HEC MONTRÉAL

affiliée à l'Université de Montréal

Prévision de l'écart des prix de l'électricité entre le marché de la veille et le temps réel : Cas du *Midcontinent Independent System Operator* (MISO)

présenté par **Azza RHAIEM** en vue de l'obtention du diplôme de *Maîtrise ès sciences appliquées* en Ingénierie financière

Février 2023

Directeur de recherche : Christian Dorion Codirectrice de recherche : Geneviève Gauthier

Février 2023

© Azza Rhaiem, 2023.

REMERCIEMENTS

Tout d'abord, je tiens à exprimer mes remerciements et ma profonde gratitude envers mes superviseurs Professeure Geneviève Gauthier et Professeur Christian Dorion. De part leur précieuse collaboration, leurs confiance et leur patience, ce projet a aboutit à sa fin.

Je souhaiterais également remercier tous les enseignants que j'ai eu l'occasion de croiser durant mon parcours à HEC Montréal. Leurs efforts à créer un environnement propice à l'apprentissage ont contribué à rendre mon expérience à HEC fort positive. Je remercie de même les membres du jury qui ont accepté d'évaluer mon travail.

Ce projet est le fruit d'une collaboration avec les négociants du parquet d'Hydro-Québec que je tiens à remercier chaleureusement pour leurs encouragements.

Finalement, je souhaiterais exprimer ma reconnaissance à ma famille pour leur soutien indéfectible.

RÉSUMÉ

Nous proposons des modèles d'apprentissage automatique et d'apprentissage profond pour prédire le DART (différence entre le prix *day-ahead* et le prix *real-time*) sur l'un des marchés nord américain de l'électricité. Les positions prises sur le marché *day-ahead* doivent être compensées par des positions inverses sur le marché *real-time*. Les négociants se trouvent ainsi exposés à des risques de pertes ou à des primes positives égaux au DART. Le défi que nous tentons de relever lors de la prévision du DART est dû d'une part à sa volatilité et d'autre part à la présence des pics.

L'exercice est effectué pour le *Midcontinent Independent System Operator* (MISO). La performance du modèle et les résultats générés par ce projet portent sur les séries de données relatives à huit *hubs* de MISO. Une analyse du comportement volatile des prix prouve l'existence de pics (*spikes*) au niveau du DART. Ceci nous amène à apporter une définition de ces *spike* et d'envisager des méthodes de traitement de ces données. Dans la quête d'un meilleur pouvoir de prédiction, les variables explicatives tiennent compte à la fois de la tendance passée du marché, des prévisions futures des conditions du marché mais aussi de ses particularités (telles que le comportement saisonnier des prix).

La valeur ajoutée de tels modèles est mise en exergue en recourant à différents exercices de négociation sur la période test soit de septembre 2021 à juillet 2022. Les prévisions s'avèrent être robustes et génèrent des profits significatifs.

Mots-clés: Marché de l'électricité, MISO, *spikes*, prévision du DART, forêts aléatoires, Light GBM, réseau de neurones profond

TABLE DES MATIÈRES

REMERCIEMENTS	ii
RÉSUMÉ	iii
TABLE DES MATIÈRES	iv
LISTE DES TABLEAUX	vi
LISTE DES FIGURES	viii
LISTE DES ANNEXES	xi
CHAPITRE 1 INTRODUCTION 1.1 Objectifs de recherche . 1.2 Plan du mémoire .	1 2 3
CHAPITRE 2 REVUE DE LITTÉRATURE	4
 CHAPITRE 3 DONNÉES ET MÉTHODOLOGIE 3.1 Description du marché et de son fonctionnement	10 10 12 18
CHAPITRE 4 MODÈLES DE PRÉVISION 4.1 Description des modèles 4.2 Optimisation des hyper-paramètres	21 21 23
CHAPITRE 5 RÉSULTATS 5.1 Performance statistique des modèles	26 26 28 33
CHAPITRE 6 CONCLUSION	44
6.1 Synthese des travaux	$\frac{44}{45}$
RÉFÉRENCES	46

ANNEXES				 			•	•					•	•		•					5	0

v

LISTE DES TABLEAUX

Tableau 3.1	Comparison of Virtual Trading Volumes and Profitability 2021 \ldots	12
Tableau 3.2	Statistiques descriptives de la variable DART historique	13
Tableau 3.3	Statistiques descriptives des $spikes$ négatifs à un seuil de -\$30/MWh .	16
Tableau 3.4	Statistiques descriptives portant sur les <i>spikes</i> positifs à un seuil de	
	\$30/MWh	16
Tableau 3.5	Seuils à considérer pour les $spikes$ positifs et négatifs selon le score Z	18
Tableau 3.6	Répartition des variables explicatives utilisées pour la prévision du DART	18
Tableau 4.1	Résultats de l'optimisation des hyperparamètres pour le modèle de	
	forêts aléatoires	24
Tableau 4.2	Résultats de l'optimisation des hyperparamètres pour le Light GBM .	24
Tableau 4.3	Résultats de l'optimisation des hyperparamètres pour le réseau de neu-	
	rones	25
Tableau 4.4	Résultats de l'optimisation des hyperparamètres pour le réseau de neu-	
	rones (Illinois) \ldots	25
Tableau 4.5	Résultats de l'optimisation des hyperparamètres pour le réseau de neu-	
	rones (Louisiana) \ldots	25
Tableau 5.1	RMSE in sample pour Indiana hub	27
Tableau 5.2	RMSE out of sample pour Indiana hub	27
Tableau 5.3	Score de vraisemblance du signe de la prévision des modèles par rapport	
	au signe du DART réel	28
Tableau 5.4	Performance des trois modèles pour la stratégie <i>price taker</i>	41
Tableau 5.5	Performance des trois modèles pour la stratégie de vente	42
Tableau 5.6	Performance des trois modèles pour la stratégie de vente conditionnelle	42
Tableau 5.7	Performance de la stratégie de vente naïve	43
Tableau A.1	RMSE in sample pour Illinois hub	57
Tableau A.2	RMSE out of sample pour Illinois hub	57
Tableau A.3	RMSE in sample pour Louisiana hub	58
Tableau A.4	RMSE out of sample pour Louisiana hub	58
Tableau A.5	RMSE in sample pour Michigan hub	59
Tableau A.6	RMSE out of sample pour Michigan hub	59
Tableau A.7	RMSE in sample pour Minnesota hub	60
Tableau A.8	RMSE out of sample pour Minnesota hub	60
Tableau A.9	RMSE in sample pour Mississippi hub	61

Tableau A.10	RMSE out of sample pour Mississippi hub	61
Tableau A.11	RMSE in sample pour Arkansas hub	62
Tableau A.12	RMSE out of sample pour Arkansas hub	62

LISTE DES FIGURES

Figure 3.1	Carte géographique représentative du marché MISO	11
Figure 3.2	Séries historiques des prix DA, prix RT et DART pour Indiana hub	14
Figure 3.3	Proportion des <i>spikes</i> négatifs selon les heures et les mois \ldots \ldots	17
Figure 5.1	Importance des variables explicatives pour Indiana hub	32
Figure 5.2	Résultat mensuel cumulatif généré par la stratégie $price\ taker$	35
Figure 5.3	Résultat mensuel cumulatif généré par la stratégie de vente	36
Figure 5.4	Résultat mensuel cumulatif généré par la stratégie de vente condi-	
	tionnelle à un seuil de $4/MWh$	37
Figure 5.5	Résultat mensuel cumulatif généré par la stratégie de vente naïve .	38
Figure 5.6	Comparaison entre la stratégie $price\ taker$ et la stratégie de vente	
	naïve	38
Figure 5.7	Résultat mensuel cumulatif généré par la stratégie d'achat $\ .\ .\ .$	39
Figure 5.8	Résultats générés par la stratégie d'achat naïf	40
Figure A.1	Séries historiques des prix DA, prix RT et DART pour Illinois hub .	50
Figure A.2	Séries historiques des prix DA, prix RT et DART pour Arkansas hub	51
Figure A.3	Séries historiques des prix DA, prix RT et DART pour Louisian a hub	52
Figure A.4	Séries historiques des prix DA, prix RT et DART pour Minnesota hub	53
Figure A.5	Séries historiques des prix DA, prix RT et DART pour Michigan hub	54
Figure A.6	Séries historiques des prix DA, prix RT et DART pour Mississippi hub	55
Figure A.7	Séries historiques des prix DA, prix RT et DART pour Texas hub .	56
Figure A.8	Importance des variables explicatives pour Illinois hub	63
Figure A.9	Importance des variables explicatives pour Louisiana hub	64
Figure A.10	Importance des variables explicatives pour Michigan hub	65
Figure A.11	Importance des variables explicatives pour Texas hub	66
Figure A.12	Importance des variables explicatives pour Minnesota hub	67
Figure A.13	Importance des variables explicatives pour Mississippi hub $\ .$	68
Figure A.14	Importance des variables explicatives pour Arkansas hub	69
Figure A.15	Shap values des trois modèles testés pour Indiana hub $\ldots\ldots\ldots\ldots$	70
Figure A.16	Shap values des trois modèles testés pour Illinois hub $\ldots\ldots\ldots\ldots$	71
Figure A.17	Shap values des trois modèles testés pour Louisiana hub \ldots	72
Figure A.18	Shap values des trois modèles testés pour Michigan hub $\ .\ .\ .\ .$	73
Figure A.19	Shap values des trois modèles testés pour Texas hub \ldots	74
Figure A.20	Shap values des trois modèles testés pour Minnesota hub	75

Figure A.21	Shap values des trois modèles testés pour Mississippi hub	76
Figure A.22	Shap values des trois modèles testés pour Arkansas hub $\ldots\ldots\ldots\ldots$	77
Figure A.23	Profits journaliers de la stratégie $price\ taker$ pour Indiana hub	78
Figure A.24	Profits journaliers de la stratégie $price \ taker$ pour Illinois hub	78
Figure A.25	Profits journaliers de la stratégie $price\ taker$ pour Louisiana hub	79
Figure A.26	Profits journaliers de la stratégie $price\ taker$ pour Michigan hub	79
Figure A.27	Profits journaliers de la stratégie $price\ taker$ pour Texas hub \ldots .	80
Figure A.28	Profits journaliers de la stratégie $price\ taker$ pour Minnesota hub	80
Figure A.29	Profits journaliers de la stratégie $price\ taker$ pour Mississippi hub .	81
Figure A.30	Profits journaliers de la stratégie $price\ taker$ pour Arkansas hub	81
Figure A.31	Profits journaliers de la stratégie de vente pour Indiana hub	82
Figure A.32	Profits journaliers de la stratégie de vente pour Illinois hub	82
Figure A.33	Profits journaliers de la stratégie de vente pour Louisiana hub $\ .$.	83
Figure A.34	Profits journaliers de la stratégie de vente pour Michigan hub	83
Figure A.35	Profits journaliers de la stratégie de vente pour Texas hub	84
Figure A.36	Profits journaliers de la stratégie de vente pour Minnesota hub	84
Figure A.37	Profits journaliers de la stratégie de vente pour Mississippi hub	85
Figure A.38	Profits journaliers de la stratégie de vente pour Arkansas hub	85
Figure A.39	Profits journaliers de la stratégie de vente conditionnelle pour Indiana	
	hub	86
Figure A.40	Profits journaliers de la stratégie de vente conditionnelle pour Illinois	
	hub	86
Figure A.41	Profits journaliers de la stratégie de vente conditionnelle pour Loui-	
	siana hub	87
Figure A.42	Profits journaliers de la stratégie de vente conditionnelle pour Michi-	
	gan hub	87
Figure A.43	Profits journaliers de la stratégie de vente conditionnelle pour Texas	
	hub	88
Figure A.44	Profits journaliers de la stratégie de vente conditionnelle pour Min-	
	nesota hub	88
Figure A.45	Profits journaliers de la stratégie de vente conditionnelle pour Missis-	
	sippi hub	89
Figure A.46	Profits journaliers de la stratégie de vente conditionnelle pour Arkan-	
	sas hub	89
Figure A.47	Profits journaliers de la stratégie de vente naïve pour Indiana hub .	90
Figure A.48	Profits journaliers de la stratégie de vente naïve pour Illinois hub	90

Figure A.49	Profits journaliers de la stratégie de vente naïve pour Louisiana hub	91
Figure A.50	Profits journaliers de la stratégie de vente naïve pour Michigan hub	91
Figure A.51	Profits journaliers de la stratégie de vente naïve pour Texas hub	92
Figure A.52	Profits journaliers de la stratégie de vente naïve pour Minnesota hub	92
Figure A.53	Profits journaliers de la stratégie de vente naïve pour Mississippi hub	93
Figure A.54	Profits journaliers de la stratégie de vente naïve pour Arkansas hub	93
Figure A.55	Profits journaliers de la stratégie d'achat pour Indiana hub	94
Figure A.56	Profits journaliers de la stratégie d'achat pour Illinois hub	94
Figure A.57	Profits journaliers de la stratégie d'achat pour Louisiana hub	95
Figure A.58	Profits journaliers de la stratégie d'achat pour Michigan hub $\ .$	95
Figure A.59	Profits journaliers de la stratégie d'achat pour Texas hub	96
Figure A.60	Profits journaliers de la stratégie d'achat pour Minnesota hub	96
Figure A.61	Profits journaliers de la stratégie d'achat pour Mississippi hub $\ .$.	97
Figure A.62	Profits journaliers de la stratégie d'achat pour Arkansas hub \ldots .	97
Figure A.63	Profits journaliers de la stratégie d'achat naïf pour Indiana hub	98
Figure A.64	Profits journaliers de la stratégie d'achat naïf pour Illinois hub	98
Figure A.65	Profits journaliers de la stratégie d'achat naïf pour Louisiana hub . $\ .$	99
Figure A.66	Profits journaliers de la stratégie d'achat naïf pour Michigan hub .	99
Figure A.67	Profits journaliers de la stratégie d'achat naïf pour Texas hub	100
Figure A.68	Profits journaliers de la stratégie d'achat naïf pour Minnesota hub .	100
Figure A.69	Profits journaliers de la stratégie d'achat naïf pour Mississippi hub .	101
Figure A.70	Profits journaliers de la stratégie d'achat naïf pour Arkansas hub .	101

LISTE DES ANNEXES

Annexe A		
----------	--	--

CHAPITRE 1 INTRODUCTION

La libéralisation des marchés de l'énergie a été entreprise dans un bon nombre de juridictions à travers l'Amérique du Nord et ailleurs dans le monde. Cette déréglementation a induit une restructuration des marchés. Les acheteurs et vendeurs de l'électricité ne sont pas appariés directement; ces marchés sont opérés par des *Independent System Operator* (ISO) ou des *Regional Transmission Organization* (RTO).

Le Midcontinent Independent System Operator (MISO) est l'entité responsable de la gestion du marché de l'énergie sur 15 États américains¹ et la province du Manitoba. Il est organisé en deux instances : un marché day-ahead (DA) et un marché real-time (RT). Le marché DA permet aux négociants la planification et la soumission des opérations d'achat et de vente de l'électricité, heure par heure, pour le lendemain, et ce compte tenu de leurs anticipations des conditions du marché. Parallèlement, sur le marché RT, les négociants adaptent leur positions suite à l'ajustement des prix par rapport aux conditions réelles du système.

La détermination des prix horaires DA et RT lui incombe. Chaque prix représente le coût d'un MWh supplémentaire (coût marginal) à un lieu précis (Locational Based Marginal Price (LBMP)) et se décompose comme suit : (1) équilibre entre offre et demande, (2) coût de la congestion² et (3) pertes. En temps réel, le prix se trouve affecté par plusieurs facteurs imprévisibles tels que la météo, la demande réelle en électricité non-prévue, la production effective (générée par les unités éoliennes, nucléaires ou solaires) ou encore les bris et les dysfonctionnements au niveau du réseau de transmission. Le prix real-time s'avère donc très volatile et présente occasionnellement des pics à la hausse et à la baisse. Ceci explique l'écart au niveau des prix DA et RT qui est derrière la genèse des transactions virtuelles.

Une transaction virtuelle est un contrat financier dont le sous-jacent est l'écart des prix entre les marchés DA et RT. Cette différence est couramment appelée DART. Ces contrats fonctionnent comme suit : une position virtuelle d'achat ou de vente sur le marché DA doit être compensée par la position inverse sur une quantité identique de MWh sur le marché RT. Une position longue sur le marché DA expose son détenteur à un risque de perte si le DART

^{1.} Arkansas, Illinois, Indiana, Iowa, Kentucky, Louisiana, Michigan, Minnesota, Mississippi, Missouri, Montana, North Dakota, South Dakota, une section de Texas, Wisconsin

^{2.} Il y a congestion sur un réseau électrique lorsque les capacités physiques de transit sur certaines lignes sont atteintes. Il n'est donc plus possible d'augmenter les flux.

est négatif et permet inversement à la partie vendeur d'en tirer profit. Yinglun Li, Nanpeng Yu et al (2022) [1] démontrent la contribution majeure de ces contrats dans la convergence des prix DA vers les prix RT. Le caractère instable des prix fait en sorte que le DART présente des pics (*spikes*) significatifs. Sa distribution est également très variable. Ceci rend l'exercice d'analyse plus ardu. De plus, une prime positive est en moyenne associée au DART. Les pics à la baisse sont davantage problématiques du fait qu'ils induisent une prime négative et par suite des pertes pour les négociants.

La majorité des travaux de recherche s'est consacrée à l'analyse de la dynamique des prix *day-ahead*. Plusieurs techniques de prévision des prix furent examinées pour le faire. Nous en citons à titre d'exemple les transformations de Fourrier [1] (2014), des modèles ARIMA univariés : [3](2002), [6] (2004), [7](2004), [8](2006), des modèles GARCH [9](2005) ainsi que différents modèles de réseaux de neurones ([12](2005), [13](2004), [14] (2002)). Nous creusons plus en profondeur au niveau des méthodes de série temporelles et du *machine learning* au niveau de la revue de littérature.

1.1 Objectifs de recherche

Nous nous intéressons particulièrement aux transactions virtuelles. La présente étude se consacre à la prévision du DART pour huit *hubs* du marché MISO qui sont : Indiana, Illinois, Arkansas, Louisiana, Mississippi, Texas, Minnesota et Michigan. L'objectif général de cette recherche est d'aboutir à un modèle de *machine learning* pouvant cerner la volatilité du DART et son comportement non-linéaire. Ceci constitue un défi majeur en raison de l'ampleur et la rapidité de l'évolution du DART.

Cette problématique est abordée par l'intermédiaire de trois modèles supervisés de Machine Learning : (1) forêts aléatoires (Random forest), (2) Light Gradient Boosting Machine (Light GBM) et (3) réseau de neurones profond (Deep Neural Networks). Les variables explicatives utilisées dans la prévision peuvent être répertoriées sous trois classes. La première concerne les variables historiques qui permettent de capturer la tendance passée du marché de l'électricité et ses déterminants. La deuxième classe regroupe les prévisions futures telles que les prévisions de la demande, la prévision de l'indice du gaz au point Henry hub ou les prévisions des indices de températures HDD et CDD. Finalement, la troisième classe permet de refléter le caractère saisonnier du marché ainsi que l'effet temps grâce aux variables indicatrices.

Ce projet s'inscrit dans le cadre d'un stage dans le parquet des transactions énergétiques

d'Hydro-Québec. Ceci amène en vue un autre objectif. Il s'agit de proposer un modèle à forte valeur ajoutée économique comparativement à la stratégie intuitive³ utilisée par les négociants du parquet. Ceci est rendu possible par l'intermédiaire de quatre stratégies que nous testons sur l'ensemble de *backtesting*. Ces dernières s'avèrent être significativement profitables.

1.2 Plan du mémoire

Le reste de ce mémoire est structuré comme suit. La section II présente une brève revue de littérature portant sur les techniques d'estimation des prix de l'électricité. La troisième section contient une brève description du marché MISO et de son fonctionnement. On y trouve aussi la description des données utilisées, une analyse exploratoire de la variable DART et les hypothèses de traitement des données. La quatrième section expose les modèles de prévision utilisés. La cinquième section est consacrée à la présentation des résultats de cette recherche. On y trouve une discussion de la performance statistique et économique des modèles ainsi que la contribution des valeurs explicatives dans la prévision. Finalement, la sixième et dernière section est consacrée à la conclusion de ce mémoire.

^{3.} Il n'existe aucun modèle statistique ou de *machine learning* pour la prévision du DART sur MISO chez Hydro-Québec. Les négociants se basent sur leur propre intuition en surveillant la prévision de la demande en électricité, la météo et la congestion. D'où l'intérêt de recourir à une stagiaire pour travailler sur l'implémentation d'un modèle de prévision.

CHAPITRE 2 REVUE DE LITTÉRATURE

Les méthodes les plus utilisées pour l'estimation des prix DA et RT de l'électricité peuvent être réparties en deux grandes familles. La première comporte des modèles économiques multi-agents (*Agent-Based Models*). Dans ce contexte, l'économie est représentée comme un système dynamique d'agents hétérogènes (opérateurs du marché, unités de génération) qui interagissent pour décider des prix selon l'offre et la demande. Dans d'autres mots, les prix de l'électricité découlent des solutions d'équilibre dont l'équilibre de Nash ou le PCM (*Production Costing Model*) à titre d'exemple. La deuxième famille s'intéresse à capturer le comportement des séries temporelles par l'intermédiaire des méthodes statistiques, des méthodes computationnelles du *machine learning* et des méthodes hybrides. Dans le cadre de ce projet, nous laissons à l'écart les modèles d'équilibre économique et nous privilégions la deuxième classe citée ci-dessus.

Les méthodes des séries temporelles ont été intensivement utilisées dans la prévision des prix à court terme. Contreras et al (2002) [3] ont recours à des modèles ARIMA univariés pour prévoir les prix *day-ahead* sur le marché de l'électricité de la Californie et de l'Espagne. De leur part, Nogales et al (2005) [4], utilisent des modèles de régression dynamique et de transfert de fonction multivariés pour l'estimation des prix DA sur ces mêmes marchés. Les séries historiques des prix et de la demande en électricité sont les variables explicatives utilisées. Les modèles de Nogales et al aboutissent à une meilleure précision au niveau des prévisions que les modèles ARIMA discutés dans [3]. Dans cette même continuité, Nogales et Conejo (2005) [5] se consacrent à prédire les prix DA sur le marché PJM par l'intermédiaire des modèles ARIMA, de régression dynamique et de fonctions de transfert. Pareillement, le modèle de transfert de fonction est le meilleur. Une méthode de transformation par ondelettes (*wavelet transformation*) est proposée par Haiteng XH et Niimura T (2004) [6] afin d'améliorer la qualité des prévisions des modèles ARIMA univariés. L'inconvénient majeur derrière ces modèles est qu'ils se basent sur l'hypothèse de stationnarité des données. Cependant, les prix de l'électricité sont loin de respecter cette hypothèse.

Les modèles GARCH ainsi que *les input-output hidden Markov Models* ont été envisagés pour remédier à cette limite. R.C Garcia et al (2005) [9] utilisent les modèles GARCH pour tenir compte de la variation de la variance des prix DA de l'électricité sur le marché de l'électricité en Espagne. Selon [10], la prévision des prix RT est un exercice plus ardu comparativement aux prévisions des prix DA. Ceci est expliqué par l'impact des facteurs imprévisibles sur le prix en temps réel. Gonzalez et al (2005) [11] proposent un *input-ouput hidden Markov Model* pour analyser et prédire les prix RT sur le marché de l'électricité en Espagne. Ils estiment que les changements au niveau des stratégies sur le marché ont un impact direct sur la volatilité des prix RT. Par suite, les changements au niveau des stratégies des concurrents sont représentées par une séquence de modèles dynamiques qui forment une chaîne de Markov à temps discret. Le marché est donc formé d'un ensemble d'états où chacun peut être expliqué par des variables qui lui sont propres. Une matrice de transition des probabilités est définie pour évaluer la probabilité de passer d'un état à un autre.

Pour résumé, les méthodes de séries temporelles s'avèrent efficaces mais se voient limitées en raison de la fréquence de la variation des données. À titre d'exemple, une variation en temps réel au niveau de la demande en électricité aura un impact soudain sur le prix horaire. Ces modèles sont inaptes de capturer cette tendance volatile des prix ainsi que les pics qu'ils peuvent connaître. Deux motivations sont derrière le recours à des modèles plus élaborés. Premièrement, il s'avère essentiel de tenir compte de la complexité relationnelle entre les prix et les autres facteurs explicatifs pour aboutir à des meilleurs prévisions. Deuxièmement, la présence de pics au niveau des prix et leur impact sur la performance statistique et économique des modèles doivent être analysés.

Ainsi, pour remédier à ces limites, d'autres modèles ont été envisagés. Il s'agit des modèles d'apprentissage profond tels que les réseaux des neurones, les réseaux de neurones fuzzy, les *Support Vector Machine (SVM)* ou des modèles hybrides combinant à la fois les techniques de série temporelles et d'apprentissage automatique. À titre d'exemple, Shiri A, Afshar M, Rahimi-Kian A et al (2015) [15] ont utilisé pour leur prévision un SVM incluant l'impact des prix du pétrole et du gaz naturel sur les prix de l'électricité. Une autre méthode de prévision des prix qui se base sur la généralisation du modèle ARMAX(*Functional ARMAX Model*) à l'espace L2 d'Hilbert a été proposée par Portela J, Munoz A, Alonso E (2017) [16]. Similairement, Cerjan et al (2019) [17] proposent la méthode HIRA (*Hybrid Iterative Reactive Adaptive*) pour prévoir les prix du marché hongrois.

Plusieurs travaux se sont focalisés particulièrement sur le perceptron multicouche et ses extensions. Ces méthodes tentent de trouver le mapping le plus approprié pour expliquer les relations entre les variables prédictives et le prix de l'électricité. Le modèle apprend des données historiques pour proposer la meilleure architecture possible selon l'objectif de l'exercice. Hassan S, Khosravi A, Jaafar J et al (2014) [18] proposent un réseau de neurones pour prédire d'une part la demande en électricité et d'autre part le prix DA de l'électricité sur le marché de la Nouvelle-Angleterre (*ISO New England*). Dans leur exercice de prévision, les prix historiques de l'électricité, les prix et les valeurs historiques hebdomadaires de la demande en électricité ainsi que la nature du jour et des heures étaient des facteurs déterminants. Un modèle de réseau de neurones simple (à une seule couche cachée) est appliqué. Finalement, l'exercice d'estimation des prix s'est avéré plus compliqué que celui de la demande en électricité et aboutissent à des résultats moins satisfaisants.

Dans le même contexte, J.P.S. Catalao a, S.J.P.S. Mariano et al (2007) [19] présente un réseau de neurones à propagation avant (*Feedforward Neural Network*) pour estimer les prix DA de l'électricité sur le marché de l'Espagne. L'estimation se fait pour les prix de la semaine à venir et une comparaison avec le marché de l'électricité californien est effectuée pour évaluer la performance du modèle au sens large. Selon les auteurs, nous retenons parmi les facteurs explicatifs utilisés dans la prévision : les prix historiques, les données historiques de la demande en électricité, les données de retraits de génération et de production de l'énergie éolienne et les capacités de transmission. L'impact de la météo est considéré implicitement au niveau de la demande en électricité. Particulièrement, parmi les déterminants susceptibles d'expliquer les pics au niveau des prix, nous y trouvons le prix du gaz, la fluctuation des données de transmission et de retraits, la croissance future de la demande en électricité ainsi que les changements météorologiques. Il convient de préciser également que le modèle construit est un réseau de neurones à trois couches cachées dont la fonction d'activation est une tangente hyperbolique.¹

L'idée de recourir à cette extension du MLP (*Multilayer Perceptron*) est appuyée également par Jesus Lago, Fjo De Ridder et Bart De Schutter (2018) [20]. En effet, ils mettent à l'exercice un modèle de réseau de neurones à deux couches cachées (MLP), une méthode hybride reposant sur un réseau LSTM (*long short-term memory*), une autre utilisant un réseau de neurones récurrent de type GRU (*Gated recurrent unit*) et un réseau de neurones convolutifs. L'objectif est de mettre en valeur la contribution des méthodes d'apprentissage profond dans la prévision des prix DA. Les auteurs comparent ces quatre modèles avec 27 différentes approches

et aboutissent à la conclusion que le MLP est le plus performant. Au niveau de la modélisation, deux aspects s'avèrent relativement important : le premier concerne la

^{1.} L'output de la fonction d'activation est compris entre -1 et 1.

modélisation en tant que telle. Deux alternatives sont testées : la première consiste à prédire les prix sur le marché local de l'électricité belge. La deuxième tient compte du concept du market integration où l'on prédit simultanément les prix DA sur le marché local et le marché voisin français. Sous la première alternative, seules les données de la prévision day-ahead de la demande en électricité sont utilisées. Quant à la deuxième approche, une méthode de feature selection est privilégiée. L'ensemble des variables disponibles tournent autour de la prévision DA de la demande sur le marché belge, la prévision DA de la génération d'électricité sur le marché belge, la série historique des prix DA sur le marché français ainsi que la prévision DA de la demande et la génération sur le marché français. Le deuxième aspect concerne les données. Deux options sont testées : La première consiste à prendre les données brutes telles qu'elles sont. Une autre consiste à supprimer toute observation (tout prix) dépassant la moyenne +/- 3 fois l'écart-type de la série. Ainsi, nous éliminons les *spikes* de notre série à prédire. Cependant, le modèle prenant les données brutes aboutit à des meilleurs résultats.

La littérature existante sur le marché de l'électricité concerne davantage les prix que le différentiel des prix entre le marché DA et le marché réel. En effet, nous constatons qu'il existe une revue très restreinte portant sur le DART en tant que tel. Trois articles portant sur la prévision du DART ont été trouvés.Nika Nizharadze, Arash Farokhi Soof et Al (2020) [21] ont recours à des modèles statistiques de *Machine Learning* ainsi qu'à un réseau de neurones profond pour prédire le gap entre les prix DA et RT sur le marché CAISO (California Independent System Operator). En effet, quatre modèles sont considérés : une régression LASSO, un SVM, un modèle de forêts aléatoires et un LSTM. Les modèles servent d'une part à prédire les prix DA et RT pour calculer ensuite la différence et d'autre part à estimer directement l'écart des prix. Le modèle de forêts aléatoires permet de classer les variables explicatives selon leur ordre d'importance. Les *features* qui contribuent le plus à l'estimation sont : le prix DA une heure avant, la série du DART, des prix DA et des prix RT pour les 24h passées, les données sur la température (telles que l'angle zénith du soleil, l'humidité, la vitesse et la direction du vent), la prévision de la demande DA et les variables catégoriques pour la nature du mois et de l'heure. L'étude concerne le noeud « MURRAY6N015 » qui se situe à San Diego. Des données horaires s'étalant du 1er janvier 2017 jusqu'au 30 décembre 2018 sont considérées. Les résultats montrent que prédire le DART est plus pertinent que prédire les prix séparément et en faire une différence. D'ailleurs, la difficulté réside dans la prévision du prix RT. Nous constatons que quoique le LSTM performe mieux que les autres modèles, la RMSE pour les prix RT est de l'ordre de 48 comparativement à une RMSE de 7.1 pour les prix DA. Ceci est justifié davantage par le comportement imprévisible des prix en temps réel. Quant au DART, le LSTM est également le plus performant avec une RMSE de 56.9. Le modèle de forêts aléatoires aboutit à de bons résultats également. Le comportement du DART étant non-linéaire, le modèle Lasso montre une très faible performance.

Ronit Das, Rui Bo et al (2022) [22] contribuent à cette même thématique de recherche en proposant un modèle LSTM bi-directionnel et un modèle *sequence-to-sequence* pour prédire le DART. Parallèlement, des modèles de classification ont été développés pour prédire les mouvements du DART autour de certains intervalles. À titre d'exemple, les auteurs se sont intéressés à évaluer la précision des mouvements du DART au-delà d'un seuil de 50\$/MWh. Le marché cible est le marché PJM où l'on considère l'année 2018 pour l'entraînement et la période de janvier 2019 jusqu'à fin février 2019 pour le *backtesting*. La prévision se fait uniquement pour l'heure suivante et non pas sur 24h. La performance de ces deux modèles est comparée avec un modèle ARIMA, XGBoost et SVR. Le modèle *sequence to sequence* performe le mieux en matière de quantification du DART et de classification. Sur la période test de janvier à février, la RMSE est de 19,47 avec une précision du bon mouvement du DART d'environ 73.28%. Ce modèle permet également de prédire la bonne direction du DART pour des valeurs extrêmement élevées. À titre d'exemple, pour un DART supérieur à 100\$/MWh, le modèle capture dans 95% des cas le bon sens.

Sous un autre onglet, Galarneau-Vincent, Gauthier et Godin (2022) [24] se sont consacrés à l'estimation de la probabilité de réalisation d'un *spike* négatif sur le marché d'électricité de New York. Ils s'intéressent à notre même variable objectif qui est le DART.

Ainsi, la revue effectuée dans le cadre de ce mémoire laisse entrevoir certaines contributions potentielles à l'avancement des connaissances sur la prévision du DART pour le marché de l'électricité. Premièrement, nous constatons que les recherches existantes se sont consacrées en grande partie aux prix laissant à l'écart le DART qui fait l'objet des transactions virtuelles. Ensuite, nous nous sommes aperçus que peu d'articles utilisant un DNN s'intéressent à l'analyse des pics au niveau du DART et leurs impacts sur la profitabilité des stratégies économiques. Pour finir, l'exercice d'estimation est effectué par l'intermédiaire d'un modèle de forêts aléatoires, un modèle de Light GBM et un réseau de neurones (MLP). Le Light GBM permet de tenir compte de l'asymétrie des prix et du déséquilibre au niveau de l'échantillon des données. Une base de données allant de décembre 2017 jusqu'à juillet 2022 est utilisée. Nous faisons donc affaire à une large quantité de données comparativement à ce qui est présenté au niveau des travaux de Nika Nizharadze et al [21] et Ronit Das, Rui Bo et al [22]. Aussi, la série horaire du DART sur le marché MISO n'a pas encore fait

l'objet d'une étude qui lui est propre malgré un volume important de transactions virtuelles. Comme on le voit donc, plusieurs raisons sont réunies pour motiver l'étude de trois différentes méthodes d'intelligence artificielle pour la prévision du DART sur huit *hubs* du marché MISO.

CHAPITRE 3 DONNÉES ET MÉTHODOLOGIE

Premièrement, nous présentons dans ce chapitre une brève description du marché MISO ainsi que le mécanisme de fonctionnement du marché DA. Par suite, nous nous arrêtons sur la variable DART et particulièrement sur les valeurs extrêmes prises par cette dernière. Des méthodes de traitement de ces valeurs sont discutées. Finalement, nous définissons les variables explicatives utilisées par nos modèles.

3.1 Description du marché et de son fonctionnement

MISO représente l'un des marchés régionaux d'électricité en Amérique du Nord. Il couvre la province de Manitoba et 15 États américains qui sont : Arkansas, Illinois, Indiana, Iowa, Kentucky, Louisiana, Michigan, Minnesota, Mississippi, Missouri, Montana, North Dakota, South Dakota, Texas, Wisconsin. Notons que seulement une petite superficie de Texas est sous la responsabilité de MISO. C'est ERCOT qui gère le marché texan de l'électricité. Chaque lieu appartenant au réseau de MISO est couramment appelé nœud. Il existe des nœuds de demande et d'autres de production. MISO compte en totalité 24 nœuds qui se transigent présentement dont 8 *hubs*. La définition d'un *hub* peut être vulgarisée comme suit : Il s'agit d'un regroupement de nœuds. Notre intérêt pour ce projet de recherche se limite aux *hubs*. La Figure 3.1 montre l'étendu géographique des *hubs* de MISO ainsi que la répartition des régions sur le nord, centre et sud.¹

En effet, MISO doit veiller sur la satisfaction de la demande et de la disponibilité des ressources nécessaires pour acheminer la génération d'un nœud de production vers un nœud de demande. Chaque ligne de transmission d'électricité a une capacité maximale et peut être congestionnée. L'électricité générée provient principalement des unités de charbon (à raison de 39% de la génération totale), des unités de gaz naturel (à raison de 28%), des unités nucléaires (aux alentours de 16%) et des unités éoliennes (de l'ordre de 13%).

^{1.} MISO nord est composé de Minnesota. MISO centre est composé d'Indiana, Illinois et Michigan. MISO sud est composé d'Arkansas, Louisiana, Mississippi et Texas.



FIGURE 3.1 Carte géographique représentative du marché MISO



(a) Étendu géographique des hubs

(b) Répartition des régions sur MISO nord, centre et sud

Dans les marchés déréglementés comme MISO, le prix est le résultant d'un mécanisme d'ajustement d'offre et de la demande fournies toutes les 5 minutes par les divers acteurs de marché, et ce pour chaque nœud. Lorsque le prix déterminé pour une heure spécifique est déduit des courbes fournies une heure auparavant, on l'appelle prix *real-time* (RT). Il est important de noter qu'en l'absence de congestion dans un réseau, les prix de tous les nœuds sont égaux. Ainsi, la congestion des lignes est également un facteur sous-tendant la complexité des prévisions. Ceci contribue à la volatilité du prix en temps réel.

Pour pallier ce problème, les ISO ont mis en place un mécanisme de livraison pour le lendemain (day-ahead). Dans un premier temps, les participants soumettent leurs offres de vente ou d'achat la veille de la journée cible pour laquelle l'électricité serait physiquement transigée (impérativement avant 10h30). Ensuite, l'ISO détermine un prix pour chacun des nœuds en agrégeant l'offre et la demande. Il prend en compte sa propre prévision de la demande interne, les diverses capacités de production et la congestion. Le prix horaire de l'électricité est annoncé sur le marché DA. Il s'agit du prix DA. Toute offre d'achat sera prise si le prix soumis par le négociant excède le prix DA et sera rejetée sinon. Dans le même ordre d'idées, une offre de vente sera acceptée si le prix soumis est inférieur au prix DA. Le lendemain, les écarts entre demande RT et demande DA, d'une part, et production RT et production DA, d'autre part, sont ajustés via un rachat ou une revente au prix RT.

Pour finir, il est important de signaler que le marché MISO est le plus important en termes de volume de transactions virtuelles. Le tableau 3.1 ci-dessous montre que MISO négocie le plus de transactions virtuelles compartivement aux autres marchés. Le profit moyen demeure cependant faible.

Market	Virtual Loa	d	Virtual Supply					
	MW as a % of load	Avg Profit	MW as a % of load	Avg Profit				
MISO	11.3%	0.75\$	11.7%	1.64\$				
NYISO	6.2%	0.95\$	9.7%	0.10\$				
ISO-NE	2.8%	-1.29\$	4.5%	2.07\$				
SPP	7.5%	0.64\$	14.1%	10.79\$				
PJM	4.8%	1.45\$	2.6%	1.10\$				

TABLEAU 3.1 Comparison of Virtual Trading Volumes and Profitability 2021

Le tableau est extrait du rapport de MISO intitulé «2021 STATE OF THE MARKET FOR THE MISO ELECTRICITY MARKETS». Il montre pour chaque marché le volume de la demande et de l'offre (en % de la génération totale) ainsi que le profit moyen qui en dégage. Les profits derrière la demande et l'offre virtuelle sont relativement faibles. Ceci est en cohérence avec l'efficience des prix sur le marché DA.

3.2 Présentation et analyse exploratoire de la variable DART

Cette section est consacrée à la présentation et l'analyse des données utilisées pour construire les modèles prédictifs. Nous nous arrêtons notamment sur les opérations de construction de variables et d'ajustement des données.

La présente étude porte sur huit *hubs* du marché MISO comme mentionné au préalable. En étroite collaboration avec le parquet des transactions énergétiques d'Hydro-Québec, nous utilisons des données collectées auprès du fournisseur *(Yes Energy / WSI Trader)* ou résultantes de modèles développés à l'interne par le météorologue du parquet. La variable cible étant le DART; elle est calculée, heure par heure, pour chaque nœud comme étant la différence entre le prix *day-ahead* et le prix *real-time* comme suit :

$$DART_t = DA_t - RT_t \tag{3.1}$$

où :

- DA_t est la série historique des prix, publiée sur le marché au lendemain (*day-ahead*) par MISO pour chaque heure et chaque nœud du réseau.
- RT_t est la série historique des prix publiée sur le marché réel (le lendemain) pour chaque heure et chaque nœud du réseau.

Comme le montre la figure 3.2 pour Indiana, nous pouvons constater aisément que la série des prix RT est beaucoup plus volatile que celle des prix DA. Cette volatilité est induite par le comportement imprévisible de la demande, les événements météorologiques affectant la production de certaines unités ou les bris d'équipements qui rendent la distribution de l'énergie difficile (Baltaoglu et al [23] (2019). Parallèlement, comme nous pouvons le constater au niveau du Tableau 3.2, la moyenne du DART varie entre \$0.5/MWh et \$1.15/MWh pour l'ensemble des nœuds à l'exception de Texas. Ceci implique une prime d'aversion au risque positive liée à la réalisation d'un pic. La distribution du DART est clairement asymétrique négative. Le coefficient d'asymétrie largement négatif prouve que plus de valeurs sont concentrées sur le côté gauche (queue gauche de la distribution). Les résultats accentuent également le caractère volatile du DART, pour des zones plus que d'autres. D'ailleurs, ce sont les nœuds qui se situent dans le sud du MISO qui sont plus volatiles, à savoir : Arkansas, Louisiana, Mississippi et Texas. L'amplitude des pics s'avère être très élevée également.

Hub	Moyenne	Écart-type	Minimum	Maximum	Asymètrie	1er quartile	3ème quartile
ARKANSAS	0.52	22.72	-3327.19	588.21	-56.56	-0.49	3.80
ILLINOIS	1.07	20.42	-825.74	278.09	-9.75	-0.71	5.29
INDIANA	0.78	38.84	-865.83	351.68	-10.64	-0.32	5.15
LOUISIANA	1.14	22.64	-3328.34	1127.15	-40.20	-0.23	4.81
MICHIGAN	0.79	68.32	-832.08	258.11	-10.41	-0.18	5.45
MINNESOTA	0.66	20.68	-803.00	420.21	-8.47	-1.53	4.97
MISSISSIPPI	1.14	33.80	-3201.70	1573.15	-42.30	-0.42	4.27
TEXAS	-0.02	32.31	-3473.19	922.27	-38.74	-0.37	4.46

TABLEAU 3.2 Statistiques descriptives de la variable DART historique

Le tableau 3.2 présente des statistiques descriptives autour des séries horaires du DART historique, respectivement pour chaque nœud du réseau. Les données proviennent de *Yes Energy* et s'étalent entre décembre 2017 et juillet 2022. Tous les nombres sont exprimés en \$/MWh.



FIGURE 3.2 Séries historiques des prix DA, prix RT et DART pour Indiana hub



L'encadré A montre les deux séries horaires des prix DA et RT pour Indiana sur la période allant du 12/2017 au 08/2022. L'encadré B représente la série du DART qui lui est associée (la différence entre le prix DA et le prix RT) pour les mêmes dates. L'encadré C est un zoom sur ce DART pour l'année 2022 (de janvier à mi-août). Le restant des nœuds se trouve à l'Annexe (Figure A.1 à Figure A.7).

2022-05

Date

2022-06

2022-07

2022-08

2022-02

2022-03

2022-04

Avant de passer en revue l'ensemble des variables explicatives pour la prévision, il est essentiel de s'arrêter sur les opérations d'ajustement et de nettoyage des données. Premièrement, au niveau des données de charge prédites à l'interne, il existe quelques valeurs manquantes, principalement celles devant être collectées le *week-end*². Les vides sont remplis par les données de l'opérateur MISO.

Deuxièmement, nous nous intéressons aux pics des prix à la hausse et à la baisse en vue de comprendre leur fréquence et leur amplitude. Leur présence peut être constatée au niveau des séries des prix (A.1-A.7). Plusieurs algorithmes du *machine learning* sont sensibles aux données d'entraînement ainsi qu'à leurs distributions. Ceci rend l'exercice d'estimation plus ardu puisque nous modélisons un évènement rare mais d'impact significatif. Plusieurs approches de détection de *spikes* existent. Nous en citons deux méthodes. La première est inspirée de la recherche de Galarneau-Vincent, Gauthier et Godin (2022) [24]. Les auteurs se sont consacrés à l'estimation de la probabilité de réalisation d'un *spike* négatif sur le marché d'électricité de New York. Ils s'intéressent à notre même variable objectif qui est le DART. Selon eux, toute valeur du DART dépassant un certain seuil est considérée comme pic. Les seuils proposés dans le papier sont d'ordre de : \$30/MWh, \$45/MWh et \$60/MWh. Ils sont respectivement testés dans notre projet. La proportion des valeurs libellées comme pics, pour les trois cas, est inférieure à 3%, pour les pics des prix à la baisse. Pareillement, pour les *spikes* à la hausse, nous constatons que la proportion du DART libellée comme pics ne dépasse pas 1.8%.

Nous pourrions aussi constater que la nature du mois et de l'heure ont un impact sur la fréquence des pics. Nous en citons qu'un seul exemple pour Indiana *hub*, le comportement étant similaire pour le restant des *hubs*. Le pic est plus significatif en hiver (mois de janvier) et à l'été (mois de juillet). Il l'est aussi le matin avant 10h ou le soir avant 20h comme le montre la Figure 3.3.

^{2.} La proportion des valeurs manquantes pour la prévision de de la demande en électricité varie entre 5 et 6.3 %. Les vides au niveau des données de prévision de l'énergie éolienne sont de l'ordre de 0.11%

	Nombre								
Hub	d'observations	Proportion	Moyenne	Écart-type	Minimum	Maximum	Asymétrie	Q1	Q3
Arkansas	717	0.017	-100.73	202.61	202.61	-30.02	-11.95	-93.08	-38.64
Illinois	1024	0.025	-76.16	76.82	-825.74	-30.02	-4.07	-78.52	-38.30
Indiana	1158	0.028	-79.01	85.03	-865.83	-30.02	-4.38	-82.99	-37.53
Michigan	1145	0.028	-85.80	84.25	-832.08	-30.03	-3.52	-93.80	-39.92
Texas	857	0.021	-163.48	425.36	-3473.19	-30.01	-6.64	-122.23	-40.74
Minnesota	1135	0.028	-69.81	72.90	-803.00	-30.03	-4.72	-69.19	-36.34
Mississippi	72	0.017	-107.20	201.07	-3201.70	-30.02	-10.87	-101.97	-38.59
Louisiana	80	0.019	-122.51	228.85	-3328.34	-30.02	-8.75	-122.33	-41.71

TABLEAU 3.3 Statistiques descriptives des spikes négatifs à un seuil de -\$30/MWh

Le tableau 3.3 montre plusieurs statistiques relatives aux séries horaires du DART inférieur à -30/MWh pour chaque *hub*. Q1 et Q3 représentent respectivement le premier quartile et le troisième quartile de la série. Les données considérées s'étalent entre décembre 2017 et juillet 2022. Tous les chiffres sont exprimés en /MWh.

TABLEAU 3.4 Statistiques descriptives portant sur les *spikes* positifs à un seuil de \$30/MWh

	Nombre								
Hub	d'observations	Proportion	Moyenne	Écart-type	Minimum	Maximum	Asymétrie	Q1	Q3
Arkansas	304	0.0074	75.92	99.97	30.05	588.21	3.49	33.82	59.47
Illinois	663	0.016	53.44	36.41	30.05	278.09	2.98	34.08	55.17
Indiana	575	0.014	59.07	48.55	30.01	351.68	3.05	34.06	59.51
Michigan	532	0.013	54.26	36.65	30.01	258.11	2.73	33.72	57.35
Texas	613	0.015	81.23	120.48	30.02	922.27	3.88	33.51	56.31
Minnesota	737	0.018	55.65	44.61	30.07	420.21	4.32	34.49	56.44
Mississippi	631	0.015	67.68	91.29	30.01	1573.15	10.15	36.01	65.71
Louisiana	745	0.018	62.27	71.95	30.01	1127.15	7.55	34.63	60.43

Le tableau 3.4 montre plusieurs statistiques relatives aux séries horaires du DART supérieur à 30/MWh pour chaque *hub*. Q1 et Q3 représentent respectivement le premier quartile et le troisième quartile de la série. Les données considérées s'étalent de décembre 2017 à juillet 2022. Tous les chiffres sont exprimés en MWh.



FIGURE 3.3 Proportion des *spikes* négatifs selon les heures et les mois

La Figure 3.3 rapporte la proportion des *spikes* négatifs (nombre d'observations libellées comme *spikes* par rapport au nombre total d'observations) pour Indiana *hub*. Les trois seuils sont testés. Les données considérées s'étalent de décembre 2017 à juillet 2022.

La deuxième alternative consiste à imputer les données extrêmes selon le score Z ou encore le score standard. C'est un moyen de décrire un point de données selon sa relation avec la moyenne et l'écart-type d'un groupe de points. L'établissement du score Z revient simplement à représenter les données dans une distribution dont la moyenne est définie sur 0 et dont l'écart-type est défini sur 1. L'idée derrière est qu'une fois que nous avons centré et remis à l'échelle les données, toute valeur très éloignée de zéro³ est considérée comme extrême.

Cette méthode est adoptée dans la recherche de Jesus Lago, Fjo De Ridder et Bart De Schutte [20]. Les auteurs se prennent comme seuil la moyenne des données +/- trois fois leur écart-type. Ce qui nous renvoie à la définition du score Z. Le Tableau 3.5 présente les seuils négatifs et positifs, pour chaque *hub*, à partir desquels la valeur est considérée comme *spike*. Nous éliminons, dans ce qui suit, toute valeur du DART dépassant les seuils présentés dans le Tableau 3.5, selon chaque *hub* concerné.

^{3.} Le seuil est généralement un score Z de 3 ou -3.

Hub	Seuil négatif	Seuil positif
Arkansas	-96.43	97.46
Illinois	-60.18	62.33
Indiana	-67.38	68.93
Louisiana	-115.37	117.66
Michigan	-67.13	68.71
Minnesota	-61.38	62.71
Mississippi	-100.27	102.55
Texas	-204.99	204.94

TABLEAU 3.5 Seuils à considérer pour les *spikes* positifs et négatifs selon le score Z

Le tableau 3.5 montre les seuils négatifs et positifs, à partir desquels une observation est considérée comme *spike*. Ils sont trouvés par la méthode du score Z. L'échantillon des données est celui du DART historique qui s'étale entre décembre 2017 et juillet 2022. Tous les chiffres sont exprimés en MWh.

3.3 Répartition des variables prédictives et définitions

Les variables prédictives utilisées peuvent être réparties en trois classes comme le montre le Tableau 3.6 : (1) les variables historiques, (2) les prévisions futures, (3) les données saisonnières. Le choix de ces variables est appuyé par la revue de littérature, principalement celle de Nika Nizharadze et al [21] et Galarneau-Vincent, Gauthier et al [24].

Variables historiques	Prévisions	Variables saisonnières
DART historique	Prévision de la demande en électricité	Variables <i>dummy</i> pour les heures
Erreur de la prévision de la demande en électricité	Prévision de la production d'énergie éolienne	Variables <i>dummy</i> pour les jours
Erreur de la prévision de la congestion	Prévision des retraits de génération	Variables <i>dummy</i> pour les mois
	Prévision de l'indice HDD	
	Prévision de l'indice CDD	
	Prévision de l'indice du gaz au point Henry hub	

Le tableau 3.6 montre l'ensemble des variables explicatives utilisées dans notre exercice.

Ci-dessous une définition des variables utilisées :

- 1. Les variables historiques sont des variables que nous avons construites à partir des données réalisées afin de capturer la tendance passée du marché⁴ :
 - Les séries historiques (horaires) des prix DA et RT qui servent à calculer le DART historique. Les données proviennent du fournisseur d'Hydro-Québec (*Yes Energy*) et s'étalent sur la période de décembre 2017 à juillet 2022.
 - L'erreur historique au niveau de la prévision de la demande en électricité : cette

^{4.} Les données utilisées dans la construction des variables historiques sont disponibles sur le site officiel de MISO. Elles le sont également sur des sites publiques tels que *energyonline.com* ou la librairie python *Pyiso* (via les API).

variable présente la différence entre la demande réelle en électricité

(*real-time load*) et la prévision de la demande telle que calculée par Hydro-Québec. La prévision de la demande en électricité est disponible sur une base horaire et est construite à partir d'un modèle interne pré-établi par le météorologue d'Hydro-Québec. La demande réelle en électricité est disponible, sur une base horaire aussi, via l'opérateur *Yes Energy*. La période d'échantillon est similaire à celui du DART. En d'autres termes, elle reflète la difficulté du marché à prévoir la demande effective en électricité. Elle est calculée comme telle :

$$Load \ error(t,T) = RT \ load(T,T) - load \ forecast(t,T)$$
(3.2)

— L'erreur historique au niveau de la prévision de la congestion : il s'agit de la différence entre la congestion prévue au DA et celle réalisée en RT. La prévision de la congestion ainsi que celle réalisée sont des données horaires disponibles par l'intermédiaire de Yes Energy sur la même période d'échantillon considérée. Elle se présente comme suit :

$$Congestion \ error(t,T) = RT \ congestion(T,T) - DA \ congestion(t,T)$$
(3.3)

- 2. Les prévisions futures consistent dans :
 - La prévision de la demande en électricité établie par Hydro-Québec : cette variable est prédite pour le nord, le centre et le sud et est utilisée dépendamment où se situe le point concerné. La fréquence de la prévision est horaire et est fournie par le météorologue d'Hydro-Québec 96 heures avant la journée cible.
 - La prévision des retraits de génération pour l'ensemble du marché MISO qui sont disponibles à 18.00h la veille du marché au lendemain. La fréquence de cette prévision est horaire (pour la journée cible).
 - La prévision de la production d'énergie éolienne pour MISO nord et MISO centre (il n'y a pas de production éolienne au sud du MISO). La fréquence de cette prévision est horaire (pour la journée cible) et est mise à disposition 96 heures avant la journée cible.
 - Les prévisions des indices de températures HDD et CDD : Le recours aux mesures HDD et CDD et non pas aux données brutes de températures fut recommandé par plusieurs travaux ((Fan et al. (2019) [29], Zahediet al. (2013) [30], Yi-Ling et al. (2014) [31]). Ceci permet entre autres de prendre en compte la non-linéarité de la relation entre l'électricité et la température.

Le HDD *(Heating Degree Day)* est une mesure conçue pour quantifier la demande d'énergie nécessaire pour chauffer un bâtiment. En revanche, le CDD *(Cooling Degree Day)* quantifie la demande de climatisation. Il convient de mentionner que les données de température utilisées dans ce calcul sont accessibles à 18.00h la veille du marché au lendemain, sur une base horaire. Ils sont définis, pour chaque nœud, par rapport à une température de base, qui est égale à 18.3 (°C) aux États-Unis, comme suit :

$$HDD_t = max(BP - T_t; 0) \tag{3.4}$$

$$CDD_t = max(T_t - BP; 0) \tag{3.5}$$

où BP=18.3 (°C) et T_t est la température en (°C) à chaque heure, pour chaque hub, fournie par WSI Trader.

- Les prévisions du prix du gaz au point Henry hub publiées par le fournisseur de données Ice Energy : Elles sont disponibles sur une base journalière (nous les transformons en séries horaires) entre 09.00h et 10.00h la veille du marché au lendemain.
- 3. Les variables saisonnières :

Afin de mettre en exergue l'effet temps et saison sur le marché de l'énergie, nous avons recours à des variables indicatrices *dummy* pour chaque heure de la journée (les heures sont segmentées en deux sous-groupes qui sont (*peak/off-peak*), pour chaque mois de l'année et notamment une *dummy* pour indiquer si la journée concernée est un jour férié ou un *week-end*.

CHAPITRE 4 MODÈLES DE PRÉVISION

Nous présentons dans cette section une brève définition des modèles utilisés pour l'estimation du DART. Ensuite, nous présentons l'étape d'optimisation des hyper-paramètres et son implication.

4.1 Description des modèles

Les trois modèles suivants font l'objet de notre intérêt : (1) les forêts aléatoires (*random forest*), (2) le LightGBM (*Light Gradient Boosting Machine*) et (3) le réseau de neurones à propagation avant (*feedforward neural network*).

Un algorithme de forêts aléatoires est constitué d'un ensemble d'arbres de décision indépendants. Chaque arbre dispose d'une vision parcellaire du problème du fait d'un double tirage aléatoire : Un tirage aléatoire avec remplacement sur les observations couramment appelé *tree bagging* et un autre tirage sur les variables explicatives appelé *feature sampling*. Le *tree bagging* permet aux arbres décisionnels individuels de partitionner aléatoirement l'ensemble de données et de les remplacer, créant ainsi des résultats différents dans chaque arbre. Dans d'autres mots, chaque arbre est construit et entraîné sur un échantillon aléatoire d'observations. Les variables prédictives ne sont pas toutes utilisées simultanément. À la fin, tous ces arbres indépendants sont assemblés. La prédiction faite sur l'ensemble de validation est alors la moyenne (dans le cas d'un problème de régression) des estimateurs de chaque arbre.

En ce qui concerne le LightGBM, cette méthode repose sur le principe du renforcement du gradient. La méthode du renforcement du gradient est une combinaison de d'apprenants très dépendants les uns des autres avec le même objectif à atteindre. Ces modèles sont des arbres de décision. Dans ce sens, LightGBM est un modèle d'apprentissage d'ensemble séquentiel, se basant sur le renforcement de gradient et des arbres de décision. Ces derniers sont combinés de manière à ce que chaque nouvel apprenant ajuste les résidus de l'arbre précédent afin que le modèle s'améliore. Le dernier arbre ajouté regroupe les résultats de chaque étape et un apprenant puissant est atteint. Ainsi, contrairement à une forêt aléatoire classique, il ajuste la base d'apprentissage au fur et à mesure de l'entraînement. Il a recours au gradient de la fonction de perte (ou descente de gradient) pour corriger les erreurs de l'arbre précédent

et ainsi optimiser les résultats du modèle. Le recours à LightGBM et non à XGBoost (eXtreme Gradient Boosting) dans notre projet est justifié par le gain du temps qui s'en découle. Le rapport performance versus temps d'exécution semble beaucoup plus intéressant pour le LightGBM. Sa performance est largement similaire à XGBoost et il est considéré comme une version améliorée de ce dernier. En effet, LightGBM fait croître l'arbre verticalement grâce à l'algorithme GOSS (Gradient-based One-Side Sampling) contrairement à XGBoost qui fait pousser des arbres horizontalement. En d'autres mots, il fait pousser l'arbre par feuille tandis que l'autre algorithme se développe par niveau. Aussi, il est beaucoup plus rapide que XG-Boost en raison de sa technique de réduction de dimension EFB (Exclusive Feature Bundling).

Pour finir, un réseau de neurones profond se distingue par une particularité : Il est composé d'au moins de deux couches cachées. Le perceptron multicouche capable de traiter des phénomènes non linéaires, est un exemple de ce type de réseau. Concrètement, les premières couches permettront d'extraire des caractéristiques simples. Les résultats de la première couche de neurones servent d'entrée au calcul de la couche suivante et ainsi de suite. Ainsi, nous devons concevoir une certaine architecture. Le modèle est composé d'une couche intrant dont le nombre de neurones équivaut le nombre de variables explicatives, d'un certain nombre de couches cachées et d'une couche sortie à une neurone à fonction d'activation linéaire. Le nombre de couches cachées, le nombre de neurones les composants, la fonction d'activation y inhérente et le *dropout rate* seront déduits du *tuning* des hyper-paramètres.

Le recours à des modèles d'apprentissage automatique supervisé a pour but de capturer les relations non-linéaires et complexes entre la variable à prédire et les variables explicatives. Deux étapes primordiales doivent être respectées : La première fut de standardiser l'ensemble des variables prédictives à l'exception des variables indicatrices comprises entre 0 et 1. Travailler avec des données d'échelles variables peut compromettre le problème de régression en ce sens qu'une variable dont la plage de valeurs est comprise entre 0 et 10000 sera plus pesante dans l'analyse qu'une variable dont les valeurs sont comprises entre 0 et 1 (telles que les indicatrices). D'où la nécessité de ramener le tout à une plage comparable. La fonction *StandardScaler* de la bibliothèque *Scikit-learn* est utilisée. Elle permet de centrer et réduire les données en soustrayant la moyenne des données et en divisant par la variance de la série. Puisque nous avons éliminé les valeurs extrêmes selon la méthode du score standard, nous garantissons un certain équilibre au niveau de la distribution des données. La deuxième opération consiste à trouver les hyperparamètres du modèle.

4.2 Optimisation des hyper-paramètres

L'optimisation des hyper-paramètres vise à trouver les paramètres d'ajustement des processus d'apprentissage là où la performance du modèle est la meilleure (selon notre objectif). Les hyperparamètres varient en fonction de la nature des algorithmes. Dans notre cas, pour chaque modèle, nous nous sommes arrêtés sur les paramètres suivants :

- Forêts aléatoires :
 - Nombre d'arbres dans la forêt
 - Profondeur maximale des arbres utilisés
 - Nombre de variables prédictives sélectionnées pour chaque arbre
 - Nombre d'observations minimal sur un noeud
 - Critère
- \blacksquare Light GBM :
 - Nombre de feuilles dans un arbre
 - Profondeur maximale de l'arbre
 - Taux d'apprentissage
- Réseau de neurone :
 - Fonction d'activation
 - Nombre de couches cachée
 - Nombre de neurones
 - Taux d'apprentissage
 - Optimiseur
 - Batch size

Ils existent plusieurs méthodes pour le réglage de ces derniers tels que Grid Search, Random search ou l'optimisation bayésienne. La méthode privilégiée dans notre projet est celle du Grid Search appuyée par une validation croisée K-fold, précisément une variation de cet algorithme (Time Series K-fold Cross-Validation) afin de tenir compte de la nature temporelle des données. Le Grid Search est une méthode d'optimisation qui prend un ensemble de paramètres candidats et en crée des combinaisons aléatoires à travers lesquelles le modèle sera entraîné. Le k-fold intervient à cette étape-ci. Il permet d'organiser les données en k échantillons. Nous sélectionnons x échantillons pour l'ensemble d'entraînement et les k-x restants permettent d'évaluer la performance du modèle. Ici, le k est fixé à 8. La répartition des données est comme suit : L'ensemble des données dédié à l'optimisation des hyper-paramètres et l'entraînement s'étale du 12/2017 au 08/2021. La période allant du 09/2021 jusqu'au 07/2022 est celle consacrée pour le backtesting. Au niveau de l'entraînement du modèle, une approche d'expanding window est privilégiée.

En effet, à la première itération, le modèle est entraîné sur les trois premières années. La validation est effectuée sur le mois juste après. Nous considérons un mois d'observations pour chaque validation. À la prochaine itération, l'ensemble d'entraînement s'agrandit d'un mois (celui dédié à la validation lors de la première itération) et le modèle sera ré-entraîné sur le nouveau set. Les prévisions seront générées pour le mois d'après et ainsi de suite. Nous nous assurons ainsi que l'échantillon de validation est après celui d'entraînement. Finalement, pour chaque combinaison de paramètres, la performance du modèle est évaluée sur l'ensemble de validation (qui est un mois d'observations à chaque tirage) et nous retenons le paramétrage qui minimise l'erreur quadratique moyenne. Pour finir, l'optimisation des hyperparamètres aboutissent aux résultats présentés dans les tableaux 4.1, 4.2, 4.3, 4.4 et 4.5.

TABLEAU 4.1 Résultats de l'optimisation des hyperparamètres pour le modèle de forêts aléatoires

Paramètre	Valeur trouvée
Nombre d'arbres dans la forêt	50
Profondeur maximale des arbres utilisés	10
Nombre de variables prédictives sélectionnées pour chaque arbre	5
Nombre d'observations minimal sur un noeud	5

Le tableau 4.1 montre les résultats de l'optimisation des hyperparamètres pour le modèle de forêts aléatoires. Les paramètres trouvés sont les mêmes pour l'ensemble des *hubs*. Les valeurs présentées au niveau du tableau sont celles qui permettent de minimiser l'erreur quadratique moyenne.

TABLEAU 4.2 Résultats de l'optimisation des hyperparamètres pour le Light GBM

Paramètre	Valeur trouvée
Nombre de feuilles dans un arbre	170
Profondeur maximale de l'arbre	7
Taux d'apprentissage	0.04
Objectif	Régression

Le tableau 4.2 montre les résultats de l'optimisation des hyperparamètres pour le Light GBM. Les paramètres trouvés sont les mêmes pour l'ensemble des *hubs*. Les valeurs présentées au niveau du tableau sont celles qui permettent de minimiser l'erreur quadratique moyenne.

Paramètre	Valeur trouvée
Nombre de couches cachée	2
Nombre de neurones dans la couche de sortie	1
Nombre de neurones par couche cachée	23
Taux d'apprentissage	0.04
Fonction d'activation	tanh
Optimiseur	sgd
Batch size	8

TABLEAU 4.3 Résultats de l'optimisation des hyperparamètres pour le réseau de neurones

Le tableau 4.3 montre les résultats de l'optimisation des hyperparamètres du MLP. Ces paramètres sont les mêmes pour Indiana, Michigan, Texas, Minnesota, Mississippi et Arkansas. Les valeurs présentées au niveau du tableau sont celles qui permettent de minimiser l'erreur quadratique moyenne.

TABLEAU 4.4 Résultats de l'optimisation des hyperparamètres pour le réseau de neurones (Illinois)

Paramètre	Valeur trouvée
Nombre de couches cachée	3
Nombre de neurones dans la couche de sortie	1
Nombre de neurones par couche cachée	100
Taux d'apprentissage	0.05
Fonction d'activation	tanh
Optimiseur	sgd
Batch size	8

Le tableau 4.4 montre le résultat de l'optimisation des hyperparamètres du MLP pour Illinois. Les valeurs présentées au niveau du tableau sont celles qui permettent de minimiser l'erreur quadratique moyenne.

TABLEAU 4.5 Résultats de l'optimisation des hyperparamètres pour le réseau de neurones (Louisiana)

Paramètre	Valeur trouvée
Nombre de couches cachée	2
Nombre de neurones dans la couche de sortie	1
Nombre de neurones par couche cachée	50
Taux d'apprentissage	0.05
Fonction d'activation	tanh
Optimiseur	sgd
Batch size	8

Le tableau 4.5 montre le résultat de l'optimisation des hyperparamètres du MLP pour Louisiana. Les valeurs présentées au niveau du tableau sont celles qui permettent de minimiser l'erreur quadratique moyenne.
CHAPITRE 5 RÉSULTATS

La première section de ce chapitre est consacrée à évaluer la performance statistique des modèles. Ensuite, nous analysons l'importance des variables explicatives. Finalement, la troisième section porte sur la contribution économique des modèles.

5.1 Performance statistique des modèles

En guise de rappel, la répartition des données est comme suit : L'ensemble des données utilisé pour l'optimisation des hyper-paramètres et l'entraînement s'étale du 12/2017 au 08/2021. La période allant du 09/2021 jusqu'au 07/2022 est celle consacrée pour le *backtesting*. Au niveau de l'entraînement du modèle, une approche d'*expanding window* est privilégiée. Deux mesures sont adoptées pour évaluer la performance des modèles. La première étant la RMSE (*Root Mean Square Error*). Elle est définie comme suit :

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^{n} (y_i - \hat{y}_i)^2}$$
(5.1)

Les tableaux 5.1 et 5.2 présentent la RMSE *in sample* et *out of sample* (entre septembre 2021 et juillet 2022) pour le *hub* Indiana. La statistique relative au restant des *hubs* se trouve au niveau des tableaux A.1 à A.12 (Annexe). y est la valeur du DART réel et \hat{y} est la valeur estimée du DART. Les séries du DART réel et du DART estimé sont des séries horaires. L'horizon de prévision est sur 24h. La différence entre la métrique *in sample* et celle *out of sample* peut être en partie induite par l'instabilité particulière du marché de l'énergie durant l'année courante. La volatilité sur le marché de l'électricité est de plus en plus accentuée en 2022 en raison de l'invasion russe de l'Ukraine. Ses impacts majeurs sur le secteur du gaz naturel et du pétrole induisent également un effet sur le prix de l'électricité. Les données utilisées pour l'estimation n'incluant pas autant l'année 2022, ne permettent pas au modèle de se familiariser avec les nouvelles conditions du système.

	Forêts aléatoires	Light GBM	Réseau de neurones
12/2017-12/2020	7.391	7.412	8.499
12/2017-01/2021	7.407	7.436	8.479
12/2017-02/2021	7.543	7.588	9.225
12/2017-03/2021	7.513	7.497	8.608
12/2017-04/2021	7.516	7.507	8.683
12/2017-05/2021	7.519	7.493	8.591
12/2017-06/2021	7.512	7.539	8.604
12/2017-07/2021	7.507	7.563	8.665
12/2017-08/2021	7.425	7.542	8.459

TABLEAU 5.1 RMSE in sample pour Indiana hub

TABLEAU 5.2 RMSE out of sample pour Indiana hub

	Forêts aléatoires	Light GBM	Réseau de neurones
09/2021-10/2021	11.584	12.833	11.588
10/2021-11/2021	14.195	15.852	13.656
11/2021-12/2021	15.047	16.078	14.818
12/2021-01/2022	10.542	10.521	10.707
01/2022-02/2022	17.462	18.096	17.922
02/202-03/2022	11.376	12.064	12.722
03/2022-04/2022	13.895	14.790	13.879
04/2022-05/2022	17.140	17.412	16.457
05/2022-06/2022	15.939	16.336	14.859
06/2022-07/2022	17.482	18.160	17.739
07/2022-08/2022	18.071	17.779	17.616

La statistique RMSE *in sample* et *out of sample* est calculée respectivement pour le modèle des forêts aléatoires, le Light GBM et le réseau de neurones. La phase d'entraînement suit le principe d'*expanding window*. Les modèles permettent également de générer des résultats sur la période du *backtesting* entre septembre 2021 et juillet 2022.

La deuxième métrique est une fonction construite par les négociants du parquet des transactions énergétiques. Pour chaque estimation du DART, la fonction enregistre l'indice de position d'un DART positif et celui d'un DART négatif. Suivant cet indice, elle vient comparer si le signe de l'estimation correspond au signe du DART réel pour la même observation au niveau de la série des données. Ensuite, si pour cette observation, le DART estimé arrive à répliquer le bon signe du DART réalisé, une valeur de 1 est assignée à la variable score. Sinon, le score prend un 0. Cette opération est répétée tout au long de la série du DART horaire estimé en sommant la variable score à chaque itération. Finalement, cette variable score (une somme de 1 et de 0) est divisée par le nombre total d'observations. Il s'agit donc d'un pourcentage qui reflète le pouvoir des modèles à répliquer le bon sens du DART.

Le tableau 5.3 montre la proportion des estimations capables de répliquer le bon sens du

DART. Le modèle de forêts aléatoires ainsi que le réseau de neurones (à l'exception de Texas) performent significativement bien.

TABLEAU 5.3 Score de vraisemblance du signe de la prévision des modèles par rapport au signe du DART réel

	Score du modèle de Forêts aléatoires	Score du modèle Light GBM	Score du réseau de neurones
Indiana	65.503	53.287	67.396
Illinois	62.522	56.549	65.733
Louisiana	71.553	69.506	71.553
Michigan	69.980	68.688	70.913
Texas	69.621	61.960	70.056
Minnesota	60.297	55.359	47.212
Mississippi	68.803	66.871	68.278
Arkansas	68.496	63.635	68.624

Le tableau 5.3 montre le score en pourcentage de la vraisemblance du signe de la prévision trouvée par rapport au signe réel du DART. Cette métrique est calculée sur la totalité de la période *out of sample*, pour les prévisions horaires trouvées par chaque modèle, pour tous les *hubs*. La période des données s'étale de septembre 2021 à juillet 2022.

5.2 Importance des variables explicatives

Pour évaluer l'impact de chaque variable explicative sur la prévision, nous avons recours aux valeurs de Shapley (shap values). Les valeurs de Shapley héritées de la théorie des jeux coopératifs est une méthode d'intelligibilité qui s'impose de plus en plus comme un outil populaire d'explication de modèles de Machine Learning. On distingue deux types d'intelligibilité : une intelligibilité locale et une autre globale. L'intelligibilité globale cherche à expliquer le modèle dans sa globalité. Dans d'autres mots, elle distingue, en moyenne, les variables les plus importantes pour le modèle. À contrario, l'intelligibilité locale, consiste à expliquer la prévision (f(x)) d'un modèle pour un x donné. La bibliothèque « Python shap », est une référence grâce à sa simplicité et la richesse de ses visualisations. On y trouve différents algorithmes adaptés à chaque type de modèle.

Deux propriétés rendent l'algorithme de Shapley particulièrement facile à utiliser dans notre cas : la première est la fonction de décomposition additive. La méthode de décomposition additive propose un modèle d'explication qui est une fonction linéaire de variables binaires approchant au mieux la prévision [27].

La fonction de décomposition est telle que :

$$g(x) = \Phi_0 + \sum_{i=1}^{n} \Phi_i(x)$$
(5.2)

avec :

$$\Phi_0 = \mathbb{E}[f(X)] \tag{5.3}$$

Pour davantage de clarté, nous faisons un parallèle entre l'exercice de prévision et la théorie des jeux :

- Chaque ligne d (de vecteur de valeurs $\mathbf{x}=(x_1, x_2, ..., x_n)$ constitue un jeu coopératif J_d dont le gain est la valeur prédite nette $:g_d = f(x_1, x_2..., x_n) - f \circ \hat{\mathbf{u}} f = \mathbb{E}[f(X)]$ est la valeur moyenne de f(.) sur l'ensemble de la base.
- Chaque sous-ensemble de variables est une coalition dans le jeu Jd.
- Enfin, la fonction caractéristique de J_d est $v_d(.)$ qui vérifie $v_d(X_1, ..., X_n) = g_d$ et $v_d(.) = 0$.

On peut alors calculer une valeur de Shapley pour le jeu J_d qui explique la contribution de chaque variable à la construction de g_d telle que :

$$\Phi(x_d) = \sum_{S \subseteq X/X_i} \omega_x(S) [v_d(S \cup X_i) - v_d(S)],$$
(5.4)

$$\omega_x(S) = \frac{|S|!(|X| - |S| - 1)!}{|X|!} \tag{5.5}$$

où :

- g est une fonction linéaire de variables binaires approchant au mieux f.
- f est la fonction (approximation résultante d'un des modèles de machine learning dans notre cas) calculant la valeur prédite en fonction des variables X.
- X est l'ensemble des variables prédictives (features) avec N variables et d lignes.
- $x = (x_1, x_2..., x_n)$ est le vecteur des valeurs prises par chaque variable prédictive.
- Φ est le score d'importance pour chaque variable.
- x_d est la valeur prise par la variable prédictive x à chaque heure.
- S est un sous-ensemble de X.

Deuxièmement, pour pouvoir comparer globalement les variables, une notion d'importance associée aux valeurs de Shapley a été mise en place. Hadj Ali, Le Biannic et Wuillemin [27] (2021) définissent l'importance de chaque variable comme étant la moyenne de ses valeurs de Shapley sur l'ensemble des jeux de la base avec :

$$\Phi_i = \frac{1}{D} \sum_{d=1}^{D} |\Phi_i(x_d)|$$
(5.6)

La Figure 5.1 ainsi que les Figures A.8 à A.14 (Annexe) rapportent l'importance globale des variables explicatives en utilisant les valeurs de Shapley en moyenne absolue (en moyennant la valeur absolue des valeurs de Shap). Les Figures A.15 à A.22 (Annexe) présentent les valeurs de Shapley dans leur ordre d'importance (les points rouges représentent des valeurs élevées de la variable et les points bleus des valeurs basses). L'exercice est effectué pour chaque modèle, sur chaque hub, pour l'ensemble *out of sample*.

Pour les nœuds du MISO centre, nous constatons un comportement similaire entre Indiana et Michigan. Le modèle de forêts aléatoires ainsi que le réseau de neurones mettent en évidence la contribution majeure du prix du gaz Henry hub suivi de la prévision de la demande en électricité et le DART historique. Cependant, le réseau de neurones a tendance à amplifier l'amplitude de cette contribution. La contribution mise en avant par le Light GBM est largement différente mais non-contradictoire avec les deux premiers modèles. En effet, ce dernier renvoie également l'importance de la prévision des retraits de génération et des dummy mois pour Indiana. Pour Michigan, c'est l'importance de la prévision de l'énergie éolienne qui ressort. En ce qui concerne Illinois, le modèle de forêts aléatoires est en norme avec le restant des hubs. Certes, le Light GBM et le réseau de neurones mettent en valeur la contribution d'autres *features* tels que l'indice de température HDD et la prévision des retraits de génération. En ce qui concerne les nœuds du sud, les variables les plus importantes que nous retenons pour les trois modèles sont les mêmes. Particulièrement, pour Louisiana, le modèle du réseau de neurones tend à mettre en avant la forte contribution de la prévision de l'indice de température CDD. Finalement, pour Minnesota qui se situe au nord, les variables ayant le plus d'impact sur la prévision semblent être les mêmes. Il s'agit du prix du gaz Henry hub suivi de la prévision de la demande en électricité et le DART historique. Le réseau de neurones se comporte de la même façon que celle observée pour le centre. Il accentue ces contributions et ressort également l'importance de l'indice de température HDD et l'erreur de congestion.

Comparativement aux variables citées ci-dessus, les autres variables semblent ajouter peu d'informations à la prévision.

En ce qui concerne les *beeswarm plots*, ils nous permettent d'avoir davantage d'informations sur l'impact qu'a la variable sur la prévision dépendamment de sa valeur. Comme expliqué préalablement, les valeurs de Shapley sont représentées pour chaque variable dans leur ordre d'importance où les points rouges représentent des valeurs élevées de la variable explicative et les points bleus les valeurs basses. À titre d'exemple, pour le modèle de forêts aléatoires sur Indiana *hub* (Figure A.15a), la prévision du prix du gaz qui est la variable la plus importante a un impact positif sur l'estimation quand la valeur de cette variable est élevée. Pareillement pour la prévision de la demande *(load forecast)* et le DART historique. En revanche, plus la prévision de l'indice de température augmente CDD, plus son impact est négatif sur la prévision du DART. Par ailleurs, le réseau de neurones au point Mississipi, montre qu'une faible erreur au niveau de la prévision de la congestion a un impact positif sur l'estimation. Une erreur de congestion élevée a un effet négatif.





La Figure 5.1 rapporte l'importance globale des variables prédictives pour Indiana, pour les trois modèles et ce selon la moyenne absolue des valeurs de Shapley calculés. La période considérée est celle out of sample de septembre 2021 jusqu'à juillet 2022.

5.3 Résultats des stratégies de négociation

Au delà de mesurer la performance statistique des modèles, il est primordial de tenir compte de la valeur ajoutée économique de cette activité de prévision. Nous retenons principalement quatre stratégies qui seront présentées ci-après.

Toutes les stratégies suivent les trois principes suivants :

Nous calculons la valeur moyenne du DART estimé sur les heures *peak* allant de 06.00h
 à 23.00h et celle des heures *off-peak* (de minuit (00.00h) à 05.00h) telle que :

$$\bar{\hat{y}}_{peak} = \frac{1}{18} \sum_{t=6}^{23} \hat{y}_t \tag{5.7}$$

$$\bar{\hat{y}}_{offpeak} = \frac{1}{6} \sum_{t=0}^{5} \hat{y}_t \tag{5.8}$$

où \hat{y}_t est la prévision horaire du DART.

Nous prenons par suite position sur toutes les heures *peak* selon le signe de $\bar{\hat{y}}_{peak}$ et toutes les heures *off-peak* selon le signe de $\bar{\hat{y}}_{offpeak}$.

- 2. La quantité achetée ou vendue est constante et équivaut 10 MWh pour l'ensemble des heures à prédire de la journée à venir.
- 3. Au niveau des stratégies, nous ne prenons aucune position si le DART est identifié comme *spike*. Le profit horaire est donc nul.

La première stratégie peut être qualifiée de stratégie *price taker*. Elle dépend du signe de la moyenne des prévisions horaires du DART. Nous faisons référence respectivement à $\bar{\hat{y}}_{peak}$ pour les heures *peak* et $\bar{\hat{y}}_{offpeak}$ pour les heures *off-peak*. Deux cas de figures se présentent à nous :

— $\bar{y}_{peak} < 0$ ou $\bar{y}_{offpeak} < 0$: Ceci implique que le prix day-ahead est inférieur au prix real-time. En prenant une position longue (position d'achat) sur le marché DA, qui ensuite sera compensée par la position inverse (position de vente) sur le marché RT, nous achetons au prix DA et nous allons vendre au prix RT. Si l'anticipation est correcte, un profit sera donc réalisé. Ce profit horaire net 1 équivaut :

$$\pi_t = -10 * (y_t - 0.5) \tag{5.9}$$

où y_t est la valeur horaire du DART réel.

— $\bar{y}_{peak} > 0$ ou $\bar{y}_{offpeak} > 0$: Inversement, le prix DA est supérieur au prix RT. En prenant une position courte (position de vente) sur le marché DA, qui ensuite sera compensée par la position inverse (position d'achat) sur le marché RT, nous vendons au prix DA et nous allons ensuite acheter au prix RT. Si l'anticipation est correcte, le profit horaire net équivant :

$$\pi_t = 10 * (y_t - 0.5) \tag{5.10}$$

où y_t est la valeur horaire du DART réel.

La période testée est de 10 mois s'étalant de septembre 2021 à juin 2022. Le profit mensuel généré par la stratégie d'Hydro-Québec est présent sur la Figure 5.2 qui illustre les résultats de nos modèles pour cette stratégie. Ceci dit, le profit d'Hydro-Québec présenté est relatif à MISO au total. À contrario, nous travaillons uniquement sur huit nœuds de MISO.

Pourtant, la comparaison peut être pertinente : En effet, au niveau de l'ensemble des variables explicatives, nous constatons que ces derniers sont classés selon si le *hub* est au nord, centre ou sud. Ces variables demeureront les mêmes pour le restant des points de MISO. L'aptitude des modèles à générer un profit, pour le restant des points, est confirmée. Par suite, l'hypothèse que les trois modèles sont déjà aptes à battre la stratégie intuitive du parquet est vérifiée.

Au delà de cette hypothèse, comme le montre la Figure 5.2, nous pouvons constater que les trois modèles génèrent un profit. Le modèle de forêts aléatoires ainsi que le réseau de neurones génèrent quasi-similairement le plus de gain sur la période considérée. Certains pics à la hausse et à la baisse sont présents aussi sans pour-autant générer de pertes. Nous remarquons par ailleurs que la performance économique du Light GBM semble instable. Il génère le moins de profits comparativement aux autres modèles et subi une tendance haussière pour atteindre un pic de gain en date de juin 2022.

^{1.} Des frais de transactions de \$0.5/MWh s'appliquent.



FIGURE 5.2 Résultat mensuel cumulatif généré par la stratégie price taker

La Figure 5.2 montre le résultat mensuel cumulatif généré par la stratégie *price taker* pour l'ensemble des *hubs*. L'exercice est répété pour les trois modèles sur la période *out of sample* qui s'étale de septembre 2021 jusqu'en juillet 2022. Les séries horaires des prévisions du DART sont utilisées pour calculer la moyenne horaire estimée du DART *peak* et celle *off-peak*. La série horaire du DART réel permet de calculer le profit net dégagé selon la position prise. Tous les chiffres sont exprimés en \$.

La deuxième stratégie étudiée est une stratégie de vente. La position courte prise sur le marché DA sera compensée par une position longue sur le marché RT. Le profit horaire net est tel que :

- Si
$$\bar{\hat{y}}_{peak} > 0$$
:
 $\pi_t = 10 * (y_t - 0.5)$
(5.11)

- Sinon :

$$\pi_t = 0 \tag{5.12}$$

où y_t est la valeur horaire du DART réel.



FIGURE 5.3 Résultat mensuel cumulatif généré par la stratégie de vente

La Figure 5.3 montre le résultat mensuel cumulatif généré par la stratégie de vente. L'exercice est répété pour les trois modèles sur la période *out of sample* qui s'étale de septembre 2021 jusqu'en juillet 2022. Les séries horaires des prévisions du DART sont utilisées pour calculer la moyenne horaire estimée du DART *peak* et celle *off-peak*. La série horaire du DART réel permet de calculer le profit net dégagé selon la position prise. Tous les chiffres sont exprimés en \$.

Nous pouvons constater une grande similarité au niveau des résultats comparativement à ceux de la première stratégie. Particulièrement, le Light GBM performe mieux.

Ensuite, la troisième stratégie reprend le même esprit que la stratégie présentée ci-dessus mais se prend un seuil à partir duquel nous transigeons de l'électricité. Un exemple serait de prendre un seuil de \$4/MWh. Il s'agit d'un exemple proposé par l'un des négociants du parquet. Tout autre critère peut être donc considéré. Le profit horaire net est tel que :

— Si
$$\bar{\hat{y}}_{peak} >$$
\$4/MWh :
 $\pi_t = 10 * (y_t - 0.5)$ (5.13)

- Sinon :

$$\pi_t = 0 \tag{5.14}$$

où y_t est la valeur horaire du DART réel.

C'est une façon de profiter des fluctuations à la hausse des prix dans une quête de plus de profits. Dans ce cas, la distribution des profits est différente des autres stratégies comme le montre la Figure 5.4. En effet, c'est le modèle de forêts aléatoires et le Light GBM qui génèrent le plus de profits. Seul le réseau de neurones dégage une perte pour le mois de novembre 2021.

Puis, nous expérimentons une stratégie de vente naïve où nous prenons une position courte sur le marché DA peu importe le signe du DART horaire moyen estimé. Comme le montre la Figure 5.5, nous nous attendons que la stratégie soit profitable étant donné que le DART réel est à 70% des cas de signe positif.

FIGURE 5.4 Résultat mensuel cumulatif généré par la stratégie de vente conditionnelle à un seuil de 4/MWh



La Figure 5.4 montre le résultat mensuel cumulatif généré par la stratégie de vente conditionnelle. L'exercice est répété pour les trois modèles sur la période *out of sample* qui s'étale de septembre 2021 jusqu'en juillet 2022. Les séries horaires des prévisions du DART sont utilisées pour calculer la moyenne horaire estimée du DART *peak* et celle *off-peak*. La série horaire du DART réel permet de calculer le profit net dégagé selon la position prise. Tous les chiffres sont exprimés en \$.

Nous comparons également à titre d'exemple la stratégie *price taker* avec la vente naïve au niveau de la Figure 5.6. Le modèle de forêts aléatoires ainsi que le réseau de neurones performent mieux que la stratégie naïve.



FIGURE 5.5 Résultat mensuel cumulatif généré par la stratégie de vente naïve

La Figure 5.5 montre le résultat mensuel cumulatif généré par la stratégie de vente naïve expliquée ci-dessus. La série horaire du DART réalisé sur la période *out of sample* qui s'étale de septembre 2021 jusqu'en juillet 2022 est utilisée. Tous les chiffres sont exprimés en \$.





La Figure 5.6 a pour objectif de comparer le résultat mensuel cumulatif dégagé de la stratégie *price taker* avec celui de la stratégie naïve. L'exercice est répété pour les trois modèles sur la période *out of sample* qui s'étale de septembre 2021 jusqu'en juillet 2022. Les séries horaires des prévisions du DART et celles du DART réel permettent de calculer le profit net dégagé selon la position prise. Tous les chiffres sont exprimés en \$.

La cinquième stratégie est une stratégie d'achat. La position longue prise sur le marché DA sera compensée par une position courte sur le marché RT. Le profit horaire net est tel que :

— Si
$$\bar{\hat{y}}_{peak} < 0$$
:
 $\pi_t = -10 * (y_t - 0.5)$ (5.15)

— Sinon :

$$\pi_t = 0 \tag{5.16}$$

où y_t est la valeur horaire du DART réel.

Nous pouvons clairement constater que les modèles génèrent significativement plus de pertes que de profits. Ceci montre la difficulté des modèles à capturer un DART négatif. La stratégie n'est pas profitable quoique le modèle de forêts aléatoires performe de loin mieux que les deux autres modèles.

Finalement, il s'agit de comparer la stratégie d'avant avec un modèle d'achat naïf. En prenant tout le temps une position longue sur le marché DA, ce modèle présente des pertes significatives sans exception.



FIGURE 5.7 Résultat mensuel cumulatif généré par la stratégie d'achat

La Figure 5.7 montre le résultat mensuel cumulatif généré par la stratégie d'achat expliquée ci-dessus. L'exercice est répété pour les trois modèles sur la période *out of sample* qui s'étale de septembre 2021 jusqu'en juillet 2022. Les séries horaires des prévisions du DART sont utilisées pour calculer la moyenne horaire estimée du DART *peak* et celle *off-peak*. La série horaire du DART réel permet de calculer le profit net dégagé selon la position prise. Tous les chiffres sont exprimés en \$.



FIGURE 5.8 Résultats générés par la stratégie d'achat naïf

La Figure 5.8 montre le résultat mensuel cumulatif généré par la stratégie d'achat naïf. L'exercice concerne la période *out of sample* qui s'étale de septembre 2021 jusqu'en juillet 2022. La série horaire du DART réalisé est utilisée dans cet exercice. Tous les chiffres sont exprimés en \$.

Les Figures A.23 jusqu'à A.70 (Annexe) rapportent les profits journaliers générés par nos modèles, pour chaque stratégie décrite ci-dessus, respectivement pour chaque hub.

Pour résumer le tout, les tableaux 5.4, 5.5, 5.6 et 5.7^2 présentent la performance de chaque stratégie (*price taker*, vente, vente conditionnelle et vente naïve) selon différentes métriques statistiques. À titre d'exemple, nous nous apercevons que la distribution des résultats générés par la stratégie *price taker* est caractérisée par une asymétrie positive (*skewness*) pour le modèle de forêts aléatoires et le Light GBM. Les résultats sont donc plus positifs que négatifs. Ils se situent à la droite de la distribution. De plus, la *kurtosis* est significativement positive. Ceci témoigne de la présence davantage de profits importants au niveau de la queue droite de la distribution. Il s'agit d'une distribution à queue droite lourde. Ceci est le cas pour toutes les distribution asymétrique négative des profits horaires cumulatifs. Ce modèle génère plus de pertes que les autres au niveau de cette stratégie. Le profit maximum ainsi que la perte maximale accentuent ce fait. Le modèle qui semble être le moins risqué est celle de la vente conditionnelle à un seuil de 4\$/MWh. Elle génère certes moins de profits que les autres. Globalement, le modèle de forêts aléatoires et le forêts aléatoires et le conditionnelle à un seuil de 4\$/MWh.

^{2.} La VaR utilisée est une VaR paramétrique horaire.

pour la stratégie *price taker* et celle de vente performent le mieux. Ces modèles surpassent la vente naïve en termes de PnL (*Profit and Loss*) cumulatif. De plus, la vente naïve semble la plus risquée en termes de VaR. Par exemple, il y a 5% de chance que la stratégie de vendre naïvement sur les 8 *hubs*, à chaque heure, génère une perte supérieure ou égale à 1185.77 sur 1h.

	Forêts aléatoires	Light GBM	Réseau de neurones
PnL cumulatif	1 381 406	1 210 134	1 221 320
Profit maximum	13996,8	17656,4	2879,1
Perte maximale	-9157,4	-5415,7	-14938,4
Premier quartile	-63,15	-112,80	-82,40
Médiane	193,2	148,8	160,7
Troisième quartile	441,3	416,2	417,5
PnL moyen	177,22	155,24	156,68
Écart-type	562,04	596,46	521,41
Skewness	1,61	5,75	-4,10
Kurtosis	89,52	159,90	99,85
Value at Risk (VaR) 95% (1h)	1101,63	1136,27	1014,27
VaR 99% (1h)	1484,63	1542,72	1369,59
Pourcentage des PnL positifs	69.68 %	65.39~%	67.39%
Nombre de PnL	7796	7796	7796

TABLEAU 5.4 Performance des trois modèles pour la stratégie price taker

Le Tableau 5.4 montre plusieurs statistiques relatives aux résultats dégagés par les trois modèles pour la stratégie *price taker*. La série de données utilisée est celle du profit horaire cumulatif de l'ensemble des *hubs* (somme des résultats horaires pour les huit *hubs*) sur la période du *backtest* (entre septembre 2021 et juillet 2022). Tous les chiffres sont exprimés en .

	Forêts aléatoires	Light GBM	Réseau de neurones
PnL cumulatif	1 328 221	$1\ 242\ 574$	1 248 140
Profit maximum	2879,1	2757,9	2879,1
Perte maximale	-9157,4	-5415,7	-14938,4
Premier quartile	-57,35	-50,03	-59,95
Médiane	198,50	174,65	180,85
Troisième quartile	437,13	395,18	416,33
PnL moyen	170,37	159,39	160,10
Écart-type	526,68	466,87	536,98
Skewness	-2,28	-1,49	-4,42
Kurtosis	25,91	14,71	94,39
VaR 95% (1h)	1036,62	927,26	1043,30
VaR 99% (1h)	1395,52	1245,41	1409,23
Pourcentage des PnL positifs	70.41 %	70.38~%	69.65%
Nombre de PnL	7796	7796	7796

TABLEAU 5.5 Performance des trois modèles pour la stratégie de vente

Le Tableau 5.5 montre plusieurs statistiques relatives aux résultats dégagés par les trois modèles pour la stratégie de vente. La série de données utilisée est celle du profit horaire cumulatif de l'ensemble des *hubs* (somme des résultats horaires pour les huit *hubs*) sur la période du *backtest* (entre septembre 2021 et juillet 2022). Tous les chiffres sont exprimés en \$.

	Forêts aléatoires	Light GBM	Réseau de neurones
PnL cumulatif	976 803	857 368	627 727
Profit maximum	2785,2	2757,9	2785,3
Perte maximale	-5130,4	-5364,1	-15397,3
Premier quartile	0	-5,50	-32,33
Médiane	36,50	63,75	67,50
Troisième quartile	237,73	233,23	233,80
PnL moyen	125,30	109,98	80,52
Écart-type	376,21	372,33	438,11
Skewness	0,01	-0,68	-7,52
Kurtosis	13,56	18,90	221,94
VaR 95% (1h)	744,06	722,37	801,09
VaR 99% (1h)	1000,43	976,10	1099,64
Pourcentage des PnL positifs	56.40 %	64.02 %	63.76%
Nombre de PnL	7796	7796	7796

TABLEAU 5.6 Performance des trois modèles pour la stratégie de vente conditionnelle

Le tableau 5.6 montrent plusieurs statistiques relatives aux résultats dégagés par les trois modèles pour la stratégie de vente conditionnelle. La série de données utilisée est celle du profit horaire cumulatif de l'ensemble des *hubs* (somme des résultats horaires pour les huit *hubs*) sur la période du *backtest* (entre septembre 2021 et juillet 2022). Tous les chiffres sont exprimés en .

	Vente naïve
PnL cumulatif	$1\ 274\ 711$
Profit maximum	2879,1
Perte maximale	-14938,4
Premier quartile	-66,55
Médiane	206,55
Troisième quartile	459,73
PnL moyen	163,51
Écart-type	621,53
Skewness	-5,73
Kurtosis	101,90
VaR 95% (1h)	1185,77
VaR 99% (1h)	1609,31
Pourcentage des PnL positifs	69.77~%
Nombre de PnL	7796

TABLEAU 5.7 Performance de la stratégie de vente naïve

Le tableau 5.7 montrent plusieurs statistiques relatives aux résultats dégagés par la stratégie de vente naïve. La série de données utilisée est celle du profit horaire cumulatif de l'ensemble des hubs (somme des résultats horaires pour les huit hubs) sur la période du *backtest* (entre septembre 2021 et juillet 2022). Tous les chiffres sont exprimés en \$.

CHAPITRE 6 CONCLUSION

Dans ce dernier chapitre, un résumé général de la recherche est présenté. Quelques pistes de recherche futures sont également suggérées.

6.1 Synthèse des travaux

Ce projet porte sur la prévision de l'écart DART entre le prix du marché au lendemain (prix DA) et le prix réel (prix RT). Notre intérêt porte sur huit *hubs* du marché MISO.

Les données utilisées se répartissent en trois catégories : (1) les variables historiques, (2) les prévisions futures, (3) les données saisonnières. Nous tenons ainsi compte à la fois de la tendance passée du marché, de la perception future de l'environnement et des particularités du marché de l'électricité. Le choix des variables explicatives résulte d'une discussion approfondie avec les négociants du parquet et est également appuyé par la revue de littérature.

Les données sont collectées dans le cadre de mon stage chez Hydro-Québec et sont standardisées. Nous traitons les valeurs extrêmes selon la fonction score-Z. Les seuils trouvés permettent de définir les spikes et de les supprimer de notre base de données. Trois modèles de machine learning sont testés pour l'exercice d'estimation à savoir : un modèle de forêts aléatoires, un modèle d'arbre de décision LightGBM (Light Gradient Boosting Machine) et un réseau de neurones à couches multiples. Une approche d'expanding window est privilégiée lors de la phase d'entraînement. La période test s'étale de septembre 2021 jusqu'à juillet 2022. Cette recherche a permis de dresser un portrait du comportement du DART. Les modèles sont challengés pour capturer la volatilité de cette variable et de tirer profit des sauts positifs du DART. La performance statistique des modèles prouve la performance des forêts aléatoires ainsi que le réseau de neurones à prédire le DART. En s'interrogeant sur l'ordre d'importance des variables explicatives, nous avons eu recours aux valeurs de Shapley pour mesurer leur impact sur l'estimation. Les trois variables qui contribuent le plus sont respectivement la prévision du gaz au point Henry hub, le DART historique et la prévision de la demande en électricité. Pour certains hubs, la prévision des indices de température CDD et HDD, la prévision des retraits de génération et l'erreur historique au niveau de la congestion ont également un impact important sur la prévision.

D'un point de vue économique, nous avons mis en place une stratégie de *price taker*, une stratégie de vente, une stratégie de vente conditionnelle à l'atteinte d'un certain DART et une stratégie d'achat. La règle de négociation se base sur la moyenne du DART pour

les heures *peak* et celle des heures *off-peak*. Leurs résultats ont été comparés aux méthodes naïves et à la stratégie intuitive des négociants. Toutes les stratégies surpassent celle en vigueur présentement au sein du parquet et sont largement profitables. Nous nous attendons à ce que la vente naïve soit difficile à battre. Ceci est en relation avec le signe du DART observé sur le marché qui est positif dans 70% des cas. La vente est par suite profitable dans ces cas là. Cependant, les stratégies *price taker* et de vente génèrent plus de profit que la vente naïve pour le *Random Forest* et le réseau de neurones. Parallèlement, les stratégies d'achat impliquent des pertes significatives. Certes, nos modèles performent mieux que la stratégie d'achat naïve.

6.2 Améliorations futures

D'autres avenues de recherche sont intéressantes à explorer. L'amélioration du pouvoir de prévision de l'amplitude du DART en est une. Ceci nécessite un choix minutieux dans la sélection des variables prédictives. D'une part, une recherche de variables permettant de prédire les *spikes* peut être potentiellement faite pour pouvoir les inclure. D'autres part, certaines variables qui semblent peu contribuer à l'estimation peuvent être éliminées.

Une autre avenue potentielle serait d'évaluer l'intérêt d'opter pour un réseau de neurones récurrents. Un réseau de neurones récurrents présente des connexions récurrentes. Il est composé de nœuds inter-connectés interagissant non-linéairement. La nature temporelle des données et la dépendance entre les séries horaires sont adaptées à ce contexte.

RÉFÉRENCES

Yinglun Li, Nanpeng Yu, Wei Wang (2022) : Machine Learning-Driven Virtual Bidding With Electricity Market Efficiency Analysis, IEEE TRANSACTIONS ON POWER SYSTEMS, VOL. 37, NO. 1, JANUARY 2022

Derk J. Swider, Christoph Weber (2007) : Extended ARMA models for estimating price developments on day-ahead electricity markets, Electric Power Systems Research, Volume 77, Issues 5–6, 2007, Pages 583-593, ISSN 0378-7796.

J. Contreras, R. Espinola, F. J. Nogales and A. J. Conejo (2002) : ARIMA Models to Predict Next-Day Electricity Prices," in IEEE Power Engineering Review, vol. 22, no. 9, pp. 57-57, Sept. 2002, doi : 10.1109/MPER.2002.4312577.

A. J. Conejo, J. Contreras, R. Esanola, and M. A. Plazas (2005) : Forecasting electricity prices for a day-ahead pool-based electric energy market," Int. Jour. of Forecasting, vol. 21, no. 3, pp. 435–462, July-May 2005.

J. Nogales and A. J. Conejo (2005) : "Electricity price forecasting through transfer function models," Journal of the Operational Research Society, pp. 1–7, 2005

Haiteng XH, Niimura T. : Short-term electricity price modeling and forecasting using wavelets and multivariate time series. In : IEEE power systems conference and exposition PES, no. 1; 10–13 October 2004. p. 208–12.

Zhou M, Yan Z, Ni Y, Li G. : An ARIMA approach to forecasting electricity price with accuracy improvement by predicted errors. In : Proceedings of IEEE power engineering society general meeting, vol. 1; 6–10 June 2004. p. 233–8.

M. Zhou, Z. Yan, Y.X. Ni, G. Li and Y. Nie : Electricity price forecasting with confidenceinterval estimation through an extended ARIMA approach, EE Proc Generation Trans Distribution, 153 (2) (2006), pp. 187-195

R.C. Garcia, J. Contreras, M. Akkeren and J.B.C. van Garcia : A GARCH forecasting model to predict day-ahead electricity prices, IEEE Trans Power Syst, 20 (2) (2005), pp. 867-874

S. K. Aggarwal, L. M. Saini, and A. Kumar (2008) : "Electricity price forecasting in deregulated markets : A review and evaluation," International Journal of Electrical Power and Energy

Systems, vol. 31, no. 1, pp. 13–22, 2009. [Online]. Available : http ://dx.doi.org/10.1016/j. ijepes.2008.09.003

A. Gonzalez, A. Roque, and J. Garcia-Gonzalez (2005) :Modeling and forecasting electricity prices with input/output hidden Markov models," IEEE Transactions onPower Systems, vol. 20, no. 1, pp. 13–24, Feb. 2005

Y.Y. Hong and Chuan-Fang Lee (2005) : A neuro-fuzzy price forecasting approach in deregulated electricity markets, Electric Power Syst Res, 73 (2005), pp. 151-157.

C.P. Rodriguez and G.J. Anders (2004) : Energy price forecasting in the Ontario competitive power system market, IEEE Trans Power Syst, 19 (3) (2004), pp. 366-374.

Niimura T, Ko Hee-Sang, Ozawa K : A day-ahead electricity price prediction based on a fuzzyneuro autoregressive model in a deregulated electricity market. In : Proceedings of the 2002 international joint conference on neural networks, vol. 2, nos. 12–17; 2002. p. 1362–6.

Shiri, Ali Afshar, Mohammad Rahimi-Kian, Ashkan Maham, Behrouz (2015) : *Electricity* price forecasting using Support Vector Machines by considering oil and natural gas price impacts. 1-5. 10.1109/SEGE.2015.7324591.

José, Portela, González., Antonio, Muñoz, San, Roque., Estrella, Alonso, Pérez (2017) : Forecasting Functional Time Series with a New Hilbertian ARMAX Model : Application to Electricity Price Forecasting. IEEE Transactions on Power Systems, 33(1) :545-556. doi : 10.1109/TPWRS.2017.2700287.

Cerjan, M.; Petričić, A.; Delimar, M. (2019) : HIRA Model for Short-Term Electricity Price Forecasting. Energies 2019, 12, 568. https://doi.org/10.3390/en12030568.

Hassan, Saima Khosravi, Abbas Jaafar, Jafreezal Raza, M. (2014) : Electricity load and price forecasting with influential factors in a deregulated power industry. 79-84. 10.1109/SY-SOSE.2014.6892467.

J.P.S. Catalão, S.J.P.S. Mariano, V.M.F. Mendes, L.A.F.M. Ferreira (2007) :Short-term electricity prices forecasting in a competitive market : A neural network approach, Electric Power Systems Research, Volume 77, Issue 10, 2007, Pages 1297-1304, ISSN 0378-7796.

Jesus Lago, Fjo De Ridder, Bart De Schutter (2018) : Forecasting spot electricity prices : Deep learning approaches and empirical comparison of traditional algorithms, Applied Energy, Volume 221, 2018, Pages 386-405, ISSN 0306-2619.

Nika Nizharadze, Arash Farokhi Soofi, Saeed D. Manshadi (2020) :Learning the Gap in the Day-Ahead and Real-Time Locational Marginal Prices in the Electricity Market, https://doi.org/10.48550/arXiv.2012.12792

R. Das et al. (2022) :Forecasting Nodal Price Difference between Day-Ahead and Real-Time Electricity Markets using Long-Short Term Memory and Sequence-To-Sequence Networks," IEEE Access, vol. 10, pp. 832 - 843, Institute of Electrical and Electronics Engineers (IEEE), Jan 2022

S. Baltaoglu, L. Tong and Q. Zhao (2019) : Algorithmic Bidding for Virtual Trading in Electricity Markets," in IEEE Transactions on Power Systems, vol. 34, no. 1, pp. 535-543, Jan. 2019, doi : 10.1109/TPWRS.2018.2862246.

Galarneau-Vincent, Rémi and Gauthier, Genevieve and Godin, Frédéric (2022) : Foreseeing the Worst : Forecasting Electricity DART Spikes (June 10, 2022). Available at SSRN : https://ssrn.com/abstract=4133744 or http://dx.doi.org/10.2139/ssrn.4133744 .

Zahedi, G., Azizi, S., Bahadori, A., Elkamel, A. Alwi, S. R. W. (2013) : Electricity demand estimation using an adaptive neuro-fuzzy network : A case study from the Ontario province-Canada. Energy, 49 :323-328.

J. Zarnikau, C.K. Woo, S. Zhu, C.H. Tsai (2019) : Market price behavior of wholesale electricity products : Texas, Energy Policy, Volume 125, 2019, Pages 418-428, ISSN 0301-4215, https://doi.org/10.1016/j.enpol.2018.10.043.

Mahdi Hadj Ali, Yann Le Biannic, Pierre-HenriWuillemin (2021) : Réseaux bayésiens et valeurs de Shapley.10èmes Journée Francophones sur les Réseaux Bayésiens et les Modèles Graphiques Probabilistes (JFRB 2021), Oct 2021, Porquerolles, France. ffhal-03417323.

MA, Z., ZHONG, H., XIE, L. et al. (2018) : Month ahead average daily electricity price profile forecasting based on a hybrid nonlinear regression and SVM model : an ERCOT case study. J. Mod. Power Syst. Clean Energy 6, 281–291 (2018). https://doi.org/10.1007/s40565-018-0395-3.

Fan, J.-L., Hu, J.-W. Zhang, X. (2019) : Impacts of climate change on electricity demand in China : An empirical estimation based on panel data. Energy, 170 :880–888.

Zahedi, G., Azizi, S., Bahadori, A., Elkamel, A. Alwi, S. R. W. (2013). : Electricity demand estimation using an adaptive neuro-fuzzy network : A case study from the Ontario province-Canada. Energy, 49 :323-328. Yi-Ling, H., Hai-Zhen, M., Guang-Tao, D. Jun, S. (2014) : Influences of urban temperature on the electricity consumption of Shanghai. Advances in Climate Change Research, 5(2):74–80.

.

ANNEXE A

FIGURE A.1 Séries historiques des prix DA, prix RT et DART pour Illinois hub



L'encadré A montre les deux séries horaires des prix DA et RT pour Illinois sur la période allant du 12/2017 au 08/2022. L'encadré B représente la série du DART qui lui est associée (la différence entre le prix DA et le prix RT) pour les mêmes dates. L'encadré C est un zoom sur ce DART pour l'année 2022 (de septembre à mi-août).



FIGURE A.2 Séries historiques des prix DA, prix RT et DART pour Arkansas hub

L'encadré A montre les deux séries horaires des prix DA et RT pour Arkansas sur la période allant du 12/2017 au 08/2022. L'encadré B représente la série du DART qui lui est associée (la différence entre le prix DA et le prix RT) pour les mêmes dates. L'encadré C est un zoom sur ce DART pour l'année 2022 (de septembre à mi-août).



FIGURE A.3 Séries historiques des prix DA, prix RT et DART pour Louisiana hub

L'encadré A montre les deux séries horaires des prix DA et RT pour Louisiana sur la période allant du 12/2017 au 08/2022. L'encadré B représente la série du DART qui lui est associée (la différence entre le prix DA et le prix RT) pour les mêmes dates. L'encadré C est un zoom sur ce DART pour l'année 2022 (de septembre à mi-août).



FIGURE A.4 Séries historiques des prix DA, prix RT et DART pour Minnesota hub

L'encadré A montre les deux séries horaires des prix DA et RT pour Minnesota sur la période allant du 12/2017 au 08/2022. L'encadré B représente la série du DART qui lui est associée (la différence entre le prix DA et le prix RT) pour les mêmes dates. L'encadré C est un zoom sur ce DART pour l'année 2022 (de septembre à mi-août).



FIGURE A.5 Séries historiques des prix DA, prix RT et DART pour Michigan hub

L'encadré A montre les deux séries horaire des prix DA et RT pour Michigan sur la période allant du 12/2017 au 08/2022. L'encadré B représente la série du DART qui lui est associée (la différence entre le prix DA et le prix RT) pour les mêmes dates. L'encadré C est un zoom sur ce DART pour l'année 2022 (de septembre à mi-août).



FIGURE A.6 Séries historiques des prix DA, prix RT et DART pour Mississippi hub

L'encadré A montre les deux séries horaire des prix DA et RT pour Mississippi sur la période allant du 12/2017 au 08/2022. L'encadré B représente la série du DART qui lui est associée (la différence entre le prix DA et le prix RT) pour les mêmes dates. L'encadré C est un zoom sur ce DART pour l'année 2022 (de septembre à mi-août).



FIGURE A.7 Séries historiques des prix DA, prix RT et DART pour Texas hub

L'encadré A montre les deux séries horaires des prix DA et RT pour Texas sur la période allant du 12/2017 au 08/2022. L'encadré B représente la série du DART qui lui est associée (la différence entre le prix DA et le prix RT) pour les mêmes dates. L'encadré C est un zoom sur ce DART pour l'année 2022 (de septembre à mi-août).

	Forêts aléatoires	Light GBM	Réseau de neurones
12/2017-12/2020	12.49	12.89	14.24
12/2017-01/2021	12.41	12.86	14.16
12/2017-02/2021	14.36	14.28	16.08
12/2017-03/2021	14.29	14.02	15.97
12/2017-04/2021	14.66	14.55	16.32
12/2017-05/2021	14.62	14.46	16.34
12/2017-06/2021	14.68	14.51	16.55
12/2017-07/2021	14.79	14.71	16.47
12/2017-08/2021	14.75	14.58	16.42

TABLEAU A.1 RMSE in sample pour Illinois hub

TABLEAU A.2 RMSE out of sample pour Illinois hub

	Forêts aléatoires	Light GBM	Réseau de neurones
09/2021-10/2021	19.03	23.78	19.02
10/2021-11/2021	22.97	35.66	22.90
11/2021-12/2021	24.35	29.42	24.94
12/2021-01/2022	22.44	22.39	22.95
01/2022-02/2022	27.62	27.66	27.74
02/202-03/2022	24.75	30.30	25.31
03/2022-04/2022	18.90	18.97	19.03
04/2022-05/2022	18.81	31.48	21.03
05/2022-06/2022	34.46	48.08	35.24
06/2022-07/2022	37.68	54.62	38.11
07/2022-08/2022	48.98	57.99	49.36

La statistique RMSE in sample et out of sample est calculée respectivement pour le modèle des forêts aléatoires, le Light GBM et le réseau de neurones, pour Illlinois *hub*. Les modèles permettent de générer des résultats sur la période de *backtesting* entre septembre 2021 et juillet 2022.

	Forêts aléatoires	Light GBM	Réseau de neurones
12/2017-12/2020	9.27	8.44	10.05
12/2017-01/2021	9.22	8.36	9.94
12/2017-02/2021	9.62	8.83	10.39
12/2017-03/2021	9.55	8.73	10.29
12/2017-04/2021	9.52	8.72	10.25
12/2017-05/2021	9.47	8.72	10.21
12/2017-06/2021	9.49	8.70	10.23
12/2017-07/2021	9.51	8.75	10.21
12/2017-08/2021	9.35	8.54	9.98

TABLEAU A.3 RMSE in sample pour Louisiana hub

TABLEAU A.4 RMSE out of sample pour Louisiana hub

	Forêts aléatoires	Light GBM	Réseau de neurones
09/2021-10/2021	14.48	14.07	13.76
10/2021-11/2021	14.03	13.55	14.16
11/2021-12/2021	11.07	10.73	10.59
12/2021-01/2022	9.94	9.95	9.80
01/2022-02/2022	8.36	9.20	7.94
02/202-03/2022	9.92	10.26	9.49
03/2022-04/2022	11.61	11.72	11.44
04/2022-05/2022	18.71	19.01	20.12
05/2022-06/2022	20.41	27.55	18.98
06/2022-07/2022	16.13	21.85	15.66
07/2022-08/2022	19.01	22.13	19.02

La statistique RMSE in sample et out of sample est calculée respectivement pour le modèle des forêts aléatoires, le Light GBM et le réseau de neurones, pour Louisiana *hub*. Les modèles permettent de générer des résultats sur la période de *backtesting* entre septembre 2021 et juillet 2022.

	Forêts aléatoires	Light GBM	Réseau de neurones
12/2017-12/2020	7.44	7.57	8.43
12/2017-01/2021	7.54	7.67	8.58
12/2017-02/2021	7.58	7.71	8.56
12/2017-03/2021	7.54	7.67	8.51
12/2017-04/2021	7.54	7.65	8.54
12/2017-05/2021	7.56	7.70	8.48
12/2017-06/2021	7.55	7.67	8.50
12/2017-07/2021	7.57	7.71	8.56
12/2017-08/2021	7.54	7.61	8.59

TABLEAU A.5 RMSE in sample pour Michigan hub

TABLEAU A.6 RMSE out of sample pour Michigan hub

	Forêts aléatoires	Light GBM	Réseau de neurones
09/2021-10/2021	13.00	15.95	13.21
10/2021-11/2021	14.16	17.46	15.25
11/2021-12/2021	11.46	11.93	11.41
12/2021-01/2022	9.86	10.02	9.86
01/2022-02/2022	15.83	17.49	15.68
02/202-03/2022	9.99	10.65	10.00
03/2022-04/2022	12.60	13.36	13.91
04/2022-05/2022	17.75	18.10	23.13
05/2022-06/2022	15.10	16.87	18.01
06/2022-07/2022	16.31	18.91	16.92
07/2022-08/2022	15.74	18.92	15.42

La statistique RMSE in sample et out of sample est calculée respectivement pour le modèle des forêts aléatoires, le Light GBM et le réseau de neurones, pour Michigan *hub*. Les modèles permettent de générer des résultats sur la période de *backtesting* entre septembre 2021 et juillet 2022.

	Forêts aléatoires	Light GBM	Réseau de neurones
12/2017-12/2020	10.58	11.36	13.13
12/2017-01/2021	10.65	11.31	13.06
12/2017-02/2021	12.22	12.94	16.67
12/2017-03/2021	12.23	12.84	16.49
12/2017-04/2021	12.70	13.38	16.81
12/2017-05/2021	12.69	13.35	16.78
12/2017-06/2021	13.29	13.94	17.33
12/2017-07/2021	13.43	14.02	17.66
12/2017-08/2021	12.89	13.86	16.69

TABLEAU A.7 RMSE in sample pour Minnesota hub

TABLEAU A.8 RMSE out of sample pour Minnesota hub

	Forêts aléatoires	Light GBM	Réseau de neurones
09/2021-10/2021	16.18	19.53	18.59
10/2021-11/2021	20.34	34.48	29.70
11/2021-12/2021	21.78	33.52	25.68
12/2021-01/2022	25.20	25.83	26.42
01/2022-02/2022	28.42	27.70	28.70
02/202-03/2022	22.32	28.55	21.04
03/2022-04/2022	16.81	18.21	18.32
04/2022-05/2022	20.99	34.80	27.16
05/2022-06/2022	29.31	44.56	44.97
06/2022-07/2022	31.18	40.21	48.72
07/2022-08/2022	22.15	28.39	21.56

La statistique RMSE in sample et out of sample est calculée respectivement pour le modèle des forêts aléatoires, le Light GBM et le réseau de neurones, pour Minnesota *hub*. Les modèles permettent de générer des résultats sur la période de *backtesting* entre septembre 2021 et juillet 2022.

	Forêts aléatoires	Light GBM	Réseau de neurones
12/2017-12/2020	7.63	7.90	9.05
12/2017-01/2021	7.61	7.82	9.01
12/2017-02/2021	7.99	8.24	9.38
12/2017-03/2021	7.93	8.19	9.38
12/2017-04/2021	7.91	8.18	9.35
12/2017-05/2021	7.91	8.20	9.21
12/2017-06/2021	7.89	8.19	9.21
12/2017-07/2021	7.90	8.15	9.13
12/2017-08/2021	7.97	8.15	9.13

TABLEAU A.9 RMSE in sample pour Mississippi hub

TABLEAU A.10 RMSE out of sample pour Mississippi hub

	Forêts aléatoires	Light GBM	Réseau de neurones
09/2021-10/2021	12.16	13.07	11.67
10/2021-11/2021	13.28	14.49	12.71
11/2021-12/2021	9.59	10.18	9.79
12/2021-01/2022	9.40	9.44	9.20
01/2022-02/2022	7.68	8.15	7.32
02/202-03/2022	9.91	12.13	10.03
03/2022-04/2022	10.04	10.33	10.11
04/2022-05/2022	18.11	19.99	17.66
05/2022-06/2022	16.16	28.71	14.48
06/2022-07/2022	17.56	31.13	18.13
07/2022-08/2022	16.34	22.41	15.86

La statistique RMSE in sample et out of sample est calculée respectivement pour le modèle des forêts aléatoires, le Light GBM et le réseau de neurones, pour Mississippi *hub*. Les modèles permettent de générer des résultats sur la période de *backtesting* entre septembre 2021 et juillet 2022.
	Forêts aléatoires	Light GBM	Réseau de neurones
12/2017-12/2020	6.89	6.99	7.89
12/2017-01/2021	6.88	6.99	7.85
12/2017-02/2021	7.35	7.40	8.36
12/2017-03/2021	7.31	7.36	8.28
12/2017-04/2021	7.33	7.35	8.24
12/2017-05/2021	7.32	7.37	8.24
12/2017-06/2021	7.23	7.33	8.22
12/2017-07/2021	7.29	7.40	8.30
12/2017-08/2021	7.29	7.40	8.30

TABLEAU A.11 RMSE in sample pour Arkansas hub

TABLEAU A.12 RMSE out of sample pour Arkansas hub

	Forêts aléatoires	Light GBM	Réseau de neurones
09/2021-10/2021	10.69	10.67	10.21
10/2021-11/2021	14.36	14.52	14.24
11/2021-12/2021	9.93	9.79	9.82
12/2021-01/2022	9.59	9.45	9.45
01/2022-02/2022	6.91	7.07	6.92
02/202-03/2022	9.21	9.63	9.25
03/2022-04/2022	9.79	9.70	9.60
04/2022-05/2022	16.02	16.02	15.72
05/2022-06/2022	15.30	15.53	15.77
06/2022-07/2022	15.05	15.14	14.89
07/2022-08/2022	13.57	14.34	13.64

La statistique RMSE in sample et out of sample est calculée respectivement pour le modèle des forêts aléatoires, le Light GBM et le réseau de neurones, pour Arkansas *hub*. Les modèles permettent de générer des résultats sur la période de *backtesting* entre septembre 2021 et juillet 2022.





La Figure A.8 rapporte l'importance globale des variables prédictives pour Illinois, pour les trois modèles et ce selon la moyenne absolue des valeurs de Shapley calculés. La période considérée est celle out of sample de septembre 2021 jusqu'à juillet 2022.





La Figure A.9 rapporte l'importance globale des variables prédictives pour Louisiana, pour les trois modèles et ce selon la moyenne absolue des valeurs de Shapley calculés. La période considérée est celle out of sample de septembre 2021 jusqu'à juillet 2022.





La Figure A.10 rapporte l'importance globale des variables prédictives pour Michigan, pour les trois modèles et ce selon la moyenne absolue des valeurs de Shapley calculés. La période considérée est celle out of sample de septembre 2021 jusqu'à juillet 2022.









La Figure A.12 rapporte l'importance globale des variables prédictives pour Minnesota, pour les trois modèles et ce selon la moyenne absolue des valeurs de Shapley calculés. La période considérée est celle out of sample de septembre 2021 jusqu'à juillet 2022.















(a) Shap values du modèle Random forest pour Indiana hub

(b) Shap values du modèle Light GBM pour Indiana hub



(c) Shap values du réseau de neurones pour Indiana hub

FIGURE A.15 Shap values des trois modèles testés pour Indiana hub



(a) Shap values du modèle random forest pour Illinois hub

(b) Shap values du modèle Light GBM pour Illinois hub



(c) Shap values du réseau de neurones pour Illinois hub

FIGURE A.16 Shap values des trois modèles testés pour Illinois hub



(a) Shap values du random forest pour Louisiana hub

(b) Shap values du modèle Light GBM pour Louisiana hub



(c) Shap values du réseau de neurones pour Louisiana hub

FIGURE A.17 Shap values des trois modèles testés pour Louisiana hub



(a) Shap values du modèle random forest pour Michigan hub

(b) Shap values du modèle Light GBM pour Michigan hub



(c) Shap values du réseau de neurones pour Michigan hub

FIGURE A.18 Shap values des trois modèles testés pour Michigan hub



(a) Shap values du modèle random forest pour Texas hub

(b) Shap values du modèle Light GBM pour Texas hub



(c) Shap values du réseau de neurones pour Texas hub

FIGURE A.19 Shap values des trois modèles testés pour Texas hub



(a) Shap values du modèle random forest pour Minnesota hub

(b) Shap values du modèle Light GBM pour Minnesota hub



(c) Shap values du réseau de neurones pour Minnesota hub

FIGURE A.20 Shap values des trois modèles testés pour Minnesota hub



(a) Shap values du modèle random forest pour Mississippi hub

(b) Shap values du modèle Light GBM pour Mississippi hub



(c) Shap values du réseau de neurones pour Mississippi hub

FIGURE A.21 Shap values des trois modèles testés pour Mississippi hub



(a) Shap values du modèle random forest pour Arkansas hub

(b) Shap values du modèle Light GBM pour Arkansas hub



(c) Shap values du réseau de neurones pour Arkansas hub

FIGURE A.22 Shap values des trois modèles testés pour Arkansas hub



FIGURE A.23 Profits journaliers de la stratégie price taker pour Indiana hub

Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie *price taker* pour Indiana. Les données impliquées sont à la fois le DART estimé, pour chaque heure, et la série horaire du DART réalisé. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.

FIGURE A.24 Profits journaliers de la stratégie price taker pour Illinois hub



Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie *price taker* pour Illinois. Les données impliquées sont à la fois le DART estimé, pour chaque heure, et la série horaire du DART réalisé. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.



FIGURE A.25 Profits journaliers de la stratégie price taker pour Louisiana hub

Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie *price taker* pour Louisiana. Les données impliquées sont à la fois le DART estimé, pour chaque heure, et la série horaire du DART réalisé. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.

FIGURE A.26 Profits journaliers de la stratégie price taker pour Michigan hub



Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie *price taker* pour Michigan. Les données impliquées sont à la fois le DART estimé, pour chaque heure, et la série horaire du DART réalisé. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.



FIGURE A.27 Profits journaliers de la stratégie price taker pour Texas hub

Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie *price taker* pour Texas. Les données impliquées sont à la fois le DART estimé, pour chaque heure, et la série horaire du DART réalisé. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.

FIGURE A.28 Profits journaliers de la stratégie price taker pour Minnesota hub



Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie *price taker* pour Minnesota. Les données impliquées sont à la fois le DART estimé, pour chaque heure, et la série horaire du DART réalisé. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.



FIGURE A.29 Profits journaliers de la stratégie price taker pour Mississippi hub

Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie *price taker* pour Mississippi. Les données impliquées sont à la fois le DART estimé, pour chaque heure, et la série horaire du DART réalisé. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.

FIGURE A.30 Profits journaliers de la stratégie price taker pour Arkansas hub



Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie *price taker* pour Arkansas. Les données impliquées sont à la fois le DART estimé, pour chaque heure, et la série horaire du DART réalisé. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.



FIGURE A.31 Profits journaliers de la stratégie de vente pour Indiana hub

Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie de vente pour Indiana. Les données impliquées sont à la fois le DART estimé, pour chaque heure, et la série horaire du DART réalisé. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.

FIGURE A.32 Profits journaliers de la stratégie de vente pour Illinois hub



Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie de vente pour Illinois. Les données impliquées sont à la fois le DART estimé, pour chaque heure, et la série horaire du DART réalisé. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.



FIGURE A.33 Profits journaliers de la stratégie de vente pour Louisiana hub

Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie de vente pour Louisiana. Les données impliquées sont à la fois le DART estimé, pour chaque heure, et la série horaire du DART réalisé. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.

FIGURE A.34 Profits journaliers de la stratégie de vente pour Michigan hub



Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie de vente pour Michigan. Les données impliquées sont à la fois le DART estimé, pour chaque heure, et la série horaire du DART réalisé. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.



FIGURE A.35 Profits journaliers de la stratégie de vente pour Texas hub

Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie de vente pour Texas. Les données impliquées sont à la fois le DART estimé, pour chaque heure, et la série horaire du DART réalisé. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.

FIGURE A.36 Profits journaliers de la stratégie de vente pour Minnesota hub



Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie de vente pour Minnesota. Les données impliquées sont à la fois le DART estimé, pour chaque heure, et la série horaire du DART réalisé. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.



FIGURE A.37 Profits journaliers de la stratégie de vente pour Mississippi hub

Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie de vente pour Mississippi. Les données impliquées sont à la fois le DART estimé, pour chaque heure, et la série horaire du DART réalisé. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.

FIGURE A.38 Profits journaliers de la stratégie de vente pour Arkansas hub



Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie de vente pour Arkansas. Les données impliquées sont à la fois le DART estimé, pour chaque heure, et la série horaire du DART réalisé. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.



FIGURE A.39 Profits journaliers de la stratégie de vente conditionnelle pour Indiana hub

Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie de vente conditionnelle pour Indiana. Les données impliquées sont à la fois le DART estimé, pour chaque heure, et la série horaire du DART réalisé. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.

FIGURE A.40 Profits journaliers de la stratégie de vente conditionnelle pour Illinois hub



Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie de vente conditionnelle pour Illinois. Les données impliquées sont à la fois le DART estimé, pour chaque heure, et la série horaire du DART réalisé. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.



FIGURE A.41 Profits journaliers de la stratégie de vente conditionnelle pour Louisiana hub

Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie de vente conditionnelle pour Louisiana. Les données impliquées sont à la fois le DART estimé, pour chaque heure, et la série horaire du DART réalisé. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.

FIGURE A.42 Profits journaliers de la stratégie de vente conditionnelle pour Michigan hub



Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie de vente conditionnelle pour Michigan. Les données impliquées sont à la fois le DART estimé, pour chaque heure, et la série horaire du DART réalisé. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.



FIGURE A.43 Profits journaliers de la stratégie de vente conditionnelle pour Texas hub

Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie de vente conditionnelle pour Texas. Les données impliquées sont à la fois le DART estimé, pour chaque heure, et la série horaire du DART réalisé. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.

FIGURE A.44 Profits journaliers de la stratégie de vente conditionnelle pour Minnesota hub



Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie de vente conditionnelle pour Minnesota. Les données impliquées sont à la fois le DART estimé, pour chaque heure, et la série horaire du DART réalisé. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.



FIGURE A.45 Profits journaliers de la stratégie de vente conditionnelle pour Mississippihub

Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie de vente conditionnelle pour Mississippi. Les données impliquées sont à la fois le DART estimé, pour chaque heure, et la série horaire du DART réalisé. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.

FIGURE A.46 Profits journaliers de la stratégie de vente conditionnelle pour Arkansas hub



Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie de vente conditionnelle pour Arkansas. Les données impliquées sont à la fois le DART estimé, pour chaque heure, et la série horaire du DART réalisé. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.



FIGURE A.47 Profits journaliers de la stratégie de vente naïve pour Indiana hub

Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie de vente naïve pour Indiana. Nous nous basons sur la série horaire du DART réalisé pour le calcul. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.

FIGURE A.48 Profits journaliers de la stratégie de vente naïve pour Illinois hub



Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie de vente naïve pour Illinois. Nous nous basons sur la série horaire du DART réalisé pour le calcul. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.



FIGURE A.49 Profits journaliers de la stratégie de vente naïve pour Louisiana hub

Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie de vente naïve pour Louisiana. Nous nous basons sur la série horaire du DART réalisé pour le calcul. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.

FIGURE A.50 Profits journaliers de la stratégie de vente naïve pour Michigan hub



Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie de vente naïve pour Michigan. Nous nous basons sur la série horaire du DART réalisé pour le calcul. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.



FIGURE A.51 Profits journaliers de la stratégie de vente naïve pour Texas hub

Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie de vente naïve pour Texas. Nous nous basons sur la série horaire du DART réalisé pour le calcul. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.

FIGURE A.52 Profits journaliers de la stratégie de vente naïve pour Minnesota hub



Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie de vente naïve pour Minnesota. Nous nous basons sur la série horaire du DART réalisé pour le calcul. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.



FIGURE A.53 Profits journaliers de la stratégie de vente naïve pour Mississippi hub

Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie de vente naïve pour Mississippi. Nous nous basons sur la série horaire du DART réalisé pour le calcul. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.

FIGURE A.54 Profits journaliers de la stratégie de vente naïve pour Arkansas hub



Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie de vente naïve pour Arkansas. Nous nous basons sur la série horaire du DART réalisé pour le calcul. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.



FIGURE A.55 Profits journaliers de la stratégie d'achat pour Indiana hub

Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie d'achat pour Indiana. Les données impliquées sont à la fois le DART estimé, pour chaque heure, et la série horaire du DART réalisé. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.

12500 Profit journalier du modèle Random Forest Profit journalier du modèle GBM Profit journalier du modèle réseau de 10000 7500 5000 Prices 2500 0 -2500 -5000 2021-09 2021-10 2021-11 2021-12 2022-01 2022-02 Date 2022-03 2022-04 2022-05 2022-06 2022-07

FIGURE A.56 Profits journaliers de la stratégie d'achat pour Illinois hub

Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie d'achat pour Illinois. Les données impliquées sont à la fois le DART estimé, pour chaque heure, et la série horaire du DART réalisé. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.



FIGURE A.57 Profits journaliers de la stratégie d'achat pour Louisiana hub

Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie d'achat pour Louisiana. Les données impliquées sont à la fois le DART estimé, pour chaque heure, et la série horaire du DART réalisé. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.

FIGURE A.58 Profits journaliers de la stratégie d'achat pour Michigan hub



Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie d'achat pour Michigan. Les données impliquées sont à la fois le DART estimé, pour chaque heure, et la série horaire du DART réalisé. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.



FIGURE A.59 Profits journaliers de la stratégie d'achat pour Texas hub

Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie d'achat pour Texas. Les données impliquées sont à la fois le DART estimé, pour chaque heure, et la série horaire du DART réalisé. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.

FIGURE A.60 Profits journaliers de la stratégie d'achat pour Minnesota hub



Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie d'achat pour Minnesota. Les données impliquées sont à la fois le DART estimé, pour chaque heure, et la série horaire du DART réalisé. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.



FIGURE A.61 Profits journaliers de la stratégie d'achat pour Mississippi hub

Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie d'achat pour Mississippi. Les données impliquées sont à la fois le DART estimé, pour chaque heure, et la série horaire du DART réalisé. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.

FIGURE A.62 Profits journaliers de la stratégie d'achat pour Arkansas hub



Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie d'achat pour Arkansas. Les données impliquées sont à la fois le DART estimé, pour chaque heure, et la série horaire du DART réalisé. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.


FIGURE A.63 Profits journaliers de la stratégie d'achat naïf pour Indiana hub

Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie d'achat naïf pour Indiana. Nous nous basons sur la série horaire du DART réalisé pour le calcul. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.



FIGURE A.64 Profits journaliers de la stratégie d'achat naïf pour Illinois hub

Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie d'achat naïf pour Illinois. Nous nous basons sur la série horaire du DART réalisé pour le calcul. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.



FIGURE A.65 Profits journaliers de la stratégie d'achat naïf pour Louisiana hub

Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie d'achat naïf pour Louisiana. Nous nous basons sur la série horaire du DART réalisé pour le calcul. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.

FIGURE A.66 Profits journaliers de la stratégie d'achat naïf pour Michigan hub



Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie d'achat naïf pour Michigan. Nous nous basons sur la série horaire du DART réalisé pour le calcul. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.



FIGURE A.67 Profits journaliers de la stratégie d'achat naïf pour Texas hub

Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie d'achat naïf pour Texas. Nous nous basons sur la série horaire du DART réalisé pour le calcul. La période considérée, celle du *back-testing*, s'étale de septembre 2021 jusqu'en juillet 2022.

FIGURE A.68 Profits journaliers de la stratégie d'achat naïf pour Minnesota hub



Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie d'achat naïf pour Minnesota. Nous nous basons sur la série horaire du DART réalisé pour le calcul. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.



FIGURE A.69 Profits journaliers de la stratégie d'achat naïf pour Mississippi hub

Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie d'achat naïf pour Mississippi. Nous nous basons sur la série horaire du DART réalisé pour le calcul. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.

FIGURE A.70 Profits journaliers de la stratégie d'achat naïf pour Arkansas hub



Les graphiques montrent les profits journaliers (cumulatifs) générés par la stratégie d'achat naïf pour Arkansas. Nous nous basons sur la série horaire du DART réalisé pour le calcul. La période considérée, celle du *backtesting*, s'étale de septembre 2021 jusqu'en juillet 2022.