	<u>0.46</u>	0.17	-0.13	-0.07	-0.03	0.36*	0.12	-0.37	-0.01	0.06
RF-MAF	0.33*	0.21	0.12	0.05	-0.03	0.32*	0.17*	0.16	0.08	-0.01
RF-X-CSF	0.34*	0.12	-0.01	0.10	0.04	0.34*	0.09**	0.01	0.07	0.07
LLF-CSF	0.35	-0.03	-0.10	-0.07	-0.11	0.33	0.08	-0.14	-0.01	0.05
ARERT	0.41	<u>0.23</u>	-0.21	-0.05	0.07	0.37	-0.04	-0.19	-0.14*	0.07
ARDIERT	0.43	-0.25	-0.19	-0.27	-0.16	0.48	0.04	0.05	-0.28***	0.08
EOTB-ERT	0.27	0.06	<u>0.16</u>	-0.25	-0.11*	<u>0.57</u>	-0.06	0.12	<u>0.09</u>	-0.02
ARRF	0.24	0.21	0.00	-0.21	-0.09*	0.28	0.07	-0.12	-0.13	-0.06
ARDIRF	0.23	-0.02	0.15	-0.52	-0.22*	0.35	0.01	-0.07	-0.20**	-0.19*
EOTB-MRF	0.21	0.04	-0.08	<u>0.17</u>	<u>0.14</u>	0.28	0.03	0.08	-0.01	0.08
ERT-MAF	0.38*	0.17	0.00	-0.01	0.04	0.34*	0.14**	0.03	0.02	0.01
Réseau de neurones										
LSTM-Dense-AR	0.06	-0.02	0.04**	0.02	0.02	0.06	-0.02	0.04**	0.02	0.02
LSTM-AR	0.01	0.02	0.01	0.01	0.02	0.01	0.02	0.01	0.01	0.02
Dense-AR	0.32	0.08	-0.03	-0.06	0.05	0.32	0.08	-0.03	-0.06	0.05
LSTM-Dense-ARDI	0.18	-0.08	0.02	-0.02	-0.04	0.40	0.20	-2.63	-0.05	-0.15
LSTM-ARDI	-0.08	0.12**	0.00	-0.04	-0.76	-0.23	-0.01	-0.29	-0.05	-0.06
Dense-ARDI	0.32	-0.24	-0.01	-0.20*	-0.26**	-1.14**	-0.64	-0.89	-0.94	-0.36
LSTM-Dense	-0.13	-0.54	0.02	-1.01*	-0.23	0.23	-0.87**	-0.16	-0.17*	<u>0.21</u>
LSTM	-0.03	-0.49**	-0.03	-0.03	-0.15	0.06	0.06	-0.07	-0.07	0.01
Dense	-0.99**	-1.65***	-0.93**	-0.19	-1.25**	-1.37*	-6.49***	-3.23*	-2.22***	-4.38**
Combinaisons de prévisions										
AVRG	0.45*	0.18**	0.09	0.04	0.04	0.47*	0.23*	0.11	0.06	0.07
Médiane	0.42*	0.14***	0.05**	0.04	0.04	0.41*	0.18**	0.05	0.04	0.05
T-AVRG,0.1	0.45*	0.17**	0.06*	0.04	0.05	0.46*	0.18**	0.05	0.05	0.06
T-AVRG,0.2	0.45*	0.17**	0.06*	0.03	0.04	0.44*	0.17**	0.05	0.04	0.06
IP-AVRG,1	0.43*	0.18**	0.07	0.03	0.04	0.46*	0.17*	0.05	0.04	0.06
IP-AVRG,0.95	0.43*	0.18**	0.07	0.03	0.04	0.45*	0.16*	0.05	0.04	0.06

TABLE 43: Emploi - Québec : Pseudo- R^2

Modèles	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC	-0.22*	-0.09	-0.09	-0.05	-0.03	-0.22*	-0.09	-0.09	-0.05	-0.03
ARDI,BIC	-0.15*	-0.01	-0.07*	-0.02	0.01	-0.15*	-0.04	-0.11*	-0.10	-0.20
Régressions pénalisées										
Ridge	-0.01	-0.03	-0.06**	0.00	0.03	-0.02	0.05	-0.05*	<u>0.02</u>	0.01
Lasso	0.00	-0.04	-0.05*	-0.02	<u>0.06</u>	-0.01	0.00	-0.08**	-0.07	-0.10*
Elastic-Net	-0.01	-0.03	-0.04	-0.01	0.03*	-0.01	-0.03	-0.04	-0.01	0.03*
Adaptive-Lasso	<u>0.02</u>	0.02	-0.01	-0.10***	-0.06*	0.00	-0.02	-0.01	-0.05**	-0.09**
ARDI,Ridge	0.00	-0.03	-0.04	-0.01	-0.03	-0.01	-0.03	-0.04	-0.01	0.03*
ARDI,Lasso	-0.21*	-0.03	-0.04	-0.01	0.01	-0.01	<u>0.07</u>	-0.04	-0.01*	<u>0.05**</u>
ARDI,Elastic-Net	-0.16	-0.03	-0.04	-0.01	0.03*	-0.01	-0.03	-0.04	-0.01	0.03*
ARDI,Adaptive-Lasso	0.02	<u>0.08</u>	-0.02	-0.05*	0.01	-0.09	-0.05	-0.07	-0.03	-0.06
Ridge-MAF	0.00	-0.05*	-0.06*	-0.02	0.03	-0.01	-0.03	-0.05***	-0.01	0.04
LASSO-MAF	-0.07*	-0.05	-0.02	-0.03	0.02	-0.03	-0.02	0.00	-0.03	0.01
ELAS-MAF	-0.05*	-0.04*	-0.01	-0.01	0.03	-0.04	-0.04*	-0.01	-0.01	0.03
Régressions régularisées par sous-ensembles complets										
T-CSR10	-0.19*	0.01	-0.26**	-0.11	-0.20*	-0.07	-0.06	-0.20	-0.35*	-0.17
T-CSR20	-0.02	0.00	-0.06**	-0.09**	0.00	<u>0.07</u>	-0.03	-0.05**	-0.06*	0.03*
CSR-R10	-0.04	-0.01	-0.08***	-0.12***	0.00	0.07	-0.03	-0.08***	-0.06**	0.03
CSR-R20	-0.05	-0.05	-0.05*	-0.03	-0.10	-0.04	-0.11	-0.04	-0.01*	-0.09
Régressions à vecteurs de support										
NL-SVRARDI	-0.14	0.01	-0.18**	-0.03	-0.08	-0.06	-0.01	-0.12	-0.15	-0.07
L-SVRARDI	-0.09	-0.18***	-0.07***	-0.07	-0.24*	0.02	-0.22*	-0.14*	-0.14	-0.10
Forêts d'arbres aléatoires										
RFARDI	-0.15*	-0.22***	-0.27***	-0.15**	-0.14*	-0.07	-0.10*	-0.21***	-0.18*	-0.17*
RF-X	-0.04	-0.11*	-0.04	-0.02	-0.03	-0.03	-0.09***	-0.11***	-0.07*	0.01
RF-CSF	-0.03	-0.16**	-0.20**	-0.16	-0.06	-0.13**	-0.25***	-0.29***	-0.21**	-0.23**
RF-MAF	-0.04	-0.17**	-0.07	-0.07	-0.08	-0.04	-0.16***	-0.13***	-0.09*	-0.08
RF-X-CSF	-0.06	-0.11**	-0.06	-0.07	-0.03	-0.02	-0.09***	-0.13***	-0.06	0.00
LLF-CSF	-0.09	-0.22*	-0.38***	-0.24	-0.14	-0.18***	-0.28***	-0.37***	-0.18*	-0.09
ARERT	-0.28**	-0.13*	-0.08	-0.15*	-0.17*	-0.12	-0.20*	-0.12*	-0.18***	-0.10
ARDIERT	-0.25**	-0.61**	-0.78**	-0.32**	-0.07	-0.30**	-0.29***	-0.21**	-0.54***	-0.11*
EOTB-ERT	-0.16**	-0.35**	-0.60	-0.64***	-0.52**	-0.20**	-0.34***	-0.11*	-0.42**	-0.29**
ARRF	-0.11*	-0.13*	-0.21*	-0.15*	-0.21*	-0.19**	-0.22**	-0.27***	-0.25***	-0.25*
ARDIRF	-0.17**	-0.42*	-0.85**	-0.57**	-0.10	-0.13	-0.49**	-0.16**	-0.35***	-0.13**
EOTB-MRF	-0.29**	-0.30**	-0.50	-0.83***	-0.33**	-0.17**	-0.25***	-0.10	-0.56***	-0.25*
ERT-MAF	-0.02	-0.14***	-0.03	-0.05	-0.04	-0.02	-0.13***	-0.08**	-0.10***	-0.06
Réseau de neurones										
LSTM-Dense-AR	-0.10	-0.04	-0.02	-0.02	0.04	-0.10	-0.04	-0.02	-0.02	0.04
LSTM-AR	-0.01	-0.01	-0.02	-0.01	0.04	-0.01	-0.01	-0.02	-0.01	0.04
Dense-AR	-0.10	-0.07	-0.06	-0.05*	0.02	-0.10	-0.07	-0.06	-0.05*	0.02
LSTM-Dense-ARDI	-0.01	-0.01	-0.02	<u>0.01</u>	-0.03	-0.24*	-0.16	-0.01	-0.03	0.03
LSTM-ARDI	-0.07**	-0.03**	-0.01	-0.08**	0.00	0.01	-0.03	-0.07	-0.09	-0.04
Dense-ARDI	-0.49***	-0.15**	<u>0.10*</u>	-0.67*	-0.11	-1.50*	-0.29*	-0.56**	-0.25*	-1.30*
LSTM-Dense	-0.70**	-0.17**	-0.86***	-0.10	-0.16	-1.07*	-0.16	-0.06	-0.17*	-0.07
LSTM	-0.08	-0.05*	-0.06	-0.22*	-0.17*	-0.20*	0.02	<u>0.01</u>	-0.17**	-0.18
Dense	-1.78*	-2.57**	-2.33**	-2.58**	-0.81***	-5.04***	-3.10**	-2.49*	-0.54*	-7.60*
Combinaisons de prévisions										
AVRG	-0.01	-0.03	-0.06	-0.05	0.01	-0.01	0.00	-0.06**	-0.06*	0.00
Médiane	-0.01	-0.04*	-0.04*	-0.01	0.02	0.00	-0.02	-0.06***	-0.02	0.02
T-AVRG,0.1	0.00	-0.03	-0.05	-0.02	0.01	0.01	-0.02	-0.05**	-0.04	0.01
T-AVRG,0.2	0.00	-0.03	-0.04*	-0.01	0.02	0.00	-0.02	-0.05**	-0.04	0.01
IP-AVRG,1	-0.01	-0.02	-0.05	-0.05	0.01	-0.01	-0.02	-0.05**	-0.05*	0.01
IP-AVRG,0.95	-0.01	-0.02	-0.06	-0.05	0.01	-0.01	-0.02	-0.05**	-0.05*	0.00

TABLE 44: Emploi - Canada : Pseudo- R^2

Modèles	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC	0.16	-0.01	-0.09*	-0.10*	-0.01	0.16	-0.01	-0.09*	-0.10*	-0.01
ARDI,BIC	0.14	-0.15*	-0.17***	-0.09**	-0.22	-0.04	-0.01	-0.47**	-0.21**	-0.10
Régressions pénalisées										
Ridge	-0.03	-0.06*	-0.11*	0.00	0.02	0.28	0.20	-0.11*	-0.12***	0.14*
Lasso	0.12	<u>0.16</u>	-0.12**	-0.06*	0.02	0.24	<u>0.22</u>	-0.18**	-0.08**	0.04
Elastic-Net	0.06	-0.06*	-0.11*	-0.05*	0.04**	0.11	-0.06*	-0.11*	-0.05*	0.04**
Adaptive-Lasso	0.30	-0.03	-0.18**	-0.18***	-0.08***	0.34	0.01	-0.09	-0.04*	-0.03
ARDI,Ridge	0.17	-0.13**	-0.11*	-0.05*	-0.15*	-0.34**	-0.03	-0.11*	-0.05**	0.04**
ARDI,Lasso	0.11	-0.06*	-0.11*	-0.04*	0.04***	-0.40*	-0.06*	-0.11*	-0.06**	0.05**
ARDI,Elastic-Net	-0.07*	-0.15**	-0.11*	-0.05*	-0.04	-0.28***	-0.06*	-0.11*	-0.05*	0.04**
ARDI,Adaptive-Lasso	0.39	0.09	-0.30***	-0.06***	0.09	<u>0.46</u>	-0.11	-0.20	-0.02	-0.01
Ridge-MAF	0.25	0.04	-0.04	0.02	0.08	0.23	0.01	-0.07***	0.00	0.09
LASSO-MAF	0.23	-0.13**	0.07	-0.06	-0.05	0.25	-0.14**	0.02	-0.03	-0.04
ELAS-MAF	0.33	0.08	0.09	-0.03	0.08	0.37	0.02	-0.04	-0.04	0.03
Régressions régularisées par sous-ensembles complets										
T-CSR10	<u>0.40</u>	-0.04	-0.04	-0.11	-0.14	0.36	0.05	-0.01	-0.12	-0.21
T-CSR20	0.23	0.07*	-0.06*	-0.05**	-0.02	0.25	0.09	-0.06**	-0.06**	-0.02
CSR-R10	0.25	0.10	-0.06**	-0.02	-0.02	0.26	0.10	-0.05***	-0.06*	-0.02
CSR-R20	0.30	0.09	-0.11*	0.00	-0.22	0.11	0.00	-0.16**	-0.12***	0.01
Régressions à vecteurs de support										
NL-SVRARDI	0.38	0.04	-0.05	-0.02	-0.02	0.37	0.13	<u>0.03</u>	-0.01	-0.01
L-SVRARDI	0.11	-0.06	-0.20***	0.00	-0.04	0.23	-0.08	-0.53***	-0.17	0.03
Forêts d'arbres aléatoires										
RFARDI	0.18	-0.12**	-0.27***	-0.27***	-0.08	0.21	-0.03	-0.13	-0.12	-0.05
RF-X	0.10	0.00	0.00	<u>0.08</u>	-0.06***	0.05	-0.16***	-0.19***	-0.12***	-0.07***
RF-CSF	0.32	0.01	-0.03	-0.08	0.04	0.15	-0.17***	-0.41**	-0.21**	0.05
RF-MAF	0.11	0.02	0.07	0.07	-0.13**	0.08	-0.02	-0.02	-0.12***	-0.14**
RF-X-CSF	0.13	0.00	-0.01	0.05	-0.02	0.06	-0.16***	-0.19***	-0.13***	-0.06***
LLF-CSF	0.29	-0.06	-0.12	-0.06	0.10	0.26	-0.02	-0.19*	-0.14	0.09
ARERT	0.21	0.10	-0.07	-0.09	-0.03	0.22	0.06	-0.14***	-0.12**	-0.03
ARDIERT	0.03	-0.57**	-0.75*	-0.45***	-0.13*	0.31	-0.08	-0.12**	-0.47***	-0.05
EOTB-ERT	0.04	-0.17**	<u>0.10</u>	-0.44***	-0.24*	-0.19**	-0.16***	-0.20***	-0.35***	-0.10
ARRF	0.23	0.05	-0.26**	0.00	-0.29***	0.23	0.02	-0.26***	-0.15***	-0.25***
ARDIRF	-0.16	-0.96*	-1.00**	-0.67***	-0.12	0.27	-0.19**	-0.15**	-0.56**	-0.26***
EOTB-MRF	-0.17***	-0.15**	-0.08	-0.31	-0.05	-0.06	-0.03	-0.14*	-0.33**	-0.19
ERT-MAF	0.14	0.03	0.00	0.01	-0.01	0.17	-0.02	-0.07	-0.06*	-0.04
Réseau de neurones										
LSTM-Dense-AR	-0.04	0.00	-0.02	-0.02	0.10**	-0.04	0.00	-0.02	-0.02	0.10**
LSTM-AR	0.02	-0.04*	-0.06	-0.03	0.08**	0.02	-0.04*	-0.06	-0.03	0.08**
Dense-AR	0.27	0.08	-0.10*	-0.13*	<u>0.12**</u>	0.27	0.08	-0.10*	-0.13*	0.12**
LSTM-Dense-ARDI	-0.05	-0.12	-0.08*	-0.04**	0.05	0.09	0.00	-0.21*	<u>0.04</u>	-0.03
LSTM-ARDI	-0.13	-0.07*	-0.09	0.00	0.03	0.07	-0.41**	-0.21*	-0.02	0.00
Dense-ARDI	-0.26	-0.23*	-0.26**	-0.27***	0.05	-0.89*	-0.54**	-0.01	-0.46**	-0.18**
LSTM-Dense	0.07	-0.83***	-0.38**	-0.50**	-0.16*	-1.74**	-0.29*	-4.30*	-2.99***	0.07
LSTM	-0.18	-0.08**	-0.08***	0.00	0.09	0.10	0.11	-0.16**	-0.04	0.15*
Dense	-8.61***	-1.79***	-3.35*	-1.23***	-0.13	-3.35**	-9.23***	-3.75**	-6.18***	-5.97***
Combinaisons de prévisions										
AVRG	0.35	0.08	-0.02	0.03	0.08	0.33	0.13	-0.06	-0.05*	0.06
Médiane	0.32	0.05	-0.06***	-0.01	0.07	0.32	0.07	-0.07**	-0.04***	0.07
T-AVRG,0.1	0.35	0.07	-0.03	0.00	0.07	0.33	0.08	-0.07**	-0.05**	0.06
T-AVRG,0.2	0.35	0.06	-0.04	-0.01	0.07	0.32	0.08	-0.08***	-0.05***	0.06
IP-AVRG,1	0.36	0.06	-0.04	0.00	0.07	0.33	0.07	-0.08**	-0.06**	0.06
IP-AVRG,0.95	0.36	0.06	-0.04	0.00	0.07	0.33	0.07	-0.08**	-0.06**	0.06

TABLE 45: Mises en chantier - Québec : Pseudo- R^2

Modèles	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC	0.13*	0.06	<u>0.08</u>	0.02	-0.07*	<u>0.13*</u>	0.06	<u>0.08</u>	0.02	-0.07*
ARDI,BIC	0.11	0.05	0.07	0.00	-0.02**	-0.03	0.02	-0.12	-0.02	-0.06**
Régressions pénalisées										
Ridge	-0.01***	0.00	0.00	0.02*	0.00	-0.01***	-0.01	0.00	0.02*	0.00
Lasso	0.00	0.01	0.00	0.02*	0.00	0.00	0.02	0.00	-0.02	0.00
Elastic-Net	-0.01***	-0.02*	0.00	0.02*	0.00	-0.01***	-0.02*	0.00	0.02*	0.00
Adaptive-Lasso	0.00	0.00	0.01	0.02	0.01	-0.01	0.01	0.03	0.03	0.03*
ARDI,Ridge	-0.03	-0.03***	0.00	0.02*	0.00	-0.01	-0.02*	-0.03	0.02*	0.00
ARDI,Lasso	0.05*	0.01	0.01	0.02*	0.00	0.04*	-0.02***	0.00	0.02*	0.00
ARDI,Elastic-Net	0.00	-0.02*	0.00	0.02*	0.00	-0.01***	-0.02*	0.00	0.02*	0.00
ARDI,Adaptive-Lasso	-0.03	-0.09*	0.00	0.02*	0.00	0.03	-0.06	-0.01	-0.02	0.01
Ridge-MAF	-0.02	0.03	0.01	0.01	0.01	0.00	0.02	0.01	0.02	0.00
LASSO-MAF	-0.01	0.00	-0.02	0.02*	0.00	0.00	0.00	0.01	0.02*	0.00
ELAS-MAF	-0.03	0.00	0.01	0.02*	0.00	0.00	0.00	0.01	0.02*	0.00
Régressions régularisées par sous-ensembles complets										
T-CSR10	0.08	-0.10	-0.17*	-0.33***	-0.23***	0.07	-0.08	-0.10	-0.30***	-0.10
T-CSR20	-0.14**	-0.10*	-0.01	0.00	0.00	-0.14**	-0.05***	-0.03	<u>0.05***</u>	0.01
CSR-R10	-0.30***	-0.15*	0.01	-0.01	0.01	-0.23**	-0.05**	-0.02	0.05***	0.00
CSR-R20	0.02	0.01	0.01	0.02*	0.00	0.02	-0.02	-0.01	0.02*	0.00
Régressions à vecteurs de support										
NL-SVRARDI	<u>0.16*</u>	-0.02	-0.03	-0.17**	-0.08*	0.13	-0.02	-0.02	-0.17***	-0.02
L-SVRARDI	0.09*	0.03	0.01	0.01	0.01	0.08**	-0.01	0.01	0.03	0.01
Forêts d'arbres aléatoires										
RFARDI	0.11*	0.03	0.02	<u>0.04</u>	-0.02	0.04	0.03	0.03	0.02	-0.02
RF-X	0.01	0.01	0.03	0.03	0.01	0.02	0.04**	0.03*	0.01	-0.01
RF-CSF	-0.05	-0.02	-0.01	-0.05*	-0.05	0.05	0.08*	0.04	-0.02	-0.10***
RF-MAF	-0.06	0.00	0.04	-0.02	-0.01	-0.02	0.04	0.02	-0.02	-0.02
RF-X-CSF	-0.02	0.02	0.06***	0.02	-0.01	0.00	0.03	0.04**	0.01	0.01
LLF-CSF	-0.03	0.04	0.00	-0.07	-0.04	0.05	0.06	0.04	0.00	-0.06***
ARERT	0.14**	-0.09	0.02	-0.03	0.01	0.07	-0.02	0.01	-0.01	<u>0.11*</u>
ARDIERT	-0.17	-0.20*	-0.49**	-0.22	0.01	-0.02	0.05	0.03	-0.13	-0.02
EOTB-ERT	-0.26**	-0.08	-0.07	-0.63**	-0.64**	-0.40***	-0.07	-0.20***	-0.18**	-0.05
ARRF	0.08*	0.00	0.02	-0.06	0.01	0.08*	0.06	0.00	0.00	-0.02
ARDIRF	0.06	-0.29	-0.22*	-0.48	-0.11	0.04	-0.01	-0.05	-0.01	-0.10
EOTB-MRF	-0.36**	-0.12	-0.22	-0.33***	-0.39**	-0.29***	-0.09*	-0.10**	-0.15*	-0.28***
ERT-MAF	-0.05	0.05**	0.01	-0.01	<u>0.02</u>	-0.04**	0.04	0.01	0.03**	-0.01
Réseau de neurones										
LSTM-Dense-AR	0.06	-0.01	-0.04	0.00	0.00	0.06	-0.01	-0.04	0.00	0.00
LSTM-AR	-0.01	-0.01	0.03	0.02*	0.00	-0.01	-0.01	0.03	0.02*	0.00
Dense-AR	0.12	<u>0.17**</u>	0.03	-0.03	-0.06***	0.12	<u>0.17**</u>	0.03	-0.03	-0.06***
LSTM-Dense-ARDI	0.04	0.01	0.00	0.01	-0.02**	-0.01	-0.04	-0.03	0.01	-0.02
LSTM-ARDI	0.10**	0.01	-0.03	0.02	-0.02**	0.03	0.00	-0.02	0.01	-0.02
Dense-ARDI	0.10	0.03	-0.26**	-0.14**	-0.13**	-0.16*	-0.42***	-0.53*	-0.19**	-0.33**
LSTM-Dense	-0.08*	-0.06*	-0.06	-0.12**	-0.01	0.01	0.05**	0.04*	-0.02	-0.04**
LSTM	-0.03*	-0.12**	0.01	0.01	-0.02	-0.01	-0.09**	-0.03	-0.07*	0.00
Dense	-0.03	-0.17	-0.05**	-0.94	-0.05*	0.02	-0.03	0.01	-0.05**	0.00
Combinaisons de prévisions										
AVRG	0.06***	0.04*	0.04**	0.00	-0.01	0.06***	0.04*	0.05**	0.02	0.00
Médiane	0.03**	0.03*	0.01*	0.02	0.00	0.02	0.02*	0.02**	0.02*	0.00
T-AVRG,0.1	0.05***	0.03	0.04**	0.01	0.00	0.04**	0.03*	0.03**	0.03**	0.00
T-AVRG,0.2	0.04**	0.03*	0.03**	0.01	0.00	0.03**	0.03*	0.03**	0.02**	0.00
IP-AVRG,1	0.06***	0.04*	0.04**	0.00	0.00	0.06***	0.05**	0.04**	0.02	0.00
IP-AVRG,0.95	0.06***	0.04*	0.04**	0.00	0.00	0.06***	0.05**	0.04*	0.02	0.00

TABLE 46: Mises en chantier - Canada : Pseudo- R^2

Modèles	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC	0.08	0.03	0.04	-0.01	-0.14*	0.08	0.03	0.04	-0.01	-0.14*
ARDI,BIC	0.09	0.01	0.04	-0.02	-0.02	<u>0.15</u>	-0.17**	-0.03	-0.05	0.00
Régressions pénalisées										
Ridge	-0.01	-0.05**	-0.01	0.01	0.00	-0.01	-0.02	-0.01	0.01	0.00
Lasso	-0.01	-0.04**	-0.01	0.01	0.00	0.01	-0.03	-0.01	0.01	0.00
Elastic-Net	-0.01	-0.02	-0.01	0.01	0.00	-0.01	-0.02	-0.01	0.01	0.00
Adaptive-Lasso	0.11	0.05	-0.03	<u>0.08*</u>	<u>0.07*</u>	0.11	0.03	0.03	0.04	0.04**
ARDI,Ridge	-0.07	-0.02	-0.03*	0.01	0.00	-0.01	-0.02	-0.01	0.01	0.00
ARDI,Lasso	-0.15*	-0.04***	-0.04	0.01	0.00	0.00	-0.02	-0.01*	0.01	0.00
ARDI,Elastic-Net	-0.01	-0.02	-0.01	0.01	0.00	-0.01	-0.03*	-0.01**	0.01	0.00
ARDI,Adaptive-Lasso	-0.04	-0.03*	-0.01	0.00	0.01	-0.10**	-0.07	0.00	0.03	0.03
Ridge-MAF	-0.07	0.03	0.01	0.00	0.01	-0.01	0.03	0.01	0.01	0.01
LASSO-MAF	0.00	0.00	0.00	0.01	0.00	0.00	0.00	0.00	0.01	-0.14**
ELAS-MAF	0.00	0.00	0.00	0.01	0.00	0.00	0.00	0.01	-0.06	
Régressions régularisées par sous-ensembles complets										
T-CSR10	<u>0.14</u>	-0.10	-0.12*	-0.33***	-0.13*	0.01	-0.07	-0.23**	-0.22**	-0.08
T-CSR20	-0.10	0.01	0.00	0.00	0.02	-0.10*	0.02	0.00	0.03**	0.03*
CSR-R10	-0.19*	0.00	0.01	0.00	0.00	-0.16*	0.03	-0.04*	0.04**	0.04*
CSR-R20	0.07	0.03	-0.01	0.01	0.00	0.02	0.03	-0.03	0.01	0.00
Régressions à vecteurs de support										
NL-SVRARDI	0.07	-0.01	-0.05	-0.13**	-0.06	-0.06	-0.01	-0.07	-0.12*	-0.05
L-SVRARDI	-0.05	-0.04	0.00	0.04	-0.10*	-0.05	-0.06	-0.10*	-0.02	-0.11*
Forêts d'arbres aléatoires										
RFARDI	-0.02	-0.01	-0.13*	-0.05	-0.03	0.00	-0.07	-0.12	-0.10	-0.01
RF-X	-0.01	0.06	0.03	0.03*	0.01	0.01	0.04	0.01	0.04*	<u>0.09*</u>
RF-CSF	0.02	0.06	0.01	-0.02	0.03	0.06	<u>0.16*</u>	<u>0.07</u>	0.01	-0.10***
RF-MAF	-0.07	<u>0.11</u>	-0.04	0.01	0.06	0.01	<u>0.17</u>	-0.02	0.00	0.07
RF-X-CSF	-0.01	0.04	0.03*	0.03	0.04	0.00	0.04	0.02	<u>0.07**</u>	0.09
LLF-CSF	-0.17**	-0.05	0.05	-0.04	-0.08*	0.05	0.11	0.06	0.01	-0.11***
ARERT	-0.14*	0.04	-0.04	-0.04	-0.14*	-0.14*	0.10	-0.05	-0.02	0.03
ARDIERT	-0.17	-0.63*	-0.19**	-0.37*	-0.30**	-0.50	-0.07	0.00	-0.33***	-0.18*
EOTB-ERT	0.07	-0.11	-0.12*	-0.08	0.05	0.05	0.08	-0.08	-0.17	-0.19*
ARRF	-0.13	0.08	0.06	-0.11	-0.15	-0.09	0.05	-0.02	-0.05	-0.24**
ARDIRF	-0.76	-0.47*	-0.10	-0.23*	-0.51**	-0.28*	0.04	-0.01	-0.43*	-0.53*
EOTB-MRF	0.13	0.00	-0.08	-0.11	-0.15	0.08	0.06	-0.07	-0.02	0.06
ERT-MAF	-0.12	0.01	0.01	-0.01	0.04	-0.01	0.09	0.00	0.01	0.05
Réseau de neurones										
LSTM-Dense-AR	-0.02	-0.02*	0.02	0.00	0.01	-0.02	-0.02*	0.02	0.00	0.01
LSTM-AR	-0.03	0.03	0.01	-0.01	-0.01	-0.03	0.03	0.01	-0.01	-0.01
Dense-AR	-0.01	0.03	0.01	0.01	-0.03	-0.01	0.03	0.01	0.01	-0.03
LSTM-Dense-ARDI	0.03	-0.05	-0.06	-0.40	-0.01	0.06	0.06	-0.09*	-0.02	-0.01
LSTM-ARDI	0.07	0.05	<u>0.09*</u>	-0.04	0.00	0.15	-0.07	-0.07	-0.04	-0.02
Dense-ARDI	0.11	-0.77**	-0.05	-0.05	-0.17**	-0.12	-0.40**	-0.29***	-0.09	-0.12
LSTM-Dense	0.03	-0.04	0.01	0.02	-0.02	-0.15	0.05	-0.01	0.00	-0.05
LSTM	0.00	-0.01	-0.03	0.01	-0.18*	0.02	0.00	-0.01	0.00	-0.01
Dense	0.00	-0.08	-0.02	0.03	-0.02	0.09	-0.12	-0.02	-0.02	-0.03**
Combinaisons de prévisions										
AVRG	0.06	0.03	0.06	0.01	0.01	0.08*	0.05	0.04	0.02	0.02
Médiane	0.04	0.04	0.03	0.02	0.01	0.02	0.04	0.01	0.01	0.01
T-AVRG,0.1	0.05	0.03	0.03	0.02	0.02	0.05	0.05	0.02	0.02	0.03
T-AVRG,0.2	0.04	0.03	0.03	0.02	0.01	0.04	0.05	0.02	0.02	0.02
IP-AVRG,1	0.06	0.03	0.05	0.01	0.01	0.08*	0.05	0.03	0.02	0.02
IP-AVRG,0.95	0.06	0.03	0.05	0.01	0.01	0.08*	0.05	0.03	0.02	0.02

TABLE 47: IPC - Québec : Pseudo- R^2

Modèles	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC	0.23***	0.29***	0.32***	<u>0.26***</u>	0.05	0.23***	0.29***	0.32***	0.26***	0.05
ARDI,BIC	0.11**	-0.08	<u>0.35***</u>	-0.13	-0.37	0.09*	-0.26	0.33***	-0.17	-0.40
Régressions pénalisées										
Ridge	0.17***	0.15***	0.13***	0.02	0.08***	0.19***	0.20***	0.13***	0.06***	0.03**
Lasso	0.29***	0.31***	0.19***	0.04	0.15***	0.30***	0.25***	0.10	0.14**	-0.03
Elastic-Net	0.13***	0.13***	0.11***	0.05***	0.03***	0.13***	0.13***	0.11***	0.05***	0.03***
Adaptive-Lasso	0.36***	<u>0.38***</u>	0.29***	0.19**	<u>0.23***</u>	0.32***	0.36***	0.29***	0.19**	0.22***
ARDI,Ridge	0.19***	0.11***	0.12***	-0.65	0.08*	0.11***	0.13***	0.11***	0.04***	0.03***
ARDI,Lasso	0.19***	0.23***	0.11***	-0.68*	0.01	0.18***	0.15***	0.11***	0.05***	0.05***
ARDI,Elastic-Net	0.13***	0.11***	0.12***	0.10**	0.03*	0.13***	0.13***	0.11***	0.05***	0.03***
ARDI,Adaptive-Lasso	0.33***	0.26***	0.18***	0.04	-0.01	0.25***	0.26***	0.22***	0.04	-0.02
Ridge-MAF	0.21***	0.22***	0.16***	0.10**	0.06	0.26***	0.22***	0.19***	0.10***	0.07**
LASSO-MAF	0.18***	0.17***	0.11***	0.08***	0.04***	0.19***	0.15***	0.13***	0.08***	0.04***
ELAS-MAF	0.18***	0.16***	0.11***	0.07***	0.06***	0.20***	0.16***	0.09**	0.07***	0.07***
Régressions régularisées par sous-ensembles complets										
T-CSR10	0.36***	0.33***	0.33***	-0.08	-0.10	0.27***	0.33***	0.29***	-0.21	-0.44
T-CSR20	0.06**	-0.01	0.28***	-0.02	0.01	0.08***	0.04**	0.19***	0.04*	0.03
CSR-R10	0.03	-0.01	0.31***	-0.02	-0.05	0.06**	0.03	0.21***	0.04*	-0.01
CSR-R20	0.34***	0.23***	0.14*	-0.41	-0.22	0.27***	0.21**	-0.09	-0.45	-0.33
Régressions à vecteurs de support										
NL-SVRARDI	0.29***	0.33***	0.34***	0.00	-0.09	0.22***	0.32***	0.33***	-0.10	-0.27
L-SVRARDI	0.24***	0.26***	0.09	-0.23	0.02	<u>0.37***</u>	0.29***	0.05	-0.17	-0.08
Forêts d'arbres aléatoires										
RFARDI	<u>0.37***</u>	0.32***	0.22**	0.08	0.16*	0.35***	0.32***	0.21***	0.05	0.16*
RF-X	0.30***	0.30***	0.28***	0.26***	0.20***	0.34***	0.32***	0.30***	<u>0.29***</u>	<u>0.25***</u>
RF-CSF	0.11	0.17*	0.12	0.11	0.22***	0.36***	0.28***	0.17	0.06	0.20**
RF-MAF	0.26***	0.24**	0.15*	0.21**	0.16***	0.32***	0.27***	0.24***	0.22**	0.18***
RF-X-CSF	0.29***	0.29***	0.27***	0.24***	0.20***	0.33***	0.31***	0.30***	0.23***	0.25***
LLF-CSF	0.09	0.10	0.16	-0.12	0.16*	0.27***	0.15	0.14	-0.01	0.19**
ARERT	0.25***	0.29***	0.20*	-0.28	0.04	0.26**	0.25***	<u>0.36***</u>	-0.03	0.11*
ARDIERT	-0.20	-0.12	-0.04	-0.64	-0.73	0.24***	0.23**	0.35***	0.11	-0.29
EOTB-ERT	-0.73*	-0.45	-0.23	-0.22	-0.04	-0.35	-0.02	0.14	-0.29	-0.09
ARRF	-0.05	0.07	0.25***	-0.34	0.09	0.13	0.22**	0.27***	-0.13	-0.03
ARDIRF	0.15	-0.32	0.20	-0.91	-0.27	0.29***	-0.18	0.34***	-0.01	-0.52
EOTB-MRF	-0.68	-0.41	-0.20	-0.18	0.06	-0.12	-0.03	0.05	-0.18	-0.14
ERT-MAF	0.24**	0.28***	0.29***	0.21***	0.17***	0.32***	0.31***	0.27***	0.29***	0.21***
Réseau de neurones										
LSTM-Dense-AR	0.14***	0.16***	0.17***	0.05	0.07	0.14***	0.16***	0.17***	0.05	0.07
LSTM-AR	0.13***	0.16**	0.04	0.09	0.05	0.13***	0.16**	0.04	0.09	0.05
Dense-AR	0.29***	0.19***	0.12*	0.09	0.07	0.29***	0.19***	0.12*	0.09	0.07
LSTM-Dense-ARDI	0.10**	-0.04	-0.03	-0.07	-0.27	-0.13**	0.00	-0.63	-0.71*	-0.56
LSTM-ARDI	0.07	0.11**	-0.01	-0.16	-0.02	0.03	0.09*	0.00	-0.27	-0.10
Dense-ARDI	0.05	0.02	0.01	-0.30	-0.11*	0.16**	-0.13	-0.44**	-0.69*	-0.03
LSTM-Dense	0.23***	-0.56	-0.06	-0.43	0.01	0.00	-0.09	-0.17*	-0.72*	-1.18**
LSTM	0.12**	0.09	0.07	0.05	-0.02	0.04	-0.02	-0.15	0.03	-0.04
Dense	-0.45*	-0.48*	-2.07***	-1.18**	-2.28***	-2.28***	-2.84*	-0.95***	-13.51***	-1.67***
Combinaisons de prévisions										
AVRG	0.26***	0.25***	0.23***	0.08	0.11*	0.30***	0.27***	0.24***	0.07	0.09
Médiane	0.28***	0.25***	0.24***	0.11*	0.13**	0.28***	0.25***	0.25***	0.13***	0.12**
T-AVRG,0.1	0.27***	0.25***	0.23***	0.09	0.12**	0.29***	0.26***	0.24***	0.11*	0.11
T-AVRG,0.2	0.28***	0.25***	0.23***	0.10	0.13**	0.29***	0.25***	0.25***	0.12**	0.12*
IP-AVRG,1	0.27***	0.25***	0.24***	0.08	0.11*	0.30***	0.27***	0.24***	0.10*	0.09
IP-AVRG,0.95	0.27***	0.25***	0.24***	0.08	0.11*	0.30***	0.27***	0.24***	0.10	0.09

TABLE 48: IPC - CAN : Pseudo- R^2

Modèles	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC	0.33***	0.35***	0.32***	<u>0.30***</u>	0.05	0.33***	0.35***	0.32***	<u>0.30***</u>	0.05
ARDI,BIC	0.30***	0.13	0.32***	-0.09	-0.09	0.25***	0.08	0.32***	-0.14	-0.10
Régressions pénalisées										
Ridge	0.21***	0.14***	0.13***	0.10***	0.05***	0.20***	0.24**	0.14***	0.01	0.06***
Lasso	0.21***	0.32***	0.20***	0.00	0.12***	0.30***	0.37***	0.18***	0.09***	0.00
Elastic-Net	0.00	0.11***	0.09***	0.04***	0.03***	0.00	0.11***	0.09***	0.04***	0.03***
Adaptive-Lasso	0.35***	0.35***	0.28***	0.21***	0.20***	0.30***	0.31***	0.28***	0.22***	0.22***
ARDI,Ridge	0.25***	0.08	0.13***	0.06**	0.03***	0.22**	0.13	0.09***	0.05***	0.03***
ARDI,Lasso	0.25**	0.10	0.13***	-0.35	-0.27	0.26***	0.18***	0.09***	0.01	-0.41
ARDI,Elastic-Net	0.16*	0.08	0.13***	-0.37	0.04**	0.13***	0.26*	0.09***	0.04***	0.03***
ARDI,Adaptive-Lasso	0.36***	0.23**	0.39***	0.18**	0.08	0.32***	0.29***	0.25***	0.11	0.05
Ridge-MAF	0.20***	0.21***	0.19***	0.10***	0.09**	0.28***	0.24***	0.23***	0.09***	0.09***
LASSO-MAF	0.18***	0.14***	0.10	0.10*	0.09***	0.22***	0.13***	0.18**	0.08*	0.10**
ELAS-MAF	0.16***	0.13***	0.10*	0.12***	0.05	0.18***	0.13***	0.15**	0.12***	0.08*
Régressions régularisées par sous-ensembles complets										
T-CSR10	<u>0.41***</u>	0.36***	<u>0.40***</u>	0.01	-0.01	0.36***	0.33***	<u>0.35***</u>	0.02	-0.24
T-CSR20	0.10***	-0.04	0.27***	-0.09*	0.10	0.09***	0.03	0.15***	0.01	0.06
CSR-R10	0.07**	0.00	0.33***	-0.12*	0.11	0.06**	0.02	0.16***	0.01	0.03
CSR-R20	0.33***	0.21**	0.12*	-0.16	-0.10	0.31***	0.25**	0.06	-0.10	-0.06
Régressions à vecteurs de support										
NL-SVRARDI	0.33***	0.33***	0.38***	0.01	0.01	0.30***	0.32***	0.35***	0.01	-0.11
L-SVRARDI	0.27***	0.19	0.11*	-0.04	-0.11	0.31***	0.12	0.13	-0.12	-0.04
Forêts d'arbres aléatoires										
RFARDI	0.33***	0.34***	0.25***	0.20***	0.17**	0.32***	0.33***	0.27***	0.21***	0.20**
RF-X	0.31***	0.30***	0.26***	0.22***	0.20***	0.32***	0.30***	0.26***	0.24***	0.20***
RF-CSF	0.28***	0.26***	0.24***	0.19**	<u>0.23***</u>	0.35***	0.34***	0.20**	0.18**	0.25***
RF-MAF	0.27***	0.26***	0.19***	0.21***	0.20***	0.27***	0.26***	0.21***	0.22***	0.21***
RF-X-CSF	0.34***	0.29***	0.24***	0.25***	0.20***	0.32***	0.30***	0.27***	0.25***	0.22***
LLF-CSF	0.18*	0.23***	0.33***	0.14	0.18*	0.30***	0.30***	0.18**	0.21***	<u>0.27***</u>
ARERT	0.38***	<u>0.41***</u>	0.36***	0.17*	0.13	0.40***	<u>0.49***</u>	0.32***	0.21**	0.00
ARDIERT	0.14	0.40***	0.28*	-0.03	-0.46	<u>0.42***</u>	0.35***	0.29***	0.05	-0.09
EOTB-ERT	-0.60*	-0.20	-0.15	-0.57	-0.06	-0.34	-0.07	0.08	-0.39	-0.19
ARRF	0.15	0.14	0.36***	0.06	0.04	0.10	0.31***	0.32***	0.01	0.10
ARDIRF	0.31***	0.25***	0.10	-0.40	-0.10	0.17	0.36***	0.23***	0.03	-0.09
EOTB-MRF	-0.26	-0.12	-0.04	-0.44	-0.11	-0.06	-0.21	0.05	-0.47	0.10
ERT-MAF	0.28***	0.29***	0.24***	0.22***	0.18***	0.32***	0.30***	0.28***	0.20***	0.19***
Réseau de neurones										
LSTM-Dense-AR	0.10***	0.08**	0.18***	0.01	0.07	0.10***	0.08**	0.18***	0.01	0.07
LSTM-AR	0.09***	0.21***	0.11***	0.08*	0.04	0.09***	0.21***	0.11***	0.08*	0.04
Dense-AR	0.19***	0.17***	0.13**	-0.04	0.18**	0.19***	0.17***	0.13**	-0.04	0.18**
LSTM-Dense-ARDI	0.05	-0.06	0.07	-0.13*	-0.05	0.01	-0.09	-0.18	-0.07**	-0.32
LSTM-ARDI	0.05	0.14**	0.07**	-0.01	-0.03	-0.04	0.02	0.02	0.04	-0.16
Dense-ARDI	0.07*	-0.04	-0.07	-0.06	-0.34	-0.19	-0.38*	-0.07	0.00	-0.49**
LSTM-Dense	0.14***	-0.07	0.01	<u>-0.55***</u>	-0.15*	0.07	0.05	0.10**	-0.21***	-0.04
LSTM	0.12	0.21**	0.10***	0.02	0.19**	-0.46*	0.25**	0.07	0.12**	-0.06
Dense	-0.82**	0.05	-1.56***	-1.47***	-1.60**	-2.48***	-2.94**	-2.70*	-1.34***	-2.17***
Combinaisons de prévisions										
AVRG	0.30***	0.28***	0.25***	0.12*	0.14**	0.29***	0.30***	0.25***	0.16***	0.13**
Médiane	0.30***	0.27***	0.24***	0.15***	0.15***	0.30***	0.28***	0.25***	0.18***	0.15***
T-AVRG,0.1	0.31***	0.27***	0.26***	0.13**	0.14**	0.29***	0.29***	0.24***	0.16***	0.14**
T-AVRG,0.2	0.30***	0.27***	0.25***	0.14*	0.14**	0.29***	0.29***	0.24***	0.16***	0.14***
IP-AVRG,1	0.31***	0.28***	0.27***	0.13*	0.13**	0.30***	0.31***	0.25***	0.16***	0.13**
IP-AVRG,0.95	0.31***	0.28***	0.27***	0.13**	0.13**	0.30***	0.31***	0.26***	0.16***	0.13**

TABLE 49: Production industrielle : Pseudo- R^2

Modèles	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC	0.18	0.02	-0.05	-0.08**	-0.04**	0.18	0.02	-0.05	-0.08**	-0.04**
ARDI,BIC	0.46*	<u>0.25**</u>	<u>0.17*</u>	0.03	0.04	<u>0.53*</u>	<u>0.38*</u>	0.02	-0.03	0.04
Régressions pénalisées										
Ridge	0.05	-0.02	-0.05***	0.10**	0.00	0.45*	0.15	-0.03**	0.02	0.03
Lasso	0.30*	0.20**	0.09**	0.10**	0.07*	0.41*	0.25*	0.03	0.00	0.07*
Elastic-Net	-0.07	-0.02*	-0.02**	0.00	0.03	0.32	-0.02*	-0.02**	0.00	0.03
Adaptive-Lasso	0.31**	0.14**	0.11*	0.10*	0.07	0.33*	0.17**	0.11	0.06	0.06
ARDI,Ridge	0.47*	0.03	-0.03	0.00	-0.07	0.06	-0.03	-0.02**	0.00	0.03
ARDI,Lasso	0.49*	0.03	0.04	0.01	0.03	0.15**	0.02	0.00	0.03*	0.03
ARDI,Elastic-Net	0.05	-0.01	-0.02**	0.00	0.03	0.05*	-0.16*	-0.02**	0.00	0.03
ARDI,Adaptive-Lasso	0.40*	0.19**	0.09	0.04	0.10	0.43*	0.11*	-0.18	0.00	0.14
Ridge-MAF	0.30**	0.08**	0.05**	0.08*	0.06	0.22**	0.07***	0.04**	0.07*	0.05
LASSO-MAF	0.15**	-0.20	0.11*	0.05*	0.04	0.27*	0.06*	-0.03*	0.05*	0.04
ELAS-MAF	0.18**	-0.08	0.03	-0.01	0.04	0.22*	0.00	0.02	0.03	0.04
Régressions régularisées par sous-ensembles complets										
T-CSR10	0.40*	0.23*	0.14*	0.08	-0.03	0.50*	0.26*	<u>0.25*</u>	<u>0.17*</u>	0.01
T-CSR20	0.19*	0.00	-0.02	-0.03*	0.03**	0.18*	0.01	-0.02	-0.02*	0.03***
CSR-R10	0.21*	0.00	-0.01	-0.02	0.03*	0.21*	0.00	0.01	-0.02	0.04***
CSR-R20	0.39*	0.22**	0.17**	0.07*	0.02	0.50*	0.19*	0.10	0.07	0.03
Régressions à vecteurs de support										
NL-SVRARDI	0.35*	0.19**	0.16**	0.11*	0.03	0.45*	0.21*	0.23*	0.17**	0.05
L-SVRARDI	0.46*	0.21**	0.15**	0.08*	0.05	0.47*	0.22	0.16*	0.06	0.08*
Forêts d'arbres aléatoires										
RFARDI	0.26*	0.17**	0.03	0.04	0.06	0.31**	0.21*	0.10	0.09	0.04
RF-X	0.20**	0.10*	0.06	0.05	0.03	0.21**	0.13**	0.04	0.08	0.04
RF-CSF	0.25*	0.16*	0.08	0.10	0.01	0.21**	0.09	-0.15	0.09	0.08
RF-MAF	0.21**	0.11**	0.00	0.06	0.05	0.19***	0.14**	0.00	0.07	0.04
RF-X-CSF	0.22**	0.13*	0.05	0.06	0.01	0.23**	0.12**	0.04	0.07	0.05
LLF-CSF	0.26**	0.18	0.07	0.08	0.07	0.27**	0.16*	0.12	0.13	0.09
ARERT	0.29	0.01	-0.06	-0.01	0.07	0.27*	0.02	-0.17	0.02	0.10
ARDIERT	0.49*	-0.05	0.03	-0.05	0.02	0.29*	-0.11	0.05	-0.04	0.06
EOTB-ERT	0.32*	-0.14	-0.21	-0.15**	0.01	0.09**	-0.04	0.02	-0.13**	-0.05
ARRF	0.36*	0.03	-0.35	-0.03	0.05	0.28	0.01	-0.05	-0.11	0.00
ARDIRF	0.53*	0.22*	0.01	0.03	0.00	0.25	-0.11	0.02	0.00	-0.01
EOTB-MRF	0.06	0.02	-0.59	-0.10**	0.04	0.27**	0.04	-0.02	-0.08**	-0.05
ERT-MAF	0.23**	0.11**	0.03	0.06	0.05	0.20**	0.12**	0.05	0.08	0.06
Réseau de neurones										
LSTM-Dense-AR	-0.02	-0.01	0.05**	0.03***	0.04	-0.02	-0.01	0.05**	0.03***	0.04
LSTM-AR	0.02	0.02	0.00	0.03***	0.02	0.02	0.02	0.00	0.03***	0.02
Dense-AR	0.20	-0.11	-0.06	-0.21*	-0.13**	0.20	-0.11	-0.06	-0.21*	-0.13**
LSTM-Dense-ARDI	-0.01	0.08**	0.03	0.06**	0.00	0.33	-0.01	-0.05	0.05*	0.08***
LSTM-ARDI	0.14*	0.09**	-0.01	0.04***	0.05	-0.01	-0.03	0.03	0.10**	0.07
Dense-ARDI	-0.02	-0.07	-0.01	-0.09	-0.24	0.34	-0.14	-0.60**	0.00	-0.45**
LSTM-Dense	0.20	0.15	0.01	<u>0.18</u>	0.06	0.17	0.14*	0.07	-0.03	-0.02
LSTM	0.13	0.13	0.10	-0.01	0.05	0.33*	0.01	0.04	0.06	<u>0.17</u>
Dense	-0.18	-1.04**	-0.56***	-0.75**	<u>0.15</u>	-0.03	-0.62	-1.00**	-0.37**	-4.68***
Combinaisons de prévisions										
AVRG	0.32*	0.12***	0.08*	0.07**	0.07*	0.37*	0.14**	0.09*	0.06*	0.05*
Médiane	0.27**	0.11**	0.07**	0.06*	0.06*	0.31**	0.10**	0.05*	0.05*	0.06
T-AVRG,0.1	0.31**	0.12**	0.08**	0.07**	0.06*	0.34*	0.12**	0.07*	0.06*	0.06
T-AVRG,0.2	0.30**	0.11***	0.08**	0.06**	0.06*	0.33*	0.10**	0.06*	0.06*	0.06
IP-AVRG,1	0.34*	0.13**	0.08*	0.08**	0.07*	0.37*	0.14**	0.09*	0.06*	0.06
IP-AVRG,0.95	0.34*	0.13**	0.08*	0.08**	0.07*	0.37*	0.14**	0.10*	0.06*	0.07

TABLE 50: Taux de change - USD/CAD : Pseudo- R^2

Modèles	CAN					CAN+US				
	h=1	h=2	h=4	h=6	h=8	h=1	h=2	h=4	h=6	h=8
Modèles de référence										
AR,BIC	0.03	-0.13*	-0.09	-0.06	-0.03	<u>0.03</u>	-0.13*	-0.09	-0.06	-0.03
ARDI,BIC	-0.02	-0.14*	-0.06	-0.02	-0.07**	-0.11	-0.26*	0.01	0.02	-0.13**
Régressions pénalisées										
Ridge	0.01	-0.01	0.01	0.01**	0.00	0.00	-0.11	0.01	0.01**	-0.04
Lasso	0.00	-0.08	0.03	-0.01	0.00	-0.03	-0.11	0.01	0.04**	-0.03
Elastic-Net	0.00	-0.01	0.01	0.01**	0.00	0.00	-0.01	0.01	0.01**	0.00
Adaptive-Lasso	0.01	-0.04	0.00	<u>0.04</u>	0.00	0.00	-0.07	-0.01	<u>0.05</u>	0.01
ARDI,Ridge	0.00	-0.01	0.01	0.01**	0.00	-0.01	-0.01	0.01	0.01**	0.00
ARDI,Lasso	-0.07	-0.01	<u>0.04</u> *	0.01*	0.00	0.00	-0.01	-0.03	-0.02	-0.11
ARDI,Elastic-Net	0.00	-0.01	0.01	0.01**	0.00	0.00	-0.01	0.01	0.01**	0.00
ARDI,Adaptive-Lasso	-0.01	-0.05*	0.00	0.01	0.00	-0.27	-0.26	-0.03	-0.01	-0.17**
Ridge-MAF	-0.01	-0.02	0.00	-0.01	-0.01	-0.01	-0.02	0.00	0.00	-0.01
LASSO-MAF	0.00	0.00	0.00	-0.01*	-0.01	0.00	0.00	0.00	-0.01*	0.00
ELAS-MAF	0.00	-0.01	0.00	-0.01*	0.00	0.00	-0.01*	0.00	-0.01*	0.00
Régressions régularisées par sous-ensembles complets										
T-CSR10	-0.18*	-0.10	-0.12	-0.08	-0.23**	-0.14**	-0.17*	-0.04	-0.07	-0.18*
T-CSR20	0.00	0.02*	0.02	0.01	-0.01	-0.01	-0.02	0.00	0.02**	-0.02
CSR-R10	0.00	0.00	0.00	0.02	-0.02	-0.01	-0.02	0.00	0.03***	-0.02
CSR-R20	0.02	-0.05	-0.07	-0.05	-0.02*	-0.12	-0.07*	-0.04	-0.11	-0.15***
Régressions à vecteurs de support										
NL-SVRARDI	-0.10	-0.09	-0.06	-0.03	-0.16*	-0.08*	-0.11*	-0.03	-0.03	-0.14*
L-SVRARDI	-0.19**	-0.12*	-0.01	-0.02	-0.11**	-0.10*	-0.16*	-0.10	-0.16**	-0.22***
Forêts d'arbres aléatoires										
RFARDI	-0.01	-0.10	0.02	-0.01	-0.07**	-0.06	-0.08	0.00	0.00	-0.08***
RF-X	0.00	-0.03	0.00	-0.05*	-0.01	0.00	-0.04	0.02	-0.01	-0.02
RF-CSF	-0.06	-0.09	-0.02	-0.18**	-0.07*	-0.07	-0.12	-0.06	-0.17*	-0.10*
RF-MAF	-0.04	-0.07	0.03	-0.10**	-0.03	-0.03	-0.05	<u>0.06</u>	-0.07	0.00
RF-X-CSF	-0.01	-0.04	0.01	-0.03	-0.02	0.00	-0.02	0.02	0.00	-0.03
LLF-CSF	-0.01	-0.08	0.01	-0.04	-0.11**	-0.05	-0.05	0.01	-0.07	-0.08**
ARERT	<u>0.05</u>	-0.13**	-0.23**	-0.44**	-0.14**	-0.05	-0.25**	-0.12*	-0.09	-0.15**
ARDIERT	-0.07	-0.49*	-0.36**	-0.15**	-0.19**	-0.03	-0.20*	-0.30**	-0.14*	-0.07
EOTB-ERT	0.00	-0.19*	0.03	-0.10**	-0.14***	-0.07*	-0.15**	0.03	-0.20***	0.02
ARRF	-0.07	-0.13*	-0.09*	-0.38**	-0.11**	-0.08	-0.11**	-0.11*	-0.48**	-0.16**
ARDIRF	-0.14	-0.48*	-0.24**	-0.17**	-0.07	-0.30	-0.48**	-0.17**	-0.15**	-0.08**
EOTB-MRF	-0.07*	-0.12*	-0.10	-0.09**	-0.19**	-0.05	-0.22**	-0.01	-0.08**	-0.03
ERT-MAF	-0.03	-0.06	0.00	-0.09**	-0.03	-0.04	-0.05	0.00	-0.06	-0.01
Réseau de neurones										
LSTM-Dense-AR	0.02	0.00	-0.01	-0.01	0.01	0.02	0.00	-0.01	-0.01	0.01
LSTM-AR	-0.02	-0.01	0.00	0.01*	0.03***	-0.02	-0.01	0.00	0.01*	<u>0.03***</u>
Dense-AR	-0.14*	-0.21***	-0.10	-0.02	0.02	-0.14*	-0.21***	-0.10	-0.02	0.02
LSTM-Dense-ARDI	0.01	0.00	-0.01	-0.02	0.00	0.02	-0.04	0.01	0.02	-0.01
LSTM-ARDI	0.01	-0.01	0.02	-0.01	0.01	0.01	-0.05	0.02	0.01	0.01
Dense-ARDI	-0.10	-0.02	-0.01	-0.11*	-0.06	-0.03	<u>0.02</u>	-0.03	-0.12**	-0.04
LSTM-Dense	0.02	-0.05*	-0.09	-0.04*	-0.01	-0.05**	-0.07	-0.03**	0.01	0.02
LSTM	0.01	-0.01	0.00	0.00	-0.01	-0.04	0.00	0.04**	-0.01	0.00
Dense	-0.08**	<u>0.04</u> *	-0.36**	-0.01	<u>0.04</u>	0.01	0.02	-0.02	0.04**	-0.04
Combinaisons de prévisions										
AVRG	0.02	-0.04	0.00	-0.01	-0.01	0.00	-0.06	0.00	-0.01	-0.02
Médiane	0.02	-0.01	0.00	0.00	0.00	0.01	-0.01	0.00	0.01	-0.02
T-AVRG,0.1	0.02	-0.02	0.00	-0.01	-0.01	0.01	-0.04	0.00	-0.01	-0.02
T-AVRG,0.2	0.02	-0.02	0.00	-0.01	-0.01	0.01	-0.04	0.00	-0.01	-0.02
IP-AVRG,1	0.02	-0.04	0.00	-0.01	-0.01	0.00	-0.06	0.00	-0.01	-0.02
IP-AVRG,0.95	0.02	-0.04	0.00	-0.01	-0.01	0.00	-0.06	0.00	-0.01	-0.02

B Prévisions

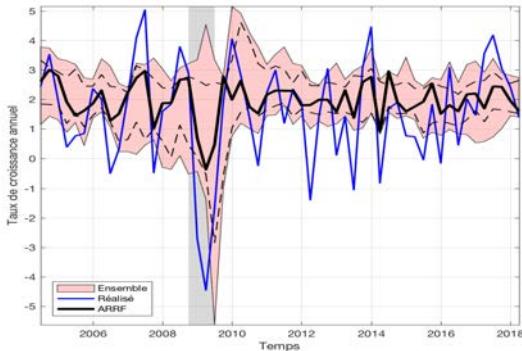
Les figure 11 et 12 montrent les prévisions 1 trimestre en avance pour toutes les 16 variables d'intérêt. La zone grise, intitulée Ensemble, illustre toutes les prévisions pour chaque période hors échantillon. La prédiction du meilleur modèle, selon EQM, est présentée en noir. Les pointillés dans la Ensemble représentent les 5^{ième} et 95^{ième} percentiles de toutes les prévisions.

Analysons par exemple le cas du PIB du Québec, à la figure 11a. Le meilleur modèle, ARRF, suit relativement bien l'évolution du taux de croissance du PIB, surtout jusqu'à 2011. Durant la récession en 2009, ce modèle n'est pas capable de générer une baisse considérable. Par contre, en regardant l'ensemble des prévisions, nous remarquons que plusieurs modèles enregistrent des prédictions très proches de la réalisation durant cette récession. De plus, la dispersion des prévisions augmente pendant la récession, témoignant une hausse de l'incertitude macroéconomique. Entre 2011 et 2016, tous les modèles ont tendance à sur-estimer la croissance de l'économie québécoise. Cette situation semble changer durant la dernière année de l'échantillon.

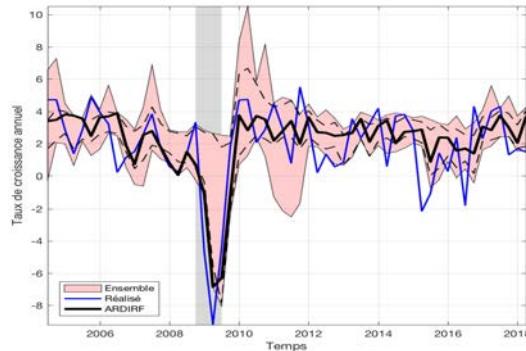
Dans le cas du PIB canadien, figure 11b, on remarque que le meilleur modèle suit l'évolution de la réalisation plus étroitement, et surtout durant la récession. Contrairement au cas précédent, il y a un peu plus de dispersion dans les prévisions entre 2010 et 2012, mais cela est probablement dû à quelques valeurs extrêmes puisque l'intervalle 5-95 reste plutôt étroit. Plusieurs modèles génèrent des baisses du taux de croissance en 2015 et 2016 lors de la chute des prix de pétrole.

En général, les figures montrent que la plupart des modèles suivent assez bien l'évolution des variables d'activité économique québécoise et canadienne. Toutefois, il y a de temps à autre des valeurs extrêmes, et il est donc important de superviser les modèles continument. Il est également une bonne pratique de surveiller la distribution de l'ensemble des prévisions car la dispersion semble corrélée avec le cycle économique.

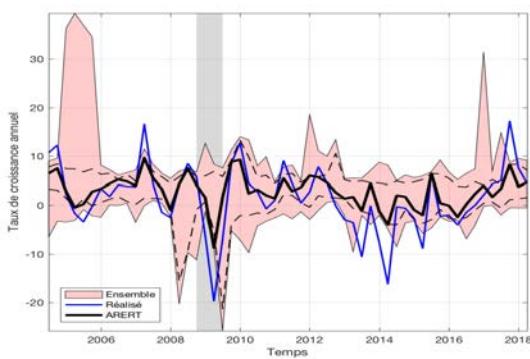
FIGURE 11: Prévision un trimestre en avance



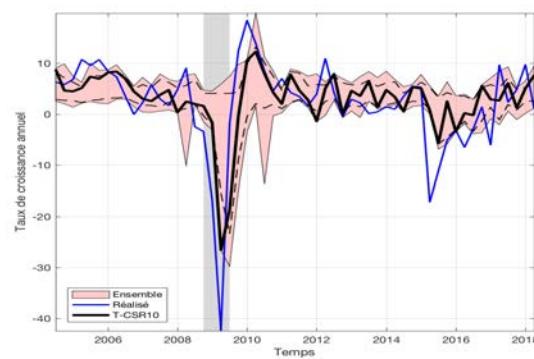
(a) PIB Québec



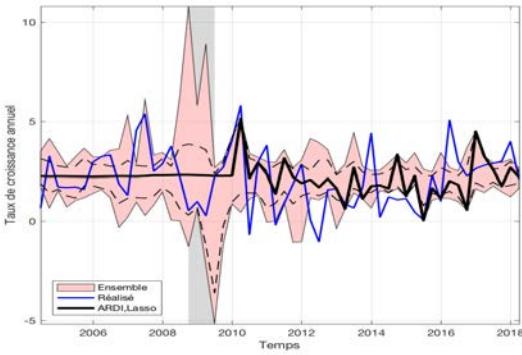
(b) PIB Canada



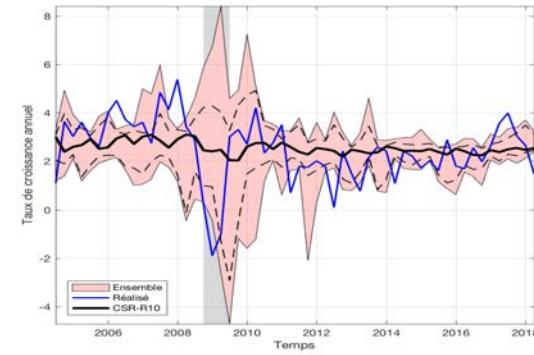
(c) Investissement Québec



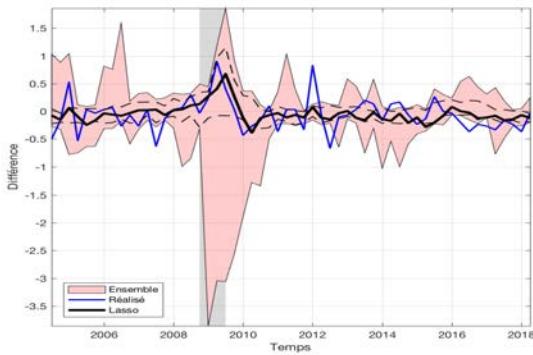
(d) Investissement Canada



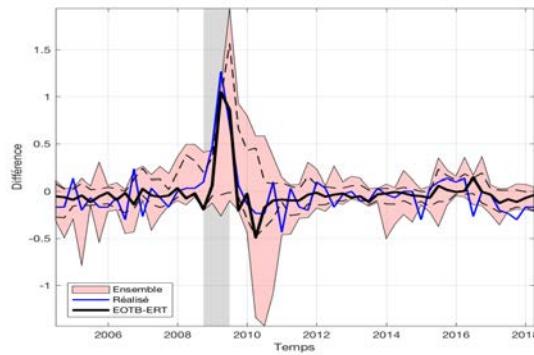
(e) Consommation Québec



(f) Consommation Canada

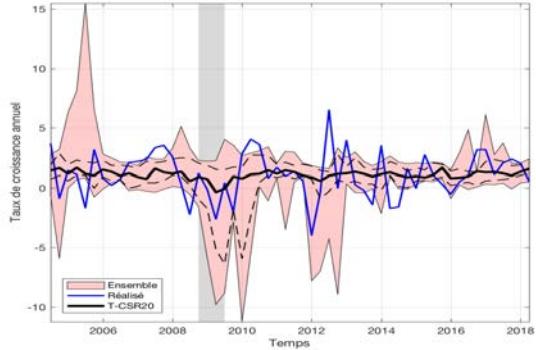


(g) Taux de chômage Québec

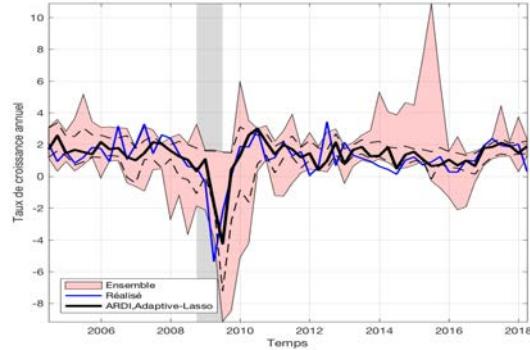


(h) Taux de chômage Canada

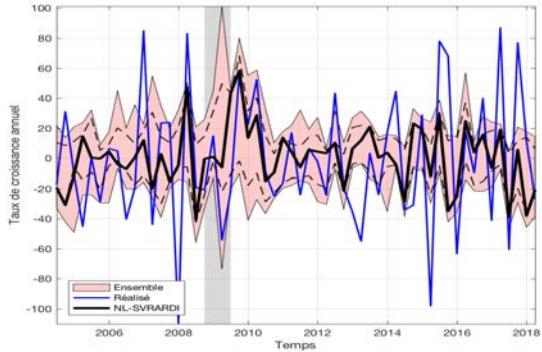
FIGURE 12: Prévision un trimestre en avance, cont.



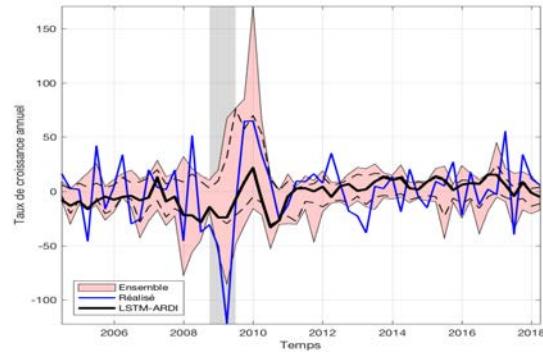
(a) Emploi Québec



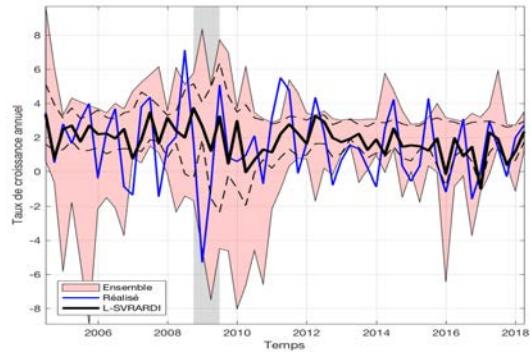
(b) Emploi Canada



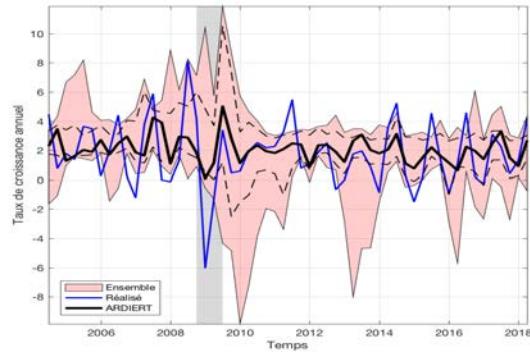
(c) Mises en chantier Québec



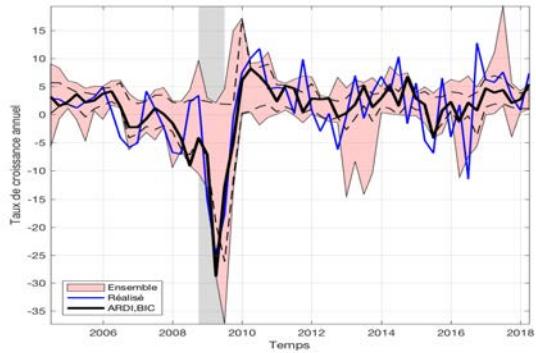
(d) Mises en chantier Canada



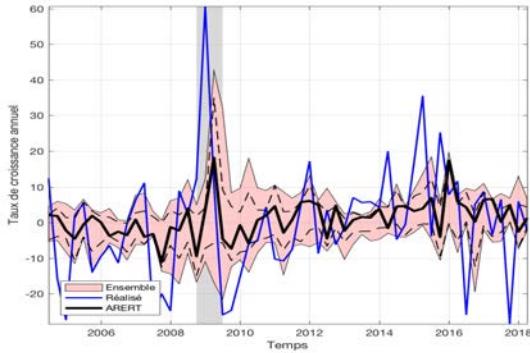
(e) Inflation Québec



(f) Inflation Canada



(g) Production industrielle



(h) Taux de change USD/CAD

Références

- Bai, J. et Ng, S. (2008). Forecasting economic time series using targeted predictors. *Journal of Econometrics*, 146, 304–317.
- Bates, B. J. et Granger, C. W. J. (1969). The combination of forecasts. *Operational Research Society*, 20(4), 451–468.
- Bergmeir, C., Hyndman, R. J. et Koo, B. (2018). A note on the validity of cross-validation for evaluating autoregressive time series prediction. *Computational Statistics and Data Analysis*, 120, 70–83.
- Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5–32.
- Chen, J., Dunn, A., Hood, K., Driessen, A. et Batch, A. (2019). *Off to the Races : A Comparison of Machine Learning and Alternative Data for Predicting Economic Indicators*. Rapport technique, Bureau of Economic Analysis.
- Chevillon, G. (2007). Direct multi-step estimation and forecasting. *Journal of Economic Surveys*, 21(4), 746–785.
- Chung, J., Gulcehre, C., Cho, K. et Bengio, Y. (2014). *Empirical evaluation of gated recurrent neural networks on sequence modeling*. Rapport technique.
- Colombo, E. et Pelagatti, M. (2020). Statistical learning and exchange rate forecasting. *International Journal of Forecasting*. <http://dx.doi.org/https://doi.org/10.1016/j.ijforecast.2019.12.007>
- Cook, T. R. et Hall, S. H. (2017). *Macroeconomic Indicator Forecasting with Deep Neural Networks*. Rapport technique, Federal Reserve Bank of Kansas City.
- Diebold, F. X. et Mariano, R. S. (1995). Comparing predictive accuracy. *Journal of Business and Economic Statistics*, 13, 253–263.
- Diebold, F. X. et Pauly, P. (1987). Structural change and the combination of forecasts. *Journal of Forecasting*, 6, 21–40.
- Döpke, J., Fritzsche, U. et Pierdzioch, C. (2017). Predicting recessions with boosted regression trees. *International Journal of Forecasting*, 33(4), 745–759.
- Driscoll, J. C. et Kraay, A. C. (1998). Consistent covariance matrix estimation with spatially dependent panel data. *The Review of Economics and Statistics*, 80(4), 549–560.
- Elliott, G., Gargano, A. et Timmermann, A. (2013). Complete subset regressions. *Journal of Econometrics*, 177(2), 357–373.
- Fortin-Gagnon, O., Leroux, M., Stevanovic, D. et Surprenant, S. (2018). *A Large Canadian Database for Macroeconomic Analysis*. Rapport technique, Department of Economics, UQAM.
- Friedberg, R., Tibshirani, J., Athey, S. et Wager, S. (2018). Local linear forests. *arXiv preprint arXiv:1807.11408*.

- Galbraith, J. (2003). Content horizons for univariate time series forecasts. *International Journal of Forecasting*, 19(1), 43–55.
- Geurts, P., Ernst, D. et Wehenkel, L. (2006). Extremely randomized trees. *Machine learning*, 63(1), 3–42.
- Giannone, D., Lenza, M. et Primiceri, G. (2017). *Macroeconomic Prediction with Big Data : the Illusion of Sparsity*. Rapport technique, Federal Reserve Bank of New York.
- Goulet-Coulombe, P. (2020). The macroeconomy as a random forest.
- Goulet-Coulombe, P., Leroux, M., Stevanovic, D. et Surprenant, S. (2019). *How is Machine Learning Useful for Macroeconomic Forecasting ?* Rapport technique, CIRANO Working Papers, 2019s-22.
- Gu, S., Kelly, B. T. et Xiu, D. (2019). *Empirical Asset Pricing via Machine Learning*. Rapport technique, Chicago Booth Research Paper No. 18-04. Forthcoming in *Review of Financial Studies*.
- Hansen, P., Lunde, A. et Nason, J. (2011). The model confidence set. *Econometrica*, 79(2), 453–497.
- Hastie, T., Tibshirani, R. et Friedman, J. (2017). *The Elements of Statistical Learning*. Springer Series in Statistics. New York : Springer-Verlag.
- Hendry, D. F. et Clements, M. P. (2004). Pooling of forecasts. *The Econometrics Journal*, 7(1).
- Hochreiter, S. et Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780.
- Hoerl, A. E. et Kennard, R. W. (1970). Ridge regression : Biased estimation for nonorthogonal problems. *Technometrics*, 12(1), 55–67.
- Joseph, A. (2019). *Shapley regressions : a framework for statistical inference on machine learning models*. Rapport technique, Bank of England, Staff Working Paper No. 784.
- Kapetanios, G. et Marcellino, M. (2006). *Factor-GMM Estimation with Large Sets of Possibly Weak Instruments*. Rapport technique, Department of Economics, Queen Mary University of London, London, U.K.
- Kim, H. H. et Swanson, N. R. (2018). Mining big data using parsimonious factor, machine learning, variable selection and shrinkage methods. *International Journal of Forecasting*, 34(2), 339–354.
- Kotchoni, R., Leroux, M. et Stevanovic, D. (2019). Macroeconomic forecast accuracy in a data-rich environment. *Journal of Applied Econometrics*, 34.
- McCracken, M. W. et Ng, S. (2016). Fred-md : A monthly database for macroeconomic research. *Journal of Business and Economic Statistics*, 34(4), 574–589.
- McCracken, M. W. et Ng, S. (2020). *FRED-QD : A Quarterly Database for Macroeconomic Research*. Rapport technique, NBER Working Paper No. 26872.
- Medeiros, M. C., Vasconcelos, G. F. R., Veiga, A. et Zilberman, E. (2019). Forecasting inflation in a data-rich environment : The benefits of machine learning methods. *Journal of Business and Economic Statistics*, 0(0), 1–22.

- Milunovich, G. (2019). *Forecasting Australian Real House Price Index : A Comparison of Time Series and Machine Learning Methods*. Rapport technique, Maquarie University.
- Mullainathan, S. et Spiess, J. (2017). Machine learning : An applied econometric approach. *Journal of Economic Perspectives*, 31(2), 574–589.
- Nakamura, E. (2005). Inflation forecasting using a neural network. *Economics Letters*, 86(3), 373–378.
- Ng, S. (2014). Boosting recessions. *Canadian Journal of Economics*, 47(1), 1–34.
- Pesaran, H. et Timmermann, A. (1992). A simple nonparametric test of predictive performance. *Journal of Business and Economic Statistics*, 10(4), 461–465.
- Qiu, Y., Xie, T. et Yu, J. (2020). *Forecast combinations in machine learning*. Rapport technique, School of Economics, Singapore Management University.
- Satchell, S. et Timmermann, A. (1995). An assessment of the economic value of non-linear foreign exchange rate forecasts. *Journal of Forecasting*, 14(6), 477–497.
- Sermpinis, G., Stasinakis, C., Theolatos, K. et Karathanasopoulos, A. (2014). Inflation and unemployment forecasting with genetic support vector regression. *Journal of Forecasting*, 33(6), 471–487.
- Smola, A. J. et Schölkopf, B. (2004). A tutorial on support vector regression. *Statistics and computing*, 14(3), 199–211.
- Stock, J. et Watson, M. (1999). *A Comparison of Linear and Nonlinear Univariate Models for Forecasting Macroeconomic Time Series*, Dans R. Engle et H. White (dir.). *Cointegration, Causality and Forecasting : A Festschrift for Clive W.J. Granger*, (p. 1–44). Oxford University Press : Oxford
- Stock, J. H. et Watson, M. W. (2002a). Forecasting using principal components from a large number of predictors. *Journal of the American Statistical Association*, 97, 1167–1179.
- Stock, J. H. et Watson, M. W. (2002b). Macroeconomic forecasting using diffusion indexes. *Journal of Business and Economic Statistics*, 20(2), 147–162.
- Stock, J. H. et Watson, M. W. (2004). Combination forecasts of output growth in a seven-country data set. *Journal of Forecasting*, 23, 405–430.
- Swanson, N. R. et White, C. H. (1997). A model selection approach to real-time macroeconomic forecasting using linear models and artificial neural networks. *The Review of Economics and Statistics*, 79(4), 540–550.
- Tashman, L. J. (2000). Out-of-sample tests of forecasting accuracy : an analysis and review. *International Journal of Forecasting*, 16(4), 437–450.
- Teräsvirta, T. (2006). Forecasting economic variables with nonlinear models. In A. T. Graham Elliott, Clive Granger (dir.), *Handbook of Economic Forecasting*, volume 1 413–457. Elsevier.
- Tibshirani, R. (1996). Regression shrinkage and selection via the lasso. *Journal of the Royal Statistical Society. Series B*, 58(1), 267–288.

- Zou, H. et Hastie, T. (2004). Regularization and variable selection via the Elastic Net. *Journal of the Royal Statistical Society. Series B*, 67(2), 301–320.
- Zou, H. et Hastie, T. (2006). The Adaptive Lasso and its oracle properties. *Journal of the American Statistical Association*, 101(476), 1418–1429.