



HAL
open science

Solutions avancées de gestion pour les micro-réseaux à fort taux de pénétration des sources renouvelables sous l'incertitude

Valentin Mathieu

► **To cite this version:**

Valentin Mathieu. Solutions avancées de gestion pour les micro-réseaux à fort taux de pénétration des sources renouvelables sous l'incertitude. Energie électrique. Université Grenoble Alpes [2020-..], 2024. Français. NNT : 2024GRALT058 . tel-04870320

HAL Id: tel-04870320

<https://theses.hal.science/tel-04870320v1>

Submitted on 7 Jan 2025

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

THÈSE

Pour obtenir le grade de

DOCTEUR DE L'UNIVERSITÉ GRENOBLE ALPES

École doctorale : EEATS - Electronique, Electrotechnique, Automatique, Traitement du Signal (EEATS)

Spécialité : Génie électrique

Unité de recherche : CEA Grenoble - LITEN

Solutions avancées de gestion pour les micro-réseaux à fort taux de pénétration des sources renouvelables sous l'incertitude

Advanced solutions of management for microgrids with high penetration of renewable energy resources under uncertainty

Présentée par :

Valentin MATHIEU

Direction de thèse :

Quoc Tuan TRAN
PROFESSEUR ET DIRECTEUR DE RECHERCHE, CEA-LITEN / INES

Directeur de thèse

Grégoire PICHENOT
INGÉNIEUR DE RECHERCHE, CEA-LITEN / INES

Co-encadrant de thèse

Rapporteurs :

Mohamed BENBOUZID
PROFESSEUR DES UNIVERSITES, UNIVERSITE DE BREST-BRETAGNE OCCIDENTALE

Bruno FRANCOIS
PROFESSEUR DES UNIVERSITES, ECOLE CENTRALE LILLE

Thèse soutenue publiquement le **27 septembre 2024**, devant le jury composé de :

Seddik BACHA,
PROFESSEUR DES UNIVERSITES, UNIVERSITE GRENOBLE ALPES

Président

Quoc Tuan TRAN,
PROFESSEUR ET DIRECTEUR DE RECHERCHE, CEA-LITEN / INES

Directeur de thèse

Mohamed BENBOUZID,
PROFESSEUR DES UNIVERSITES, UNIVERSITE DE BREST-BRETAGNE OCCIDENTALE

Rapporteur

Bruno FRANCOIS,
PROFESSEUR DES UNIVERSITES, ECOLE CENTRALE LILLE

Rapporteur

Corinne ALONSO,
PROFESSEURE DES UNIVERSITES, UNIVERSITE TOULOUSE III
- PAUL SABATIER

Examinatrice

Invités :

Grégoire PICHENOT
INGÉNIEUR DE RECHERCHE, CEA-LITEN / INES



"À Mamichou, à Papidou,"

Remerciements

Le chemin pour arriver à cette soutenance de thèse a été un parcours ardu assimilable à une randonnée alpine, avec son lot de montées interminables, de panoramas à contempler, de vallées sombres, d'alpages fleuris, de pierriers glissants et de lacs translucides. À l'arrivée, on pourrait croire être de retour au point de départ, inchangé et immobile, mais le chemin parcouru et le travail réalisé enrichissent l'esprit. Comme en montagne, il est essentiel de bien s'entourer, car personne n'apprend seul.

La recherche scientifique repose sur la reconnaissance et les échanges entre pairs. Je tiens donc à remercier en premier lieu mes rapporteurs, Mohamed Benbouzid et Bruno François, pour leur regard d'expert et leurs remarques très constructives sur mon manuscrit. Je remercie également le président de mon jury, Seddik Bacha, qui a dirigé cette soutenance de manière fluide et sympathique, marquant ainsi la fin de plusieurs mois de travail. Merci également à Corinne Alonso d'avoir accepté de faire partie de ce jury, avec lequel j'ai apprécié échanger après ma présentation sur la portée, les apports et les limites de mes travaux.

Dans un second temps, je soulignerai le rôle de ceux qui m'ont aidé à tracer mon sentier grâce à leurs connaissances et leur soutien. Merci à Tuan, mon directeur de thèse, pour son suivi et sa vision des enjeux de mes recherches. Merci à Grégoire pour sa patience, sa rigueur et ses remarques précieuses sur les aspects les plus pointus de mon sujet. Merci aussi d'avoir partagé ta culture générale lors de nos longues réunions, qui nous ont permis d'aérer nos cerveaux et de trouver des liens entre nos travaux et des sujets variés.

L'équipe du **LIRE** a également joué un rôle important. Je remercie tout particulièrement Phong pour son soutien et ses encouragements réguliers, ainsi que Grégory pour ses mots motivants, son humanisme et sa compréhension dès son arrivée en tant que chef de laboratoire. L'équipe des doctorants m'a permis de bénéficier d'un bureau jovial et multiculturel, d'un groupe pour déjeuner et évaluer scientifiquement la qualité des desserts de la cantine, ainsi que pour partager les aventures du statut si particulier de jeune chercheur, naviguant dans des océans chacun dans sa coquille de noix. Merci de votre présence, Antoine, Marta, Omar, Paul, Sameh et Yara.

J'aimerais également évoquer mes colocataires, compagnons du quotidien, qui ont égayé mes journées. Leur rôle a été crucial dans l'apprentissage de la collaboration, de l'ouverture d'esprit et de la vie collective, si importante dans la vie professionnelle. Merci pour cela, mais aussi pour les sourires du matin, les pauses déjeuner prolongées et les moments conviviaux du soir 🍷. Miaou miaouoou 😊.

Une pensée spéciale pour mes cercles d'amis, partenaires de jeux, de soirées, de vacances, de week-ends, de débats, de blagues et de sports en tous genres. Leur soutien a été primordial dans les moments difficiles de cette thèse. Comme pour mes colocataires, je ne me risquerai pas à les citer ; ils savent déjà quelle place ils occupent dans mon cur et j'espère continuer à écrire nos histoires ensemble ♥.

Comment évoquer le rôle de ma famille sans écrire un deuxième manuscrit. Je vais faire court : il me suffit de fermer les yeux pour vous savoir à mes côtés et compter sur votre amour à chaque instant pour m'aider à avancer. Papa, Maman, Romane, Clément 🍷.

Enfin, une **grosse** pensée pour Ambre, ma gardienne de refuge, mon étoile du berger, ma compagne de cordée, pour cette dernière année et celles à venir ... 🍷

Table des matières

Remerciements	i
Table des matières	iii
Liste des figures	vii
Liste des tableaux	xi
Nomenclature	xiii
Abréviations et acronymes	xv
Glossaire	xvii
Introduction générale	1
Partie I État de l’art et concepts pour la prévision PV et la gestion de micro-réseau sous incertitude	9
Chapitre 1 Prévision de la production d’une centrale PV et son incertitude	11
1.1 Aléa photovoltaïque : variabilité et incertitude	12
1.2 Ensemble des données utilisées pour la prévision	13
1.3 Approches de prévisions	14
1.3.1 Prévision directe vs. indirecte	14
1.3.2 Horizons de prévision	15
1.3.3 Modélisation de l’incertitude	15
1.4 Méthodes de prévisions	17
1.4.1 Modèles physiques	18
1.4.2 Modèles non-physiques ou statistiques	18
1.4.3 Modèles ensemblistes	21
1.4.4 Modèles hybrides	21
1.4.5 Perspectives	22
1.5 Représentation de l’incertitude : la prévision probabiliste	22
1.5.1 Prévision déterministe, stochastique, québécois	22
1.5.2 Différentes approches de représenter l’incertitude	23
1.6 Évaluation de la prévision	27
1.6.1 Indicateurs pour prévision déterministe	27
1.6.2 Indicateurs pour prévision probabiliste	29
1.7 Conclusions	32
Chapitre 2 Gestion de micro-réseau sous incertitude	35
2.1 L’optimisation appliquée au problème de la gestion de micro-réseau	36
2.1.1 Le principe de l’optimisation	36
2.1.2 Méthodes d’optimisation	36
2.1.3 Autres approches	37
2.2 Optimisation probabiliste	38

2.2.1	Optimisation stochastique	38
2.2.2	Optimisation robuste	39
2.2.3	Optimisation avec contraintes probabilistes	40
2.3	Applications pour la gestion de micro-réseau	41
2.3.1	Opérations et participation au marché	41
2.3.2	Services systèmes	43
2.3.3	Stabilité, sécurité et fiabilité d'opération	44
2.4	Conclusions	45
 Partie II Une représentation de l'incertitude : génération de scénarios de productible PV		47
 Chapitre 3 Caractérisation de l'aléa PV : de la prévision à la loi multivariée		57
3.1	Construction des lois marginales à partir de prévisions probabilistes	58
3.1.1	Obtention des prévisions probabilistes : la régression quantile et sa mise en oeuvre	60
3.1.2	Estimation de la fonction de répartition empirique	63
3.1.3	Support des fonctions de répartition marginales	64
3.1.4	Construction des lois marginales empiriques	67
3.1.5	Contrôle de l'obtention des pseudo-variables	68
3.2	Caractérisation d'un modèle de corrélation	68
3.2.1	La notion de corrélation	70
3.2.2	Présentation de différentes copules et méthodes de caractérisation	72
3.2.3	Résultats de la caractérisation et comparaison des copules	76
3.3	Conclusions, limites et perspectives	79
 Chapitre 4 Génération d'un ensemble de réduit de scénarios		81
4.1	Génération de scénarios	82
4.1.1	Méthode de tirage de scénarios	82
4.1.2	Présentation de scénarios générés	83
4.1.3	Vérification des scénarios	83
4.2	Réduction de scénarios	85
4.2.1	Méthode heuristique	86
4.2.2	Méthode de clustering : k-médoïdes	87
4.2.3	Résultats de la réduction	87
4.2.4	Comparaison des méthodes et nombre minimal de scénarios initial	88
4.2.5	Intérêt de la méthode	90
4.2.6	Effet du nombre de scénarios final	90
4.2.7	Exemple d'un ensemble réduit de scénarios	91
4.3	Conclusions, limites et perspectives	93
 Chapitre 5 Assimilation de données de production PV		95
5.1	Description de la méthode d'assimilation	96
5.1.1	Copule conditionnelle	96
5.1.2	Loi normale multivariée conditionnelle	97
5.1.3	Loi t-Student multivariée conditionnelle	97
5.1.4	Obtention de quantiles conditionnels	98
5.2	Échantillon issu de l'assimilation	98
5.3	Intérêt de l'assimilation de données	102
5.4	Conclusions, limites et perspectives	102

Partie III Planification de micro-réseau sous incertitude	105
Chapitre 6 Cas d'étude : planification d'un micro-réseau sous incertitude	107
6.1 Présentation du cas d'étude considéré	108
6.1.1 Horizon temporel et variables étudiées	109
6.1.2 Caractéristiques du système étudié	110
6.1.3 Association d'une courbe de charge résidentielle et de production PV	113
6.1.4 Le rôle du pilotage de la batterie et du micro-réseau	115
6.1.5 Hypothèses simplificatrices	116
6.1.6 Conventions	116
6.2 Modèles des entités	116
6.2.1 Charge	116
6.2.2 Centrale PV	117
6.2.3 Stockage	117
6.3 Stratégies de planification	117
6.3.1 Critère économique	118
6.3.2 Contraintes sur la puissance soutirée	119
6.3.3 Formalisation du problème de planification	120
6.4 Méthodologie d'évaluation des approches	122
6.4.1 Coût des écarts	122
6.4.2 Contrainte de soutirage	123
6.4.3 Autoconsommation	124
Chapitre 7 Résultats de la planification	127
7.1 Intérêt de l'anticipation et de la planification	128
7.1.1 Cas d'étude sans planification	128
7.1.2 Cas d'étude avec stockage et planification	131
7.2 Résultats de la planification déterministe	136
7.2.1 Focus sur certaines journées	136
7.2.2 Résultats globaux	148
7.3 Résultats de la planification stochastique	152
7.3.1 Focus sur certaines journées	152
7.3.2 Résultats globaux et comparaison avec l'approche déterministe	161
7.4 Influence du nombre de scénarios	165
7.5 Influence de la pénalité des écarts	167
7.6 Intérêt de la méthode de génération de scénarios	167
7.6.1 Prise en compte de la dépendance temporelle	167
7.6.2 Méthode de réduction de scénario	169
7.7 Conclusions, limites et perspectives	169
Conclusion générale et perspectives	171
Partie IV Annexes	I
Publications	III
Bibliographie	V

Annexe A Bases de la théorie des probabilités	XXIII
A.1 Espaces de probabilités, variables aléatoires	XXIV
A.1.1 L'espace de probabilité	XXIV
A.1.2 La variable aléatoire	XXIV
A.1.3 La loi de variable aléatoire	XXIV
A.2 Fonctions associées à une variable aléatoire	XXIV
A.2.1 Fonction de répartition	XXIV
A.2.2 Densité de probabilité	XXV
A.3 Autres concepts	XXVI
A.3.1 Covariance	XXVI
Annexe B Données d'entrée	XXVII
B.1 Prévisions PV	XXVIII
B.2 Réalisations	XXVIII
B.2.1 PV	XXVIII
B.2.2 Charge	XXVIII
B.2.3 Disponibilité des données	XXVIII
B.3 Diversité des distribution de production PV	XXVIII
Annexe C Diagrammes de blocs	XXXIII
Annexe D Résultats de la planification	XXXV
D.1 Plan détaillé de la planification stochastique	XXXVI
D.1.1 Cas 1	XXXVI
D.1.2 Cas 2	XLII
D.2 Résultats globaux de la planification stochastique	XLVIII
D.2.1 Distribution horaire des écarts planifiés	XLVIII
D.2.2 Distribution horaire des écarts réalisés	XLIX
Résumé - Abstract	LI

Table des figures

1	Évolution de la capacité installée et de la part de l'énergie photovoltaïque dans le mix électrique en France (2013-2022) [7].	2
2	Représentation schématique du concept de micro-réseau	3
1.1	Résumé des facteurs principaux influençant la variabilité de la production PV . . .	12
1.2	Catégories d'horizons de prévision PV	15
1.3	Exemples de densités de probabilité pour différents paramètres pouvant servir à une approche paramétrique de la prévision PV [31]	16
1.4	Aperçu des différents types de modèles de prévision PV	17
1.5	Illustration des différentes représentations de l'incertitude de prévision	24
1.6	Illustration du principe de réduction de scénarios	26
2.1	Résumé des différentes méthodes d'optimisation employées dans la gestion des micro-réseaux	38
2.2	Illustration des différentes approches d'optimisation probabiliste	40
2.3	Organisation et temporalités du marché de l'électricité en Europe [130]	42
2.4	Effet des différents types de réserves sur l'équilibrage du réseau [137]	43
2.5	Différentes applications de l'optimisation probabiliste pour la gestion et l'opération de micro-réseaux	44
2.6	Représentation du processus de génération de scénario	49
2.7	Illustration du processus permettant d'obtenir un échantillon aléatoire selon une loi	51
2.8	Illustration de la notion de copule à travers les FdR marginales d'une variable et sa correspondance dans la dimension de la copule	54
3.1	Exemple d'une prévision probabiliste	59
3.2	Contrôle des quantiles par comptage avant et après recalibrage	62
3.3	Distributions des observations de production PV	64
3.4	Illustration de l'approximation de fonction de répartition par interpolation linéaire par une liste de quantiles et tirage aléatoire associé)	65
3.5	Illustration du principe de l'estimation par noyau	67
3.6	Exemples d'estimation de lois de probabilité	69
3.7	Histogramme des mesures transformées sur l'horizon de test	70
3.8	Nuage de points des puissances PV entre 11h et 12h et entre 12h et 13h	71
3.9	Copule gaussienne bivariée	72
3.10	Loi gaussienne bivariée	73
3.11	Densité de probabilité et échantillon de la copule Student bivariée	74
3.12	Exemple de différentes copules archimédiennes bivariées	75
3.13	Matrice de corrélation de la copule gaussienne	76
3.14	Matrice de corrélation de la copule gaussienne	77
4.1	Prévision probabiliste du 04/01/2019 pour	84
4.2	Exemples de scénarios	84
4.3	Distribution des valeurs de scénarios pour deux intervalles de temps	85

4.4	Distribution de la puissance PV estimée à partir de la prévision probabiliste pour deux intervalles	86
4.5	Comparaison des temps d'exécution des algorithmes de réduction de scénarios	88
4.6	Comparaison de deux méthodes de réduction en fonction du nombre de scénarios initial	89
4.7	Comparaison des distances relatives avec et sans méthode réduction pour quatre prévisions distinctes	90
4.8	Résultat la méthode k-médoïdes en fonction du nombre de scénarios final	91
4.9	Exemples de scénarios issus de la réduction	92
5.1	Représentation du processus d'assimilation de données	96
5.2	Illustration du principe d'assimilation	99
5.3	Exemples d'assimilations pour différentes prévisions	101
6.1	Schéma simplifié des entités du micro-réseau considéré	108
6.2	Représentation des horizons de pilotage prédictif et de simulation	109
6.3	Courbe de charge résidentielle moyenne	111
6.4	Courbe de charge en fonction de la saison	112
6.5	Courbe de productible PV en fonction de la saison	113
6.6	Exemples de prévisions de charge et de productible PV	114
6.7	Distributions de la charge et de la charge résiduelle ainsi que de leur amplitude	114
6.8	Courbe moyenne de charge résiduelle	115
6.9	Courbe journalière des prix de l'énergie	119
6.10	Courbe représentative du calcul du coût des écarts	123
7.1	Écarts à l'issue de la simulation sans pilotage	130
7.2	Comparaison de l'énergie consommée et de l'énergie soutirée depuis le réseau - Sans planification	131
7.3	Résumé des trajectoires issues de la planification à partir de Q_{50} - 15/07/2020	133
7.4	Bilan de l'énergie transitant dans la batterie en fonction de la zone de prix pour la simulation de planification à partir de Q_{50}	134
7.5	Courbe de charge, production PV et charge résiduelles prévues à partir de Q_{50} - 31/01/2020	137
7.6	Résumé des trajectoires issues de la planification à partir de Q_{50} - Contrainte explicite - 31/01/2020	139
7.7	Résumé des trajectoires issues de la planification à partir de Q_{50} - Contrainte incitative - 31/01/2020	141
7.8	Courbe de charge, production PV et charge résiduelles prévues à partir de Q_{50} - 11/10/2020	143
7.9	Résumé des trajectoires issues de la planification à partir de Q_{50} - Contrainte explicite - 11/10/2020	145
7.10	Résumé des trajectoires issues de la planification à partir de Q_{50} - Contrainte incitative - 11/10/2020	146
7.11	Synthèse planification déterministe - Coût totaux d'opération par période de prix	148
7.12	Résumé des trajectoires de la batterie sur l'ensemble des journées simulées - Synthèse planification déterministe	149
7.13	Synthèse planification déterministe - distributions des coûts et amplitudes journalières en fonction de la stratégie	150
7.14	Courbe de charge, production PV et charge résiduelles prévues à partir d'une prévision probabiliste - 31/01/2020	153
7.15	Résumé des trajectoires issues de la planification à partir de 4 scénarios - Contrainte explicite - 31/01/2020	155

7.16	Résumé des trajectoires issues de la planification à partir de 4 scénarios - Contrainte incitative - 31/01/2020	156
7.17	Courbe de charge, production PV et charge résiduelles prévues à partir d'une prévision probabiliste - 11/10/2020	158
7.18	Résumé des trajectoires issues de la planification à partir de 4 scénarios - Contrainte explicite - 11/10/2020	159
7.19	Résumé des trajectoires issues de la planification à partir de 4 scénarios - Contrainte incitative - 11/10/2020	160
7.20	Résumé des trajectoires de la batterie sur l'ensemble des journées simulées - Synthèse planification stochastique	163
7.21	Résumé des écarts et de leurs coûts sur l'ensemble des journées simulées - Synthèse planification stochastique	164
7.22	Distribution des amplitudes journalières prévues et simulées en fonction de la stratégie	165
7.23	Evolutions des coûts d'opération simulés en fonction du nombre de scénarios initial en paramètre d'entrée du problème de planification	166
7.24	Evolution des coûts d'opération pour diverses simulations	168
A.1	Illustration du concept de variable et de loi aléatoire d'un espace inconnu vers un espace d'état connu [176]	XXIV
B.1	Disponibilité des données de prévision et de mesure PV	XXIX
B.2	Distributions de production PV horaire sur la journée du 13/07/2019	XXX
B.3	Distributions de production PV entre 9h et 10h pour différentes journées issues de mois différents	XXXI
C.1	Diagrammes de blocs des processus développés durant les travaux	XXXIV
D.1	Résumé des trajectoires de PV et charge prévues issues du pilotage prédictif à partir de 4 scénarios - Contrainte explicite - 31/01/2020	XXXVI
D.2	Résumé des trajectoires de charge résiduelle prévues issues du pilotage prédictif à partir de 4 scénarios - Contrainte explicite - 31/01/2020	XXXVII
D.3	Résumé des trajectoires de charge résiduelle prévues issues du pilotage prédictif à partir de 4 scénarios - Contrainte explicite - 31/01/2020	XXXVIII
D.4	Résumé des trajectoires de PV et charge prévues issues du pilotage prédictif à partir de 4 scénarios - Contrainte implicite - 31/01/2020	XXXIX
D.5	Résumé des trajectoires de charge résiduelle prévues issues du pilotage prédictif à partir de 4 scénarios - Contrainte implicite - 31/01/2020	XL
D.6	Résumé des trajectoires de charge résiduelle prévues issues du pilotage prédictif à partir de 4 scénarios - Contrainte implicite - 31/01/2020	XLI
D.7	Résumé des trajectoires de PV et charge prévues issues du pilotage prédictif à partir de 4 scénarios - Contrainte explicite - 11/10/2020	XLII
D.8	Résumé des trajectoires de charge résiduelle prévues issues du pilotage prédictif à partir de 4 scénarios - Contrainte explicite - 11/10/2020	XLIII
D.9	Résumé des trajectoires de charge résiduelle prévues issues du pilotage prédictif à partir de 4 scénarios - Contrainte explicite - 11/10/2020	XLIV
D.10	Résumé des trajectoires de PV et charge prévues issues du pilotage prédictif à partir de 4 scénarios - Contrainte implicite - 11/10/2020	XLV
D.11	Résumé des trajectoires de charge résiduelle prévues issues du pilotage prédictif à partir de 4 scénarios - Contrainte implicite - 11/10/2020	XLVI
D.12	Résumé des trajectoires de charge résiduelle prévues issues du pilotage prédictif à partir de 4 scénarios - Contrainte implicite - 11/10/2020	XLVII

D.13 Distributions des écarts planifiés en fonction du nombre de scénario initial - Synthèse planification stochastique - Contrainte incitative	XLVIII
D.14 Distributions des écarts réalisés en fonction du nombre de scénario initial - Synthèse planification stochastique - Contrainte incitative	XLIX

Liste des tableaux

3.1	Différents types de copules archimédiennes et leur caractéristiques	75
3.2	Paramètre estimé de chaque copule archimédienne	78
3.3	Indicateurs de score obtenus pour chaque type de copule paramétrée	78
5.1	Indicateurs statistiques de la méthode d'assimilation sur plusieurs cas d'étude et au global	100
6.1	Paramètres des entités du système	110
6.2	Convention de signe pour la puissance de chaque entité du système	116
7.1	Résumé des écarts des simulations sans planification avec différentes prévisions .	129
7.2	Résultats économiques des simulations sans planification avec différentes prévisions	129
7.3	Résultats sur l'amplitude de soutirage des simulations sans planification avec différentes prévisions	130
7.4	Résumé des écarts des simulations de planification sans contraintes de soutirage .	132
7.5	Résultats économiques des simulations de planification sans contraintes de soutirage	132
7.6	Résumé des gains des simulations avec planification	134
7.7	Résultats sur l'amplitude de soutirage des simulations de planification sans contraintes de soutirage	135
7.8	Résumé de l'énergie totale soutirée et transitant dans la batterie pour les simulations de planification sans contraintes de soutirage	135
7.9	Résultats des coûts journaliers pour la simulation de la planification déterministe - Cas 1 - 31/01/2020	140
7.10	Résultats des écarts journaliers pour la simulation de la planification déterministe - Cas 1 - 31/01/2020	140
7.11	Résultats de l'amplitude journalière pour la simulation de la planification déterministe - Cas 1 - 31/01/2020	142
7.12	Résultats des coûts journaliers pour la simulation de la planification déterministe - Cas 2 - 11/10/2020	147
7.13	Résultats des écarts journaliers pour la simulation de la planification déterministe - Cas 2 - 11/10/2020	147
7.14	Résultats de l'amplitude journalière pour la simulation de la planification déterministe - Cas 2 - 11/10/2020	147
7.15	Résultats globaux des coûts d'opérations pour la planification déterministe	148
7.16	Résultats globaux des écarts pour la planification déterministe	151
7.17	Résultats des coûts journaliers pour la planification - Cas 1 - 31/01/2020	157
7.18	Résultats des écarts journaliers pour la planification - Cas 1 - 31/01/2020	157
7.19	Résultats globaux des coûts d'opérations pour la planification stochastique	161

Nomenclature

Ensembles et indices

K	Ensemble des intervalles de temps
k	Indice des intervalles de temps ($k \in \{1, 2, \dots, k, \dots, K\} \subset \mathbb{N}$)
m	Indice de l'historique des réalisations disponibles ($m \in \{1, 2, \dots, m, \dots, M\} \subset \mathbb{N}$)
n	Indice des scénarios ($n \in \{1, 2, \dots, n, \dots, N\} \subset \mathbb{N}$)
p	Indice des niveaux de quantile ($p \in \{1, 2, \dots, p, \dots, P\} \subset \mathbb{N}$)
q	Indice d'assimilation des mesures
S	Ensemble des scénarios ($S = S^1, S^2, \dots, S^n, \dots, S^N$)
v	Indice des variables explicatives d'une régression ($v \in \{1, 2, \dots, v, \dots, V\} \subset \mathbb{N}$)

Paramètres

ΔT_k	Durée du pas de temps k
μ	Espérance d'une loi normale
$\rho_{charge/décharge}$	Rendements de la batterie
ρ_n	Probabilité associée au scénario n
Σ	Matrice de corrélation
σ	Coefficient linéaire de corrélation
τ	Niveau d'un quantile
q^τ	Quantile de niveau τ
t	Instant où la prévision est obtenue

Variables

β	Vecteur de coefficients d'une régression quantile.
$B_k^{Batterie}$	Variable binaire caractérisant l'état de la batterie (charge/décharge) sur l'intervalle k .
F_X	Fonction de répartition de la variable X .
$P_k^{Batterie}$	Puissance électrique de la batterie sur l'intervalle k .
P_k^{Charge}	Puissance électrique consommée sur le micro-réseau sur l'intervalle k .
$P_k^{PV,prévue}$	Puissance PV prévue sur l'intervalle k .
P_k^{PV}	Puissance électrique produite par la centrale PV sur l'intervalle k .
$P_k^{Réseau}$	Puissance électrique active soutirée depuis le réseau principal sur l'intervalle k .
$P_{min/max}^{Batterie}$	Puissance minimale/maximale de la batterie.

Nomenclature

$Prix_k^{Réseau}$ Prix de l'énergie soutirée depuis le réseau sur l'intervalle k .

$SoC_k^{Batterie}$ Etat de charge de la batterie sur l'intervalle k .

$SoC_{min/max}^{Batterie}$ Etat de charge minimal/maximal de la batterie.

X_k Dénomination simplifiée de P_k^{PV} pour la génération de scénario.

x_k Réalisation possible de la variable X_k .

X_T Vecteur contenant K variables : $\{X_T = X_1, X_2, \dots, X_k, \dots, X_K\}$.

Y_k Variable aléatoire correspondant à X_k dans l'espace des pseudos-variables.

Z_k Variable aléatoire correspondant à Y_k dans l'espace de génération.

Abréviations et acronymes

DdP densité de probabilité.

ED Economical Dispatch.

EIQ écart interquartile.

EnR énergie renouvelable.

FdR fonction de répartition.

GES gaz à effet de serre.

GRD gestionnaire de réseau de distribution.

LIRE Laboratoire de pilotage Intelligent du Réseau Électrique.

MPP Maximum Power Point.

PCC Point de Couplage Commun.

PLNE programmation linéaire en nombres entiers.

ppm partie par million.

PV photovoltaïque.

RE responsable d'équilibre.

s.u. sans unité.

SAA Sample Average Estimation.

TRVE Tarif Réglementé de Vente d'Electricité.

TURPE Tarif d'Utilisation des Réseaux Publics d'Electricité.

UC Unit Commitment.

UTC Coordinated Universal Time.

Glossaire

cardinalité (mathématiques) Nombre d'éléments d'un ensemble.

consigne Valeur de la grandeur physique, fixée par la partie commande, qu'un automatisme visera à atteindre.

contingence Événement imprévu ou non planifié qui peut affecter la production, la transmission ou la distribution d'énergie.

dispatch Fait référence à la gestion en temps réel de la production et de la distribution d'électricité, permet d'assurer l'équilibre entre l'offre et la demande d'électricité sur le réseau.

distribution Ensemble des valeurs expérimentales ou théoriques d'une variable statistique ou aléatoire donnée.

déterministe Se dit d'un système dans lequel, à partir des conditions initiales et des règles données, les résultats sont toujours identiques et parfaitement prévisibles.

irradiation Quantité d'énergie électromagnétique reçue par unité de surface et par unité de temps, provenant du soleil.

loi (de probabilité) Décrit de manière théorique le caractère aléatoire d'une expérience dont le résultat dépend du hasard.

marginale (loi de probabilité) Une loi de probabilité marginale d'un vecteur aléatoire est la loi de distribution d'une de ses composantes.

modeleur Outil ou un logiciel utilisé pour formuler des problèmes d'optimisation de manière à les rendre solubles par des algorithmes informatiques.

probabilité (d'un événement) Nombre réel compris entre 0 et 1. Plus ce nombre est grand, plus le risque, ou la chance, que l'événement se produise est grand.

productible Quantité d'énergie pouvant être obtenue par un équipement de production d'énergie.

prédiction Action d'annoncer à l'avance un événement par calcul, par raisonnement, par induction; p.méton., ce qui est ainsi annoncé [1].

prévision Étude générale d'une situation donnée, dont on peut, par déduction, calcul, mesure scientifique, connaître par avance l'évolution; p.ext., ce que l'on prévoit, ce qui est prévisible, ce que l'on juge devoir être [1].

solveur Logiciel ou bibliothèque algorithmique conçu pour trouver la meilleure solution possible à un problème d'optimisation formulé mathématiquement.

stochastique Synonyme d'aléatoire, en référence au hasard et s'oppose par définition au déterminisme.

Introduction générale

L'EFFET photovoltaïque a été découvert par Edmond Becquerel en 1839¹, les premiers modules utilisant cet effet pour produire de l'électricité ont été développés dans les années 1950 à 310 ppm. Aujourd'hui, en 421 ppm, ils occupent une place cruciale dans notre transition énergétique.

L'évolution de la concentration en CO_2 dans l'atmosphère depuis le milieu du $XIX^{\text{ème}}$ siècle, mesurée en **partie par million (ppm)**, apparaît de plus en plus préoccupante, car en majeure responsable du dérèglement climatique actuel. Le lien de causalité entre l'augmentation des **gaz à effet de serre (GES)** et les activités anthropiques est établi depuis des décennies [2]. La principale raison est l'utilisation croissante de combustibles fossiles (charbon, pétrole et gaz naturel), dont la combustion produit des **GES** (CO_2 entre autres), libérés ensuite dans l'environnement. A l'échelle du globe, les principaux secteurs polluants sont l'énergie, l'industrie et les transports ; afin de limiter leurs impacts néfastes [3] sur l'environnement leur profonde refonte structurelle est nécessaire en vue d'un système économique plus durable [4].

Les évolutions du système électrique

Les énergies fossiles représentent 80% de l'énergie primaire² et près de 60% de la production d'électricité dans le monde [5]. Les efforts à fournir pour diminuer leur part dans les besoins énergétiques mondiaux sont donc très importants. Plusieurs solutions existent comme l'efficacité énergétique des usages ou la sobriété mais également le déploiement de sources d'**énergie renouvelables (EnRs)**, moins émissives de **GES**. Dans le système électrique, le déploiement de ces énergies est déjà important mais s'accélère d'année en année, d'autant plus avec l'électrification de nombreux usages, notamment dans les transports [6].

L'évolution du système électrique au $XXI^{\text{ème}}$ siècle est donc caractérisée par une transition énergétique marquée par l'intégration croissante des **EnRs** et une tendance vers la décentralisation de la production d'électricité. Dans le contexte de la lutte contre le changement climatique, cette transformation s'inscrit dans la nécessité de réduire la dépendance aux combustibles fossiles. L'essor des technologies d'**EnR**, telles que le solaire **photovoltaïque (PV)** et l'éolien, a modifié la structure du secteur de la production énergétique, induisant une reconfiguration des réseaux, des marchés et des modes de consommation. On observe ainsi en France un développement important des capacités de production PV, avec notamment un doublement de la puissance installée entre 2015 et 2020. Ceci se traduit par l'augmentation significative au fil des années de la part de l'énergie **PV** dans le mix électrique français (voir figure 1).

Les systèmes énergétiques, traditionnellement centralisés, cèdent progressivement la place à des modèles plus distribués, où la production d'énergie se fait plus proche des lieux de consommation grâce aux **EnRs**. Cette décentralisation offre une réduction des pertes en transmission et distribution et favorise l'autonomie énergétique des communautés locales. L'intégration de ces énergies pose de nombreux défis, notamment en termes d'acceptation sociale et d'investissements.

1. L'initiative **Born in PPM** fait correspondre chaque année civile avec un taux de concentration de CO_2 , pour illustrer l'augmentation de ce dernier au fil des ans.

2. L'énergie primaire désigne l'ensemble des formes d'énergie disponibles dans la nature avant toute transformation ou conversion par l'être humain.

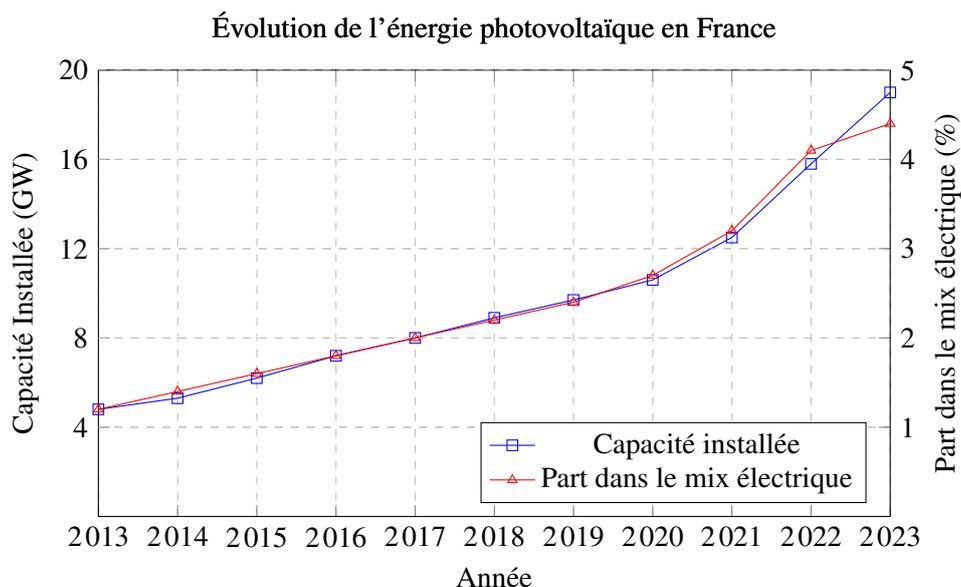


FIGURE 1 – Évolution de la capacité installée et de la part de l'énergie photovoltaïque dans le mix électrique en France (2013-2022) [7].

Cependant, nous nous concentrerons ici sur les challenges technologiques liés à leur intégration au réseau électrique.

L'arrivée de ces nouvelles sources d'énergie, du fait de leurs caractéristiques, pose toutefois des défis significatifs en termes de régulation et de maintien de la stabilité, nécessitant des avancées dans les technologies de stockage d'énergie et les systèmes de gestion intelligente de l'énergie. Leur implémentation dans les micro-réseaux contribue donc à ce changement de paradigme dans le système électrique, avec ses atouts majeurs mais également ses challenges.

Qu'est ce qu'un micro-réseau ?

Le terme micro-réseau est un mot composé de l'affixe **micro**, venant du grec « *μικροσ* » signifiant petit, et du mot **réseau**, originaire du latin « *retis* » désignant originellement un filet. Sa signification a évolué et prend ici le sens d'un ensemble interconnecté, fait de composants et de leurs relations, autorisant la circulation de flux, quel qu'en soit sa nature. Ici il est sous-entendu que l'on parle d'un réseau électrique et donc de flux d'électrons. Ce terme est finalement assez clair sur la place du micro-réseau dans le vaste écosystème électrique. Désormais avec des flux bi-directionnels, le réseau électrique accueille de nouveaux éléments à gérer et se retrouve de plus en plus maillé, se rapprochant ainsi du sens originel du mot réseau. On parle ici d'une entité plus petite que le réseau de distribution en terme de puissance.

Le micro-réseau peut se voir comme une partie du système électrique qui aurait acquis des degrés de liberté par rapport au réseau autrefois centralisé avec des flux verticaux, son opérateur doit donc prendre des décisions et le gérer comme il l'entend.

Un micro-réseau électrique, souvent désigné sous le terme anglais « *microgrid* », est un système de distribution d'énergie électrique localisé qui fonctionne de manière autonome ou en parallèle avec le réseau électrique principal. Ce système intègre généralement plusieurs sources d'énergie, qui peuvent inclure des générateurs conventionnels à base de carburants fossiles ainsi que des sources d'**EnR** comme le solaire photovoltaïque, l'éolien, et parfois des systèmes de stockage d'énergie comme les batteries (voir figure 2).

Les micro-réseaux sont conçus pour optimiser l'utilisation des ressources énergétiques locales, améliorer la fiabilité et la qualité de l'énergie fournie, et réduire les émissions de gaz à effet de serre

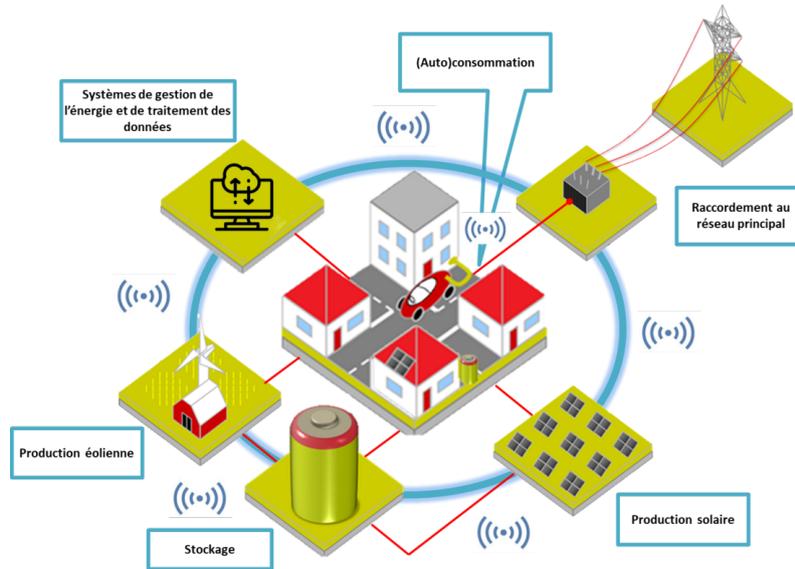


FIGURE 2 – Représentation schématique du concept de micro-réseau [8]

mais également d'acquérir une relative indépendance. Ils possèdent ainsi parfois la capacité de se déconnecter du réseau principal et d'opérer en mode « îlotage », permettant ainsi une résilience accrue lors de pannes générales ou de catastrophes naturelles.

Cette définition générique ne devrait pas occulter qu'il existe une grande variété de caractéristiques qui varient d'un micro-réseau à l'autre : type de courant, moyen de supervisions, connection au réseau principal, nombres de phases, grande variété d'entités, multi-vecteurs d'énergie, etc. [9].

Opération d'un micro-réseau

Sur le plan technique, un micro-réseau utilise des systèmes de gestion avancés et des technologies de contrôle intelligentes pour gérer la production et la consommation d'énergie au sein de son périmètre. Ces systèmes doivent, à l'instar du réseau principal interconnecté, assurer une régulation précise des flux d'énergie, garantissant ainsi l'équilibre entre offre et demande en temps réel, tout en maintenant la stabilité du réseau et en respectant les normes de qualité de l'énergie.

L'exploitant d'un micro-réseau souhaite opérer son système de la meilleure façon possible. Pour cela il existe une multitude de critères. Il existe aussi différents types de problèmes qui correspondent à différentes temporalités. Pour opérer un réseau électrique, nous aurons de l'échelle de temps la plus courte à la plus longue :

- Le contrôle du réseau électrique qui se préoccupera des flux de puissances à travers le contrôle de variable comme la tension, la fréquence du réseau opéré et permettra d'assurer la sécurité et la fiabilité du système en temps réel.
- Le problème de la gestion d'énergie se concentre lui sur les équilibres de puissance à court et moyen terme.
- Le problème de dimensionnement et de développement de nouvelles capacités doit lui s'assurer que le système est viable à plus long terme.

Les récentes avancées de la recherche dans le domaine des micro-réseau entraînent des changements dans les méthodes employées. Si l'approche déterministe était très courante et reste encore très présente dans la recherche et les gestionnaires de réseau, l'utilisation d'approches dites *stochastiques* tend à se développer [10].

Déterministe vs. stochastique

La différence entre une vision *déterministe* et une vision *stochastique* est fondamentale et permet d'étudier un système complètement différemment selon que l'on adopte l'une ou l'autre approche.

Le terme « déterministe » fait référence à quelque chose qui est prévisible et contrôlable, où les résultats sont déterminés par des causes précises et identifiables. Dans un système déterministe, les événements futurs peuvent être prédits avec précision à partir des conditions initiales et des lois ou règles du système. Par exemple, dans la physique classique, les mouvements des planètes dans le système solaire sont déterminés avec précision par les lois de la gravitation de Newton.

Avant de parler du terme « stochastique » il convient de définir deux notions : statistique et la probabiliste. Le terme « statistique » fait référence à la science qui se consacre à la collecte, l'analyse, l'interprétation, la présentation et l'organisation de données. En pratique, elle permet de tirer des conclusions à partir de données, de détecter des patterns ou des tendances, et de prendre des décisions basées sur des données empiriques. Le terme « probabiliste » se réfère à tout ce qui est relatif à la *probabilité*, c'est-à-dire à l'étude mathématique de la mesure de la certitude ou de la possibilité qu'un événement particulier se produise. La probabilité est une branche des mathématiques qui quantifie l'incertitude et est essentielle pour la prise de décisions basée sur des événements incertains.

Le terme « stochastique » est utilisé pour décrire un processus ou un système ayant une composante aléatoire ou probabiliste. Il est souvent employé pour caractériser des phénomènes dont l'issue n'est pas totalement prédictible, mais qui peuvent être analysés à l'aide de *probabilités* ou de statistiques. En essence, un processus stochastique est une suite de variables aléatoires dont les réalisations ne sont pas déterminées avec certitude, mais suivent certaines *lois de probabilités*. Dans un système stochastique, les résultats ne peuvent pas être prédits de manière précise, même si les conditions initiales sont connues.

En résumé, le déterminisme se rapporte à la prédictibilité et à la certitude, tandis que l'approche stochastique se rapporte à l'incertitude et au hasard. Ces concepts sont utilisés pour décrire et modéliser une grande variété de phénomènes dans divers domaines scientifiques et technologiques, dont la *prévision* de production photovoltaïque et la gestion de micro-réseaux.

Objectifs et contributions

Cette thèse a pour vocation de s'inscrire dans la continuité des recherches les plus récentes sur la question de la gestion de l'énergie dans les micro-réseaux. Plus particulièrement, nous traiterons du problème de planification et d'anticipation de son fonctionnement, auquel nous ajouterons la prise en compte de l'incertitude. En effet, une forte présence de moyens de production d'énergie comme le photovoltaïque est une source d'aléa importante du fait de son intermittence et de son imprévisibilité. Il apparaît donc crucial de prendre en compte cette incertitude dans les processus de décision et de pilotage d'un micro-réseau.

Pour cela notre travail est divisé en différents objectifs séquentiels, permettant in fine de répondre au challenge énoncé ci-dessus :

- Maîtriser et exploiter le plus possible l'information à disposition sur l'aléa étudié.
- Caractériser l'incertitude liée à ce aléa de la façon la plus versatile possible.
- Etudier l'impact et l'apport d'une prise en compte d'incertitude dans un modèle de planification de micro-réseau.
- Élaborer un modèle de planification optimisant les coûts d'opération tout en étant capable de fournir un service système au réseau principal.

Ainsi, ce travail comportera diverses contributions sur ces sujets. Nous nous pencherons en premier lieu sur la caractérisation de cette incertitude, avec le développement d'une méthode per-

mettant d'obtenir des **prévisions** probabilistes de **productible** PV puis de **construire leurs lois empiriques**. En croisant ces **lois** avec des observations, nous **définissons** et **paramétrons** le **modèle de dépendance temporelle** le plus approprié pour la centrale PV considérée. Ce modèle se basant sur la notion de copule, est **générique**, c'est-à-dire applicable à d'autres sources d'incertitude qui pourraient s'ajouter à notre modèle. Les travaux effectués jusqu'alors et particulièrement la définition d'un modèle de dépendance permettent ensuite d'effectuer une **assimilation de données** de production mesurée, générant une nouvelle **prévision**. De plus, les **lois** obtenues, nous autoriserons à effectuer une génération de scénario puis de **paramétrer une méthode de réduction de scénarios**, modélisant ainsi l'incertitude de la production PV sur l'horizon temporel étudié.

Dans la seconde partie des travaux, on s'intéresse au problème de gestion de micro-réseau et en particulier à la planification. Les **prévisions** étant un paramètre d'entrée de ce processus, nous **décrivons** ensuite donc un **modèle stochastique de planification** permettant de prendre en compte les ensembles de scénarios produits. Nous montrerons l'**intérêt de l'approche stochastique** sur la maîtrise du risque économique lié au soutirage depuis le réseau principal. Un **service système original** est également ajouté au modèle et nous estimerons son **coût et sa fiabilité**. Finalement nous montrons l'**apport des ensembles de scénarios réduits** pour la planification stochastique.

Organisation

Ce manuscrit de thèse se divise en 4 parties et 7 chapitres permettant de traiter les objectifs susmentionnés, organisés selon la structure ci-dessous.

- La partie **I** détaille l'état de l'art et les concepts clés du sujet du manuscrit.
 - Le chapitre **1** traite de la **prévision** PV et son incertitude.
 - Le chapitre **2** permet de donner un aperçu des méthodes de gestion de micro-réseau sous incertitude.
- La partie **II** porte le traitement de l'incertitude PV.
 - Dans le chapitre **3**, nous caractériserons l'aléa photovoltaïque sur une journée en déterminant, d'une part les **lois** suivies aux différentes heures mais également une structure de dépendance, permettant de définir une **loi** pour l'ensemble des intervalles considérés.
 - Dans le chapitre **4**, nous effectuerons, grâce aux travaux du chapitre précédents, le paramétrage d'une méthode de génération d'ensembles réduits de scénarios.
 - Dans le chapitre **5**, la structure de dépendance estimée permet d'exploiter le recueil de mesures de production en temps réel pour effectuer de l'assimilation de données observées.
- La partie **III** permet de traiter les problématique liées à la planification stochastique de micro-réseau.
 - Dans le chapitre **6**, nous présentons le cas d'étude : ses entités, les hypothèses et la méthodologie d'évaluation des méthodes employées.
 - Dans le chapitre **7**, nous détaillons les résultats de méthodes et stratégies de planification développées, tout en exploitant les données issues de la partie **II**.
- La partie **IV** regroupe les annexes.

Première partie

État de l'art et concepts pour la prévision PV et la gestion de micro-réseau sous incertitude

1

Prévision de la production d'une centrale PV et son incertitude

Ce chapitre permet de poser le cadre scientifique dans lequel s'inscrit nos recherches menées sur la prévision de la production d'une centrale PV et son incertitude. De nombreuses méthodes de prévisions et de représentation de l'incertitude sont présentées, tout comme les moyens pour les évaluer.

Sommaire

1.1	Aléa photovoltaïque : variabilité et incertitude	12
1.2	Ensemble des données utilisées pour la prévision	13
1.3	Approches de prévisions	14
1.3.1	Prévision directe vs. indirecte	14
1.3.2	Horizons de prévision	15
1.3.3	Modélisation de l'incertitude	15
1.4	Méthodes de prévisions	17
1.4.1	Modèles physiques	18
1.4.2	Modèles non-physiques ou statistiques	18
1.4.3	Modèles ensemblistes	21
1.4.4	Modèles hybrides	21
1.4.5	Perspectives	22
1.5	Représentation de l'incertitude : la prévision probabiliste	22
1.5.1	Prévision déterministe, stochastique, quésaco	22
1.5.2	Différentes approches de représenter l'incertitude	23
1.6	Évaluation de la prévision	27
1.6.1	Indicateurs pour prévision déterministe	27
1.6.2	Indicateurs pour prévision probabiliste	29
1.7	Conclusions	32

Pour relever les défis de l'intégration de l'énergie PV dans les réseaux électriques, il est crucial d'avoir à disposition des prévisions de son productible de qualité. Ces dernières sont essentielles pour de nombreux aspects : aussi bien pour anticiper le fonctionnement du réseau (estimer les réserves, gérer les congestions du réseau, etc.) que pour permettre d'en optimiser les coûts d'opération. Ainsi, plus la part de la puissance PV dans un réseau augmente, plus la qualité de la prévision sera critique pour ce système.

Ce chapitre présente un état de l'art de la recherche sur les méthodes de prévision photovoltaïque et aborde également la question de l'incertitude qui leur est inhérente. L'objectif est de fournir une vue d'ensemble des approches existantes, de leurs avantages et limites et synthétiser les défis à relever pour améliorer l'ensemble processus de prévision PV. Dans un premier temps, l'aléa de la production photovoltaïque sera présenté. Ensuite, les différentes méthodes de prévision seront passées en revue, tout comme la quantification et la représentation de l'incertitude. Finalement nous évoquerons les méthodes d'évaluations avant de conclure.

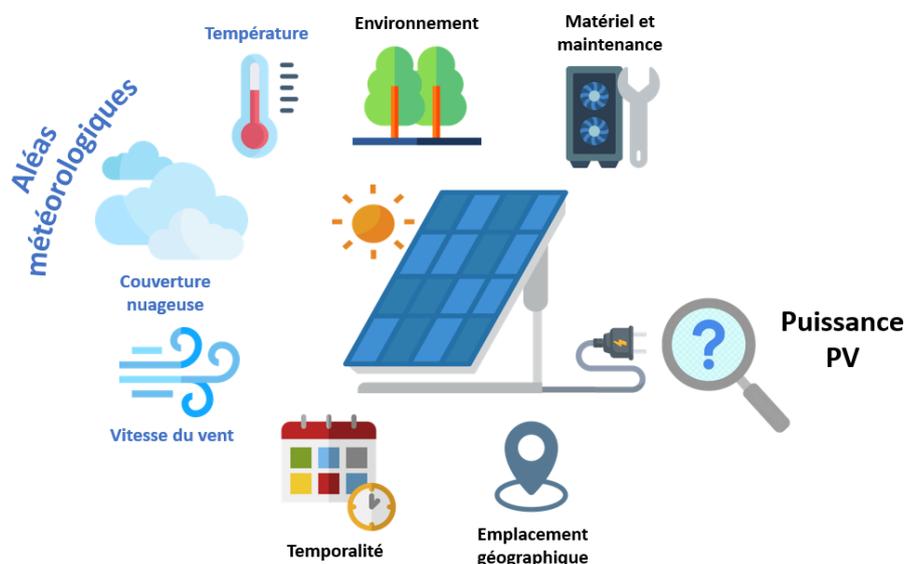


FIGURE 1.1 – Résumé des facteurs principaux influençant la variabilité de la production PV

1.1 Aléa photovoltaïque : variabilité et incertitude

La variabilité de la production photovoltaïque fait référence aux fluctuations de la puissance produite par les panneaux solaires. Ces dernières peuvent être dues à de nombreux facteurs : changements des conditions météorologiques telles que l'intensité de la lumière du soleil, couverture nuageuse, température, vitesse du vent, etc. En revanche, l'incertitude concerne la difficulté de prédire précisément ces variations sur différentes échelles de temps.

Les conditions météorologiques jouant un rôle significatif dans la production d'énergie PV, des facteurs tels que la couverture nuageuse, provoquant des changements rapides de l'exposition au soleil des panneaux, entraînent des baisses ou des pics soudains de la production d'électricité [11]. Les variations de température de l'air peuvent également affecter l'efficacité des panneaux [12]. La vitesse du vent impacte le refroidissement des panneaux solaires et donc leur température, contribuant aussi à la variabilité de la production [13]. L'ensemble des fluctuations liées à la météo sont donc autant d'aléas qui affecteront le productible PV et sa prévision.

L'environnement d'une installation PV joue aussi un rôle important dans son exposition au soleil, et donc sur sa production. Des paramètres telles que l'emplacement géographique et l'ombrage provenant de structures ou de la végétation à proximité influent significativement la quantité de rayonnement solaire reçue par les panneaux PV tout au long de la journée. Les zones

situées à des latitudes élevées ou ayant une météo présentant fréquemment une couverture nuageuse peuvent connaître une plus grande variabilité de la productible PV par rapport aux régions plus proches de l'équateur bénéficiant d'un ensoleillement plus régulier et important. Les facteurs temporels, tels que l'heure de la journée et la saison, ont également un fort impact sur les schémas de production d'énergie solaire. En effet, l'angle et l'intensité de l'irradiation varient au fil de la journée et au cours des différentes saisons en raison de l'inclinaison de la Terre par rapport à son orbite autour du soleil. Ces variations entraînent donc des niveaux variables d'énergie disponible pour les systèmes photovoltaïques, ce qui rend plus complexe la prévision [14].

La conception des systèmes PV et le choix de leurs composants contribuent également de manière significative à la variabilité de la production d'énergie. En effet, les différences entre les types de cellules PV, les onduleurs ou encore les systèmes de suivi (tracker) amènent différentes conditions de fonctionnement et peuvent donc affecter l'efficacité du système. On peut également citer l'importance de la maintenance et de l'entretien des systèmes [15].

Les techniques de prévision jouent donc un rôle très important dans la gestion de la variabilité et la modélisation des incertitudes associées aux sources d'énergie renouvelables intermittentes comme l'énergie solaire. Les différentes sources d'aléa sont résumées figure 1.1. Dans la section suivante nous allons évoquer les différentes données nécessaires à la prévision.

1.2 Ensemble des données utilisées pour la prévision

Les méthodes de prévision photovoltaïque reposent sur une variété de données qui peuvent être divisées en plusieurs catégories : les données d'irradiation solaire et météorologiques ainsi que les données spécifiques à la centrale considérée. La qualité, la résolution et la disponibilité de ces données ont une influence significative sur la précision et la fiabilité des prévisions.

a) Données d'irradiation solaire

Les données d'irradiation solaire sont directement corrélées à la puissance électrique produite par les systèmes PV et sont probablement les paramètres les plus critiques pour la prévision de l'énergie solaire.

Parmi les types d'irradiations solaires on trouve :

- Irradiation normale directe (abrégée DNI en anglais) : quantité de radiation solaire reçue par unité de surface provenant directement du soleil (sans être diffusé ou réfléchi), mesurée sur une surface perpendiculaire aux rayons, elle varie donc en fonction de l'angle d'incidence de ces derniers.
- Irradiance horizontale diffuse (abrégée DHI en anglais) : quantité de radiation solaire reçue indirectement (diffusée par les molécules de l'atmosphère) par unité de surface horizontale.
- Irradiance horizontale globale (abrégée GHI en anglais) : quantité totale de radiation solaire reçue par une surface horizontale, qui comprend à la fois l'irradiation normale directe et l'irradiance horizontale diffuse.

Ce type de mesure peut être obtenu de trois manières :

- Pyranomètres et pyréliomètres : ces instruments mesurent respectivement le GHI et le DNI.
- Caméras : elles permettent d'observer le ciel à proximité de la centrale et d'estimer indirectement l'irradiation.
- Satellites : les données satellitaires permettent de fournir des données complètes de radiation solaire en analysant des images de l'atmosphère, complétant ainsi ou remplaçant les instruments susmentionnés [16].

b) Autres donn ees m eteorologiques

Des donn ees m eteorologiques compl etant celles d'irradiation sont  galement essentielles pour les mod eles de pr evision PV. Ces donn ees comprennent principalement la temp erature, la vitesse du vent, l'humidit e et la pression atmosph erique. Ces param etres influencent la quantit e d'irradiation solaire atteignant la surface de la Terre et affectent donc le productible du syst eme PV.

Il y a globalement deux sources principales pour ces donn ees :

- Stations m eteorologiques : elles fournissent des donn ees localis ees et sont souvent utilis ees pour la pr evision   court terme [17].
- Satellites : pour une couverture plus large, les donn ees satellitaires offrent des estimations de la couverture nuageuse et d'autres conditions atmosph eriques sur de vastes zones g eographiques [18].

c) Donn ees sp ecifiques

Les donn ees sp ecifiques   l'installation solaire PV, telles que le type de cellule, l'orientation, l'angle d'inclinaison et l' ge de l'installation, jouent  galement un r ole crucial dans la production d' nergie PV et donc dans sa pr evision, ces facteurs affectant l'efficacit e de conversion des modules solaires. En effet deux centrales expos ees aux m emes conditions m eteorologiques, ne produiront pas forc ement la m eme puissance.

La plupart des syst emes modernes de PV sont  quip es de capteurs et de logiciels de surveillance qui enregistrent continuellement les donn ees op erationnelles, y compris la production d' nergie, l'efficacit e et l' tat du syst eme. Ces donn ees sont critiques pour calibrer les mod eles de pr evision et pour effectuer des ajustements en fonction des tendances de performance mesur ees et de la d egradation observ ee au fil du temps.

Obtenir, comprendre et utiliser efficacement ces diff erentes donn ees est fondamental pour d evelopper des mod eles de pr evision PV performants. L'int egration de donn ees pr ecises, fiables et   haute r esolution (temporelle et spatiale) provenant de plusieurs sources am eliorent les capacit es pr edictives de ces mod eles, pouvant ainsi faciliter la gestion de l' nergie et, de fait, son l'int egration au r eseau. Avant d'aborder la question des mod eles de pr evisions, nous introduirons les diff erentes approches qu'il est possible d'adopter lorsqu'on s'attache   produire une pr evision PV.

1.3 Approches de pr evisions

1.3.1 Pr evision directe vs. indirecte

Pour la pr evision de productible photovolta ique, il est possible d'utiliser des m ethodes directes ou indirectes en fonctions des donn ees   disposition.

Les m ethodes de pr evision directes permettent de pr evoir directement la puissance  lectrique produite par une installation PV en utilisant des  chantillons de donn ees historiques, tels que la production et les donn ees m eteorologiques associ ees. Cette approche est appropri ee lorsque des donn ees historiques de la centrale PV sont disponibles pour l'entra nement des mod eles. L'avantage de cette m ethode est qu'elle peut capturer et transposer les caract eristiques sp ecifiques de la centrale PV.

Quant   elles, les m ethodes de pr evision indirectes sont utilis ees lorsque la pr evision directe de la production d' nergie PV n'est pas possible, par exemple dans le cas d'une nouvelle centrale PV o  des donn ees historiques ne sont pas disponibles. Dans de tels cas, la pr evision indirecte est mise en uvre en collectant des donn ees d'irradiation solaire et m eteorologiques, ainsi que des informations sur l'emplacement de la centrale PV. Ces param etres sont ensuite utilis es pour pr evoir la puissance solaire gr ce   des mod eles de performance (voir section 1.4.1.c).

1.3.2 Horizons de prévision

Si il existe différentes façons possibles pour produire une prévision PV, la temporalité de cette dernière est aussi très importante dans le processus et peut varier beaucoup d'une prévision à l'autre. Ainsi en fonction de l'horizon de prévision, on aura ni la même source de données, ni la même méthode, ni la même application pour le système énergétique [19]. Il est donc courant de classer les prévisions en différentes catégories :

- De quelques secondes à quelques minutes : la prévision de *très court-terme*, utilisée pour le contrôle actif des installations [20].
- De quelques secondes à quelques heures : la prévision *intra-horaire*, indispensable pour assurer la stabilité du réseau avec notamment la constitution des réserves mais elle trouve aussi des applications dans la formulation des offres sur le marché de l'électricité [21].
- De 30 minutes à 6 heures : la prévision de *court-terme*, dont l'application est liée au marché de l'électricité ou à l'opération du réseau [22].
- De quelques secondes à quelques heures : la prévision *intra-journalière*, dont l'usage est très similaire aux deux appellations précédentes [23].
- De 6 heures à 24 heures : la prévision de *moyen-terme*, employée pour la maintenance des systèmes PV [20].
- De 6 heures à 48 heures : la prévision *pour le lendemain*, essentiellement à destination des problèmes de planification lié au marché de l'électricité (Unit Commitment et Optimal Dispatch, voir section 2.3.1) [24].
- Plus de 24 heures et pouvant aller jusqu'à un an : la prévision de *long-terme*, utilisée pour la planification des opérations du système énergétique (renforcement du réseau de distribution voire de transport) mais aussi de la centrale elle-même pour en connaître les variations saisonnières [25].

On remarque que ces catégories se recoupent temporellement, illustrant la variété des applications dans la gestion des systèmes PV qui nécessitent des prévisions. La figure 1.2 illustre les différentes temporalités des catégories listées précédemment.

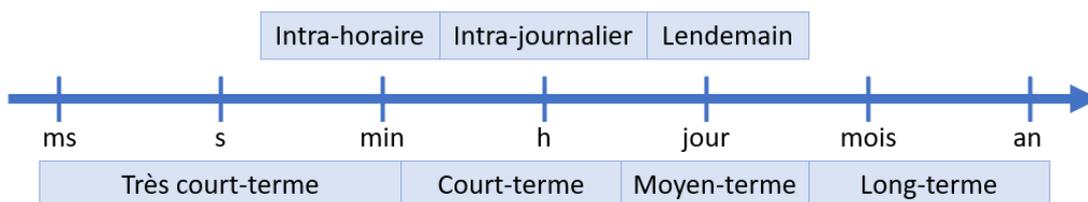


FIGURE 1.2 – Catégories d'horizons de prévision PV

On notera également que toutes les centrales n'ont pas les mêmes dynamiques temporelles relativement aux aléas météo. Des facteurs comme la taille de la centrale et la vitesse du vent influent grandement sur les variations de production.

1.3.3 Modélisation de l'incertitude

De façon générale, la notion d'incertitude caractérise l'imprécision que l'on a d'une grandeur : c'est la dispersion des valeurs qu'elle pourrait prendre. La **prédiction** de productible PV est une variable aléatoire : il est impossible de donner sa valeur à l'avance avec certitude. Ce travail de prévision revient donc à étudier cette variable, pour cela la théorie des probabilités et les statistiques aideront à rationaliser les issues possible de cette expérience aléatoire.

Dans le domaine de la prévision photovoltaïque, la modélisation précise de l'incertitude fait partie intégrante de la production de la prévision elle-même : il est crucial de capturer et refléter la variabilité et la stochasticité inhérentes à la production d'énergie solaire. Une modélisation efficace de l'incertitude est donc essentielle pour fournir des prévisions fiables qui influenceront les décisions dans la gestion du réseau ou encore les prises de positions sur le marché de l'énergie.

Afin de caractériser la **distribution** des valeurs de prévisions, les modèles de prévisions se divisent en deux approches : paramétrique et non-paramétrique. La section suivante permet de distinguer leurs différences ainsi que leurs forces et faiblesses.

a) Approche paramétrique

L'approche paramétrique de prévision PV impliquent de choisir préalablement le type de **distribution** paramétrique supposément suivie par des variables d'intérêt. Ces modèles sont avantageux pour leur simplicité et la facilité de compréhension de leurs résultats.

Ces modèles nécessitent donc de caractériser les paramètres d'un modèle prédéfini en ajustant grâce aux données les paramètres du type de courbe sélectionné. Les approches paramétriques sont généralement très efficaces sur le plan computationnel car elles ne nécessitent pas de grandes quantités de données mais peuvent manquer de flexibilité si le modèle choisi ne s'avère finalement pas une bonne approche de la **distribution** de la prévision [26].

Pour le productible PV, certains auteurs utilisent donc des fonctions paramétriques parmi les suivantes et représentées figure 1.3 :

- La loi normale : approche courante pour modéliser la **distribution** des erreurs mais se révélant inexacte en cas de non-symétrie des données observées [27] ;
- La loi gamma [28] ;
- La loi bêta [29].

Les deux dernières lois citées permettent de palier au problème de symétrie de la loi normale mais ne règlent pas la question de la multi-modalité potentielle des variables étudiées, illustrée par Munkhammar et al. [30].

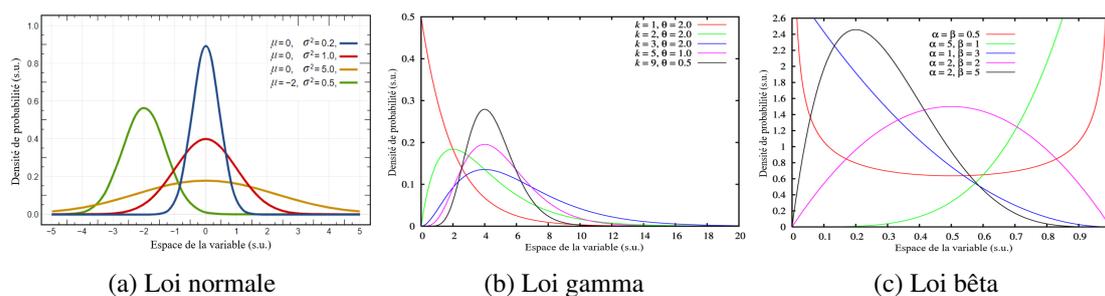


FIGURE 1.3 – Exemples de densités de probabilité pour différents paramètres pouvant servir à une approche paramétrique de la prévision PV [31]

Il a été montré que par Almeida et al. que leur pendant, les approches non-paramétriques, présentaient certains avantages [26], que nous allons présenter dans la section suivante.

b) Approche non-paramétrique

Les modèles non-paramétriques sont préférés pour leur capacité à modéliser les données sans faire d'hypothèses sur la forme de **distribution** des variables considérées. Ces modèles sont plus adaptables et peuvent gérer des situations complexes et relations non linéaires souvent présentes dans les données météorologiques pour la prévision PV.

Comme le soulignent Pan et al., cette approche est excellente pour gérer la nature très variable des paramètres couramment utilisés dans le domaine, notamment en étant robuste face aux valeurs aberrantes. Leurs principaux défauts sont qu'elles nécessitent plus de données et ont un coût calculatoire plus élevé que les approches paramétriques [32].

Le choix entre d'une approche paramétrique ou non pour la prévision PV va dépendre de la nature des données, des relations entre les paramètres considérés et des besoins spécifiques de l'application à laquelle est destinée la prévision. Alors que les méthodes paramétriques offrent simplicité et efficacité, les non-paramétriques fournissent plus de flexibilité, pouvant ainsi plus facilement modéliser des relations complexes, communes dans la production photovoltaïque. Après avoir détaillé les approches possibles pour la prévision et son incertitude, nous explorerons les principaux modèles de prévision dans la section suivante.

1.4 Méthodes de prévisions

Les méthodes de prévision pour les systèmes photovoltaïques peuvent être divisées en deux types principaux : les modèles physiques et les non-physiques. Chaque type utilise des approches distinctes et présente ses propres forces et faiblesses. Les modèles physiques, utilisent les lois de la physique pour prédire la production solaire. Ces modèles sont cruciaux pour comprendre les interactions fondamentales entre les conditions atmosphériques, l'irradiation solaire et puissance produite.

Les modèles non-physiques, quant à eux, utilisent plutôt des techniques statistiques et d'apprentissage automatique en assimilant à partir de données historiques. Ils permettent de décrire des phénomènes qui ne peuvent parfois pas être explicitement définis par des équations physiques. Ces modèles offrent de la flexibilité et de l'adaptabilité dans la gestion de données et interactions complexes. On peut également citer les approches ensemblistes, utilisant plusieurs « sous-modèles » et hybrides, tirant partie de différents modèles.

Cette section vise donc à explorer ces différentes techniques de prévision, en soulignant leurs applications, leurs capacités actuelles et les orientations futures dans la prévision PV. La figure 1.4 ci-dessous permet d'avoir un premier aperçu des grandes catégories de modèles de prévision PV.

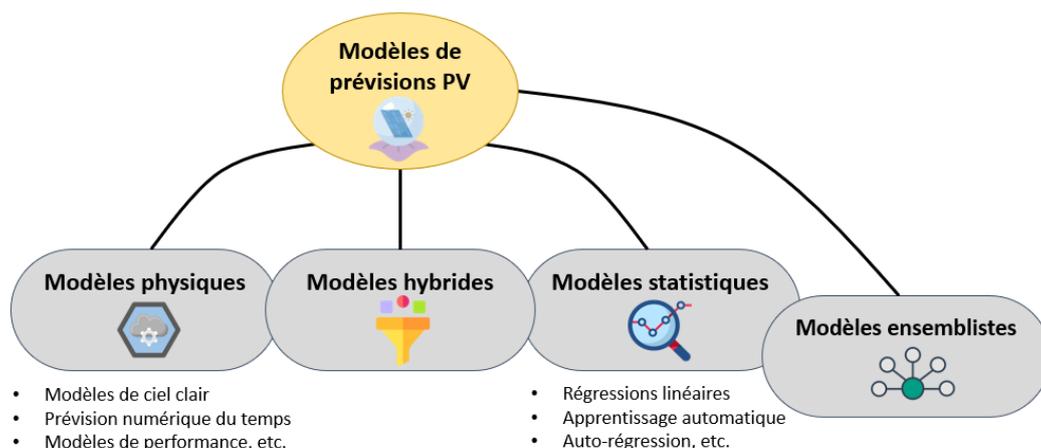


FIGURE 1.4 – Aperçu des différents types de modèles de prévision PV

1.4.1 Mod eles physiques

a) Mod eles de rayonnement ciel clair

Les mod eles de ciel clair (connus sous leur appellation anglaise : Clear-Sky Models, CSM) estiment le rayonnement solaire dans des conditions id eales, fournissant une r ef erence pour la pr evision de l' nergie PV [33]. Ils utilisent des param etres tels que la position du soleil et les propri et es optiques de l'atmosph ere pour pr edire l'irradiation solaire, en supposant une atmosph ere id eale dite de ciel clair (i.e. sans couverture nuageuse). Il existe plusieurs mod eles de ciel clair bien connus, tels que le mod ele Simplified Solis ou le mod ele Bird Clear Sky, chacun avec ses hypoth eses et applications de pr edilection. Ces mod eles diff erent principalement dans la fa con dont ils g erent l'absorption et la diffusion du rayonnement solaire par l'atmosph ere [34]. Ces mod eles de rayonnement sont essentiels comme r ef erence pour des  tudes de pr evision et de variabilit e d'irradiation plus complexes.

Bien qu'utiles, les CSM ont des limites. Ils ne tiennent pas compte des conditions atmosph eriques impr evues comme les concentrations d'a erosols ou les changements m eteorologiques soudains, ce qui en fait une pr evision simple mais limit ee. Un  etalonnage r egional est souvent n ecessaire pour garantir la pertinence et la pr ecision de ces mod eles [35].

b) Pr evision num erique du temps

Les mod eles de pr evision num erique du temps (Numerical Weather Prediction, NWP) sont essentiels pour la pr evision de la production d' nergie PV car ils fournissent des informations d etaill ees sur les variables m eteorologiques impactant la production d' nergie solaire (voir section 1.1). Ces derniers fournissent donc des estimations de param etres telles que la temp erature, la vitesse du vent, l'humidit e et la couverture nuageuse, ce qui leur permet surtout de pr edire l'irradiation solaire [36]. Les mod eles NWP int egrent des mod eles de rayonnement solaire (voir section 1.4.1.a ci-dessus) pour ainsi pr evoir le rayonnement atteignant potentiellement une centrale PV, en traduisant les param etres m eteorologiques calcul es en estimations d'irradiation solaire au niveau du sol. Les avanc ees r ecentes se concentrent sur l'am elioration de la r esolution et de la pr ecision des pr evisions, tout comme la vitesse de calcul des mod eles et l'obtention de meilleures donn ees d'entr ees. Ces mod eles deviennent moins pr ecis avec l'augmentation de l'horizon de pr evision et la diminution de la r esolution spatiale : les ph enom enes m eteorologiques locaux pouvant causer des changements soudains du niveau d'irradiation [37].

c) Mod eles de performance PV

Ce type de mod ele permet de passer des param etres physiques (variables m eteorologiques et propri et es de l'installation PV)   la puissance  lectrique effectivement produite par la centrale. Les facteurs les plus courants sont donc l'irradiation, la temp erature, l'ombrage, l'alb edo et l'angle d'incidence de la lumi ere du soleil sur les panneaux. Il en existe diff erents types, du mod ele   une diode aux mod eles empiriques, et n ecessitent le plus souvent un  etalonnage [38]. Ces mod eles de performance sont utilis es   la fois pour les pr evisions de production d' nergie servant   l'op eration du syst eme mais aussi pour la conception du syst eme en amont de l'installation [39].

1.4.2 Mod eles non-physiques ou statistiques

  l'inverse de la cat egorie pr ecedente les mod eles non-physiques ne sont pas bas es sur les lois physiques mais plut ot sur de la statistique : c'est en accumulant des donn ees et en les analysant qu'on est capable de pr evoir la puissance produite par une installation photovolta ique. Dans les sections suivantes, nous listerons les mod eles les plus couramment utilis es et cit es dans la litt erature.

a) Modèles de régression

Les modèles de régression sont capables de prédire la production d'énergie solaire en modélisant une relation statistique entre une ou plusieurs variables explicatives et une variable expliquée (la prévision). Les variables explicatives les plus communes sont l'irradiation solaire, la température et l'heure de la journée (affectant la position du soleil dans le ciel). Les techniques de régression pour la prévision PV vont de la régression linéaire simple à des modèles de régression plus élaborés (comme la régression logistique ou la régression polynomiale) en fonction de la nature et de la complexité de la relation considérée entre variables d'entrée et de sortie [24], [40]. La régression linéaire, modélisant la production PV comme une fonction linéaire des variables d'entrée est largement utilisée en raison de sa simplicité et de son efficacité. Les modèles de régression sont simples à appréhender et à mettre en œuvre et leur efficacité repose sur leur capacité à modéliser avec versatilité les relations entre les paramètres d'entrée, souvent complexes dans la réalité. Leur précision dépend fortement d'une sélection pertinente des variables explicatives et du choix de la relation entre variables explicatives et variable à prédire.

b) Modèles d'auto-régression

Ces modèles de prévision de séries temporelles sont une des approches pour la prévision photovoltaïque les plus abordées dans la littérature. Ils utilisent le lien avec les valeurs passées pour prédire les valeurs futures de production PV en employant diverses techniques statistiques qui peuvent capturer les tendances, comme la saisonnalité ou d'autres corrélations temporelles [41]. Les modèles d'auto-régression les plus courants sont :

- ARMA (AutoRegressive Moving Average) : moyenne mobile autorégressive où la valeur à prédire est exprimé comme une combinaison de ses valeurs passées :

$$Y_t = \varepsilon_t + \sum_{i=1}^p \phi_i Y_{t-i} + \sum_{i=1}^q \theta_i \varepsilon_{t-i}$$

où Y_t est la valeur à prévoir à l'instant t , ϕ_i et θ_i sont des coefficients du modèle à déterminer et ε_t les termes d'erreur.

- ARIMA (AutoRegressive Integrated Moving Average) : moyenne mobile autorégressive intégrée, la version stationnarisée du modèle ARMA.
- SARIMA (seasonal ARIMA) : c'est le modèle ARIMA prenant en compte des tendances saisonnières.

Le modèle ARMA nécessite cependant des données stationnaires, ce qui signifie que la moyenne, la variance et la structure d'autocorrélation de la série ne doivent pas changer temporellement. Les non-stationnarités dues à l'évolution du système étudié peuvent compliquer les efforts de modélisation, mais c'est ce que les modèles ARIMA ET SARIMA permettent de corriger par rapport au modèle ARMA [42]. La force de ces modèles est aussi leur faiblesse, la modélisation étant linéaire elle donne de très bon résultats lorsque les données sont très liées, notamment à court terme, et des performances moins satisfaisante sur des horizons plus lointains.

c) Lissage exponentiel

La technique du lissage exponentiel se base aussi sur la reconnaissance de certains motifs temporels dans les données historiques. Cette méthode présente la particularité de donner des poids différents en fonction de la temporalité de la donnée, réduisant ainsi l'influence des données passées par rapport aux données récentes de façon exponentielle [43]. Ainsi l'équation suivante régit cette méthode de prévisions :

$$Y_t = \alpha y_{t-1} + (1 - \alpha) Y_{t-1}$$

o , X_t la valeur   pr evoir   l'instant t , x_{t-i} l'observation   l'instant $t - 1$, α la constante de lissage (comprise entre 0 et 1) et X_{t-1} la pr evision pr ec edente.

Cette m ethode peut  tre adapt ee pour prendre en compte des tendances comme la saisonnalit  [19]. De fa on g n erale le lissage exponentiel est simple   mettre en place et produit de bons r esultats dont des conditions stables. Le mod le est moins pr ecis lorsque les changements brusques de tendance sont rares m me si le coefficient α ajoute un degr  de versatilit  au mod le permettant de l'ajuster. Cette difficult    pr evoir des ph nom nes soudains et l'impossibilit  de traiter des tendances non-lin aires sont ces principaux d fauts.

d) Cha nes de Markov

Une cha ne de Markov est un objet math matique permettant de mod liser des processus stochastiques. Sa principale caract ristique est de consid rer que l'information n cessaire pour pr edire l' tat futur du syst me est enti rement comprise dans son  tat pr esent (propri t  de Markov). Cette m thode subdivise donc la production PV envisageable en  tats distincts, qui peuvent inclure diff rents niveaux de puissance ou des param tres m t orologiques ayant un impact sur l'irradiation solaire. Ainsi on pr edit la puissance PV X_t , uniquement   partir de l' tat $t - 1$ gr ce au mod le de la cha ne de Markov qui d crit les probabilit s de passer d'une valeur   une autre, apprises   partir des donn es historiques. On estime par exemple la probabilit  de passer d'une forte production avec un ciel d gag    une chute de production [44].

Ce type de mod le est simple   mettre en oeuvre et ne n cessite que peu de puissance de calcul. Il reste cependant limit  par la simplicit  de la mod lisation de la relation entre l' tat et peine donc   repr senter des donn es non-stationnaires, ou   capturer des tendances non d pendantes   l' tat pr esent.

e) Mod les d'apprentissage automatique non-lin aires

Dans la pr evision photovolta que, les mod les d'apprentissage automatique non-lin aires sont de plus en plus utilis es et pl biscit es. Ils sont capables de pr edire la production future d' nergie solaire en assimilant de grandes quantit s de donn es en mod lisant des relations complexes   priori non- videntes ou non-mod lisables par les m thodes statistiques traditionnelles pr esent es pr ec edemment.

R seaux de neurones artificiels (Artificial Neural Networks, ANN)

Les r seaux de neurones artificiels (ANN) sont employ s avec succ s dans le domaine de la pr evision PV, notamment pour mod liser les relations complexes entre l'irradiation solaire, la temp rature et la production d' nergie [45]. Ils sont constitu s de plusieurs couches de neurones (une d'entr e, une cach e et une de sortie) qui vont permettre d'apprendre   partir de donn es. Les neurones repr sentent diff rentes fonctions et ont chacun un poids dans le mod le. Ainsi il y a toujours une  tape d'entra nement gr ce   un algorithme et une  tape de test pour valider le mod le, o  l'on fait passer des donn es   travers un r seau de neurones. Il existe une tr s grande vari t  d'architecture de r seau en fonction des param tres du probl me [22].

Machines   vecteurs de support (Support Vector Machine, SVM)

Cette m thode d'apprentissage automatique supervis e  tait initialement utilis e pour les t ches de classification mais est d sormais tr s courante et efficace pour la pr evision PV [46]. Elle permet d'effectuer une r gression non lin aire en transformant les donn es gr ce   un noyau, auquel les r sultats sont donc tr s sensibles [47].

Dans cette catégorie de méthodes, on peut également citer les méthodes de forêts aléatoires (random forest) [48] ou des k plus proches voisins (k -nearest neighbors, KNN) [49]. En conclusion, ces modèles d'apprentissage automatique présentés dans cette section s'avèrent hautement efficaces dans le domaine de la prévision PV, offrant des outils versatiles et précis pour prédire la production d'énergie solaire. Ces modèles peuvent s'adapter aux non-linéarités et aux dynamiques complexes des données étudiées. On peut cependant déplorer leur forte demande en données pour pouvoir obtenir de bon résultats et une possibilité de surapprentissage (lorsque le modèle s'adapte trop aux données d'entraînement). De plus, ces modèles sont souvent qualifiés de « boîtes noires » rendant très compliquée l'interprétabilité des résultats et ils demandent également une forte intensité computationnelle pour leur entraînement [50].

1.4.3 Modèles ensemblistes

La prévision ensembliste est une approche également très courante dans le domaine de la prévision PV. Le but est de d'augmenter la précision et la robustesse du processus par rapport aux données d'entrée en utilisant plusieurs fois le même modèle mais caractérisé ou entraîné différemment. Les modèles ensemblistes sont considérés comme proches de l'apprentissage automatique car ces derniers sont souvent employés comme « sous-modèles » dans l'approche ensembliste. Cette méthode est particulièrement efficace car les données d'entrées pour la prévision PV étant sujettes à une variabilité importante (voir section 1.1), on souhaite diminuer la variance et l'erreur des résultats obtenus, ce que permet cette approche par rapport à l'utilisation d'un unique modèle [21], [51].

Parmi les approches ensemblistes on peut citer :

- Le bagging : entraînement de multiples modèles en parallèle puis le résultat est fonction des sorties de tous les modèles, souvent comme moyenne [52].
- Le boosting : entraînement de modèles de façon séquentielle [53].
- Le stacking : entraînement de multiples modèles de « premier niveau » puis leurs résultats sont donnés comme entrée à un modèle de « second niveau » qui donnera la prévision finale [54].

L'avantage principal de ces modèles est qu'il sont peu sujets au surapprentissage et très bons pour modéliser des relations complexes. Cependant, ils requièrent des calculs importants et ne sont pas facile à mettre en oeuvre du fait de leur complexité.

1.4.4 Modèles hybrides

Les modèles hybrides permettent de profiter des avantages de différentes méthodes complémentaires en les combinant dans une approche cohérente [55]. Il devient ainsi possible de tirer profit à la fois d'un modèle physique et d'un modèle statistique : Akter et al. présentent de nombreuses combinaisons possibles [56]. La combinaison de plusieurs méthodes permet une analyse plus complète et fine des données, capturant ainsi la variété des relations pouvant exister entre les paramètres. Cela permet souvent d'améliorer la prévision dans un contexte où deux modèles séparés donneraient des résultats peu satisfaisants. La combinaison des modèles est choisie en fonction de l'application désirée, ce qui offre une grande versatilité à cette approche hybride. Cependant elle est parfois compliquée à mettre en place, nécessitant de prendre en compte les liens entre les modèles utilisés.

Ce sous-domaine de la prévision PV est encore récent mais montre des résultats très prometteurs. Son avantage est de pouvoir utiliser de nombreuses données d'entrées mais nécessite aussi une coordination entre les modèles utilisés. Cela implique également un coût calculatoire élevé, ce qui peut être rédhibitoire pour de la prévision court terme.

1.4.5 Perspectives

Nous avons parcouru un grand nombre de techniques de pr evisions PV en listant leur sp ecificit es, avantages et d efauts. Si de grands progr es ont ainsi  et e produits par la communaut e ces derni eres ann ees, il reste n eanmoins des perspectives particuli erement prometteuses, notamment dans les domaines suivants :

- Apprentissage profond (Deep Learning, DL) : cette technique de pr evision, sous-cat egorie de l'apprentissage automatique, a la particularit e est d'utiliser des r eseaux de neurones  a plusieurs couches (r eseaux profonds) pour analyser les donn ees. Ces r eseaux permettent de mod eliser des relations encore plus complexes entre les param etres par rapport aux mod eles d'apprentissage automatique mentionn es section 1.4.2.e. Ainsi Zhong et al. ont d evvelopp e une approche pour la pr evision long-terme [57] et Mellit et al. ont obtenus d'excellents scores avec leur r eseau de neurones profonds par rapport aux m ethodes « traditionnelles » [58].
- Big data : la multiplication des syst emes d'acquisition permet de collecter de plus en plus de donn ees (voir section 1.2). Un des principal d efi du domaine de la pr evision est alors la gestion et l'exploitation de ses donn ees pour perfectionner les mod eles. Il est av er e que l'utilisation de donn ees massives, combin ees la plupart du temps  a des m ethodes d'apprentissage automatique, permet d'am eliorer la pr ecision et la mod elisation des incertitudes. Cependant il n'est pas toujours possible ni facile de mettre en place ces m ethodes et la litt erature fait  etat de ces d efis concernant les big data [59].
- Mod eles hybrides : nous avons  evoqu e leur principe pr ec edemment (voir section 1.4.4) mais ce domaine  etant plut ot r ecent et offrant un tr es grand nombre de combinaisons possibles entre mod eles, il est donc encore vu comme un champ de recherche tr es actif et prometteur par Li et al. notamment [60].
- Analyse de donn ees en temps r eel : cette approche consiste  a traiter les donn ees d es leur obtention, sans ou avec peu de d elai, permettant ainsi d'obtenir des informations compl ementaires sur le syst eme consid er e. En croisant cette nouvelle source d'information avec celles dont ils disposent d ej a, les pr evisionnistes peuvent mettre  a jour leurs pr edictions et ainsi prendre en compte les param etres, am eliorant ainsi la pr evision [15].

Pour conclure cette revue des m ethodes de pr evision PV, nous pouvons affirmer que le domaine est tr es dynamique et que la diversit e des approches, conjugu ee  a la qualit e des travaux des auteurs mentionn es, permettent d'am eliorer continuellement la qualit e des r esultats pour les nombreuses applications possibles. Tous ces progr es facilitent donc la gestion de l' nergie solaire et son int egration aux syst emes  electriques. Nous avons qu'il restait encore des progr es  a effectuer notamment sur l'utilisation des donn ees aquis es  a court terme.

1.5 Repr esentation de l'incertitude : la pr evision probabiliste

1.5.1 Pr evision d eterministe, stochastique, qu esaco

De fa con g en erale, on retrouve deux types d'approches diff erentes dans le domaine de la pr evision : les m ethodes offrant un r esultat d eterministe et celles donnant un probabiliste. Comprendre les diff erences entre ces deux types de pr evisions est crucial pour les utiliser efficacement dans diverses applications.

a) R esultat d eterministe

Les pr evisions d eterministes fournissent une valeur sp ecifique pour un  v enement futur, comme la production PV qui sera g en er e  a un moment particulier de la journ ee (ex. : entre 11h et 12h,

la puissance moyenne produite sera de 250 kW). Ces prévisions produisent une seule valeur, représentant le « meilleur pronostic » que l'on est capable de fournir, sans indiquer son degré de certitude. On choisit le plus souvent une estimation de la *moyenne* ou la *médiane* de la variable aléatoire considérée. Ces prévisions sont plus simples et plus faciles à comprendre et à communiquer, car elles fournissent une prévision claire et sans ambiguïté. Les prévisions déterministes sont couramment utilisées dans un contexte où les décisions peuvent être basées sur un résultat unique, comme la planification de la maintenance, mais elle est aussi utilisée pour la planification quotidienne des opérations du réseau [61]. Les prévisions déterministes sont plus adaptées à des applications simples, où l'on néglige l'aspect stochastique de la prévision, permettant de se détacher de la complexité supplémentaire des *distributions* de probabilité.

b) Résultat probabiliste

Les prévisions probabilistes, en revanche, fournissent une gamme de résultats possibles associée à une mesure de probabilité pour les différentes issues envisagées. Ces prévisions prennent en compte l'incertitude inhérente à la *prédiction* d'événements futurs. Au lieu d'une seule valeur, les prévisions probabilistes peuvent présenter les *prédictions* sous la forme de *distributions* de probabilité, de quantiles ou de scénarios avec des probabilités associées.

Elles offrent une représentation de la variabilité potentielle et donc du risque, ce qui est particulièrement précieux dans les processus de prise de décision où l'incertitude joue un rôle important. Les prévisions probabilistes sont essentielles pour la gestion de risque, comme dans le commerce de l'énergie, où la compréhension du procédé stochastique influence les stratégies d'achat et de vente, pour ainsi éviter certains scénarios catastrophes [62]. Elles sont cruciales dans l'analyse de *contingence*, où l'on se prépare à faire face à différentes situations relativement à leur niveaux de risque [60]. Les prévisions probabilistes sont généralement plus complexes à obtenir et à interpréter, nécessitant des méthodes statistiques sophistiquées et une compréhension plus profonde du risque par les opérateurs et gestionnaires d'installations énergétiques.

Les prévisions déterministes impliquent un niveau de certitude en prévoyant un résultat spécifique, tandis que les prévisions probabilistes fournissent un spectre de résultats possibles, incluant l'incertitude. Les deux jouent des rôles importants dans la prévision PV et la gestion de l'énergie. Dans le contexte opérationnel, le choix entre l'utilisation d'une prévision déterministe ou probabiliste dépend des exigences spécifiques de l'application, de la nature des décisions à prendre et du niveau d'incertitude qui doit être géré.

1.5.2 Différentes approches de représenter l'incertitude

Pour les systèmes nécessitant anticipation et prise de décisions importantes, dont font partie les réseaux électrique et les installations PV, la prévision et son incertitude sont clés. Ainsi une représentation adaptée à la situation et fidèle à la réalité est cruciale. C'est pourquoi, nous allons en étudier les différentes possibilités dans la section suivante en discutant des différentes façons de représenter l'incertitude d'une prévision PV (présentées figure 1.5).

a) Distribution de probabilité

Comme évoqué plus tôt, la valeur de la prévision PV est une variable aléatoire que l'on souhaite étudier et modéliser (voir section 1.3.3). Or la meilleure façon de caractériser une variable aléatoire est de connaître sa *distribution* de probabilité, cette dernière étant communément représentée par sa *densité de probabilité* (DdP) ou par sa *fonction de répartition* (FdR). On peut obtenir une *distribution* grâce à une approche paramétrique ou en l'estimant à partir d'autres méthodes comme l'estimation par noyau [32] ou par réseaux de densité de mélange gaussien (Gaussian Mixture Density Networks, GMDN) [63]. On peut également citer la méthode des cumulants qui permet d'approximer une densité en estimant ses moments [64]. Il existe une grande variété d'approches

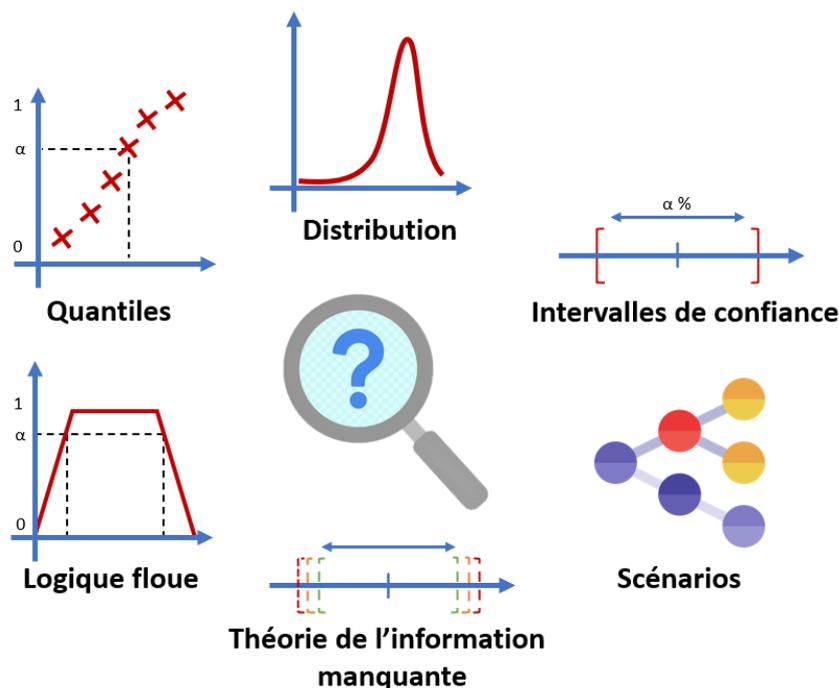


FIGURE 1.5 – Illustration des différentes représentations de l'incertitude de prévision

pour estimer la **distribution** de variables aléatoires dans les systèmes d'énergie comme l'on montré Aien et al. dans leur revue de littérature [65]

Si avoir à disposition la **distribution** de probabilité permet en théorie de prendre des décision avec la meilleure connaissance possible du futur, il n'est pas toujours possible de le faire car cela demande une quantité importante de données et d'autres représentations moins complètes sont souvent suffisantes.

b) Les quantiles

Les quantiles sont une représentation de l'incertitude de prévision PV particulièrement employé dans le domaine [15]. Ils permettent d'estimer des points de la fonction de répartition de la production PV. En effet un quantile, associé à son niveau, représente un productible attendu avec la probabilité de l'atteindre. La plupart du temps on cherche à obtenir une liste de quantiles et de leurs niveaux, formant une estimation discrète de l'espace des valeurs possibles de la variable prédite. Plus on a de quantiles et plus leur niveaux sont répartis sur l'espace des probabilités, meilleure sera la représentation de l'incertitude, ce choix dépendant du contexte où la prévision est utilisée.

Il existe de nombreuses méthodes pour obtenir ces quantile, allant de la régression quantile [66] aux réseaux de neurones [67]. Cette représentation est particulièrement adaptable car le choix des niveaux permet de modéliser différentes situations de risques. Cependant les quantiles ne permettent pas de modéliser des corrélations spatiales ou temporelles.

c) Les intervalles de confiance

Cette section présente une autre prévision probabiliste permettant de quantifier l'incertitude inhérente à cette dernière. Ainsi, il est possible d'obtenir à partir de multiples méthodes des intervalles de confiance de la production PV future : méthodes ensemblistes, d'apprentissage automatique ou hybrides [68]-[70]. Cette notion d'intervalle de confiance, issue de théorie des probabilités et des statistiques, permet de donner un intervalle avec un niveau de confiance associé, représentant la probabilité de trouver la valeur concernée par la prévision dans cet intervalle, elle est donc

également lié à la fonction de répartition de la variable. On peut ainsi choisir le niveau de confiance en fonction de son positionnement face au risque. La plupart du temps les intervalles sont sur en une dimension (concernant une variable) mais il est également possible d'en produire à plusieurs dimensions considérant alors un cas multivarié et traitant donc les dépendances possibles, sous la forme de polyèdres (hypercubes par exemple) ou d'ellipsoïdes [71]-[73].

L'avantage de cette représentation est qu'elle est simple et claire à appréhender. Cependant, la précision des intervalles de confiance dépend fortement de la qualité et de la quantité des données à disposition : leur mauvaise qualité peuvent conduire à des intervalles trompeurs.

d) La génération de scénarios

Dans de nombreux domaines, la génération de scénarios, et en particulier la simulation de Monte-Carlo est une approche très populaire pour modéliser une ou plusieurs variables aléatoires [74]. Le principe est de générer aléatoirement des scénarios représentant les futurs possibles pour la ou les variables étudiées. Dans le cas de la prévision PV, l'objectif est de produire, l'horizon temporel considéré, un très grand nombre de trajectoires temporelles envisageables de la production PV. Cette technique est précieuse pour la prévision PV probabiliste car elle permet d'explorer une large gamme de futurs possibles, en intégrant la variabilité et les incertitudes inhérentes aux conditions météorologiques et autres paramètres clés [65].

Méthode de génération

Pour générer des scénarios il est nécessaire d'avoir accès à la **distribution**, ou du moins à une estimation (voir section 1.5.2.a), de la variable dont on veut caractériser l'incertitude. De nombreuses variations de méthodes de tirage de scénario existent, on peut notamment citer le Monte-Carlo séquentiel, qui permet de modéliser des dépendances temporelles, en effectuant des tirages successifs dépendant des valeurs déjà tirées [75]. On peut également évoquer les méthodes de tirage stratifiées : elles permettent de peupler différemment l'espace des valeurs possibles, en biaisant le tirage, c'est notamment intéressant pour obtenir des valeurs extrêmes, pas bien représentées du fait de leur probabilité faible. Parmi elles on compte l'échantillonnage par hypercube latin et la méthode de Taguchi [75], [76].

Prise en compte de la corrélation

Dans les réseaux énergétique, il est très courant d'observer des corrélations spatio-temporelles : entre la production d'une installation PV à différents instants rapprochés, ou entre centrales espacées de quelques kilomètres par exemple. De plus, on observe également des corrélations entre certaines variables comme la consommation électrique et l'ensoleillement. Leur prise en compte dans les scénarios est donc prise très au sérieux dans la communauté scientifique [77].

Ma et al. et Pinson et al. utilisent une matrice de covariance dans le processus de génération, considérant la dépendance avec une fonction gaussienne multivariée [78], [79]. Van de Meer et al. vont plus loin en utilisant la notion de copule pour modéliser cette dépendance [80]. On peut également évoquer les travaux de Cui et al. qui utilisent un modèle de mélange de gaussiennes généralisées (Generalized Gaussian Mixture Model, GGMM), associé à un réseau de neurones pour modéliser la dépendance entre les erreurs de prévision d'énergie éolienne [81] ou encore ceux de Lee et Baldick qui utilisent le modèle de facteur dynamique généralisé (Generalized Dynamic Factor Model, GDFM) [82].

R eduction de sc enario

Nous avons vu ci-dessus qu'il  tait possible d'obtenir un grand nombre de sc enarios pour repr esenter l'incertitude li e   la pr evision PV. Or les applications qui utilisent ces sc enarios ne peuvent pas toujours prendre en compte autant de donn ees d'entr ee. C'est pourquoi de nombreuses techniques de r eductions de sc enarios, dont le principe g en eral est illustr e figure 1.6, ont  t e mise en place et peuvent  tre divis ees en diff erentes cat egories :

- Bas ees sur une distance : une m etricque est d efinie pour quantifier la distance entre les sc enarios de l'ensemble, ensuite diff erentes approches (algorithmes heuristiques ou mod eles d'optimisation) existent pour arbitrer et s electionner les sc enarios   supprimer et ceux   garder tout en calculant leurs probabilit es [83], [84].
- Construction d'arbre : ces m ethodes consistent   construire un arbre de d ecision avec des nuds et des branches repr esentant les diff erents  tats et  volutions possibles du syst eme. On r eduit alors le nombre de sc enarios en  laguant les branches les moins probables ou les plus similaires   fur et   mesure en partant du premier nud [85].
- M ethodes de partitionnement (ou clustering) : cette approche permet,   partir d'un algorithme, de regrouper les sc enarios similaires en groupes, puis   s electionner des sc enarios repr esentatifs pour chaque groupe en fonction d'une mesure d efinie. Cela permet de r eduire le nombre de sc enarios   consid erer tout en pr eservant leur diversit e et donc la repr esentation de l'incertitude. On peut citer la m ethodes des K-moyennes ou celle des K-m edo ides [86].
- Int egr ee au probl eme d'optimisation : certains mod eles d'optimisation utilis es pour la planification ou l'exploitation du syst eme  lectrique int egrent la r eduction de sc enarios. Ainsi le processus de r eduction est formul e comme faisant partie du probl eme, l'ensemble de sc enarios est raffin e en utilisant souvent un processus it eratif [87]. Cela permet de s electionner les sc enarios les plus pertinents pour la prise de d ecision tout en r eduisant la complexit e de calcul.

Les techniques de r eduction de sc enarios sont cruciales pour faciliter la prise de d ecision en r eduisant astucieusement le nombre de sc enarios   consid erer. Les diff erentes m ethodes ont leurs propres avantages et limites, et doivent  tre choisies en fonction des besoins sp ecifiques de gestion de l'incertitude.

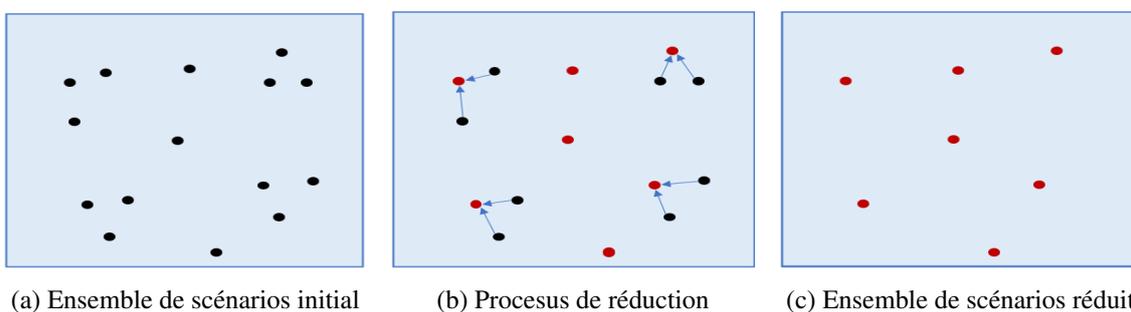


FIGURE 1.6 – Illustration du principe de r eduction de sc enarios

La g en eration de sc enarios de pr evision pour les syst emes PV est essentielle pour faciliter l'int egration de l' nergie solaire dans les r eseaux  nerg etiques. Les avanc ees technologiques, en particulier dans les domaines de l'apprentissage automatique mais plus largement dans le traitement des donn ees, continuent d'am eliorer les capacit es de g en eration de sc enarios, en faisant ainsi profiter les applications.

e) Autres méthodes

Les quatre représentations citées précédemment ne sont pas les seules étudiées dans la littérature. On peut évoquer les travaux de Chatterjee et al. qui ont utilisé les principes de la logique floue pour représenter l'incertitude de la prévision [88]. Cette approche, étendant la logique booléenne en utilisant des Z-nombres, permet d'estimer un degré d'incertitude mais reste complexe à implémenter. On peut également citer Soroudi et al., qui ont travaillé sur une notion appelée théorie de décision avec manque d'information (Info-Gap Decision Theory, IGDT) [89]. Cette approche est capable de considérer des intervalles dont les bornes sont variables et incertaines. Il est alors possible d'étudier différents cas en fonction de son aversion au risque. Le principal défaut de cette méthode est son conservatisme.

De nombreuses représentations de l'incertitude de la prévision sont donc utilisées dans la littérature, chacune avec ses avantages et ses limites. Nous verrons dans le chapitre suivant que suivant l'application voulue chacune peut s'avérer précieuse en vue des nombreux aspects de la gestion d'un réseau impliquant une source d'énergie intermittente comme le PV.

1.6 Évaluation de la prévision

Nous avons déjà évoqué l'importance de la précision de la prévision du fait de sa criticité pour la gestion du système électrique, il apparaît donc naturel de détailler les différentes méthodes d'évaluation possible. Pour cela, cette section détaillera les indicateurs les plus couramment utilisés dans la littérature. Nous diviserons cette revue d'ensemble en deux parties : les indicateurs pour prévision déterministe et ceux pour la probabiliste.

1.6.1 Indicateurs pour prévision déterministe

Dans le cas des prévisions déterministe, l'erreur de prévision (ou résidu) E_t pour instant t est la différence entre la valeur mesurée que l'on cherche à estimer Y_t et la valeur de sa prévision \hat{Y}_t . [90]

$$E_t = Y_t - \hat{Y}_t \quad (1.1)$$

Une bonne prévision doit avoir des résidus à la fois de :

- Valeur moyenne nulle,
- Valeurs non corrélées,
- Distribution symétrique [91].

Il existe différentes catégories d'indicateurs statistiques permettant de jauger la précision d'une prévision [91]. En premier lieu, on détaillera les erreurs dépendant de l'échelle : l'ampleur de l'erreur va dépendre de l'ordre de grandeur des données. Il faut donc prendre des précautions lorsque l'on veut comparer des prévisions issues de différents jeux de données en utilisant ces indicateurs.

Pour les indicateurs présentés, N représente la taille de l'échantillon utilisé pour le calcul.

a) Erreurs dépendant de l'échelle

- Erreur moyenne (ou Mean Bias Error, MBE) : $MBE = \frac{\sum_{i=1}^N E_i}{N}$
- Erreur de variance (ou Standard Deviation Error, SDE) : $SDE = \sqrt{\frac{1}{N} \sum_{i=1}^N (E_i - MBE)^2}$
- Erreur absolue moyenne (ou Mean Absolute Error, MAE) : $MAE = \frac{\sum_{i=1}^N |E_i|}{N}$

- Maximum de l'erreur absolue : $MaxAE = \max_{i=1}^N |E_i|$
- Racine de l'erreur quadratique moyenne (ou Root Mean Square Error, RMSE) :

$$RMSE = \sqrt{\frac{\sum_{i=1}^N E_i^2}{N}}$$

b) Erreurs sans échelle

Les indicateurs d'erreurs sans échelles permettent, eux, de comparer les prévisions entre elles lorsqu'elles ne sont pas issues des mêmes données.

- Erreur normalisée (ou nE) : $nE = \frac{E_t}{\max(Y_t)}$

Tous les indicateurs de la section 1.6.1.a précédente peuvent être repris en utilisant l'erreur normalisée nE .

- Moyenne du pourcentage absolu d'erreur (ou Mean Absolute Percentage Error, MAPE) :

$$MAPE = 100 \times \frac{\sum_{i=1}^N \frac{|E_i|}{Y_i}}{N}$$

- Médiane du pourcentage absolu d'erreur (ou Median Absolute Percentage Error, MdAPE) :

$$MdPAE = \text{médiane}\left(\left|100 \times \frac{E_i}{Y_i}\right|\right)$$

- Déviation du pourcentage moyen absolu (ou MAPD) : $MAPD = \frac{\sum_{i=1}^N |E_i|}{\sum_{i=1}^N |Y_i|}$

L'erreur en pourcentage ($P_i = 100 \times \frac{E_i}{Y_i}$) a l'avantage d'être indépendante de l'échelle. Ces déclinaisons sont donc souvent utilisées pour comparer les performances des prévisions entre différentes séries. Cependant ces indicateurs basés sur les erreurs en pourcentage ont l'inconvénient d'être infinis ou indéfinis s'il y a des valeurs nulles ou proches de zéro dans une série.

Il est également courant de mesurer la corrélation entre observations et prévisions, permettant de juger le degré de correspondance de leurs variations conjointes.

- Coefficient de corrélation : $\rho = \frac{Cov(E_t, Y_t)}{\sqrt{Var(E_t) \times Var(Y_t)}}$

c) Autres types d'erreurs

On peut mesurer l'asymétrie de la [distribution](#) de probabilité et cela correspond au troisième moment normalisé. Une asymétrie positive des erreurs de prévision conduit à une queue de [distribution](#) surestimée et inversement pour une asymétrie négative.

- Asymétrie (ou Skewness) :

$$Skewness = \frac{N}{(N-1)(N-2)} \sum_{i=1}^N \left(\frac{nE - \overline{nE}}{\hat{\sigma}} \right)^3$$

L'aplatissement est une mesure de la taille du pic de la [distribution](#) des erreurs de prévision, ou inversement de la largeur de la [distribution](#), et constitue le quatrième moment normalisé. La différence entre l'aplatissement d'une [distribution](#) d'échantillon et celui de la [distribution](#) normale est connue sous le nom d'aplatissement excédentaire (ou kurtosis). Une [distribution](#) avec une valeur de kurtosis positive indique une [distribution](#) avec un pic étroit ; tandis qu'un kurtosis négatif indique une [distribution](#) de données large ou plate. Le pic prononcé indique un grand nombre de très petites erreurs de prévision, ce qui témoigne d'une meilleure performance.

- Aplatissement excédentaire (ou excess Kurtosis) :

$$Kurtosis = \left\{ \frac{N(N+1)}{(N-1)(N-2)(N-3)} \sum_{i=2}^N \left(\frac{nE - \bar{nE}}{\bar{\sigma}} \right)^4 \right\} - \frac{3(N-1)^2}{(N-2)(N-3)}$$

L'asymétrie et l'aplatissement sont des indicateurs complémentaires à la MAE et RMSE et ne peuvent pas être analysés indépendamment [90].

1.6.2 Indicateurs pour prévision probabiliste

Il n'est pas possible d'utiliser les mêmes indicateurs que ceux définis dans la section ci-dessus pour les prévisions probabiliste. Ces dernières contenant plus d'informations qu'une simple valeur, il a donc été nécessaire de développer des moyens de mesurer leurs performances par rapport aux observations [21].

a) Indicateurs statistiques

Vérification des distributions

La vérification des **distributions** consiste à effectuer la correspondance entre les probabilités prévues et les fréquences observées. Il est possible de le faire à partir d'histogrammes de rang qui représentent la **distribution** de la fréquence à laquelle les observations se placent par rapport à la **distribution** attendue de la variable (**distribution** des valeurs de scénarios par exemple). Un histogramme de rang plat est une condition nécessaire pour valider les prévisions probabilistes. Cette vérification peut être effectuée pour chaque intervalle de l'horizon de prévision considéré, ou pour tous en même temps [92].

Il est aussi possible d'évaluer les **distributions marginales** prédictives grâce au « Continuous Rank Probability Score » (CRPS), qui peut être traduit par score de probabilité de rang continu. Le CRPS est une métrique couramment utilisée pour évaluer les prévisions probabilistes. Il mesure la dissemblance entre la fonction de répartition des prévisions et celle des observations pour chaque intervalle considéré. Le CRPS est défini comme l'intégrale de la différence absolue entre ces deux fonctions de répartition, sur tous les niveaux de probabilité. Il est exprimé dans les mêmes unités que les données et prend des valeurs comprises entre 0 et l'infini, 0 étant la valeur parfaite. Le CRPS pour l'horizon $t+k$, avec $\hat{F}_{t+k|t}$ la fonction de répartition estimée à l'instant t de l'observation y_{t+k} , est calculé comme ceci :

$$CRPS_k = \frac{1}{T} \sum_{t=1}^T \left(\int_0^1 (\hat{F}_{t+k|t}(y) - \mathbb{1}(y - y_{t+k}))^2 dy \right) \quad (1.2)$$

où $\mathbb{1}(y - y_{t+k})$ est la fonction de répartition de l'observation $t+k$, et T , le nombre d'horizons de prévision considérés (par exemple 365 pour une année).

Le CRPS est une métrique qui prend en compte à la fois la précision et la dispersion des prévisions. Elle est également sensible aux erreurs systématiques et permet aussi de comparer des prévisions probabilistes avec des prévisions déterministes. Plus le CRPS est faible, plus les prévisions sont précises.

Score d'énergie

Le score d'énergie (ou Energy Score, ES) est une généralisation du CRPS : il permet de mesurer la précision des prévisions sur plusieurs horizons de prévision simultanément [77].

La formule du score d'énergie ES_t pour une prévision effectuée à l'instant t est donnée par :

$$ES_t = \frac{1}{N} \sum_{n=1}^N \left\| y_t - \hat{y}_t^{(n)} \right\|^2 - \frac{1}{2N^2} \sum_{i=1}^N \sum_{j=1}^N \left\| \hat{y}_t^{(i)} - \hat{y}_t^{(j)} \right\|^2 \quad (1.3)$$

o  N est le nombre de sc enarios, y_t , la s erie temporelle observ ee   partir de l'instant t , $\hat{y}_t^{(n)}$ les valeurs des sc enarios, et $\|\cdot\|_2$ la norme euclidienne.

Comme pour le CRPS, la valeur du score d' nergie pour un instant t est moyenn e sur le nombre d'horizons de pr evision consid er e pour obtenir un score global : $ES = \sum_{t=1}^T ES_t$, on pourra aussi  tudier la variance de ES_t .

Cet indicateur poss ede une bonne capacit e de discrimination pour  valuer les pr evisions dont les **marginales** ont une variance correcte mais des moyennes biais ees. Cependant, il est insensible   une mauvaise sp ecification des structures de d ependance [93]. L'ES fournit une valeur unique n egative pour un ensemble de sc enarios, plus le score sera faible, meilleure sera la pr evision.

Score de variogramme

Pour palier aux d efauts de l'indicateur susmentionn e, Scheuerer et al. ont mis au point un indicateur permettant d' valuer des pr evisions multivari ees (trajectoires temporelles) en se basant sur le concept de variogramme. Le score de variogramme (ou Variogram-based score, VS)  tudie   la fois la moyenne, la variance et la corr elation. Ainsi pour une pr evision de dimension d , concernant une variable al eatoire multivari ee \hat{Y}_t de fonction de r epartition \hat{F}_t , l'indicateur VS_t d'ordre α est d efini ainsi :

$$VS_t = \sum_{i,j=1}^d w_{ij} (|y_{t,i} - y_{t,j}|^\alpha - E_F |\hat{Y}_{t,i} - \hat{Y}_{t,j}|^\alpha) \quad (1.4)$$

o  $\hat{Y}_{t,i}$ et $\hat{Y}_{t,j}$ sont les  l ements i et j de la variable al eatoire multivari ee \hat{Y}_t . Le variogramme E_F de la pr evision est estim e ainsi :

$$E_F |\hat{Y}_{t,i} - \hat{Y}_{t,j}|^\alpha \approx \frac{1}{N} \sum_{n=1}^N |\hat{y}_{t,i}^{(n)} - \hat{y}_{t,j}^{(n)}|^\alpha, \quad \forall i, j = 1, 2, \dots, d. \quad (1.5)$$

On obtient finalement l'indicateur global en sommant l'indicateur VS_t pour les T horizons temporels de pr evision  tudi es :

$$VS = \frac{1}{T} \sum_{t=1}^T VS_t \quad (1.6)$$

b) Indicateurs de forme

Les approches de v erification des pr evisions de la section ci-dessus permettent de juger statistiquement diff erents ensembles de trajectoires, mais elles ne fournissent pas d'informations sur leur capacit e   imiter certaines caract eristiques des variables al eatoires  tudi ees. Pour cela, plusieurs approches bas ees sur l' tude de la forme et des variations de la pr evision ont  t e mise en place.

Score  v nementiel

Golestaneh et al. ont d ecrit une m ethode permettant de v erifier la probabilit e que les pr evisions v erifient certains  v nements observ es dans les s eries temporelles r ealis ees [93].

Les  v nements sont d efinis par le d epassement ou non d'un seuil par une variable continue, par exemple « la production photovolta ique est sup erieure   200 kW ». Pour chaque valeur de sc enario compar ee aux observations on obtient donc un r esultat binaire (0, 1), en fonction de la r ealisation ou non de l' v nement. La probabilit e de r ealisation sur l'ensemble de sc enarios est elle comprise entre [0,1].

Des fonctionnelles peuvent être définies pour décrire des types d'évènement différents. Celle ci dessus permet pour une trajectoire z_t de vérifier si ses valeurs y_{t+i} (étant la $i^{\text{ème}}$ valeur de z_t), dépassent un certain seuil ξ pour une période de h intervalles de temps autour de l'instant k :

$$g(z_t, k, h, \xi) = \prod_{i=k-h/2}^{i=k+h/2} \mathbb{1}\{y_{t+i} \geq \xi\} \quad (1.7)$$

Ici $\mathbb{1}\{\bullet\}$ retourne 1 si la condition est respectée et 0 sinon.

On peut aussi définir une autre fonctionnelle qui permet de repérer des valeur de gradients ξ pour une période de h intervalles de temps autour de l'instant k :

$$g(z_t, k, h, \xi) = \mathbb{1}\{(\max_i y_{t+i} - \min_i y_{t+i}) \geq \xi\} \quad (1.8)$$

avec $i \in \{k - h/2, \dots, k + h/2\}$

Finalement on calcule la probabilité d'un évènement défini par $g(\cdot, \theta)$ avec $\theta = (k, h, \xi)$, les paramètres de l'évènement, en sommant les résultats des fonctionnelles ci-dessus de chaque scénario z_t^n de l'ensemble z_t^N :

$$P_t [z_t^N, g(\cdot, \theta)] = \frac{1}{N} \sum_{n=1}^N g(z_t^n, \theta) \quad (1.9)$$

Score de Brier

Le score de Brier (BS) permet d'aller plus loin dans l'analyse événementielle en étudiant la déviation quadratique entre la prévision de probabilité d'un évènement, définie par l'équation 1.9 ci-dessus, et son occurrence observée. Le BS est calculé selon l'équation 1.10 ci-dessous, pour un évènement $g(\cdot, \theta)$, des ensembles de scénarios z_t^N et des observations y_t correspondant à T horizons temporels de prévision.

$$BS = \frac{1}{T} \sum_{t=1}^T (P_t [z_t^N, g(\cdot, \theta)] - g(y_t, \theta))^2 \quad (1.10)$$

Plus l'indicateur BS sera petit, meilleure sera la performance de la prévision pour représenter l'évènement considéré.

Evaluation d'intervalles

Quan et al. ont mis au point une méthode pour évaluer un autre type de prévision probabiliste : les intervalles de confiance. Pour cela il ont définis deux indicateurs permettant de comparer la prévision aux observations [94]. Cette méthode permet aussi d'analyser une liste de quantiles, ces derniers étant liés aux intervalles de confiance (voir section 1.5.2.b).

L'acuité et la fiabilité des intervalles peuvent être exprimées quantitativement à l'aide de la largeur moyenne normalisée de l'intervalle de prévision (PINAW) combinée à la probabilité de couverture de l'intervalle de prévision (PICP). Alors que la première est une propriété de la prévision seule, la deuxième quantifie la probabilité que l'intervalle de prévision couvre les observations avec un niveau de couverture défini μ . Le niveau de couverture μ est un paramètre important dans les processus de prise de décision.

$$PINAW = \frac{1}{TR} \sum_{t=1}^T (U_t - L_t) \quad (1.11)$$

avec L_t et U_t respectivement les bornes inférieure et supérieure de l'intervalle de confiance, T , le nombre d'horizons étudiés et R un facteur de normalisation.

$$PICP = \frac{1}{T} \sum_{t=1}^T \varepsilon_t \quad (1.12)$$

avec $\varepsilon_t = \mathbb{1}\{y_t \in [L_t, U_t]\}$

Cette section nous a permis de d ecrire le cadre dans lequel la performance des pr evisions, aussi bien d eterministe que probabiliste, peut ˆetre mesur ee.

1.7 Conclusions

A travers cette revue de litt erature concernant la pr evision PV, nous avons pu d'abord appr ehender l'origine de son incertitude, due ˆa la nature stochastique des conditions m eteorologiques dont elle d epend. Par la suite, les diff erentes approches et m ethodes permettant d'obtenir des pr evisions ont  et e d ecrites, en soulignant leur grande diversit e et l'activit e de la recherche dans ce domaine. Ainsi, les nombreuses applications possibles de l'utilisation d'une pr evision PV trouvent une m ethode de pr evision adapt ee. Ce chapitre a  egalement permis d'illustrer que la repr esentation de l'incertitude  etait aussi vari ee que cruciale pour les installations PV. Finalement nous avons discut e des m ethodes pour  evaluer ces pr evisions,  etape de validation indispensable du proc ed e de statistique de taritement de donn ees.

Nos travaux se positionneront ˆa la fois sur les m ethodes de pr evision avec notamment la production de quantiles. Nous explorons aussi les diff erentes repr esentations des [distributions](#) de pr evision PV avec notamment la prise en compte et la caract erisation de corr elations temporelles pour une centrale donn ee, permise par l'utilisation d'un mod ele g en erique de d ependance. Notre approche nous permettra de g en erer un ensemble r eduit de sc enario ˆa partir de nombreuses informations statistiques mais aussi de tirer profit de donn ees observ ees en effectuant de l'assimilation de donn ees pour am eliorer notre connaissance du futur.

Dans le chapitre suivant, nous ferons le lien entre ces pr evisions et leur utilisation dans la gestion de micro-r eseau. En effet, utilis ees comme donn ees d'entr ee, leur vari et e et leur qualit e permet de faire face ˆa l'al ea de la production PV pour de nombreuses applications.

2

Gestion de micro-réseau sous incertitude

Ce chapitre décrit le cadre scientifique dans lequel nos travaux pour la gestion de micro-réseau sous incertitude s'inscrivent. Il présente les différentes approches par rapport à l'incertitude considérée et les applications correspondantes dans les multiples aspects de l'opération optimale d'un micro-réseau.

Sommaire

2.1	L'optimisation appliquée au problème de la gestion de micro-réseau	36
2.1.1	Le principe de l'optimisation	36
2.1.2	Méthodes d'optimisation	36
2.1.3	Autres approches	37
2.2	Optimisation probabiliste	38
2.2.1	Optimisation stochastique	38
2.2.2	Optimisation robuste	39
2.2.3	Optimisation avec contraintes probabilistes	40
2.3	Applications pour la gestion de micro-réseau	41
2.3.1	Opérations et participation au marché	41
2.3.2	Services systèmes	43
2.3.3	Stabilité, sécurité et fiabilité d'opération	44
2.4	Conclusions	45

2.1 L'optimisation appliquée au problème de la gestion de micro-réseau

La gestion d'un micro-réseau nécessite de l'anticipation pour plusieurs problématiques à différents niveaux temporels. Ces problèmes impliquent des prendre des décisions pour le futur tout en ayant une connaissance imparfaite, par exemple une prise de position sur un marché, le démarrage d'un groupe thermique ou encore la gestion d'un stock d'énergie. Ces choix sont faits en fonction d'hypothèses, notamment de prix de l'énergie ou de prévisions de production, et d'un objectif, qui peut être économique, environnemental ou concerner la satisfaction des usagers. On souhaite ainsi déterminer les choix à faire pour la gestion du micro-réseau en fonction de notre objectif tout en tenant en compte nos hypothèses et des paramètres du système étudié (ses entités, composants et leurs interactions possibles).

2.1.1 Le principe de l'optimisation

L'approche la plus courante dans la littérature pour résoudre ses problèmes dans les micro-réseaux, est d'utiliser l'optimisation mathématique [95]. Cette approche permet de modéliser le problème sous la forme présentée ci-dessous :

$$\left\{ \begin{array}{ll} \min_{x \in \mathbb{R}} & f(x) \\ s.c. & g(x) \geq 0 \\ & h(x) = 0 \end{array} \right. \quad (2.1)$$

Ainsi on cherche à minimiser (ou maximiser) une fonction **f** dite **objectif** en choisissant la valeur optimale de certaines **variables de décisions x**. Cependant, ces variables de décisions, correspondant aux différents choix possibles pour opérer le micro-réseau, ne sont pas complètement libres : elles sont contraintes par les fonctions **g** et **h** (*s.c.* : sous contraintes), qui permettent de les modéliser sous la forme d'inéquations et d'équations. L'ensemble des variables respectant ces contraintes sont appelées solutions « admissibles » ou « réalisables ».

Ces différentes contraintes peuvent concerner les limites de production des entités du système, les capacités de stockage limitées ou encore des contraintes opérationnelles. Par exemple, la puissance maximum soutirable depuis le réseau peut être une variable de décision contrainte par le contrat signé avec le fournisseur et/ou l'équipement du réseau, ($P^{\text{RÉSEAU}} \leq P_{\text{Max}}^{\text{RÉSEAU}}$).

Une fois formalisé par un **modeleur** pour qu'il soit compréhensible par les algorithmes d'un **solveur**, ce dernier se charge « résoudre » le problème, c'est à dire trouver les valeurs des variables de décisions qui minimisent la fonction objectif tout en respectant les contraintes. Différents algorithmes peuvent être utilisés pour obtenir la solution optimale du problème, leur choix dépend de sa nature [96].

2.1.2 Méthodes d'optimisation

L'optimisation mathématique est utilisée dans de nombreux domaines [97] et il existe un panel d'approches permettant de traiter des problèmes spécifiques en fonction de leurs particularités :

- La programmation linéaire (Linear Programming, LP) : dans ce type de modèle il est uniquement possible de combiner linéairement des variables continues. C'est assez restrictif pour la modélisation mais donne des problèmes très simples à résoudre grâce au fait que l'ensemble des solutions admissible soit convexe [98].
- La **programmation linéaire en nombres entiers** (Mixed Integer Linear Programming, MILP) : dans ce type de problème, les variables de décision peuvent prendre des valeurs entières ou continues. Cette méthode est utilisée pour résoudre des problèmes où certaines variables

doivent être exprimées en nombres entiers, comme l'affectation de ressources ou la planification et est donc très populaire dans la gestion des micro-réseau [99]. Ce type de problème permet également de linéariser des modèles complexes et permet d'utiliser des [solveurs globaux](#).

- La programmation dynamique (Dynamic Programming, DP) : permet de résoudre des problèmes en décomposant ceux-ci en sous-problèmes plus simples tout en mémorisant les résultats intermédiaires. Cette technique est particulièrement efficace pour les problèmes d'optimisation où les décisions prises à un moment donné dépendent des solutions des sous-problèmes antérieurs [100].
- La programmation non-linéaire (Non-Linear Programming, NLP) : dans ce type de modèle les relations entre variables provoquent des non-linéarités entraînant des difficultés de résolution pour le [solveur](#) et souvent l'obtention d'optimum locaux, mais peut s'avérer précieux dans la modélisation de réseaux électriques, notamment pour le problème de flux de puissance [101].
- La programmation probabiliste : permet d'intégrer l'incertitude dans les problèmes en considérant certains paramètres ou contraintes comme aléatoires. Cette approche permet d'obtenir des solutions prenant en compte des aléas, ce qui est crucial pour la planification et la prise de décision dans des environnements incertains.

Ces approches ne sont ni exhaustives (voir figure), ni cloisonnées, il est possible, et même courant de combiner ces approches comme le montrent Qiu et al. dans leurs travaux en utilisant à la fois la [programmation linéaire en nombres entiers \(PLNE\)](#) et plusieurs modèles de programmation probabiliste [102].

2.1.3 Autres approches

Il n'y a pas non plus que l'optimisation mathématique qui est capable de traiter de tels problèmes d'optimisation pour la gestion de micro-réseaux. On peut ainsi citer les approches basées sur l'intelligence artificielle et les réseaux de neurones notamment, qui amènent leur habileté à modéliser des systèmes complexes, particulièrement adaptée à certaines situations pour la gestion de réseaux électriques [103], [104].

Certains auteurs utilisent des méthodes heuristiques et méta-heuristiques pour les problèmes de prise de décision dans les micro-réseaux : on peut notamment citer les algorithmes génétiques avec les travaux de Chen et al. [105]. Les algorithmes évolutionnaires sont également très étudiés avec les techniques d'optimisation par essaim (Swarm Optimization) et celles par colonie de fourmis (Ant Colony Optimization) [106], [107]. Ces algorithmes ont pour avantage de fournir des solutions très rapidement mais ne garantissent pas leur optimalité [96].

On peut aussi évoquer la commande prédictive (Model Predictive Control, MPC) : cette branche de l'automatique permet d'anticiper le comportement futur d'un système et ainsi optimiser son contrôle en conséquence. On résout de manière séquentielle un problème d'optimisation sur un horizon temporel glissant, ajustant les actions de commande au fur et à mesure que les informations sont révélées (optimisation en ligne). Elle est couramment utilisée pour résoudre des problèmes dans l'opération de micro-réseaux à court terme [108].

Nous avons introduit la grande variété de méthodes analytiques disponibles et performantes pour la gestion des micro-réseaux, elles sont résumées figure 2.1. Dans la majorité des cas, les décisions doivent se prendre en présence d'incertitudes [109], et en particulier lorsque des sources d'énergie intermittentes, sujettes aux aléas comme le PV, occupent une place importante (voir chapitre 1). C'est pourquoi la section suivante détaillera les approches probabilistes, particulièrement adaptées à la prise de décision sous incertitude [110].

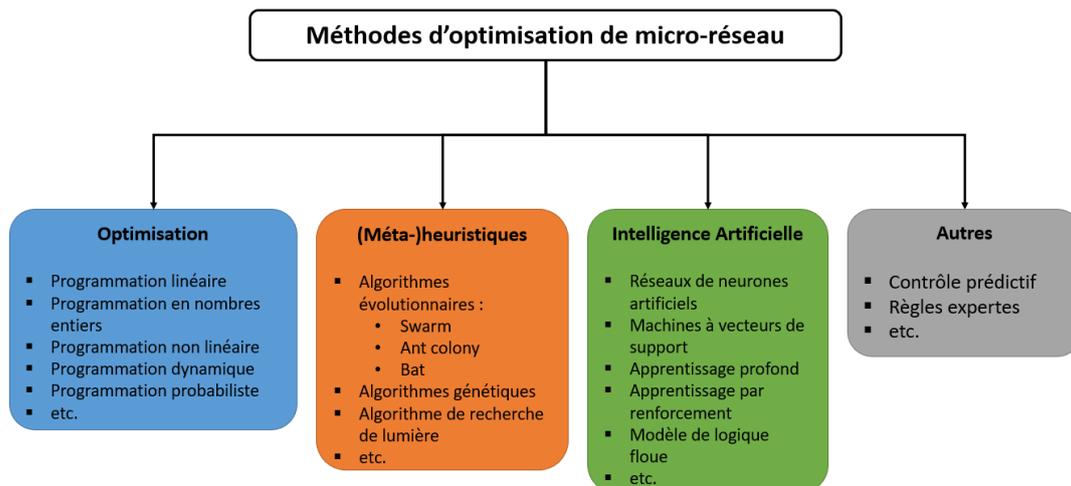


FIGURE 2.1 – Résumé des différentes méthodes d’optimisation employées dans la gestion des micro-réseaux

2.2 Optimisation probabiliste

Nous avons vu précédemment que l’optimisation probabiliste intègre les incertitudes dans leur modèle, permettant ainsi de prendre en compte le risque potentiel dans le processus de prise de décision. En fonction de l’exposition au risque voulue ou acceptée par le décisionnaire, il existe donc différentes approches au sein de l’optimisation probabiliste :

- Optimisation stochastique : pour une exposition neutre au risque.
- Optimisation robuste : pour une posture conservatrice face au risque.
- Optimisation avec contraintes probabilistes : cette approche permet d’adapter le degré d’exposition au risque.

Ces trois approches trouvent chacune leurs applications dans la gestion des micro-réseau. Quel que soit le type d’optimisation sélectionné, on peut définir une méthodologie commune pour l’optimisation probabiliste.

1. Définition de l’incertitude : il est crucial de définir le modèle que l’on souhaite utiliser pour caractériser l’incertitude ou appréhender celui qui est disponible.
2. Modélisation du problème : Un modèle d’optimisation est formulé spécifiquement pour l’approche retenue et le modèle des incertitudes.
3. Résolution et interprétation : Une fois les résultats obtenus via le *solveur*, il est indispensable d’analyser les résultats obtenus au regard de l’incertitude que l’on a modélisé.

2.2.1 Optimisation stochastique

L’approche stochastique permet de modéliser l’incertitude avec une position neutre face au risque dans la prise de décision, nous allons décrire ses spécificités dans cette section. Le modèle standard est décrit dans l’équation 2.2 ci-dessous.

$$\left\{ \begin{array}{l} \min_{x \in \mathbb{R}} \quad \mathbb{E}[f(x, \omega)] \\ s.c. \quad g(x, \omega) \geq 0 \\ \quad \quad h(x, \omega) = 0 \\ \quad \quad \forall \omega \in \Omega \end{array} \right. \quad (2.2)$$

Avec Ω représentant, l'espace de probabilités des paramètres stochastiques ω . Le modèle stochastique considère donc l'ensemble des possibles pour le problème étudié, et l'espérance de la fonction objectif est minimisée (ou maximisée) au regard des probabilités définies [111]. Dans les problèmes stochastiques l'espace des probabilités est discrétisé grâce à un ensemble de scénario : $\Omega = \{\omega_n : n = 1, \dots, N\}$. Permettant ainsi d'exprimer l'espérance de la fonction objectif grâce à l'approximation par moyenne d'échantillon [112] : $\mathbb{E}[f(x, \omega)] = \frac{1}{N} \sum_{n=1}^N f(x, \omega_n)$.

Si l'on considère l'incertitude dans un modèle stochastique, il faut tout de même obtenir un résultat permettant de prendre des décisions au moment où le problème est résolu. Ainsi on divise de problème entre les variables à fixer (variables « here-and-now »), notées x et les variables dépendant des paramètres aléatoires (variables « wait-and-see »), notées y , dont on peut se permettre de ne pas décider de leur valeur immédiatement. On divise donc le problème en deux étapes : le problème principal et le « recours » :

$$\min_x f_x(x) + \mathbb{E}_{\omega} [F_y(x, \omega)] \quad (2.3)$$

Cette approche permet « d'explorer » les valeurs possibles envisagées y pour prendre les meilleures décisions x . Ainsi $F_y(x, \omega)$ est la solution optimale du sous-problème défini ci-dessous.

$$\begin{cases} \min_{y \in \mathbb{R}} f_y(y, \omega) \\ s.c. \quad g_y(x, y, \omega) \geq 0 \\ \quad \quad h_y(x, y, \omega) = 0 \end{cases} \quad (2.4)$$

Dans le cas des micro-réseau, il est courant de trouver des problèmes multi-étages, permettant de modéliser différents horizons temporels où les incertitudes et les décisions à prendre sont distinctes en fonction du temps [113], [114].

L'optimisation stochastique implique donc de créer un ensemble de scénarios pour modéliser l'incertitude, les différentes façons sont évoquées au chapitre précédent (voir section 1.5.2.d).

Les limites de l'optimisation stochastique est le coût computationnel : plus on veut une bonne représentation des distribution modélisant l'incertitude plus il faut un nombre important de scénarios, ce qui entraîne des problèmes de plus grande taille et longs à résoudre (« la malédiction de la dimension ») [115], [116].

2.2.2 Optimisation robuste

L'approche robuste permet une autre approche de l'incertitude dans un modèle de prise de décision probabiliste. Le modèle standard est décrit dans l'équation 2.5 ci-dessous [71].

$$\begin{cases} \min_{x \in \mathbb{R}} f(x, \omega) \\ s.c. \quad g(x, \omega) \geq 0 \\ \quad \quad h(x, \omega) = 0 \\ \quad \quad \forall \omega \in \mathcal{U} \end{cases} \quad (2.5)$$

avec \mathcal{U} , l'ensemble des valeurs possible de ω . Dans le cas de l'optimisation robuste l'objectif est d'obtenir une solution pour tout les cas de figures possibles, cela revient donc à optimiser le pire cas possible.

Cela implique la création d'un ensemble d'incertitudes, qui est une description mathématique de tous les scénarios possibles ou des variations acceptables des paramètres aléatoires du modèle (voir chapitre précédent, section 1.5.2.c).

Tout comme pour les modèles stochastiques il est possible de créer des modèles multi-étapes qui permettent de décourvrir les incertitudes au fur et à mesure de l'horizon temporel étudié [117], [118].

Les avantages de tels modèles est qu'il permettent un haut niveau de fiabilité par rapport à l'incertitude mais il amène également un surconservatisme [119].

2.2.3 Optimisation avec contraintes probabilistes

Ces modèles permettent d'affecter une probabilité à un ensemble de contraintes : on souhaite que certaines contraintes du problème ait un niveau de probabilité donné d'être respectée.

$$\mathbb{P}_{\omega} [h(x, \omega) \leq 0] \geq \alpha \quad (2.6)$$

Avec α la probabilité de respect de la contrainte aussi considérée comme sa fiabilité.

Par rapport au conservatisme des modèles robustes, cette approche permet de garder un degré de fiabilité important sans pour autant considérer le pire des cas envisageable, cela permet de moins pénaliser la fonction objectif. Cependant la modélisation de contraintes probabilistes peut engendrer des non-linéarités et une non-convexité de l'ensemble des solutions admissibles [120]. Or, il est possible dans certains cas de modifier le problème pour qu'il soit traitable par des solveurs en utilisant des approximations sur l'ensemble des solutions admissibles [121] ou en linéarisant ces contraintes à partir de la fonction de répartition inverse des paramètres aléatoires [122].

Les trois approches sont résumées sur la figure 2.2 ci-dessous : la discrétisation de la distribution par les scénarios de l'optimisation stochastique, la prise en compte de tous les cas de figures pour l'optimisation robuste et la modélisation d'un degré de confiance pour la dernière.

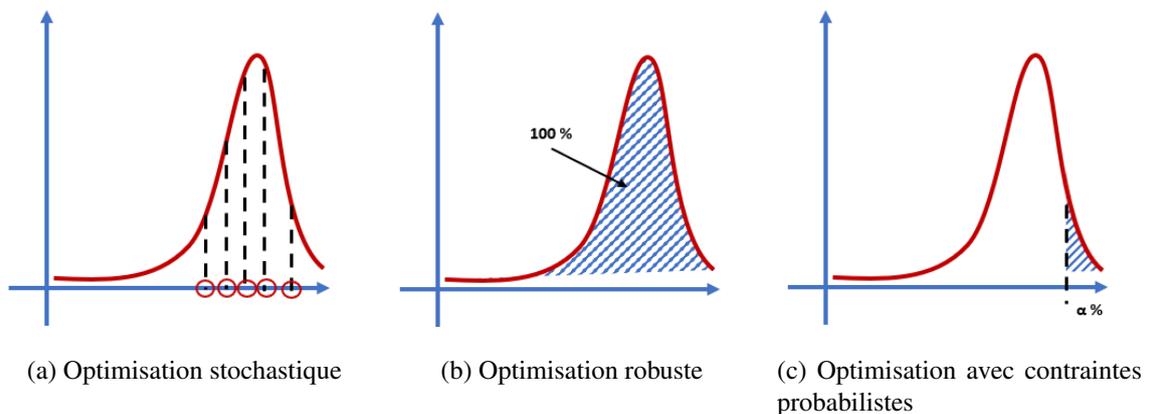


FIGURE 2.2 – Illustration des différentes approches d'optimisation probabiliste

Il est possible de combiner ces différentes approches afin de différencier l'appréhension du risque en fonction des paramètres considérés ou de mélanger les représentations en fonction des prévisions disponibles. Cette approche hybride est très utile dans le cas de la gestion des micro-réseau où l'on ne veut pas traiter toutes les contraintes de la même façon. Il est ainsi courant de modéliser par une contrainte probabiliste les chances de ne pas fournir la demande tout en ayant une fonction objectif probabiliste où les incertitudes des énergies intermittentes sont modélisées par des scénarios [123]. Après avoir discuté les principes de différentes techniques d'optimisation, nous allons évoquer les applications possibles pour la gestion de micro-réseau dans la section suivante.

2.3 Applications pour la gestion de micro-réseau

Nous avons vu dans l'introduction que l'apparition de moyens de production renouvelables, décentralisés et intermittents était un challenge pour l'opération du réseau électrique, y compris pour les micro-réseaux. Le problème de gestion de l'énergie dans les micro-réseaux, comme à plus grande échelle, se concentre sur l'équilibre de puissance électrique à court et moyen terme entre les différentes entités qui le composent : moyens de production, consommation et systèmes de stockage de l'énergie. Coordonner et anticiper leur fonctionnement permet à l'opérateur d'un micro-réseau d'en assurer la fiabilité, la rentabilité et la durabilité. Cela implique de gérer la variabilité et l'incertitude des ressources comme le solaire et l'éolien, ainsi que la demande fluctuante des consommateurs mais également des autres sources d'incertitudes.

Les stratégies d'opération d'un micro-réseau, incluant la gestion de l'énergie et le pilotage des entités, doivent donc pouvoir s'adapter aux changements à la fois de l'offre et la demande d'énergie, en atténuer les risques associés, et assurer une alimentation électrique continue dans diverses conditions de fonctionnement [124].

Pour ce challenge de gestion de l'énergie dans les micro-réseaux, les techniques d'optimisation sont très employées et visent à atteindre l'optimalité d'opération au regard des critères fixés (fonction objectif et contraintes). L'intégration croissante des énergies renouvelables dans les micro-réseaux rend la modélisation des incertitudes de plus en plus cruciale pour continuer d'opérer ces systèmes de façon optimale, en termes de coût et de fiabilité notamment [125]. Les techniques d'optimisation probabiliste sont donc particulièrement indiquées pour la prise en compte d'incertitude dans ce contexte.

Ainsi Cifti et al ont utilisé des contraintes probabilistes pour fixer un niveau de fiabilité de 95% sur le bilan de puissance du micro-réseau étudié [126]. Quant à eux, Ebrahimi et Amjady ont développé un problème robuste à trois niveaux, permettant d'envisager le cas le moins favorable avec comme sources d'incertitudes le prix de l'électricité, l'énergie PV, éolienne et la charge permettant ainsi de limiter les conséquences d'évènements extrêmes [127]. Finalement, l'optimisation stochastique peut aussi être employé, et ce dans de nombreux cas, notamment pour baisser les coûts moyens d'approvisionnement en électricité sur un horizon temporel important grâce à l'approche par scénarios [113]

De plus, il n'est pas rare que les micro-réseaux incluent d'autres formes de vecteurs énergétiques, ajoutant une couche supplémentaire de complexité à leur gestion, mais également des sources d'incertitude. Ainsi Ahn et al. étudient la combinaison d'électricité et de chaleur dans un micro-réseau et l'optimisation probabiliste leur permet de modéliser la corrélation entre les deux demandes de vecteurs [128]. Les techniques probabilistes rendent possible la prise en compte des dépendances dans de nombreux autres cas [60]. L'apparition de nouveaux usages du réseau électrique, permet d'illustrer ces avantages avec la prise en compte de l'incertitude lié aux véhicules électriques [129].

La question de la gestion d'énergie, découlant de la nécessité d'équilibre des puissances est la pierre angulaire de l'opération d'un réseau électrique. Dans la section suivante, nous allons évoquer les conséquences d'une participation au marché de l'électricité pour un micro-réseau sur ce problème de gestion.

2.3.1 Opérations et participation au marché

Les micro-réseaux pouvant être couplé à un réseau de distribution d'électricité, il ont donc la possibilité d'échanger de l'énergie avec certains acteurs. Il existe deux possibilités : l'achat d'électricité au détail en passant par la signature d'un contrat avec un fournisseur ou les échanges sur les marchés de gros, cette seconde option engendre des enjeux plus importants dans la gestion du micro-réseau.

Bien que des différences puissent exister dans la conception et la structure de ces marchés,

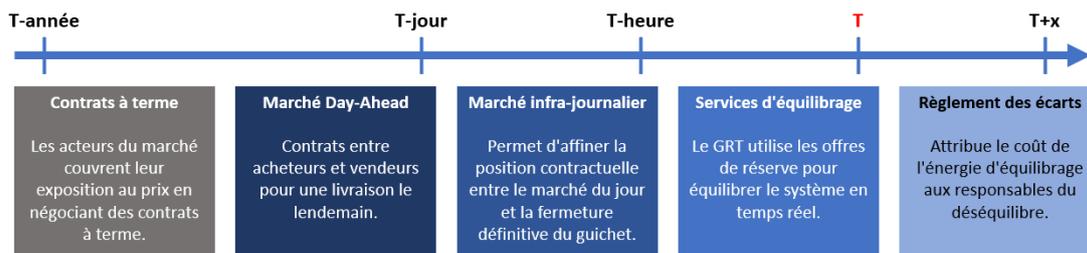


FIGURE 2.3 – Organisation et temporalités du marché de l'électricité en Europe [130]

la plupart des marchés de gros d'électricité adoptent un système avec différentes temporalités (résumées figure 2.3), composé d'un marché « spot » à la journée (day-ahead) et infra-journalier (intraday) ainsi que d'un marché à terme. Les deux premiers marchés mentionnés sont indépendants, on prend des engagements en premier lieu sur le marché day-ahead, la veille d'une journée d'exploitation du système et on peut éventuellement en prendre de nouveaux durant cette journée pour rectifier ou modifier sa stratégie grâce au marché infra-journalier. Le marché spot est financièrement contraignant, on doit ainsi respecter des engagements d'achat ou de vente à différents horizons temporels, et les écarts éventuels seront pénalisés [130]. Il est donc très important de baser ses engagements sur des prévisions fiables mais surtout de les anticiper dans la gestion des entités du micro-réseau.

Suivant cette conception du marché spot, des modèles spécifiques d'optimisation ont été développés afin d'adopter une gestion optimale des entités et des ressources pour planifier les unités de production en minimisant les coûts totaux d'opération :

- Modèles d'**engagement des unités**, ou **Unit Commitment (UC)** : ils permettent d'établir l'allumage et la puissance fournie par les unités de production pilotables dont les dynamiques et le modèle de coût nécessitent d'anticiper leur fonctionnement plusieurs heures en amont (les groupes thermiques notamment). Ces modèles sont exécutés à la fois la veille d'une journée d'exploitation mais aussi pendant.
- Modèles de **répartition économique**, ou **Economical Dispatch (ED)** : ils déterminent comment répartir la charge électrique entre les différentes unités de production disponibles (dont l'allumage est fonction des résultats du UC) de manière à minimiser les coûts de production tout en satisfaisant les engagements. Contrairement au modèle UC, le **dispatch** économique est généralement recalculé toutes les quelques minutes pour s'adapter aux changements en temps réel de la demande et des conditions de production.

Typiquement, les deux modèles sont formulés comme des modèles d'optimisation prenant en compte diverses contraintes, telles que les capacités de chaque unité ainsi que les exigences de stabilité du réseau [109].

Actuellement, la plupart des opérateurs exécutent uniquement des modèles UC et ED déterministes. Les aléas de charge et d'énergie renouvelable sont traditionnellement couverts par des différents systèmes de réserves, de gestion de fréquence et tension. Cependant, une grande variété de méthodes probabilistes est proposée dans la littérature pour répondre aux défis de la prise en compte d'incertitude dans ces modèles. La prévision probabiliste s'intègre naturellement dans ce cadre puisque les incertitudes peuvent être représentées sous diverses formes et utilisées pour l'application adaptée. Ainsi Zachar et al. ont développé un modèle probabiliste combinant Unit Commitment et Economic Dispatch permettant de gérer les engagements sur le marché de façon optimale en utilisant des contraintes probabilistes [131].

De plus, les méthodes d'optimisation permettent de modéliser les comportements des autres acteurs et ainsi estimer les meilleurs choix d'engagements à faire sur les marchés. Cette approche est utilisée par Shi et al. en utilisant des ensembles de scénarios pour déterminer les offres optimales à faire sur le marché spot [132]. Zhang et al. utilisent une approche robuste, envisageant

les pires scénarios de production PV, pour les échanges d'énergie entre micro-réseaux connectés [133].

Même les micro-réseaux îlotés ou ne participant pas au marché de gros utilisent cette approche pour le problème de gestion de l'énergie, ce qui permet d'optimiser le coût de fonctionnement des unités pilotables [134].

2.3.2 Services systèmes

Bien que la commodité principale échangée sur les marchés de gros soit l'énergie électrique, divers services systèmes ont aussi leur rôle et leur propre marché. Ces services, qui varient selon les places de marchés en termes de types et de fonctions, ont principalement pour objectif de :

- garantir une fourniture d'énergie fiable et de qualité,
- assurer la sécurité du réseau,
- maintenir la fréquence et la tension,
- minimiser les écarts sur les zones d'équilibre.

Le service système le plus important est celui des réserves. Ces dernières sont utilisées pour maintenir à la fois la stabilité de la fréquence du système, un indicateur de l'équilibre de la puissance réelle [135], mais aussi de la tension en divers endroits du réseau [136]. Ces réserves sont fournies et constituées par des moyens de production capables d'ajuster leurs puissances en cas de besoin (chute de fréquence ou modulation de tension). Dans le cas des réserves constituées pour la fréquence, il existe plusieurs temporalités possible pour s'engager : les réserves primaire, secondaire et tertiaire (par temps de réponse croissant, voir figure 2.4 ci-dessous).

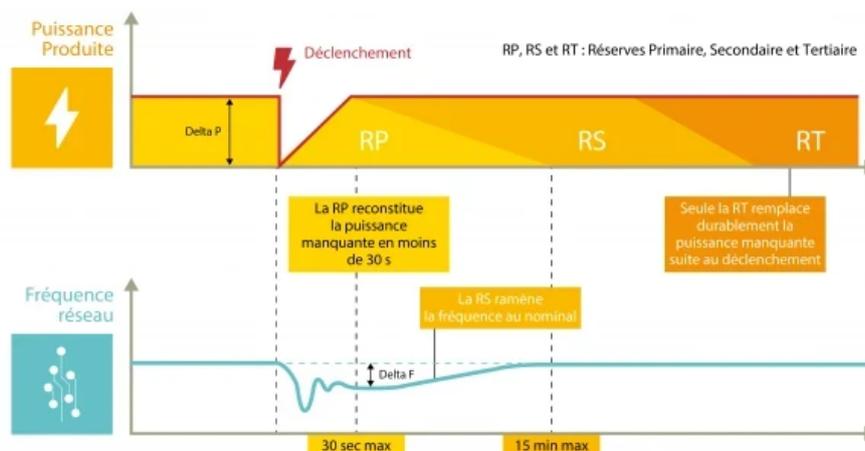


FIGURE 2.4 – Effet des différents types de réserves sur l'équilibrage du réseau [137]

Ainsi, le fait de participer au marché de réserve est un engagement et nécessite une disponibilité des groupes éligibles et retenus par le marché si le besoin se fait sentir. Il est donc primordial de prendre en compte cela dans la gestion du micro-réseau [138]. Comme pour les cas précédents, la prise en compte des incertitudes en présence d'aléas dans le micro-réseau est importante, Wang et al. ont ainsi développé une méthode hybride, robuste et stochastique, permettant de réduire le risque pour l'engagement de micro-réseaux sur le marché des services systèmes [139]. L'ajout d'une demande de réserve opérationnelle présente un défi pour les opérateurs de réseau, Wen montre l'importance de l'utilisation d'une approche stochastique pour les choix d'opération des moyens de production à faire entre la fourniture de la charge et de la réserve [140].

Les opérateurs des micro-réseaux îlotés ou ne participant pas au marché de la réserve mettent aussi en place des modèles probabilistes permettant de dimensionner des réserves. Cela permet, à l'instar du réseau principal, d'améliorer la fiabilité du système face aux aléas. Ainsi, en modélisant

la distribution de la charge résiduelle, la charge à laquelle on soustrait les sources d'énergies non pilotables, on peut dimensionner les besoins de réserve. Si ils sont habituellement calculés avec des modèles déterministes ou heuristiques, Yan et al. montrent l'importance de l'approche probabiliste dans le processus, permettant ainsi de baisser le coût de la réserve [141].

2.3.3 Stabilité, sécurité et fiabilité d'opération

Nous avons jusqu'à présent discuté du problème de gestion d'énergie, permettant d'anticiper l'équilibre de puissance active au sein du micro-réseau. Or, il est très important d'évoquer le contrôle de ce dernier à une échelle temporelle plus fine, où d'autres équilibres rentrent en compte. En effet pour opérer un micro-réseau en toute fiabilité il faut également s'assurer des équilibres de fréquence et de tension, variables d'état critiques : une **contingence** sur le réseau ne doit pas provoquer de congestion de ligne ou de violation des limites de tension [142].

Pour palier à ces éventualités non souhaitées, il est courant d'effectuer des études de flux de puissance (Power-Flow), afin d'étudier les problèmes et les solutions correctives à mettre en place [143]. De nombreux auteurs montrent que l'utilisation d'une modélisation probabiliste est cruciale pour ce type d'étude : Giraldo et al. utilisent à la fois des scénarios et des ensembles d'incertitudes (intervalles de confiance à partir de la PEM, Point Estimation Method) pour améliorer les résultats de l'analyse de sécurité [144].

Pour la gestion et le contrôle d'un micro-réseau, le problème de flux de puissance optimal (Optimal Power Flow) peut être intégré dans différents modèles. Dans leurs travaux, Yugeswar et al. optimisent le flux de puissance en temps réel en modélisant la corrélation entre charge et PV grâce à un modèle probabiliste [145]. Souza et al. intègrent, quant à eux, un modèle OPF dans le problème de gestion de l'énergie, en anticipation d'une journée, permettant de mieux appréhender l'impact des **contingences** engendrées par les aléas pour un micro-réseau isolé [146]

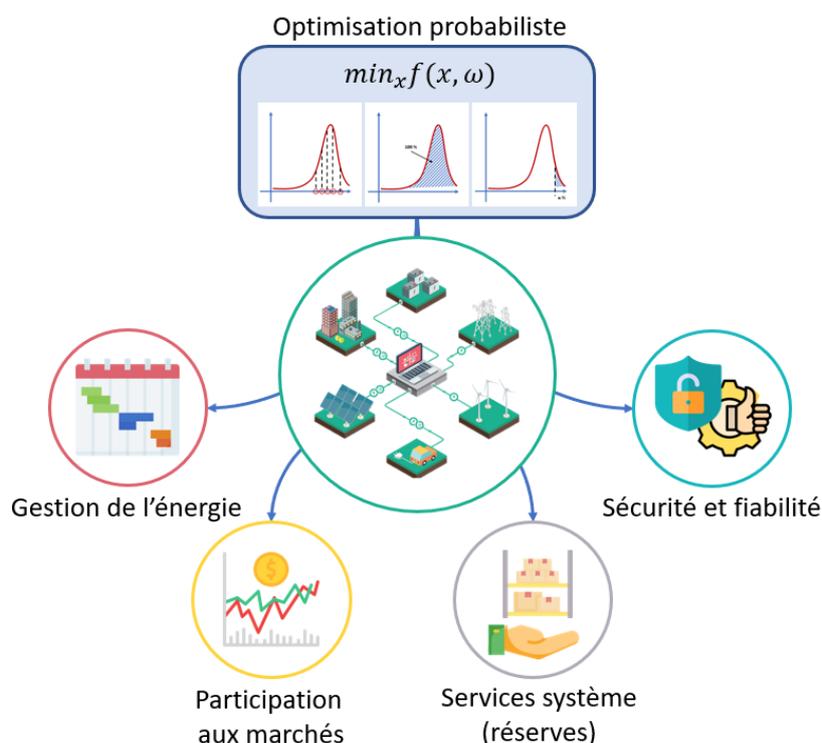


FIGURE 2.5 – Différentes applications de l'optimisation probabiliste pour la gestion et l'opération de micro-réseaux

2.4 Conclusions

Dans ce chapitre, nous avons parcouru une grande quantité de méthodes pour la gestion de micro-réseau sous incertitude. Après avoir discuté des grandes approches de l'optimisation probabiliste et de leurs spécificités nous avons pu évoquer leurs applications pour le secteur considéré (résumés figure 2.5 ci-dessus) et les enjeux de la prise en compte d'incertitude dans celles-ci.

Ainsi tant pour la gestion d'énergie, que pour les engagements sur le marché, la constitution de réserves et la fiabilité d'opération, les différentes méthodes d'optimisation probabiliste montrent leurs atouts, les méthodes stochastique et robuste étant particulièrement populaires. Nous avons également évoqué d'autres approches permettant de traiter les challenges énoncés dans le secteur des micro-réseaux. Le machine-learning, encore sous-étudié selon la littérature [147], fait partie des domaines très actifs et prometteurs, d'autant plus avec la multiplication des données disponibles [148].

L'évolution du système électrique entraîne aussi l'apparition de nouveaux usages comme les réseaux multi-vecteurs ou encore les véhicules électriques, dont la prise en compte des incertitudes n'est pas encore tout à fait mature. Le changement de paradigme amène aussi différentes façon d'opérer les systèmes et donc de modéliser les problèmes d'optimisation usités, Gao et al. pointent ainsi l'apparition de nouveaux objectifs et contraintes, permettant notamment d'analyser les émissions d'un micro-réseau [110]. Ce type d'approche reste encore marginal mais étudié dans la littérature récente.

Notre travail permettra d'explorer la gestion d'énergie d'un micro-réseau sujet à l'aléa d'une centrale PV. En plus du problème de planification, nous étudions la possibilité, grâce à une formulation originale des modèles d'optimisation, d'un service système inovant permettant de réduire l'amplitude journalière.

Deuxième partie

Une représentation de l'incertitude : génération de scénarios de productible PV

Dans cette partie, le but est d'obtenir, à partir d'une prévision, une représentation du productible futur d'une centrale photovoltaïque par génération de scénarios. La génération est un processus qui permet d'obtenir au hasard des réalisations de variables aléatoires tandis qu'un scénario est la notion multivariée d'une réalisation. En considérant le productible PV sur différents intervalles de temps comme variables aléatoires d'étude, le résultat espéré est un ensemble de scénarios représentant les propriétés statistiques de la prévision sur l'horizon considéré. La méthode est ainsi illustrée par la figure 2.6 : à l'instant présent on connaît les réalisations passées, certaines et donc uniques, et à ce moment là on souhaite générer un faisceau de scénarios montrant les trajectoires futures possibles.

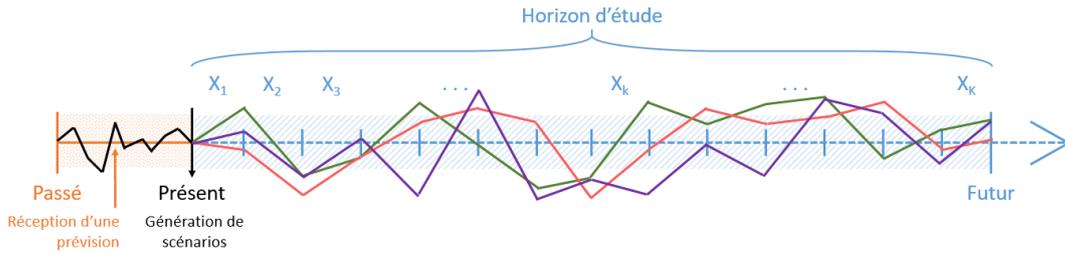


FIGURE 2.6 – Processus de génération de scénarios d'un vecteur aléatoire (X_T de dimension K) sur un horizon temporel : à partir de la prévision on génère des trajectoires (ici en vert, violet et rouge) débutant dès la fin de la réalisation passée (en noir).

Les variables aléatoires étudiées (correspondant chacune à un intervalle de temps, voir figure ci-dessus 2.6) sont donc rassemblées en un vecteur aléatoire, noté X_T :

$$X_T = \underbrace{\left(\overbrace{X_1}^{\text{loi marginale}}, X_2, \dots, X_k, \dots, X_K \right)}_{\text{loi conjointe}} \quad (2.7)$$

Ici, un scénario est donc un vecteur composé d'un échantillon de chaque variable aléatoire d'intérêt. Un scénario, noté S , est donc une réalisation envisagée du vecteur X_T :

$$S = \left(\overbrace{x_1}^{\text{réalisation de la variable } X_1}, x_2, \dots, x_k, \dots, x_K \right) \quad (2.8)$$

Pour permettre de répondre à l'objectif principal et mettre en place une méthodologie de génération de scénarios, un historique de données est disponible. Cet historique est une collection de données enregistrées au fil du temps, il est constitué d'informations sur une multitude d'horizons d'étude sur plusieurs années, et donc sur les variables associées. Dans le cas étudié, il contient de deux types de données :

- Des prévisions probabilistes, envoyées par un fournisseur de prévisions : c'est une prévision qui fournit des informations sur la distribution de probabilités des valeurs possibles d'une variable à un instant futur.
- Les productions réalisées associées, mesurées sur la centrale.

Ces données vont permettre de concevoir notre méthode sur un grand nombre d'itérations pour qu'elle soit statistiquement significative. En outre, cet apport conséquent de données va permettre d'extraire des connaissances supplémentaires sur les variables considérées.

Les travaux seront divisés en trois grandes étapes avec différents objectifs intermédiaires permettant de saisir l'information statistique à disposition :

1. Être en mesure de modéliser les lois de probabilité suivies par chaque variable aléatoire, appelées *lois marginales* (voir équation 2.7).

2. Pouvoir prendre en compte les corrélations entre ces variables aléatoires, car elles ne sont à priori pas indépendantes. Il faudra donc être capable de déterminer une loi de probabilité multivariée, appelée *loi conjointe* (voir équation 2.7), représentant la dépendance entre les différentes variables du vecteur aléatoire. Ce travail permettra de se doter d'un modèle de corrélation indépendant des lois marginales de chaque variable grâce au concept de copule, prenant en compte l'historique des données pour être défini.
3. Finalement, être en mesure de générer un ensemble de scénario par la technique de Monte-Carlo. Cette opération est effectuée à partir des lois marginales déduites des prévisions probabilistes sur l'horizon étudié ainsi que des paramètres caractérisant leur dépendance. La méthode de Monte-Carlo consiste à générer un grand nombre de valeurs aléatoires, puis à utiliser ces dernières pour estimer une valeur, ici le productible PV sur l'horizon.

Maintenant que le processus a été expliqué dans sa globalité et que les principales définitions ont été posées, nous allons détailler les fondements théoriques et la logique de l'enchaînement des étapes de la méthode développée.

Principes de génération de scénarios d'un vecteur aléatoire avec interdépendance

Cette section permet de retracer l'ensemble des procédés formant notre méthode de génération, afin d'appréhender sa cohérence globale et sa généralité. Comme indiqué ci-dessus, on cherche à obtenir des valeurs de réalisations possibles de variables aléatoires, pour cela on effectue un tirage selon leurs lois de probabilité (ou de la connaissance qu'on en a). Avant d'évoquer le cas multivarié, on se contente de décrire le principe de tirage pour une seule variable.

Tirage aléatoire selon une loi de probabilité

La méthode de la transformée inverse permet d'effectuer le tirage d'un échantillon selon la loi de probabilité d'une variable. Cette technique est basée sur une des propositions du théorème de la réciproque (théorème A.1, complet en annexe).

Théorème (de la réciproque - Proposition 3) : *Soit U une variable aléatoire de loi uniforme sur $[0, 1]$. La fonction F est la fonction de répartition de la variable aléatoire $F^{-1}(U)$.*

La démarche pour obtenir un échantillon d'une variable X dont on connaît la fonction de répartition inverse F_X^{-1} est donc divisée en deux étapes :

1. Tirage d'un échantillon de taille N de la variable Y , suivant la loi uniforme sur l'intervalle $[0, 1]$: $Y \sim Unif[0, 1]$. Pour cela, on utilise un algorithme permettant de générer des échantillons pseudos-aléatoires selon cette dernière loi (ici, le Mersenne Twister [149]).
2. Transformation de cet échantillon de la variable Y grâce à la fonction de répartition inverse de X pour obtenir les antécédents formant l'échantillon de taille N de la variable X :

$$(x^1, x^2, \dots, x^n, \dots, x^N) = \left(F_X^{-1}(y^1), F_X^{-1}(y^2), \dots, F_X^{-1}(y^n), \dots, F_X^{-1}(y^N) \right)$$

La méthode, est dite de la transformée inverse car elle utilise l'inverse de la fonction de répartition [150], et est illustrée par la figure 2.7 ci-dessous pour une variable suivant une loi Gamma. Un échantillon réduit ($N = 10$) tiré selon la loi uniforme est présenté sur l'axe des ordonnées à droite (y^n) puis sa transformation par la fonction de répartition inverse (courbe noire) est montrée par les flèches jusqu'à l'obtention de l'échantillon désiré, suivant la loi Gamma, sur l'axe des abscisses (x^n). Cette figure présente aussi une illustration du théorème de la réciproque (A.1) : un échantillon de grande taille tiré selon la loi $Unif[0, 1]$, reproduit la densité de probabilité de la

loi uniforme sur $[0, 1]$ (histogramme à gauche). Une fois transformé via la fonction de répartition inverse de la loi Gamma, l’histogramme de cet échantillon reproduit bien la densité de probabilité de la loi Gamma $\Gamma(9, 0, 5)$.

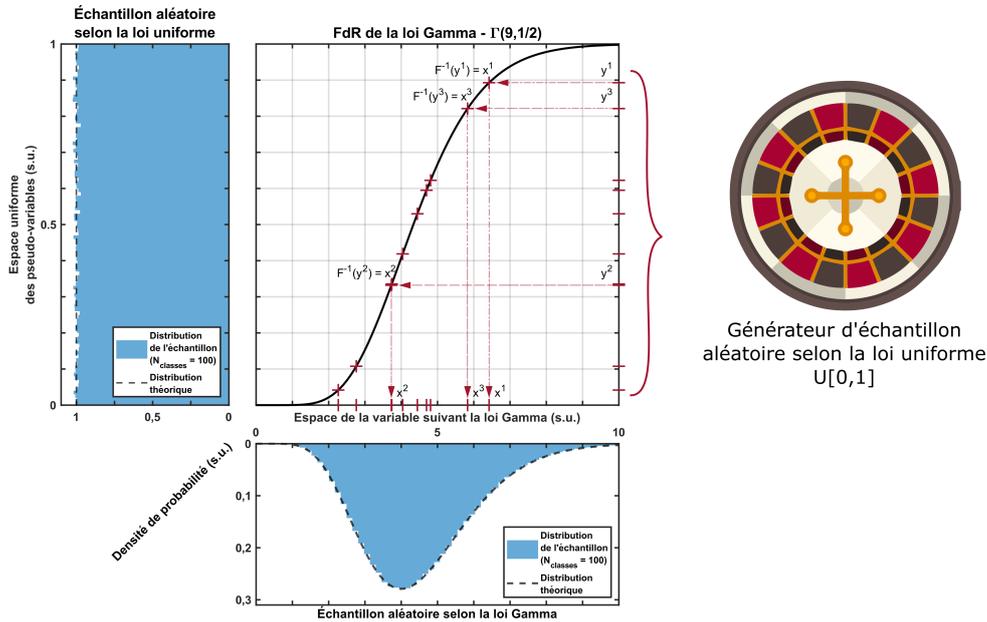


FIGURE 2.7 – Illustration du processus permettant d’obtenir un échantillon aléatoire selon une loi à partir d’un autre tiré selon une loi uniforme

Si l’on répète cette méthode pour chaque variable considérée de notre horizon, on obtient donc des échantillons de toutes les variables aléatoires constituant le vecteur X_T , soit K échantillons indépendants de taille N . En formant des vecteurs avec une valeur de chaque variable issue du tirage, on obtient N échantillons de taille K du vecteur X_T (voir équation 2.9). Cependant, avant de pouvoir effectuer ces tirages aléatoires, il faut donc obtenir, ou du moins décrire le plus précisément possible, ces différentes lois de probabilité suivies par les variables étudiées.

$$\begin{array}{ccc}
 \text{échantillon de } X_1 \{ & (x_1^1, \dots, x_N^1) & \\
 & \vdots & \\
 & (x_1^K, \dots, x_N^K) & \\
 & & \text{échantillon de } X_T
 \end{array}
 \rightarrow
 \begin{array}{ccc}
 \left(\begin{array}{c} x_1^1 \\ \vdots \\ x_1^K \end{array} \right) & \dots & \left(\begin{array}{c} x_N^1 \\ \vdots \\ x_N^K \end{array} \right)
 \end{array}
 \quad (2.9)$$

Estimation de la loi de probabilité ①

La première étape de notre méthode consiste donc à définir les lois de probabilité que suivent les variables étudiées, i.e. la production PV attendue pour chaque intervalle de temps. En réalité, on ne pourra qu’estimer ces lois à partir des connaissances à notre disposition.

Ces lois seront estimées et modélisées par le biais de leur fonction de répartition (voir section 3.1) et plus précisément à partir d’une liste de points de cette fonction : les quantiles. En fonction du type de prévision à disposition, une étape pour obtenir les quantiles pourra être nécessaire.

Changements d’espaces et modèle de corrélation ②-③

Pour l’horizon temporel et la centrale PV étudiée, on considère en première approche une indépendance entre les différentes variables. Or, on sait qu’en réalité il peut exister une corrélation temporelle liée à la météo (mais également spatiale si on s’intéresse à plusieurs centrales voisines).

Il apparaît donc important de se doter d'un modèle de corrélation permettant de prendre en compte cette éventuelle dépendance entre variables.

On dispose donc initialement de K variables indépendantes composant le vecteur X_T , dont les lois *marginales* sont modélisés par leurs fonctions de répartition. La notion de copule (définition 2.1) et le théorème de Sklar (théorème 2.1) permettent de définir une *loi conjointe* dans espace multidimensionnel ($F(X_1, \dots, X_K)$) où la corrélation entre les variables considérées pourra être modélisée, indépendamment des lois *marginales* de X_T .

Définition 2.1 (Copule) Une copule est une fonction de répartition multivariée de dimension K , notée C , définie sur $[0, 1]^K$, dont les *marginales* sont uniformes sur $[0, 1]$.

Théorème 2.1 (Sklar) Si C est une copule, et si F_1, \dots, F_d sont des fonctions de répartition, alors $F(X_1, \dots, X_d) = C(F_1(X_1), \dots, F_d(X_d))$ est une fonction de répartition de dimension d , dont les marges sont précisément F_1, \dots, F_d .

Cependant, avant de pouvoir utiliser ces concepts, certaines transformations sont nécessaires. En utilisant une autre proposition du théorème de la réciproque (théorème A.1, complet en annexe) que pour le tirage aléatoire, on peut obtenir l'image du vecteur X_T par ses fonctions de répartition *marginales*.

Théorème (de la réciproque - Proposition 4) : Soit X une variable aléatoire à valeurs dans \mathbb{R} de fonction de répartition F . Si F est continue, alors $F(X)$ est de loi uniforme sur $[0, 1]$.

Ainsi appliquée à chaque composante du vecteur X_T , cette transformation permet de former le vecteur aléatoire suivant dont chacune des *marginales* suit la loi uniforme $Unif[0, 1]$ (illustré pour une dimension figure 2.8a) :

$$\left(F_1(X_1), F_2(X_2), \dots, F_K(X_K) \right) = \left(\overset{\sim Unif([0,1])}{Y_1}, Y_2, \dots, Y_K \right) = Y_T$$

Cette transformation, associée à la notion de copule, mène donc au théorème de Sklar, présentés ci-dessus. Les lois *marginales* transformées et suivant toutes la même loi uniforme peuvent donc être reliées par une fonction de répartition multivariée : une copule.

Ainsi, la copule du vecteur aléatoire multivarié $X_T = (X_1, X_2, \dots, X_K)$ définit une loi conjointe dont les *marginales* sont (Y_1, Y_2, \dots, Y_K) .

$$C(y_1, y_2, \dots, y_K) = \Pr[Y_1 \leq y_1, Y_2 \leq y_2, \dots, Y_K \leq y_K].$$

Pour résumer, la copule va contenir la structure caractérisant la dépendance entre les variables tandis que les fonctions *marginales* F_k déterminent les informations sur chaque composante X_k du vecteur aléatoire. Chaque composante va donc correspondre à une dimension de la copule, et donc à une variable dans l'espace des *pseudo-variables*, notée Y_k suivant la loi uniforme $U[0, 1]$, ainsi qu'à une variable suivant la loi spécifique de la copule dans un autre espace, appelé *espace de génération*, dénotée Z_k et issue de la transformation par l'inverse de la fonction de répartition multivariée. Cette décomposition est illustrée pour une dimension sur les figures 2.8a et 2.8b : les deux lois *marginales* (de la composante initiale de X_T et sa correspondante via la copule Z_T) sont reliés par leur uniformité suite à leur transformation par leur fonction de répartition.

En utilisant une quantité significative de données de production historique (i.e des réalisations des variables X_k) et leur prévisions associées (i.e. leur fonction de répartition estimée F_k), il est possible de passer dans l'espace des *pseudo-variables* puis dans l'espace de *génération*, illustré par les flèches et points *rouges* sur la figure 2.8c, afin de caractériser les paramètres de la copule reliant ces variables par inférence.

Tirage selon une copule ④-⑤

Le modèle de corrélation, une fois déterminé, permet d'effectuer le tirage d'échantillons (y_1, y_2, \dots, y_K) du vecteur aléatoire Y_T [151], représentant les marges de la copule. En effectuant ensuite les transformations appropriées on obtient alors l'échantillon voulu, un scénario de production PV : (x_1, x_2, \dots, x_K) . Cette étape est illustrée par les flèches et points **verts** sur la figure 2.8c.

$$(x_1, x_2, \dots, x_K) = \left(F_1^{-1}(y_1), F_2^{-1}(y_2), \dots, F_d^{-1}(y_K) \right)$$

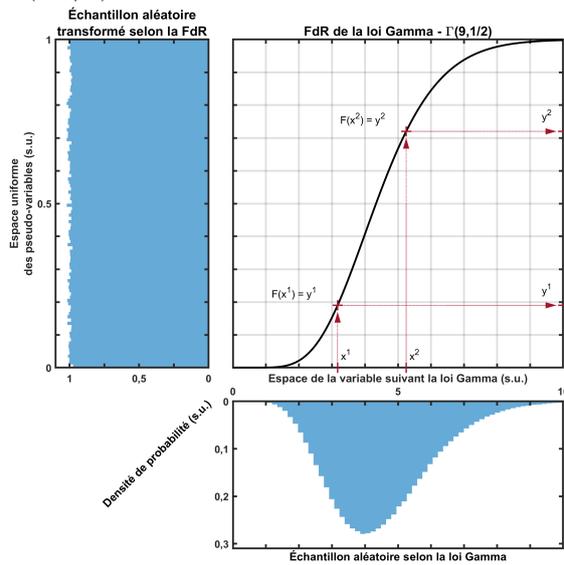
Résumé de la méthode

Les différentes étapes de cette méthode sont résumées pour une dimension dans la figure 2.8c :

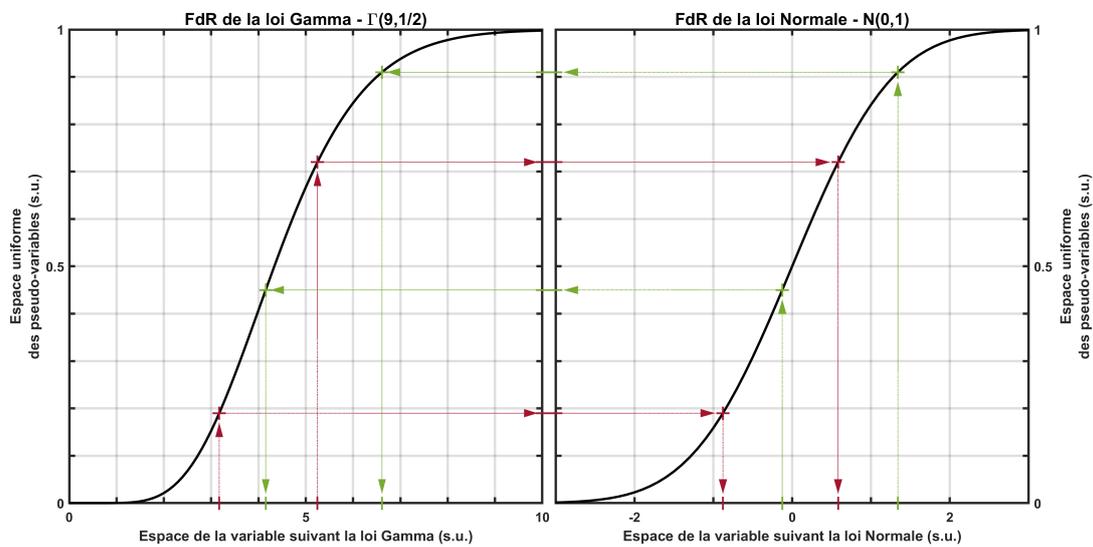
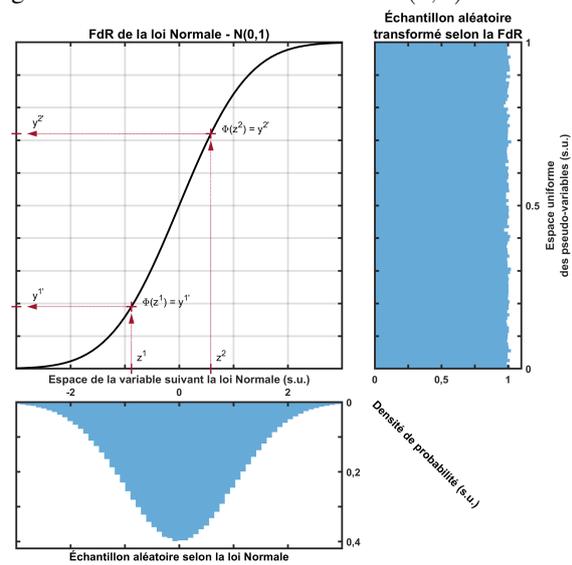
- ① Construction de la fonction de répartition (suivant ici une loi Gamma).
- ② Transformation des données disponibles dans l'espace des pseudos-variables et éventuellement dans l'espace de génération en fonction du type de copule (chemin **rouge**).
- ③ Caractérisation de la copule.
- ④ Tirage d'un échantillon dans l'espace de la copule.
- ⑤ Retour dans la dimension des variables d'étude via l'espace des pseudo-variables (chemin **vert**).

Dans ce chapitre, la question de caractériser l'incertitude des variables étudiées sera abordée, en premier lieu via la notion de fonction de répartition. Cette étape permettra in fine d'effectuer le passage dans l'espace des pseudos-variables et donnera la possibilité de modéliser la dépendance entre variables via une copule.

(a) FdR d'une variable suivant une loi Gamma $\Gamma(9, 1/2)$



(b) FdR marginale correspondante de la copule gaussienne suivant la loi normale $\mathcal{N}(0, 1)$



(c) Illustration de la transformation d'un échantillon suivant une loi Gamma par sa fonction de répartition jusque dans l'espace de génération de la copule gaussienne (rouge) et de l'inverse pour un échantillon tiré selon la loi de la copule (vert)

FIGURE 2.8 – Illustration de la notion de copule à travers les FdR marginales d'une variable et sa correspondance dans la dimension de la copule

3

Caractérisation de l'aléa PV : de la prévision à la loi multivariée

Ce chapitre décrit une méthode développée pour exploiter toute l'information disponible pour caractériser l'incertitude liée à plusieurs variables aléatoires dépendantes à partir de prévisions et d'observations. Cette méthode est générique et peut être appliquée à une grande diversité de variables. Elle est appliquée ici au productible d'une centrale photovoltaïque sur un horizon temporel.

Sommaire

3.1	Construction des lois marginales à partir de prévisions probabilistes	58
3.1.1	Obtention des prévisions probabilistes : la régression quantile et sa mise en oeuvre	60
3.1.2	Estimation de la fonction de répartition empirique	63
3.1.3	Support des fonctions de répartition marginales	64
3.1.4	Construction des lois marginales empiriques	67
3.1.5	Contrôle de l'obtention des pseudo-variables	68
3.2	Caractérisation d'un modèle de corrélation	68
3.2.1	La notion de corrélation	70
3.2.2	Présentation de différentes copules et méthodes de caractérisation	72
3.2.3	Résultats de la caractérisation et comparaison des copules	76
3.3	Conclusions, limites et perspectives	79

Dans ce chapitre, nous verrons comment obtenir les lois **marginales** des variables étudiées à partir de prévisions probabilistes, tout en présentant une méthode permettant d'obtenir ces dernières, la régression quantile (étape ①). Finalement, nous étudierons la dépendance entre les variables considérées pour déterminer leur loi conjointe en utilisant un modèle de corrélation, la copule (étapes ② et ③).

3.1 Construction des lois marginales à partir de prévisions probabilistes

La représentation de l'incertitude d'une variable aléatoire peut prendre différentes formes : intervalles, scénarios, distribution d'erreurs, quantiles, etc. [19], [50]. Cependant la représentation la plus versatile, offrant le plus de possibilités d'exploitation est la fonction de répartition.

L'objectif de cette partie est donc de proposer une méthode générale permettant d'obtenir la fonction de répartition d'une variable réelle continue et bornée, essayant ainsi de caractériser complètement sa loi de probabilité et ainsi son incertitude, à partir d'informations à disposition : une prévision probabiliste.

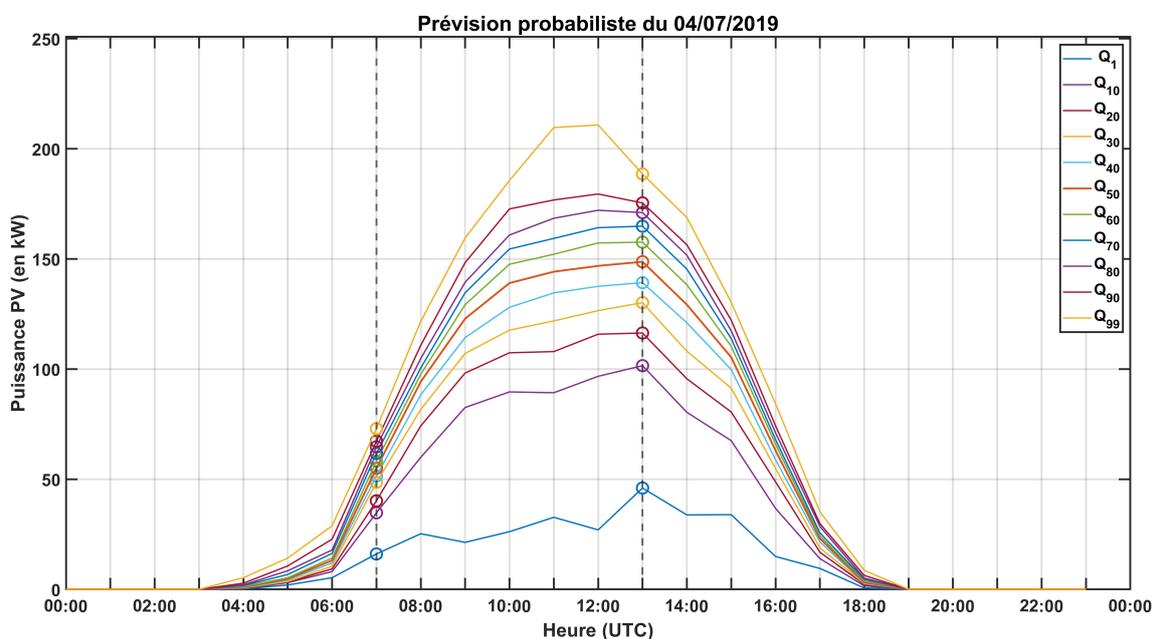
Prévision probabiliste de productible PV

Pour un moment donné la prévision probabiliste est constituée d'une liste de P quantiles (couple quantile, q^τ , et niveau correspondant, τ , dans le cas d'une fonction de répartition continue ils sont reliés par l'égalité $q^\tau = F^{-1}(\tau)$, voir définition A.2) :

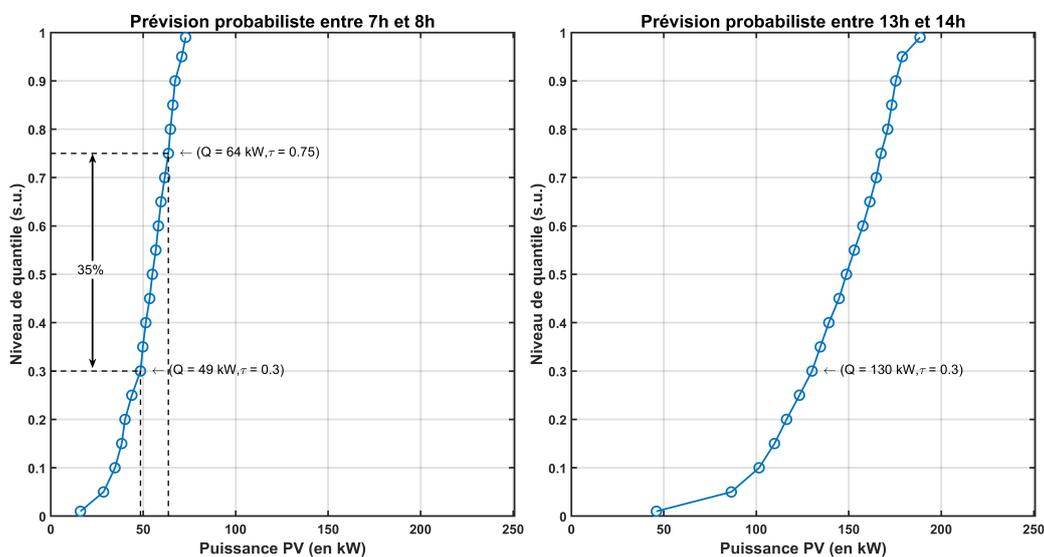
$$\{(q^{\tau_1}, \tau_1), \dots, (q^{\tau_p}, \tau_p), \dots, (q^{\tau_P}, \tau_P)\}$$

Un quantile q^τ et son niveau associé τ permettent de diviser l'ensemble de définition de la variable à laquelle ils se rapportent. Pour un quantile donné q^τ les valeurs ont $(100 \times \tau) \%$ de chances d'être en dessous du quantile q^τ et $(100 \times (1 - \tau)) \%$ chances d'être au-dessus. Un exemple de prévision probabiliste est illustré sur la figure ci-dessous. En premier lieu, on observe la prévision sur l'ensemble d'une journée avec des intervalles horaires sur la figure 3.1a. Sur chaque intervalle la variable correspondante est la puissance moyenne produite par la centrale. Chaque couleur de courbe représente ici un niveau de quantile pour chaque heure de la journée, par exemple la courbe bleue marine décrit le niveau de quantile 1% sur tout l'horizon : le productible PV a donc 1% d'être en dessous de ces valeurs à chaque heure (ou plutôt 99% de chances d'être au-dessus). Deux intervalles de temps de la prévision probabiliste sont représentés en détail sur les figures 3.1b et 3.1c. Sur ces deux figures, les quantiles sont en abscisse et leur niveau associé en ordonnée. Cette représentation permet de mieux appréhender les informations que contient la liste des quantiles et peut être interprété de différentes façons. Des exemples de valeurs de quantiles sont montrés sur ces deux figures : entre 7h et 8h, on a 30% de chances d'être en dessous de 49 kW tandis qu'entre 13h et 14h, on a 30% de chances d'être en dessous de 130 kW. De plus en faisant la différence entre deux quantiles, on peut déterminer la probabilité de la variable d'être dans un intervalle particulier. Pour la figure 3.1b, si l'on soustrait les niveaux de quantiles 30% et 75%, on peut en déduire, que le productible PV a 35% de chances d'être entre 49 et 64 kW. Concernant la figure 3.1c, si l'on effectue la même opération entre les quantiles de niveau 1% et 99%, on peut dire qu'il y a 98% de chances que la puissance PV produite soit comprise entre 46 et 189 kW.

Malgré toutes les informations qu'il est possible d'en tirer, cette liste de quantiles n'est pas exploitable facilement en l'état par une méthode permettant la planification d'un micro-réseau par l'optimisation (voir section 2.2). Cette prévision doit donc être traitée pour prendre une autre forme. La représentation permettant le plus grand nombre de possibilités est la fonction de répartition. C'est en effet, avec la densité de distribution, la façon la plus complète de caractériser



(a) Prévision probabiliste du 04/07/2019



(b) Prévision probabiliste entre 7h et 8h

(c) Prévision probabiliste entre 13h et 14h

FIGURE 3.1 – Exemple d’une prévision probabiliste sur la journée du 04/07/2019 avec intervalles horaires détaillés pour deux exemples

l'aléa d'une variable aléatoire. Cette estimation sera faite numériquement : l'objectif est d'obtenir suffisamment de points pour décrire précisément cette fonction.

Pour cela on souhaite se doter d'une méthodologie générale applicable à toute prévision probabiliste que l'on pourra avoir à traiter dans le cadre de la planification d'un micro-réseau. Si l'on a pas accès à un service offrant des prévisions probabilistes, il est possible se contenter de prévisions plus rudimentaires et obtenir une liste de quantiles par d'autres moyens (voir section 3.1.1).

Propriétés d'une fonction de répartition

Avant même de concevoir une méthode, il convient de poser le cahier des charges que devront respecter les fonctions construites. D'après la propriété A.1, la fonction de répartition F de la variable réelle continue X doit répondre aux critères suivants :

- Être définie sur le même intervalle que la variable X : $\mathcal{D}_F = [\inf(X), \sup(X)] = [X_{min}, X_{max}]$
- Être croissante et donc bijective. Cette dernière propriété est importante aussi bien pour passer dans l'intervalle des pseudos-variables pour ensuite estimer les paramètres du modèle de corrélation que pour revenir de cet espace pour obtenir les échantillons à partir de la copule (voir introduction partie II).
- Être continue.
- Avoir pour limite 0 en sa borne inférieure : $\lim_{x \rightarrow X_{min}} F(x) = 0$
- Avoir pour limite 1 en sa borne supérieure : $\lim_{x \rightarrow X_{max}} F(x) = 1$

3.1.1 Obtention des prévisions probabilistes : la régression quantile et sa mise en oeuvre

Si une prévision probabiliste n'est pas directement disponible (ou trop biaisée) il est tout de même possible, dans certaines conditions, d'en obtenir à partir d'autre types de prévision et de données complémentaires. Pour le cas de la prévision PV, on peut citer deux possibilités :

- Prévision naïve : le productible PV attendu de l'intervalle de temps considéré ($k + K$) sera le même que celui de l'intervalle de temps correspondant de l'horizon précédent : $P_{k+K}^{PV} = P_k^{PV}$.
- Prévision déterministe $P_k^{PV, det}$: aucune incertitude n'est prise en compte, la prévision est ponctuelle tout comme la précédente. Si l'on devait exprimer cette prévision d'un point de vue probabiliste, cela signifierait qu'on considère qu'il y a 100% de chance que le productible PV atteigne exactement la valeur de la prévision.

Même si elles exploitent et présentent de l'information statistique, les deux précédentes prévisions n'en donnent pas sur leur incertitude, du moins pas directement. Il est possible d'en obtenir via des quantiles en effectuant une *régression quantile*.

De façon générale, une régression est une méthode statistique permettant d'expliquer une variable Y , dite d'intérêt, selon d'autres variables ($X_1, \dots, X_v, \dots, X_V$), dites explicatives, qui seraient corrélées. En utilisant cette propriété statistique d'interdépendance, on peut alors en déduire des informations sur la variable d'intérêt. On définit ainsi une fonction de régression définissant un indicateur \mathbb{I} de la loi de Y (espérance, médiane, variance, quantiles, etc.) conditionnellement aux valeurs des autres variables [152] :

$$f(x_1, \dots, x_v, \dots, x_V) = \mathbb{I}(Y | X_v = x_v)$$

La régression quantile va permettre d'obtenir une estimation de différents quantiles de la variable Y à partir de variables explicatives et d'une constante, regroupés en un vecteur $X = (1, X_1, \dots, X_v, \dots, X_V)$. On va ainsi pouvoir obtenir une liste de quantiles de la distribution conditionnelle ($Y|X$) (et leur niveau τ associé) en fonction. L'expression des quantiles dans la régression standard est une forme

linéaire de coefficients $\beta = (\beta_0, \beta_1, \dots, \beta_v, \dots, \beta_V)$, propres à chaque quantile et correspondants aux V variables explicatives et à constante β_0 :

$$q(Y|X) = X'\beta = \beta_0 + \beta_1 X_1 + \dots + \beta_V X_V$$

Pour obtenir une estimation des coefficients $\hat{\beta}$ et donc des quantiles $\hat{q}(Y|X)$, on souhaite résoudre l'équation suivante pour un niveau de quantile τ donné :

$$\hat{\beta}_\tau = \operatorname{argmin}_\beta \mathbb{E} [\rho_\tau(Y - X'\beta)]$$

avec $\rho_\tau(u) = [\tau - \mathbb{1}^1(u \leq 0)]u$, une fonction de perte spécifique à la régression quantile permettant de pénaliser les écarts entre les prévisions du modèle $x'_i\beta$ et les observations y_i . Dans ce cas, cette fonction pénalise lorsque le niveau de quantile τ est élevé et la prévision faible et inversement (niveau de quantile bas et prévisions élevée) [153], [154].

Théoriquement, il est possible d'effectuer une régression quantile pour toutes les valeurs de niveau de quantiles possibles ($\tau \in [0, 1]$). Il y a ainsi une infinité de régressions imaginables pour une distribution conditionnelle donnée, il serait alors possible de décrire complètement la fonction quantile de la variable $Y|X$, qui n'est autre que l'inverse de la fonction de répartition. Il faudrait cependant une grande quantité infinie d'observations pour obtenir des quantiles significatifs. En pratique, on s'attachera donc à effectuer un nombre raisonnable de régressions quantiles pour un certain jeu de données [155].

Pour obtenir des quantiles à partir de données voici les variables explicatives les plus couramment utilisées :

- Historique de mesures
- Données météo (prévision et/ou historique) :
 - Température,
 - Ensoleillement, etc.

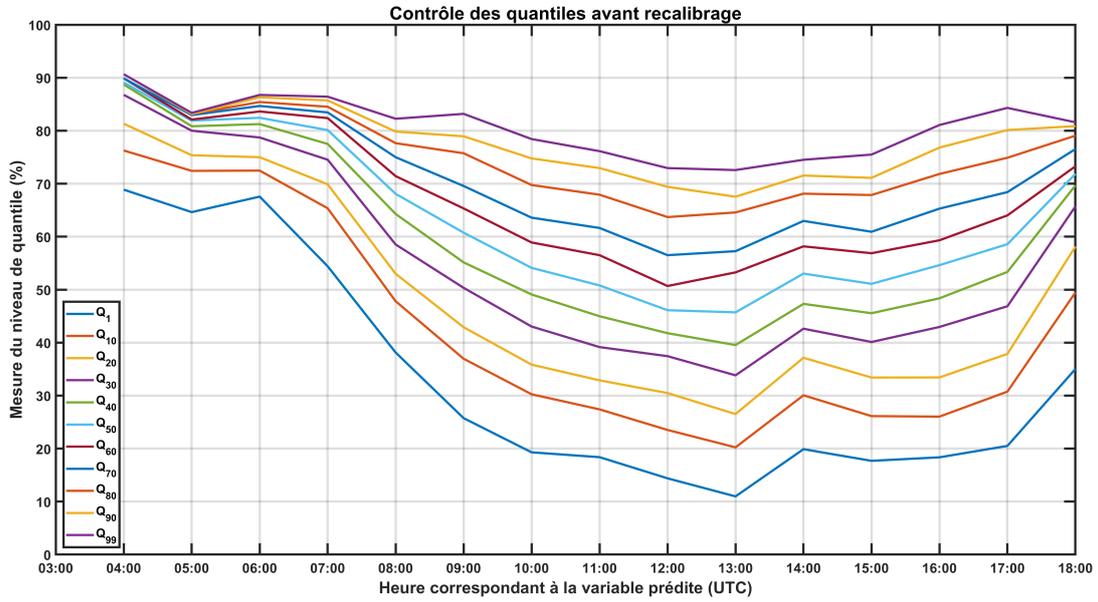
Pour le jeu de données étudié, l'examen des quantiles a révélé leur inexactitude statistique. Comme observé sur la figure 3.2a, si l'on procède à un recomptage des quantiles via les observations, on remarque que les quantiles n'ont pas leur niveau τ escompté. Un recalibrage de quantiles, sous la forme d'une régression quantile, a donc été effectué. Pour ce processus les variables explicatives étaient les suivantes :

- La prévision déterministe horaire,
- Les quantiles 0%, 10%, 50%, 90% et 100% initiaux,
- Un indicateur météo de clarté du ciel.

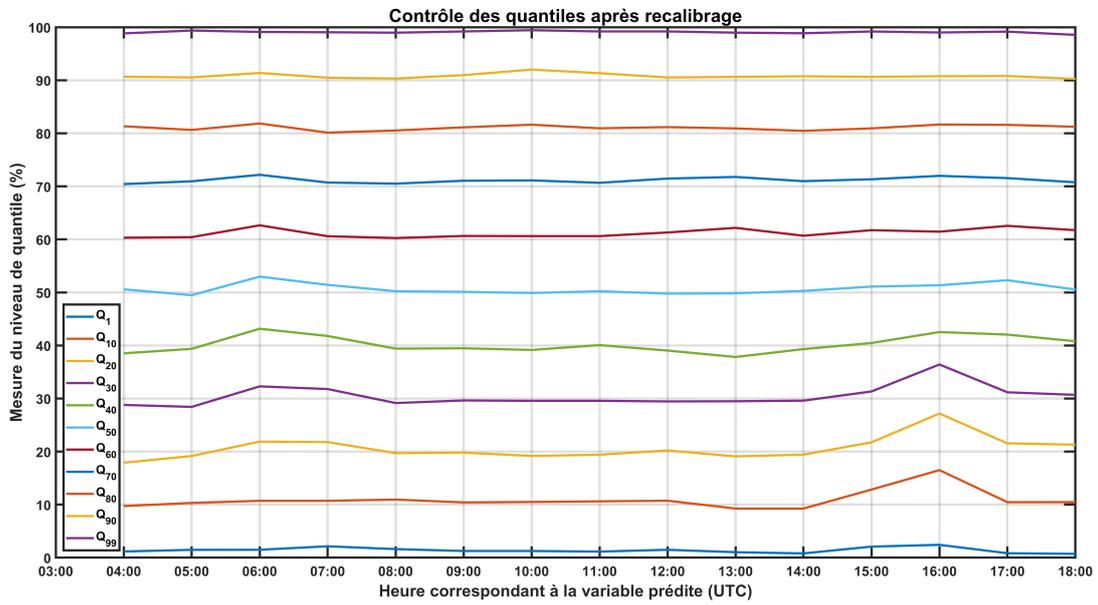
De nouveaux quantiles ont été estimés à partir de la méthode de Liu et Wu [156]. Cette méthode permet d'éviter aux quantiles estimés de se croiser ce qui violerait la propriété de monotonie de la fonction de répartition (voir section 3.1) : un quantile de niveau τ_1 est nécessairement supérieur ou égal au quantile de niveau τ_2 si $\tau_1 > \tau_2$.

À la suite de ce recalibrage un nouveau comptage est effectué. Les niveaux de quantiles observés sont alors bien plus conformes aux attentes (voir figure 3.2b). Seuls quelques quantiles entre 10% et 30% pour la variable #16 semblent légèrement mal calibrés, mais pas assez pour invalider la régression quantile mise en œuvre.

1. On note $\mathbb{1}(\cdot)$ la fonction indicatrice qui vaut 1 ou 0 selon l'état (vrai ou faux) de l'expression logique entre parenthèses



(a) Avant recalibrage



(b) Après recalibrage

FIGURE 3.2 – Contrôle des quantiles par comptage avant et après recalibrage

Méthode de vérification du niveau de quantile

Pour effectuer ce contrôle des différents quantiles, il faut à la fois un historique de mesures (réalisations) et de prévision (quantiles) pour chaque intervalle k de l'horizon étudié. On croise alors les quantiles avec les réalisations de productible PV afin de compter le nombre de mesures inférieures à chaque quantiles et ainsi ré-estimer le niveau de quantile \hat{q}^{τ^p} de façon globale (selon l'équation 3.1), si il est proche de sa valeur attendue q^{τ^p} , on peut se satisfaire de la qualité de chaque quantile.

$$\hat{q}^{\tau^p} = \frac{1}{M} \sum_{m=1}^M \mathbb{1}^2(x_k^m < q^{\tau^p}) \quad (3.1)$$

Cette étape permet de s'assurer de la qualité statistique des quantiles à disposition. Si il n'apparaît pas raisonnable d'approcher la fonction de répartition en multipliant les régressions quantiles car il faudrait une quantité énorme de données, il est néanmoins possible de transformer une liste de quantiles (et leur niveau associé) en une estimation de fonction de répartition pour chaque variable étudiée en répondant aux critères énoncés.

3.1.2 Estimation de la fonction de répartition empirique

Comme indiqué précédemment, la fonction de répartition est une manière de décrire complètement la loi de probabilité suivie par une variable. Y avoir accès permet de choisir entre différentes représentations d'incertitude en fonction de l'approche : à partir de cette dernière il est possible d'obtenir des intervalles de confiance, les modes de la variable (médiane, moyenne, etc.) mais surtout de générer des échantillons (voir introduction partie II).

Afin d'obtenir cette dernière à partir des quantiles, différentes étapes sont nécessaires. L'objectif est d'obtenir une approximation la plus détaillée possible de cette fonction. Dès lors, comme décrit dans l'état de l'art (voir section 1.3.3), deux représentations sont possibles : une *paramétrique*, où l'on cherchera à calibrer un modèle (équation de courbe) grâce à des données et une *non-paramétrique* où aucune hypothèse ne sera adoptée sur la forme de cette distribution. Dans ce second cas il s'agira d'une approximation numérique discrète : à l'instar de la liste de quantiles qui est utilisé comme entrée, le but est d'obtenir une liste de points modélisant cette fonction de répartition. Dans les deux cas la fonction obtenue sera empirique car basée sur des données d'observations et non un raisonnement purement théorique.

Dans notre démarche, on considère en première approche une seule variable aléatoire globale (le productible PV sur intervalle de temps). Sa distribution, approchée grâce à un histogramme de l'ensemble de ses observations est présenté figure 3.3a. Son allure ne permet pas d'ajuster une équation paramétrique d'une loi commune de façon satisfaisante. Dans une seconde approche, les variables étudiées sont regroupés sur un horizon journalier : c'est la même variable de productible PV horaire qui est considérée quelque soir le jour de l'année. L'examen des différentes distributions ne pousse pas non plus pour l'utilisation de fonctions paramétriques. En effet, la figure 3.3b montrant l'histogramme des réalisations observées, ne permet pas non plus d'identifier une loi paramétrique usuelle pour chaque des distributions.

Quand bien même ces distributions pourraient être approchées par une fonction paramétrique, il paraît illusoire de considérer et décrire les variables avec cette granularité temporelle : un seul type de loi de probabilité pour la production PV quelque soit la saison ou la journée. Cela occulterait la réalité de la complexité des phénomènes météo à l'origine du productible PV : l'évolution de leur variabilité a lieu aussi bien au fil de l'année que d'une même journée (couverture nuageuse,

2. On note $\mathbb{1}(\cdot)$ la fonction indicatrice qui vaut 1 ou 0 selon l'état (vrai ou faux) de l'expression logique entre parenthèses

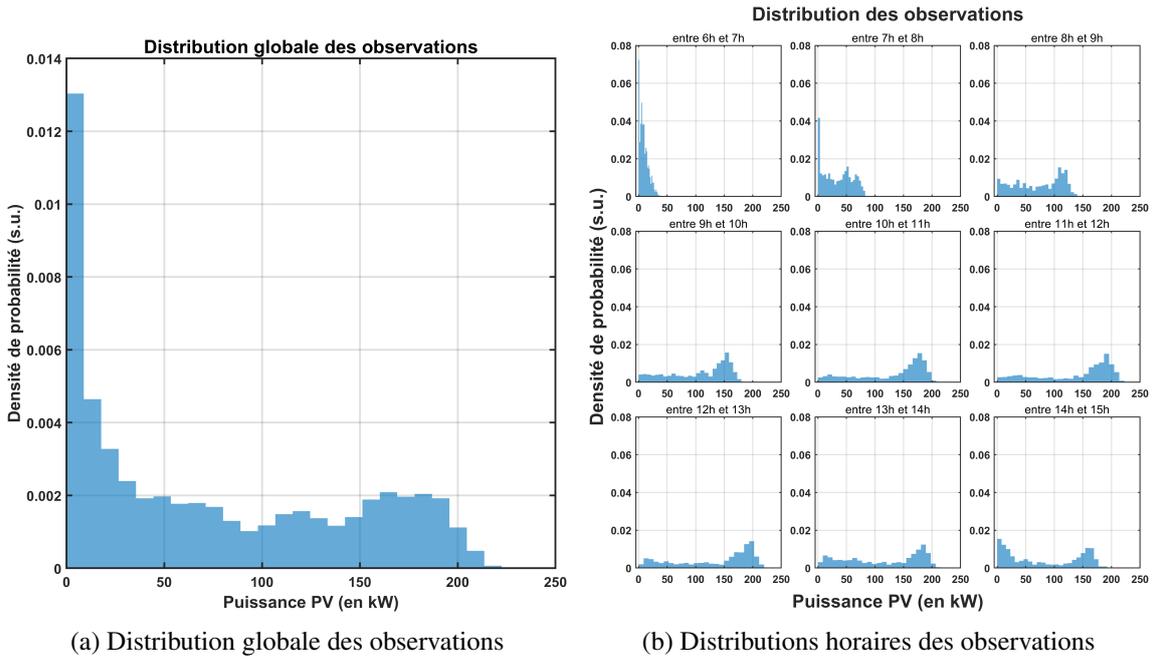


FIGURE 3.3 – Distributions des observations de production PV (normalisées pour obtenir une approximation de la densité de probabilité)³

course du soleil, température de l'air, vitesse du vent).

Opter pour des distributions paramétriques occulte donc la variété des formes possibles des fonctions de distribution et n'exploite pas toute l'information présente à travers les prévisions probabilistes. Nous avons donc choisi de se focaliser sur une approche non-paramétrique permettant d'obtenir une représentation empirique de la fonction de répartition.

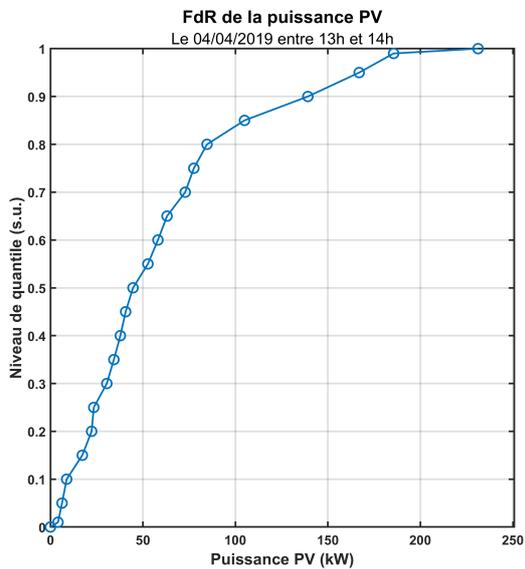
Pour obtenir une représentation de la fonction de répartition on pourrait effectuer, en première approche, une interpolation linéaire entre les points formés par les quantiles (voir figure 3.4a). Cette approximation s'avère peu satisfaisante car elle revient à considérer une juxtaposition de lois uniformes, que l'on peut observer facilement si on s'intéresse à sa densité de probabilité associée estimée par tirage qui en résulte (voir figure 3.4b). De plus certains quantiles peuvent parfois être très proches voire égaux pour un même niveau (voir figure 3.4c). Cela mènerait à des accumulations suspectes de valeurs si l'on tirait des scénarios à partir de cette distribution (voir autour de 30 kW, figure 3.4d). L'interpolation mise en place par la suite a donc vocation à lisser la fonction de répartition empirique recherchée pour limiter l'impact du bruit statistique associé aux données disponibles.

3.1.3 Support des fonctions de répartition marginales

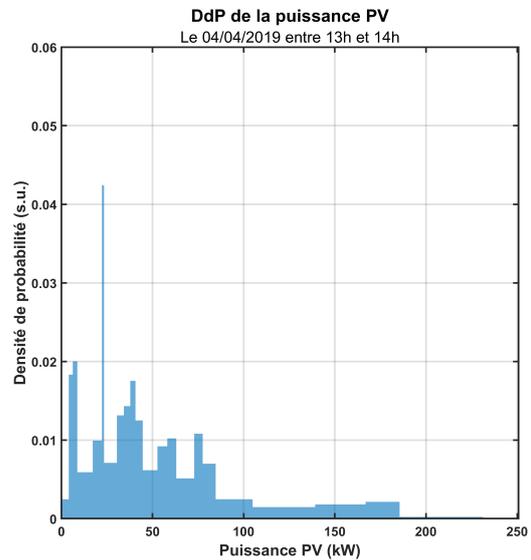
La première étape de la démarche consiste à définir l'ensemble de définition de la variable étudiée et donc du support de la fonction de répartition à approximer. Si une variable aléatoire réelle est bornée alors, d'après la définition du quantile (voir A.2), les bornes inférieure et supérieures de son support vont respectivement correspondre aux quantiles de niveau 0% et 100%. On écrit donc de façon générale pour chaque fonction de répartition :

$$F : [X_{min}, X_{max}] \rightarrow [0, 1] \quad (3.2)$$

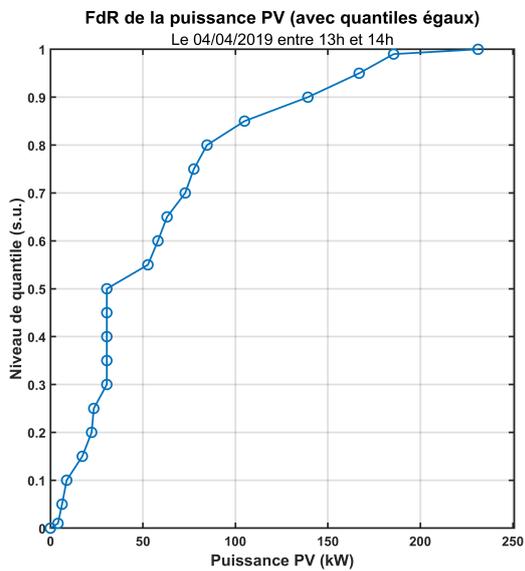
3. soit i , l'indice de classe, c_i l'effectif de classe, w_i la largeur de classe et N l'effectif total, la valeur v_i de classe est donnée par $v_i = \frac{c_i}{N \cdot w_i}$



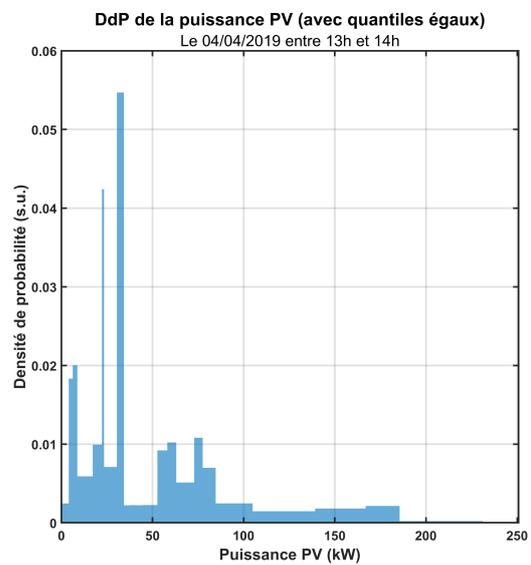
(a) Liste quantiles de la puissance PV



(b) Distribution des valeurs la puissance PV tirée selon la FdR (a)



(c) Liste quantiles de la puissance PV (avec quantiles égaux)



(d) Distribution des valeurs la puissance PV tirée selon la FdR (c)

FIGURE 3.4 – Illustration de l'approximation de fonction de répartition par interpolation linéaire par une liste de quantiles et tirage aléatoire associé)

La liste des quantiles est finie et il est difficile d'estimer les quantiles dont le niveau est voisin de 0% et 100%. La première étape va donc être de déterminer les bornes de la distribution, soit faire une extrapolation, avant d'interpoler la courbe pour la ré-échantillonner.

a) Extremas du support de la distribution : extrapolation

Dans le cas étudié, les quantiles sont fournis la plupart du temps sur l'intervalle [1%, 99%] donc pas sur le support complet de la fonction de répartition. En effet en probabilité, il est par définition (on étudie des variables aléatoires), compliqué d'atteindre un degré de certitude total (0% ou 100%) correspondant aux bornes inférieure ou supérieure de la distribution. Cela signifierai qu'on est certain qu'aucune réalisation de la variable aléatoire ne sera respectivement inférieure ou supérieure. Définir ses bornes revient à faire une hypothèse très forte sur la variable aléatoire étudiée. Le processus d'extrapolation est donc à la fois nécessaire et délicat. Pour l'étude du productible PV, la physique peut nous aider dans cette tâche. En effet la puissance électrique produite par une centrale est bornée de façon assez simple :

- Sa borne inférieure est $P_{PV,min} = 0 \text{ W}$
- Sa borne supérieure peut-être approchée grâce à un historique de données

Maintenant que le support de la fonction de répartition est clairement défini, on va pouvoir s'attacher à interpoler numériquement sa courbe : c'est à dire faire coïncider la fonction à estimer avec une équation de fonction plus simple. Cela permet d'avoir une nouvelle représentation de la fonction de répartition et de l'utiliser pour certaines opérations.

b) Ré-échantillonnage de la variable

L'interpolation permet d'effectuer un ré-échantillonnage de la variable afin d'obtenir un échantillon uniformément réparti sur son ensemble de définition. Pour cela, une interpolation spline est utilisée : la fonction sera considéré comme polynomiale par parties [157], l'objectif étant d'obtenir une courbe lisse et régulière. Ici les points de la prévision probabiliste, les couples quantile et niveau de quantile, sont donc considérés comme des points de la fonction de répartition et on cherche les paramètres des polynômes approchant le mieux chaque segment formé par la liste de quantiles.

Si ce processus est efficace pour obtenir une courbe avec les caractéristiques de continuité et dérivabilité désirées, il ne respecte pas une propriété essentielle de la fonction de répartition : la monotonicité. Une autre méthode a donc été mise en place pour approximer la fonction de répartition, tout en corrigeant les problèmes du processus précédent.

c) Estimation par noyau

L'estimation par noyau est une méthode d'estimation de densité de probabilité. Elle ne permet donc pas d'obtenir directement la fonction de répartition mais il est possible de passer de l'une à l'autre en utilisant le lien entre les deux fonctions (voir définition A.3 et propriété A.1). Avec un échantillon à disposition et en connaissant son support, on va donc chercher l'expression de la fonction de densité de probabilité.

Cette méthode est une généralisation de la méthode d'estimation par histogramme à partir d'un échantillon de taille $N : (x_1, \dots, x_N)$ d'une variable aléatoire X , dont l'écueil principal est qu'elle donne une représentation discontinue de la densité. Cependant, à la place d'utiliser des intervalles et de compter les valeurs qui s'y trouvent, la méthode d'estimation par noyau permet d'assurer la continuité de l'estimation en utilisant une somme de noyaux de densité. La densité de probabilité au point x est ainsi estimée avec les valeurs de l'échantillon la fenêtre choisie et le noyau :

$$\hat{f}_h(x) = \frac{1}{Nh} \sum_{i=1}^N K\left(\frac{x-x_i}{h}\right) \tag{3.3}$$

Plus x sera proche de la valeur de l'échantillon x_i , relativement à la fenêtre h choisie, plus le noyau lui donnera une importance dans l'estimation de la densité. Deux paramètres sont importants dans cette méthode :

- Le noyau K , dans la plupart des cas c'est la densité d'une fonction gaussienne standard qui sert de noyau :

$$K(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2}$$

- La fenêtre h . Ce paramètre est crucial, car il va influencer de façon importante sur la forme de la fonction. Si il est trop grand, la fonction sera trop lissée et des informations perdues, si il est trop petit la fonction sera trop détaillée par rapport un bruit statistique de l'échantillon (voir figure 3.5). Dans notre cas, le choix s'est porté sur la valeur la plus souvent utilisée dans l'état de l'art qui est un multiple de l'écart-type estimé de l'échantillon [158].

Cette méthode est illustrée par la figure 3.5a, où l'on peut voir à l'œuvre le principe de l'estimation par noyau. Dans ce cas, l'échantillon est réduit à six valeurs qui forment autant de noyaux gaussiens, la courbe bleue, somme des noyaux, montre le résultat de l'estimation de la densité de probabilité. Dans notre cas ce sont les interpolations obtenues à l'étape précédentes (voir 3.1.3.b) qui sont utilisées comme échantillon de la densité. On passe ensuite de la densité à la fonction de répartition de façon triviale en intégrant la densité de probabilité sur un intervalle (voir figure 3.6 qui présente les deux fonctions).

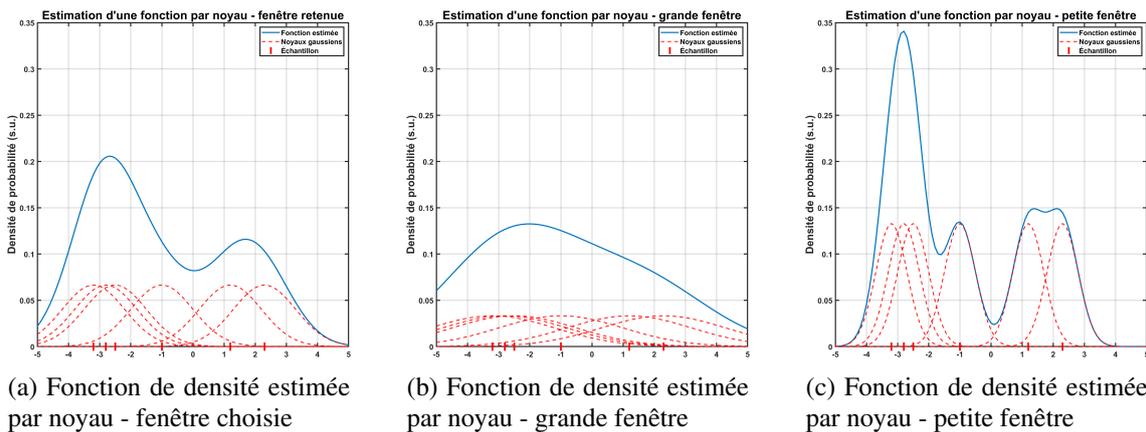


FIGURE 3.5 – Illustration du principe de l'estimation par noyau pour différentes fenêtres sur un échantillon réduit

3.1.4 Construction des lois marginales empiriques

La méthode a été appliquée sur l'ensemble des données à disposition. Ainsi, autant de fonction de répartition ont été estimées que de liste de quantiles disponibles. Certains résultats sont présentés figure 3.6. La figure présente deux graphiques pour chaque prévision : un avec l'estimation de la densité de probabilité (dessus) et un autre avec la fonction de répartition correspondante (dessous). Ce dernier montre la liste de quantile initiale qui sert de première approximation à la loi de probabilité ainsi que la fonction de répartition lissée issue de notre méthode. Le premier quant à lui illustre l'approximation de la densité de probabilité issue de la liste des quantiles ainsi que celle issue de l'estimation par noyau.

Sur les trois première figures, trois intervalles de la même journée sont représentés. La première observation manifeste est que les distributions ont des formes très variées même au sein de la même journée, ces résultats corroborent l'hypothèse d'utiliser une approche non-paramétrique. On retrouve en annexe des figures complémentaire présentant plus de distributions et illustrant la

variété de leurs formes, étayant notre parti pris (voir figure B.2 pour une journée entière et figure B.3 pour le même intervalle horaire considéré lors de différents mois de l'année). Ensuite si l'on observe en détail les densités, on peut facilement se rendre compte que la méthode est efficace pour réduire le bruit induit par la première approximation : les fonctions en orange apparaissent bien plus régulières, on ne remarque pas de pics de densité inopportuns.

La seconde partie de la figure présente différents cas particuliers. En premier lieu (figure 3.6d), on observe le même intervalle de temps que la figure précédente (figure 3.6c), cependant la liste des quantiles initiale a été modifiée pour que certains quantiles soient égaux (du niveau 30% à 50%), ce qui peut arriver lors de l'élaboration des prévisions. On note que cette anomalie ne gêne pas le processus d'estimation de la loi de probabilité de la variable même si le résultat obtenu diffère légèrement du cas avec tous les quantiles distincts. La méthode permet en tout cas de gommer l'anomalie statistique des quantiles égaux qui causerait une accumulation de valeurs lors d'un tirage (voir section 3.1.2). Les graphiques suivants (figure 3.6e) présentent toujours le même intervalle de temps mais cette fois la liste des quantiles disponibles a été réduite de moitié (10 quantiles disponibles au lieu de 21). Cette réduction du nombre de quantiles n'impacte pas non plus beaucoup l'estimation de la loi de probabilité de la variable concernée : les formes des fonctions restent très similaires. Pour finir, un dernier intervalle est présenté, le problème de ce cas se trouve sur les bornes de la fonction de répartition estimée. En effet, si on regarde la réalisation de la variable, on peut voir qu'elle n'est pas dans le domaine de définition de la fonction estimée (voir figure (figure 3.6f)). Cela pose un problème pour obtenir l'image de la mesure par la fonction de répartition. Heureusement ce cas de figure reste marginal dans cette étude (274 cas sur 21 515, 1,3%). Il est normal d'avoir des difficultés pour modéliser les queues de distributions, en effet elles représentent des évènements très rares et donc difficiles à "capturer" statistiquement (voir section 3.1.3.a).

3.1.5 Contrôle de l'obtention des pseudo-variables

Pour examiner la transformation de l'espace de la variable à celui des pseudo-variables, étape essentielle de notre processus (II), une méthode de contrôle a été mise en place. Cette opération utilisant la fonction de répartition, elle est donc aussi vérifiée par extension. Ce contrôle est possible en croisant des historiques de mesures, i.e. de réalisations des variables, et de fonction de répartition des variables correspondantes, obtenues à partir de prévisions.

En obtenant l'image de la réalisation par la fonction de répartition et en utilisant le théorème de la réciproque (voir section II). Selon le théorème, la distribution issue de cette transformation est uniforme. Ainsi si on trace l'histogramme de l'ensemble de ces mesures transformées, on devrait obtenir une distribution uniforme.

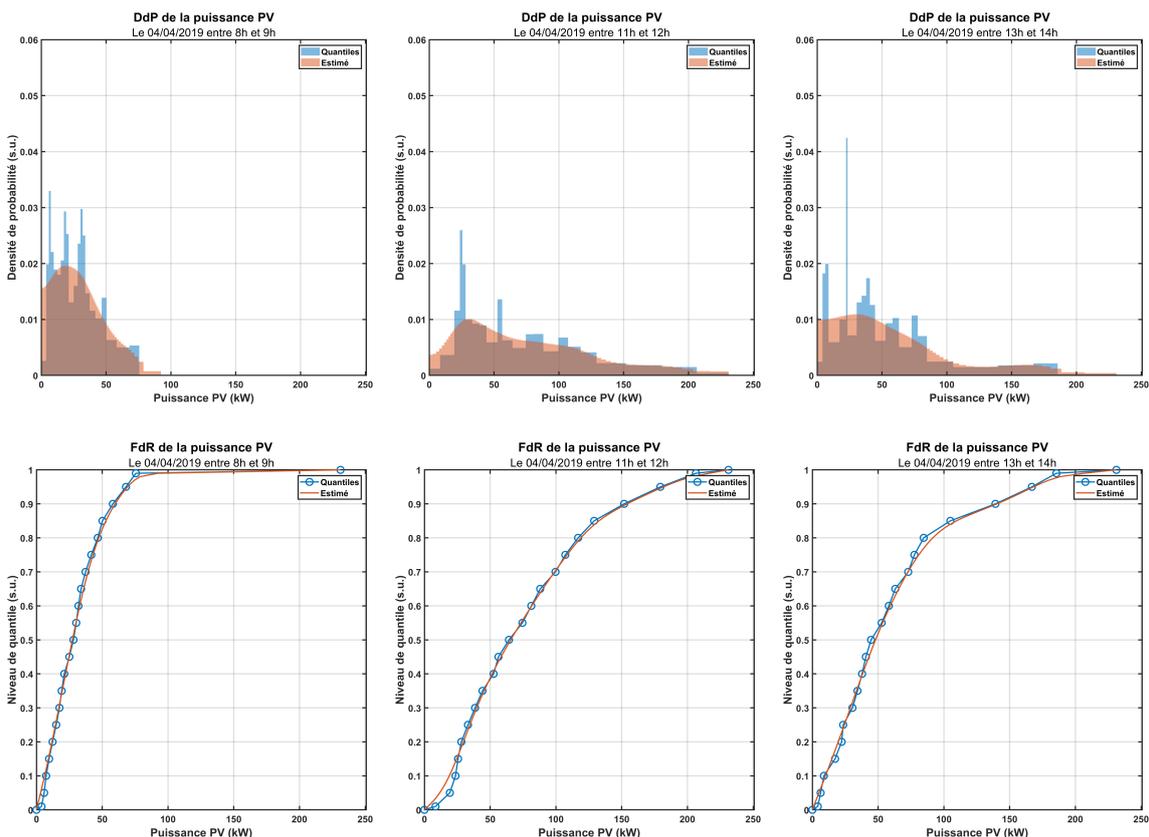
La figure 3.7 nous montre les résultats de cet exercice et illustre que la méthode est satisfaisante : le croisement des données (mesures et prévisions) présente donc bien les propriétés attendues. On peut néanmoins émettre quelques réserves pour la représentation des valeurs dont la probabilité est supérieure à 96% et pour celles inférieures à 2% (les queues de distribution).

Cette première étape étant maîtrisée et validée, elle ouvre la possibilité de la seconde, à savoir la détermination d'un modèle de corrélation.

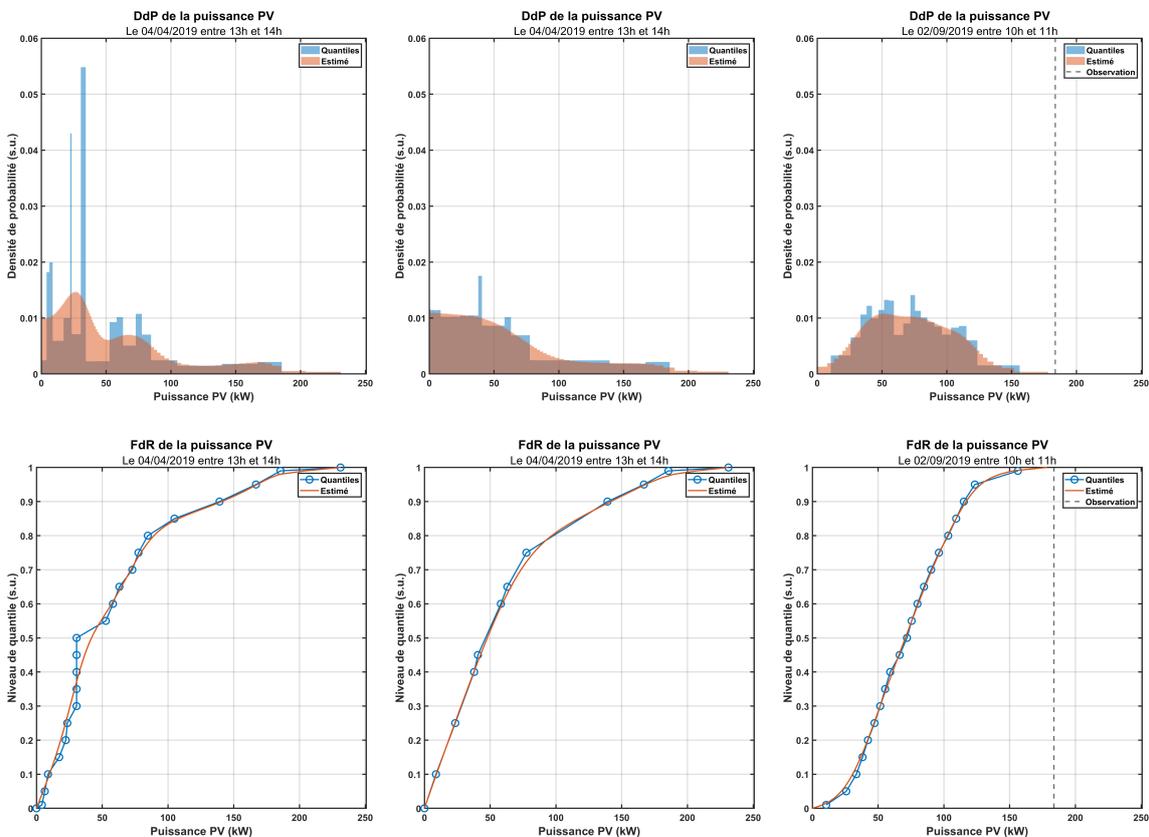
3.2 Caractérisation d'un modèle de corrélation

Jusqu'alors, le productible PV potentiel sur l'horizon étudié a été considéré comme un vecteur de variables indépendantes. Or, dans les faits, la réalisation et l'erreur de prévision de ces variables montrent une corrélation [159]. Cette corrélation observée est intuitivement liée aux conditions météorologiques : entre deux pas de temps rapprochés la météo a des chances d'être similaire, cette section propose d'explorer cette dépendance avec la notion de copule.

Le choix a été fait de calculer un modèle de corrélation sur l'ensemble des données : peu importe le mois ou la saison, le modèle de corrélation est annuel. De plus le modèle de corrélation



(a) 04/04/2019 - entre 8h et 9h (b) 04/04/2019 - entre 11h et 12h (c) 04/04/2019 - entre 13h et 14h



(d) 04/04/2019 - entre 13h et 14h (avec quantiles égaux) (e) 04/04/2019 - entre 13h et 14h (avec quantiles manquants) (f) 02/09/2019 - entre 10h et 11h

FIGURE 3.6 – Exemple d'estimation de lois de probabilité (densité de probabilité et fonction de répartition) pour différents intervalles

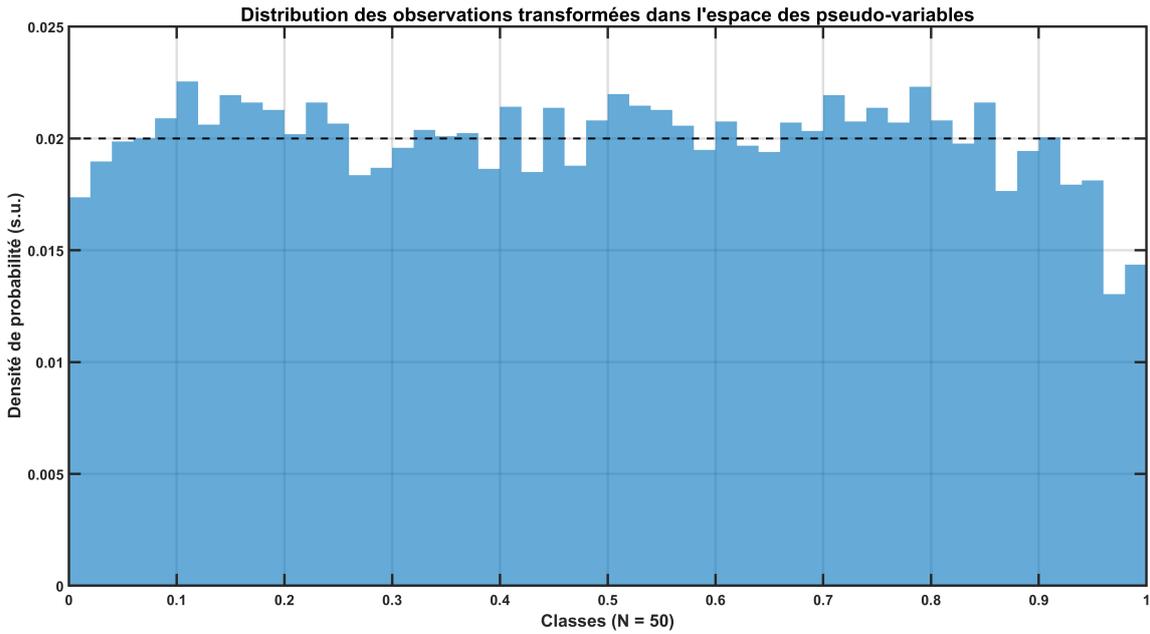


FIGURE 3.7 – Histogramme des mesures transformées sur l'horizon de test

a été calculé de façon horaire sur un horizon de 48h, ce qui est justifié par l'horizon considéré par la planification (ref chapitre 3).

3.2.1 La notion de corrélation

Montrer une corrélation, ou la non-indépendance, entre deux variables X et Y peut se faire de multiples façons. La façon la plus commune est d'étudier le coefficient linéaire de corrélation ρ_{XY} ou ρ , défini comme le rapport de la covariance (voir définition A.4) et du produit de leurs écart-types respectifs :

$$\rho = \frac{Cov(X,Y)}{\sigma_X \sigma_Y} = \frac{E(XY) - E(X)E(Y)}{\sigma_X \sigma_Y} \quad (3.4)$$

Ce coefficient est nombre réel compris entre -1 et 1. Deux variables indépendantes auront une corrélation linéaire nulle ($\rho = 0$) mais la réciproque n'est pas vraie : une corrélation nulle n'entraîne pas forcément l'indépendance. Plus la valeur absolue de ce coefficient s'approche de 1, plus la corrélation linéaire est forte.

Pour le vecteur aléatoire étudié dans ces travaux $(X_1, X_2, \dots, X_k, \dots, X_K)$, on peut introduire la notion de matrice de corrélation, dont les éléments i, j peuvent être exprimés ainsi :

$$\rho_{i,j} = Cor(X_i, X_j) = \frac{Cov(X_i, X_j)}{\sigma_X \sigma_Y}$$

Cette matrice, dont les termes sur la diagonales sont égaux à 1, est carré d'ordre K , symétrique et semi-définie positive⁴ [152].

Estimation de ρ

A partir d'échantillons on peut estimer ce coefficient de corrélation :

$$\hat{\rho} = \frac{\hat{\sigma}_{XY}}{\hat{\sigma}_X \hat{\sigma}_Y} \quad (3.5)$$

4. Se dit d'une matrice réelle symétrique dont la forme bilinéaire associée est positive ou nulle.

avec

$$\hat{\sigma}_{XY} = \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x}) \cdot (y_i - \bar{y})$$

$$\hat{\sigma}_X = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2} \quad \text{et} \quad \hat{\sigma}_Y = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (y_i - \bar{y})^2}$$

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i \quad \text{et} \quad \bar{y} = \frac{1}{N} \sum_{i=1}^N y_i$$

Ce coefficient a été calculé entre deux variables de notre jeu de données : la puissance PV moyenne produite entre 11h et 12h et celle entre 12h et 13h. Le coefficient de corrélation linéaire obtenu valait 0,906, ce qui traduit une forte corrélation entre les deux variables. La figure 3.8, montrant les réalisations de ces deux variables l'une en fonction de l'autre, illustre bien la valeur de ce coefficient de corrélation : le nuage de points formé semble plutôt suivre la forme d'une droite.

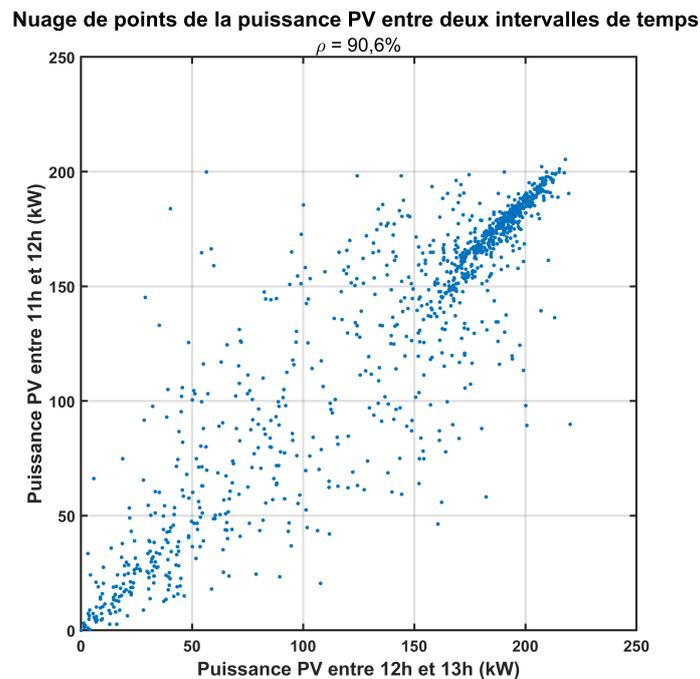


FIGURE 3.8 – Nuage de points des puissances PV entre 11h et 12h et entre 12h et 13h

Cette corrélation entre les mesures de la puissance PV entre 11h et 12h et entre 12h et 13h n'est pas surprenante et explicable : entre deux intervalles horaires la puissance produite par la centrale PV a peu de chance de beaucoup changer, les réalisations seront donc liées. La position du soleil dans sa course a peu varié, si il faisait beau (bon l'ensoleillement), il y a de grandes chances que cela soit aussi le cas pour l'intervalle suivant et inversement avec un mauvais ensoleillement. On remarque plus de dispersions pour les puissances moyennes (entre 50 et 150 kW), lorsque le temps est incertain.

Si cette corrélation peut facilement être interprétée, elle n'est pas exploitable pour notre étude. En effet, on ne connaît pas les lois de probabilité des variables sur ces intervalles annuellement mais seulement individuellement pour chaque horizon journalier (cf. section 3.1.4). La notion de copule va permettre de se donner un cadre pour étudier les corrélations entre les variables considérées tout en considérant leurs fonctions de répartition propres.

3.2.2 Présentation de différentes copules et méthodes de caractérisation

Comme décrit dans la présentation de la méthode section II, c'est grâce à un objet mathématique particulier, la copule, que la corrélation entre variables est ici modélisée. Afin de caractériser ses paramètres, il faut un échantillon significatif de réalisations des marginales de la copule, ce qui va permettre l'inférence statistique.

a) Copule gaussienne

Pour se rendre compte de ce qu'est une copule, l'exemple de la copule gaussienne est présenté ci-dessous figure 3.9. La copule gaussienne a une fonction de répartition dont les marginales U_k sont définies sur $[0,1]$ et suivent la loi uniforme ($Unif[0,1]$) ainsi que la relation suivante pour d dimensions (avec Φ^{-1} l'inverse de la fonction de répartition de la loi normale standard⁵ et Φ_{Σ} l'inverse de la fonction de répartition de la loi normale multivariée $\mathcal{N}(0, \Sigma)$) :

$$C_{\Sigma}(U_1, \dots, U_K) = \Phi_{\Sigma}(\Phi^{-1}(U_1), \dots, \Phi^{-1}(U_K)) \quad (3.6)$$

La fonction de répartition de la copule gaussienne bivariée pour un coefficient de corrélation ρ ($\Sigma = \begin{pmatrix} 1 & \rho \\ \rho & 1 \end{pmatrix}$) est représentée figure 3.9a. On intuite que chaque marginale est bien uniforme sur l'intervalle $[0, 1]$, en repérant la linéarité de la fonction de répartition de $Unif[0, 1]$ sur cette figure. La densité de probabilité correspondante à cette fonction de répartition est montrée figure 3.9b et permet de mieux appréhender la structure de dépendance de ce type de copule. Finalement, le tirage d'un échantillon selon cette copule représente encore mieux la corrélation entre les deux dimension de la copule gaussienne (figure 3.9c).

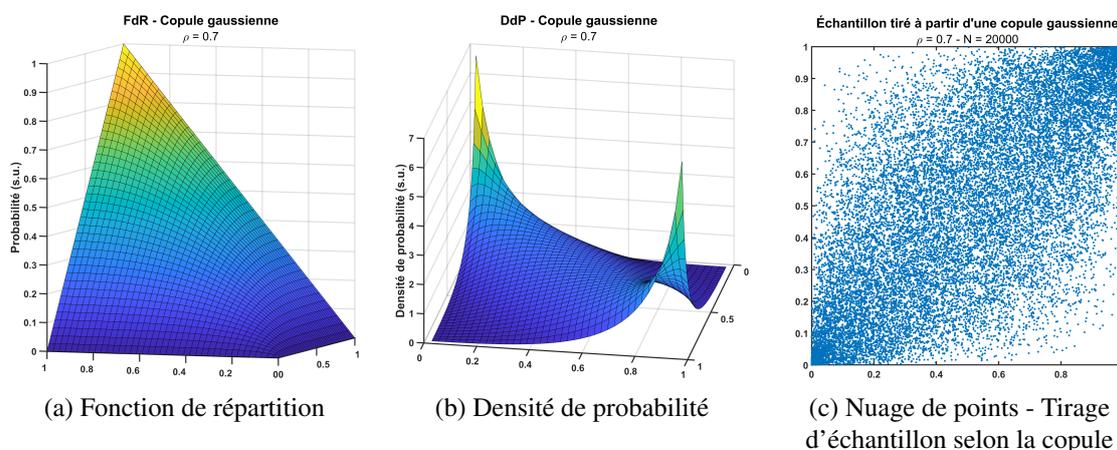
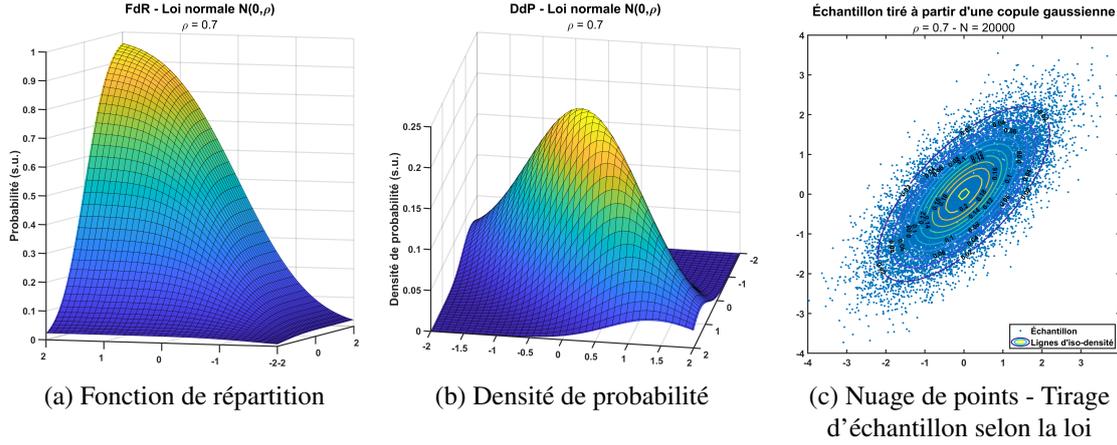


FIGURE 3.9 – Copule gaussienne bivariée de paramètre $\rho = 0,7$

Si l'on se penche de plus près sur l'expression de la copule gaussienne (équation 3.6), on peut remarquer que chaque variable marginale U_k est transformée via la fonction de répartition inverse de la loi normale standard. D'après le théorème de la réciproque (voir section II), la variable $\Phi^{-1}(U_k)$ suit alors la loi normale standard $\mathcal{N}(0, 1)$. Ces dernières sont ensuite transformées de nouveau via la fonction de répartition de la loi gaussienne multivariée $\mathcal{N}(0, \Sigma)$ et repassent dans l'espace uniforme $[0, 1]$ pour chacune des marginales tout en appliquant la corrélation contenue dans Σ et représentée figure 3.10.

Une copule de dimension K peut donc être vue comme une généralisation du théorème de la réciproque en multivarié, permettant de capturer la structure de dépendance d'une loi multivariée donnée dans l'espace uniforme $[0, 1]^K$.

5. Appelée fonction probit : $\Phi^{-1} :]0, 1[\rightarrow \mathbb{R}$


 FIGURE 3.10 – Loi gaussienne bivariée de paramètre $\rho = 0,7$

Pour la copule gaussienne, l'unique paramètre que l'on cherche est donc la matrice de variance-covariance Σ . Cependant, pour estimer les paramètres de cette copule à partir des échantillons des variables considérées (X_T), il va d'abord falloir passer dans l'espace de la copule (Z_T).

Passage dans l'espace de la copule

Grâce à l'estimation de la fonction de répartition des variables et à chaque réalisation correspondante, on est capable de passer dans l'espace des pseudo-variables pour obtenir des échantillons du vecteur aléatoire Y_T (transformation ①, voir équation 3.7 et section II). Chaque dimension du vecteur Y_T correspond alors à une distribution marginale de la copule. On utilise ensuite, selon la copule, la fonction de répartition inverse (pour la gaussienne la fonction Φ^{-1}) pour ainsi obtenir l'échantillon de Z_T désiré dans le bon espace (transformation ②).

$$\begin{pmatrix} x_1^1 & \dots & x_K^1 \\ \vdots & & \vdots \\ x_1^M & \dots & x_K^M \end{pmatrix} \xrightarrow{\textcircled{1}} \begin{pmatrix} y_1^1 & \dots & y_K^1 \\ \vdots & & \vdots \\ y_1^M & \dots & y_K^M \end{pmatrix} \xrightarrow{\textcircled{2}} \begin{pmatrix} z_1^1 & \dots & z_K^1 \\ \vdots & & \vdots \\ z_1^M & \dots & z_K^M \end{pmatrix} \quad (3.7)$$

L'échantillon multi-dimensionnel de Z_N dans l'espace de la copule gaussienne permet alors d'estimer la matrice de variance-covariance. Comme l'écart type des loi marginales est unitaire, cette matrice sera égale à la matrice de corrélation :

$$\forall (i, j), \sigma_i = 1, \sigma_j = 1 \Rightarrow \frac{\text{Cov}(Z_i, Z_j)}{\sigma_i \sigma_j} = \rho \quad (3.8)$$

La méthode pour estimer cette matrice de corrélation a été décrite précédemment (voir 3.2.1).

b) Copule t-Student

La copule t-Student est à l'instar de la copule gaussienne une copule elliptique (les contours de la densité de loi à la quelle elles sont reliées sont elliptiques voir figure 3.10c). Son expression est la suivante :

$$C_{\Sigma, \nu}(U_1, \dots, U_K) = \mathbf{t}_{\Sigma, \nu}(t_{\nu}^{-1}(U_1), \dots, t_{\nu}^{-1}(U_K)) \quad (3.9)$$

avec Σ , la matrice de variance-covariance et ν , le degré de liberté. La densité de probabilité de cette copule ainsi qu'un échantillon sont représentés figure 3.11.

Le paramètre ν peut être estimé par la méthode du maximum de vraisemblance [160], voir paragraphe ci-dessous. La matrice Σ est, elle, estimée comme pour la copule gaussienne une fois

que le paramètre ν est obtenu. En effet, sans $\hat{\nu}$, on ne peut pas utiliser la réciproque t_ν^{-1} de la fonction de répartition pour effectuer la transformation de l'échantillon.

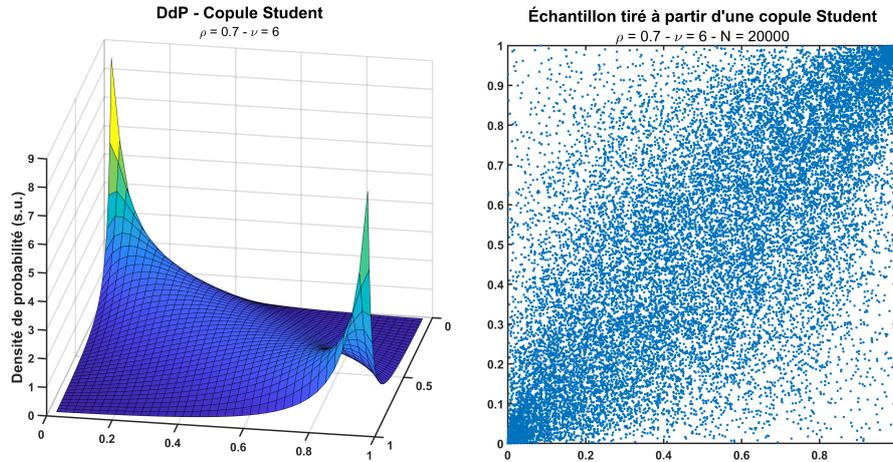


FIGURE 3.11 – Densité de probabilité et échantillon de la copule Student bivariate

Estimation de paramètres par maximum de vraisemblance

Cette technique permet d'estimer un paramètre d'une loi statistique grâce à des observations. Le choix de ce paramètre est fait en maximisant la fonction de vraisemblance, qui décrit la plausibilité (sous la forme d'une probabilité) d'une réalisation du vecteur aléatoire observé étant donné la valeur du paramètre à estimer. La vraisemblance L s'exprime donc en fonction d'une observation x et du paramètre θ et est égale à la densité de X au point x : $L(\theta | x) = f_\theta(x)$. De façon générale on va utiliser un échantillon de plusieurs observations (x_1, \dots, x_n) pour cette estimation, la fonction de vraisemblance globale s'écrit alors comme le produit des vraisemblances de chaque réalisation :

$$L(x_1, \dots, x_n; \theta) = f_\theta(x_1) \times \dots \times f_\theta(x_n) = \prod_{i=1}^n f_\theta(x_i) \quad (3.10)$$

Pour un échantillon donné (x_1, \dots, x_n) , on va donc chercher à maximiser la fonction L pour que les probabilités des observations soient également maximum. Ainsi on prendra comme estimation de θ , la valeur qui maximise la fonction de vraisemblance, voir équation 3.11 [152], [161].

$$\sup_{\theta} L(x_1, \dots, x_n; \theta) = L(x_1, \dots, x_n; \hat{\theta}) \quad (3.11)$$

Cette méthode du maximum de vraisemblance est asymptotiquement sans biais et convergente, mais nécessite donc un échantillon de grande taille pour être valide.

c) Copules Archimédiennes

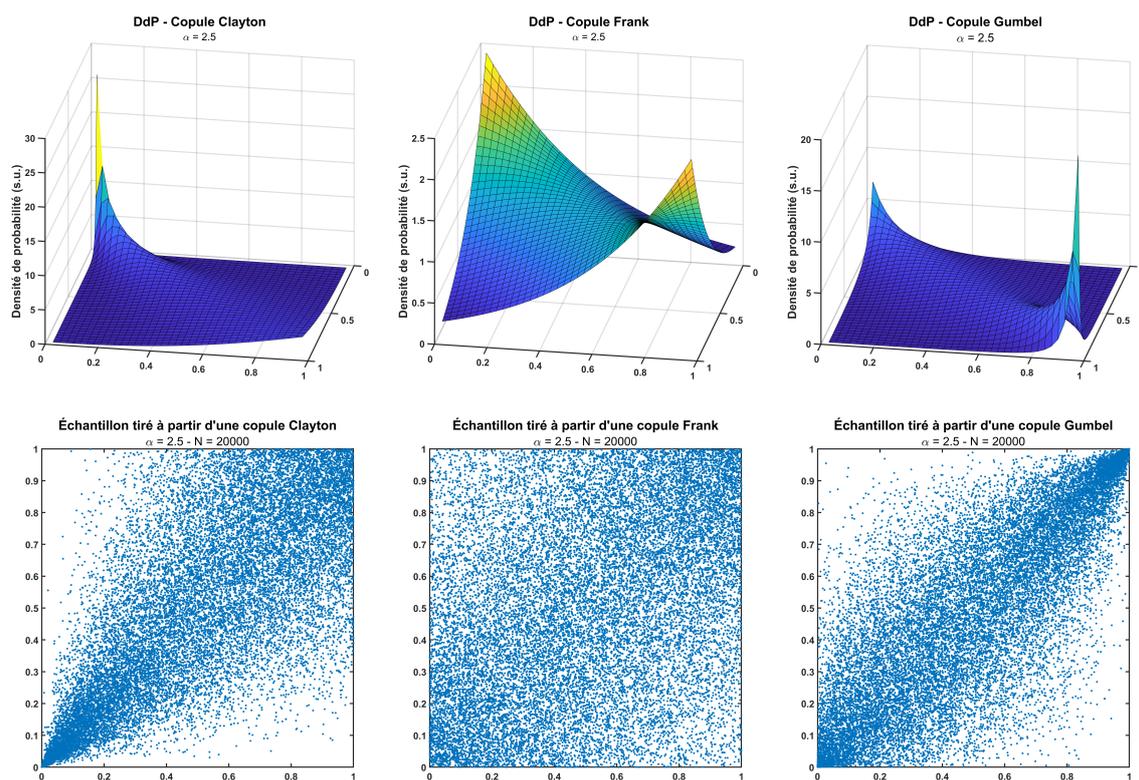
Les copules archimédiennes se différencient des copules gaussiennes par leur expression. En effet ces copules n'ont qu'un seul paramètre permettant de caractériser la dépendance entre les variables, nommé θ . De plus, leur fonction de répartition admet une formulation explicite, exprimée à l'aide d'un générateur, appelé ψ . Leur forme générale se présente selon l'équation 3.12 :

$$C(U_1, \dots, U_K; \theta) = \psi^{[-1]}(\psi(U_1; \theta) + \dots + \psi(U_K; \theta); \theta) \quad (3.12)$$

Seuls 3 types de copules archimédiennes ont été considérées et sont présentées dans le tableau 3.1 ci-dessous.

Type	Paramètre θ	Générateur $\psi_\theta(t)$	Réciproque du générateur $\psi_\theta^{-1}(t)$
Clayton	$\theta \in [-1, +\infty] \setminus \{0\}$	$\frac{1}{\theta}(t^{-\theta} - 1)$	$(1 + \theta t)^{-1/\theta}$
Frank	$\theta \in \mathbb{R} \setminus \{0\}$	$-\log\left(\frac{\exp(-\theta t) - 1}{\exp(-\theta) - 1}\right)$	$-\frac{1}{\theta} \log(1 + \exp(-t)(\exp(-\theta) - 1))$
Gumbel	$\theta \in [1, +\infty]$	$(-\log(t))^\theta$	$\exp(-t^{1/\theta})$

TABLEAU 3.1 – Différents types de copules archimédiennes et leur caractéristiques



(a) Densité de probabilité et échantillon de la copule Clayton bivariée (b) Densité de probabilité et échantillon de la copule Frank bivariée (c) Densité de probabilité et échantillon de la copule Gumbel bivariée

FIGURE 3.12 – Exemple de différentes copules archimédiennes bivariées

Le paramètre à estimer pour chacune de ces copules est aussi obtenu par la maximisation d'une fonction de vraisemblance, (voir paragraphe 3.2.2.b ci-dessus). Leurs densités de probabilité et un échantillon sont représentés figure 3.12 pour un paramètre donné.

3.2.3 Résultats de la caractérisation et comparaison des copules

La paramétrisation des différentes copules est effectuée selon les méthodes décrites ci-dessus et grâce à un échantillon de mesures pour 770 prévisions portant sur un vecteur de 48 variables (horizon de prévision de 48h).

a) Résultats de la caractérisation

Copule gaussienne

Pour la copule gaussienne, la matrice de corrélation obtenue est présentée figure 3.13. Cette matrice montre l'existence d'une assez forte corrélation intra-journalière et particulièrement sur les intervalles voisins entre 9h et 14h où le coefficient de corrélation monte jusqu'à 0,72. La corrélation inter-journalière ne semble pas significative excepté entre les variables du matin (entre 7h et 8h) et du soir (entre 18h et 19h) à 24h d'intervalle où elle monte jusqu'à 0,4. Naturellement les coefficients de corrélation pour les variables concernant les heures de la nuit sont nulles (la puissance PV a 100% de chances d'être nulle pour chaque variable).

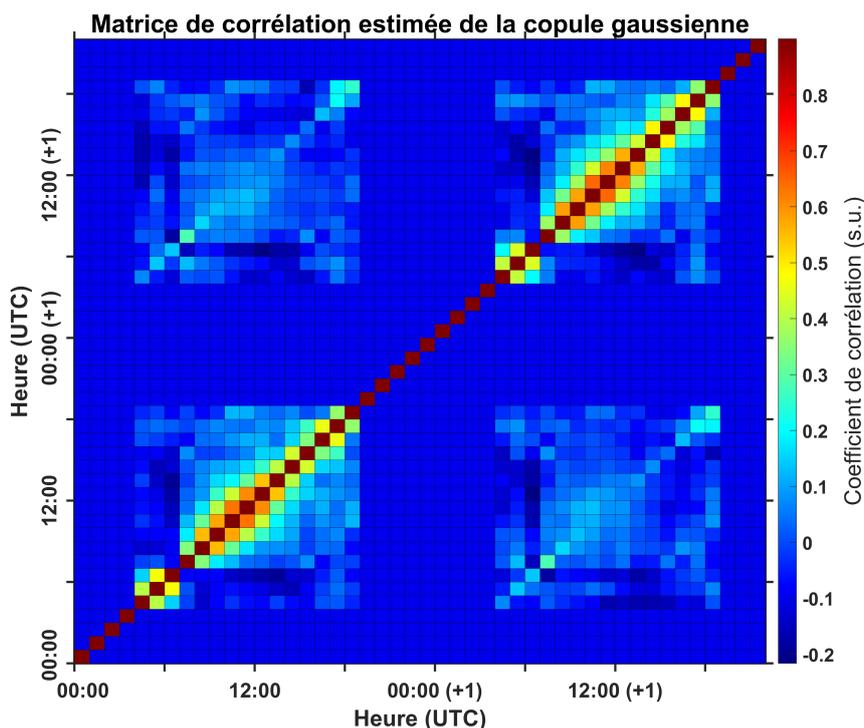


FIGURE 3.13 – Matrice de corrélation de la copule gaussienne

Copule Student

La figure 3.14 montre la matrice de corrélation caractérisant la copule Student. L'autre paramètre de cette copule (ν , les degrés de liberté) a été estimé à 7,33. Les coefficients de la matrice sont très proches de ceux de la copule gaussienne, on y retrouve les mêmes tendances sur les corrélation entre variables. Les coefficients sont cependant globalement légèrement supérieurs : 0,78 au lieu de 0,72 au maximum par exemple.

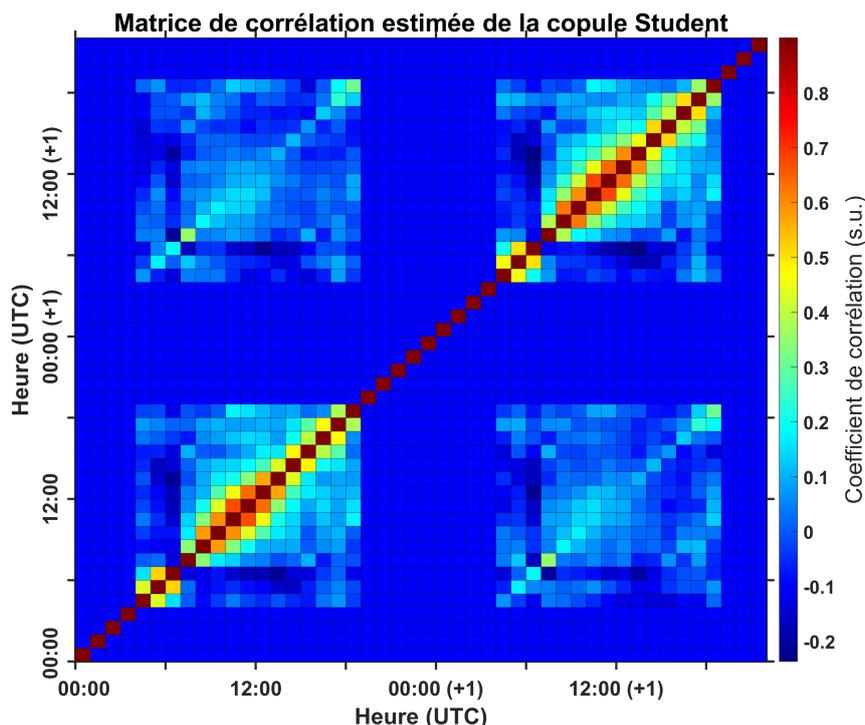


FIGURE 3.14 – Matrice de corrélation de la copule Student

L'estimation des paramètres de ces deux copules montre bien l'existence de corrélations temporelles entre les variables considérées et donc la nécessité de se doter d'un modèle permettant la prise en compte cette dépendance dans l'espace de la copule. De façon générale, l'interprétation de ces matrices estimées est que les probabilités de réalisation du productible PV (i.e. leurs images par leurs fonctions de répartition, vecteur Y_T) sont liées entre deux intervalles de temps et particulièrement entre horaires voisins. D'un point de vue météorologique, on peut interpréter cela par le fait que si une tendance s'installe, par exemple une perturbation nuageuse qui fait que l'image du productible PV attendu par sa fonction de répartition est petite, elle aura des chances de continuer sur l'intervalle d'après. Les images des variables temporelles voisines étant corrélées, le productible sera avec plus de probabilité dans les niveaux de quantiles inférieurs.

Copules archimédiennes

Pour cette famille de copule, les résultats de l'estimation sont renseignés dans le tableau 3.2 ci-dessous. Le paramètre estimé pour ces copules détermine une corrélation assez faible dans chacun des cas. Dans l'espace des copules archimédiennes, les variables étudiées ne montrent pas de structure de dépendance significative. Cela peut être expliqué par la nature même de ses copules : elle n'ont qu'un seul paramètre pouvant modéliser la dépendance entre toutes les variables considérées (30 ici en ne comptant pas les variables concernant la nuit). Le fait d'avoir un paramètre général pour toutes les variables semble gommer la dépendance étudiée, qui semble ici être significative par paires et entre variables voisines.

Copulas	Paramètre θ
Clayton	0,27
Frank	1,34
Gumbel	1,20

TABLEAU 3.2 – Paramètre estimé de chaque copule archimédienne

b) Capacité des copules à reproduire les observations

Une fois leurs paramètres estimés, il faut comparer les différentes copules étudiées. Pour cela on définit 3 différents indicateurs de la qualité des modèles :

- **Log-like** : Cet indicateur découle de la méthode du maximum de vraisemblance, on cherchera à le maximiser.

$$Log - like = \sum \log(L)$$

- **AIC (Aikake Information Criterion)** : ce critère est basé sur l'arbitrage à faire entre le nombre de paramètres du modèle qui pourrait permettre l'augmentation de la vraisemblance et la parcimonie qui stipule qu'il faut décrire les données avec le moins de paramètres possible (éviter le sur-entraînement). On cherchera à minimiser sa valeur le plus possible.

$$AIC = 2k - 2 \ln(L)$$

- **BIC (Bayesian Information Criterion)** : Le BIC pénalise plus fortement le nombre de paramètres que l'AIC et ajoute la taille de l'échantillon comme grandeur. Tout comme l'indicateur précédent, plus sa valeur est faible mieux la copule reproduira les données observées.

$$BIC = -2 \ln(L) + \ln(M)k$$

avec k le nombre de paramètres à estimer, M le nombre d'observations dans l'échantillon et L le maximum de vraisemblance.

Selon les indicateurs définis, les copules elliptiques et en particulier la copule de Student sont les plus à même de modéliser la corrélation entre variables (voir Tableau 3.3 ci-dessous).

Copulas	Log Likelihood	AIC	BIC
Student	3 897	- 7 409	- 6 771
Normal	3 445	- 6 507	- 5 872
Gumbel	973	- 1 944	- 1 940
Clayton	926	- 1 851	- 1 846
Franck	846	- 1 691	- 1 686

TABLEAU 3.3 – Indicateurs de score obtenus pour chaque type de copule paramétrée

Pour résumer cette section sur le modèle de corrélation, nous sommes passés dans trois espaces différents :

- L'espace du vecteur X_T , où on trouve l'information portée par la prévision.
- L'espace du vecteur Y_T dont les éléments sont corrélés et font le lien entre X_T et Z_T .
- L'espace du vecteur Z_T qui porte le modèle et la forme de la corrélation.

3.3 Conclusions, limites et perspectives

Ce chapitre nous a permis de détailler une méthode générique permettant de caractériser l'aléa PV. Ainsi, à partir de données, nous avons pu obtenir une prévision probabiliste permettant par la suite d'estimer les distributions suivies par les variables [marginales](#) étudiées. Par la suite, grâce à la notion de copule, nous avons pu modéliser la dépendance entre ces variables.

Dans notre cas, les variables d'études forment un horizon temporel de 48 heures soit 48 variables aléatoires. Une des limites est que nous considérons que pour tous les horizons temporels d'une année, le modèle de corrélation est le même. Or, si nous avons trouvé des valeurs significatives de dépendance, rien ne garantit qu'il n'existe pas de meilleurs modèles pour la décrire. On pourrait notamment imaginer un modèle qui changerait au fil de l'année voire en fonction du type de météo attendu : ciel dégagé ou temps instable, les dynamiques météorologiques étant très différentes en fonction des journées.

L'approche choisie est de modéliser une corrélation avec des lois paramétriques, il aurait également été possible de déterminer une copule non-paramétrique empirique mais les données disponibles n'étaient pas suffisantes pour obtenir des résultats statistiquement valides. Pour explorer d'autres pistes et améliorer notre modèle de corrélation, il est envisageable d'utiliser les copules de vine, qui permettent de modéliser les corrélations deux à deux des variables mais peuvent aussi relier certaines dépendances elles-mêmes [162]. Cela pourrait être judicieux car on a vu que c'est entre variable voisines que la dépendance était forte.

4

Génération d'un ensemble de réduit de scénarios

*Ce chapitre traite de notre méthode de génération d'un ensemble de scénario ainsi que de la réduction de sa **cardinalité**. Les différents paramètres de la réduction sont discutés et un indicateur permettant de quantifier cette réduction est présenté.*

Sommaire

4.1	Génération de scénarios	82
4.1.1	Méthode de tirage de scénarios	82
4.1.2	Présentation de scénarios générés	83
4.1.3	Vérification des scénarios	83
4.2	Réduction de scénarios	85
4.2.1	Méthode heuristique	86
4.2.2	Méthode de clustering : k-médoïdes	87
4.2.3	Résultats de la réduction	87
4.2.4	Comparaison des méthodes et nombre minimal de scénarios initial	88
4.2.5	Intérêt de la méthode	90
4.2.6	Effet du nombre de scénarios final	90
4.2.7	Exemple d'un ensemble réduit de scénarios	91
4.3	Conclusions, limites et perspectives	93

Les trois précédentes étapes détaillées au chapitre précédent, à savoir le traitement de la prévision probabiliste, les changement d'espaces et la définition d'un modèle de corrélation, permettent désormais de générer des ensembles de scénarios à partir des informations à notre connaissance matérialisées par la loi multivariée suivie par les variables considérées. Nous verrons donc comment générer et vérifier que les scénarios obtenus ont les propriétés attendus (étapes ④ et ⑤). Ensuite nous étudierons deux méthodes de réduction afin de sélectionner la plus appropriée aux ensemble de scénario de production PV puis nous détaillerons l'influence des paramètres de la réduction, comme le nombre de scénario final.

4.1 Génération de scénarios

4.1.1 Méthode de tirage de scénarios

L'objectif est ici d'obtenir des trajectoires pour toutes les variables de l'horizon considéré, i.e. des échantillons du vecteur X_T . Ces derniers devront posséder les propriétés statistiques que nous avons à disposition :

- les *loi marginales* suivies par chacune des variables ;
- la *loi conjointe*, portée par une copule.

Vu les résultats de la section précédente (voir section 3.2.3.b), on se contentera de décrire la méthode et les résultats de tirage pour les copules élliptiques uniquement (gaussienne et Student).

Le principe général du tirage de scénario a été décrit section II : en premier lieu, on souhaite obtenir des échantillons du vecteur Y_T selon la copule considérée, dans l'*espace des pseudos variables*. Dans un second temps, on utilise les fonctions de répartition empiriques pour transformer les échantillons dans l'*espace des variables*.

Dans le cas spécifique de la génération par des copules élliptiques, on devra effectuer l'exact inverse de la transformation qui a été faite pour la caractérisation de la dépendance car les échantillons doivent passer par l'espace de la copule (voir la transformation équation 3.7, section 3.2.2.a). Dorénavant, on va donc s'attacher à générer un échantillon de Z_T , portant la dépendance spécifique de la copule puis le transformer jusque dans l'espace de X_T .

Pour générer un échantillon selon une copule élliptique, les étapes sont les suivantes :

1. Génération d'échantillons du vecteur Y_T^{ind} selon la loi uniforme $Unif \sim [0, 1]$, dont les marginales sont indépendantes.
2. Passage dans l'espace de la copule grâce au théorème de la réciproque et aux fonctions de répartition marginales de la copule pour obtenir Z_T^{ind} .
3. Transformation pour ajouter aux échantillons la dépendance présente dans la matrice Σ , caractérisant la copule, pour obtenir Z_T .
4. Passage dans l'espace des pseudos-variable pour obtenir Y_T .

Les deux premières étapes ayant déjà été traitées plus tôt dans ce manuscrit, on se propose de décrire directement la suivante : la transformation de l'échantillon de Z_T^{ind} pour qu'il prenne en compte la dépendance. Les copules gaussienne et Student partagent le même paramètre définissant la corrélation entre leurs dimensions : la matrice de variance-covariance Σ , c'est à partir d'elle que nous allons injecter la structure de dépendance dans l'échantillon considéré.

Factorisation de Cholesky

La matrice de variance-covariance Σ peut être factorisée grâce à la transformation de Cholesky [163].

Définition 4.1 Soit A une matrice symétrique définie positive, la factorisation de Cholesky consiste à décomposer A en deux matrices (L , une matrice triangulaire inférieure et L^T , sa transposée) et à déterminer L telle que :

$$A = LL^T$$

Plusieurs algorithmes permettent facilement d'obtenir cette décomposition [164].

Échantillon selon la loi de la copule

Une fois la factorisation effectuée, il est possible d'utiliser L pour que chaque échantillon soit transformé selon la dépendance choisie. Les échantillons suivront alors donc la loi multivariée liée à la copule considérée [151], [165].

L'espérance de chaque marginale étant nulle, la transformation pour les variables dans chaque dimension de la copule gaussienne multivariée est la suivante :

$$Z_k = L \cdot Z_k^{ind}$$

Le vecteur Z_T suit alors la loi de gaussienne multivariée $\mathcal{N}(0, \Sigma)$.

Pour le cas de la copule student multivariée, l'espérance est aussi nulle dans chaque dimension, la transformation est donc :

$$Z_k = L \cdot Z_k^{ind} \cdot \sqrt{\frac{v}{U}}$$

avec la variable U suivant une loi du χ_v^2 . Le vecteur Z_T suit alors la loi de Student multivariée $t_{\Sigma, v}$.

Transformations finales de de l'échantillon selon la loi de la copule

L'échantillon de Y_T selon la copule est alors obtenu grâce à la fonction de répartition multivariée de la copule (pour rappel $Y_T = F_C^{-1}(Z_T)$). La finalisation de la génération de scénarios (i.e. d'échantillons de X_T) est faite via la fonction de répartition inverse de chaque variable marginale.

4.1.2 Présentation de scénarios générés

La méthode de génération de scénarios concernant un horizon de prévision nécessite donc une prévision probabiliste ainsi qu'un modèle de corrélation (voir section 3.2.3.a pour les paramètres retenus). La figure 4.1 ci-dessous montre la prévision du 04/01/2019 et la figure 4.2 présente quant à elle un exemple de quatre scénarios tirés aléatoirement selon les informations à notre disposition sur les lois marginales et la loi conjointe du vecteur X_T .

Il est difficile de commenter un tel échantillon de scénario car il ne représentent à eux quatre qu'une infime partie des trajectoires possible pour cette prévision. Il semble que la corrélation entre les variables voisines soit bien prise en compte car nous observons une certaine proximité entre les réalisations voisines (par rapport à leur positionnement dans la liste de quantiles). Cependant il n'est pas possible de l'affirmer avec un échantillon si réduit. Il existe néanmoins des méthodes pour juger de la qualité du tirage effectué, voir section 4.1.3 ci-dessous.

4.1.3 Vérification des scénarios

Maintenant que des exemples de scénarios ont été présentés, il est nécessaire de se poser la question de savoir si ils possèdent les propriétés attendues. Pour cela, nous en avons tiré un très grand nombre pour que l'ensemble soit bien représentatif des phénomènes que l'on souhaite modéliser. C'est le principe de la génération par méthode Monte-Carlo, qui se base sur la loi des grands nombres.

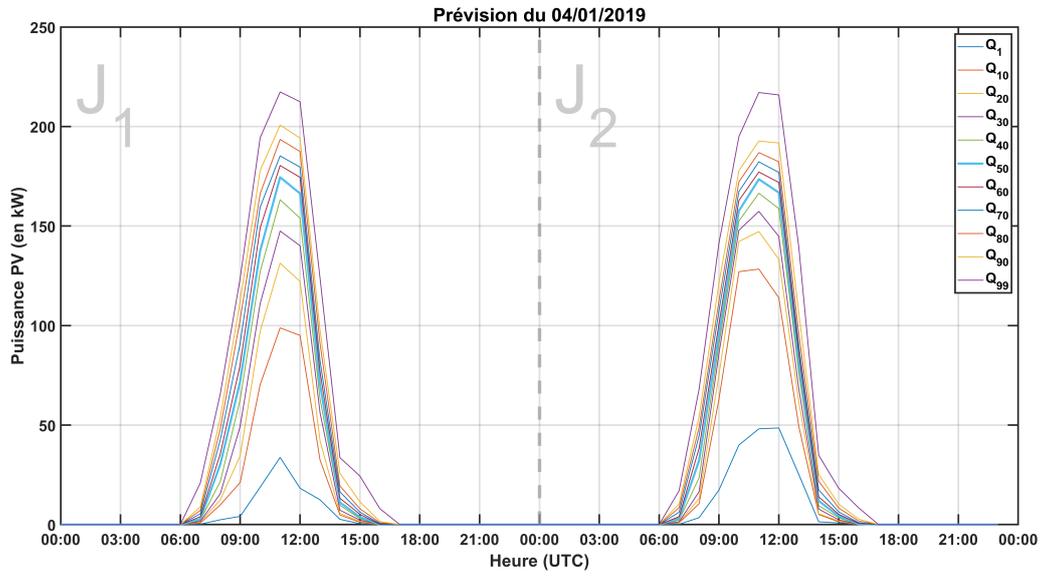
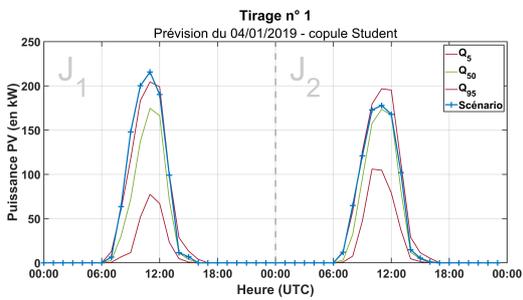
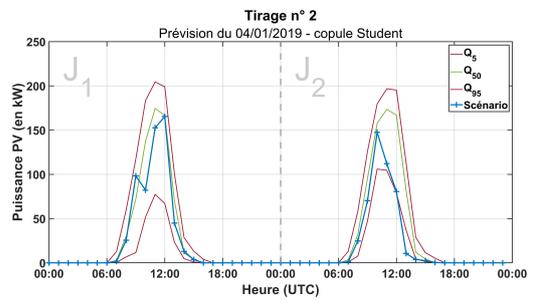


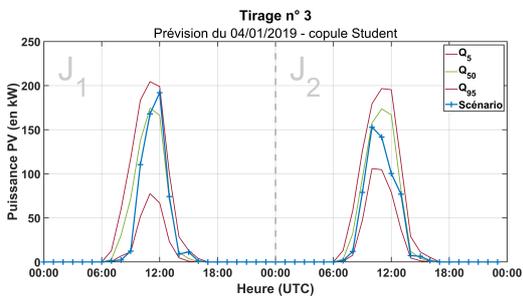
FIGURE 4.1 – Prédiction probabiliste du 04/01/2019 pour



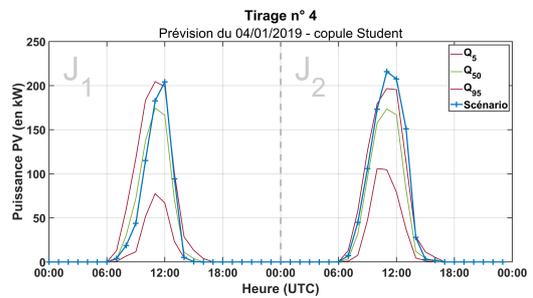
(a) Scénario #1



(b) Scénario #2



(c) Scénario #3



(d) Scénario #4

FIGURE 4.2 – Exemples de scénarios pour la prédiction du 04/01/2019

La figure 4.3 présente la distribution des valeurs d'un million de scénarios en se focalisant sur deux intervalles de temps : la puissance PV entre 10h et 11h et celle entre 11h et 12h (i.e. deux variables voisines temporellement du vecteur aléatoire considéré). Cette figure nous permet d'affirmer que les propriétés statistiques contenues dans la prévision probabiliste et dans le modèle de corrélation sont bien respectées par l'ensemble de scénario généré pour cette prévision donnée.

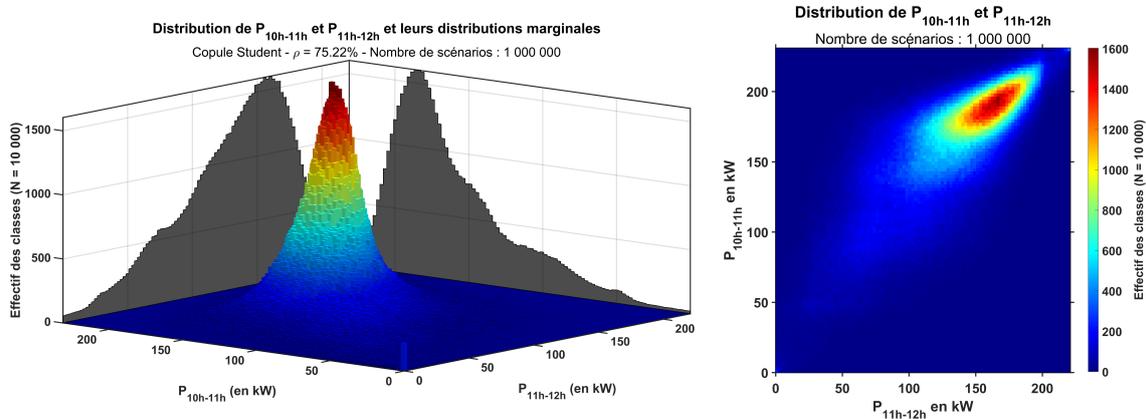


FIGURE 4.3 – Distribution des valeurs de scénarios pour deux intervalles de temps (vue de côté et de dessus)

Premièrement, les distributions des valeurs de chaque variable ont été comptabilisées indépendamment l'une de l'autre et sont représentés sur la figure comme si elles étaient l'ombre de la distribution bivariable, chacune projetée sur un plan. Ces deux distributions coïncident exactement avec les deux loi marginales obtenues à partir des prévisions probabilistes (voir figure 4.4) : notre ensemble de scénario reproduit bien les propriétés des prévisions probabilistes. Finalement, si on s'attarde sur la distribution bivariable, on peut clairement identifier une corrélation entre les réalisations des variables. En effet, si l'on calcule le coefficient de corrélation linéaire entre les deux variables on trouve une dépendance de 75%. Graphiquement la corrélation est assez claire, on trouve une forte densité de valeurs entre 150 et 200 kW pour les deux variables. Ce pic est expliqué non seulement par les deux densités de probabilité maximale qui sont maximales dans cette intervalles mais aussi par le modèle de corrélation qui a été utilisé pour la génération. Si l'on effectue la transformation de ces données jusque dans l'espace des copules (voir section 3.2.2.a), on retrouve bien une valeur de ρ de 0,78 pour la dépendance dans cet espace, ce qui est bien fidèle au modèle employé pour la génération (voir figure 3.14).

4.2 Réduction de scénarios

L'objectif de la réduction de scénarios est d'obtenir un nombre jugé raisonnable de scénarios, plus petit qu'initialement. En effet, ces derniers, une fois générés, sont les paramètres d'entrée d'un modèle d'optimisation pour la planification de micro-réseau (voir partie 6). Or la taille du problème et sa difficulté à résoudre sous-jacente sont directement proportionnelles au nombre de scénarios initial. Il faut donc limiter la **cardinalité** de l'ensemble de scénario que l'on va fournir au processus de planification.

Cependant, pour avoir un échantillon de scénarios représentatif des lois marginales et de la loi conjointe suivies par le vecteur X_T , il est nécessaire de tirer dans un premier temps un grand nombre de scénarios (principe de la méthode Monte-Carlo, voir section 4.1.3). Il est donc indispensable de faire un arbitrage entre un nombre de scénario significatif statistiquement et un nombre réduit permettant de résoudre rapidement le problème de planification.

Dans notre cas, un ensemble de scénario, appelé S , est constitué de N scénarios, notés S_n , et dont la somme des probabilités vaut un ($\sum_{n=1}^N \pi_n = 1$). Cet ensemble est censé représenter tous

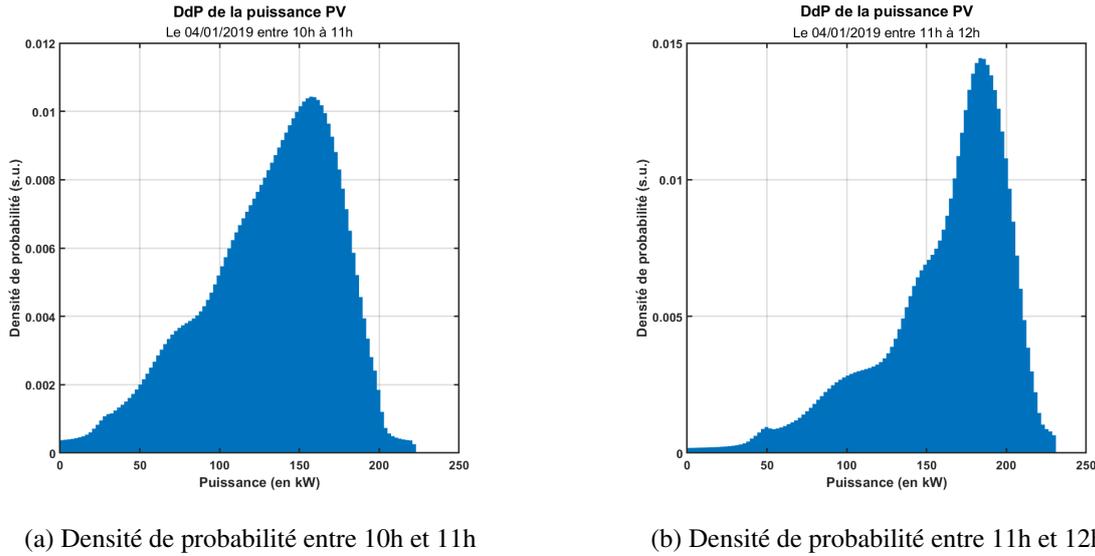


FIGURE 4.4 – Distribution de la puissance PV estimée à partir de la prévision probabiliste pour deux intervalles

les futurs possibles pour les variables considérées. Le tirage de la méthode de Monte-Carlo donne un ensemble dont chacun des scénarios est équiprobable : il n'est pas possible d'affirmer que l'un a plus de chances de réalisation qu'un autre. La probabilité de chaque scénario est donc assez évidente à obtenir en utilisant la **cardinalité** de l'ensemble. Le but de notre méthode sera d'obtenir un échantillon de scénario réduit mais qui couvre toujours l'espace des probabilité (i.e. dont la somme vaut un).

Il existe plusieurs techniques pour obtenir un ensemble de scénarios de **cardinalité** restreinte qui conserve au mieux les propriétés de l'ensemble initial (voir section 1.5.2.d). Les deux approches étudiées sont une méthode heuristique et une méthode de partitionnement ou regroupement de données (communément dites de *clustering*, de l'anglais). De façon générale, ces méthodes statistiques visent à organiser un ensemble d'observations en groupes homogènes. Cette organisation se base sur les similarités entre les observations, sans qu'il y ait eu de classification préalable. Dans notre cas, on cherchera donc à regrouper les scénarios de l'ensemble initial et désigner un candidat pour représenter chaque groupe, le nombre de groupes final correspondant à la **cardinalité** voulue.

4.2.1 Méthode heuristique

Dans un premier temps, c'est l'approche de Dupacova et al. et Heitsch et al. [166], [167] qui a été étudiée. Leur méthode heuristique est un algorithme permettant de regrouper des scénarios en calculant une distance entre l'ensemble de scénario initial et le réduit afin de choisir le scénario à éliminer en fonction des probabilités et de la proximité de leurs valeurs, estimée grâce à une norme, voir ci-dessous équation 4.1. La probabilité de celui qui a été supprimé est alors affectée au scénario le plus proche gardé dans l'ensemble.

Métrique de probabilité

La distance de Wasserstein ou de Kantorovich, notée $d_{\mathcal{W}}$, permet de mesurer une distance entre deux ensembles qui possèdent des mesures de probabilité selon une norme donnée (ici la norme euclidienne $\|\cdot\|_2$).

$$d_{\mathcal{W}}(S_i, S_r) = \sum_{\omega \in S_i} \left\{ \pi(\omega) \cdot \sum_{\omega_r \in S_r} [\pi(\omega_r) \cdot \|\omega - \omega_r\|_2] \right\} \quad (4.1)$$

Ici S_i et S_r désignent respectivement les ensembles de scénarios initial et réduit, ω un scénario et π sa probabilité associée.

On peut voir cette distance comme une estimation de la dégradation de l'information par rapport à l'ensemble initial, on supprimera donc à chaque itération de l'algorithme qui augmente le moins cette distance.

Pour cette approche il existe différents algorithmes, en fonction de la réduction voulue et du nombre initial de scénarios. Dans notre cas, la réduction d'un grand ensemble vers un très réduit, on utilise l'algorithme « Forward ».

Cette méthode présente de nombreuses possibilités et avantages : d'une part elle permet une approche rationnelle de la réduction au regard de la métrique choisie. De plus l'approche quantitative permet de choisir certains paramètres intéressants qui n'ont pas été exploré ici :

- Choisir une distance relative de réduction plutôt qu'un nombre de scénario final.
- Faire de la construction d'arbre : cela permet de réduire le nombre de noeuds de l'arbre des possible formé par les scénarios (i.e. réduire le nombre de variables aléatoires).

4.2.2 Méthode de clustering : k-médoïdes

Une autre méthode de regroupement a été testée pour la réduction de scénarios : la méthode k-médoïdes [168]. Dans cette approche chaque groupe de scénarios est représenté par un médoïde, qui fait lui-même partie du groupe. En statistique, un médoïde est défini comme un point central d'un groupe d'observations. Il est l'élément du cluster qui minimise la somme des distances entre lui-même et tous les autres points du groupe. Les étapes principales de la méthode k-médoïdes à partir du choix du nombre de groupes à former (k) sont les suivantes [169] :

1. Initialisation : k éléments sont sélectionnés aléatoirement comme médoïdes initiaux.
2. Affectation des éléments aux médoïdes : chaque scénario est affecté au cluster dont le médoïde est le plus proche. La distance entre éléments est calculée à l'aide de la norme euclidienne.
3. Mise à jour des médoïdes : pour chaque cluster, le médoïde est mis à jour comme étant le point du cluster qui minimise la somme des distances entre les points du cluster et lui-même.
4. Répétition des étapes 2 et 3 jusqu'à ce que les médoïdes ne changent plus, ou jusqu'à ce qu'un nombre maximum d'itérations soit atteint.

On obtient ainsi k groupes de scénarios. À la différence de la méthode vue dans la section précédente, l'algorithme ne prend pas en compte les probabilités de chaque scénario lors de ses itérations. C'est seulement une fois l'algorithme fini, lorsque que l'on somme le nombre de scénarios dans chaque groupe que l'on peut définir la probabilité du médoïde représentant le cluster. Cette méthode ne garanti pas l'optimalité de la solution fournie (le problème étant NP-difficile) mais elle fourni des résultats très satisfaisants (voir ci-dessous).

4.2.3 Résultats de la réduction

Le deux méthodes présentées ci-dessus ont été testées et comparées sur des ensembles de scénarios générés à partir des prévisions probabilistes à notre disposition. La première chose que nous regardons est le temps d'exécution des deux processus. Par la suite, nous avons cherché à comparer les résultats des deux méthodes et à déterminer le nombre de scénario minimal à générer puis nous nous sommes posé la question de l'impact de la **cardinalité** de l'ensemble réduit sur la destruction de l'information statistique.

a) Temps d'exécution

Le temps d'exécution d'un algorithme est une composante cruciale de sa mise en uvre et de son utilisation. En effet, un temps d'exécution trop long sera rédhibitoire dans certains cas. La

figure 4.5 présente le temps d'exécution médian en fonction du nombre de scénarios initial pour 20 réductions vers un ensemble réduit de 10 scénarios.

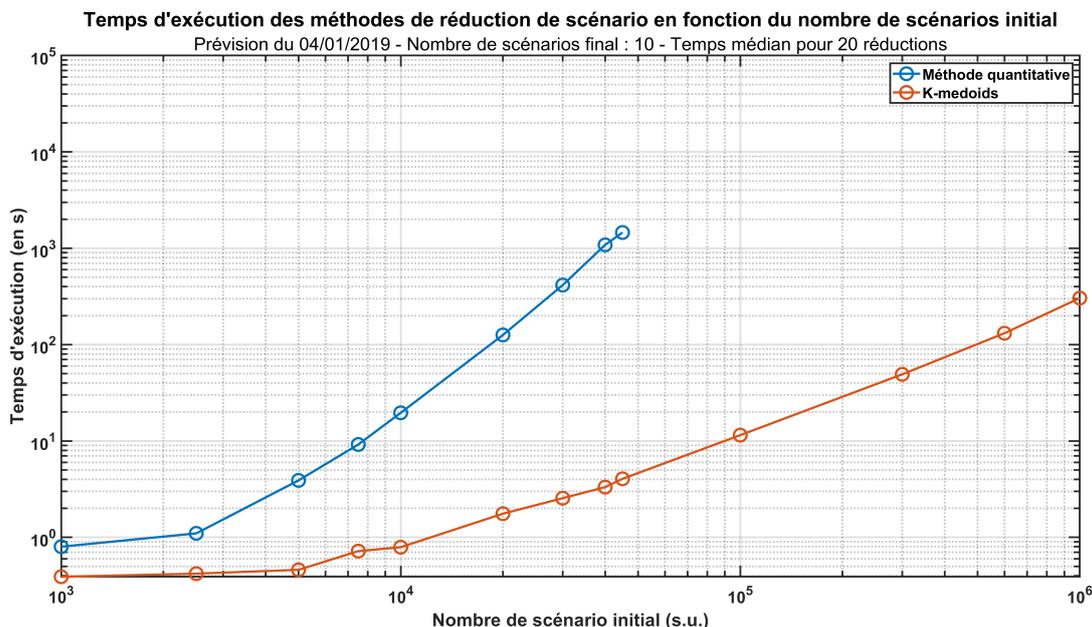


FIGURE 4.5 – Comparaison des temps d'exécution des algorithmes de réduction de scénarios

Globalement, nous observons que la méthode k-médoïdes est significativement plus rapide que l'autre méthode. À 10 000 scénarios de départ, la méthode heuristique a un temps d'exécution médian de 20 s, ce qui est encore correct mais la méthode heuristique est toujours sous la seconde et il lui faut 100 000 scénarios pour dépasser les 10s. Ce dernier algorithme est donc bien plus rapide que la méthode de Dupacova et al., qui a un temps d'exécution réhibitoire au delà de 10 000 scénarios initiaux. La **cardinalité** de l'échantillon final affecte aussi le temps d'exécution, mais pas dans l'ordre de grandeur de taille d'ensemble final que nous recherchons ($N < 100$), son influence n'a donc pas été étudiée ici.

4.2.4 Comparaison des méthodes et nombre minimal de scénarios initial

Après avoir comparé les temps d'exécution, il est nécessaire de se poser la question des résultats obtenus par ces algorithmes : les ensembles de scénarios réduits. Pour cela, on se dote d'un indicateur permettant de quantifier la destruction d'information par chaque méthode.

Distance relative

Afin de pouvoir confronter des algorithmes de réduction, on utilisera la métrique qui a été définie plus haut (voir section 4.2.1). Cette métrique est calculée pour avoir la distance de Wassertein (ou distance absolue de réduction) entre l'ensemble de scénario initial S_i et le final S_r . On effectue le ratio de cette dernière avec la distance de la réduction maximum que l'on pourrait effectuer : celle vers un scénario, cela nous donne la distance relative d_R . En effet, lorsque l'ensemble final ne possède plus qu'un seul scénario S_1 , on peut dire qu'il n'est plus possible de supprimer plus d'informations par rapport à l'échantillon initial. La mesure de distance de probabilité par rapport au groupe de départ ne peut plus augmenter en supprimant d'autres scénarios à part si on choisit un scénario représentant très mal l'ensemble, mais on s'attachera ici à choisir le meilleur possible. On fait donc le rapport entre la quantité d'information effectivement perdue (représentée par la distance $d_{\mathcal{W}}(S_i, S_r)$) et la quantité que l'on pourrait perdre au maximum, $d_{\mathcal{W}}(S_i, S_1)$.

$$d_R(S_i, S_r) = \frac{d_{\mathcal{W}}(S_i, S_r)}{d_{\mathcal{W}}(S_i, S_1)} \quad (4.2)$$

Une distance relative nulle signifiera que l'on a effectué aucune réduction, tandis que plus on se rapprochera de 100%, plus on aura perdu de l'information. Cette distance relative peut tout à fait dépasser 100% dans le cas où l'ensemble de scénario final est très réduit et où les scénarios sont des "mauvais" représentants, la distance absolue entre cet ensemble et l'ensemble initial pourrait alors dépasser celle calculée par rapport à un unique et "bon" représentant.

Pour étudier cet indicateur, nous avons effectué 20 réductions avec chaque méthode pour différents nombre de scénarios initiaux. La figure 4.6 présente les résultats de ces réductions à travers cet indicateur de distance relative pour un échantillon de 20 réductions pour chaque cardinalité de départ et chaque méthode. Tout d'abord, les résultats des deux algorithmes étant très similaires pour les mêmes données de départ nous considérons leurs résultats équivalents. Le temps d'exécution de la méthode k-médoïdes étant bien plus rapide que la méthode heuristique, nous nous restreindrons par la suite à utiliser les résultats de cet algorithme pour nos analyses.

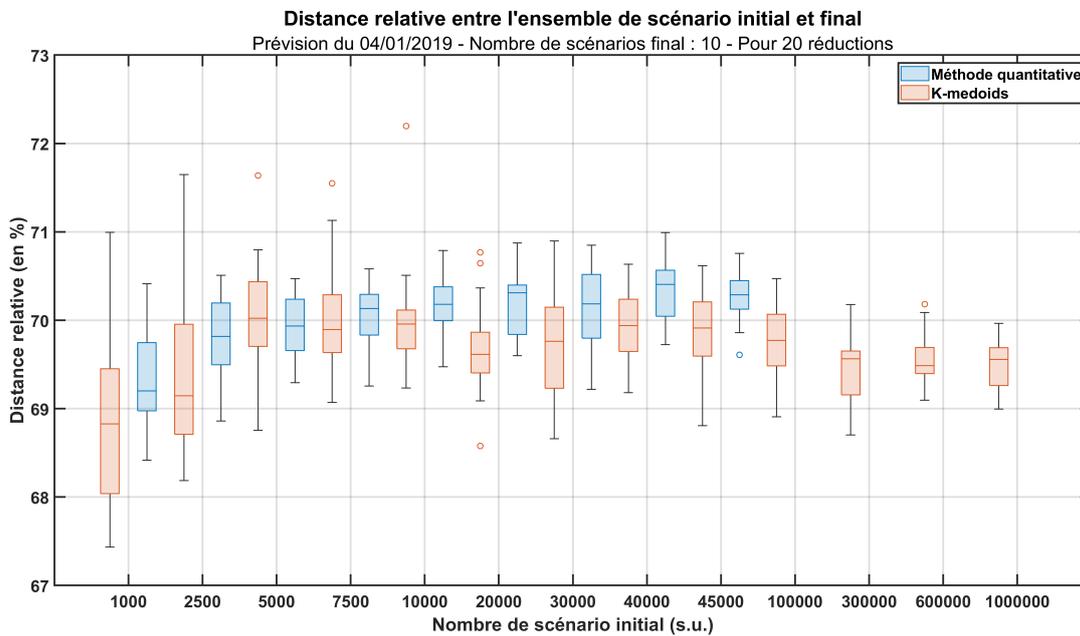


FIGURE 4.6 – Comparaison du résultat de deux méthodes de réduction en fonction du nombre de scénarios initial¹

La question du nombre de scénarios à tirer initialement se pose ensuite. En effet, si il est important de tirer un nombre de scénario important pour avoir une représentativité statistique, il est aussi crucial pour le temps d'exécution de limiter la cardinalité de l'ensemble de scénarios initial. Pour une cardinalité de 10 scénarios dans l'ensemble final, on observe sur la figure 4.6 que la distance de probabilité est assez variable avant 10 000 scénarios (l'écart interquartile dépasse les 1%), cela signifie que la cardinalité de l'ensemble initial n'est pas assez élevée. Après, 20 000 scénarios de départ, on remarque que la valeur médiane ne varie plus beaucoup, le résultat de la réduction semble converger. Notre choix s'est donc porté sur un ensemble de scénarios initial de 20 000 scénarios, qui semble un bon arbitrage entre représentativité, temps d'exécution et convergence du résultat de la réduction (la distance relative).

1. Pour ce diagramme en boîte et les suivants, la médiane de l'échantillon est représentée par le milieu de la boîte. Ses extrémités délimitent les quartiles inférieur (Q_1) et supérieur (Q_3), c'est donc également une mesure de l'écart interquartile (EI). Le segment noir défini le maximum et le minimum des valeurs atypiques ($[Q_1 - 1,5 \times EI, Q_3 + 1,5 \times EI]$)

4.2.5 Intérêt de la méthode

Cette mesure de distance relative permet également de justifier de l'intérêt de la méthode de réduction de scénarios. En effet, si l'on utilise cette métrique pour comparer des ensembles réduits issus de la réduction et d'autres dont la réduction a été faite aléatoirement, on peut remarquer une grande différence. La figure 4.7 présente ainsi un échantillon de distances relatives à l'issue de 20 réductions à partir d'ensembles de départ différents pour quatre prévisions, avec et sans méthode de réduction. Pour les échantillons sans méthode de réduction, on prélève au hasard le nombre de scénario voulu, ici 10, pour représenter l'ensemble final, on l'appellera méthode naïve. Tout d'abord on remarque une grande variabilité des résultats par rapport aux échantillons où k-médoïdes a été utilisé lorsque cette dernière est employée, ce qui montre la stabilité de l'algorithme heuristique pour le nombre de scénarios initial choisi. De plus, on observe systématiquement un écart important entre les deux approches : la méthode de réduction heuristique permet d'obtenir des distances bien plus faibles (plus de 10% en moyenne) entre les ensembles de départ et d'arrivée, donc de détruire moins d'informations. De plus, on peut s'apercevoir qu'il existe une différence entre les distances relatives en fonction de la prévision dont est issu l'ensemble de scénario, dans ce cas la différence est de 6% au maximum.

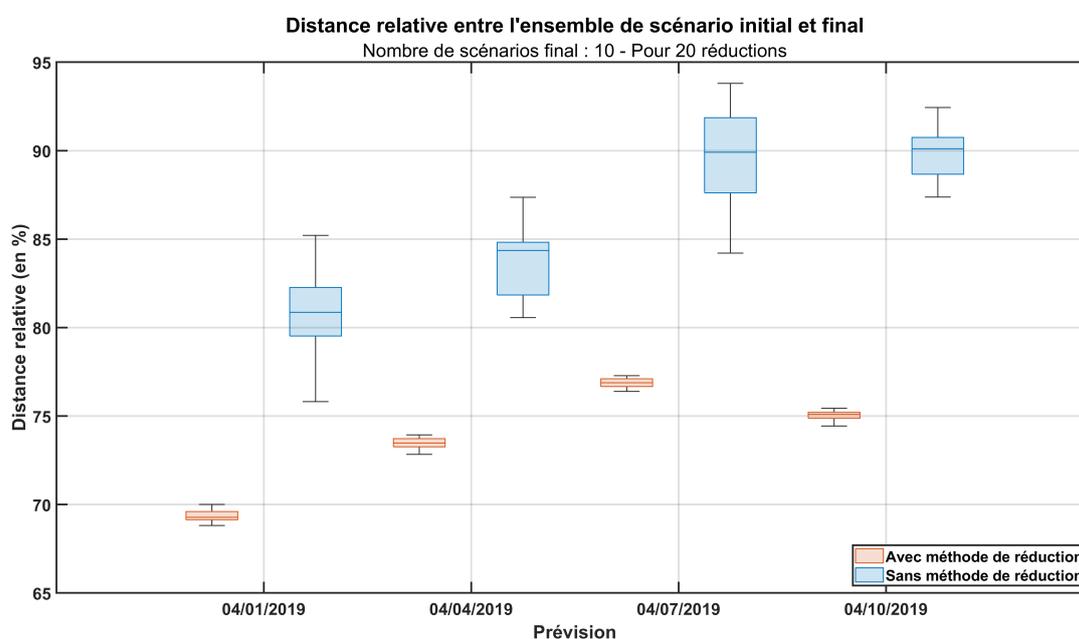


FIGURE 4.7 – Comparaison des distances relatives avec et sans méthode réduction pour quatre prévisions distinctes

4.2.6 Effet du nombre de scénarios final

Maintenant que la méthode de réduction a été choisie, à l'instar du nombre de scénario initial, et que son intérêt est démontré, nous nous intéressons à l'importance du nombre de scénario dans l'échantillon réduit. La figure 4.8 présente ainsi pour quatre prévisions différentes l'évolution de la distance relative en fonction du nombre de scénario dans l'ensemble final. On observe tout d'abord que la distance augmente avec la réduction de la taille de l'ensemble final jusqu'à atteindre 100% lorsque qu'il n'y a plus qu'un seul scénario pour représenter l'ensemble. Cette observation est logique au vu de l'interprétation de cette distance, plus on a une taille d'ensemble réduite, plus on a détruit de l'information par rapport à l'ensemble de base. En outre, on peut constater que la différence entre les prévisions de départ semble bien exister peu importe le nombre de scénario final mais se ressert avec la réduction du nombre de scénarios jusqu'à converger pour un scénario :

ils tous sont à 100%. Cependant, quelque soit la prévision de départ les distances relatives restent très proches. Pour garder 50% de l'information contenue dans l'ensemble initial il faudrait garder environ 300 scénarios et si on garde 10 000 scénario, soit la moitié de l'échantillon de départ on a une distance relative de 18% ce qui représente une faible destruction de l'information (on en garderaidonc 82%) mais un temps de calcul rédihibitoire et une taille trop importante pour le problème de planification. Pour notre cas d'application il paraît raisonnable de garder entre 10 et 20 scénarios. L'influence du nombre de scénario comme paramètre de notre modèle d'optimisation pour la planification sera étudiée au chapitre 6.

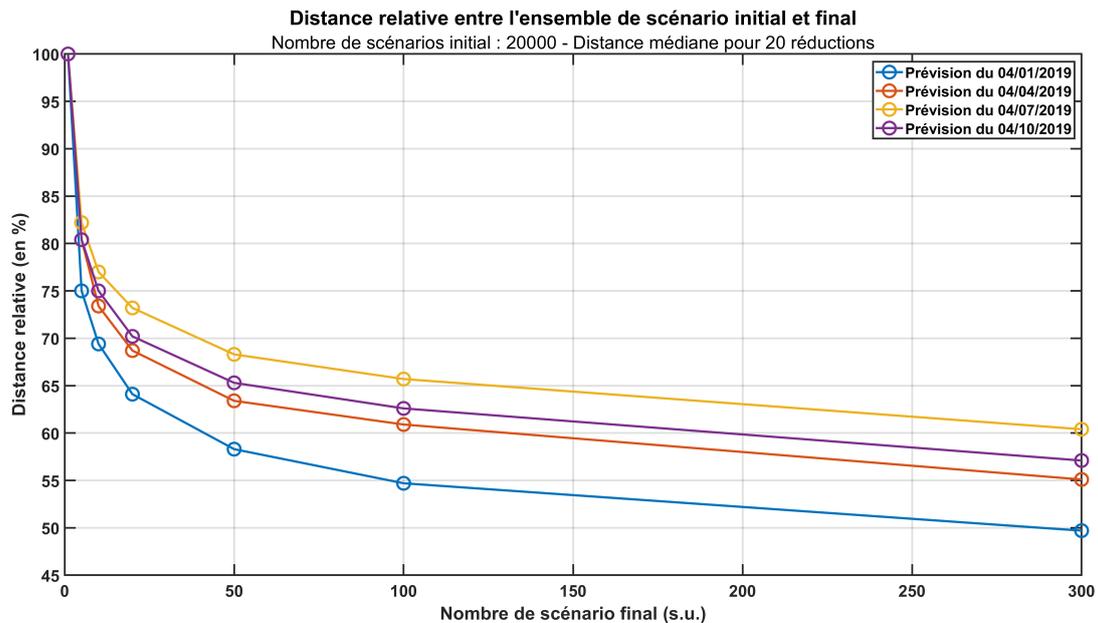


FIGURE 4.8 – Résultat la méthode k-médoïdes en fonction du nombre de scénarios final pour quatre prévisions

4.2.7 Exemple d'un ensemble réduit de scénarios

La figure 4.9 ci-dessous présente un échantillon de 5 scénarios issus de la réduction d'un ensemble de initial en comptant 20 000 pour la prévision du 04/01/2019. On peut remarquer que les probabilités des scénarios choisis vont de 24,8% à 12,2%. Ainsi on ne retrouve pas ici de représentant dont la probabilité est élevé et leurs probabilités sont assez proches. C'est comme si l'ensemble avait été découpé en morceaux de taille allant du simple au double (la probabilité du médoïde représentant la taille) mais sans groupe très dominant. Cette observation a été faite pour un nombre important de réductions mais aucune méthodologie rigoureuse de contrôle ni d'analyse des ensembles obtenus n'a été mise en place.

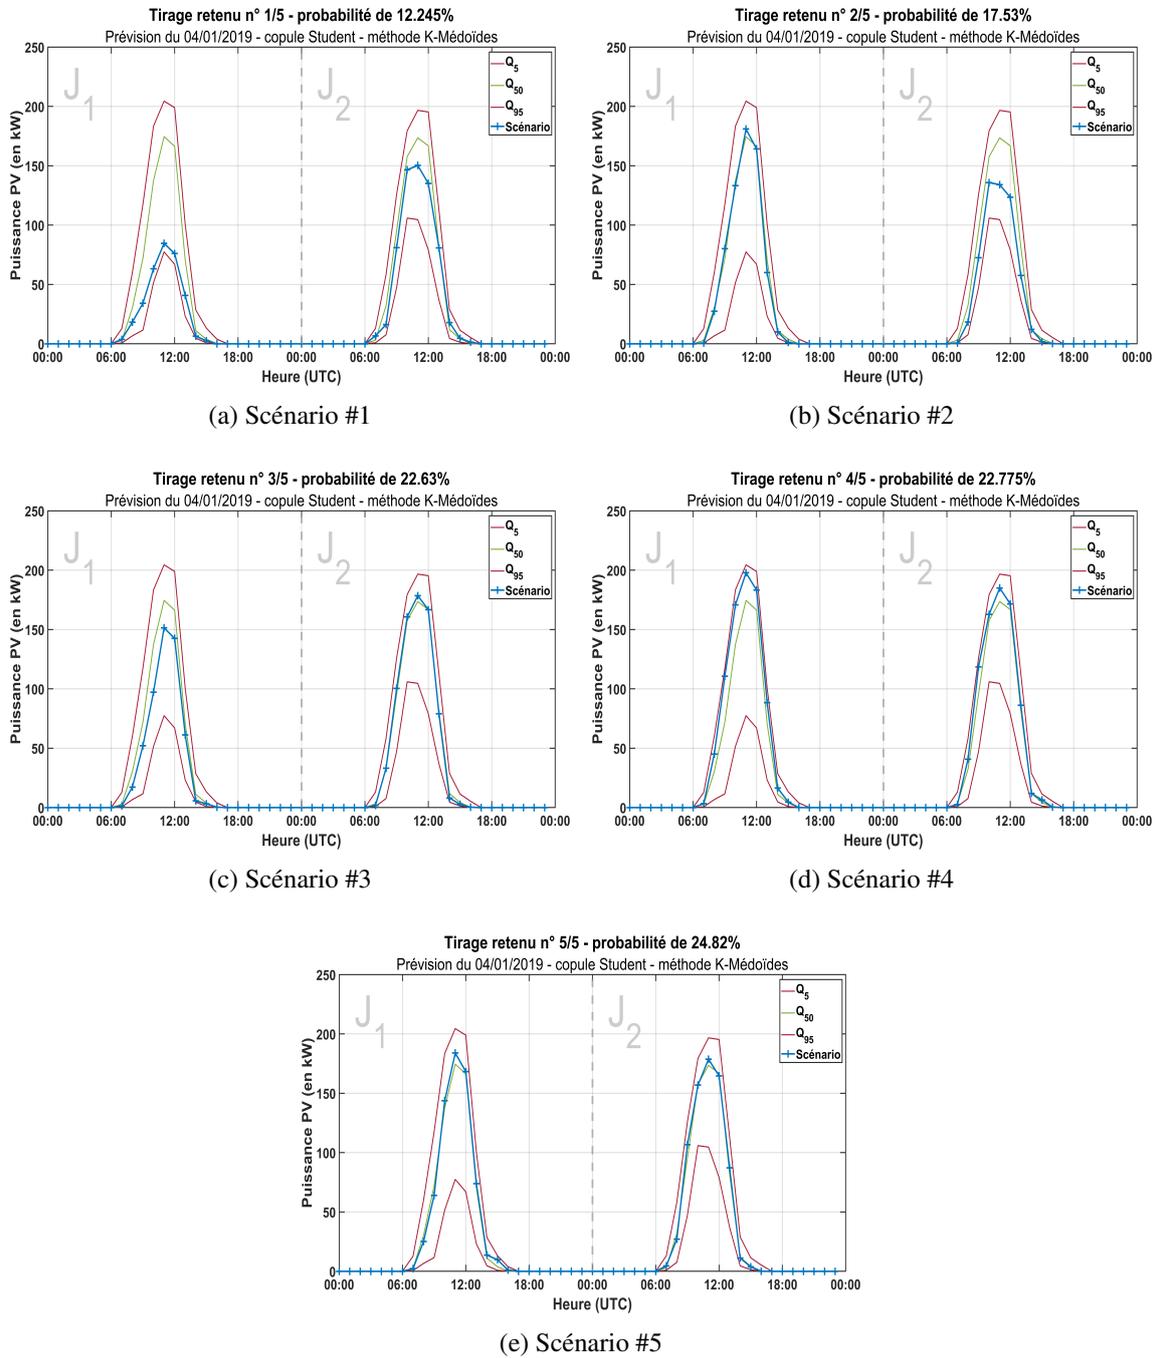


FIGURE 4.9 – Exemples de scénarios issus de la réduction pour la prévision du 04/01/2019

4.3 Conclusions, limites et perspectives

Cette section nous a permis de mettre en place et de choisir une méthodologie de réduction de scénarios. Nous avons étudié son temps d'exécution, l'influence du nombre de scénarios initial et final, ainsi que défini un indicateur permettant de quantifier la perte d'information afin de maîtriser et analyser son résultat. Pour finir nous avons également montré son intérêt par rapport à une méthode naïve mais seul les résultats du cas d'étude du chapitre 7 nous permettra de statuer sur la qualité et l'utilité de l'algorithme de réduction utilisé. Afin de consolider les résultats obtenus par cette réduction, nous pourrions les confronter à certains indicateurs permettant de statuer sur la représentativité de certains comportements des données observées dans les scénarios générés (voir section 1.6.2.b).

5

Assimilation de données de production PV

Ce chapitre permet de conclure le travail sur la modélisation de l'aléa PV en exploitant le travail effectué et le recueil de mesures pour faire de l'assimilation de données. Ainsi grâce au modèle de dépendance établi précédemment on détaille une méthode permettant de générer des prévisions prenant en compte de nouvelles informations, améliorant ainsi la connaissance du futur.

Sommaire

5.1	Description de la méthode d'assimilation	96
5.1.1	Copule conditionnelle	96
5.1.2	Loi normale multivariée conditionnelle	97
5.1.3	Loi t-Student multivariée conditionnelle	97
5.1.4	Obtention de quantiles conditionnels	98
5.2	Échantillon issu de l'assimilation	98
5.3	Intérêt de l'assimilation de données	102
5.4	Conclusions, limites et perspectives	102

Par la suite, on présentera les résultats de la génération de trajectoires de productible PV ainsi qu’une méthode pour réduire la taille des ensembles de scénarios produits. Pour finir, on

Notre approche de la modélisation de la corrélation entre les différentes variables, grâce à la notion de copule, ouvre une autre possibilité de gestion de l’incertitude : l’assimilation de données de mesure. La disponibilité des prévisions probabilistes n’étant pas continue, dans notre cas une fois par jour à minuit, il est tout de même possible d’avoir une connaissance plus fine de l’incertitude de production PV au fil du temps. En effet, on peut exploiter les mesures effectuées sur la centrale le long de la journée pour obtenir de nouvelles distributions pour les variables étudiées. Ce processus est illustré figure 5.1.

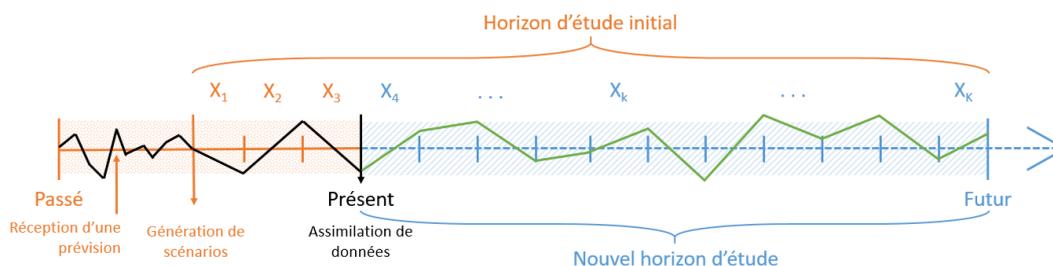


FIGURE 5.1 – Processus d’assimilation de données : à partir des réalisations de certaines variables considérées de l’horizon initial (de X_1 à X_3) et de l’étape de génération de scénario qui a permis de caractériser les loi de probabilités, on génère une nouvelle trajectoire (ici en vert) débutant dès la fin de la réalisation passée (en noir).

5.1 Description de la méthode d’assimilation

Après la réception de la prévision, on est capable d’estimer les distributions (voir section 3.1), en y associant un modèle de corrélation (voir section 3.2) on peut générer des scénarios (voir section 4.1). En avançant dans l’horizon temporel, on peut se poser la question de savoir si notre connaissance du futur (i.e. l’incertitude des variables considérées) est toujours la même ou si il est possible de la mettre à jour avec de nouvelles informations. En effet, au fur et à mesure de la journée, des réalisations de productible PV sont disponibles pour la centrale étudiée, en les croisant avec notre représentation du vecteur aléatoire, il est possible de les exploiter et obtenir une nouvelle vision du futur. La section suivante montre comment le formaliser mathématiquement ainsi que les bénéfices pouvant découler de cette méthode.

La notion de distribution conditionnelle

En théorie des probabilités, la distribution conditionnelle se réfère à la distribution de probabilité d’une variable aléatoire donnée, sachant certaines informations (comme la réalisation d’une variable par exemple). En d’autres termes, elle représente la manière dont la probabilité des valeurs possibles d’une variable aléatoire change en fonction d’une information supplémentaire disponible. La distribution conditionnelle de X_B sachant X_A , notée $P(X_B|X_A)$, représente la distribution de probabilité de X_B lorsque nous connaissons la valeur de X_A . Cette notion est particulièrement utile dans la modélisation et l’analyse de situations avec des variables dépendantes les uns des autres, ce qui est le cas ici.

5.1.1 Copule conditionnelle

La copule désignant une fonction de répartition multivariée, elle est comme décrit dans II reliée à une loi statistique et sa distribution. Ayant la donnée sur la réalisation de certaines variables

d'étude, on va chercher à obtenir la distribution conditionnelle tenant en compte de cette nouvelle information.

On s'intéresse au vecteur (X_1, \dots, X_N) dont on connaît certaines réalisations (x_1, \dots, x_q) avec $q < N$. A la suite de la transformation dans l'espace des copules (équation 3.7), on s'intéresse au vecteur (Z_1, \dots, Z_N) et aux réalisations $z_A = z_1, \dots, z_q$. Cette réalisation va donc permettre de diviser le vecteur aléatoire en deux parties : l'une connue (Z_1, \dots, Z_q) , noté Z_A et de taille et l'autre inconnue (Z_{q+1}, \dots, Z_N) , notée Z_B . Ce qui est recherché est alors la distribution de Z_B sachant $Z_A = z_A$, la connaissance de la distribution de Z étant définie par le modèle de corrélation paramétré préalablement.

Pour cette étape d'assimilation, seules les copules gaussiennes et Student seront étudiées (celles ayant été retenues au regard de leurs scores).

5.1.2 Loi normale multivariée conditionnelle

Dans le cas général, la fonction multivariée normale initiale a comme paramètres μ et Σ . En premier lieu, on isole certaines parties de ces paramètres :

$$\mu = \begin{bmatrix} \mu_A \\ \mu_B \end{bmatrix} \text{ de tailles } \begin{bmatrix} q \times 1 \\ (N-q) \times 1 \end{bmatrix}$$

$$\Sigma = \begin{bmatrix} \Sigma_{AA} & \Sigma_{AB} \\ \Sigma_{BA} & \Sigma_{BB} \end{bmatrix} \text{ de taille } \begin{bmatrix} q \times q & q \times (N-q) \\ (N-q) \times q & (N-q) \times (N-q) \end{bmatrix}$$

L'expression des paramètres de la loi normale conditionnelle, $\mu_{B|A}$ et $\Sigma_{B|A}$ tels que $(Z_B|Z_A = z_A) \sim \mathcal{N}(\mu_{B|A}, \Sigma_{B|A})$ est donnée formellement par ses formules [170] :

$$\mu_{B|A} = \mu_B + \Sigma_{BA} \Sigma_{AA}^{-1} (z_A - \mu_A)$$

$$\Sigma_{B|A} = \Sigma_{BB} - \Sigma_{BA} \Sigma_{AA}^{-1} \Sigma_{AB}, \text{ le complément de Schur de } \Sigma_{AA} \text{ dans } \Sigma$$

5.1.3 Loi t-Student multivariée conditionnelle

Dans le cas général, la fonction t-Student multivariée initiale a comme paramètres μ , Σ et ν . En premier lieu, on isole certaines parties de ces paramètres comme pour le cas normal multivariée.

La distribution conditionnelle s'écrit alors [171] :

$$Z_B|Z_A \sim t_{p_B} \left(\mu_{B|A}, \frac{\nu + d_A}{\nu + p_A} \Sigma_{B|A}, p_B \right)$$

avec $\mu_{B|A}$ et $\Sigma_{B|A}$ similaires à ceux de la distribution normale multivariée ;

$$d_A = (z_A - \mu_A)^T \Sigma_{AA}^{-1} (z_A - \mu_A),$$

le carré de la distance de Mahalanobis¹ entre z_A et μ_A avec Σ_{AA} comme matrice de variance-covariance ;

$$p_B = \nu + p_A, \text{ le nouveau nombre de degré de liberté}$$

La copule conditionnelle va permettre de fournir :

1. La distance de Mahalanobis permet ici d'estimer la distance au regard de la variance entre un échantillon d'un vecteur aléatoire et sa distribution (représentée par les moyennes attendues) tout en prenant en compte la dépendance entre les variables grâce aux covariances [172].

- Une nouvelle représentation probabiliste à partir de la fonction de répartition pouvant être sous la forme de quantiles ou de scénarios
- Une représentation déterministe en fournissant uniquement de nouvelles valeurs de quantiles de niveau 50% pour chacune des variables.

C'est cette dernière qui a été testée sur le jeu de données disponible.

5.1.4 Obtention de quantiles conditionnels

Les notions introduites ci-dessus nous permettent donc d'assimiler des observations pour en tirer de nouvelles informations sur les variables considérées. On se propose dans cette partie de détailler le processus permettant d'assimiler la valeur réalisée d'une variable (qui devient donc variable observée) et celui menant à l'obtention d'une nouvelle valeur de Q_{50} pour une variable dont l'aléa existe encore. Par simplicité, nous appellerons ensuite cette nouvelle prévision P_{assim} .

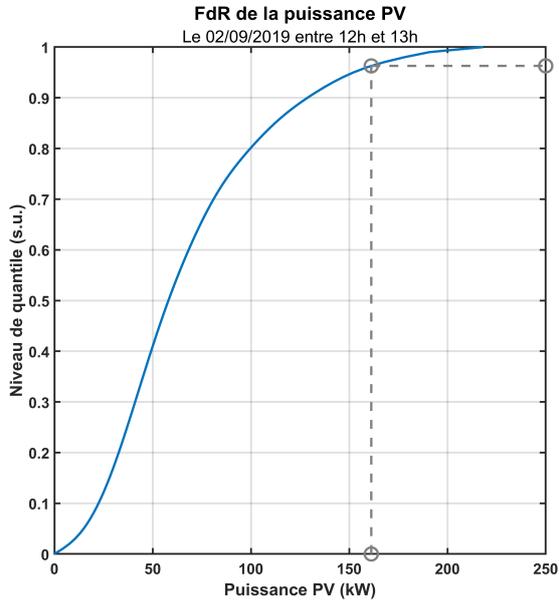
La figure 5.2 nous montre l'ensemble du processus d'assimilation en se focalisant donc sur deux variables voisines temporellement : la puissance PV entre 11h et 12h, dernière variable observée, et celle entre 12h et 13h, première variable aléatoire du nouveau vecteur étudié. En premier lieu, l'observation de la variable est reportée dans l'espace des pseudos-variables (voir figure 5.2a). On peut remarquer que cette réalisation se situe proche de la borne support et est associée au quantile 99% par la fonction de répartition. Pour calculer la distribution conditionnelle de cette assimilation, on transforme l'observation jusque dans l'espace de la copule. Comme on peut le voir sur la figure 5.2b, la réalisation précédente correspond à une zone de faible densité de probabilité dans l'espace de la copule. Une fois dans le bon espace, on calcule les paramètres de la distribution conditionnelle comme indiqué dans la section 5.1.1 précédente. Sur la figure 5.2d, on peut observer la densité de probabilité correspondant à la loi conditionnelle dans l'espace de la copule de la variable aléatoire considérée (en orange). Sa densité de probabilité avant le calcul de la loi conditionnelle a également été présenté pour comparaison (en bleu). Pour obtenir le Q_{50} conditionnel de cette variable, on prend la valeur de la médiane de cette loi conditionnelle et pour retourner dans l'espace de la variable, on la transforme à nouveau via les fonctions de répartition de la copule et de la variable (voir figure 5.2d), une nouvelle fois en passant par l'espace des pseudos-variables. A travers ce process, nous observons bien l'influence via la copule entre ces deux variables, une réalisation correspondant au quantile 99% de la première va entraîner un Q_{50} conditionnel qui correspond au quantile 96% de la fonction de répartition de la variable.

5.2 Échantillon issu de l'assimilation

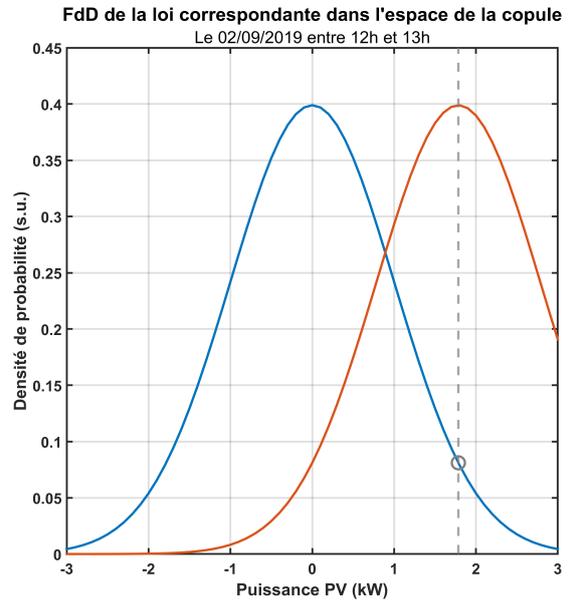
Dans cette section, on se propose d'étudier différents cas de prévision où la méthode d'assimilation a été testée. Nous avons identifié différentes situations dans lesquelles il serait intéressant d'observer les résultats d'assimilation. Pour cela nous avons croisé des prévisions (déterministe et Q_{50}) avec les observations mesurées sur la centrale. Nous avons décidé de couper la journée en deux en décidant d'effectuer l'assimilation à 11h (fin de l'intervalle correspondant à la variable de productible PV entre 10h et 11h). Nous avons retenu cinq situations par rapport à la qualité constatée de l'estimation de la production par les prévisions :

- Cas A : Surestimation de la production sur la 1^{ère} et la 2^{ème} moitiés de journée.
- Cas B : Surestimation de la production sur la 1^{ère} puis bonne estimation sur la 2^{ème} partie.
- Cas C : Sous-estimation de la production sur la 1^{ère} et la 2^{ème} moitiés de journée.
- Cas D : Sous-estimation de la production sur la 1^{ère} puis bonne estimation sur la 2^{ème} partie.
- Cas E : Bonne estimation de la production sur la 1^{ère} et la 2^{ème} moitiés de journée.

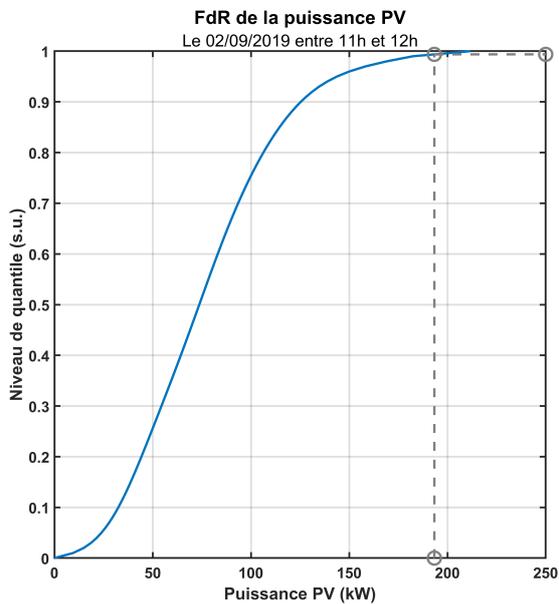
La figure 5.3 présente les résultats de ces différents cas d'assimilation. De façon générale, la nouvelle prévision issue l'assimilation, appelée P_{assim} , semble attirée par la tendance des observations de la 1^{ère} moitié de journée : si il y avait une surestimation du productible PV la matinée,



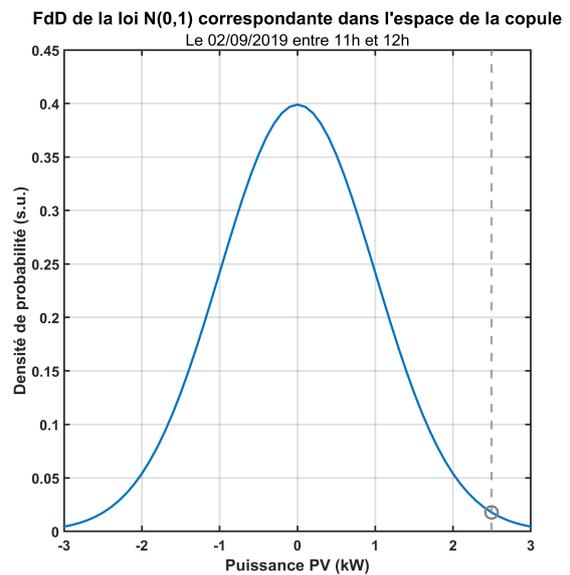
(a) Fonction de répartition de la puissance PV entre 11h et 12h



(b) Densité de probabilité correspondante à (a) dans l'espace de la copule



(c) Fonction de répartition de la puissance PV entre 12h et 13h



(d) (en orange) Densité de probabilité correspondante à (c) dans l'espace de la copule

FIGURE 5.2 – Illustration du principe d'assimilation avec une variable observé et une variable aléatoire dont on détermine un nouveau Q_{50}

l'assimilation va prédire cette même orientation. Ce résultat est logique car les corrélations entre les variables considérées sont positives : la position des réalisations dans l'espace des pseudo-variables va agir comme un attracteur pour le niveau du Q_{50} conditionnel des variables aléatoires restantes.

On peut observer les indicateurs statistiques pour comparer les performances de la nouvelle prévision calculée par rapport aux prévisions non actualisées pour les cas mentionnés précédemment dans le tableau 5.1. En premier lieu les résultats du cas montrent que si la prévision reste bonne toute la journée (cas d'une journée de grand soleil), la nouvelle prévision obtenue ne permet pas d'améliorer la performance des prévisions initiales. Les Cas B et D, montre à peu près le même phénomène : respectivement la prévision sur- et sous-estime le productible PV dans la matinée avant de se corriger dans la 2^{ème} partie de journée. Dans ces deux cas, P_{assim} obtient globalement de moins bons résultats que les prévisions initiales, ici l'assimilation peut donc s'avérer trompeuse. Pour finir, les cas A et C, qui montraient la même tendance d'erreur (respectivement sur- et sous-estimation) sur l'entièreté de la journée, permettent d'illustrer l'intérêt de l'assimilation d'observations. Ainsi les deux figures 5.3a et 5.3c et les indicateurs dans le tableau nous montrent bien que la nouvelle prévision calculée permet de combler une partie de l'erreur de prévision sans assimilation. Finalement, si l'on s'en tient à l'étude de ces cinq cas, on ne peut statuer pour l'instant sur l'intérêt de l'assimilation.

		EM (kW)	REQM (kW)	EAM (kW)	MaxEA (kW)	MPAE (%)	EV (kW)	Skewness	Kurtosis
Cas A	P_{det}	-53,7	75,5	60	131,94	-	-	-	-
	Q_{50}	-50,9	73,1	57,9	126,6	-	-	-	-
	P_{assim}	-14,4	31	24,3	50	-	-	-	-
Cas B	P_{det}	6,6	11,9	9,8	23,8	-	-	-	-
	Q_{50}	-8,7	16,6	11,2	32,5	-	-	-	-
	P_{assim}	10	15,6	11,1	30,6	-	-	-	-
Cas C	P_{det}	66	80,7	66	115,9	-	-	-	-
	Q_{50}	73	91,6	73,3	141,5	-	-	-	-
	P_{assim}	50,7	63,9	51,6	91,5	-	-	-	-
Cas D	P_{det}	-2,8	5,4	3,5	11,6	-	-	-	-
	Q_{50}	8,9	12,8	9,4	21,6	-	-	-	-
	P_{assim}	-1,3	9,4	7,7	14,9	-	-	-	-
Cas E	P_{det}	5,2	5,8	5,2	10,6	-	-	-	-
	Q_{50}	5,1	7,1	5,2	15,4	-	-	-	-
	P_{assim}	1,9	6,2	5,1	12,7	-	-	-	-
Global	P_{det}	-1,5	28,9	18,7	158,4	6,7	28,9	-0,58	3,63
	Q_{50}	-2,2	28,8	17,5	162,8	6,1	28,7	-0,60	5,03
	$P_{assim,Gauss}$	-1,5	25,3	15,2	142,6	6,1	25,3	-0,53	4,74
	$P_{assim,Stud}$	-1,4	25,3	15,2	144,2	6,1	25,2	-0,49	4,74

TABLEAU 5.1 – Indicateurs statistiques de la méthode d'assimilation sur plusieurs cas d'étude et au global

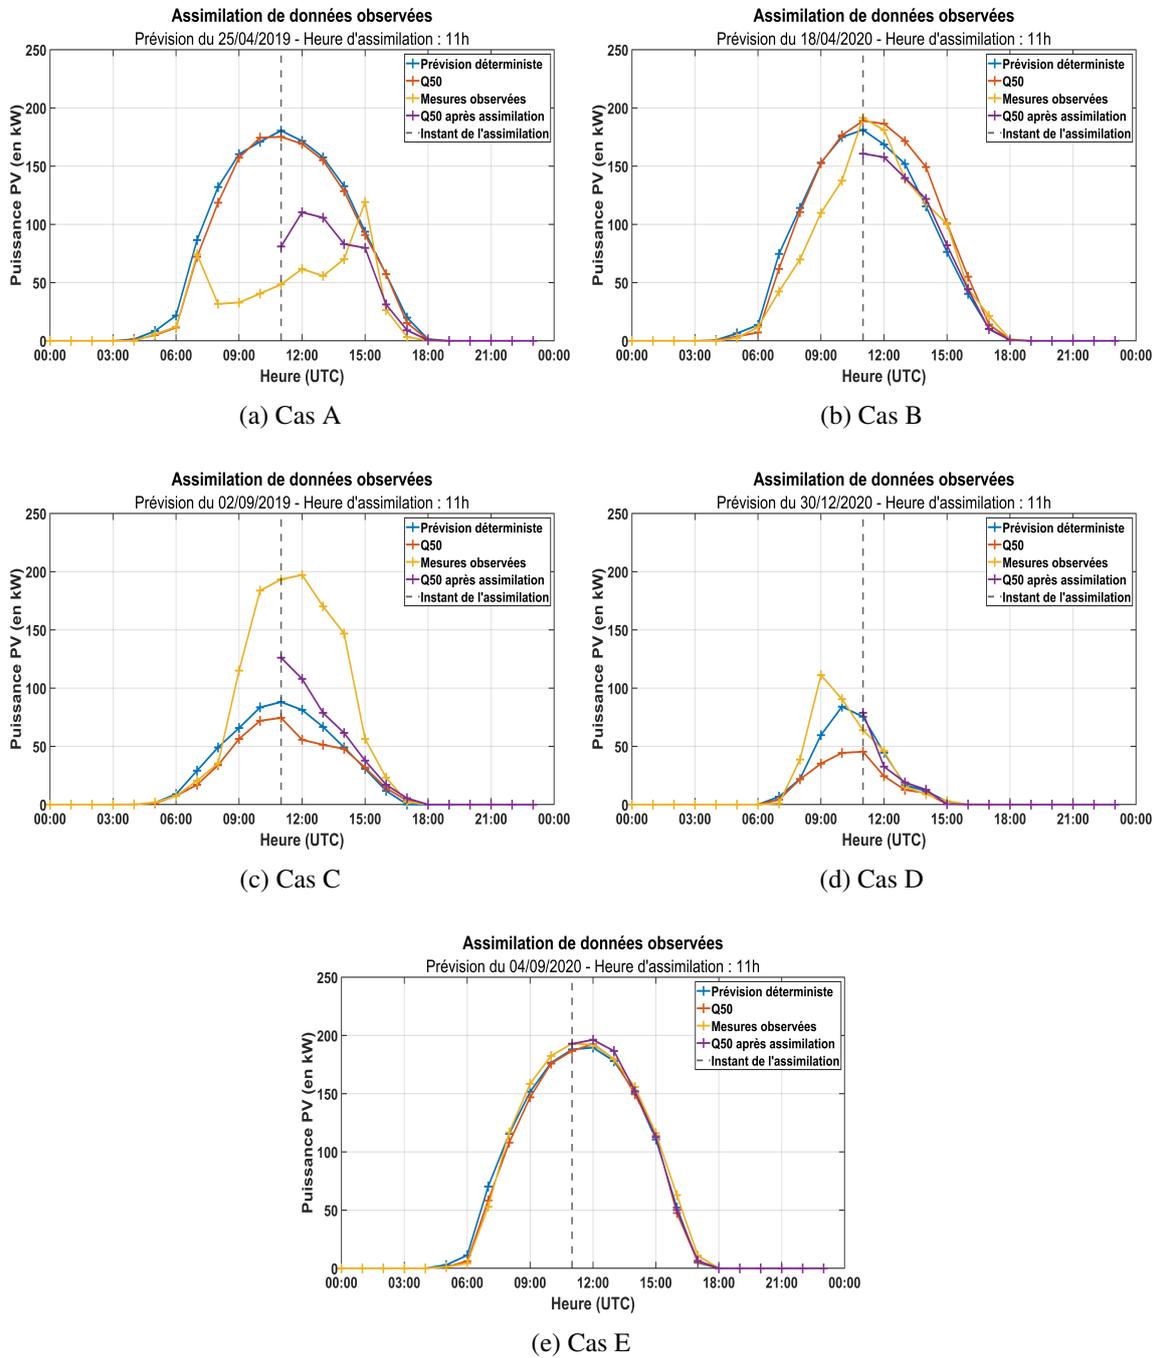


FIGURE 5.3 – Exemples d'assimilations pour différentes prévisions

5.3 Intérêt de l'assimilation de données

Après avoir étudié différents cas particuliers, se pose la question de l'intérêt de l'assimilation. Pour y répondre, il faut tester cette méthode sur un plus grand nombre de cas, nous le faisons sur l'entièreté des données à notre disposition. On parcourt ainsi toutes les prévisions disponibles et on effectue l'assimilation des observations à 1h pour en tirer une nouvelle prévision.

Les résultats de cette simulation de l'assimilation sont disponibles en bas du tableau 5.1. Premièrement, nous avons décidé de comparer les deux copules élliptiques (Gaussienne et Student). Du point de vue des indicateurs statistiques étudiés, les deux copules sont quasiment équivalentes. Même si la copule Student modélise mieux la dépendance entre variables (voir section 3.2.3.b) et devance très légèrement la copule gaussienne sur plusieurs indicateurs (EM, EV, Skewness) contre un seul pour la seconde (MaxEA), il serait très difficile de trancher en faveur de l'une ou l'autre. Deuxièmement, on cherche à statuer sur les performances de la prévision issue de l'assimilation par rapport aux prévisions initiales (P_{det} et Q_{50}). Pour l'erreur moyenne, il n'est pas possible d'affirmer que P_{assim} est meilleure que P_{det} mais uniquement de Q_{50} . En revanche notre prévision recalculée obtient des scores bien meilleurs que les prévisions initiales pour la racine de l'erreur quadratique moyenne (environ 3,5 kW de mieux), l'erreur absolue moyenne (aussi 3,5 kW de mieux), le maximum de l'erreur absolue (environ 15 kW de mieux) et pour l'erreur de variance. Seule la prévision déterministe initiale est meilleure que les prévisions recalculées sur le kurtosis : la distribution de ses erreurs contient plus de petites valeurs que les autres. La skewness et l'erreur moyenne montrent de façon général que la production PV est surestimée mais on sait grâce à la valeur du skewness de $P_{assim,Stud}$ que sa queue de distribution contient moins d'observations qui ont surestimé le productible que les autres prévisions. Finalement, nous avons réalisé le même processus avec une assimilation une heure avant (à 10h) et une heure après (à 12h) et les résultats sont sensiblement les mêmes.

5.4 Conclusions, limites et perspectives

Dans cette section, nous avons donc détaillé un processus performant d'assimilation d'observations de productible PV. Cette méthode est basée sur les modèles de corrélations estimés plus tôt dans ces travaux ainsi que sur le calcul de distributions conditionnelles. On a vu que dans certains cas particuliers, elle pouvait être trompeuse mais que globalement elle apportait bien des informations statistiques importantes. L'assimilation vient donc ajouter un dernier outil dans la gestion de l'incertitude du vecteur aléatoire étudié. Cette méthode pourrait s'avérer précieuse lorsque des prévisions ne sont pas disponibles régulièrement, or la plupart des fournisseurs de prévisions proposent des mises à jour régulières. Il serait possible d'améliorer ce processus d'assimilation en observant les données sur des échelles de temps plus réduites ou avec d'autres modèles de dépendance (voir section 3.3).

Cette partie sur l'incertitude de la prévision PV nous a permis de traiter les prévisions probabilistes, comme d'autres sources de données pour en tirer le maximum d'informations. De plus cette méthode est généralisable à d'autres sources de prévisions avec incertitudes (production éolienne, consommation, etc.). Si l'objectif d'obtenir un ensemble de scénarios réduits et prenant en compte les corrélations a été rempli, la question se pose maintenant de savoir si l'exploitation de ces informations supplémentaires a un impact positif sur la planification d'un micro-réseau. L'approche et les modèles utilisés ici pour des prévisions court-terme pourraient tout à fait être applicables pour d'autres échelles temporelles, notamment le long-terme, où les études de développement de réseau utilisent souvent des scénarios comme paramètres.

Troisième partie

Planification de micro-réseau sous incertitude

6

Cas d'étude : planification d'un micro-réseau sous incertitude

Ce chapitre présente les particularités du cas d'étude : l'horizon temporel étudié, les entités qui le composent et les hypothèses principales. La formulation du problème de planification y est détaillé tout comme les différentes stratégies de gestion. Finalement, la méthodologie d'évaluation des stratégies est abordée.

Sommaire

6.1	Présentation du cas d'étude considéré	108
6.1.1	Horizon temporel et variables étudiées	109
6.1.2	Caractéristiques du système étudié	110
6.1.3	Association d'une courbe de charge résidentielle et de production PV	113
6.1.4	Le rôle du pilotage de la batterie et du micro-réseau	115
6.1.5	Hypothèses simplificatrices	116
6.1.6	Conventions	116
6.2	Modèles des entités	116
6.2.1	Charge	116
6.2.2	Centrale PV	117
6.2.3	Stockage	117
6.3	Stratégies de planification	117
6.3.1	Critère économique	118
6.3.2	Contraintes sur la puissance soutirée	119
6.3.3	Formalisation du problème de planification	120
6.4	Méthodologie d'évaluation des approches	122
6.4.1	Coût des écarts	122
6.4.2	Contrainte de soutirage	123
6.4.3	Autoconsommation	124

L'objectif de ce chapitre est d'étudier différentes approches de la planification d'un micro-réseau électrique à travers l'étude d'un cas particulier. On se focalisera en particulier sur la prise en compte des incertitudes de productible PV à travers la différence entre formulations déterministe et stochastique du problème de d'optimisation que constitue l'anticipation du fonctionnement du système étudié.

6.1 Présentation du cas d'étude considéré

Le micro-réseau considéré représente un quartier résidentiel. Dans une optique d'autoconsommation, ce quartier a décidé d'investir dans une centrale photovoltaïque avec pour objectif de consommer une électricité produite localement et sans émission directe de gaz à effet de serre. Cette production PV pourrait être issue de panneaux installés sur les toits ou d'une ou plusieurs centrales. De plus ils se dotent d'un système de stockage d'énergie permettant de stocker et déstocker de l'énergie en la pilotant, ajoutant ainsi un degré de liberté à leur système énergétique. Ce système n'étant pas isolé, il est relié à un réseau de distribution permettant de fournir de façon garantie de l'énergie électrique.

Notre cas d'étude est donc un micro-réseau composé de plusieurs éléments :

- Des points de soutirage (ou consommateurs),
- Un point de connexion au réseau de distribution, aussi appelé **Point de Couplage Commun (PCC)**,
- Une centrale solaire photovoltaïque,
- Une batterie de stockage électro-chimique.

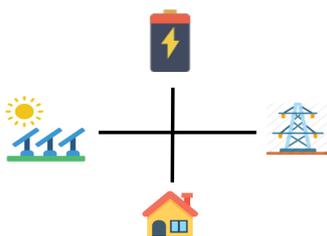


FIGURE 6.1 – Schéma simplifié des entités du micro-réseau considéré

La problématique pour l'opérateur du micro-réseau est de pouvoir anticiper son pilotage afin d'en optimiser les coûts d'opération. Dans cette optique, il est crucial voire nécessaire de prévoir le planning des différentes entités énumérées ci-dessus. En effet, il faut notamment annoncer le plan de soutirage depuis le réseau afin que le **responsable d'équilibre (RE)** puisse jouer son rôle auprès du **gestionnaire de réseau de distribution (GRD)** et sera pénalisé en cas d'écarts dans le bilan de son périmètre. On doit donc fournir à l'avance au **RE** la puissance que l'on souhaite soutirer à chaque heure de la journée qui vient et le non-respect du plan annoncé expose le micro-réseau à des pénalités répercutées par le **RE** car il doit les compenser. Il est donc important de pouvoir planifier l'opération du micro-réseau de la façon la plus juste possible : avec le moins d'erreurs entre l'annonce et la réalisation du plan car elles impacteront ses coûts d'opération. L'opérateur souhaite également rendre des services système au **GRD** grâce à des contraintes sur la puissance à prendre en compte dans son plan de soutirage.

Le principal défi de cet exercice est que ce système est exposé à des aléas : il n'est par exemple pas possible de connaître à l'avance la puissance exacte que va produire la centrale PV à chaque pas de temps. On dispose cependant de certaines données pour nos besoins d'anticipation : la connaissance de l'état du réseau (ex. : état de charge de la batterie) et d'informations sur le futur (prix de l'énergie, prévisions PV, etc.). On utilisera donc ces prévisions permettant d'avoir une meilleure connaissance des aléas et donc de mieux gérer l'incertitude.

Le problème de planification va donc prendre en paramètre ces données sur les aléas ainsi que les caractéristiques du système et déterminer les trajectoires optimales pour la **consigne** de chacune des entités pour la journée à venir. Ces trajectoires sont choisies au regard de l'objectif principal : en espérant minimiser les coûts d'opération, constitués ici des achats d'énergie et des pénalités éventuelles en cas de non respect du plan annoncé.

Pour pouvoir statuer sur la qualité et la pertinence de la méthode de planification, nous effectuerons tout d'abord le processus permettant de déterminer les trajectoires des entités puis nous simuleront l'opération du système avec ce programme planifié, une fois les réalisations des aléas connues sur la journée considérée (i.e. la productible PV observé).

Afin de clarifier l'analyse du cas d'étude, il convient de préciser certains éléments de langage qui seront utilisés par la suite :

- **Prévu** : concerne la prévision d'une grandeur, ex. : la puissance de la charge du lendemain.
- **Planifié** : issu de l'étape de planification, ex. : le choix de la puissance de la batterie.
- **Observé** : concerne la réalisation d'une grandeur, ex. : la puissance PV finalement observée.
- **Simulé** : issu de l'étape de simulation des trajectoires planifiée avec les valeurs observées, ex. : la puissance effectivement soutirée depuis le réseau.

6.1.1 Horizon temporel et variables étudiées

Pour effectuer la planification du pilotage à partir d'une prévision donnée sur un horizon, on procède à une discretisation temporelle. Ainsi l'horizon est divisé en intervalles de temps. Pour chacun d'eux, la puissance de chaque entité du micro-réseau est associée soit à un paramètre, si elle est connue ou si on peut estimer sa valeur soit à une variable que l'on souhaite déterminer, si elle est pilotable.

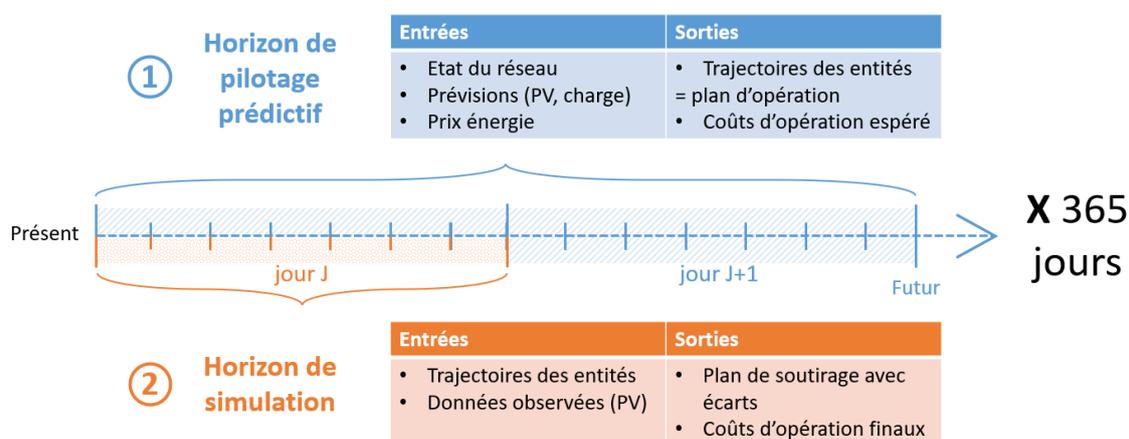


FIGURE 6.2 – Représentation des horizons de pilotage prédictif et de simulation

Concernant l'horizon temporel de la planification, le problème est résolu sur un horizon de deux jours (soit 48 intervalles horaires) puis simulé sur une journée comme décrit sur la figure 6.2 ci-dessus. Cela permet une gestion plus intelligente de l'énergie stockée dans la batterie. En effet, l'énergie étant valorisée dans notre problème, si l'on ne considère qu'une seule journée, on a intérêt à ce que la batterie soit complètement vide à la fin de l'horizon considéré, sinon cela représenterait un manque à gagner. Or, si la planification est faite de façon discontinue, l'opération d'un tel micro-réseau peut nécessiter de prendre en compte les éventualités qui peuvent se produire après la journée que l'on souhaite simuler, il peut donc être intéressant de garder un certain stock d'énergie d'une journée à l'autre.

De plus, on effectuera ce travail de simulation sur une année entière afin de s'affranchir des variations saisonnières de la consommation électrique et de la production photovoltaïque : pour une année donnée on effectue une planification puis une simulation toutes les 24h.

6.1.2 Caractéristiques du système étudié

Dans notre cas d'étude, le système n'est pas autonome en énergie, la puissance PV installée ne permet pas de fournir la demande à chaque instant même couplée à une batterie, il est donc relié à un réseau de distribution. On considère ici un système qui cherche à faire de l'autoconsommation sans revente de surplus, l'injection est donc interdite et non valorisée économiquement. L'injection peut en effet avoir des conséquences importantes sur le réseau auquel on est relié (modification du plan de tension, congestions, voir section 2.3.2). De plus, on ne considère pas de contrainte sur la puissance de soutirage.

La charge considérée représente l'équivalent de 3000 foyers non délestables : il est impossible de piloter à la hausse ou la baisse la puissance électrique qu'ils consomment, la demande doit être fournie à chaque instant. De plus, du fait du nombre de consommateurs considérés et de leur foisonnement, on considère qu'il n'y a pas d'aléa sur la prévision agrégée de leur consommation. La puissance de la charge est donc connue au moment de l'étape de planification.

La centrale PV connectée à notre micro-réseau a une puissance crête de 1,25 MW. En outre, il est possible de piloter la centrale en modulant à la baisse la puissance qu'elle produit (grâce aux régulateurs **Maximum Power Point (MPP)**, [173]).

Finalement, le dernier élément du système, le stockage d'énergie possède quatre caractéristiques principales : une capacité de stockage, une puissance commune de charge et de décharge, un état de charge minimal et maximal ainsi qu'un rendement appliqué à la puissance de charge et de décharge.

Toutes les caractéristiques des entités du micro-réseau sont consignées dans le tableau 6.1 ci-dessous.

Réseau	Consommateurs	PV	Batterie
<ul style="list-style-type: none"> • Pas de limite de soutirage (ni en énergie ni en puissance) • Pas d'injection 	<ul style="list-style-type: none"> • 3000 points de soutirage • Pas de délestage • Pas d'incertitude 	<ul style="list-style-type: none"> • 1,25 MWc • Modulation possible • Aléa sur la production 	<ul style="list-style-type: none"> • Capacité : 2 MWh • Puissance : 1MW • $SoC_{min-max}$: 10-90% • Rendement : 90%

TABLEAU 6.1 – Paramètres des entités du système

a) Courbe de charge résidentielle

L'objectif de cette section est de décrire les principales caractéristiques d'une courbe typique de charge résidentielle : forme, saisonnalité, variabilité, etc. Pour cela on présente les données utilisés sous la forme de graphes avec certaines grandeurs statistiques calculées de façon horaire pour différentes périodes.

De façon générale la forme d'une courbe de charge se divise entre trois types de périodes :

- **Creuse** : c'est lors de ce type de période que la demande électrique des ménages est la plus faible. Elle a lieu entre la soirée et le petit matin.
- **Pointe** : par opposition aux périodes creuses, les périodes de pointe correspondent aux moments de pics de la courbe de consommation. On retrouve souvent deux pointes dans une journée normale, une autour de midi et une vers 18h/19h, qui correspond très souvent au maximum de la journée considérée.

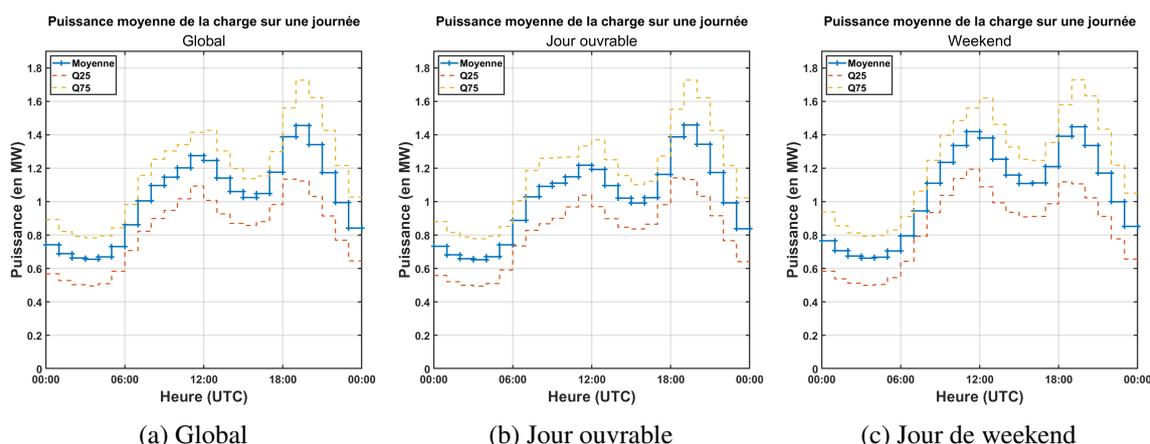


FIGURE 6.3 – Courbe de charge résidentielle moyenne au global et en fonction de la période de la semaine

- **Pleine** : représente les moments où la consommation est intermédiaire entre les deux types de périodes présentés ci-dessus.

La figure 6.3a, représentant la courbe de charge moyenne sur l'ensemble des données, illustre très bien ces trois différents types de périodes. En effet la courbe présentée commence par la période creuse puis on atteint la première période de pointe avant 12h après une période pleine. Avant la deuxième pointe qui survient à partir de 18h, on retrouve une période pleine et on finit par le retour à une creuse. On remarquera que l'écart interquartile (EIQ) est globalement constant à une valeur inférieure à 200 kW toute la journée à part durant la pointe du soir où il monte à 600 kW.

Une autre caractéristique de la courbe de charge résidentielle est illustrée figures 6.3b et 6.3c : la variabilité entre les jours ouvrables et le weekend. En effet, les deux courbes présentent bien la forme caractéristique d'une courbe de charge résidentielle mais on remarque bien une différence entre les deux. Du à la plus forte présence des gens à leur domicile le weekend durant la matinée, la première pointe est en moyenne 200 kW plus importante que celle de la semaine, la période pleine qui suit est elle aussi plus haute que pendant les jours ouvrables.

La différence entre la semaine et le weekend n'est pas la seule variation temporelle notable de la courbe de charge résidentielle. En fonction des saisons, on va retrouver des modulations de puissance de la courbe de charge. La consommation électrique étant thermo-sensible, il est logique de retrouver le niveau moyen de consommation le plus important sur la figure 6.4a. La figure 6.4d, représentant la courbe automnale de charge, présente des niveaux de consommation similaire. Cependant la pointe du soir est moins élevée (-100 kW) et on remarque un plus grand EIQ autour de cette pointe qu'en hiver : si il est possible d'avoir des températures douces en automne, les températures hivernales sont moins variables. Concernant la courbe de puissance moyenne de la charge sur une journée printanière (voir figure 6.4b), on remarque le le niveau de consommation a globalement baissé quelque-soit le type de période : en période creuse, sur la première pointe et la période pleine on perd en moyenne 200 kW de puissance. La pointe soir, diminue elle de 600 kW par rapport à l'hiver et atteint un niveau proche de la pointe du milieu de journée. Finalement la courbe de charge en été, figure 6.4c, présente une forme similaire à la courbe du printemps tout en montrant une diminution globale de 100 kW. De plus, on remarque une très faible variabilité tout au long de la journée comparée aux autres saisons.

b) Courbe de production photovoltaïque

La courbe de charge a donc ses caractéristiques propres et notamment saisonnières, si l'on se penche sur la courbe de production PV, on peut aussi retrouver des particularités. De façon générale, la production d'une centrale photovoltaïque étant proportionnelle à l'éclairement, la courbe de

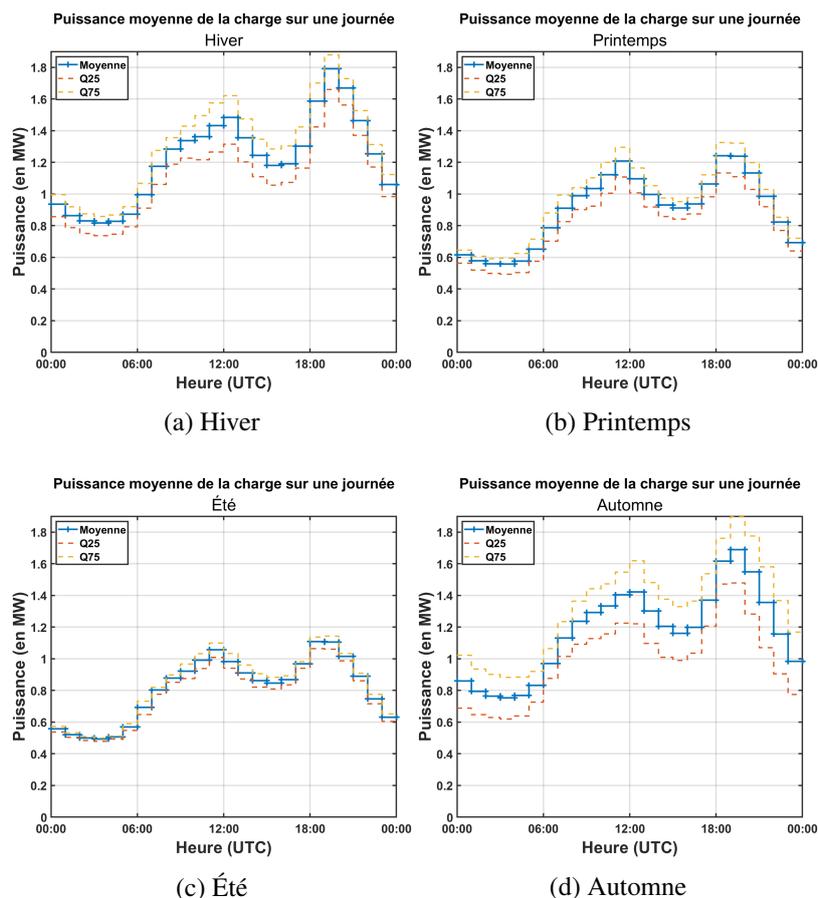


FIGURE 6.4 – Courbe de charge en fonction de la saison - moyenne, quantiles 25 et 75

production par temps dégagé prend la forme d'une hyperbole qui correspond à l'irradiance lumineuse par ciel clair. On remarque cette forme caractéristique sur les quatre graphes présentés dans la figure 6.5 ci-dessous.

Concernant la production lors des différentes saisons, on remarque sur la figure 6.5c que la production de la production atteint son maximum moyen sur la période estivale, c'est également le moment où la variabilité est la plus faible et garanti donc un niveau plus élevé de production. Le niveau moyen de la courbe au printemps n'est qu'un tout petit peu inférieur à celui de l'été mais la variabilité est plus grande. Ainsi le quantile 75% est plus haut qu'en été, les températures moins élevées du printemps étant plus favorables aux pics de production PV (voir figure 6.5b). Grâce à une orientation favorable pour cette saison (+20°, légèrement sud-ouest), les niveaux de production durant l'hiver affichés figure 6.5a ne sont pas très inférieurs à ceux des deux premières saisons citées. On observe cependant une plus grande variabilité durant cette saison avec un EIQ de près de 700 kW sur la puissance entre 11h et 12h. De plus, on remarque, tout comme pour la production automnale figure 6.5d, que l'amplitude journalière de production est réduite en commençant plus tard et en finissant plus tôt dans la journée. Pour la centrale étudiée, c'est en automne que la production moyenne est la plus faible en perdant entre 150 kW et 50 kW selon l'heure considérée.

Il faut cependant garder en tête que les courbes présentées sont des moyennes horaires, calculée sur les grandes périodes. La production PV à laquelle on peut s'attendre pour une journée quelconque et sur des intervalles temporels plus petits sera sensible aux conditions météorologiques et donc bien plus variable.

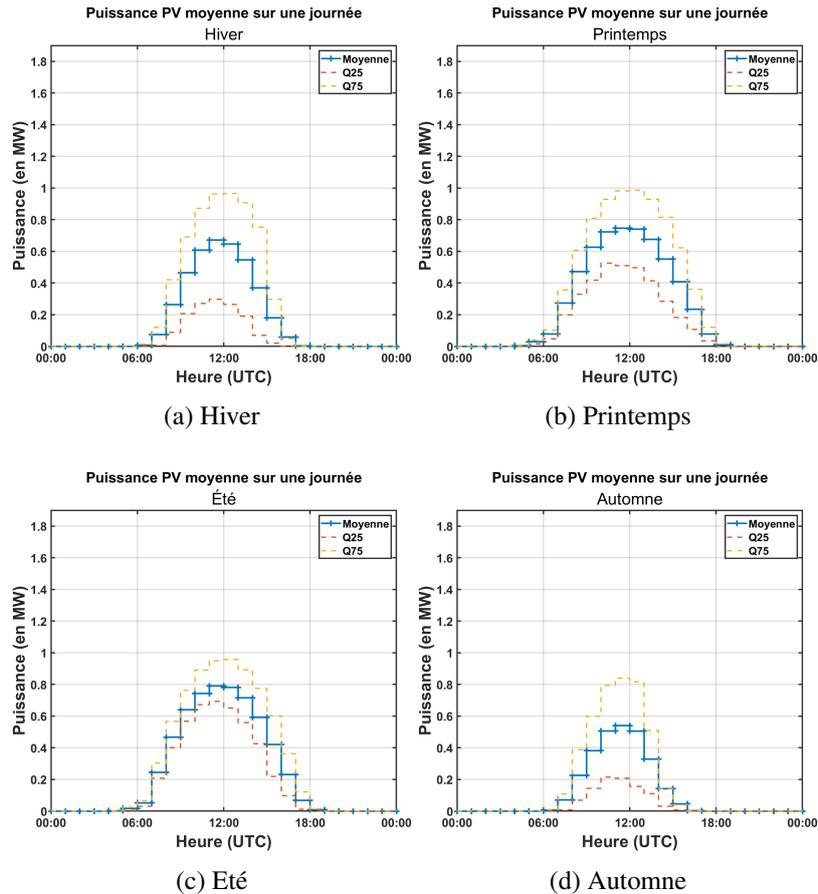


FIGURE 6.5 – Courbe de productible PV en fonction de la saison - moyenne, quantiles 25 et 75

6.1.3 Association d'une courbe de charge résidentielle et de production PV

Avant même d'étudier le fonctionnement du micro-réseau avec un système de stockage, il paraît primordial de se pencher sur la simple combinaison d'une courbe de charge et de production PV. En effet, injecter la puissance produite par la centrale à chaque instant dans notre micro-réseau a forcément des conséquences importantes sur la puissance de soutirage depuis le réseau de distribution. La section suivante se propose d'étudier cet effet.

Cet impact est illustré sur la figure 6.6 : pour deux journées données, la production photovoltaïque et la demande de la charge sont représentées séparément (figures 6.6a et 6.6c), puis agrégées (figures 6.6b et 6.6d) où la production PV vient se soustraire à la charge. La combinaison des deux séries temporelles, formant ici la *charge résiduelle*, produit globalement toujours le même effet dans des proportions différentes. La production PV étant élevée entre 7h et 17h, elle va donc donner une charge résiduelle bien plus faible que la charge sur la première pointe, ainsi on peut trouver environ 20% des valeurs maximales journalières durant la première pointe pour la charge mais aucune pour la charge résiduelle. Etant maximale au milieu de la journée pendant la période de charge pleine, elle va aussi fortement diminuer sa puissance et dans la plupart des cas atteindre des niveaux plus faibles que pendant la période creuse. Si l'on retrouve tous les minima journaliers avant 5h pour la charge, on en trouve plus que 25% pour la charge résiduelle. Cela mène très souvent à une augmentation de l'amplitude journalière par rapport à la courbe de charge initiale (dans 77% des cas). Pour la première journée représentée on passe ainsi d'une amplitude de 500 kW au double, mais ce n'est pas toujours le cas comme le montre la deuxième journée, où le productible PV vient seulement effacer une partie de la première pointe.

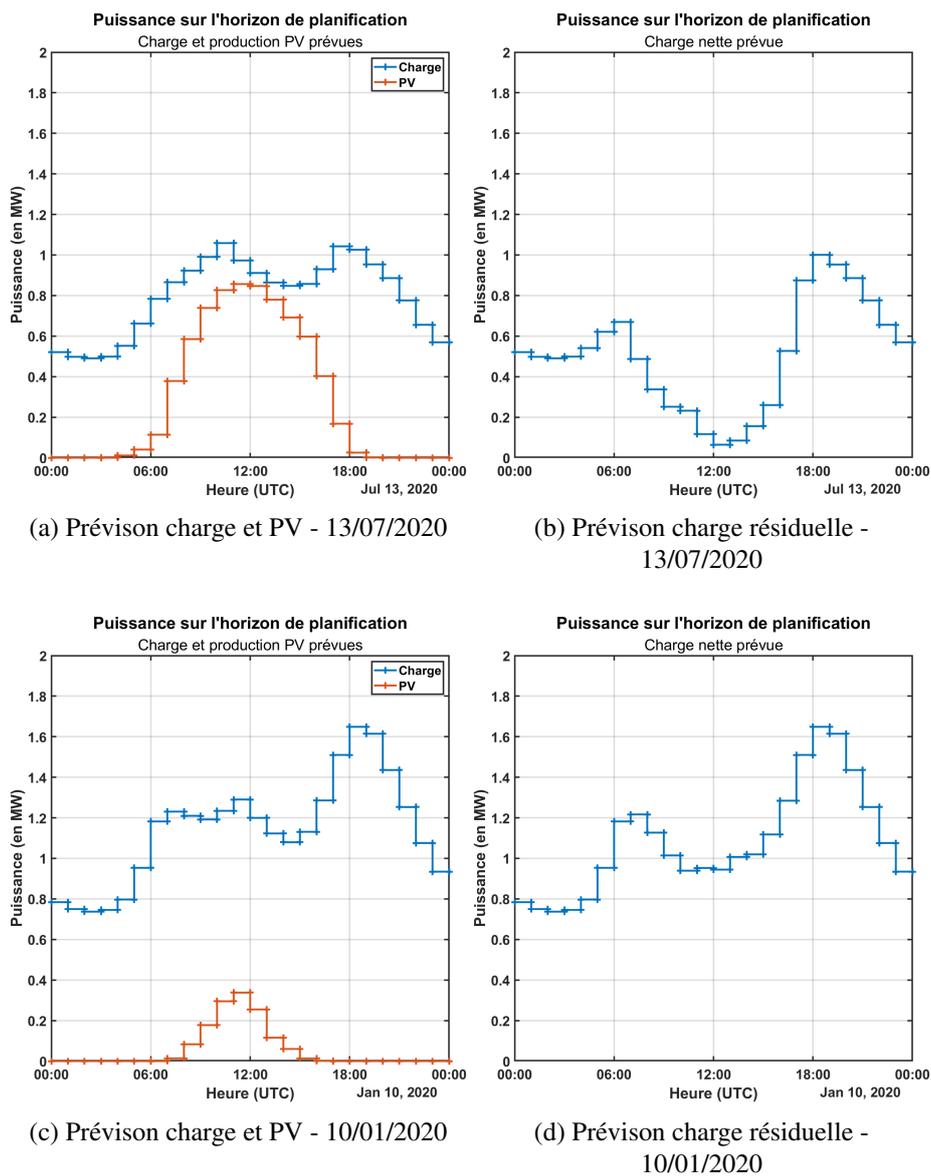


FIGURE 6.6 – Exemples de prévisions de charge et de productible PV

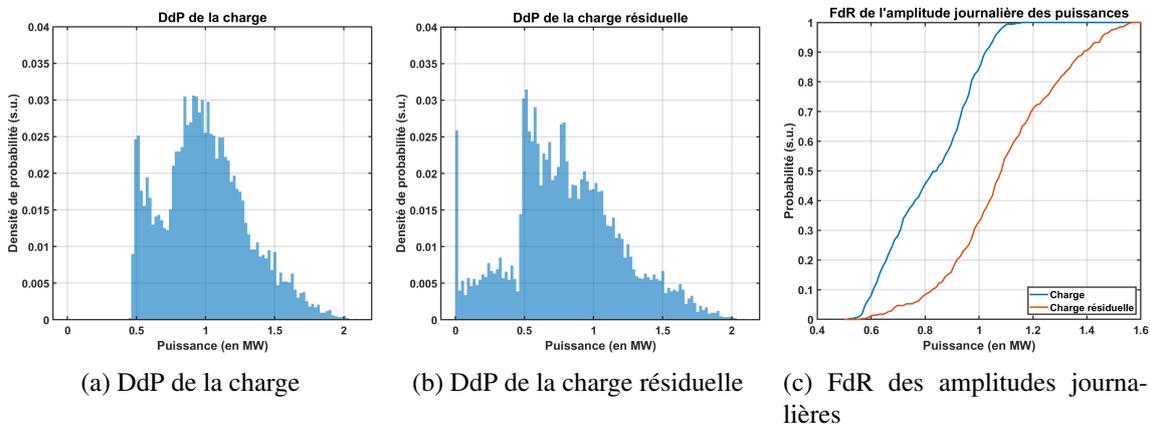


FIGURE 6.7 – Distributions de la charge et de la charge résiduelle ainsi que de leur amplitude

La figure 6.7 illustre très bien les phénomènes décrits précédemment sur l'ensemble des données. Ainsi les figures 6.7a et 6.7b nous montrent respectivement les densités de probabilité de la puissance de charge et de charge résiduelle. Ainsi on observe sur la seconde distribution l'apparition de valeurs inférieures à 500 kW jusqu'à une charge résiduelle nulle et la densité se décalant vers zéro. Cependant les valeurs élevées de la distribution (supérieures à 1,5 MW), correspondant à la pointe du soir, voient leur densité peut modifiée. Ces deux effets combinés vont donc mener à une augmentation de l'amplitude journalière : la figure 6.7c montre ainsi que la valeur médiane de l'amplitude journalière est augmentée de près de 250 kW entre la charge et la charge résiduelle. De plus on remarque que l'amplitude avait une probabilité de 15% d'être supérieur à 1 MW pour la charge alors qu'elle est de plus de 65% pour la charge résiduelle.

Puissance moyenne de la charge résiduelle sur une journée
Global

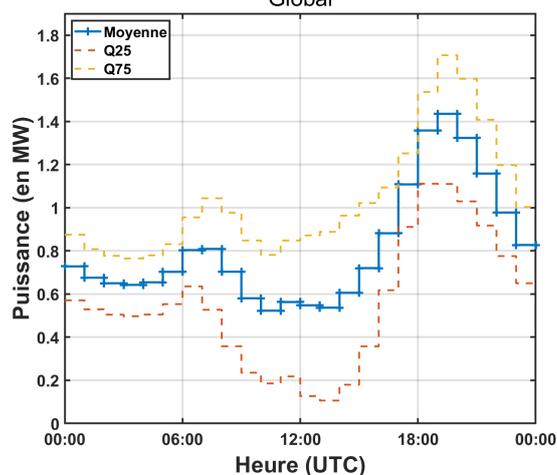


FIGURE 6.8 – Courbe moyenne de charge résiduelle - moyenne, quantiles 25 et 75

Finalement, l'aggrégation des courbes de charge et de production est représentée au global figure 6.8. Si on la compare à son équivalent pour la charge uniquement (figure 6.3a), la différence illustre bien la très forte baisse de la puissance pendant la pointe de la fin de matinée ainsi que sur la période pleine, où les valeurs moyennes sont plus faibles que sur la période creuse. De plus, on remarque que l'EIQ maximal est passé de la pointe du soir (600 kW) au moment où la production PV est la plus importante. Pour conclure la comparaison sur l'agrégation des deux courbes, par rapport à la charge, la variabilité de la charge résiduelle a augmenté et la forme de la courbe a également beaucoup changé avec notamment une augmentation de l'amplitude et un déplacement du minimum.

6.1.4 Le rôle du pilotage de la batterie et du micro-réseau

Pour contrebalancer les effets évoqués dans la section précédente, une batterie peut être ajoutée au système afin de stocker une partie de la puissance produite lors du pic de production PV et de la restituer à d'autres moments de la journée, notamment durant la pointe du soir. Il est aussi possible de limiter cette augmentation de l'amplitude avec certaines contraintes sur la puissance de soutirage spécifiques au réseau fixées dans le problème de planification (voir section 6.3.2).

La combinaison de l'énergie photovoltaïque et de la batterie peut permettre de tirer le meilleur de cette source d'énergie : la production photovoltaïque est une source d'électricité à faible teneur en carbone et disponible localement. Cependant sa production est maximale au zénith du soleil, vers midi, alors que le pic de la demande dans la courbe de demande résidentielle typique se situe dans la soirée. Ainsi, l'utilisation de la flexibilité de la batterie, c'est-à-dire sa capacité à stocker et à déstocker l'énergie électrique, peut donc aider à déplacer l'énergie des heures de faible demande vers les heures de pointe et à réaliser des arbitrages économiques concernant le prix de l'électri-

ité, qui varie tout au long de la journée. La batterie pourrait également compenser l'incertitude de la production d'énergie photovoltaïque et modifier la trajectoire de soutirage depuis le réseau pour minimiser les écarts engendrés par les aléas. Cependant, les batteries sont des installations de stockage complexes; il est donc primordial de maîtriser et d'anticiper leur contrôle, en particulier pour maintenir la longévité de leurs performances.

6.1.5 Hypothèses simplificatrices

Dans notre périmètre d'étude on s'intéresse aux grandeurs qui sont valorisées financièrement sur un réseau électrique, à savoir la puissance active. C'est donc les flux de cette dernière entre les différentes entités du système que nous allons considérer. La modélisation du réseau électrique est ainsi simplifiée : les contraintes et variables de contrôle d'un réseau électrique (tension, intensité, fréquence, etc.) ne sont pas considérées. On se préoccupe donc uniquement des équilibres de puissance active dans ce micro-réseau et on néglige les pertes et congestions liés aux transits de puissance dans un réseau électrique. Cette hypothèse permet d'agrèger les différentes entités en un point du réseau.

La préoccupation de notre problème de planification est donc finalement d'optimiser des flux de puissances sur différents pas de temps, soit les échanges d'énergies entre les entités du système sur un horizon donné au regard des objectifs que l'on se donne.

6.1.6 Conventions

Dans notre cas d'étude, on utilisera la convention du producteur : la puissance électrique sera positive si elle est produite et négative si elle représente une consommation. Cette convention déclinée pour chaque entité du micro-réseau dans le tableau 6.2 ci-dessous.

	≤ 0	≥ 0
Réseau	Injection	Soutirage
Consommateurs	Charge	
PV		Production
Batterie	Charge	Décharge

TABLEAU 6.2 – Convention de signe pour la puissance de chaque entité du système

Si l'on transpose cette convention aux écarts de soutirage..

6.2 Modèles des entités

Comme évoqué précédemment, on utilise pour le problème de planification un modèle de programmation linéaire en nombres entiers (PLNE). L'utilisation de ce type de modèle nécessite une formulation bien précise : on utilise des variables continues et entières ainsi que leurs combinaisons linéaires pour mettre notre problème sous forme d'équations. Les **variables** seront représentées en gras pour les différencier des paramètres dans la formulation du problème.

6.2.1 Charge

Dans notre problème de planification la puissance de la charge n'est pas une variable pouvant être choisie (charge non délestable, ni flexible) c'est un paramètre : elle ne varie jamais par rapport à son niveau, noté P_k^{Charge} .

6.2.2 Centrale PV

La centrale PV peut être modélisée grâce à plusieurs variables. A chaque instant, la centrale photovoltaïque possède un potentiel productible, qui représente ce qu'elle pourrait produire au maximum $P^{PV,potentiel}$, pour les conditions météorologiques données. Or il est possible d'ajuster sa puissance produite par la centrale, cependant il est uniquement possible de limiter la puissance par rapport au potentiel maximal de production.

Il n'y a qu'une contrainte sur la puissance photovoltaïque, qui permet cette opération : une réduction volontaire de la puissance de la centrale électrique, limitant la puissance photovoltaïque de zéro à sa valeur prévue.

$$0 \leq \mathbf{P}_k^{PV} \leq P_k^{PV,prévu} \quad (6.1)$$

6.2.3 Stockage

Le système de stockage d'énergie électrique est lui modélisé grâce à plusieurs variables et contraintes. En premier lieu, on considère que deux variables définissent l'état de la batterie à chaque intervalle :

- La puissance délivrée ou absorbée, $\mathbf{P}_k^{Batterie}$, possédant un maximum et un minimum.
- L'état de charge de la batterie, $\mathbf{SoC}_k^{Batterie}$, possédant également un maximum et un minimum.

La première équation (6.2) régit l'évolution de l'état de charge de la batterie en reliant les variables de puissance et d'état de charge, tout en tenant compte de l'efficacité des opérations de la batterie. Le calcul du rendement dépendant du signe de la puissance de la batterie, il justifie l'usage de deux variables distinctes pour la charge et la décharge du système de stockage. Les contraintes (6.3), (6.4) et (6.5) sur la batterie garantissent que la batterie ne puisse pas se charger et se décharger en même temps, en utilisant une variable binaire $\mathbf{B}_k^{Batterie}$ ($\in \{0, 1\}$), tout en garantissant que la puissance de la batterie reste bornée par ses valeurs minimales et maximales. Finalement l'équation 6.6 permet de borner l'état de charge de la batterie entre $SoC_{max}^{Batterie}$ et $SoC_{min}^{Batterie}$.

$$(\mathbf{SoC}_{k-1}^{Batterie} - \mathbf{SoC}_k^{Batterie}) = \frac{\mathbf{P}_k^{Batterie,décharge}}{\rho_{décharge}} + \rho_{charge} \times \mathbf{P}_k^{Batterie,charge} \quad (6.2)$$

$$\mathbf{P}_k^{Batterie} = \mathbf{P}_k^{Batterie,charge} + \mathbf{P}_k^{Batterie,décharge} \quad (6.3)$$

$$-P_{max}^{Batterie,charge} \times \mathbf{B}_k^{Batterie} \leq \mathbf{P}_k^{Batterie,charge} \leq 0 \quad (6.4)$$

$$0 \leq \mathbf{P}_k^{Batterie,décharge} \leq P_{max}^{Batterie,décharge} \times (1 - \mathbf{B}_k^{Batterie}) \quad (6.5)$$

$$SoC_{max}^{Batterie} \leq \mathbf{SoC}_k^{Batterie} \leq SoC_{min}^{Batterie} \quad (6.6)$$

6.3 Stratégies de planification

Avec seulement une certaine connaissance de l'état du micro-réseau (état de charge de la batterie notamment) et du futur (prévision et éventuellement son incertitude sous-jacente) comme paramètres sur un horizon de deux jours, la méthode de planification a pour objectifs :

- Définir des trajectoires pour chaque entité du système : soutirage depuis le réseau et donc achats d'énergie correspondants, charge et décharge de la batterie, réduction de la puissance photovoltaïque. De plus, cette anticipation doit garantir le respect de certaines contraintes comme les contraintes techniques relatives à chaque composant (voir section 6.2).

- Minimiser les coûts d'exploitation du système : la méthode d'optimisation est capable de faire des compromis entre les différents moments de la journée en fonction des prix de l'énergie.
- Fournir des services systèmes au gestionnaire du réseau de distribution (GRD) : réduire l'amplitude journalière de la puissance de soutirage et avoir une puissance constante en période de pointe. En effet, pour un GRD, plus la courbe de puissance des différents points de soutirage est plate plus il sera aisé de gérer et anticiper le fonctionnement du réseau.

On a vu précédemment l'intérêt de piloter les différentes entités du micro-réseau étudié. Il est primordial de déterminer selon quels critères on définit les trajectoires que l'on souhaite suivre. Pour cela on distingue :

- D'une part l'ensemble des trajectoires réalisables, c'est à dire les valeurs des variables qui respectent les contraintes définies.
- D'autre part on définit une trajectoire *optimale* parmi les trajectoires réalisables. La définition de son optimalité est cependant relative à certains critères.

C'est donc l'objet de la section suivante : selon quels critères définir la trajectoire *optimale* des entités du micro-réseau ?

6.3.1 Critère économique

Dans notre cas le critère sera économique : on souhaite trouver la trajectoire qui minimise le coût d'opération du système. Ici, ce coût est lié à l'achat de l'énergie soutirée depuis le réseau de distribution. Le prix de l'énergie électrique soutirée est variable en fonction du temps. Dans notre cas d'étude, il est corrélé à la demande : plus il y a de demande, plus le prix est élevé et inversement en cas de demande faible. On affecte donc à la puissance soutirée un prix de l'énergie pour chaque intervalle de temps, ce qui nous permet finalement d'obtenir le coût de fourniture de l'énergie pour chaque intervalle et pour l'horizon considéré en sommant, comme le montre l'équation 6.7.

$$Coût = \sum_{k=1}^K \mathbf{P}_k^{\text{Réseau}} \times \text{Prix}_k^{\text{Réseau}} \times \Delta T_k \quad (6.7)$$

Dans notre problème le prix a été divisé en trois types de périodes :

- Période creuse : la nuit de 21h à 8h,
- Première période de pointe : de 8h à 13h,
- Période pleine : la journée de 13h à 17h
- Deuxième période de pointe : de 17h à 21h,

Ce découpage et ces niveaux de prix sont basés sur la tarification réglementée de l'électricité. Plus précisément, les différentes périodes sont celles définies dans le [Tarif d'Utilisation des Réseaux Publics d'Electricité \(TURPE\)](#). Le prix de référence utilisé ici est celui du [Tarif Réglementé de Vente d'Electricité \(TRVE\)](#) fixé en février 2021 soit 18,0 ct/kWh et les niveaux des différentes périodes ont été fixés pour refléter l'équilibre offre-demande, plus la demande est élevée, plus le prix l'est aussi. La courbe journalière des prix est présentée figure 6.9, les lignes verticales permettent de délimiter les différentes zones de prix et seront présentes sur tous les graphiques liés à la planification.

Pour les besoins de la formulation des contraintes sur le soutirage on divise les intervalles de temps considérés dans le problème en deux types :

- Ensemble K_{pointe} : cet ensemble contient lui-même deux sous-ensembles distincts (d'indice i) regroupant les intervalles correspondants aux périodes de pointes.

$$K_{\text{pointe}} = K_{\text{pointe},1} \oplus K_{\text{pointe},2}$$

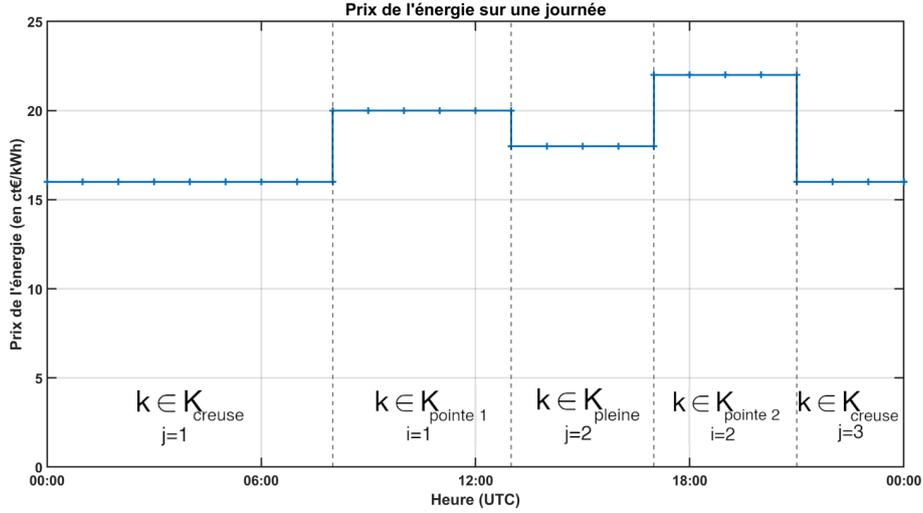


FIGURE 6.9 – Courbe journalière des prix de l'énergie

- Ensemble $K_{hors-pointe}$: cet ensemble contient lui même trois sous-ensembles distincts (d'indice j) regroupant les intervalles correspondants aux périodes hors des pointes. Chaque $K_{hors-pointe,j}$ étant associé à une période : $K_{creuse,1} = K_{hors-pointe,1}$, $K_{pleine} = K_{hors-pointe,2}$, $K_{creuse,2} = K_{hors-pointe,3}$.

$$K_{hors-pointe} = K_{hors-pointe,1} \oplus K_{hors-pointe,2} \oplus K_{hors-pointe,3}$$

6.3.2 Contraintes sur la puissance soutirée

Nous avons constaté dans la section 6.1.3, les effets de combiner production PV et charge sur le soutirage depuis le réseau avec notamment l'augmentation de l'amplitude journalière de la puissance. Pour palier cet effet un ensemble de contraintes a été mises en place.

a) Contrainte explicite

Une première approche contraignant explicitement l'amplitude journalière forme un groupe de trois contraintes. Les deux premières (6.8 et 6.9) permettent d'obtenir le maximum et le minimum des valeurs de soutirage et la dernière (6.10) permet de contraindre la différence de ces valeurs (donc l'amplitude) à l'amplitude de la charge.

$$P_k^{\text{Réseau}} \leq C_{\text{max}}^{\text{Réseau}} \quad (6.8)$$

$$P_k^{\text{Réseau}} \geq C_{\text{min}}^{\text{Réseau}} \quad (6.9)$$

$$\max_k(P_k^{\text{Charge}}) - \min_k(P_k^{\text{Charge}}) \geq C_{\text{max}}^{\text{Réseau}} - C_{\text{min}}^{\text{Réseau}} \quad (6.10)$$

b) Contrainte incitative

Un autre ensemble de contraintes a été mis en place de façon heuristique afin de d'inciter la diminution d'amplitude plutôt qu'uniquement laisser libre d'avoir une amplitude inférieure ou égale à l'amplitude initiale comme décrit dans la section 6.3.2.a ci-dessus.

La première contrainte (6.11) permet de contraindre la puissance de soutirage à être constante pendant les périodes de pointe. On remarquera qu'il y a autant de variables $C_{\text{pointe},i}$ que de périodes de pointes : la constante choisie pour les deux périodes ne sont pas forcément les mêmes. La

deuxième contrainte (6.12) s'assure qu'en dehors des périodes de pointe la puissance du réseau conserve la même forme que la série temporelle initial de la demande. Là aussi il y a autant de variables $C_{\text{hors-pointe},j}$ que de périodes hors-pointes.

$$P_k^{\text{Réseau}} = C_{\text{pointe},i}, \forall k \in K_{\text{pointe},i}, i \in \{1, 2\} \quad (6.11)$$

$$P_k^{\text{Réseau}} = C_{\text{hors-pointe},j} \times P_k^{\text{Charge}}, \forall k \in K_{\text{hors-pointe},j}, j \in \{1, 2, 3\} \quad (6.12)$$

Afin d'inciter économiquement la diminution de l'amplitude de soutirage, nous avons mis en place un dernier type de contrainte (6.13). Cette contrainte permet de s'assurer que la constante choisie pour chaque période de pointe ne soit pas inférieure au minimum de la période précédente. En effet si l'on diminue le minimum on augmente de fait l'amplitude. Les prix de l'énergie étant plus élevés sur les périodes de pointe, cet ensemble de contrainte va inciter à recharger la batterie pendant les périodes creuse ou pleine, soit quand la charge est faible ou l'énergie photovoltaïque maximale, et à la décharger lors des pointes, et donc à choisir les constantes $C_{\text{pointe},i}$ les plus faibles possible, ce qui diminuera le maximum de soutirage et donc l'amplitude.

$$C_{\text{pointe},i} \geq C_{\text{hors-pointe},j} \times \min_k P_k^{\text{Charge}}, \forall k \in K_{\text{hors-pointe},j}, (i, j) \in \{(1, 1), (2, 2)\} \quad (6.13)$$

Une dernière contrainte est formalisée pour s'assurer que la puissance du réseau est positive ou nulle pour qu'il n'y ai pas d'injection sur le réseau auquel est relié le micro-réseau.

$$P_k^{\text{Réseau}} \geq 0 \quad (6.14)$$

6.3.3 Formalisation du problème de planification

Nous avons présenté dans la partie (ref état de l'art), la forme canonique des problèmes d'optimisation. Si l'on a présenté certaines contraintes précédement, il manque des éléments pour que le problème de planification soit complètement défini et modélise le système étudié. Nous détaillerons la formulation selon deux approches : en premier lieu, déterministe et dans un second temps, stochastique.

a) Formulation Déterministe

Le problème de planification est formulé sous la forme d'un PLNE, contenant les contraintes définis précédement ainsi qu'une fonction objectif permettant relier ces contraintes à un critère d'optimalité (voir section 6.3.1). La fonction objective à minimiser est donc composée du coût d'achat de l'énergie du réseau, qui dépend de la puissance du soutiragedepuis le réseau à chaque instant, du prix de l'électricité et de la longueur du pas de temps.

$$\min \text{Coût}^{\text{Réseau}} = \min \sum_{k=1}^K P_k^{\text{Réseau}} \times \text{Prix}_k^{\text{Réseau}} \times \Delta T_k \quad (6.15)$$

Le modèle inclut également une dernière contrainte qui assure l'équilibre de puissance pour chaque pas de temps entre les entités du système :

$$P_k^{\text{Réseau}} + P_k^{\text{Charge}} + P_k^{\text{PV}} + P_k^{\text{Batterie}} = 0 \quad (6.16)$$

b) Formulation Stochastique

La différence entre l'approche stochastique et la déterministe : elle permet de considérer les aléas de la production PV. Si la formulation déterministe ne considère qu'un seul futur possible, l'aspect clé de l'approche stochastique est que si nous ne pouvons pas prédire exactement ce qui va se passer, nous pouvons décrire les probabilités des différents résultats possibles et ainsi fournir au problème différents scénarios envisagés ainsi que leur probabilité de réalisation associée. On décline donc le problème déterministe pour évaluer chaque scénario n , sauf pour la charge, sa valeur étant fixe.

$$\begin{aligned} \mathbf{P}_{k,1}^{\text{Réseau}} + P_k^{\text{Charge}} + \mathbf{P}_{k,1}^{\text{PV}} + \mathbf{P}_{k,1}^{\text{Batterie}} &= 0 \\ &\vdots \\ \mathbf{P}_{k,n}^{\text{Réseau}} + P_k^{\text{Charge}} + \mathbf{P}_{k,n}^{\text{PV}} + \mathbf{P}_{k,n}^{\text{Batterie}} &= 0 \end{aligned} \quad (6.17)$$

Le challenge de la formulation stochastique est donc d'envisager différents futurs possibles mais la prise d'une décision d'une seule trajectoire communes à tous les scénarios. Le micro-réseau n'ayant qu'une seule batterie et qu'un seul point de couplage avec le réseau principal, on souhaite ici choisir les variables $\mathbf{P}_k^{\text{Réseau}}$ et $\mathbf{P}_k^{\text{Batterie}}$ pour chaque pas de temps. Le problème devient donc :

$$\begin{aligned} \mathbf{P}_k^{\text{Réseau}} + P_k^{\text{Charge}} + \mathbf{P}_{k,1}^{\text{PV}} + \mathbf{P}_k^{\text{Batterie}} &= 0 \\ &\vdots \\ \mathbf{P}_k^{\text{Réseau}} + P_k^{\text{Charge}} + \mathbf{P}_{k,N}^{\text{PV}} + \mathbf{P}_k^{\text{Batterie}} &= 0 \end{aligned} \quad (6.18)$$

Or, ce système d'équations implique de tous les scénarios de production PV soient égaux sinon les équations ne peuvent être respectées. Il faut donc ajouter un degré de liberté au problème : on introduit alors la variable, $\Delta \mathbf{P}_{k,n}^{\text{Réseau}}$, qui va permettre de modéliser les écarts par rapport au plan prévu $\mathbf{P}_k^{\text{Réseau}}$ en fonction de chaque scénario, pour chaque intervalle de temps.

$$\Delta \mathbf{P}_{k,n}^{\text{Réseau}} = \mathbf{P}_{k,n}^{\text{Réseau}} - \mathbf{P}_k^{\text{Réseau}} \Leftrightarrow \mathbf{P}_{k,n}^{\text{Réseau}} = \mathbf{P}_k^{\text{Réseau}} + \Delta \mathbf{P}_{k,n}^{\text{Réseau}} \quad (6.19)$$

Finalement, si on remplace $\mathbf{P}_{k,n}^{\text{Réseau}}$ dans le système 6.17 par sa valeur modélisée avec écart (6.19), les équations bilans du modèle stochastique s'écrivent selon l'équation 6.20 ci-dessous.

$$\mathbf{P}_k^{\text{Réseau}} + \Delta \mathbf{P}_{k,n}^{\text{Réseau}} + P_k^{\text{Charge}} + \mathbf{P}_{k,n}^{\text{PV}} + \mathbf{P}_k^{\text{Batterie}} = 0 \quad (6.20)$$

La nouvelle variable $\Delta \mathbf{P}_{k,n}^{\text{Réseau}}$ permet à la fois d'équilibrer chaque équation bilan et mais également d'anticiper le coût des écarts dans la fonction objectif décrite ci-dessous (6.21). Pour résoudre ce problème, on va donc choisir d'une trajectoire qui permet de minimiser les coûts d'opération système, formés par les coûts de la trajectoire $\mathbf{P}_k^{\text{Réseau}}$ choisie et de l'espérance des écarts futurs.

$$\begin{aligned} \min \mathbb{E}[\text{Coûts}] &= \min \left(\text{Coût}^{\text{Réseau}} + \mathbb{E} \left[\text{Coût}^{\Delta \mathbf{P}^{\text{Réseau}}} \right] \right) \\ &= \min \left(\sum_{k=1}^K \left[\mathbf{P}_k^{\text{Réseau}} \times \text{Prix}_k^{\text{Réseau}} \times \Delta T_k + \sum_{n=1}^N \rho_n \times \text{Coût}_{k,n}^{\Delta \mathbf{P}^{\text{Réseau}}} \right] \right) \end{aligned} \quad (6.21)$$

On utilise ici l'estimation par la moyenne de l'échantillon, ou [Sample Average Estimation \(SAA\)](#), qui permet de résoudre un problème stochastique en espérance avec un recours (voir section 2.2.1).

De plus l'approche stochastique nécessite de mettre à jour certaines contraintes, notamment celles liées à la puissance de soutirage. En effet, l'objectif étant de diminuer l'amplitude de soutirage il est nécessaire d'intégrer la puissance des écarts à ces contraintes car il impacteront la puissance de soutirage simulée. Pour toutes les contraintes définies à la section 6.3.2 on ajoute l'espérance de la puissance des écarts à la puissance de soutirage :

$$P_k^{\text{Réseau}} \rightarrow P_k^{\text{Réseau}} + \sum_{n=1}^N \rho_n \times \Delta P_{k,n}^{\text{Réseau}} \quad (6.22)$$

6.4 Méthodologie d'évaluation des approches

Le but du problème de planification est d'anticiper le mieux possible l'opération du micro-réseau. En résolvant ce problème, on obtient donc des trajectoires pour chaque des entités. Pour juger de la qualité des résultats obtenus, ces trajectoires sont évaluées en simulant le fonctionnement du micro-réseau en les appliquant aux entités. On va donc simuler le pilotage du micro-réseau à l'aide de ces trajectoires jusqu'à la planification suivant. Au fur et à mesure de l'horizon temporel étudié, l'incertitude de la production solaire est levée car on peut observer le productible PV de la centrale à chaque instant. Cela nous donnera l'équation bilan suivante pour chaque intervalle de l'horizon :

$$P_k^{\text{Réseau,simulé}} + P_k^{\text{Charge}} + P_k^{\text{PV,observé}} + P_k^{\text{Batterie,prévu}} = 0 \quad (6.23)$$

Dans cette équation simulant l'opération du système, la trajectoire de la batterie étant fixée par la planification elle devient un paramètre au même titre que la puissance PV effectivement produite et la consommation électrique. Il ne restera donc plus qu'un degré de liberté dans ce bilan : la puissance soutirée depuis le réseau de distribution. C'est ainsi qu'on observera des écarts entre la trajectoire de soutirage prévue et la trajectoire simulée. On souhaite que la planification soit respectée du mieux possible lors de l'opération du système, on voudra ainsi minimiser et donc pénaliser ces écarts.

$$\Delta P_k^{\text{Réseau}} = P_k^{\text{Réseau,prévu}} - P_k^{\text{Réseau,simulé}} \quad (6.24)$$

6.4.1 Coût des écarts

Après avoir défini comment les écarts étaient obtenus, il nous faut donc définir un prix pour obtenir le coût de ses écarts par rapport au plan prévu. Notre approche de pénalisation est la suivante et est relative au prix de l'électricité de l'intervalle correspondant :

- Pour un écart à la hausse (positif) : cela signifie que l'on soutire plus de puissance depuis le réseau que prévu. Il faut donc racheter de l'énergie par rapport au plan défini par la planification. Pour que cette différence entre le plan et la réalisation de l'opération du réseau soit pénalisé, on définit un prix d'achat plus élevé que si l'énergie avait été achetée au moment de la planification. On définit ce tarif pénalisé comme une augmentation relative du tarif d'achat initial (+10% dans le cas de référence).
- Pour un écart à la baisse (négatif) : cela signifie que l'on soutire moins de puissance depuis le réseau que prévu. On se retrouve ainsi avec un engagement de soutirage sur le réseau mais on n'a finalement pas besoin de cette énergie : il va donc falloir s'en débarrasser. On va donc revendre « virtuellement » l'énergie que l'on s'était engagé à soutirer. Pour que cette revente soit pénalisée elle est revendue moins cher qu'elle avait été achetée (-10% dans le cas de référence).

Le prix des écarts (et donc leur coût) va donc dépendre de leur signe. Finalement le coût des écarts en de leur puissance et de leur signe, modélisé dans le problème de planification sous la

forme de deux équations (6.25 et 6.26), peut être représenté figure 6.10. On notera que ce modèle du coût des écarts permet de conserver la convexité de l'ensemble des solutions admissibles.

On peut donc formaliser le coût des écarts dans le problème de planification grâce à deux équations :

$$\text{Coût}_{k,n}^{\Delta P^{\text{Réseau}}} \geq \Delta P_{k,n}^{\text{Réseau}} \times \text{Prix}_k^{\Delta P \geq 0} \times \Delta T_k \quad (6.25)$$

$$\text{Coût}_{k,n}^{\Delta P^{\text{Réseau}}} \geq \Delta P_{k,n}^{\text{Réseau}} \times \text{Prix}_k^{\Delta P \leq 0} \times \Delta T_k \quad (6.26)$$

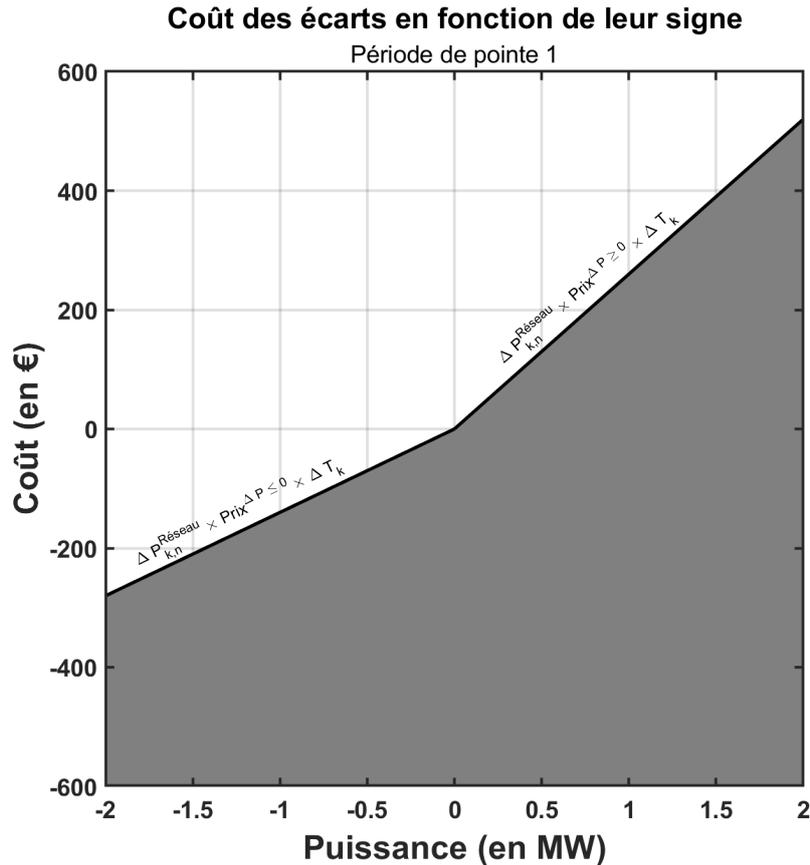


FIGURE 6.10 – Courbe représentative du calcul du coût des écarts (ici pour une pénalité de 20% :

$$\text{Prix}_k^{\Delta P} = (1 \pm 20\%) \times \text{Prix}_k^{\text{Réseau}}$$

6.4.2 Contrainte de soutirage

Comme nous ajoutons des contraintes sur la puissance soutirage depuis le réseau lors de la planification, on souhaite mettre en place une méthode pour vérifier l'occurrence de leur respect après simulation.

Pour la première contrainte sur l'amplitude du soutirage, il suffit de calculer l'amplitude de soutirage simulée et de vérifier si elle respecte l'inégalité ci-dessous.

$$\max_k(P_k^{\text{Charge}}) - \min_k(P_k^{\text{Charge}}) \geq \max_k(P_k^{\text{Réseau,simulé}}) - \min_k(P_k^{\text{Réseau,simulé}}) \quad (6.27)$$

Pour la seconde contrainte sur le soutirage, à savoir, une puissance constante durant les période de pointe, on regardera la distribution et la quantité des écarts lors de ces périodes.

6.4.3 Autoconsommation

L'objectif d'autoconsommation est lui implicite mais peut-être vérifié simplement. Il faudra en effet calculer l'énergie totale soutirée depuis le réseau sur l'année simulée et la retrancher à l'énergie totale consommée sur le micro-réseau.

$$E_{Totale}^{Charge,autoconsommé} = E_{Totale}^{Charge} - E_{Totale}^{Réseau,simulé} \quad (6.28)$$

7

Résultats de la planification

Ce chapitre contient l'ensemble des résultats des simulations de planification : de l'illustrant de son intérêt à l'étude des ensembles de scénarios comme paramètre d'entrée en passant par la comparaison des approches stochastique et déterministe. Les deux contraintes mise en place ainsi que la mitigation des écarts sont également discutés.

Sommaire

7.1 Intérêt de l'anticipation et de la planification	128
7.1.1 Cas d'étude sans planification	128
7.1.2 Cas d'étude avec stockage et planification	131
7.2 Résultats de la planification déterministe	136
7.2.1 Focus sur certaines journées	136
7.2.2 Résultats globaux	148
7.3 Résultats de la planification stochastique	152
7.3.1 Focus sur certaines journées	152
7.3.2 Résultats globaux et comparaison avec l'approche déterministe	161
7.4 Influence du nombre de scénarios	165
7.5 Influence de la pénalité des écarts	167
7.6 Intérêt de la méthode de génération de scénarios	167
7.6.1 Prise en compte de la dépendance temporelle	167
7.6.2 Méthode de réduction de scénario	169
7.7 Conclusions, limites et perspectives	169

Ce chapitre, comme suite immédiate du précédent, permet de détailler les résultats du cas d'étude défini : la planification d'un micro-réseau sous incertitude. En premier lieu, nous discuterons de l'intérêt même de ce processus d'anticipation de l'opération d'un tel système, sujet aux aléas de la production d'énergie PV, contraint par le fonctionnement de ses entités mais également par ses interactions avec le réseau principal. Ainsi nous verrons que des modèles d'optimisation, déterministe ou stochastique, permettent de répondre à ces challenges tout en minimisant les coûts d'opérations. Par la suite, nous évoquerons les effets de l'ajout de contraintes sur la puissance de soutirage puis nous détaillerons les bénéfices de l'approche stochastique, notamment dans la gestion du risque et de son coût. Finalement, nous discuterons de l'apport des méthodes de génération détaillées dans la partie II comme données d'entrée de la planification.

7.1 Intérêt de l'anticipation et de la planification

Avant d'étudier l'intérêt de la planification du micro-réseau et plus particulièrement de la gestion d'un système de stockage, on s'attache à montrer l'importance d'une prévision de qualité.

7.1.1 Cas d'étude sans planification

Dans le cas du micro-réseau étudié, pour pouvoir annoncer un plan de soutirage la veille de chaque journée, il faut donc avoir une idée de la consommation électrique et de la production photovoltaïque futures. La consommation est considérée comme certaine et connue à l'avance (voir section 6.2.1), sans prévision PV disponible, la meilleure estimation possible est d'utiliser la production de la veille (modèle de persistance, noté P_{Pers}). Pour montrer ici l'intérêt de l'utilisation d'une prévision de meilleure qualité pour notre cas d'étude on simule donc le système avec deux prévisions différentes et en utilisant la persistance. De plus on pourra comparer l'utilisation d'une prévision déterministe et d'une prévision issue de la liste des quantiles à disposition (le quantile 50% pour chacun des intervalles considérés, noté Q_{50}). Afin d'avoir une référence, il sera aussi intéressant de connaître les résultats avec une prévision parfaite (P_{Parf}), c'est à dire avec les observations de production PV.

Le plan de soutirage est prévu selon l'équation 7.1 puis simulé selon l'équation 7.2. Dans les deux cas, on interdit l'injection vers le réseau et on module la puissance PV vers le bas en cas d'excès ($P_k^{CHARGE} \leq P_k^{PV}$). Les écarts sont ensuite calculés comme décrits dans le chapitre précédent section 6.4, équation 6.24.

$$P_k^{RÉSEAU,prévu} = P_k^{CHARGE} + P_k^{PV,prévu} \quad (7.1)$$

$$P_k^{RÉSEAU,simulé} = P_k^{CHARGE} + P_k^{PV,observé} \quad (7.2)$$

a) Coûts globaux d'opération

Les résultats de ces simulations sont présentés dans les tableaux 7.1 et 7.2 ci-dessous. Dans le premier, on présente tout d'abord les écarts totaux ainsi que leur signe et leur valeur absolue. Le second tableau permet de détailler le coût total, regroupant en fonction de la prévision utilisée le coût prévu et simulé puis celui des écarts, simulé à partir des observations du productible PV, tous deux présentés dans les colonnes qui suivent. Finalement, le tableau montre le coût des pénalités, qui indique l'écart de coût entre une simulation donnée et la simulation qui a été faite à partir d'une prévision parfaite. C'est les 10% de surcoût ou de manque à gagner du prix des écarts, ainsi ces pénalités sont toujours positives (voir section 6.4.1).

Premièrement, on remarque que les résultats entre les deux types de prévisions déterministes (P_{Det} et Q_{50}) sont très similaires. Deuxièmement, on s'aperçoit que les écarts totaux représentent une très faible part d'énergie totale soutirée (6,6 GWh), au maximum 1% pour la simulation avec

	Écarts totaux (en MWh)	Écarts positifs (en MWh)	Écarts négatifs (en MWh)	Écarts absolus (en MWh)
Q_{50}	+50,7	+180,5	-129,8	310,3
P_{Det}	+104,5	+220,6	-116,1	336,7
P_{Pers}	-9,0	+290,7	-299,7	590,4

TABLEAU 7.1 – Résumé des écarts des simulations sans planification avec différentes prévisions

	Coût total (en M)	Coût prévu (en M)	Coût des écarts simulés (en k)	Coût des pénalités (en k)
P_{Parf}	1,208	1,208		
Q_{50}	1,214	1,198	+15,865	5,846
P_{Det}	1,214	1,188	+25,966	6,325
P_{Pers}	1,219	1,209	+10,377	11,151

TABLEAU 7.2 – Résultats économiques des simulations sans planification avec différentes prévisions

P_{Det} , si l'on prend en compte les écarts absolus on monte à 7% pour la simulation à partir de la persistance. On observe également que le coût des écarts pour toutes les simulations est quasiment négligeable par rapport aux coûts totaux d'opérations. En effet, ils ne représentent pas plus de 2% des coûts totaux (voir tableau 7.2).

Entre les deux options de prévision disponibles, la différence est que sur l'ensemble de la période simulée la prévision déterministe sous-estime plus le productible PV (écart totaux de +104 MWh contre +50 MWh, voir tableau 7.1) cela entraîne donc des écarts globalement positifs et donc des achats supplémentaires d'énergie qui seront pénalisés. Cependant si l'on s'intéresse au montant des pénalités, on s'aperçoit qu'il n'y a que 500 d'écart entre les deux prévisions. Le coût des pénalités va être proportionnel aux écarts absolus de la simulation : on est pénalisé dès qu'il y a un écart, peu importe son signe. Les écarts absolus des deux prévisions comparées étant très proches il est donc logique de retrouver un montant similaire de pénalités.

Si l'on s'intéresse maintenant aux résultats de la prévision P_{Pers} , on note qu'elle a au global très légèrement surestimé la production photovoltaïque et entraîne donc plus d'écarts négatifs que positifs. Or, on remarque que le coût des écarts est lui bien positif : c'est l'illustration de l'effet des pénalités. Comme expliqué plus haut, ces pénalités sont proportionnelles aux écarts absolus, ceux du modèle de persistance étant pratiquement deux fois supérieurs à ceux des deux autres prévisions il n'est pas surprenant de constater leur impact sur le coût total de la simulation (+11 k).

Ces simulations montrent donc l'intérêt d'utiliser des prévisions qualitatives dans notre cas d'étude et permet également d'introduire les ordres de grandeurs des coûts d'opération du système ainsi que ceux des écarts. On remarque notamment la faible part qu'occupent ces derniers (avec leurs pénalités associées) dans le coût total, ce qui nous montre que les gains à faire dessus seront faibles.

b) Objectifs de soutirage

On s'intéresse dorénavant aux objectifs sur le soutirage : la réduction de l'amplitude et un soutirage constant pendant les périodes de pointe. Ces premières simulations ne présentant aucun degré de liberté pour agir sur ces deux contraintes, on ne peut donc que constater leur réalisation

au cours de la simulation.

Le tableau 7.3 ci-dessous présente les résultats sur l'amplitude du soutirage. On remarque que l'utilisation ou non d'une prévision n'a qu'une influence négligeable sur l'augmentation de l'amplitude journalière. Le respect de l'objectif est le même quelque soit la simulation et relativement faible (23%). Cela illustre bien le besoin de pilotage du micro-réseau afin de diminuer le taux d'occurrence d'augmentation de l'amplitude.

	Occurrence d'augmentation de l'amplitude (en %)	Médiane de l'amplitude journalière de soutirage (en kW)	Augmentation de la médiane l'amplitude journalière de soutirage (en kW)
P_{Parf}	77	1 083	+249
Q_{50}	77	1 090	+256
P_{Det}	77	1 093	+259
P_{Pers}	77	1 088	+254

TABLEAU 7.3 – Résultats sur l'amplitude de soutirage des simulations sans planification avec différentes prévisions

La figure 7.1 ci-dessous permet d'observer la distribution des écarts en fonction des périodes de prix. On remarque que les conclusions de la section précédente sur la différence de surestimation entre Q_{50} et P_{Det} sont vérifiées : cette dernière est légèrement plus optimiste et engendre plus d'écarts positifs. Le deuxième enseignement apporté par ce graphique est la distribution des écarts en fonction des différentes périodes. Ces derniers se concentrent naturellement pendant les périodes où le productible PV est le plus important, donc le plus sujet aux aléas. On remarquera notamment que la période de la première pointe est celle qui en regroupe le plus : ce qui peut être expliqué par sa durée conséquente (5h) et le fait qu'elle contienne la période de production maximale (zénith de la course du soleil). En revanche, les écarts sur la seconde période de pointe sont très réduits du fait de la faible présence de production PV à ce moment. On peut donc en déduire que l'objectif d'avoir un soutirage constant sera plus facile à respecter pour cette pointe que pour la première.

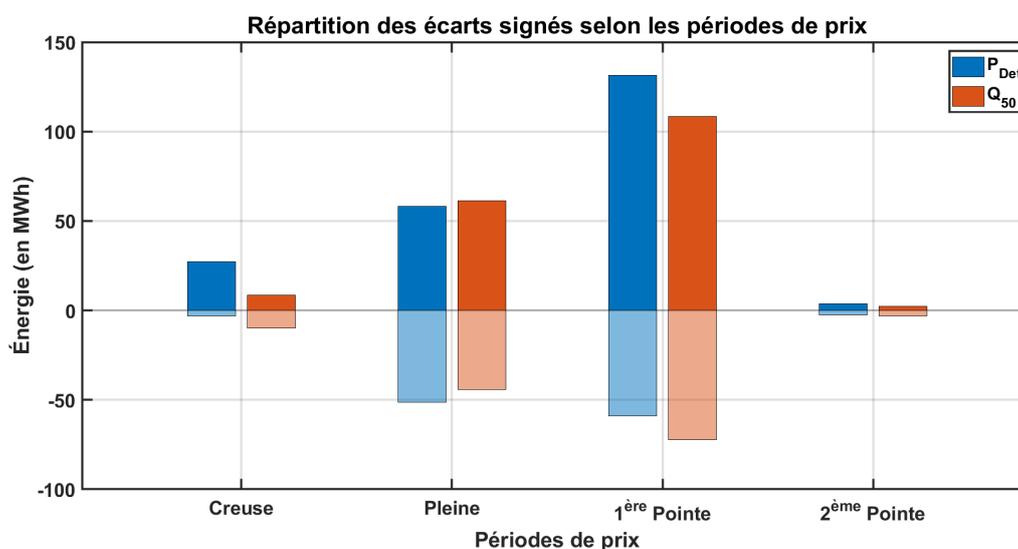


FIGURE 7.1 – Écarts à l'issue de la simulation sans pilotage

c) Autoconsommation

Pour comparer la quantité d'énergie soutirée par rapport à l'énergie de la charge, leur somme sur l'ensemble des simulations est représentée figure 7.2. On remarque que le productible PV permet, sans action de gestion particulière, d'augmenter l'autoconsommation sur la première période de pointe et la période pleine.

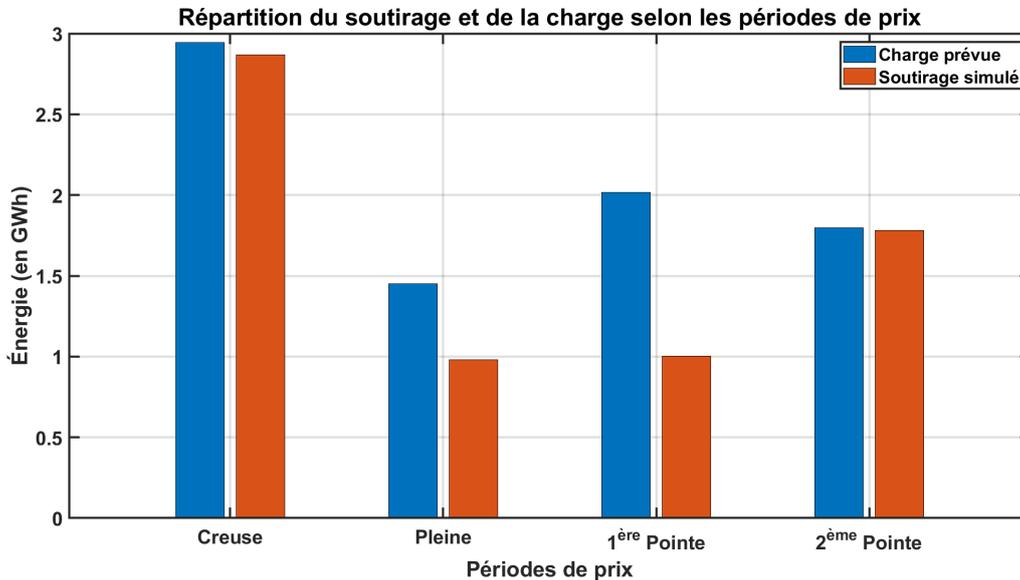


FIGURE 7.2 – Comparaison de l'énergie consommée et de l'énergie soutirée depuis le réseau - Sans planification

Si l'on regarde l'autoconsommation comme définie dans la section 6.4.3, les résultats obtenus par les différentes simulations sont les mêmes et pour une consommation totale de 8,207 GWh on obtient un soutirage de 6,634 GWh soit un taux de 19,2% d'autoconsommation.

7.1.2 Cas d'étude avec stockage et planification

De la même façon que dans la section précédente avec l'utilisation de prévisions qualitatives, on se pose la question de la pertinence de l'ajout d'un système de stockage et de la mise en place d'une méthode de planification sur un tel micro-réseau; avant même d'y intégrer des contraintes sur le soutirage ou une formulation stochastique permettant de prendre en compte les écarts futurs. On suppose que l'ajout d'une batterie permet de stocker de l'énergie sur l'horizon étudié va permettre de faire des arbitrages économiques entre certains moment de la journée et qu'une méthode de planification permet d'anticiper la gestion de ce stockage.

a) Coûts globaux d'opération

Les résultats globaux sont consignés dans les tableaux 7.5 et 7.1 ci-dessous. Ces derniers sont similaires aux tableaux de résultats des simulations précédentes, on y a juste ajouté le gain sur les coûts d'opérations globaux par rapport aux simulations sans planification.

Si l'on s'intéresse aux écarts en premier lieu, on remarque qu'il sont quasiment identiques aux simulations de la section 7.1.1. Cette similarité est naturelle : peu importe le fait d'utiliser une méthode de planification ou non, on se base sur une prévision donnée (P_{Det} ou Q_{50}), on sera donc exposé au même aléa dans les deux cas. En effet, on prend la décision d'un plan de soutirage à partir de la même information; lorsque la simulation sera réalisée, l'erreur de la prévision concernant la puissance PV effectivement produite et l'écart engendré sur le soutirage seront donc les mêmes. A la nuance près de la modulation PV vers le bas. Ainsi dans le premier cas (sans pilotage) cette

	Écart total (en MWh)	Écart positif (en MWh)	Écart négatif (en MWh)	Écart absolu (en MWh)
Q₅₀	+51,7	+181,2	-129,5	310,7
P_{det}	+104,7	+220,7	-116,0	336,7

TABLEAU 7.4 – Résumé des écarts des simulations de planification sans contraintes de soutirage

	Coût total (en M)	Gain par rapport à la simulation précédente (en %)	Coût prévu (en M)	Coût des écarts simulés (en k)	Coût des pénalités (en k)
P_{Parf}	1,196	-1,0	1,196		
Q₅₀	1,203	-0,9	1,187	+16,066	5,855
P_{Det}	1,203	-0,9	1,177	+26,002	6,325

TABLEAU 7.5 – Résultats économiques des simulations de planification sans contraintes de soutirage

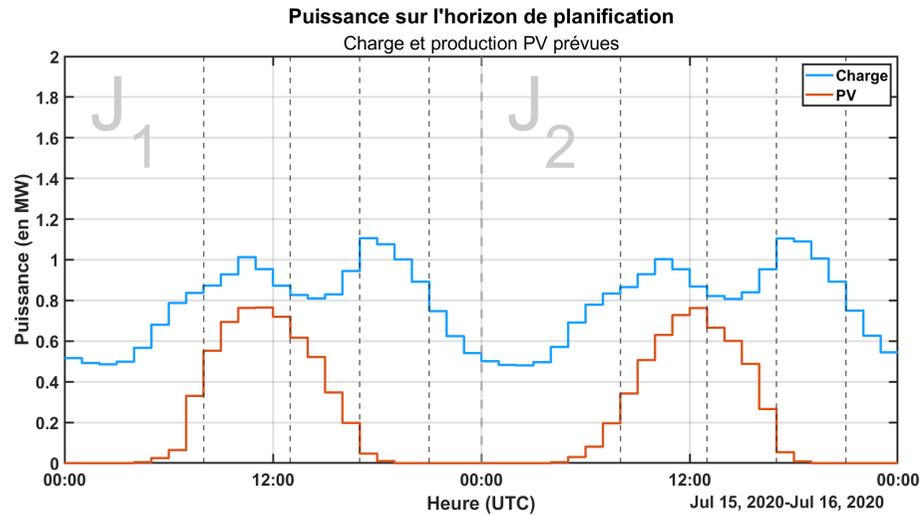
réduction de la puissance PV est subie dans les étapes de prévision et de réalisation du plan. Dans le cas où un système de stockage et une méthode de planification sont mis en place, la batterie permet d'encaisser des éventuels surplus de production et ne prévoit aucune diminution volontaire de production PV. Lors de l'étape de réalisation du plan décidé, où la puissance de la batterie est déjà fixée et ne peut donc pas absorber un éventuel surplus, la modulation est alors possible. La simulation avec planification va donc mener à prévoir moins de modulation vers le bas du PV et donc à plus utiliser d'énergie PV au global. Or si l'on utilise plus de PV, on s'expose à plus d'aléas et donc d'écarts, d'où cette très légère différence. On notera malgré tout que cela concerne seulement quelques MWh sur l'ensemble des simulations.

Dans un second temps, on remarque que le pilotage améliore les coûts totaux dans tous les cas, nous allons voir dans la section suivante l'origine de ces gains. Ce gain reste cependant très faible relativement aux coûts d'opérations totaux. Quant à lui, le coût des écarts bouge très peu pour chaque simulation, il n'y a en effet pas de moyen pour diminuer ces contingences (cf. paragraphe ci-dessus).

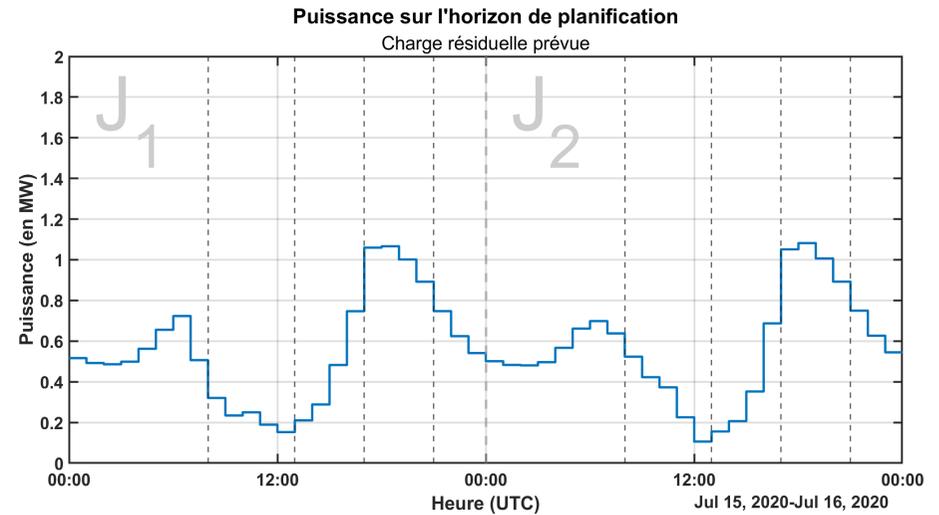
Arbitrages économiques grâce à la batterie

La figure 7.3 résume les différentes prévisions et trajectoires issues de la planification pour un horizon donné. Les prévisions de charge, de puissance PV et de charge résiduelle sont d'abord présentées figures 7.3a et 7.3b. On peut ensuite observer le plan de la batterie sur la figure 7.3c : la stratégie retenue consiste à recharger la batterie sur la période creuse afin de bénéficier du tarif le plus bas de la journée puis de décharger l'intégralité de son stock lorsque l'énergie est la plus chère, soit lors de la deuxième pointe. On note l'impact de cette stratégie sur le soutirage prévu sur la figure 7.3d : un pic de soutirage pendant la période creuse (400 kW plus élevé que la valeur maximum de la charge) et un creux de soutirage pendant la seconde pointe (quasiment 500 kW plus faible que la valeur minimum de la charge).

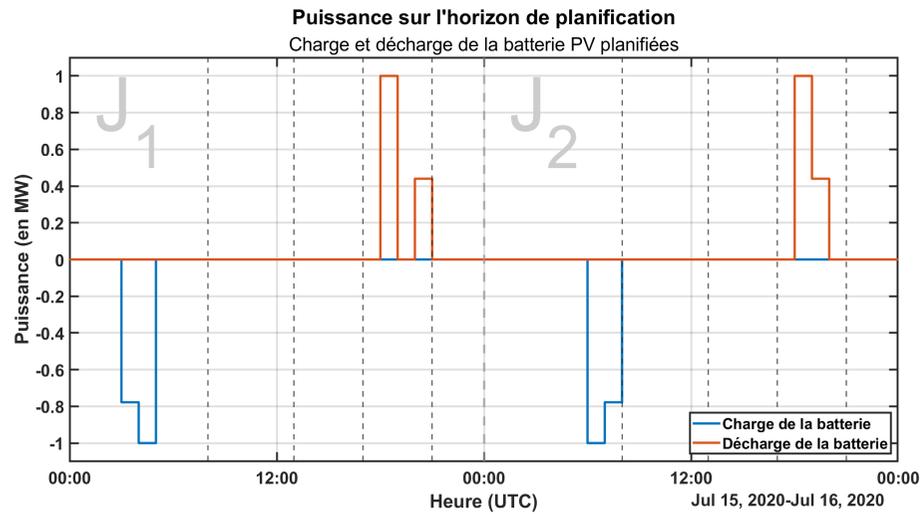
Sur cette journée, les coûts d'opération sont de 2 739 contre 2 771 pour la simulation sans planification ni stockage, soit un gain de 32 (1,2%). Les résultats globaux sur les gains journaliers globaux sont consignés dans le tableau 7.6. Ce sont donc 78% des journées simulées avec une planification à partir d'une prévision qui ont un meilleur coût d'opération. Le gain sur la médiane du coût journalier est d'environ 32 ce qui représente moins de 1% de ce coût journalier.



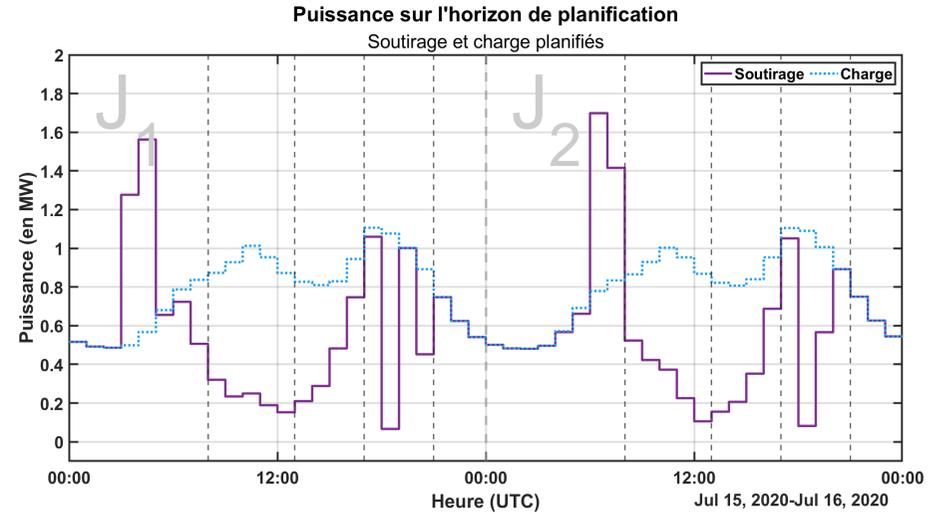
(a) Charge et PV prévus



(b) Charge résiduelle prévue



(c) Puissance prévue de la batterie



(d) Plan de soutirage et charge prévus

FIGURE 7.3 – Résumé des trajectoires issues de la planification à partir de Q_{50} - 15/07/2020

	Gain total (en k)	Gain journalier médian (en)	Part de jours de gain (en %)
P_{Parf}	12,356	32,4	78
Q_{50}	11,504	32,4	78
P_{Det}	11,399	32,4	78

TABLEAU 7.6 – Résumé des gains des simulations avec planification

L'énergie totale transitant dans la batterie en fonction de la zone de prix, représentée figure 7.4 nous montre bien que le fonctionnement de la batterie est similaire tous les jours simulés. Quasi systématiquement, elle stocke de l'énergie que le micro-réseau soutire durant la période creuse puis délivre l'énergie stockée pendant la seconde pointe. On notera qu'il y a extrêmement peu d'activité dans les deux autres zones de prix.

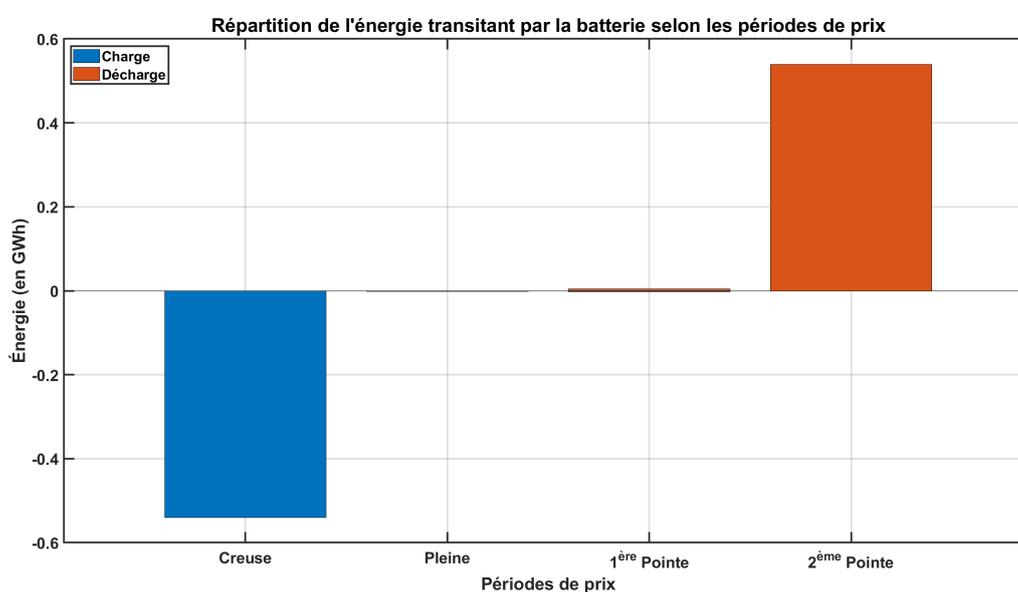


FIGURE 7.4 – Bilan de l'énergie transitant dans la batterie en fonction de la zone de prix pour la simulation de planification à partir de Q_{50}

b) Objectifs de soutirage

Le tableau 7.7 présente les résultats sur le respect de l'objectif d'amplitude de soutirage. Les résultats sont très similaires pour toutes les simulations avec une grande amplitude médiane et une forte augmentation de cette dernière par rapport à celle de la charge.

On remarque ainsi que la contrainte d'amplitude n'est jamais respectée dans le cas de la simulation avec la prévision parfaite et qu'elle est respectée dans une infime partie des deux autres simulations. Cela est lié au fonctionnement de la batterie induit par la construction du problème de planification. En effet, comme présenté dans la section précédente, pour notre système le meilleur moyen de diminuer son coût d'opération est de soutirer le moins possible lorsque le prix de l'énergie est le plus élevé et inversement lorsque le prix est le plus faible pour charger la batterie. Le fonctionnement de la batterie va donc être similaire pour toutes les journées simulées comme dans le cas présenté figure 7.3. De façon générale les points de soutirage extrêmes (maximum et minimum) sont modifiés (respectivement à la hausse et à la baisse) et cela entraîne donc une augmentation de l'amplitude journalière. Le cas de la figure 7.3d représente une situation où l'amplitude passe de 600 à 1 500 kW, soit une augmentation de 900 kW. C'est lors d'une période

	Occurrence d'augmentation de l'amplitude (en %)	Médiane de l'amplitude journalière de soutirage (en kW)	Augmentation de la médiane l'amplitude journalière de soutirage (en kW)
P_{Parf}	100	1 590	+756
Q₅₀	99,7	1 592	+758
P_{det}	99,7	1 593	+759

TABLEAU 7.7 – Résultats sur l'amplitude de soutirage des simulations de planification sans contraintes de soutirage

estivale, où l'amplitude est plus faible que pour les autres saisons (voir figure 6.4c), il est donc logique de trouver une augmentation conséquente par rapport à la médiane de l'amplitude sur toute la simulation.

c) Autoconsommation

Les différents résultats pour l'autoconsommation dans ces simulations sont présentés dans le tableau 7.8 ci-dessous.

	Énergie totale soutirée (en MWh)	Taux d'autoconsommation (en %)	Énergie totale transitant dans la batterie (en MWh)
P_{Parf}	6 633	17,7	548
Q₅₀	6 638	17,7	543
P_{Det}	6 640	17,7	542

TABLEAU 7.8 – Résumé de l'énergie totale soutirée et transitant dans la batterie pour les simulations de planification sans contraintes de soutirage

On observe que le taux d'autoconsommation a diminué de quelques pourcents par rapport aux simulations sans planification ni stockage. On peut expliquer cette tendance par l'utilisation de la batterie, ainsi à chaque fois qu'1 MWh transite par la batterie, il y aura des pertes de rendement, on aura donc besoin de soutirer plus d'1 MWh pendant la période creuse pour fournir 1 MWh de la charge pendant la pointe du soir. Ces pertes sont jugées viables économiquement car elle permettent de gagner plus qu'elles ne coûtent. On remarquera également que les résultats entre les trois simulations sont extrêmement similaires, ce qui illustre que peu importe la prévision utilisée, la planification entraîne la même gestion de la batterie que celle décrite dans la section 7.1.2.a plus haut.

Cette section nous a montré tout l'intérêt de l'utilisation d'un système de stockage ainsi que d'effectuer une planification. En effet, en modélisant la planification sous la forme d'un problème d'optimisation avec une fonction objectif à minimiser, on permet à la batterie à stocker et déstocker stratégiquement l'énergie au cours de l'horizon journalier considéré. En revanche, sans aucune contrainte formulé dans le problème, les objectifs secondaires (soutirage et autoconsommation), ne sont pas poussés à se réaliser, les résultats de la planification nous montrent que c'est même le contraire. C'est donc le but des contraintes que nous avons ajouté au modèle de planification (voir section 6.3.2), que nous allons étudier dans les sections suivantes.

7.2 Résultats de la planification déterministe

Cette section présente les résultats de la simulation de la planification déterministe, telle que modélisée dans la section 6.3.3.a et à partir d'une prévision déterministe comme paramètre d'entrée. Dans un premier temps, les résultats sont détaillés pour deux journées puis le bilan global sur l'ensemble des horizons temporels simulés est discuté.

7.2.1 Focus sur certaines journées

Afin de comprendre l'effet des contraintes définies sur la planification et sa simulation, on analyse les résultats sur des horizons de planification particuliers. Pour cela deux cas ont été sélectionnés :

- Une journée avec beaucoup de productible PV prévue, mais finalement à la baisse, ce qui entraîne des écarts positifs.
- Une journée avec peu de productible PV prévue, mais finalement à la hausse, ce qui entraîne des écarts négatifs.

a) Cas 1

Présentation du cas

La figure 7.5 ci-dessous représente les prévisions pour la première journée étudiée. Sur cet horizon de deux jours on retrouve une courbe de charge typique de l'automne avec une pointe du soir marquée et on remarque une pointe du midi plus importante sur la deuxième journée que sur la première. La courbe de productible PV attendue est quant à elle plutôt faible avec une puissance maximale de 400 kW sur l'horizon considéré. Si l'on regarde la courbe de charge résiduelle associée à ces deux précédentes prévisions, on remarque que l'impact de l'association des deux courbes se résume à une baisse de la puissance principalement sur la période de la 1^{ère} pointe.

Dans les sections suivantes, on se propose d'étudier les résultats de la planification en fonction des deux stratégies mises en place pour remplir nos objectifs économiques et sur la puissance de soutirage depuis le réseau. Pour cela les différentes trajectoires déterminées à partir des deux prévisions de la figure 7.5a sont présentées dans les figures 7.6 et 7.7, pour chacune des stratégies.

Stratégie avec contrainte explicite

Pour cette première stratégie de réduction de l'amplitude, on remarque tout d'abord que toute la puissance PV prévue est planifiée (voir figure 7.6b), étant plutôt réduite elle ne va pas pénaliser la contrainte de réduction de l'amplitude, il est donc logique de profiter de cette énergie dans le plan et de ne pas moduler sa puissance à la baisse. Le choix de la courbe de soutirage que l'on voit sur la figure 7.6a est donc complètement lié à la consigne de la batterie. On remarque une stratégie similaire pour les deux journées de l'horizon : on profite de la période creuse pour recharger la batterie afin de bénéficier de son prix avantageux et recharger entièrement la batterie, comme l'indique la trajectoire de son état de charge figure 7.6c. On note sur la figure 7.6a que la puissance soutirée utilisée pour stocker l'énergie dans la batterie est répartie sur la période creuse afin de ne pas augmenter l'amplitude journalière, à l'inverse de la planification sans contrainte (voir section 7.1.2.b).

A la suite de cette période vient la première pointe de la journée, et, pour maintenir un soutirage constant, on remarque que la puissance de la batterie suit donc celle de la charge résiduelle (voir figure 7.5b). Pour les deux journées de l'horizon, on note qu'à la suite de cette pointe du midi, la batterie est encore à un niveau de charge élevé (respectivement 90 et 73%). Ce stock d'énergie est

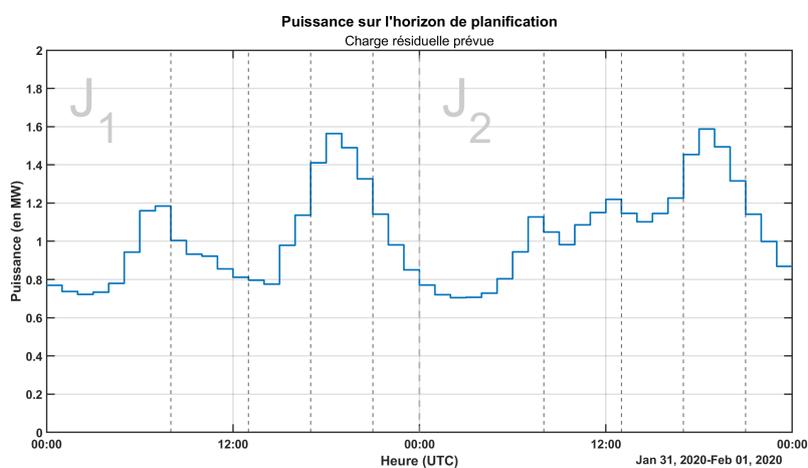
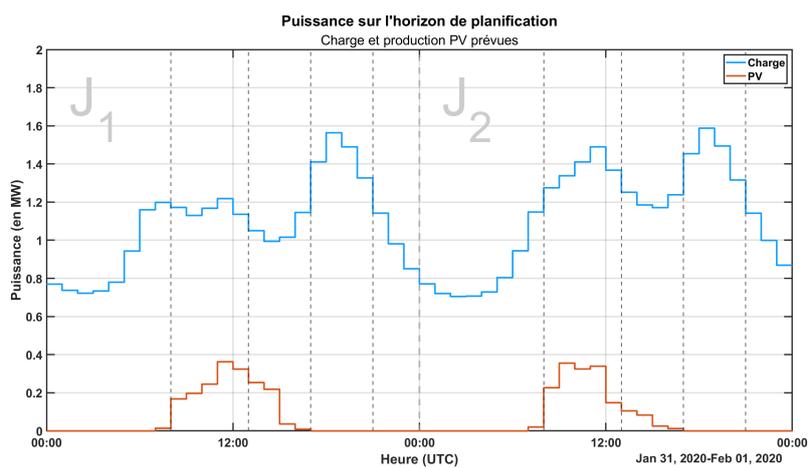
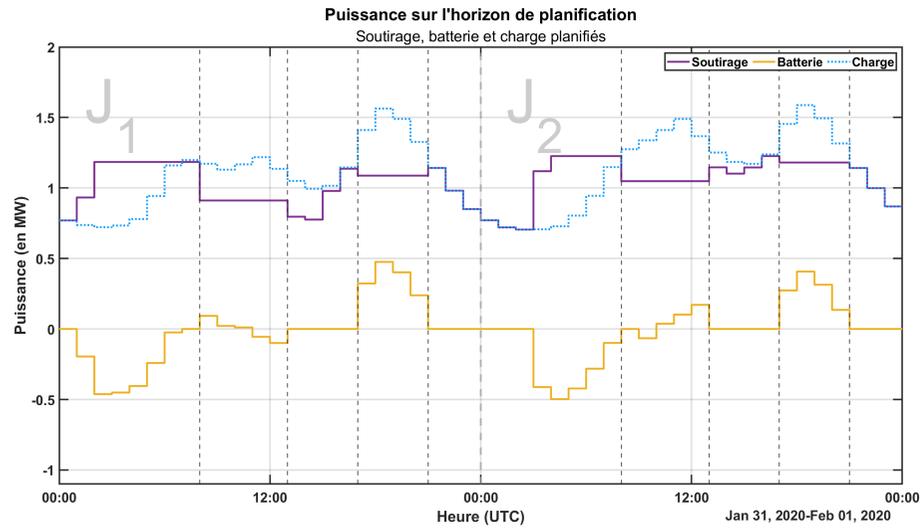


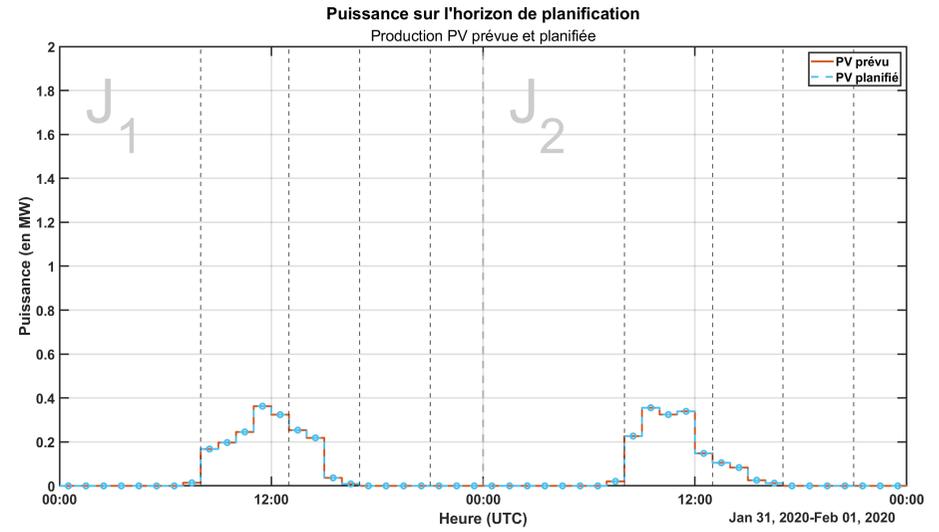
FIGURE 7.5 – Courbe de charge, production PV et charge résiduelles prévues à partir de Q_{50} - 31/01/2020

important pour respecter la contrainte liée à la 2^{ème} pointe de la journée. En effet, sur cet intervalle, la puissance PV étant nulle, seule la batterie peut ajuster la puissance de soutirage afin qu'elle soit constante. De plus, l'énergie étant la plus chère à cet instant de la journée, la puissance constante choisie doit donc être la plus faible possible pour réduire le coût le plus possible. Il faut donc que l'état de charge de la batterie soit haut avant que cette période commence, si il est maximal sur la première journée le modèle de planification choisi de ne pas plus charger la batterie avant la pointe du soir le deuxième jour. Il est donc estimé que la différence de prix entre la période pleine et la la seconde pointe n'était pas assez avantageuse pour recharger la batterie à ce moment là. En effet, à cause des pertes liées au rendement de la batterie on perd environ 20% de l'énergie transitant dans la batterie, il faut donc que l'arbitrage économique soit plus intéressant que les pertes liées à ce rendement.

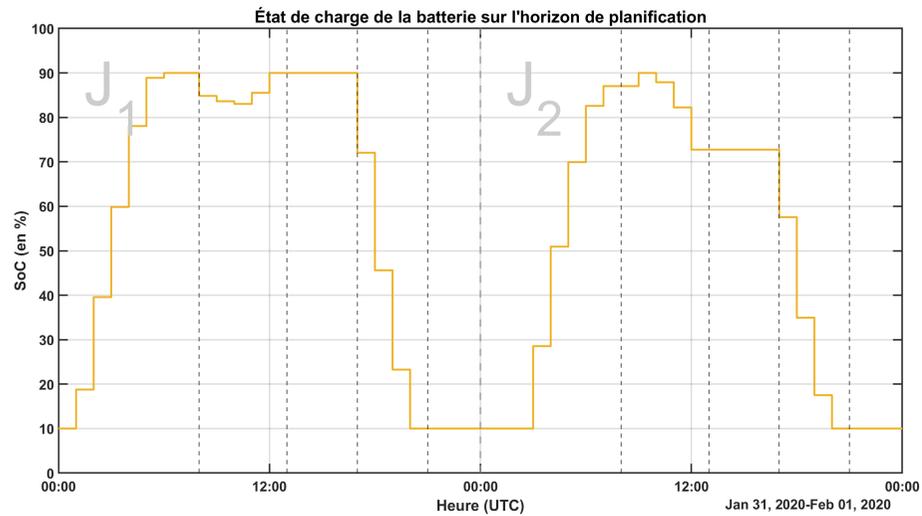
On remarque que l'objectif de diminution de l'amplitude est rempli et même dépassé car on passe d'un amplitude journalière de la charge prévue de 840 kW à 416 pour celle du soutirage. Cependant si l'on observe les résultats de la simulation figure 7.6d et 7.6e, on peut constater les effets des écarts liés à l'aléa PV. Ainsi la puissance PV sur la journée simulée et bien plus importante que prévue et cela entraine des écarts négatifs : on va soutirer moins que prévu. Cela a pour effet malheureux de diminuer la puissance minimale de soutirage et donc d'augmenter l'amplitude journalière à 969 kW (+ 127), violant ainsi la contrainte sur l'amplitude mais aussi celle sur la puissance de soutirage constante. Cependant cela a pour effet de diminuer le coût journalier car les écarts négatifs ainsi produits constituent un gain, tout de même pénalisé de 10 % pra rapport au prix de l'énergie initial (voir section 6.4.1).



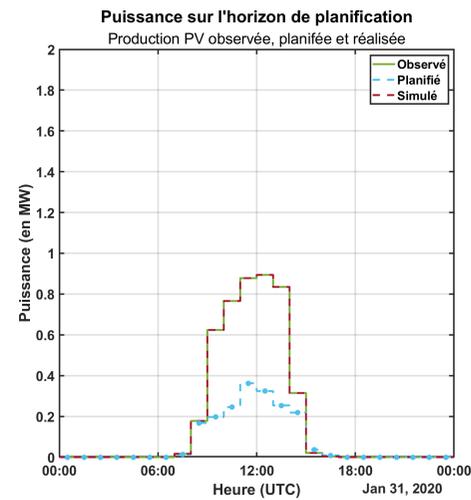
(a) Soutirage et batterie planifiés, charge prévue



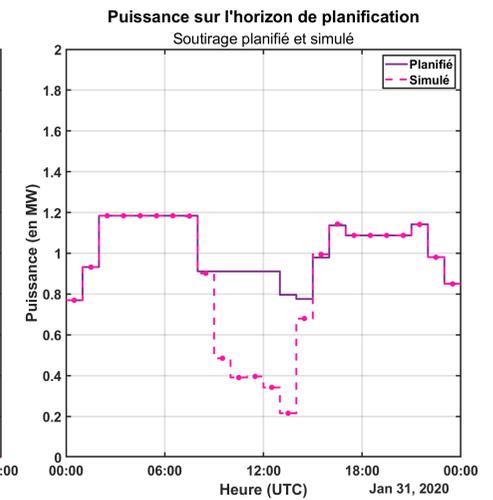
(b) PV prévu et planifié



(c) Etat de charge de la batterie prévu



(d) PV planifié, observé et simulé



(e) Soutirage prévu et simulé

FIGURE 7.6 – Résumé des trajectoires issues de la planification à partir de Q_{50} - Contrainte explicite - 31/01/2020

Stratégie avec contrainte incitative

Les trajectoires estimées et simulées à partir du problème de planification avec la contrainte incitative sont consignées dans la figure 7.7. Pour cette seconde stratégie, le résultat de la planification présente des similarités avec la première : la puissance de soutirage devant être constante durant les périodes de pointe, c'est la modulation de celle de la batterie qui va le permettre.

De plus, pour cette stratégie, la forme de la courbe de soutirage doit rester la même que celle de la charge initiale. Ainsi pour la première journée, la charge de la batterie est donc répartie sur toute la période creuse grâce à cette contrainte. Sur l'intervalle de la 1^{ère} pointe, la batterie va, comme pour la stratégie précédente, suivre la forme de la courbe de charge résiduelle tout en se déchargeant pour minimiser le soutirage total sur cette période où l'énergie est chère. Le gain est cependant limité par le fait de devoir anticiper la seconde pointe et par la contrainte qui minore cette constante afin de ne pas augmenter l'amplitude journalière (voir équation 6.13, section 6.3.2.b). Nous avons vu précédemment qu'il n'était pas forcément rentable de stocker de l'énergie sur la période pleine mais pour respecter la contrainte de forme de soutirage, la batterie se charge au minimum à ce moment sur les deux journées, constituant ainsi un stock pour la période suivante. Lors de la deuxième pointe, c'est une nouvelle fois la batterie qui permet d'ajuster le soutirage : tout en le gardant constant, on vide le stock d'énergie au maximum pour diminuer le coût des achats d'énergie de cette période.

Ici encore l'objectif de diminution de l'amplitude journalière est atteint avec une diminution prévue de 277 kW par rapport à la charge. Toutefois si l'on s'intéresse aux courbes issues de la simulation, on observe le même écueil que pour la stratégie précédente avec des écarts importants qui empêchent le respect de l'objectif sur le soutirage. L'augmentation de l'amplitude est plus importante dans que pour la première stratégie dans ce cas puisque le maximum de soutirage est légèrement plus important et la diminution liées aux écarts reste la même (figures 7.6 et 7.7).

Résultats comparés des deux stratégies

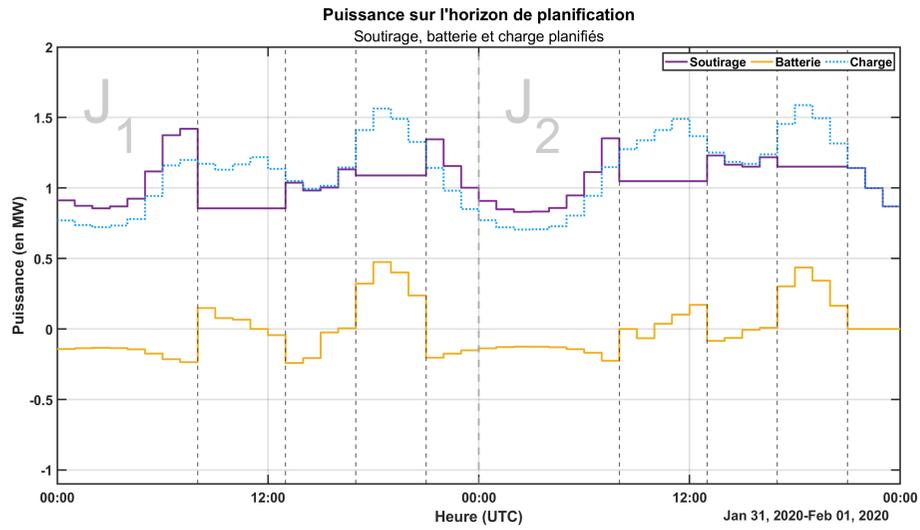
Les différents indicateurs sur les coûts journaliers, les écarts et l'amplitude journalière de soutirage sont consignés pour les deux stratégies dans les tableaux 7.9, 7.10 et 7.11 ci-après.

	Coût journalier prévu (en €)	Coût journalier simulé (en €)	Coût des écarts (dont pénalités, en €)
Contrainte explicite	4 418	3 944	-474 (54)
Contrainte incitative	4 458	3 984	-474 (54)

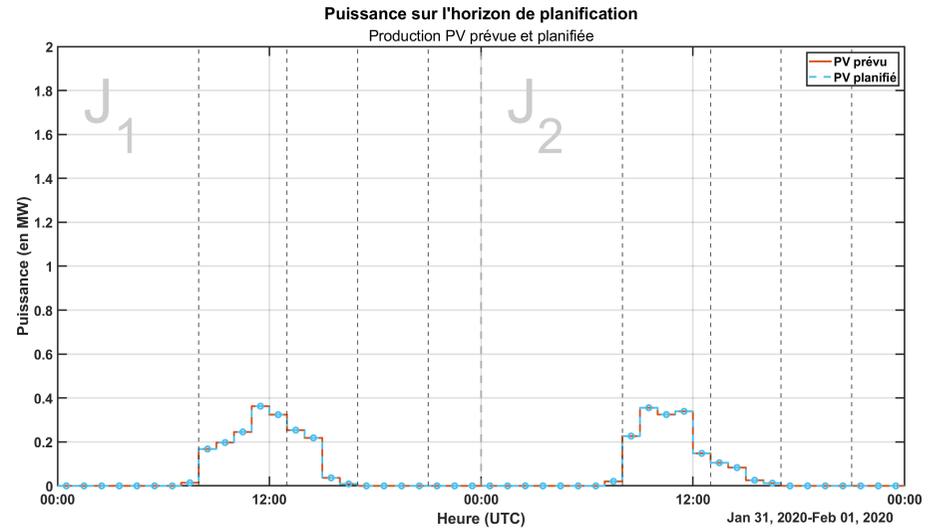
TABLEAU 7.9 – Résultats des coûts journaliers pour la simulation de la planification déterministe - Cas 1 - 31/01/2020

	Écarts journaliers (en kWh)	Écarts journaliers absolus (en kWh)
Contrainte explicite	-2 701	2 744
Contrainte incitative	-2 701	2 744

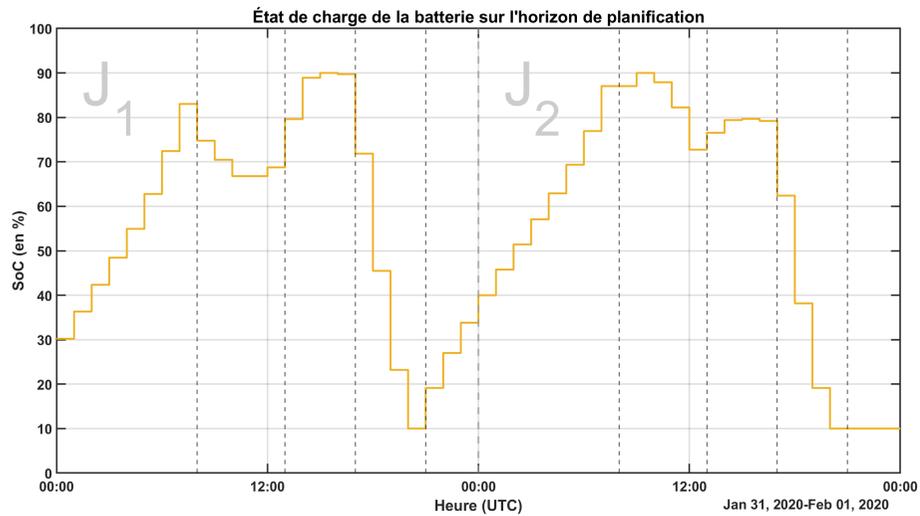
TABLEAU 7.10 – Résultats des écarts journaliers pour la simulation de la planification déterministe - Cas 1 - 31/01/2020



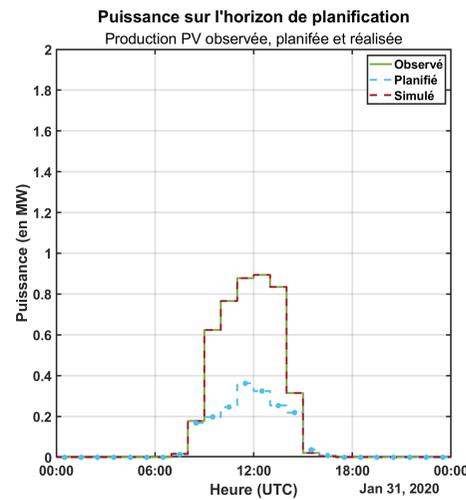
(a) Soutirage et batterie planifiés, charge prévue



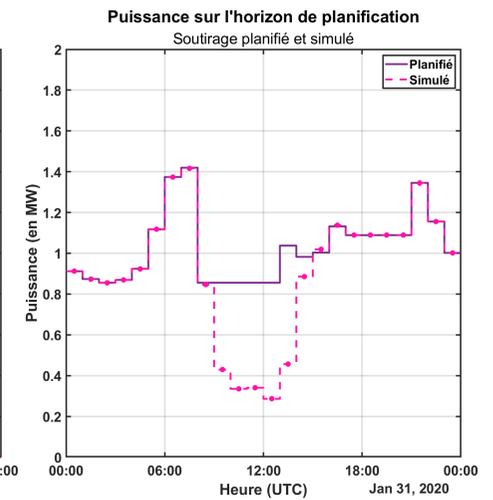
(b) PV prévu et planifié



(c) Etat de charge de la batterie prévu



(d) PV planifié, observé et simulé



(e) Soutirage prévu et simulé

FIGURE 7.7 – Résumé des trajectoires issues de la planification à partir de Q_{50} - Contrainte incitative - 31/01/2020

	Amplitude journalière prévue (en kW)	Variation par rapport à la charge (en kW)	Amplitude journalière simulée (en kW)	Variation par rapport à la charge (en kW)
Contrainte explicite	414	-426	969	+127
Contrainte incitative	564	-277	1 131	+289

TABLEAU 7.11 – Résultats de l’amplitude journalière pour la simulation de la planification déterministe - Cas 1 - 31/01/2020

La comparaison des résultats pour cette journée simulée entre les deux stratégies de réduction de l’amplitude montre quelques différences mineures.

En premier lieu, on observe un coût légèrement plus élevé pour la seconde stratégie. Cela s’explique par le fait que cette dernière est plus contraignante que la première. En effet, pour respecter la contrainte de forme du plan de soutirage, le problème de planification doit parfois charger et décharger la batterie alors qu’il n’y aurait pas forcément d’intérêt économique à le faire. Ce qui amène donc la seconde stratégie à soutirer plus d’énergie sur la journée considérée (24,64 contre 24,38 MWh), cette très légère différence permet d’avoir une puissance constante soutirage plus faible durant la première pointe donc de faire plus d’économies sur le prix mais ne compense pas le surplus de soutirages aux autres périodes.

Concernant les écarts, il n’est pas surprenant qu’ils soient identiques pour les deux cas puisque que la simulation du plan de permet pas de les mitiger. On remarque tout de même qu’ils quasiment exclusivement négatifs, illustrant le pessimisme de la prévision PV. On notera également que le montant des pénalités est assez conséquent, une prévision parfaite aurait permis d’économiser 54 , ce qui reste très peu par rapport aux coûts d’opérations journaliers.

Pour l’objectif de réduction de l’amplitude, cette journée paraissait assez favorable au moment de la planification car la puissance PV prévue était plutôt faible, ce qui avait pour conséquence de ne pas augmenter l’amplitude de la charge résiduelle (voir section 6.1.3). La première stratégie n’a donc pas de mal à respecter la contrainte fixée, la deuxième stratégie non plus mais la relation de proportionnalité entre la charge et le soutirage entraîne un pic plus important à la fin de la période creuse, ce qui cause une amplitude prévue plus importante dans ce cas. Une fois la journée simulée et les écarts de production PV révélés, les résultats montrent, qu’aucune des deux stratégies n’a permis de maintenir la réduction d’amplitude.

b) Cas 2

Présentation du cas

Le deuxième cas particulier présente deux journées bien différentes du cas précédent. On présente les prévisions de charge, PV et charge résiduelle sur les figures 7.8a et 7.8b ci-après. Ici la période est automnale, le premier pic de consommation de la première journée est plus important que dans le premier cas (c’est un jour de weekend) mais le niveau de consommation est plus faible durant la nuit (i.e. période creuse). La différence majeure dans ce cas est la puissance PV, qui est ici bien supérieure avec deux pics prévus à près de 1 MW. L’effet sur la courbe de charge résiduelle est donc bien plus important que dans le cas précédent : l’association de la charge et de la courbe PV « creuse » la charge résiduelle sur la période de production PV. L’effet est d’autant plus important sur la deuxième journée où la charge est plus faible sur la pointe du midi et la période pleine.

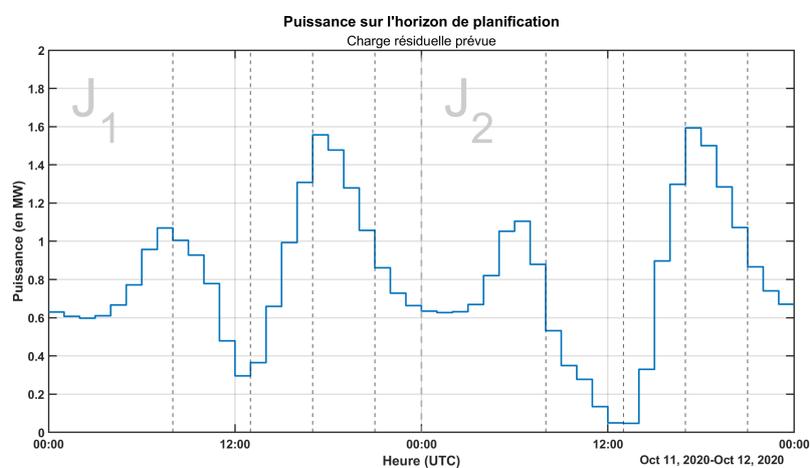
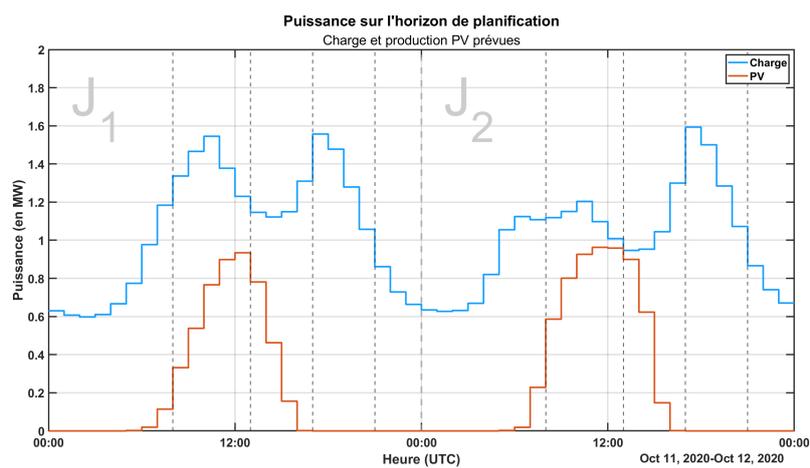


FIGURE 7.8 – Courbe de charge, production PV et charge résiduelles prévues à partir de Q_{50} - 11/10/2020

Stratégie avec contrainte explicite

La stratégie de planification engendrée par la contrainte explicite présentée figure 7.9 est ici finalement assez similaire à celle du premier cas : charger la batterie au maximum durant la période creuse pour bénéficier du meilleur prix, ajuster la puissance de soutirage pendant la 1^{ère} pointe pour obtenir une constante faible mais en gardant un état de charge conséquent pour déstocker le plus possible d'énergie durant la 2^{nde} pointe.

On remarque qu'aucune modulation de PV n'est prévue : toute l'énergie produite est prévue d'être utilisée, et ce malgré son effet sur l'amplitude de la charge résiduelle. C'est la batterie qui permet d'atténuer son effet par son plan de charge et de décharge : lors du pic de production qui se trouve autour de la pointe de la fin de matinée, la batterie se décharge et se charge tout à tour permettant de garder la puissance de soutirage constante mais aussi de diminuer le creux de la charge résiduelle de 70 kW tout en baissant également la puissance maximum permettant ainsi de remplir l'objectif sur l'amplitude. On prend également soin de répartir la charge sur les périodes favorables pour ne pas augmenter trop le soutirage maximum. On observe ici un plan similaire sur les deux journées.

Sur les figures 7.9d et 7.9e, on peut observer les résultats après la simulation du plan prévu. On remarque que la puissance PV est bien moins importante que prévue, créant donc des écarts à la hausse. Sur la dernière figure représentant le plan de soutirage prévu et le simulé, on peut voir que ça a pour effet d'augmenter la puissance maximale de soutirage mais cela hausse aussi la valeur minimale donc l'effet en assez neutre sur l'amplitude journalière.

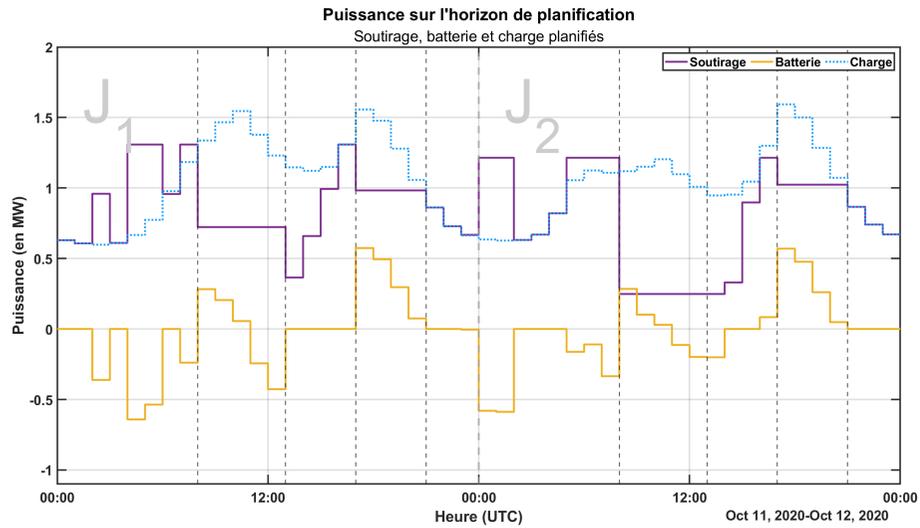
Stratégie avec contrainte incitative

La planification résultant de la stratégie incitative est présentée ci-après figure 7.9. Ici, on peut remarquer une véritable différence entre les deux approches.

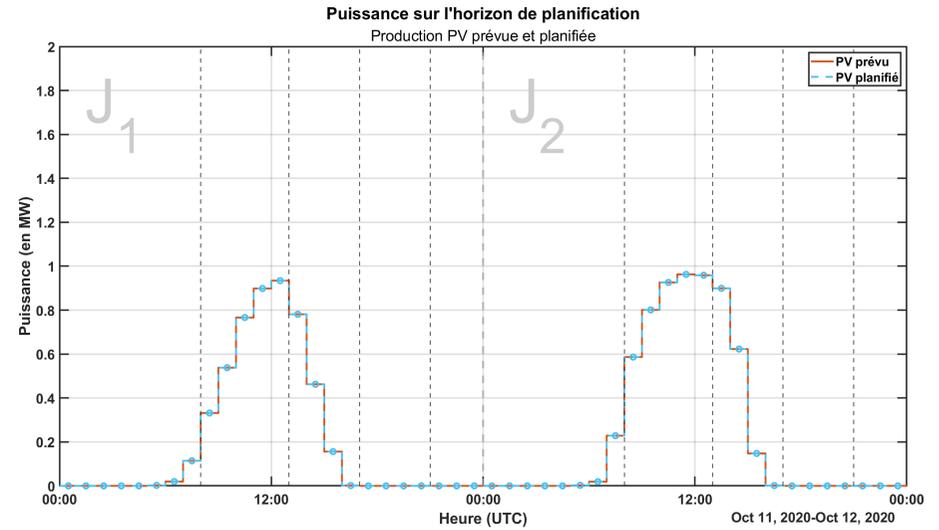
Cette stratégie opte pour une recharge assez faible de la batterie durant la période creuse de la première journée (jusqu'à 50 % de sa capacité), puis module sa puissance afin de maintenir une puissance constante durant la première pointe. Dans ce cas de figure, la batterie se recharge ensuite en même temps que la production PV est maximale ce qui permet de contrer l'effet du PV sur la puissance minimale de charge résiduelle plus efficacement que la 1^{ère} stratégie, on augmente ainsi le minimum de 250 kW.

Dans ce cas la batterie se retrouve « coincée » entre les arbitrages économiques et le fait de devoir réduire l'amplitude journalière. En effet la seconde journée étant particulièrement difficile pour diminuer l'amplitude de la charge, la batterie est obligée d'arriver avec un stock le plus bas possible lors de la pointe de fin de matinée de la 2^{nde} journée : pour respecter le fait de soutirer à puissance constante, la batterie va devoir se charger le plus possible durant cette période. Et pour que la constante soit la plus basse possible et faut que le soutirage soit le plus faible possible durant la nuit, d'où le fait de décharger la nuit et non durant la pointe du soir. On peut ainsi expliquer le comportement de la batterie qui ne semble pas faire les arbitrages économiques observés dans le plan de la stratégie précédente. C'est l'illustration de l'incitation à la diminution d'amplitude, et ici on la diminue de 120 kW de plus.

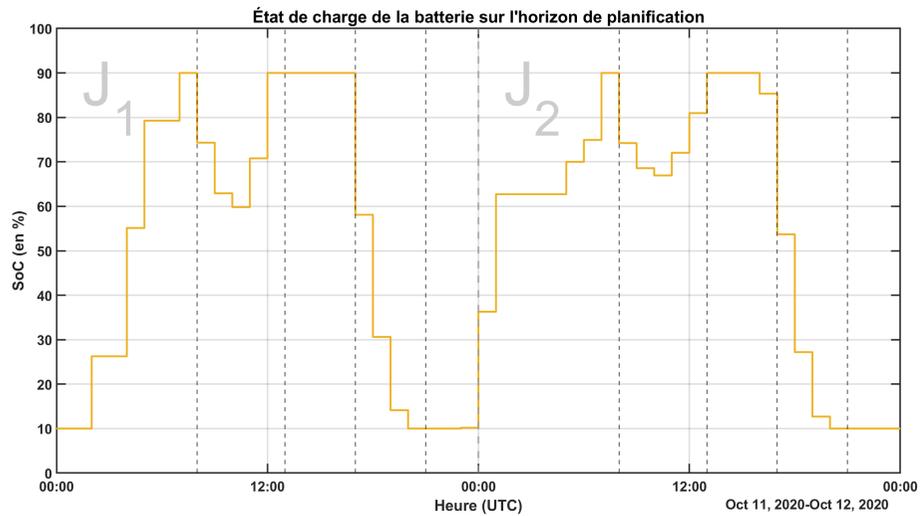
Concernant les résultats de la simulation présentés figure 7.9e, on remarque que les écarts positifs importants engendrés par la réalisation de la puissance PV ont un effet plus négatif que pour la stratégie précédente. Le minimum de soutirage étant plus important, l'augmentation de son maximum fait que l'objectif n'est plus atteint.



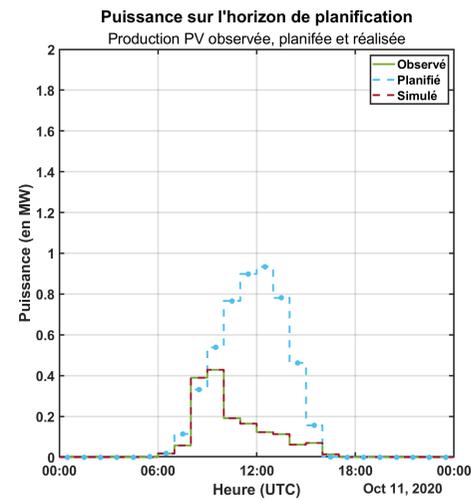
(a) Soutirage et batterie planifiés, charge prévue



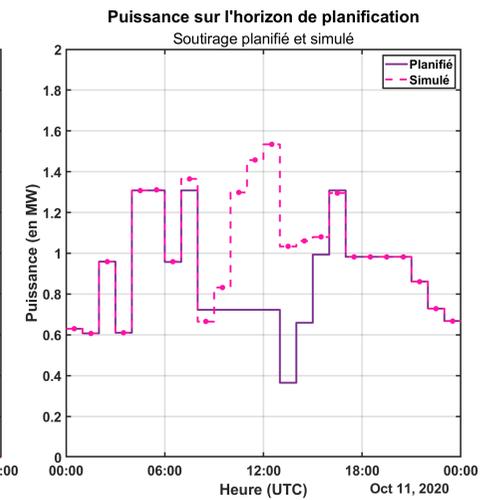
(b) PV prévu et planifié



(c) Etat de charge de la batterie prévu

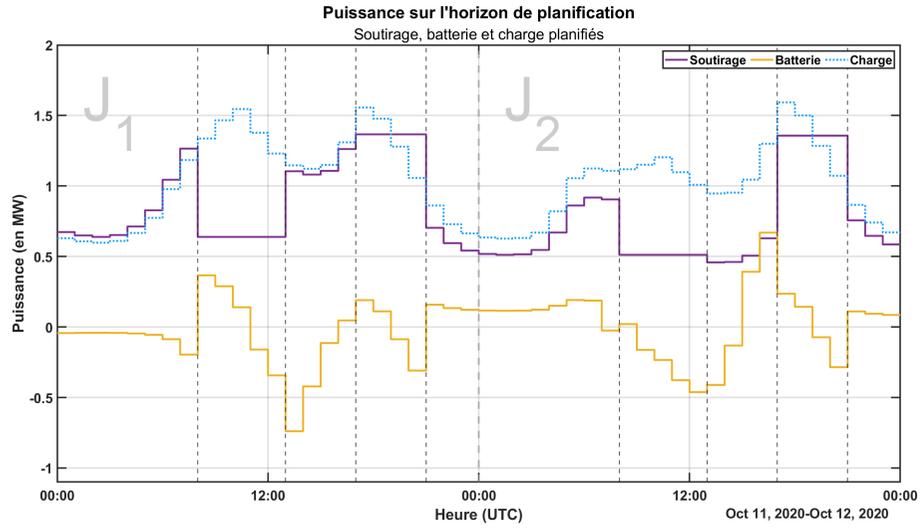


(d) PV planifié, observé et simulé

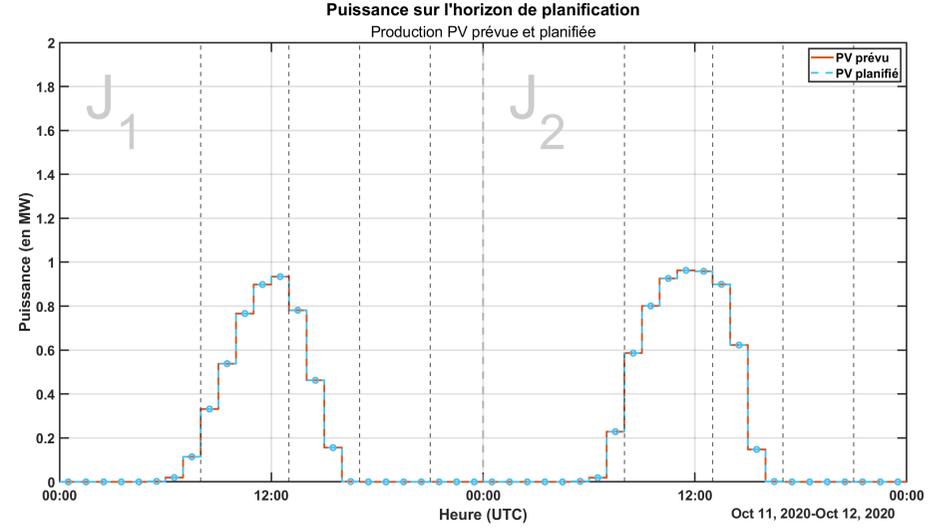


(e) Soutirage prévu et simulé

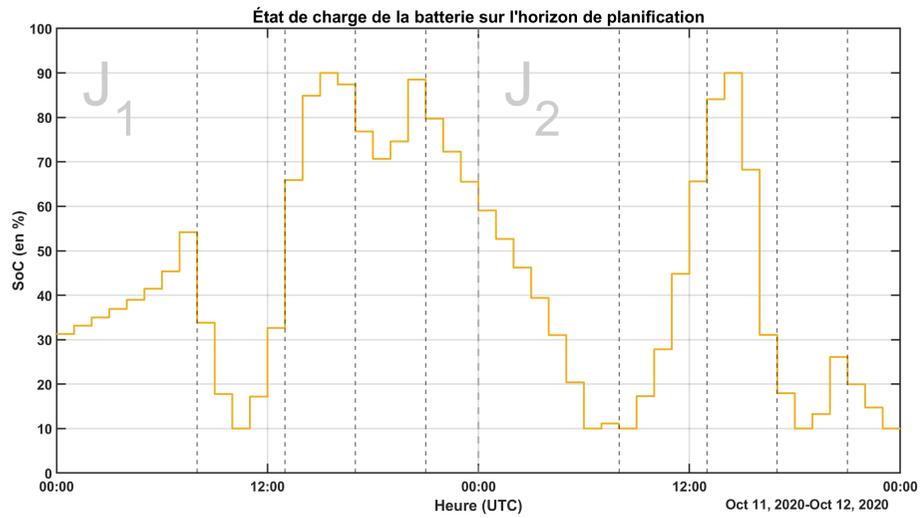
FIGURE 7.9 – Résumé des trajectoires issues de la planification à partir de Q_{50} - Contrainte explicite - 11/10/2020



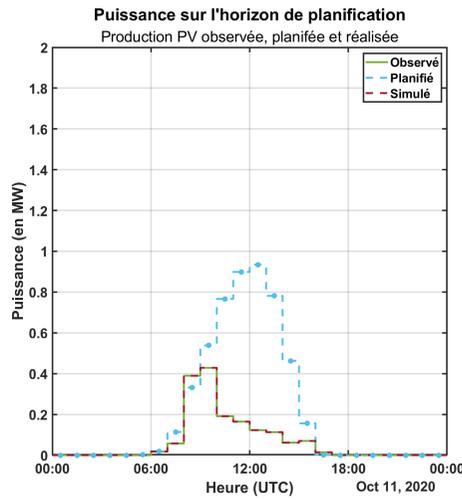
(a) Soutirage et batterie planifiés, charge prévue



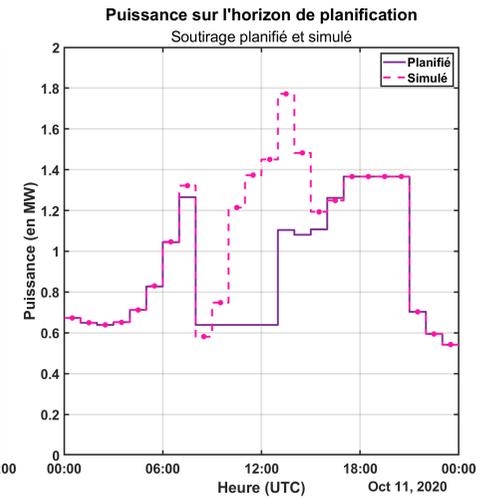
(b) PV prévu et planifié



(c) Etat de charge de la batterie prévu



(d) PV planifié, observé et simulé



(e) Soutirage prévu et simulé

FIGURE 7.10 – Résumé des trajectoires issues de la planification à partir de Q_{50} - Contrainte incitative - 11/10/2020

Résultats comparés des deux stratégies

Les différents indicateurs sur les coûts journaliers, les écarts et l'amplitude journalière de soutirage sont consignés pour les deux stratégies dans les tableaux 7.12, 7.13 et 7.14 ci-après.

	Coût journalier prévu (en)	Coût journalier simulé (en)	Coût des écarts (dont pénalités en)
Contrainte explicite	3 778	4 495	+717 (68)
Contrainte incitative	3 990	4 707	+717 (68)

TABLEAU 7.12 – Résultats des coûts journaliers pour la simulation de la planification déterministe - Cas 2 - 11/10/2020

	Écarts journaliers (en kWh)	Écarts journaliers absolus (en kWh)
Contrainte explicite	-3 376	3 518
Contrainte incitative	-3 376	3 518

TABLEAU 7.13 – Résultats des écarts journaliers pour la simulation de la planification déterministe - Cas 2 - 11/10/2020

	Amplitude journalière prévue (en kW)	Variation par rapport à la charge (en kW)	Amplitude journalière simulée (en kW)	Variation par rapport à la charge (en kW)
Contrainte explicite	943	-15	926	-32
Contrainte incitative	824	-134	1 231	+271

TABLEAU 7.14 – Résultats de l'amplitude journalière pour la simulation de la planification déterministe - Cas 2 - 11/10/2020

Tout comme le cas précédent, on observe une différence de coût tant à l'étape de planification qu'après celle de simulation à l'avantage de la première stratégie. En effet, une nouvelle fois la stratégie incitative mène à plus de soutirage sur le réseau et donc à plus d'achats d'énergie, ce qui se répercute sur le coût d'opération. De plus, comme nous l'avons vu dans l'étude du second cas la construction de la contrainte incitative fait que la planification baisse moins le soutirage lors de la période de pointe du soir (1 366 contre 983 kW pour la stratégie explicite), ce qui engendre moins d'arbitrage économique favorable. On peut également citer le fait que dans la seconde stratégie, l'état de charge de la batterie est encore assez haut à la fin de la journée, et contient donc de la valeur à l'inverse de l'autre approche, ce qui permet de nuancer l'écart de coût.

On remarque aussi que les pénalités représente encore une grosse part du coût des écarts (environ 9%), ce qui n'est pas étonnant au vu de la quantité d'énergie représentée par les écarts, à la hausse cette fois.

Quant à l'objectif sur l'amplitude de soutirage, le sujet a déjà été évoqué dans l'analyse individuelles des deux cas mais le tableau 7.14 permet d'effectuer la comparaison directe. Dans les deux cas l'étape de planification permet effectivement de réduire l'amplitude mais il n'y a que pour la première stratégie qu'il est rempli après la simulation.

7.2.2 Résultats globaux

Après cet examen détaillé de deux cas particuliers, la section suivante permet d’analyser les résultats sur l’ensemble des simulations effectuées, soit une année.

a) Coûts d’opération

	Coût total prévu (en k)	Coût total simulé (en k)	Coût des écarts (dont pénalités en k)
Contrainte explicite	1 190	1 205	+15,3 (6,0)
Contrainte incitative	1 208	1 223	+14,5 (6,0)

TABLEAU 7.15 – Résultats globaux des coûts d’opérations pour la planification déterministe

Les résultats économiques sont représentés dans les tableaux 7.15 ci-dessus. On remarque tout d’abord que la stratégie explicite possède des coûts d’opération inférieurs à ceux obtenus après la simulation faite avec la contrainte incitative. On note cependant que cet écart ne représente qu’environ 1,5% des coûts totaux. De plus on observe également que, quelque soit la simulation, le coût simulé une fois les écarts de production PV révélés est supérieur au coût prévu à l’issue de la planification. Une nouvelle fois, la différence est de l’ordre du pourcent entre le coût prévu et simulé. Comme nous l’avons décrit dans l’étude des deux cas particuliers, la stratégie explicite semble plus encline à faire des arbitrages économiques intéressants. La figure 7.11 permet d’illustrer ce phénomène en montrant les coûts du soutirage de l’énergie sur les différentes périodes de la journée (présentés par ordre croissant de prix), et ce pour la charge résiduelle sans planification, puis selon les deux stratégies étudiées. On peut donc s’apercevoir que pour la période de prix la plus pénalisante, la 2^{ème} pointe, les deux stratégies permettent de diminuer le soutirage et donc de faire des économies, la stratégie explicite montrant tout de même une plus forte baisse. Sur la 1^{ère} pointe, on observe le même effet de baisse de soutirage par rapport à la charge résiduelle pour la première stratégie mais une augmentation pour la seconde stratégie de réduction de l’amplitude.

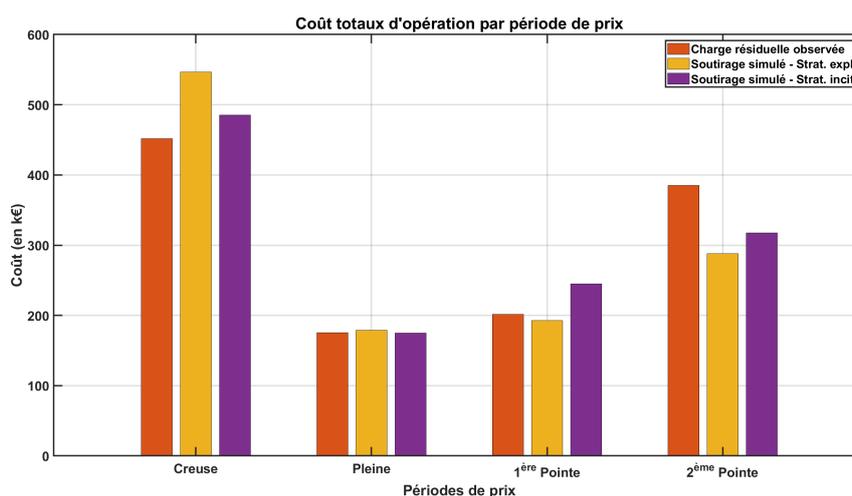
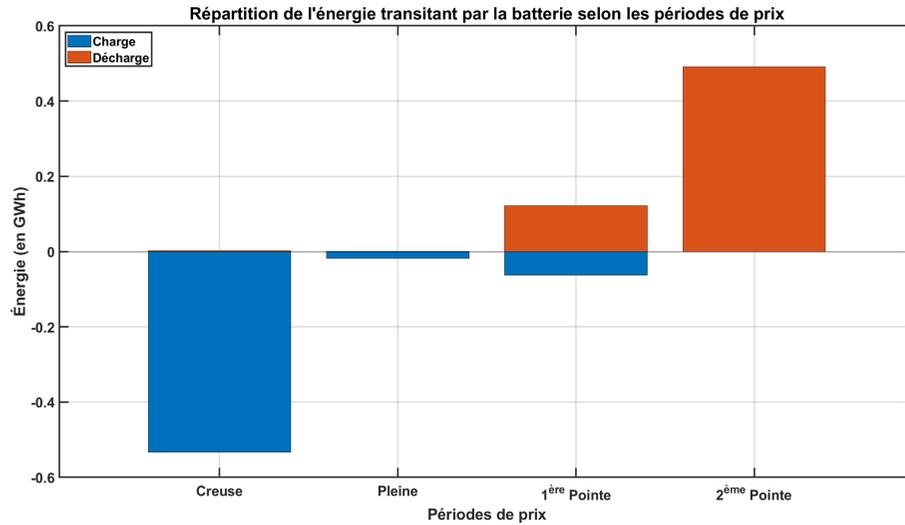
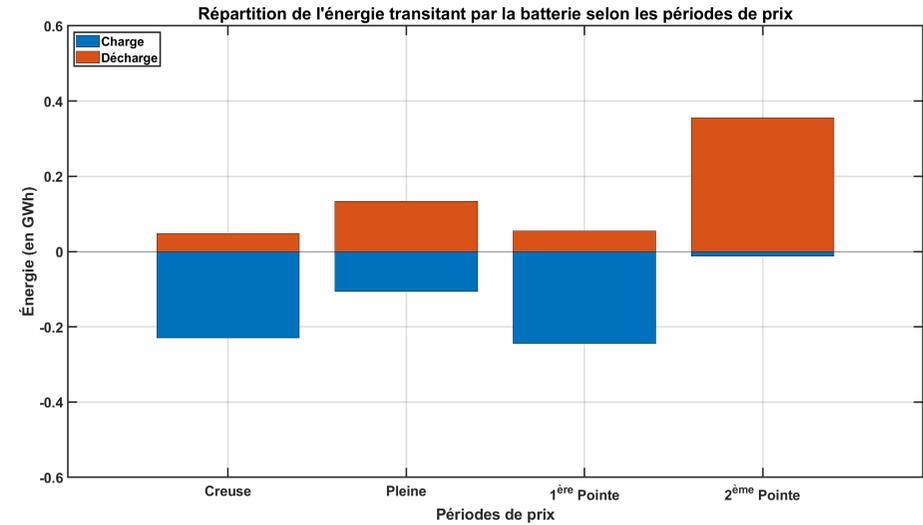


FIGURE 7.11 – Synthèse planification déterministe - Coût totaux d’opération par période de prix

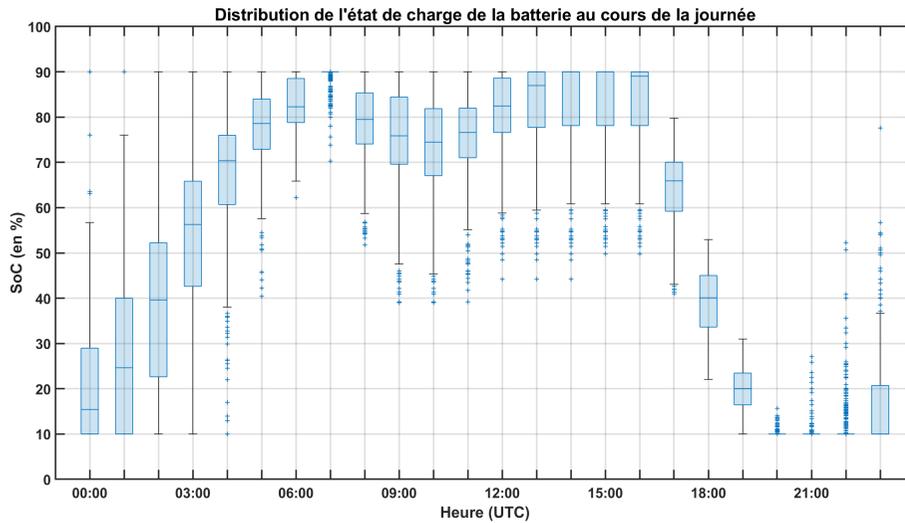
Ces différences de coûts et de soutirage entre les deux stratégies sont liés au fonctionnement de la batterie induit par les contraintes rajoutées au problème de planification. La figure 7.12 permet de présenter globalement l’utilisation de la batterie sur la simulation pour chaque stratégie : le premier graphique présente la quantité globale d’énergie ayant transité par la batterie et le second présente la distribution de l’état de charge pour chaque heure de la journée.



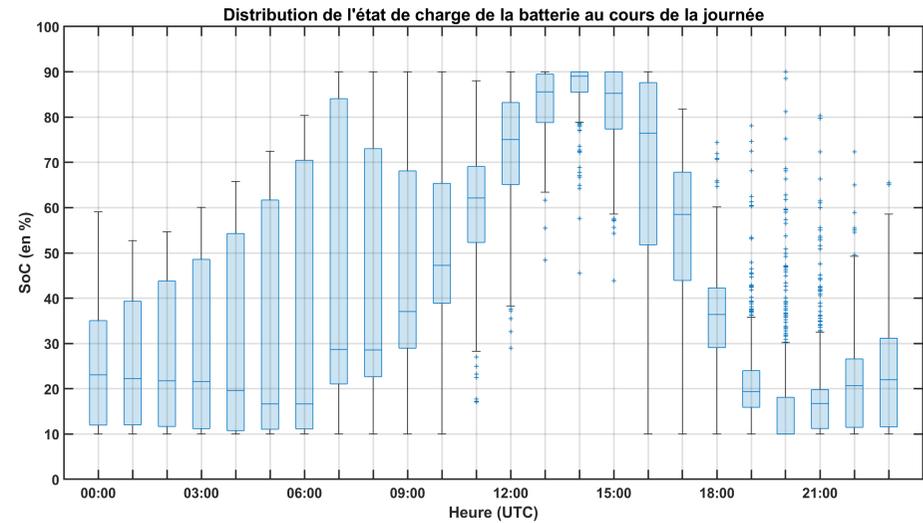
(a) Énergie transitant par la batterie selon les périodes de prix - Contrainte explicite



(b) Énergie transitant par la batterie selon les périodes de prix - Contrainte incitative



(c) Distribution de l'état de charge de la batterie au cours de la journée - Contrainte explicite

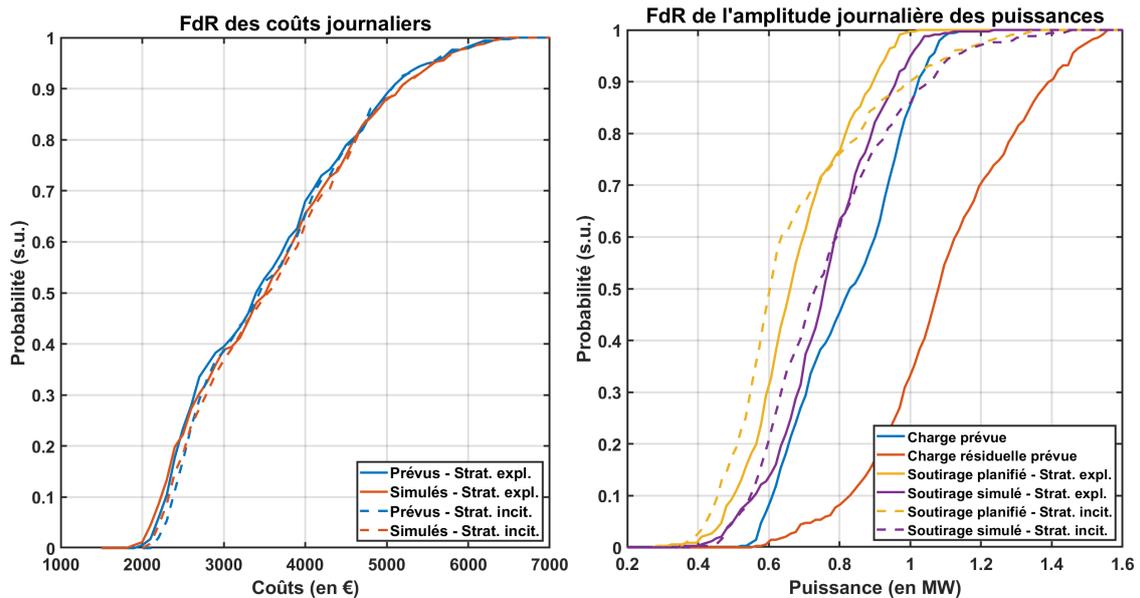


(d) Distribution de l'état de charge de la batterie au cours de la journée - Contrainte incitative

FIGURE 7.12 – Résumé des trajectoires de la batterie sur l'ensemble des journées simulées - Synthèse planification déterministe

Les figures résumant l'activité de la batterie permettent de confirmer ce qui a déjà été montré durant l'étude des cas particuliers. Dans le cas de la stratégie explicite : on retrouve globalement la même structure avec une recharge durant la période creuse et la majorité de la décharge durant la pointe du soir, ce qui permet de faire le meilleur arbitrage économique sur la journée. Entre la période creuse et cette dernière pointe la batterie est moins active, sauf pour limiter la baisse du minimum de soutirage en se chargeant avec l'énergie solaire durant la 1^{ère} pointe ou la période pleine, à la marge. On remarque d'ailleurs sur la figure 7.12c, que l'EIQ de l'état de charge de la batterie est assez faible pour chaque heure de la journée, ce qui signifie qu'il y a peu de variation du plan de la batterie au fil des jours : son état de charge arrive près de son maximum au début de la pointe de la matinée, permet de garder le soutirage constant en se déchargeant, et arrive à son minimum à la fin de la pointe du soir.

Si l'on se penche sur le cas de la contrainte incitative on remarque une utilisation bien différente du système de stockage. La batterie ne se charge pas quasiment exclusivement sur la période creuse, la construction des contraintes l'entraînant à stocker durant toutes les périodes, même parfois celle de la pointe du soir comme dans le second cas d'étude (voir section 7.2.1.b). D'autre part, l'état de charge est plus variable selon les journées, comme le montre son EIQ. Cela permet d'illustrer que la stratégie incitative doit plus s'adapter aux situations particulières de chaque horizon considéré et simulé. On notera que la stratégie explicite utilise légèrement plus la batterie que la stratégie incitative (616 contre 592 MWh transités).



(a) Distribution des coûts journaliers prévus et simulés (b) Distribution des amplitudes journalières prévues et simulées

FIGURE 7.13 – Synthèse planification déterministe - distributions des coûts et amplitudes journalières en fonction de la stratégie

b) Anticipation des écarts

Au global, les écarts de coût entre les deux approches restent très faibles comme en témoigne la figure 7.13a, présentant la distribution des coûts d'opération journaliers. On remarque ainsi une très légère différence entre les deux stratégies. Comme les coûts globaux et l'analyse précédente l'indiquent, cette différence économique est à l'avantage de la stratégie explicite.

Cette figure permet également de confirmer la très faible part des écarts, illustrés par la différence entre les coûts prévus et simulés. Au global les écarts sont très similaires entre les deux

simulations, comme indiqué dans le tableau 7.16. A la nuance près de la modulation par les bas effectué dans certains cas par la planification avec contrainte incitative. Ainsi dans certains cas il est plus favorable de se priver de l'énergie gratuite pour réaliser plus « facilement » (i.e. économiquement) les contraintes fixées. Le fait de moduler la puissance PV à la baisse permet également de moins d'exposer aux écarts positifs, d'où cette différence entre les résultats des deux approches. Logiquement la somme des écarts absolus sur la simulation est la même que pour les deux premières simulations (voir sections 7.1.1.a et 7.1.2.a) puisque rien ne permet ni de les anticiper ni de les corriger.

	Écarts totaux (en MWh)	Écarts positifs (en MWh)	Écarts négatifs (en MWh)	Écarts absolus (en MWh)
Contrainte explicite	48	179	-131	310
Contrainte incitative	44	179	-135	314

TABLEAU 7.16 – Résultats globaux des écarts pour la planification déterministe

c) Objectifs de soutirage

Si l'on se penche sur le respect de l'objectif de soutirage, à savoir la réduction de son amplitude journalière, la figure 7.13b permet d'illustrer l'apport des deux stratégies. En effet en regardant la distribution de l'amplitude planifiée par les deux stratégies pour rapport à celle de la charge, on note que les deux entraînent une baisse importante, respectivement de -174 et -231 kW pour les stratégies explicite et incitative. Cette dernière remplit donc bien son objectif d'une baisse plus importante par rapport à la première. Cependant la première prévoit logiquement de remplir l'objectif dans 100% des plans prévus tandis que la seconde dans 70% uniquement.

Cet avantage s'inverse si l'on se penche sur l'amplitude après simulation du plan : l'objectif est respecté dans 57% des cas pour la contrainte incitative et dans 52% des cas pour l'explicite. Cette dégradation est à nuancer puisqu'on diminue tout de même l'amplitude médiane d'environ 100 kW et on reste très largement en dessous de l'amplitude de la charge résiduelle dans le cas des deux contraintes. On peut expliquer cette dégradation pour la contrainte explicite par l'action plus rare de la batterie lors des périodes pleines et sur la première pointe. Cela entraîne le minimum de soutirage à être souvent planifié sur cet intervalle où la puissance PV est importante, exposant le micro-réseau aux aléas et notamment aux écarts positifs de surproduction PV, entraînant donc une baisse du soutirage pouvant violer la contrainte fixée. Pour la contrainte incitative les extrêmes de soutirage prévus sont répartis différemment sur la journée et moins soumis aux aléas du PV, d'où la baisse moins importante de l'objectif. On peut également constater que la stratégie explicite permet une plus grande limitation des amplitudes « extrêmes » : en effet, les distributions montrent que seules 5% des journées simulées présentent une amplitude supérieure à 1MW pour la stratégie explicite contre plus de 15% pour la stratégie incitative. C'est notamment ce qu'illustre le second cas particulier, voir section 7.2.1.b.

Le taux d'autoconsommation des deux approches est globalement le même, l'énergie soutirée depuis de réseau étant respectivement de 6 647 et 6 642 MWh pour les stratégies explicite et incitative. La différence étant due au fait qu'il y a légèrement plus d'énergie transistant dans la batterie dans le premier cas. Cette énergie soutirée comparée à l'énergie PV utilisée donne un taux d'autoconsommation de 17,6%.

Si les deux approches permettent effectivement de diminuer légèrement l'amplitude journalière de la charge nous avons vu que chaque approche menait à une gestion de la batterie bien différente. Bien que causant une différence de coût économique marginale (+2000 , soit + 0,16%

par rapport à la planification sans contrainte), la stratégie explicite permet de faire de meilleurs arbitrages sur les prix. Cet avantage est contrebalancé par une exposition plus importante aux aléas PV et une moins bonne performance sur l'objectif de soutirage. La seconde contrainte incitative a quant à elle un coût de 20 000 (+ 1,6%) rapport à la planification sans contrainte. Dans la section suivante nous allons voir les résultats des mêmes approches mais à partir de la formulation stochastique.

7.3 Résultats de la planification stochastique

Dans cette section, on présente les résultats de la planification stochastique. Comme exposé précédemment, cette approche propose des différences majeures par rapport à la planification déterministe (voir section 6.3.3.b). Ce type de modèle permet en effet de prendre en compte l'incertitude de la prévision PV, sous la forme d'un ensemble de scénarios associés à leurs probabilités. Le fait d'avoir cette représentation de l'incertitude permet également d'anticiper les écarts (et leur coût) entre le plan de soutirage choisi et les différentes trajectoires envisagées pour le futur, représentées par les scénarios.

7.3.1 Focus sur certaines journées

Comme pour l'analyse du pilotage déterministe présenté section 7.2.1, on commencera par l'étude de deux cas particuliers, les mêmes journées que précédemment. Afin de pouvoir comparer les deux stratégies de réduction de l'amplitude journalière, les ensembles de scénarios utilisés comme données d'entrée pour chaque simulation seront identiques. Pour une analyse plus claire, les ensembles de scénarios sont réduit à 4 éléments, mais une analyse de l'influence de ce choix de taille est faite par la suite.

a) Cas 1

Présentation du cas

Les prévisions pour la première journée étudiée sont présentées figure 7.14, on y trouve la prévision probabiliste de productible PV et la prévision de charge. La charge étant connue de façon certaine, on peut, en retranchant les quantiles de la prévision probabiliste à la charge, obtenir la prévision probabiliste de la charge résiduelle. Cette représentation, bien que le nombre de quantile soit ici limité, permet de mieux de rendre compte de la distribution potentielle du productible PV et de la charge résiduelle. On remarque notamment une faible amplitude sur la distribution de la seconde journée, même entre les quantiles 1 et 99%. Les quatre scénarios issus de cette distribution sont présentées en annexes (voir figure D.1).

Stratégie avec contrainte explicite

La stratégie avec la contrainte explicite présente très peu de différences notables avec l'approche déterministe. La gestion de la batterie est globalement similaire dans les deux cas avec une charge durant la période creuse, une petite décharge durant la première pointe pour satisfaire la contrainte et arbitrer sur le prix de l'énergie puis finalement une décharge complète durant la pointe du soir. On remarque tout de même sur la figure 7.15b, qui représente l'espérance de la production PV attendue, que pour la même journée la prévision stochastique est ici plus optimiste que la prévision déterministe, cela entraîne le choix d'une constante de soutirage plus faible pour la pointe de la matinée.

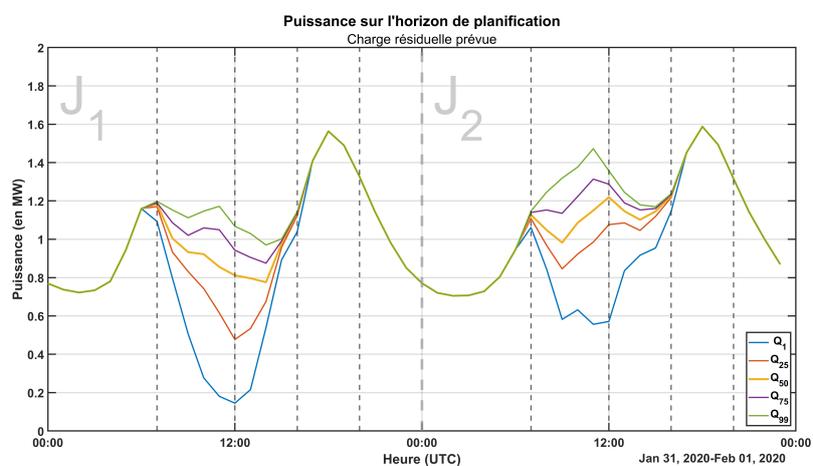
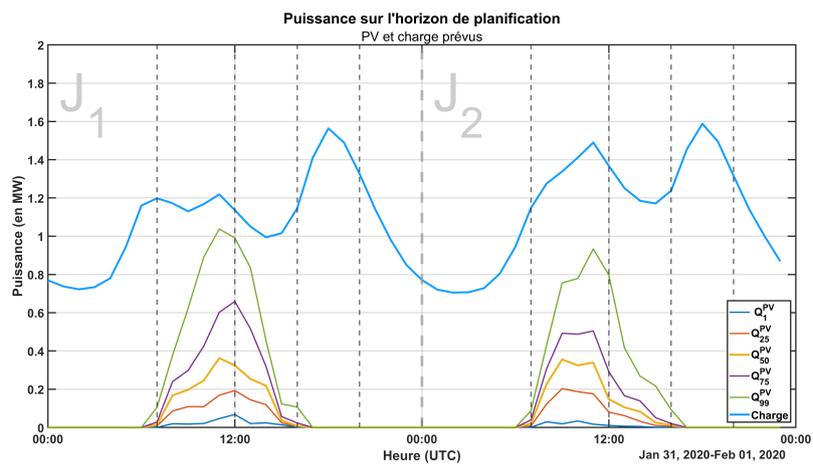
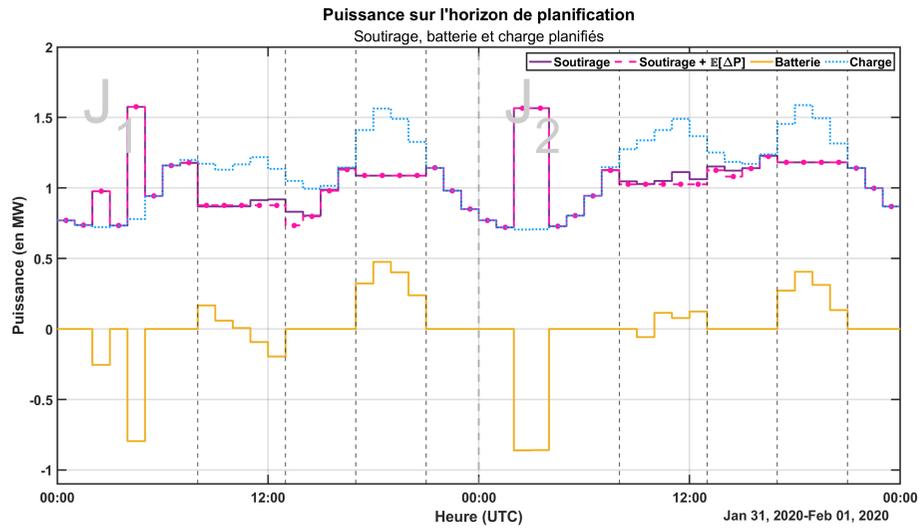


FIGURE 7.14 – Courbe de charge, production PV et charge résiduelles prévues à partir d'une prévision probabiliste - 31/01/2020

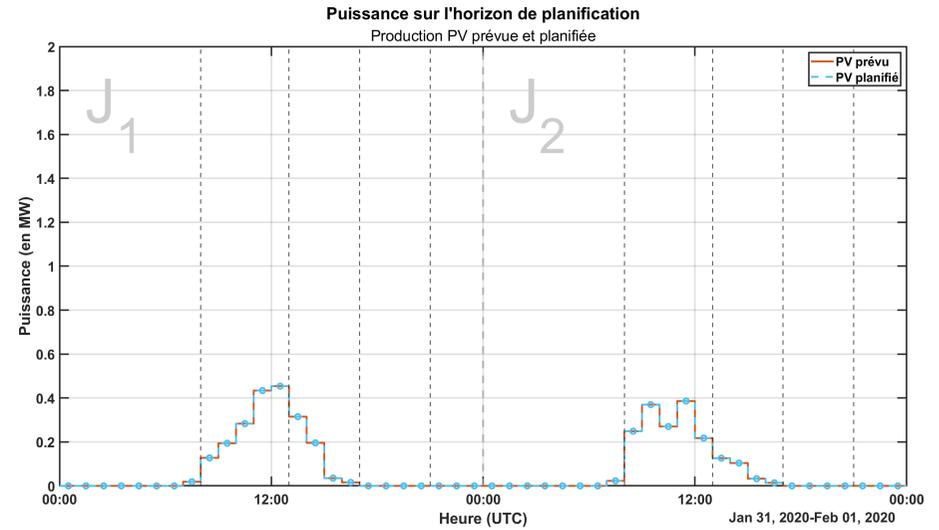
Contrairement, à la planification déterministe qui ne permettait pas de prévoir certains écarts par rapport au plan annoncé, l'approche stochastique le permet et nous en avons l'illustration sur le plan présenté figure 7.15 entre 11h et 14h. Ici la planification choisi d'annoncer un plan de soutirage tout en prévoyant des écarts à la baisse (soit une hausse de la production PV). C'est ce qu'on peut remarquer sur la figure D.3 en annexe, deux scénarios sur quatre anticipent des écarts négatifs, la planification choisi donc un positionnement en prenant en compte cette possibilité et le fait qu'un écart à la baisse fera diminuer les coûts d'opération. On note que la planification fait le choix de recharger la batterie en causant des pics de soutirage, ici c'est équivalent à la méthode plus lissée du cas déterministe puisque la contrainte sur l'amplitude est respectée. Cependant, les résultats de la simulation, avec de forts écarts à la baisse, présentent une grosse augmentation de l'amplitude par rapport à la charge (+518 kW).

Stratégie avec contrainte incitative

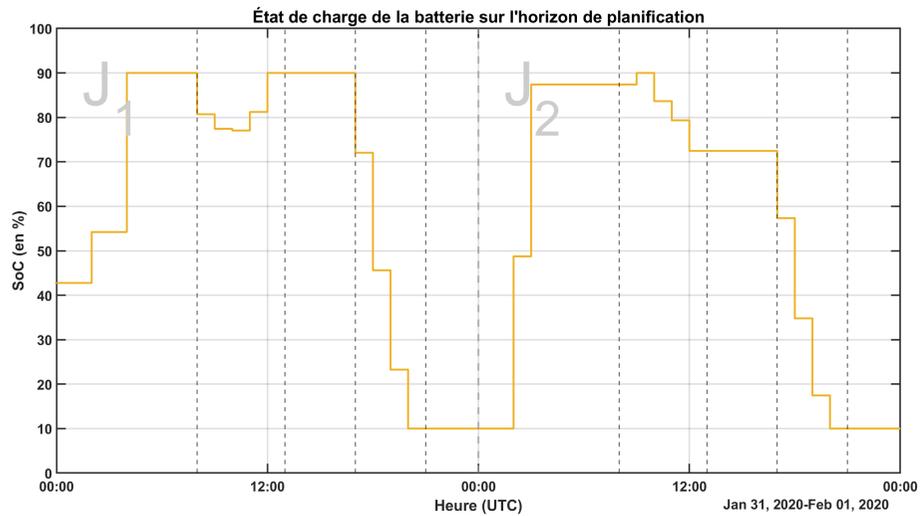
Tout comme pour la stratégie explicite, les résultats de la planification stochastique avec la contrainte incitative présentent des résultats similaires à la déterministe. Le seul petit constat, comme expliqué dans le paragraphe précédent, est lié à la différence de prévision PV qui cause une contrainte de soutirage plus basse et donc plus avantageuse économiquement que pour le cas déterministe. On notera, les deux types d'approches ayant les mêmes paramètres d'entrée (i.e. les scénarios de productible PV), que les écarts prévus sont les mêmes. En effet, même si les plans choisis sont différents, les variations d'amplitudes de PV attendues se produiront au même moment et auront donc le même poids dans la fonction objectif. Contrairement à l'approche stochastique, où l'objectif d'amplitude de soutirage est détérioré par rapport à l'approche déterministe, ici on observe le même comportement entre les deux cas : une faible amplitude prévue et une importante simulé, due aux écarts à la baisse.



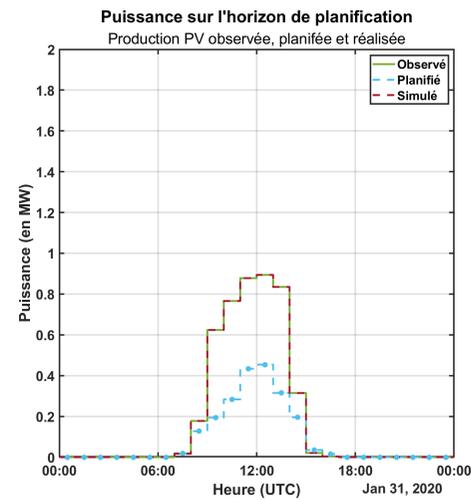
(a) Soutirage et batterie planifiés, charge prévue



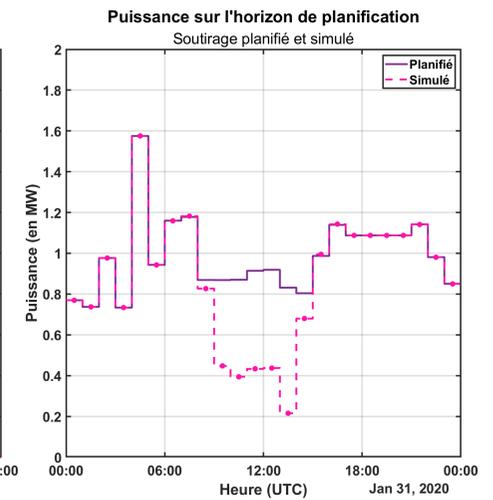
(b) PV prévu et planifié



(c) Etat de charge de la batterie prévu

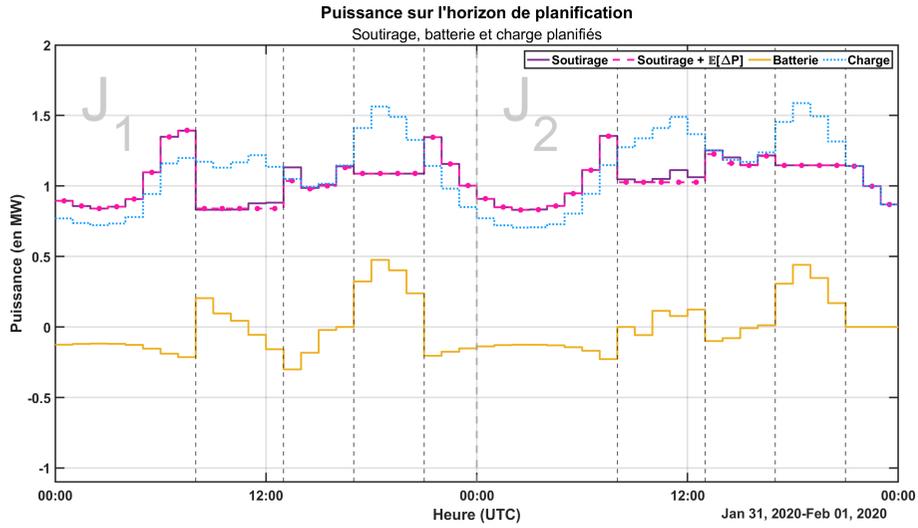


(d) PV planifié, observé et simulé

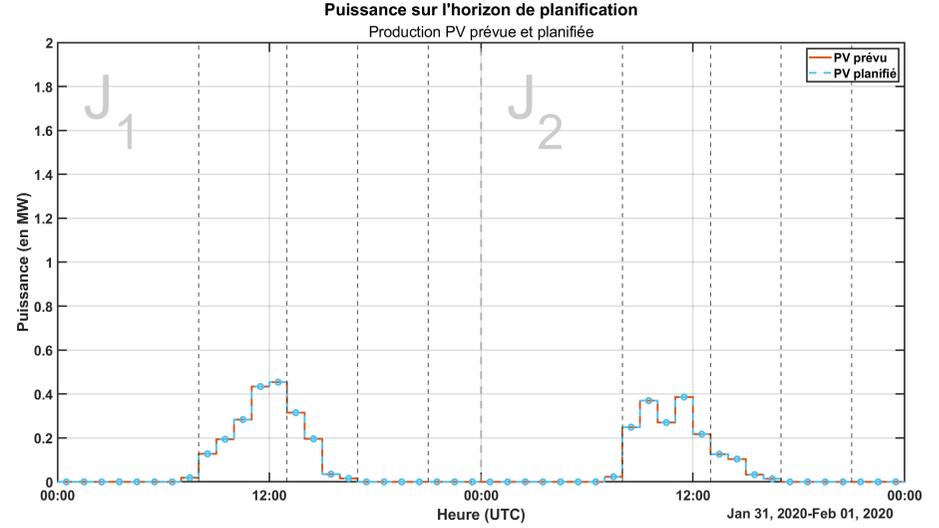


(e) Soutirage prévu et simulé

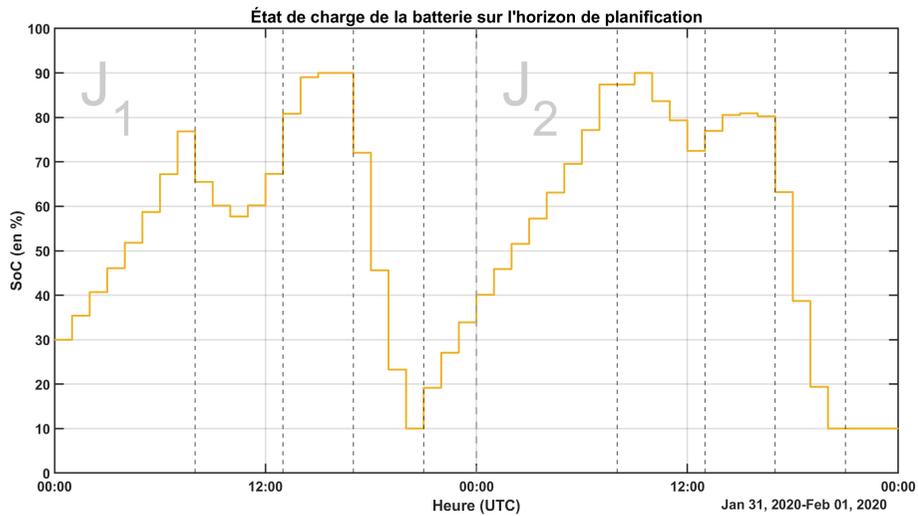
FIGURE 7.15 – Résumé des trajectoires issues de la planification à partir de 4 scénarios - Contrainte explicite - 31/01/2020



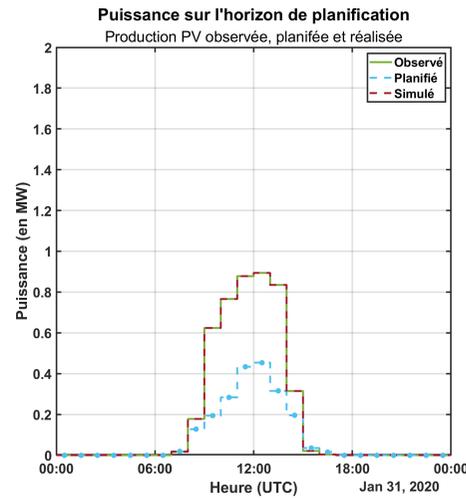
(a) Soutirage et batterie planifiés, charge prévue



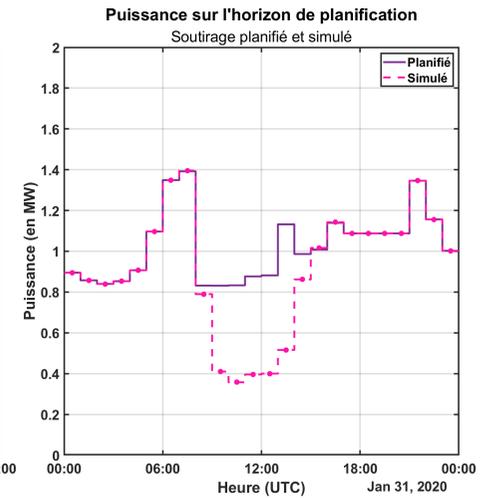
(b) PV prévu et planifié



(c) Etat de charge de la batterie prévu



(d) PV planifié, observé et simulé



(e) Soutirage prévu et simulé

FIGURE 7.16 – Résumé des trajectoires issues de la planification à partir de 4 scénarios - Contrainte incitative - 31/01/2020

Résultats

Les différents indicateurs sur les coûts et écarts journaliers sont consignés dans les tableaux 7.17 et 7.18 ci-dessous. Par rapport à l'approche déterministe, seule la stratégie explicite obtient un meilleur résultat après la simulation sur cette journée, la stratégie incitative a des résultats stables. Les bénéfices de l'approche stochastique pour la première stratégie sont ici d'avoir diminué le soutirage pour la pointe de la matinée. Comme expliqué dans les paragraphes précédents, les écarts prévus sont les mêmes, les écarts simulés seront donc aussi égaux, sauf en cas de modulation du PV.

	Coût journalier prévu (en)	Coût des écarts prévu (dont pénalités, en)	Coût journalier simulé (en)	Coût des écarts simulé (dont pénalités, en)
Contrainte explicite	4 270	-20 (4)	3 831	-459 (52)
Contrainte incitative	4 428	-20 (4)	3 988	-459 (52)

TABLEAU 7.17 – Résultats des coûts journaliers pour la planification - Cas 1 - 31/01/2020

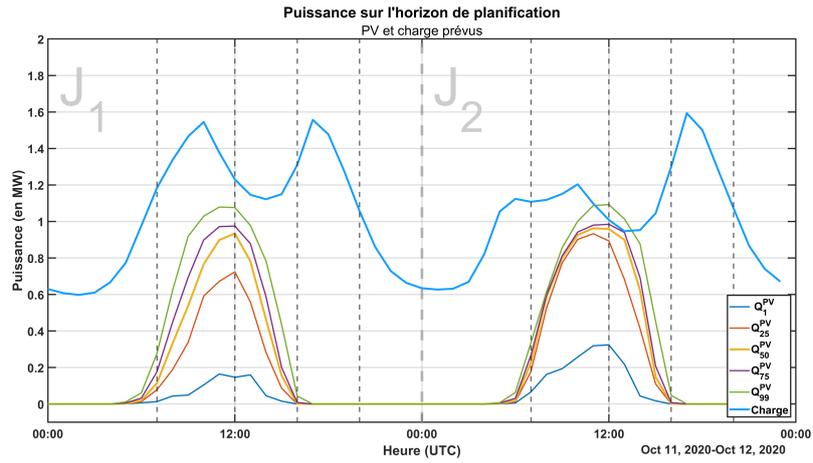
	Écarts journaliers prévus (en kWh)	Écarts journaliers absolus prévus (en kWh)	Écarts journalier simulés (en kWh)	Écarts journalier absolus simulés (en kWh)
Contrainte explicite	-171	222	-2 628	2 656
Contrainte incitative	-171	222	-2 628	2 656

TABLEAU 7.18 – Résultats des écarts journaliers pour la planification - Cas 1 - 31/01/2020

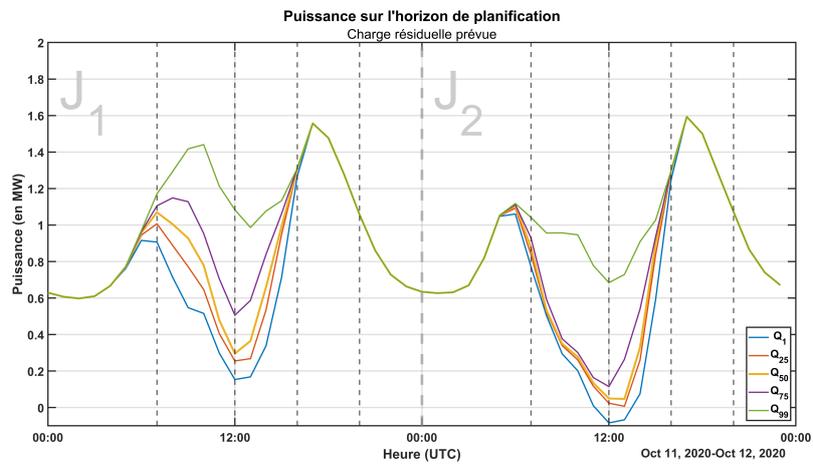
b) Cas 2

Présentation du cas

Les données d'entrée du second cas d'étude sont présentées sur la figure 7.17. On y retrouve la prévision probabiliste de productible PV et celle de charge, déterministe, ce qui permet d'en déduire celle de la charge résiduelle. Comparé au cas précédent, on observe ici une plus grande amplitude prévue avec des quantiles 50 et 25% assez bas en puissance. Pendant la seconde journée, on remarque même que le quantile 1% est inférieur à zéro pendant sur 2h, ce qui signifie un excédent de PV par rapport à la charge. Si la seconde journée annonce une grande confiance en une production PV importante, la première journée paraît moins sûre avec des quantiles plus dispersés sur la distribution de puissance.

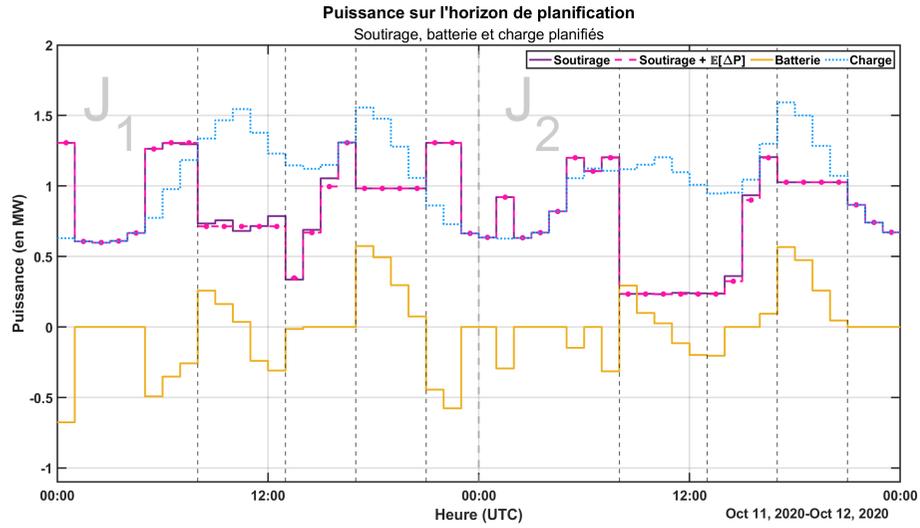


(a) Charge et PV prévus

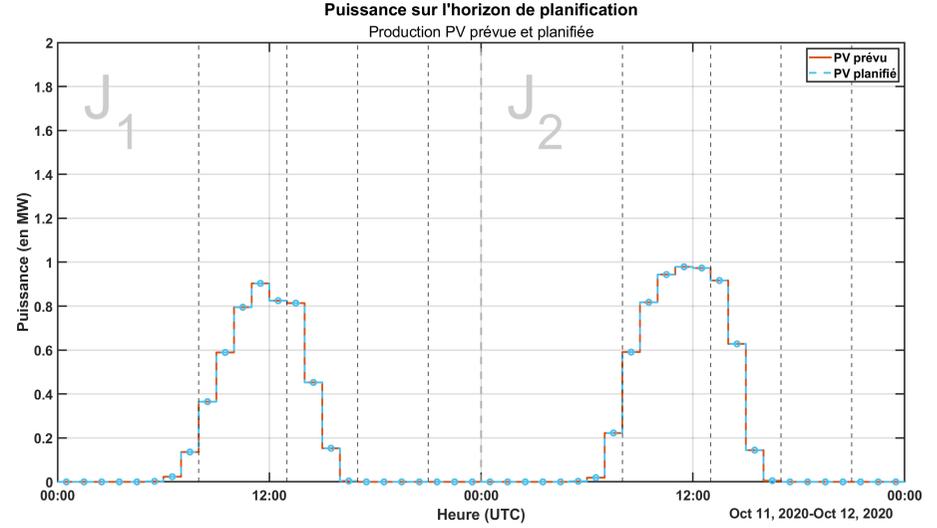


(b) Charge résiduelle prévue

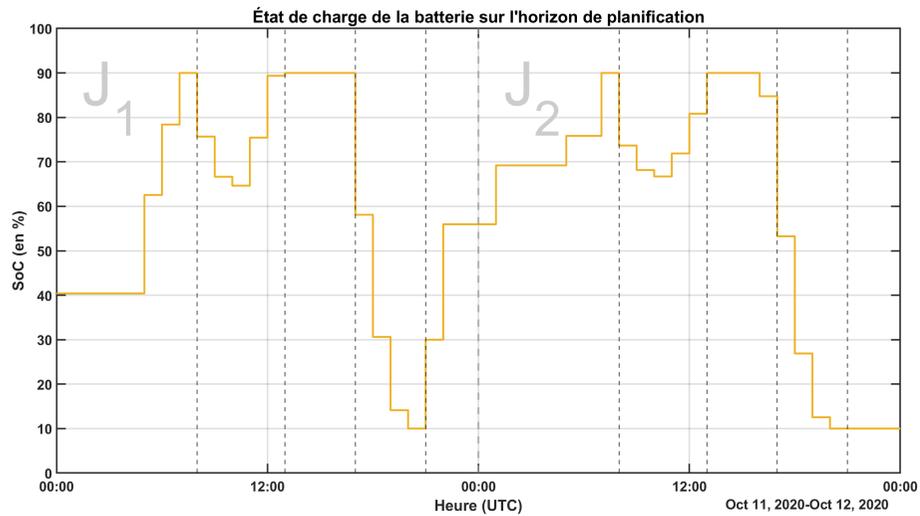
FIGURE 7.17 – Courbe de charge, production PV et charge résiduelles prévues à partir d'une prévision probabiliste - 11/10/2020



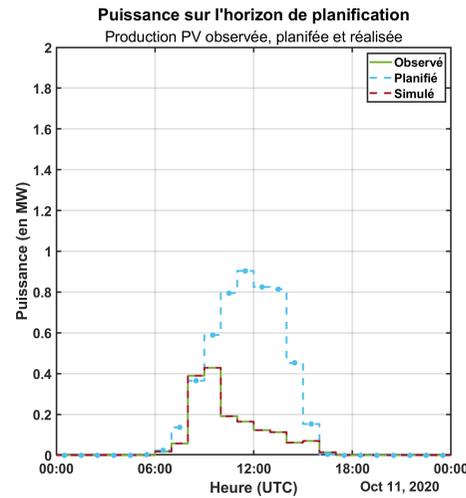
(a) Soutirage et batterie planifiés, charge prévue



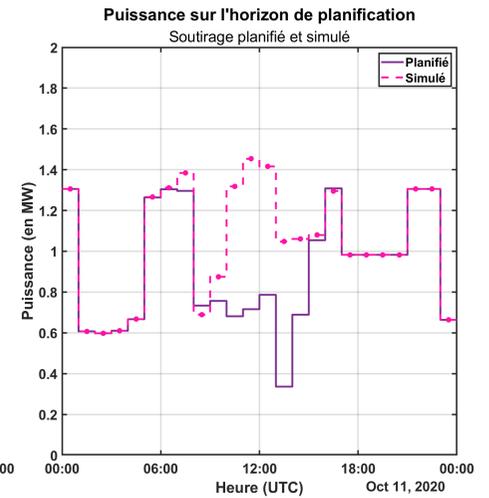
(b) PV prévu et planifié



(c) Etat de charge de la batterie prévu

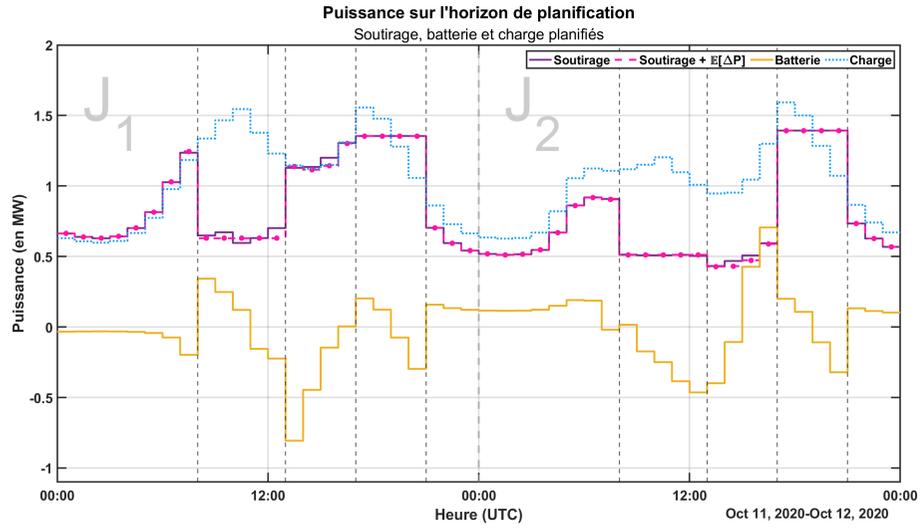


(d) PV planifié, observé et simulé

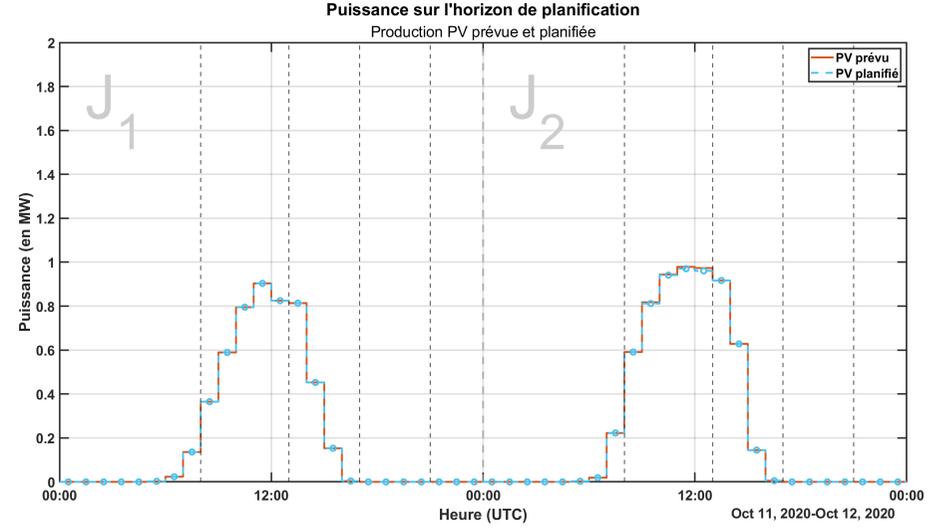


(e) Soutirage prévu et simulé

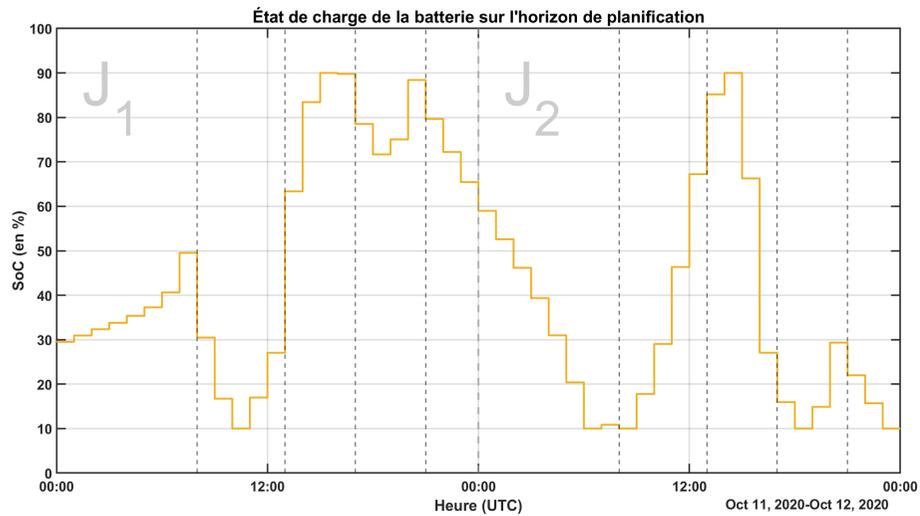
FIGURE 7.18 – Résumé des trajectoires issues de la planification à partir de 4 scénarios - Contrainte explicite - 11/10/2020



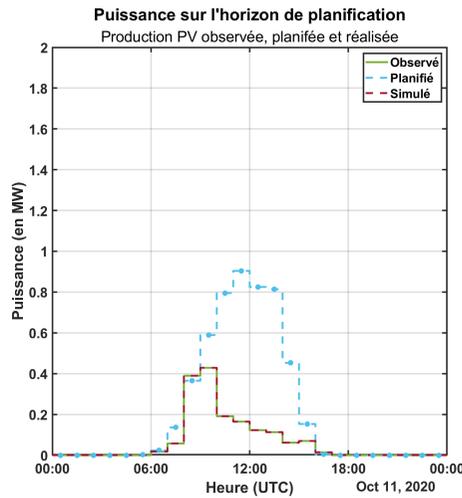
(a) Soutirage et batterie planifiés, charge prévue



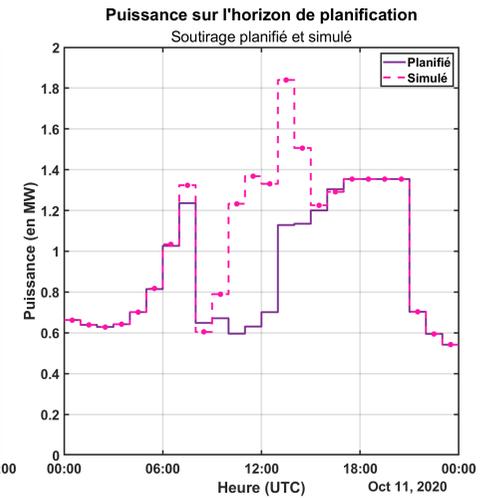
(b) PV prévu et planifié



(c) Etat de charge de la batterie prévu



(d) PV planifié, observé et simulé



(e) Soutirage prévu et simulé

FIGURE 7.19 – Résumé des trajectoires issues de la planification à partir de 4 scénarios - Contrainte incitative - 11/10/2020

Résultats

Les résultats des deux stratégies sont consignés dans les figures 7.18 et 7.19. Comme pour le cas précédent on remarque très peu de différences entre l'approche déterministe et la stochastique. Seule l'anticipation de petits écarts pendant la 1^{ère} pointe, permettant de moins utiliser la batterie, marque la différence entre les plans déterministe et la stochastique. On note tout de même que la prévision stochastique était un peu moins optimiste que la déterministe, ce qui a entraîné un choix de constante de soutirage plus élevé lors de la première pointe pour la stratégie explicite.

Les observations faite sur ces deux cas particuliers permettent de se rendre compte de la particularité de l'approche stochastique pour ce cas d'étude. Si elle ne va pas entraîner de grands changement en moyenne (id. « en espérance »), elle va permettre de réaliser de petits arbitrages qui seront bénéfiques sur l'ensemble de simulations. C'est ce que nous allons voir dans l'analyse des résultats globaux.

7.3.2 Résultats globaux et comparaison avec l'approche déterministe

a) Coûts d'opération

Après avoir détaillé les résultats de l'approche stochastique sur les deux journées sélectionnées, cette section propose de faire le bilan de la simulation de la planification sur l'ensembles des horizons considérés. En même temps que la synthèse de ces résultats prenant en compte l'incertitude, nous en profiterons pour les comparer avec ceux de l'approche déterministe.

	Coût total prévu (en k)	Coût des écarts prévus (dont pénalités en k)	Coût total simulé (en k)	Coût des écarts simulés (dont pénalités en k)
Contrainte explicite	1 194	-1,1 (1,2)	1 206	+10,1 (6,2)
Contrainte incitative	1 211	-1,0 (1,2)	1 222	+9,9 (6,2)

TABLEAU 7.19 – Résultats globaux des coûts d'opérations pour la planification stochastique

Le tableau 7.19 ci-dessus présente les principaux résultats économiques des deux simulations en fonction de la stratégie de réduction de l'amplitude de soutirage. Comme le montrent ces résultats, il y a toujours un écart entre les deux approches, à l'avantage de la stratégie explicite, lié à la gestion de la batterie qui permet de faire plus d'arbitrages économiques. Si l'on compare les planification sdéterministe et stochastique, on constate que les dynamiques sont opposés en fonction de la stratégie. En effet le coût total de la stratégie explicite a augmenté de 489 (soit de 1,4 par jour simulé) et celui de la stratégie incitative diminue de 835 (soit de 2,5 par jour). Ces écarts de prix sont marginaux par rapport au coût totaux d'opérations.

La figure 7.20 permet de se rendre compte que la gestion de la batterie est quasiment identique à celle de l'approche déterministe présentée figure 7.12. Ces petites variations au niveau du prix sont dues à l'anticipation des écarts, car même si en moyenne les trajectoires planifiées sont similaires, l'approche stochastique, de par sa connaissance plus fine du futur, permet de faire de petits gains.

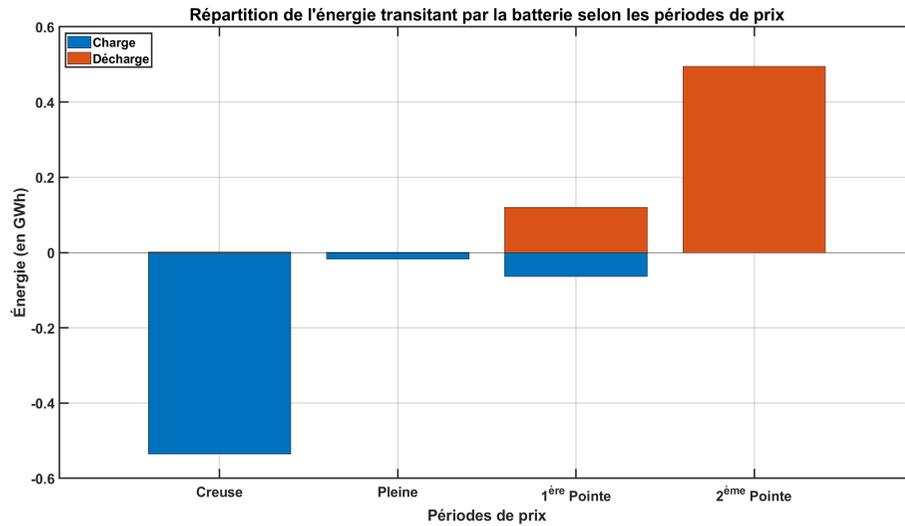
b) Anticipation des écarts

Dans ce cas la nuance ajoutée par l'approche stochastique a donc finalement peu d'effet sur les résultats globaux économiques. Si l'on se penche sur l'anticipation des écarts par cette planification, on peut voir dans le tableau 7.19 que l'approche stochastique prévoit des écarts globalement négatifs, ce qui est assez logique puisque permettant de gagner sur les coûts d'opération. Or on observe qu'une fois simulés, leurs coûts sont globalement positifs.

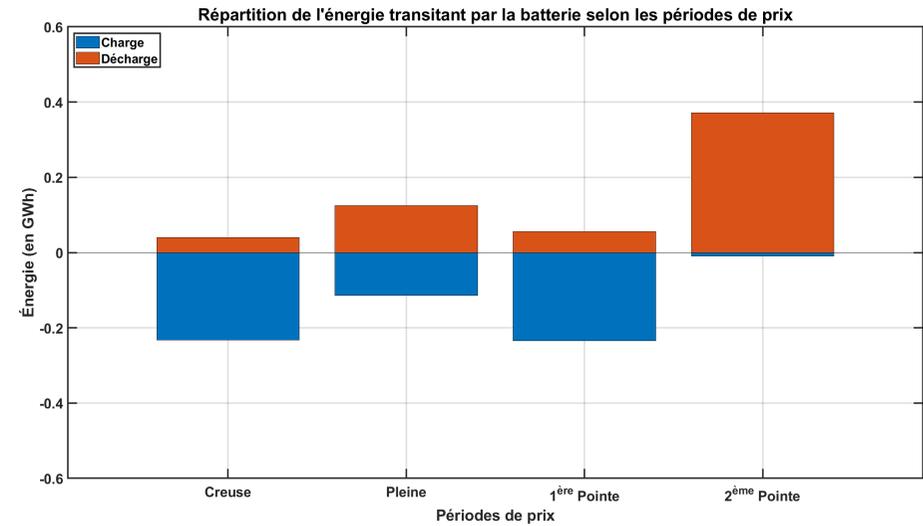
On remarque une légère différence entre les deux stratégies, qui s'explique, comme pour l'approche déterministe (voir section 7.2.2), par le fait que la simulation issue de la stratégie incitative prévoit de moduler plus souvent le PV à la baisse (5,5 contre 0 MWh). La figure 7.21 permet de détailler la structure des écarts sur pour la simulation avec la stratégie explicite, les écarts étant quasiment identiques peu importe la stratégie de réduction de l'amplitude employée, on se contentera de son analyse. Le graphique 7.21a illustre la différence entre les écarts observés (entre la prévision PV et sa réalisation), les écarts prévus par la prévision et les écarts une fois la simulation effectuée. Ces écarts sont signés permettant de différencier les écarts à la hausse et à la baisse. On voit donc que la planification sous-estime assez logiquement les écarts : étant pénalisés, il faut des conditions particulières pour que la prévision en anticipe. De façon générale, la planification stochastique va chercher une trajectoire de soutirage et de batterie permettant de minimiser ces écarts (et donc leurs coûts). Dans certains cas, il vaut mieux se priver ou réduire l'utilisation de la batterie, et de ses pertes de rendements, et prévoir de subir de faibles écarts tout en respectant les contraintes, comme illustré sur la première période de pointe des cas particuliers étudiés (voir section 7.3.1.a).

Si on peut anticiper la distribution des écarts de la prévision PV, il est impossible de connaître lors de la planification leur valeur réalisée et si l'on prévoit un écart à la hausse, il est tout à fait possible que l'écart réel soit à la baisse. On observe donc sur la figure 7.21a, que les écarts observés viennent donc s'ajouter en partie aux écarts prévus quand ils leur sont supérieurs ou de signe opposés. Dans les cas où le signe de l'écart était bien anticipé, l'écart simulé sera donc minoré par l'écart prévu. Sur la globalité de la simulation, la planification prévoit des écarts totaux de -17 MWh pour des écarts simulés à 24 MWh soit une erreur de 41 MWh contre 48 MWh pour la planification déterministe, on a donc réussi à « gommer » 7 MWh d'écarts. Cependant si l'on s'intéresse aux écarts absolus on remarque qu'ils ont augmentés en passant de 310 MWh à 323 MWh, on peut donc voir que si leur coût global a diminué en passant de +15 k à +10 k, le montant des pénalités a lui augmenté de 300, car proportionnel aux écarts absolus (voir figure 7.21c).

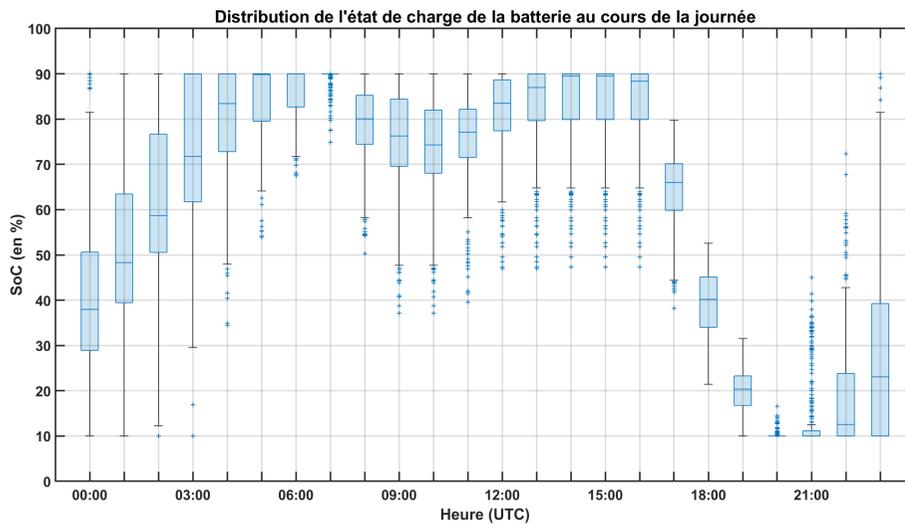
Les figures 7.21c et 7.21d, représentant la distribution de l'espérance des écarts prévus et celle des écarts simulés pour chaque heure de l'horizon considéré. On observe bien sur le premier graphique, les efforts de la planification pour anticiper des écarts assez faibles mais les écarts simulés montrent que l'aléa est bien différent de son espérance : en pratique la distribution des écarts sera bien plus grande.



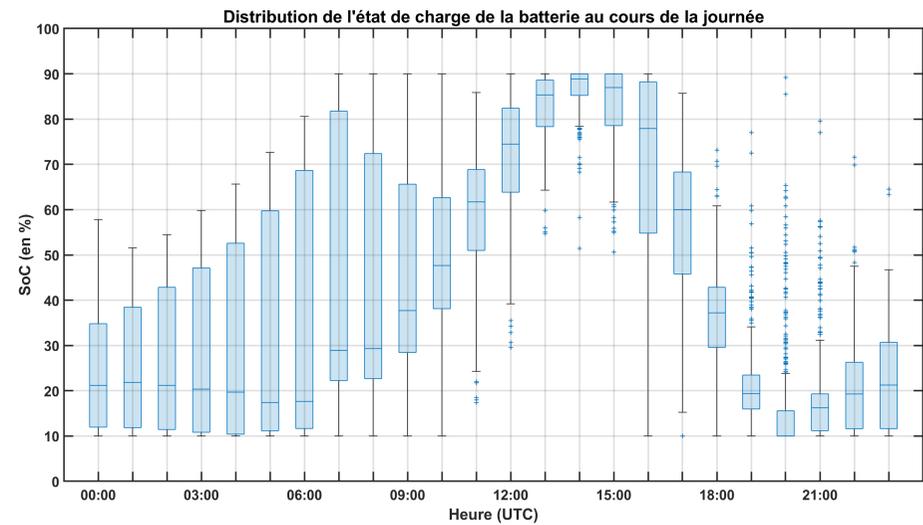
(a) Énergie transitant par la batterie selon les périodes de prix - Contrainte explicite



(b) Énergie transitant par la batterie selon les périodes de prix - Contrainte incitative

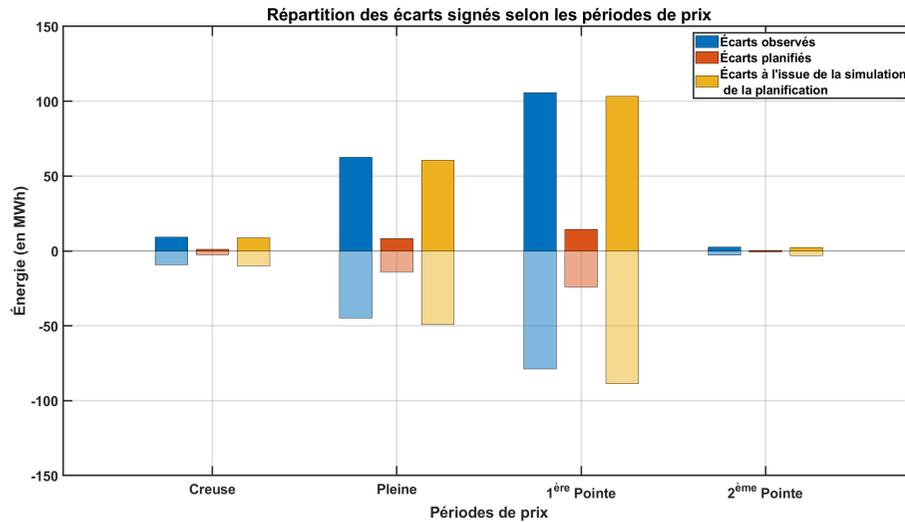


(c) Distribution de l'état de charge de la batterie au cours de la journée - Contrainte explicite

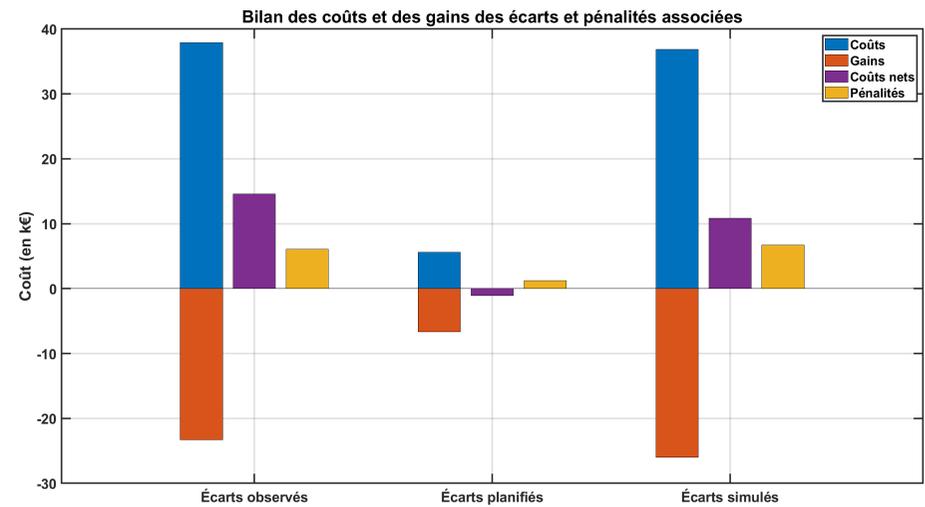


(d) Distribution de l'état de charge de la batterie au cours de la journée - Contrainte incitative

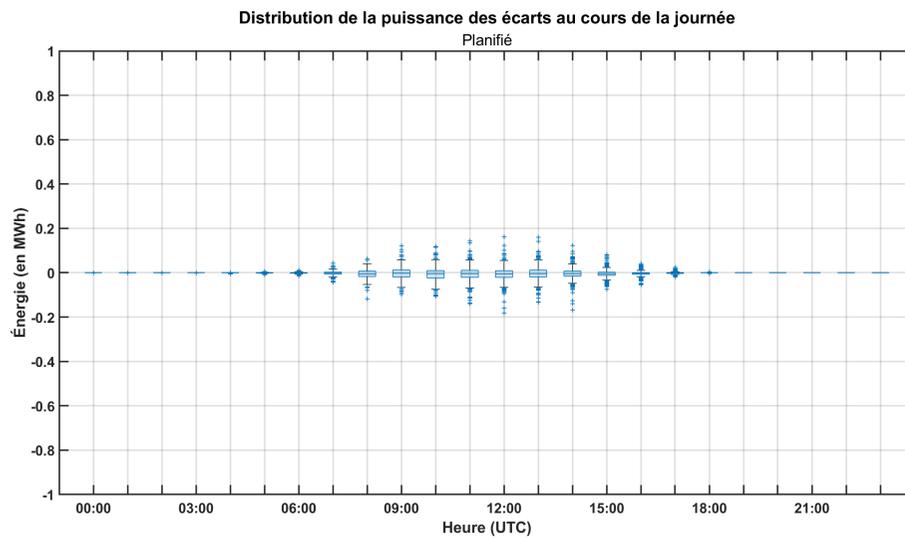
FIGURE 7.20 – Résumé des trajectoires de la batterie sur l'ensemble des journées simulées - Synthèse planification stochastique



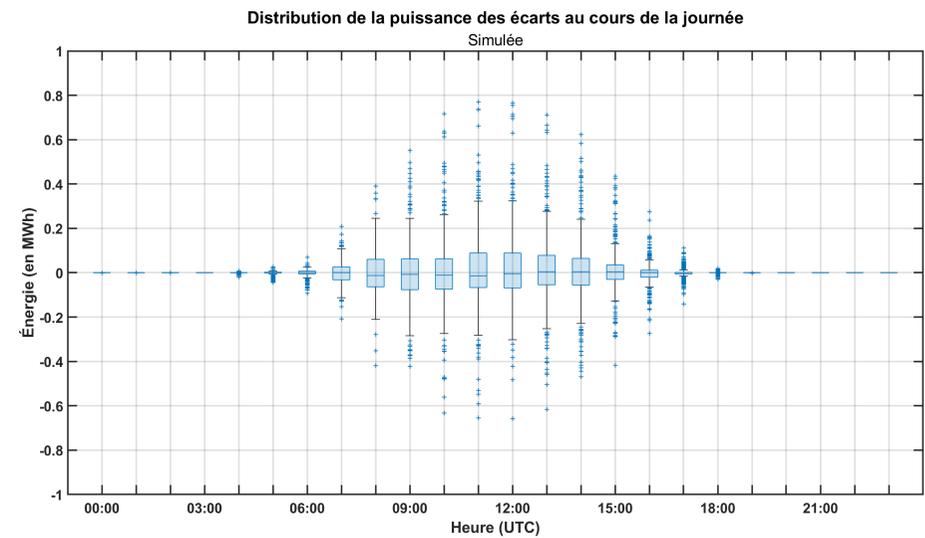
(a) Distribution des écarts signés selon les périodes de prix - Contrainte explicite



(b) Comparaison du coût des écarts prévus et simulés - Contrainte explicite



(c) Distribution de l'espérance des écarts prévus au cours de la journée - Contrainte explicite



(d) Distribution des écarts simulés au cours de la journée - Contrainte explicite

FIGURE 7.21 – Résumé des écarts et de leurs coûts sur l'ensemble des journées simulées - Synthèse planification stochastique

c) Objectifs de soutirage

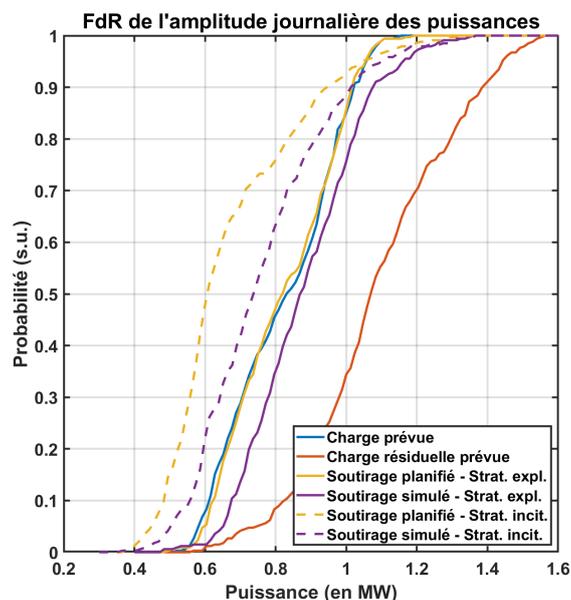


FIGURE 7.22 – Distribution des amplitudes journalières prévues et simulées en fonction de la stratégie

Concernant l'objectif de réduction de l'amplitude de soutirage pour la planification stochastique, la figure 7.22 présente les distributions de l'amplitude journalière planifiée et simulée pour les deux stratégies mises en place. Lors de la planification, l'objectif est toujours rempli pour la contrainte explicite et pour 73% des journées dans le cas de l'autre stratégie. En revanche on observe une augmentation de la médiane de l'amplitude prévue ainsi que de la simulée pour la contrainte explicite. Le taux d'augmentation de l'amplitude après simulation passe alors à 63%, contre 48% pour l'approche déterministe, mais l'amplitude médiane reste tout de même proche de celle de la charge (+42 kW). Ceci s'explique par le fait que la stratégie explicite entraîne souvent un minimum de soutirage entre 10h et 15h, soit lorsque l'énergie PV est élevée et que les écarts sont plus importants en moyenne. A l'inverse la contrainte incitative ne subit pas de tel et respecte l'objectif dans 59% des cas après simulation.

Nous avons donc vu ce que pouvait entraîner l'anticipation des écarts de l'approche stochastique pour la planification : si les trajectoires planifiées sont en moyenne identiques à l'approche déterministe, la prise en compte des écarts dans le modèle permet d'effectuer des arbitrages supplémentaires avec la batterie. Ces derniers peuvent donc influencer à la marge la fonction objectif mais également les contraintes de soutirage fixées. Néanmoins, ces résultats sont à nuancer car obtenus à partir de simulations considérant uniquement 4 scénarios. Les sections suivantes vont donc permettre de montrer l'influence de cette représentation de l'incertitude qu'est un ensemble de scénario, à commencer par la **cardinalité** de ce paramètre d'entrée dans la planification stochastique.

7.4 Influence du nombre de scénarios

Pour analyser l'influence des scénarios sur la simulation on va tout d'abord s'intéresser aux coûts d'opération totaux. En effet, ce sont les coûts d'achat d'énergie depuis le réseau, associés aux coûts du règlement des écarts qui forment la fonction objectif que minimise le problème de planification. Plus on fournit des prévisions de qualité au problème, plus on s'attend à obtenir de

bons résultats avec la méthode de planification. Comme nous l'avons décrit dans le chapitre 4, plus un ensemble de scénario est important, plus il est susceptible de fournir une grande quantité d'information et d'être pertinent pour le problème de planification.

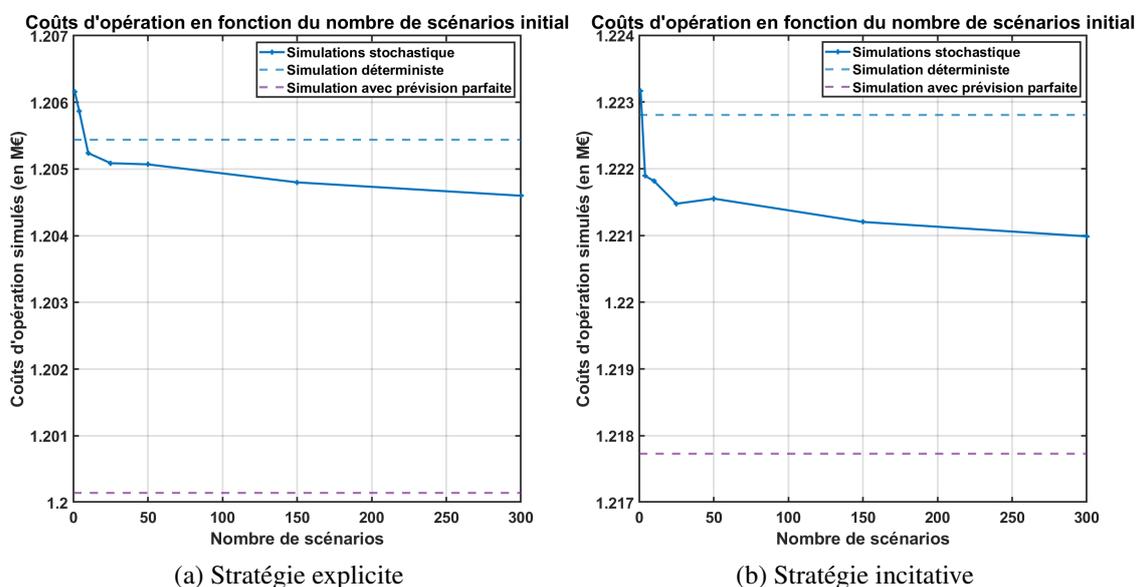


FIGURE 7.23 – Evolutions des coûts d'opération simulés en fonction du nombre de scénarios initial en paramètre d'entrée du problème de planification

La figure 7.23 ci-dessus permet de représenter, pour les deux stratégies, l'évolution des coûts d'opération simulés en fonction du nombre de scénarios initial, leur nombre variant de 1 à 300. Pour chacune des approches, on choisit deux simulations de référence afin de pouvoir les comparer : la planification déterministe, effectuée à partir d'une prévision déterministe (Q_{50}) et la planification « parfaite », effectuée à partir des observations de la puissance PV produite. Cette dernière n'entraîne donc aucun écart entre la planification et la simulation du plan, on peut donc considérer qu'elle représente le minimum des coûts d'opération tout en respectant les contraintes.

La tendance, quel que soit la stratégie, est la même sur ces deux figures : on peut observer une réduction des coûts d'opération lorsque l'on augmente de nombre de scénarios fournis au problème d'optimisation. Ainsi, pour un unique scénario, cas de figure où le moins d'information est disponible, les coûts sont certes proches de ceux de la simulation déterministe mais tout de même supérieurs. En suite, le nombre de scénarios augmentant, les coûts d'opérations vont tendre asymptotiquement vers leur limite. Les gains obtenus par rapport aux coûts totaux de l'approche déterministe paraissent marginaux, mais la différence entre la simulation déterministe et parfaite est elle aussi marginale : il y a moins de 0,5% de différence entre les deux. Si l'on s'intéresse aux gains possibles entre la simulation déterministe et la simulation parfaite, cela représente 5 294 pour la stratégie explicite. Si l'on regarde maintenant le gain de la simulation stochastique avec 300 scénarios par rapport à la déterministe, on constate un gain de 840 soit -15% et un gain journalier médian de 2,78. Le fait d'avoir plus de scénarios à disposition va donner au problème de planification plus de latitude et d'informations pour estimer et choisir la trajectoire optimale en espérance.

Comme illustré sur la figure D.13 en annexe, l'augmentation du nombre de scénarios va mener à une diminution des écarts planifiés. Cela va faire tendre les écarts absolus simulés vers ceux observés, permettant de minimiser les pénalités tout en faisant des arbitrages avec la batterie engendrant des gains.

Si ces figures permettent d'illustrer les gains effectués par l'approche stochastique, ils illustrent également la faible part qu'occupent les écarts dans notre cas d'étude. On pouvait s'attendre à cette place assez neutre des écarts dans la modélisation puisqu'ils ont finalement une importance

réduite dans la fonction objectif, étant pénalisés de seulement 10% par rapport au prix d'achat de référence. Dans cette situation, le micro-réseau était donc finalement peu exposé au risque, même en ignorant les écarts lors de la planification. Afin d'illustrer les apports de la planification stochastique dans l'anticipation des écarts, on se propose d'étudier les résultats pour différentes valeurs de pénalités dans la section suivante.

7.5 Influence de la pénalité des écarts

Comme expliqué dans la section précédente, du fait de la faible contribution des pénalités au problème, le micro-réseau n'apparaît pas assez exposé au risque économique pour justifier de l'utilisation de la planification stochastique. Dans cette section, on propose donc d'étudier les résultats de la planification stochastique, en faisant varier l'importance de la pénalité.

Comme expliqué dans la section 6.4.1, le prix des écarts dépend du prix du soutirage, auquel est affecté une pénalité, négative ou positive en fonction du signe de l'écart. Dans le cas de référence la pénalité est de 10% du prix d'achat de l'énergie. On étudiera ici les résultats pour une pénalité de 50% et de 80%. Les résultats sont synthétisés dans les figures 7.24a et 7.24b, où l'on observe les coûts d'opération simulés en fonction de la pénalité et du nombre de scénarios initial. Ici, la simulation de la planification « parfaite » servira toujours de référence.

Premièrement, on constate bien l'augmentation des coûts d'opération avec celle de la pénalité : les coûts de la simulation déterministe augmentent de 2 380 (+2,0%) pour une pénalité de 50% et de 3 450 (+3,5%) pour une pénalité de 80%. Ces résultats corroborent les conclusions précédentes sur la faible part occupée par les écarts dans la fonction objectif économique. De plus, concernant les résultats des simulation stochastiques, on remarque que les coûts sont bien décroissants en fonction du nombre de scénarios initial.

Deuxièmement, ces résultats nous montrent l'importance de l'approche stochastique dans un cas où l'exposition au risque est plus importante. En effet, la différence entre les résultats déterministe et la meilleure simulation stochastique (systématiquement celle avec 300 scénarios) croît avec celle de la pénalité. Pour un même aléa, les écarts observés ici n'ayant pas changés, plus la pénalité est importante, plus l'utilisation d'une planification stochastique se justifie, quelle que soit la stratégie adoptée.

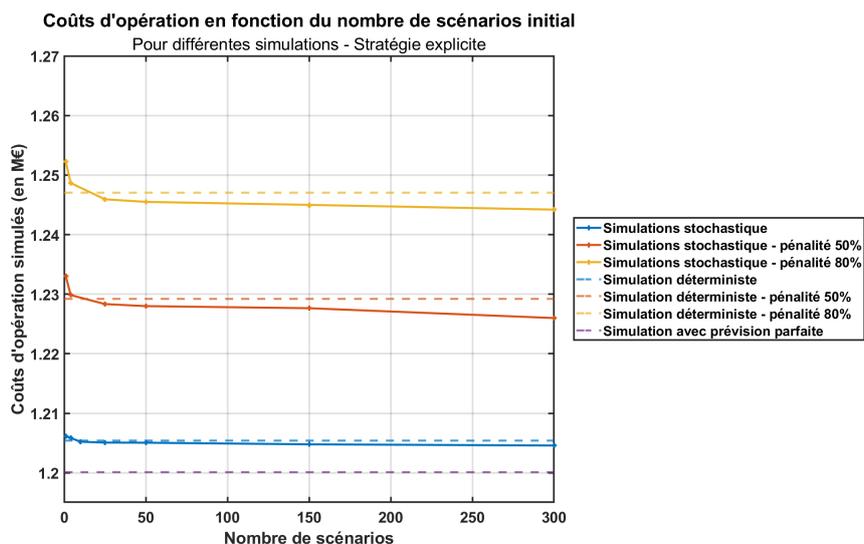
7.6 Intérêt de la méthode de génération de scénarios

Si la question précédente illustre l'importance de l'approche stochastique avec l'augmentation des pénalités, on peut désormais se poser la question des scénarios pris comme donnée d'entrée. En effet jusqu'à lors nous avons utilisé, les méthodes de génération puis celle de réduction présentées chapitre 4. Cette section se propose d'étudier l'intérêt de cette méthode à travers ses deux caractéristiques principales : la prise en compte de la dépendance temporelle et la réduction de l'ensemble de scénario.

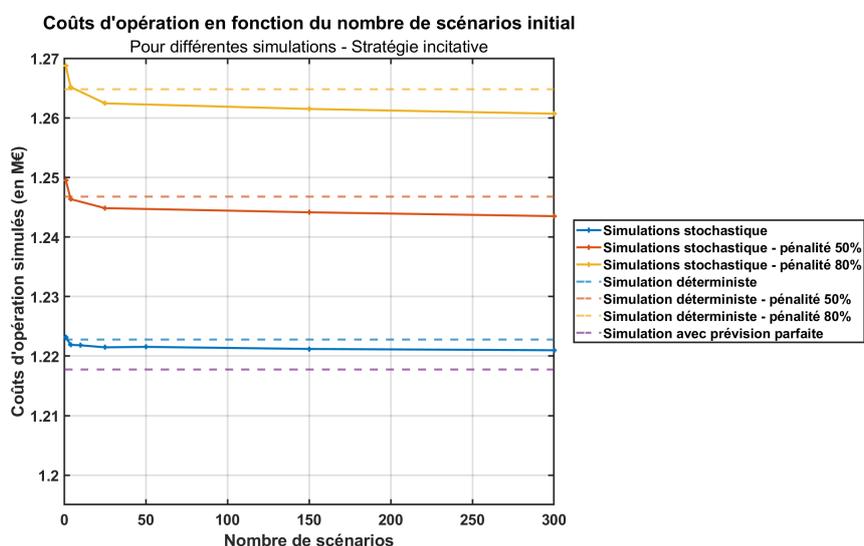
7.6.1 Prise en compte de la dépendance temporelle

Tout d'abord, la prise en compte de la dépendance temporelle est étudiée. Pour cela on effectue l'étape de génération de scénario présentée section 4.1.1, en ignorant la loi conjointe des variables considérées (la production PV à chaque heure de la journée), puis en la prenant en compte. Une fois ces deux ensembles de scénarios distincts générés, on peut les utiliser comme paramètres pour la simulation de la planification du micro-réseau étudiée.

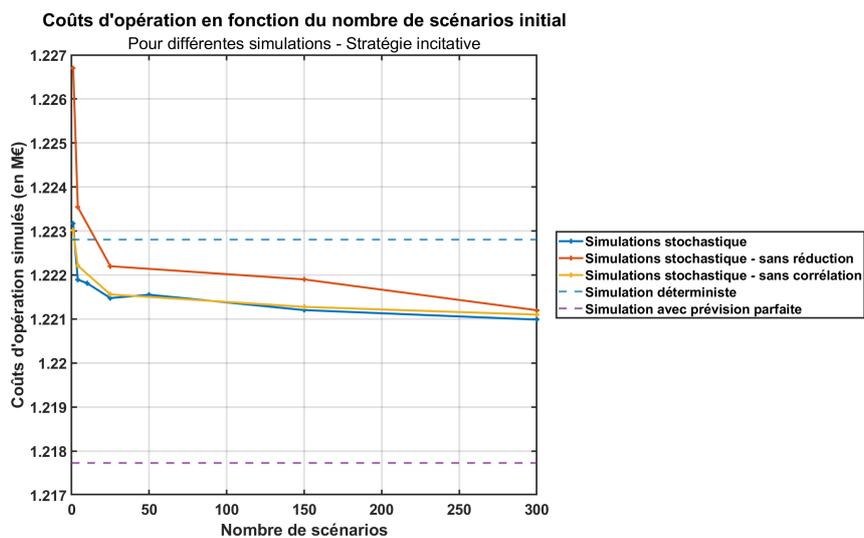
Les résultats sont présentés figure 7.24c. Quel que soit le nombre de scénarios étudiés, le résultat des deux approches est très proche. On peut donc en conclure que l'intérêt de la modélisation de la corrélation temporelle est limité dans ce cas de planification : seule les distributions marginales de la puissance PV semblent influencer les résultats.



(a) Coûts d'opérations en fonction de la pénalité et du nombre de scénarios - Stratégie explicite



(b) Coûts d'opérations en fonction de la pénalité et du nombre de scénarios - Stratégie incitative



(c) Coûts d'opérations en fonction de la pénalité - Sans corrélation ni réduction - Stratégie incitative

FIGURE 7.24 – Evolution des coûts d'opération pour diverses simulations

7.6.2 Méthode de réduction de scénario

Par la suite, l'intérêt de la méthode de réduction de scénario est questionnée. Dans un premier temps, on effectue donc l'étape de génération de scénario en choisissant directement le nombre de scénario voulu puis d'un autre côté en tirant un très grand nombre et en utilisant consécutivement la méthode de réduction (voir section 4.2). Une fois ces deux ensembles de scénarios générés, on peut les utiliser comme donnée d'entrée pour la simulation de la planification.

La figure 7.24c permet de comparer les deux approches. Si on remarque une différence marquée pour les petits ensembles de scénarios, elle s'estompe à mesure de leur augmentation. Cette différence est assez logique puisque plus un ensemble de scénario est important mieux il représentera la distribution escomptée. La méthode de réduction montre donc son intérêt pour les ensembles de scénarios très réduits.

7.7 Conclusions, limites et perspectives

Ce chapitre nous a donc permis d'analyser en profondeur les résultats du cas d'étude mis en place pour simuler la planification d'un micro-réseau sous incertitude. Nous avons tout d'abord illustré l'intérêt d'avoir des prévisions de qualité à disposition mais également d'un système de stockage puis celui de l'anticipation amenée par un modèle de planification.

Notre objectif était de minimiser les coûts d'opération du système, constitués de l'approvisionnement en énergie mais aussi du coût des écarts engendrés par la différence entre prévision et production PV. De plus, nous voulions apporter un service système au réseau : limiter l'amplitude journalière du soutirage. Pour cela, nous avons mis en place deux contraintes : l'une permettant uniquement de limiter l'augmentation de l'amplitude et l'autre incitant à la réduire. Le défi était de prendre en compte l'aléa PV dans cette simulation, un modèle déterministe et un stochastique ont donc été comparés.

Nous avons tout d'abord montré l'efficacité des contraintes mises en place pour contenir mais aussi pour diminuer l'augmentation de l'amplitude, engendrée par la combinaison de l'énergie PV et de la charge ; et ce pour un coût limité. De plus nous avons étudié l'impact de l'approche stochastique sur l'anticipation des coûts d'opération et des écarts. Dans notre cas de référence, l'exposition aux coûts étant limitée, les gains de la simulation stochastique le sont tout autant sur les coûts globaux, mais importants par rapport au meilleur scénario possible (en connaissance parfaite des incertitudes). De plus, en cas de plus forte exposition au risque des écarts, nous avons montré que l'approche stochastique pourrait s'avérer précieuse. Nous avons également présenté l'intérêt de la réduction de scénarios pour les ensembles à cardinalité limitée, ce qui pourrait s'avérer utile pour diminuer la taille des problèmes d'optimisation. En revanche la prise en compte de la corrélation s'est avérée limitée.

Si les objectifs de soutirage étaient naturellement remplis lors de la planification, la simulation entraîne une assez forte dégradation de ces objectif. Pour y palier, il est tout à fait possible d'envisager une modélisation robuste ou à contraintes probabiliste (voir section 2.1.3). L'autre solution aurait été de monétiser cette réduction d'amplitude pour qu'elle influe la fonction objectif, tel un autre service système (voir section 2.3.2), mais un tel service n'existant pas ça n'a pas été possible. A défaut nous avons pu estimer son impact sur les coûts d'opération. On pourrait également mettre en place une autre méthode de simulation du plan avec son pilotage et son contrôle, permettant alors de limiter les écarts à une échelle temporelle plus fine et moins anticipée. Concernant l'objectif d'autoconsommation, on aurait pu l'augmenter en fixant des contraintes supplémentaires sur la charge de la batterie, notamment en interdisant la charge de nuit.

De plus, ce système est assez limité, présentant une structure de prix simple, peu d'entités et avec une seule source d'incertitudes. Il serait tout à fait possible d'y ajouter des éléments comme une autre centrale PV ou une production éolienne, où le modèle de corrélation pourrait se montrer précieux.

Conclusion générale et perspectives

Les objectifs établis visaient à caractériser l'incertitude liée à la production photovoltaïque en exploitant statistiquement un maximum d'informations. Le but suivant était de considérer son utilisation et étudier son impact sur la planification de micro-réseaux, en développant un modèle optimisant les coûts d'opération tout en intégrant cette incertitude. Ces objectifs sont atteints au fil différents chapitres et des travaux effectués, on peut ainsi montrer une progression méthodique vers leur réalisation.

Le chapitre 3 se concentre sur la première étape cruciale, à savoir celle de la caractérisation de l'aléa photovoltaïque. En exploitant les prévisions probabilistes pour estimer les distributions des variables marginales tout en validant la méthode grâce aux mesures, ce chapitre répond directement au premier objectif. La modélisation de la dépendance entre ces variables, à l'aide de copules, apporte une compréhension approfondie et fine de l'incertitude, essentielle pour les étapes ultérieures de modélisation pour la planification.

Si la caractérisation de la corrélation a été probante, il n'est pas exclu qu'il existe des modèles plus performants. On pourrait ainsi continuer les explorations en ce sens en utilisant d'autres modèles de copules, comme les copule de vine ou une copule empirique si plus de données venaient à être disponibles. Il serait également possible de discuter l'hypothèse, utilisée dans nos travaux, d'un modèle de corrélation global. Il serait en effet judicieux d'étudier les variations de la dépendance en fonction de journées météorologiques « types » ou sur un horizon temporel glissant. Nous serions également en mesure d'exploiter cette méthode sur une granularité temporelle différente ou même spatiale. Pour finir, on notera qu'il pourrait être envisagé de poursuivre l'étude de cette approche en prenant en compte de nouvelles sources d'incertitude, comme la charge ou l'énergie éolienne.

Le chapitre 4 aborde le développement de techniques pour générer et réduire des ensemble de scénarios, permettant une représentation de l'incertitude plus exploitable pour la planification. En réduisant efficacement le nombre de scénarios tout en conservant une représentation fidèle de l'incertitude, ce chapitre contribue directement au premier objectif mais contribue également au second en permettant d'optimiser les ressources computationnelles et de simplifier la gestion des incertitudes dans la planification opérationnelle des micro-réseaux.

Cette section de l'étude a donc été consacrée à la mise en place et à la sélection d'une méthodologie efficace pour la réduction de scénarios et à sa paramétrisation. Une attention particulière a été portée sur l'évaluation du temps d'exécution de la méthode choisie, ainsi que sur l'impact du nombre de scénarios initial et final sur les résultats. Un indicateur a été présenté pour quantifier la perte d'information, ce qui permet une analyse plus précise et contrôler des résultats obtenus par la méthode de réduction.

Pour renforcer la fiabilité des résultats obtenus par cette méthode de réduction, il serait judicieux de les confronter à des indicateurs complémentaires. Ces indicateurs devraient permettre d'évaluer la représentativité des comportements des données observées dans les scénarios réduits, offrant ainsi une perspective scientifique plus solide sur l'efficacité de la méthodologie adoptée. L'intégration de ces indicateurs permettrait d'assurer que la réduction des scénarios maintient une fidélité suffisante aux données originales, garantissant ainsi l'intégrité des analyses subséquentes basées sur ces scénarios.

Le chapitre 5 développe l'assimilation de données pour améliorer les prévisions de production photovoltaïque. En intégrant de nouvelles informations pour raffiner les prévisions, ce chapitre renforce la maîtrise de l'information et la précision des prévisions, en ligne avec les deux premiers objectifs. Cette amélioration est cruciale pour adapter la prévision en temps réel et gestion du micro-réseau en conséquence, en tenant compte des variations et des imprévus.

Cette technique repose sur l'utilisation des modèles de corrélations développés précédemment ainsi que sur le calcul de distributions conditionnelles. Bien que cette méthode puisse présenter des limites dans certains cas, où elle peut s'avérer trompeuse et empirer la prévision, elle fournit en globalité des informations statistiques précieuses et contribue efficacement à la gestion de l'incertitude associée au vecteur aléatoire étudié.

Cette méthode d'assimilation d'observations pourrait être particulièrement utile dans des contextes où les prévisions régulières ne sont pas disponibles, malgré le fait que la plupart des fournisseurs de prévisions offrent des mises à jour fréquentes. Pour optimiser ce processus, il serait bénéfique de considérer des observations sur des échelles de temps réduites, d'utiliser des modèles de dépendance alternatifs, ou intégrer d'autres sources de données comme des capteurs.

Le chapitre 6 permet de mettre en place notre cas d'étude, les entités le composant, les risques et contraintes auquel il est exposé. Il illustre également notre travail de modélisation. En effet, on y détaille le passage d'un modèle de planification déterministe à un modèle stochastique, tout en définissant un cadre pour pouvoir comparer leurs résultats par la suite. C'est aussi dans ce chapitre que sont décrites les deux stratégies mises en place pour réduire l'amplitude de soutirage.

Le chapitre 7 approfondi l'analyse des résultats d'une étude de cas dédiée à la simulation de la planification d'un micro-réseau électrique sous incertitude, permettant de comprendre le fonctionnement et l'action de tels modèles. L'étude a mis en évidence l'importance de disposer de prévisions de qualité et d'un système de stockage, ainsi que les avantages d'un modèle de planification anticipative. L'objectif principal était de minimiser les coûts d'opération du système, qui incluent à la fois l'approvisionnement en énergie et les coûts liés aux écarts engendré par l'aléa de la production photovoltaïque, entre prévision et réalisation. En outre, l'étude visait à offrir un service au réseau consistant à limiter l'amplitude journalière du soutirage d'énergie.

Pour atteindre ces objectifs, deux types de contraintes ont été implémentées : une visant à limiter l'augmentation de l'amplitude du soutirage, et l'autre à la réduire. L'incertitude liée à la production photovoltaïque a été un défi central, adressé par la comparaison entre un modèle déterministe et un modèle stochastique. Les résultats ont montré que les contraintes étaient efficaces pour contrôler l'augmentation de l'amplitude à un coût modéré et que l'approche stochastique était bénéfique pour anticiper les coûts des écarts mais pas forcément sur les respect des contraintes espéré. En montrant l'avantage des approches stochastiques sur les approches déterministes pour gérer l'incertitude, ce chapitre souligne l'efficacité des méthodes développées pour optimiser les coûts d'opération et améliorer la fiabilité et l'exposition au risque du système. Cela répond directement au second objectif en mettant en lumière l'importance d'intégrer les ensembles de scénarios dans la planification.

L'étude a également souligné l'utilité de la réduction de scénarios pour obtenir des ensembles à **cardinalité** limitée, facilitant ainsi la résolution des problèmes d'optimisation. Cependant, la corrélation entre les variables bien que prise en compte, montre un intérêt limité dans la planification stochastique. Si les objectifs de soutirage ont été initialement atteints lors de la planification, la simulation a conduit à une dégradation notable de ces objectifs. Pour y remédier, une modélisation robuste ou des contraintes probabilistes peuvent être envisagées.

Il est également envisageable de poursuivre les travaux en intégrant les résultats de l'assimilation, améliorant la prévision et donc la donnée d'entrée du problème de planification, dans une étape de re-planification au fur et à mesure de la mise à disposition d'observations. Cela pourrait permettre d'obtenir des plans plus dynamiques face aux aléas météos.

En outre, on pourrait aussi explorer la possibilité d'introduire une rémunération pour la réduction de l'amplitude du soutirage, comme un service supplémentaire au système, bien que ce type de produit n'existe pas sur le marché de l'électricité. La mise en uvre d'autres méthodes de simulation pour le pilotage et le contrôle du plan a également été suggérée pour mieux gérer les écarts à une échelle temporelle plus fine et ainsi s'approcher d'un système réel.

Enfin, pour augmenter l'autoconsommation, il serait possible de mettre en place des contraintes supplémentaires sur la charge de la batterie, telles que l'interdiction de la charge nocturne. Afin de poursuivre les travaux sur l'exposition au risque économique, une étude avec une structure de prix plus détaillée et moins lisse serait judicieuse. Le système actuel, avec son nombre limité d'entités, pourrait être étendu pour inclure des sources d'énergie additionnelles comme une autre installation photovoltaïque ou de l'énergie éolienne, où notre modèle de corrélation pourrait être particulièrement utile.

À travers ces chapitres, la thèse démontre une progression méthodique vers une gestion intégrée de l'incertitude dans les micro-réseaux. Chaque chapitre contribue à un aspect spécifique des objectifs globaux, en construisant une base solide pour une gestion plus efficace et intelligente des systèmes énergétiques et des micro-réseau face à l'incertitude. Les méthodologies développées montrent qu'une meilleure compréhension et intégration de l'incertitude peut significativement améliorer les stratégies de planification et d'opération.

Quatrième partie

Annexes

Publications

Au cours de mes travaux de doctorat, plusieurs résultats ont été diffusés à travers des publications dans des journaux scientifiques et des communications lors de conférences internationales. Cette section présente une liste de ces publications, qui témoignent des avancées réalisées dans le cadre de cette recherche.

- V. MATHIEU et al., “Optimal Management of Microgrid Under PV Forecast Uncertainty Using Stochastic Programming,” in *2023 IEEE International Conference on Environment and Electrical Engineering and 2023 IEEE Industrial and Commercial Power Systems Europe (EEEIC / I&CPS Europe)*, Madrid, Spain : IEEE, juin 2023, p. 1-6. DOI : [10.1109/EEEIC/ICPSEurope57605.2023.10194797](https://doi.org/10.1109/EEEIC/ICPSEurope57605.2023.10194797)
- V. MATHIEU et al., “From Probabilistic PV Power Forecasting to Stochastic Programming : a Method for Microgrid Planning Under Uncertainty,” in *2022 Workshop on Blockchain for Renewables Integration (BLORIN)*, Palermo, Italy : IEEE, sept. 2022, p. 128-131. DOI : [10.1109/BLORIN54731.2022.10028583](https://doi.org/10.1109/BLORIN54731.2022.10028583)

Bibliographie

- [1] C. N. de Ressources Textuelles et LEXICALES, *Portail lexical - Définitions*, 2012. visité le 13 oct. 2023. adresse : <https://www.cnrtl.fr/definition/>.
- [2] INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE (IPCC), *Climate Change 2021 The Physical Science Basis : Working Group I Contribution to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change*, 1^{re} éd. Cambridge University Press, juill. 2023, ISBN : 978-1-00-915789-6. DOI : [10.1017/9781009157896](https://doi.org/10.1017/9781009157896). visité le 7 mai 2024. adresse : <https://www.cambridge.org/core/product/identifier/9781009157896/type/book>.
- [3] INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE (IPCC), *Climate Change 2022 Impacts, Adaptation and Vulnerability : Working Group II Contribution to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change*, 1^{re} éd. Cambridge University Press, juin 2023, ISBN : 978-1-00-932584-4. DOI : [10.1017/9781009325844](https://doi.org/10.1017/9781009325844). visité le 7 mai 2024. adresse : <https://www.cambridge.org/core/product/identifier/9781009325844/type/book>.
- [4] INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE (IPCC), éd., *Climate Change 2022 - Mitigation of Climate Change : Working Group III Contribution to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change*, 1^{re} éd. Cambridge University Press, août 2023, ISBN : 978-1-00-915792-6. DOI : [10.1017/9781009157926](https://doi.org/10.1017/9781009157926). visité le 7 mai 2024. adresse : <https://www.cambridge.org/core/product/identifier/9781009157926/type/book>.
- [5] IEA, *World Energy Outlook 2023*, IEA. 2023. adresse : <https://www.iea.org/reports/world-energy-outlook-2023>.
- [6] P. JADUN, C. MCMILLAN, D. STEINBERG, M. MURATORI, L. VIMMERSTEDT et T. MAI, “Electrification Futures Study : End-Use Electric Technology Cost and Performance Projections through 2050,” rapp. tech. NREL/TP-6A20-70485, 1416113, 7830, déc. 2017, NREL/TP-6A20-70485, 1416113, 7830. DOI : [10.2172/1416113](https://doi.org/10.2172/1416113). visité le 7 mai 2024. adresse : <https://www.osti.gov/servlets/purl/1416113/>.
- [7] RTE, *Production d'énergie solaire*, 2024. adresse : <https://analysesetdonnees.rte-france.com/production/solaire>.
- [8] C. de Régulation de L'ENERGIE, *Le concept de microréseau*, French. visité le 26 juin 2023. adresse : <https://www.smartgrids-cre.fr/encyclopedie/les-microgrids/le-concept-de-microreseau>.
- [9] M. F. ZIA, E. ELBOUCHIKHI et M. BENBOUZID, “Microgrids energy management systems : A critical review on methods, solutions, and prospects,” en, *Applied Energy*, t. 222, p. 1033-1055, juill. 2018, ISSN : 03062619. DOI : [10.1016/j.apenergy.2018.04.103](https://doi.org/10.1016/j.apenergy.2018.04.103). visité le 17 avr. 2023. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0306261918306676>.
- [10] J. M. MORALES, A. J. CONEJO, H. MADSEN, P. PINSON et M. ZUGNO, *Integrating renewables in electricity markets : operational problems*. Springer Science & Business Media, 2013, t. 205.

- [11] M. Q. RAZA, M. NADARAJAH et C. EKANAYAKE, “On recent advances in PV output power forecast,” en, *Solar Energy*, t. 136, p. 125-144, oct. 2016, ISSN : 0038092X. DOI : [10.1016/j.solener.2016.06.073](https://doi.org/10.1016/j.solener.2016.06.073). visité le 17 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0038092X16302547>.
- [12] Y. SUN, F. WANG, B. WANG, Q. CHEN, N. ENGERER et Z. MI, “Correlation Feature Selection and Mutual Information Theory Based Quantitative Research on Meteorological Impact Factors of Module Temperature for Solar Photovoltaic Systems,” en, *Energies*, t. 10, n° 1, p. 7, déc. 2016, ISSN : 1996-1073. DOI : [10.3390/en10010007](https://doi.org/10.3390/en10010007). visité le 17 avr. 2024. adresse : <http://www.mdpi.com/1996-1073/10/1/7>.
- [13] I. CEYLAN et al., “Determination of the heat transfer coefficient of PV panels,” en, *Energy*, t. 175, p. 978-985, mai 2019, ISSN : 03605442. DOI : [10.1016/j.energy.2019.03.152](https://doi.org/10.1016/j.energy.2019.03.152). visité le 17 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0360544219305729>.
- [14] M. IQBAL, *An introduction to solar radiation*. Toronto ; New York : Academic Press, 1983, ISBN : 978-0-12-373750-2 978-0-12-373752-6.
- [15] P. GUPTA et R. SINGH, “PV power forecasting based on data-driven models : a review,” en, *International Journal of Sustainable Engineering*, t. 14, n° 6, p. 1733-1755, nov. 2021, ISSN : 1939-7038, 1939-7046. DOI : [10.1080/19397038.2021.1986590](https://doi.org/10.1080/19397038.2021.1986590). visité le 22 août 2023. adresse : <https://www.tandfonline.com/doi/full/10.1080/19397038.2021.1986590>.
- [16] A. R. PAZIKADIN, D. RIFAI, K. ALI, M. Z. MALIK, A. N. ABDALLA et M. A. FARAJ, “Solar irradiance measurement instrumentation and power solar generation forecasting based on Artificial Neural Networks (ANN) : A review of five years research trend,” en, *Science of The Total Environment*, t. 715, p. 136 848, mai 2020, ISSN : 00489697. DOI : [10.1016/j.scitotenv.2020.136848](https://doi.org/10.1016/j.scitotenv.2020.136848). visité le 19 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0048969720303582>.
- [17] C. A. GUEYMARD et S. M. WILCOX, “Assessment of spatial and temporal variability in the US solar resource from radiometric measurements and predictions from models using ground-based or satellite data,” en, *Solar Energy*, t. 85, n° 5, p. 1068-1084, mai 2011, ISSN : 0038092X. DOI : [10.1016/j.solener.2011.02.030](https://doi.org/10.1016/j.solener.2011.02.030). visité le 19 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0038092X11000855>.
- [18] N. KRISHNAN, K. R. KUMAR et C. S. INDA, “How solar radiation forecasting impacts the utilization of solar energy : A critical review,” en, *Journal of Cleaner Production*, t. 388, p. 135 860, fév. 2023, ISSN : 09596526. DOI : [10.1016/j.jclepro.2023.135860](https://doi.org/10.1016/j.jclepro.2023.135860). visité le 19 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0959652623000185>.
- [19] R. AHMED, V. SREERAM, Y. MISHRA et M. ARIF, “A review and evaluation of the state-of-the-art in PV solar power forecasting : Techniques and optimization,” en, *Renewable and Sustainable Energy Reviews*, t. 124, p. 109 792, mai 2020, ISSN : 13640321. DOI : [10.1016/j.rser.2020.109792](https://doi.org/10.1016/j.rser.2020.109792). visité le 22 août 2023. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S1364032120300885>.
- [20] Y. REN, P. SUGANTHAN et N. SRIKANTH, “Ensemble methods for wind and solar power forecastingA state-of-the-art review,” en, *Renewable and Sustainable Energy Reviews*, t. 50, p. 82-91, oct. 2015, ISSN : 13640321. DOI : [10.1016/j.rser.2015.04.081](https://doi.org/10.1016/j.rser.2015.04.081). visité le 1^{er} avr. 2021. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S1364032115003512>.

-
- [21] J. ANTONANZAS, N. OSORIO, R. ESCOBAR, R. URRACA, F. Martinez-de PISON et F. ANTONANZAS-TORRES, “Review of photovoltaic power forecasting,” en, *Solar Energy*, t. 136, p. 78-111, oct. 2016, ISSN : 0038092X. DOI : [10.1016/j.solener.2016.06.069](https://doi.org/10.1016/j.solener.2016.06.069). visité le 21 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0038092X1630250X>.
- [22] U. K. DAS et al., “Forecasting of photovoltaic power generation and model optimization : A review,” en, *Renewable and Sustainable Energy Reviews*, t. 81, p. 912-928, jan. 2018, ISSN : 13640321. DOI : [10.1016/j.rser.2017.08.017](https://doi.org/10.1016/j.rser.2017.08.017). visité le 22 août 2023. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S1364032117311620>.
- [23] H. T. PEDRO et C. F. COIMBRA, “Assessment of forecasting techniques for solar power production with no exogenous inputs,” en, *Solar Energy*, t. 86, n° 7, p. 2017-2028, juill. 2012, ISSN : 0038092X. DOI : [10.1016/j.solener.2012.04.004](https://doi.org/10.1016/j.solener.2012.04.004). visité le 21 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0038092X12001429>.
- [24] M. ZAMO, O. MESTRE, P. ARBOGAST et O. PANNEKOUCKE, “A benchmark of statistical regression methods for short-term forecasting of photovoltaic electricity production, part I : Deterministic forecast of hourly production,” en, *Solar Energy*, t. 105, p. 792-803, juill. 2014, ISSN : 0038092X. DOI : [10.1016/j.solener.2013.12.006](https://doi.org/10.1016/j.solener.2013.12.006). visité le 19 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0038092X13005239>.
- [25] M. K. BEHERA, I. MAJUMDER et N. NAYAK, “Solar photovoltaic power forecasting using optimized modified extreme learning machine technique,” en, *Engineering Science and Technology, an International Journal*, t. 21, n° 3, p. 428-438, juin 2018, ISSN : 22150986. DOI : [10.1016/j.jestch.2018.04.013](https://doi.org/10.1016/j.jestch.2018.04.013). visité le 21 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S2215098617316063>.
- [26] M. P. ALMEIDA, M. MUÑOZ, I. de la PARRA et O. PERPIÑÁN, “Comparative study of PV power forecast using parametric and nonparametric PV models,” en, *Solar Energy*, t. 155, p. 854-866, oct. 2017, ISSN : 0038092X. DOI : [10.1016/j.solener.2017.07.032](https://doi.org/10.1016/j.solener.2017.07.032). visité le 1^{er} avr. 2021. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0038092X17306175>.
- [27] M. DAVID, F. RAMAHATANA, P. TROMBE et P. LAURET, “Probabilistic forecasting of the solar irradiance with recursive ARMA and GARCH models,” en, *Solar Energy*, t. 133, p. 55-72, août 2016, ISSN : 0038092X. DOI : [10.1016/j.solener.2016.03.064](https://doi.org/10.1016/j.solener.2016.03.064). visité le 6 avr. 2021. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0038092X16300172>.
- [28] A. BRACALE, P. CARAMIA, G. CARPINELLI, A. R. D. FAZIO et P. VARILONE, “A Bayesian-Based Approach for a Short-Term Steady-State Forecast of a Smart Grid,” *IEEE Transactions on Smart Grid*, t. 4, n° 4, p. 1760-1771, 2013. DOI : [10.1109/TSG.2012.2231441](https://doi.org/10.1109/TSG.2012.2231441). adresse : <https://ieeexplore.ieee.org/document/6670219>.
- [29] E. LORENZ, D. HEINEMANN, H. WICKRAMARATHNE, H. BEYER et S. BOFINGER, “Forecast of ensemble power production by grid-connected PV systems,” in *Proc. 20th European PV Conference, Milano, Italy, 2007*.
- [30] J. MUNKHAMMAR, J. WIDÉN et L. M. HINKELMAN, “A copula method for simulating correlated instantaneous solar irradiance in spatial networks,” en, *Solar Energy*, t. 143, p. 10-21, fév. 2017, ISSN : 0038092X. DOI : [10.1016/j.solener.2016.12.022](https://doi.org/10.1016/j.solener.2016.12.022). visité le 25 mai 2021. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0038092X16306168>.
-

- [31] WIKIPEDIA CONTRIBUTORS, *List of probability distributions* Wikipedia, *The Free Encyclopedia*, 2024. adresse : https://en.wikipedia.org/w/index.php?title=List_of_probability_distributions&oldid=1205800534.
- [32] J. PAN, W. HE, Y. SHI, R. HOU et H. ZHU, "Uncertainty analysis based on non-parametric statistical modelling method for photovoltaic array output and its application in fault diagnosis," en, *Solar Energy*, t. 225, p. 831-841, sept. 2021, ISSN : 0038092X. DOI : [10.1016/j.solener.2021.07.064](https://doi.org/10.1016/j.solener.2021.07.064). visité le 19 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0038092X2100640X>.
- [33] P. INEICHEN et R. PEREZ, "A new airmass independent formulation for the Linke turbidity coefficient," en, *Solar Energy*, t. 73, n° 3, p. 151-157, sept. 2002, ISSN : 0038092X. DOI : [10.1016/S0038-092X\(02\)00045-2](https://doi.org/10.1016/S0038-092X(02)00045-2). visité le 18 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0038092X02000452>.
- [34] C. A. GUEYMARD, "The suns total and spectral irradiance for solar energy applications and solar radiation models," en, *Solar Energy*, t. 76, n° 4, p. 423-453, avr. 2004, ISSN : 0038092X. DOI : [10.1016/j.solener.2003.08.039](https://doi.org/10.1016/j.solener.2003.08.039). visité le 18 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0038092X03003967>.
- [35] P. LOUTZENHISER, H. MANZ, C. FELSMANN, P. STRACHAN, T. FRANK et G. MAXWELL, "Empirical validation of models to compute solar irradiance on inclined surfaces for building energy simulation," en, *Solar Energy*, t. 81, n° 2, p. 254-267, fév. 2007, ISSN : 0038092X. DOI : [10.1016/j.solener.2006.03.009](https://doi.org/10.1016/j.solener.2006.03.009). visité le 18 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0038092X06000879>.
- [36] E. LORENZ, J. HURKA, D. HEINEMANN et H. G. BEYER, "Irradiance Forecasting for the Power Prediction of Grid-Connected Photovoltaic Systems," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, t. 2, n° 1, p. 2-10, mars 2009, ISSN : 1939-1404, 2151-1535. DOI : [10.1109/JSTARS.2009.2020300](https://doi.org/10.1109/JSTARS.2009.2020300). visité le 6 avr. 2021. adresse : <https://ieeexplore.ieee.org/document/4897348/>.
- [37] P. MATHIESEN et J. KLEISSL, "Evaluation of numerical weather prediction for intra-day solar forecasting in the continental United States," en, *Solar Energy*, t. 85, n° 5, p. 967-977, mai 2011, ISSN : 0038092X. DOI : [10.1016/j.solener.2011.02.013](https://doi.org/10.1016/j.solener.2011.02.013). visité le 18 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0038092X11000570>.
- [38] J. A. DUFFIE et W. A. BECKMAN, *Solar Engineering of Thermal Processes*, en, 1^{re} éd. Wiley, avr. 2013, ISBN : 978-0-470-87366-3 978-1-118-67160-3. DOI : [10.1002/9781118671603](https://doi.org/10.1002/9781118671603). visité le 18 avr. 2024. adresse : <https://onlinelibrary.wiley.com/doi/book/10.1002/9781118671603>.
- [39] A. MERMOUD et T. LEJEUNE, "Performance Assessment of a Simulation Model for PV Modules of Any Available Technology," 2010. adresse : <https://api.semanticscholar.org/CorpusID:109727191>.
- [40] D. C. MONTGOMERY, E. A. PECK et G. G. VINING, *Introduction to linear regression analysis* (Wiley series in probability and statistics), eng, Sixth edition. Hoboken, New Jersey : Wiley, 2021, ISBN : 978-1-119-57872-7.
- [41] R. J. HYNDMAN et G. ATHANASOPOULOS, *Forecasting : principles and practice*, eng, Third print edition. Melbourne, Australia : Otexts, Online Open-Access Textbooks, 2021, ISBN : 978-0-9875071-3-6.
- [42] G. E. P. BOX, G. M. JENKINS, G. C. REINSEL et G. M. LJUNG, *Time series analysis : forecasting and control* (Wiley series in probability and statistics), eng, Fifth edition. Hoboken, New Jersey : Wiley, 2016, ISBN : 978-1-118-67502-1.

-
- [43] P. R. WINTERS, "Forecasting Sales by Exponentially Weighted Moving Averages," en, *Management Science*, t. 6, n° 3, p. 324-342, avr. 1960, ISSN : 0025-1909, 1526-5501. DOI : [10.1287/mnsc.6.3.324](https://pubsonline.informs.org/doi/10.1287/mnsc.6.3.324). visité le 21 avr. 2024. adresse : <https://pubsonline.informs.org/doi/10.1287/mnsc.6.3.324>.
- [44] S. BHARDWAJ et al., "Estimation of solar radiation using a combination of Hidden Markov Model and generalized Fuzzy model," en, *Solar Energy*, t. 93, p. 43-54, juill. 2013, ISSN : 0038092X. DOI : [10.1016/j.solener.2013.03.020](https://linkinghub.elsevier.com/retrieve/pii/S0038092X13001278). visité le 21 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0038092X13001278>.
- [45] X. LUO, D. ZHANG et X. ZHU, "Deep learning based forecasting of photovoltaic power generation by incorporating domain knowledge," en, *Energy*, t. 225, p. 120-240, juin 2021, ISSN : 03605442. DOI : [10.1016/j.energy.2021.120240](https://linkinghub.elsevier.com/retrieve/pii/S0360544221004898). visité le 19 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0360544221004898>.
- [46] X. WANG, Y. SUN, D. LUO et J. PENG, "Comparative study of machine learning approaches for predicting short-term photovoltaic power output based on weather type classification," en, *Energy*, t. 240, p. 122-233, fév. 2022, ISSN : 03605442. DOI : [10.1016/j.energy.2021.122733](https://linkinghub.elsevier.com/retrieve/pii/S0360544221029820). visité le 19 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0360544221029820>.
- [47] J. SHI, W.-J. LEE, Y. LIU, Y. YANG et P. WANG, "Forecasting Power Output of Photovoltaic Systems Based on Weather Classification and Support Vector Machines," *IEEE Transactions on Industry Applications*, t. 48, n° 3, p. 1064-1069, mai 2012, ISSN : 0093-9994, 1939-9367. DOI : [10.1109/TIA.2012.2190816](http://ieeexplore.ieee.org/document/6168891/). visité le 21 avr. 2024. adresse : <http://ieeexplore.ieee.org/document/6168891/>.
- [48] D. LIU et K. SUN, "Random forest solar power forecast based on classification optimization," en, *Energy*, t. 187, p. 115-140, nov. 2019, ISSN : 03605442. DOI : [10.1016/j.energy.2019.115940](https://linkinghub.elsevier.com/retrieve/pii/S036054421931624X). visité le 21 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S036054421931624X>.
- [49] F. WANG, Z. ZHEN, B. WANG et Z. MI, "Comparative Study on KNN and SVM Based Weather Classification Models for Day Ahead Short Term Solar PV Power Forecasting," en, *Applied Sciences*, t. 8, n° 1, p. 28, déc. 2017, ISSN : 2076-3417. DOI : [10.3390/app8010028](http://www.mdpi.com/2076-3417/8/1/28). visité le 23 avr. 2024. adresse : <http://www.mdpi.com/2076-3417/8/1/28>.
- [50] S. SOBRI, S. KOOHI-KAMALI et N. A. RAHIM, "Solar photovoltaic generation forecasting methods : A review," en, *Energy Conversion and Management*, t. 156, p. 459-497, jan. 2018, ISSN : 01968904. DOI : [10.1016/j.enconman.2017.11.019](https://linkinghub.elsevier.com/retrieve/pii/S0196890417310622). visité le 22 août 2023. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0196890417310622>.
- [51] X. ZHANG, Y. LI, S. LU, H. F. HAMANN, B.-M. HODGE et B. LEHMAN, "A Solar Time Based Analog Ensemble Method for Regional Solar Power Forecasting," *IEEE Transactions on Sustainable Energy*, t. 10, n° 1, p. 268-279, jan. 2019, ISSN : 1949-3029, 1949-3037. DOI : [10.1109/TSTE.2018.2832634](http://ieeexplore.ieee.org/document/8353805/). visité le 19 avr. 2024. adresse : [https://ieeexplore.ieee.org/document/8353805/](http://ieeexplore.ieee.org/document/8353805/).
- [52] S. CHOI et J. HUR, "An Ensemble Learner-Based Bagging Model Using Past Output Data for Photovoltaic Forecasting," en, *Energies*, t. 13, n° 6, p. 1438, mars 2020, ISSN : 1996-1073. DOI : [10.3390/en13061438](https://www.mdpi.com/1996-1073/13/6/1438). visité le 21 avr. 2024. adresse : <https://www.mdpi.com/1996-1073/13/6/1438>.
-

- [53] N. RAHIMI et al., “A Comprehensive Review on Ensemble Solar Power Forecasting Algorithms,” en, *Journal of Electrical Engineering & Technology*, t. 18, n° 2, p. 719-733, mars 2023, ISSN : 1975-0102, 2093-7423. DOI : [10.1007/s42835-023-01378-2](https://doi.org/10.1007/s42835-023-01378-2). visité le 21 avr. 2024. adresse : <https://link.springer.com/10.1007/s42835-023-01378-2>.
- [54] A. ABDELLATIF et al., “Forecasting Photovoltaic Power Generation with a Stacking Ensemble Model,” en, *Sustainability*, t. 14, n° 17, p. 11 083, sept. 2022, ISSN : 2071-1050. DOI : [10.3390/su141711083](https://doi.org/10.3390/su141711083). visité le 21 avr. 2024. adresse : <https://www.mdpi.com/2071-1050/14/17/11083>.
- [55] P. LI, K. ZHOU, X. LU et S. YANG, “A hybrid deep learning model for short-term PV power forecasting,” en, *Applied Energy*, t. 259, p. 114 216, fév. 2020, ISSN : 03062619. DOI : [10.1016/j.apenergy.2019.114216](https://doi.org/10.1016/j.apenergy.2019.114216). visité le 19 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0306261919319038>.
- [56] M. N. AKHTER, S. MEKHILEF, H. MOKHLIS et N. MOHAMED SHAH, “Review on forecasting of photovoltaic power generation based on machine learning and metaheuristic techniques,” en, *IET Renewable Power Generation*, t. 13, n° 7, p. 1009-1023, mai 2019, ISSN : 1752-1416, 1752-1424. DOI : [10.1049/iet-rpg.2018.5649](https://doi.org/10.1049/iet-rpg.2018.5649). visité le 21 avr. 2024. adresse : <https://onlinelibrary.wiley.com/doi/10.1049/iet-rpg.2018.5649>.
- [57] T. ZHONG et al., “A city-scale estimation of rooftop solar photovoltaic potential based on deep learning,” en, *Applied Energy*, t. 298, p. 117 132, sept. 2021, ISSN : 03062619. DOI : [10.1016/j.apenergy.2021.117132](https://doi.org/10.1016/j.apenergy.2021.117132). visité le 21 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0306261921005729>.
- [58] A. MELLIT, A. M. PAVAN et V. LUGHI, “Deep learning neural networks for short-term photovoltaic power forecasting,” en, *Renewable Energy*, t. 172, p. 276-288, juill. 2021, ISSN : 09601481. DOI : [10.1016/j.renene.2021.02.166](https://doi.org/10.1016/j.renene.2021.02.166). visité le 21 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0960148121003475>.
- [59] G. DE FREITAS VISCONDI et S. N. ALVES-SOUZA, “A Systematic Literature Review on big data for solar photovoltaic electricity generation forecasting,” en, *Sustainable Energy Technologies and Assessments*, t. 31, p. 54-63, fév. 2019, ISSN : 22131388. DOI : [10.1016/j.seta.2018.11.008](https://doi.org/10.1016/j.seta.2018.11.008). visité le 23 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S2213138818301036>.
- [60] B. LI et J. ZHANG, “A review on the integration of probabilistic solar forecasting in power systems,” en, *Solar Energy*, t. 210, p. 68-86, nov. 2020, ISSN : 0038092X. DOI : [10.1016/j.solener.2020.07.066](https://doi.org/10.1016/j.solener.2020.07.066). visité le 1^{er} avr. 2021. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0038092X20307982>.
- [61] M. PIERRO et al., “Deterministic and Stochastic Approaches for Day-Ahead Solar Power Forecasting,” en, *Journal of Solar Energy Engineering*, t. 139, n° 2, p. 021 010, avr. 2017, ISSN : 0199-6231, 1528-8986. DOI : [10.1115/1.4034823](https://doi.org/10.1115/1.4034823). visité le 19 avr. 2024. adresse : <https://asmedigitalcollection.asme.org/solarenergyengineering/article/doi/10.1115/1.4034823/392523/Deterministic-and-Stochastic-Approaches-for>.
- [62] Y. DEMYANYK et O. VAN HEMERT, “Understanding the Subprime Mortgage Crisis,” en, *Review of Financial Studies*, t. 24, n° 6, p. 1848-1880, juin 2011, ISSN : 0893-9454, 1465-7368. DOI : [10.1093/rfs/hhp033](https://doi.org/10.1093/rfs/hhp033). visité le 26 avr. 2024. adresse : <https://academic.oup.com/rfs/article-lookup/doi/10.1093/rfs/hhp033>.

-
- [63] O. DOELLE, N. KLINKENBERG, A. AMTHOR et C. AMENT, “Probabilistic Intraday PV Power Forecast Using Ensembles of Deep Gaussian Mixture Density Networks,” en, *Energies*, t. 16, n° 2, p. 646, jan. 2023, ISSN : 1996-1073. DOI : [10.3390/en16020646](https://doi.org/10.3390/en16020646). visité le 23 avr. 2024. adresse : <https://www.mdpi.com/1996-1073/16/2/646>.
- [64] M. FAN, V. VITTAL, G. T. HEYDT et R. AYYANAR, “Probabilistic Power Flow Studies for Transmission Systems With Photovoltaic Generation Using Cumulants,” *IEEE Transactions on Power Systems*, t. 27, n° 4, p. 2251-2261, nov. 2012, ISSN : 0885-8950, 1558-0679. DOI : [10.1109/TPWRS.2012.2190533](https://doi.org/10.1109/TPWRS.2012.2190533). visité le 24 avr. 2024. adresse : <http://ieeexplore.ieee.org/document/6185718/>.
- [65] M. AIEN, A. HAJEBRAHIMI et M. FOTUHI-FIRUZABAD, “A comprehensive review on uncertainty modeling techniques in power system studies,” *Renewable and Sustainable Energy Reviews*, t. 57, p. 1077-1089, 2016, ISSN : 1364-0321. DOI : <https://doi.org/10.1016/j.rser.2015.12.070>. adresse : <https://www.sciencedirect.com/science/article/pii/S1364032115014537>.
- [66] Y. WEN et al., “Performance Evaluation of Probabilistic Methods Based on Bootstrap and Quantile Regression to Quantify PV Power Point Forecast Uncertainty,” *IEEE Transactions on Neural Networks and Learning Systems*, t. 31, n° 4, p. 1134-1144, avr. 2020, ISSN : 2162-237X, 2162-2388. DOI : [10.1109/TNNLS.2019.2918795](https://doi.org/10.1109/TNNLS.2019.2918795). visité le 23 avr. 2024. adresse : <https://ieeexplore.ieee.org/document/8744492/>.
- [67] M. P. ALMEIDA, O. PERPIÑÁN et L. NARVARTE, “PV power forecast using a nonparametric PV model,” en, *Solar Energy*, t. 115, p. 354-368, mai 2015, ISSN : 0038092X. DOI : [10.1016/j.solener.2015.03.006](https://doi.org/10.1016/j.solener.2015.03.006). visité le 23 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0038092X15001218>.
- [68] Q. NI, S. ZHUANG, H. SHENG, G. KANG et J. XIAO, “An ensemble prediction intervals approach for short-term PV power forecasting,” en, *Solar Energy*, t. 155, p. 1072-1083, oct. 2017, ISSN : 0038092X. DOI : [10.1016/j.solener.2017.07.052](https://doi.org/10.1016/j.solener.2017.07.052). visité le 23 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0038092X17306370>.
- [69] Y. HAN, N. WANG, M. MA, H. ZHOU, S. DAI et H. ZHU, “A PV power interval forecasting based on seasonal model and nonparametric estimation algorithm,” en, *Solar Energy*, t. 184, p. 515-526, mai 2019, ISSN : 0038092X. DOI : [10.1016/j.solener.2019.04.025](https://doi.org/10.1016/j.solener.2019.04.025). visité le 23 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0038092X19303561>.
- [70] D. KODAIRA, K. TSUKAZAKI, T. KURE et J. KONDOH, “Improving Forecast Reliability for Geographically Distributed Photovoltaic Generations,” en, *Energies*, t. 14, n° 21, p. 7340, nov. 2021, ISSN : 1996-1073. DOI : [10.3390/en14217340](https://doi.org/10.3390/en14217340). visité le 23 avr. 2024. adresse : <https://www.mdpi.com/1996-1073/14/21/7340>.
- [71] D. BERTSIMAS, D. B. BROWN et C. CARAMANIS, “Theory and Applications of Robust Optimization,” en, *SIAM Review*, t. 53, n° 3, p. 464-501, jan. 2011, ISSN : 0036-1445, 1095-7200. DOI : [10.1137/080734510](https://doi.org/10.1137/080734510). visité le 23 mars 2021. adresse : <http://epubs.siam.org/doi/10.1137/080734510>.
- [72] M. RANA, I. KOPRINSKA et V. G. AGELIDIS, “2D-interval forecasts for solar power production,” en, *Solar Energy*, t. 122, p. 191-203, déc. 2015, ISSN : 0038092X. DOI : [10.1016/j.solener.2015.08.018](https://doi.org/10.1016/j.solener.2015.08.018). visité le 23 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0038092X15004545>.
-

- [73] F. GOLESTANEH, P. PINSON, R. AZIZIPANAH-ABARGHOEE et H. B. GOOI, “Ellipsoidal Prediction Regions for Multivariate Uncertainty Characterization,” *IEEE Transactions on Power Systems*, t. 33, n° 4, p. 4519-4530, juill. 2018, ISSN : 0885-8950, 1558-0679. DOI : [10.1109/TPWRS.2018.2791975](https://doi.org/10.1109/TPWRS.2018.2791975). visité le 23 avr. 2024. adresse : <https://ieeexplore.ieee.org/document/8253871/>.
- [74] A. SHAPIRO, “Monte Carlo Sampling Methods,” en, in *Handbooks in Operations Research and Management Science*, t. 10, Elsevier, 2003, p. 353-425, ISBN : 978-0-444-50854-6. DOI : [10.1016/S0927-0507\(03\)10006-0](https://doi.org/10.1016/S0927-0507(03)10006-0). visité le 24 mars 2021. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0927050703100060>.
- [75] ZHEN SHU et P. JURUTITJAROEN, “Latin Hypercube Sampling Techniques for Power Systems Reliability Analysis With Renewable Energy Sources,” *IEEE Transactions on Power Systems*, t. 26, n° 4, p. 2066-2073, nov. 2011, ISSN : 0885-8950, 1558-0679. DOI : [10.1109/TPWRS.2011.2113380](https://doi.org/10.1109/TPWRS.2011.2113380). visité le 24 avr. 2024. adresse : <http://ieeexplore.ieee.org/document/5729359/>.
- [76] G. CARPINELLI, R. RIZZO, P. CARAMIA et P. VARILONE, “Taguchi’s method for probabilistic three-phase power flow of unbalanced distribution systems with correlated Wind and Photovoltaic Generation Systems,” en, *Renewable Energy*, t. 117, p. 227-241, mars 2018, ISSN : 09601481. DOI : [10.1016/j.renene.2017.10.048](https://doi.org/10.1016/j.renene.2017.10.048). visité le 28 avr. 2021. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S096014811731011X>.
- [77] H. LI et al., “A review of scenario analysis methods in planning and operation of modern power systems : Methodologies, applications, and challenges,” en, *Electric Power Systems Research*, t. 205, p. 107722, avr. 2022, ISSN : 03787796. DOI : [10.1016/j.epsr.2021.107722](https://doi.org/10.1016/j.epsr.2021.107722). visité le 24 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0378779621007033>.
- [78] X.-Y. MA, Y.-Z. SUN et H.-L. FANG, “Scenario generation of wind power based on statistical uncertainty and variability,” *IEEE Transactions on Sustainable Energy*, t. 4, n° 4, p. 894-904, 2013, Publisher : IEEE. DOI : [10.1109/TSTE.2013.2256807](https://doi.org/10.1109/TSTE.2013.2256807). adresse : <https://ieeexplore.ieee.org/document/6504817>.
- [79] P. PINSON, H. MADSEN, H. A. NIELSEN, G. PAPAETHYMIU et B. KLÖCKL, “From probabilistic forecasts to statistical scenarios of short-term wind power production,” *Wind Energy : An International Journal for Progress and Applications in Wind Power Conversion Technology*, t. 12, n° 1, p. 51-62, 2009, Publisher : Wiley Online Library. DOI : [10.1002/we.284](https://doi.org/10.1002/we.284). adresse : <https://onlinelibrary.wiley.com/doi/abs/10.1002/we.284>.
- [80] D. van der MEER, D. YANG, J. WIDÉN et J. MUNKHAMMAR, “Clear-sky index space-time trajectories from probabilistic solar forecasts : Comparing promising copulas,” en, *Journal of Renewable and Sustainable Energy*, t. 12, n° 2, p. 026 102, mars 2020, ISSN : 1941-7012. DOI : [10.1063/1.5140604](https://doi.org/10.1063/1.5140604). visité le 5 mai 2021. adresse : <http://aip.scitation.org/doi/10.1063/1.5140604>.
- [81] M. CUI, J. ZHANG, Q. WANG, V. KRISHNAN et B.-M. HODGE, “A Data-Driven Methodology for Probabilistic Wind Power Ramp Forecasting,” *IEEE Transactions on Smart Grid*, t. 10, n° 2, p. 1326-1338, mars 2019, ISSN : 1949-3053, 1949-3061. DOI : [10.1109/TSG.2017.2763827](https://doi.org/10.1109/TSG.2017.2763827). visité le 24 avr. 2024. adresse : <https://ieeexplore.ieee.org/document/8068999/>.
- [82] D. LEE et R. BALDICK, “Load and Wind Power Scenario Generation Through the Generalized Dynamic Factor Model,” *IEEE Transactions on Power Systems*, t. 32, n° 1, p. 400-410, jan. 2017, ISSN : 0885-8950, 1558-0679. DOI : [10.1109/TPWRS.2016.2562718](https://doi.org/10.1109/TPWRS.2016.2562718). visité le 27 avr. 2024. adresse : <http://ieeexplore.ieee.org/document/7466134/>.

-
- [83] H. HEITSCH et W. ROMISCH, "Generation of multivariate scenario trees to model stochasticity in power management," in *2005 IEEE Russia Power Tech*, St. Petersburg, Russia : IEEE, juin 2005, p. 1-7, ISBN : 978-5-93208-034-4. DOI : [10.1109/PTC.2005.4524696](https://doi.org/10.1109/PTC.2005.4524696). visité le 20 déc. 2021. adresse : <http://ieeexplore.ieee.org/document/4524696/>.
- [84] Z. LI et Z. LI, "Linear programming-based scenario reduction using transportation distance," en, *Computers & Chemical Engineering*, t. 88, p. 50-58, mai 2016, ISSN : 00981354. DOI : [10.1016/j.compchemeng.2016.02.005](https://doi.org/10.1016/j.compchemeng.2016.02.005). visité le 24 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0098135416300291>.
- [85] N. GROWE-KUSKA, H. HEITSCH et W. ROMISCH, "Scenario reduction and scenario tree construction for power management problems," in *2003 IEEE Bologna Power Tech Conference Proceedings*, t. 3, Bologna, Italy : IEEE, 2003, p. 152-158, ISBN : 978-0-7803-7967-1. DOI : [10.1109/PTC.2003.1304379](https://doi.org/10.1109/PTC.2003.1304379). visité le 18 mars 2021. adresse : <http://ieeexplore.ieee.org/document/1304379/>.
- [86] N. KOLTSAKLIS, I. P. PANAPAKIDIS, D. POZO et G. C. CHRISTOFORIDIS, "A Prosumer Model Based on Smart Home Energy Management and Forecasting Techniques," en, *Energies*, t. 14, n° 6, p. 1724, mars 2021, ISSN : 1996-1073. DOI : [10.3390/en14061724](https://doi.org/10.3390/en14061724). visité le 24 avr. 2024. adresse : <https://www.mdpi.com/1996-1073/14/6/1724>.
- [87] M. BUCCIARELLI, S. PAOLETTI et A. VICINO, "Optimal sizing of energy storage systems under uncertain demand and generation," en, *Applied Energy*, t. 225, p. 611-621, sept. 2018, ISSN : 03062619. DOI : [10.1016/j.apenergy.2018.03.153](https://doi.org/10.1016/j.apenergy.2018.03.153). visité le 24 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0306261918305002>.
- [88] K. CHATTERJEE et S. KAR, "A multi-criteria decision making for renewable energy selection using Z-numbers in uncertain environment," *Technological and Economic Development of Economy*, t. 24, n° 2, p. 739-764, fév. 2018, ISSN : 2029-4913, 2029-4921. DOI : [10.3846/20294913.2016.1261375](https://doi.org/10.3846/20294913.2016.1261375). visité le 16 mars 2021. adresse : <http://journals.vgtu.lt/index.php/TEDE/article/view/254>.
- [89] A. SOROUDI, A. RABIEE et A. KEANE, "Information gap decision theory approach to deal with wind power uncertainty in unit commitment," en, *Electric Power Systems Research*, t. 145, p. 137-148, avr. 2017, ISSN : 03787796. DOI : [10.1016/j.epsr.2017.01.001](https://doi.org/10.1016/j.epsr.2017.01.001). visité le 16 mars 2021. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0378779617300019>.
- [90] J. ZHANG et al., "A suite of metrics for assessing the performance of solar power forecasting," en, *Solar Energy*, t. 111, p. 157-175, jan. 2015, ISSN : 0038092X. DOI : [10.1016/j.solener.2014.10.016](https://doi.org/10.1016/j.solener.2014.10.016). visité le 14 fév. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0038092X14005027>.
- [91] R. J. HYNDMAN et A. B. KOEHLER, "Another look at measures of forecast accuracy," en, *International Journal of Forecasting*, t. 22, n° 4, p. 679-688, oct. 2006, ISSN : 01692070. DOI : [10.1016/j.ijforecast.2006.03.001](https://doi.org/10.1016/j.ijforecast.2006.03.001). visité le 23 août 2023. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0169207006000239>.
- [92] P. PINSON et R. GIRARD, "Evaluating the quality of scenarios of short-term wind power generation," en, *Applied Energy*, t. 96, p. 12-20, août 2012, ISSN : 03062619. DOI : [10.1016/j.apenergy.2011.11.004](https://doi.org/10.1016/j.apenergy.2011.11.004). visité le 18 mai 2021. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0306261911006994>.
- [93] F. GOLESTANEH, H. B. GOOI et P. PINSON, "Generation and evaluation of spacetime trajectories of photovoltaic power," en, *Applied Energy*, t. 176, p. 80-91, août 2016, ISSN : 03062619. DOI : [10.1016/j.apenergy.2016.05.025](https://doi.org/10.1016/j.apenergy.2016.05.025). visité le 14 avr. 2021. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0306261916306079>.
-

- [94] H. QUAN, D. SRINIVASAN et A. KHOSRAVI, "Short-Term Load and Wind Power Forecasting Using Neural Network-Based Prediction Intervals," *IEEE Transactions on Neural Networks and Learning Systems*, t. 25, n° 2, p. 303-315, fév. 2014, ISSN : 2162-237X, 2162-2388. DOI : [10.1109/TNNLS.2013.2276053](https://doi.org/10.1109/TNNLS.2013.2276053). visité le 25 avr. 2024. adresse : <https://ieeexplore.ieee.org/document/6581855/>.
- [95] G. S. THIRUNAVUKKARASU, M. SEYEDMAHMOUDIAN, E. JAMEI, B. HORAN, S. MEKHILEF et A. STOJCEVSKI, "Role of optimization techniques in microgrid energy management systems A review," en, *Energy Strategy Reviews*, t. 43, p. 100-899, sept. 2022, ISSN : 2211467X. DOI : [10.1016/j.esr.2022.100899](https://doi.org/10.1016/j.esr.2022.100899). visité le 27 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S2211467X22000931>.
- [96] A. AHMAD KHAN, M. NAEEM, M. IQBAL, S. QAISAR et A. ANPALAGAN, "A compendium of optimization objectives, constraints, tools and algorithms for energy management in microgrids," en, *Renewable and Sustainable Energy Reviews*, t. 58, p. 1664-1683, mai 2016, ISSN : 13640321. DOI : [10.1016/j.rser.2015.12.259](https://doi.org/10.1016/j.rser.2015.12.259). visité le 17 avr. 2023. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S1364032115016421>.
- [97] F. S. HILLIER et G. J. LIEBERMAN, *Introduction to operations research*, Tenth edition. New York, NY : McGraw-Hill, 2015, ISBN : 978-0-07-352345-3.
- [98] D. QUIGGIN, S. CORNELL, M. TIERNEY et R. BUSWELL, "A simulation and optimisation study : Towards a decentralised microgrid, using real world fluctuation data," en, *Energy*, t. 41, n° 1, p. 549-559, mai 2012, ISSN : 03605442. DOI : [10.1016/j.energy.2012.02.007](https://doi.org/10.1016/j.energy.2012.02.007). visité le 28 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0360544212001016>.
- [99] Q. JIANG, M. XUE et G. GENG, "Energy Management of Microgrid in Grid-Connected and Stand-Alone Modes," *IEEE Transactions on Power Systems*, t. 28, n° 3, p. 3380-3389, août 2013, ISSN : 0885-8950, 1558-0679. DOI : [10.1109/TPWRS.2013.2244104](https://doi.org/10.1109/TPWRS.2013.2244104). visité le 28 avr. 2024. adresse : <http://ieeexplore.ieee.org/document/6472268/>.
- [100] K. RAHBAR, J. XU et R. ZHANG, "Real-Time Energy Storage Management for Renewable Integration in Microgrid : An Off-Line Optimization Approach," *IEEE Transactions on Smart Grid*, t. 6, n° 1, p. 124-134, jan. 2015, ISSN : 1949-3053, 1949-3061. DOI : [10.1109/TSG.2014.2359004](https://doi.org/10.1109/TSG.2014.2359004). visité le 27 avr. 2024. adresse : <http://ieeexplore.ieee.org/document/6913531/>.
- [101] P. STLUKA, D. GODBOLE et T. SAMAD, "Energy management for buildings and microgrids," in *IEEE Conference on Decision and Control and European Control Conference*, Orlando, FL, USA : IEEE, déc. 2011, p. 5150-5157, ISBN : 978-1-61284-801-3 978-1-61284-800-6 978-1-4673-0457-3 978-1-61284-799-3. DOI : [10.1109/CDC.2011.6161051](https://doi.org/10.1109/CDC.2011.6161051). visité le 28 avr. 2024. adresse : <http://ieeexplore.ieee.org/document/6161051/>.
- [102] H. QIU, W. GU, P. LI, X. ZHANG, H. LONG et Z. WU, "CRSO approach for microgrid power dispatching," en, *IET Generation, Transmission & Distribution*, t. 13, n° 11, p. 2208-2215, juin 2019, ISSN : 1751-8695, 1751-8695. DOI : [10.1049/iet-gtd.2018.6889](https://doi.org/10.1049/iet-gtd.2018.6889). visité le 28 avr. 2024. adresse : <https://onlinelibrary.wiley.com/doi/10.1049/iet-gtd.2018.6889>.
- [103] H. R. BAGHAEI, M. MIRSALEM, G. B. GHAREHPETIAN et H. A. TALEBI, "Decentralized Sliding Mode Control of WG/PV/FC Microgrids Under Unbalanced and Nonlinear Load Conditions for On- and Off-Grid Modes," *IEEE Systems Journal*, t. 12, n° 4, p. 3108-3119, déc. 2018, ISSN : 1932-8184, 1937-9234, 2373-7816. DOI : [10.1109/JSYST.2017.2761792](https://doi.org/10.1109/JSYST.2017.2761792). visité le 28 avr. 2024. adresse : <https://ieeexplore.ieee.org/document/8104961/>.

-
- [104] P. CHAUDHARY et M. RIZWAN, “Energy management supporting high penetration of solar photovoltaic generation for smart grid using solar forecasts and pumped hydro storage system,” en, *Renewable Energy*, t. 118, p. 928-946, avr. 2018, ISSN : 09601481. DOI : [10.1016/j.renene.2017.10.113](https://doi.org/10.1016/j.renene.2017.10.113). visité le 28 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0960148117310911>.
- [105] C. CHEN, S. DUAN, T. CAI, B. LIU et G. HU, “Smart energy management system for optimal microgrid economic operation,” en, *IET Renewable Power Generation*, t. 5, n° 3, p. 258, 2011, ISSN : 17521416. DOI : [10.1049/iet-rpg.2010.0052](https://doi.org/10.1049/iet-rpg.2010.0052). visité le 28 avr. 2024. adresse : <https://digital-library.theiet.org/content/journals/10.1049/iet-rpg.2010.0052>.
- [106] R. ENRICH, P. SKOVRON, M. TOLOS et M. TORRENT-MORENO, “Microgrid management based on economic and technical criteria,” in *2012 IEEE International Energy Conference and Exhibition (ENERGYCON)*, Florence, Italy : IEEE, sept. 2012, p. 551-556, ISBN : 978-1-4673-1454-1 978-1-4673-1453-4 978-1-4673-1452-7. DOI : [10.1109/EnergyCon.2012.6348214](https://doi.org/10.1109/EnergyCon.2012.6348214). visité le 28 avr. 2024. adresse : <http://ieeexplore.ieee.org/document/6348214/>.
- [107] M. MARZBAND, E. YOUSEFNEJAD, A. SUMPER et J. L. DOMÍNGUEZ-GARCÍA, “Real time experimental implementation of optimum energy management system in standalone Microgrid by using multi-layer ant colony optimization,” en, *International Journal of Electrical Power & Energy Systems*, t. 75, p. 265-274, fév. 2016, ISSN : 01420615. DOI : [10.1016/j.ijepes.2015.09.010](https://doi.org/10.1016/j.ijepes.2015.09.010). visité le 28 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0142061515003920>.
- [108] I. PRODAN et E. ZIO, “A model predictive control framework for reliable microgrid energy management,” en, *International Journal of Electrical Power & Energy Systems*, t. 61, p. 399-409, oct. 2014, ISSN : 01420615. DOI : [10.1016/j.ijepes.2014.03.017](https://doi.org/10.1016/j.ijepes.2014.03.017). visité le 28 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0142061514001197>.
- [109] A. J. CONEJO, M. CARRIÓN, J. M. MORALES et OTHERS, *Decision making under uncertainty in electricity markets*. Springer, 2010, t. 1.
- [110] K. GAO, T. WANG, C. HAN, J. XIE, Y. MA et R. PENG, “A Review of Optimization of Microgrid Operation,” en, *Energies*, t. 14, n° 10, p. 2842, mai 2021, ISSN : 1996-1073. DOI : [10.3390/en14102842](https://doi.org/10.3390/en14102842). visité le 27 avr. 2024. adresse : <https://www.mdpi.com/1996-1073/14/10/2842>.
- [111] D. FOUSKAKIS et D. DRAPER, “Stochastic Optimization : a Review,” en, *International Statistical Review*, t. 70, n° 3, p. 315-349, déc. 2002, ISSN : 03067734. DOI : [10.1111/j.1751-5823.2002.tb00174.x](https://doi.org/10.1111/j.1751-5823.2002.tb00174.x). visité le 11 mars 2023. adresse : <https://onlinelibrary.wiley.com/doi/10.1111/j.1751-5823.2002.tb00174.x>.
- [112] J. R. BIRGE, “The value of the stochastic solution in stochastic linear programs with fixed recourse,” en, *Mathematical Programming*, t. 24, n° 1, p. 314-325, déc. 1982, ISSN : 0025-5610, 1436-4646. DOI : [10.1007/BF01585113](https://doi.org/10.1007/BF01585113). visité le 11 mars 2023. adresse : <http://link.springer.com/10.1007/BF01585113>.
- [113] F. LUO, G. RANZI, S. WANG et Z. Y. DONG, “Hierarchical Energy Management System for Home Microgrids,” *IEEE Transactions on Smart Grid*, t. 10, n° 5, p. 5536-5546, sept. 2019, ISSN : 1949-3053, 1949-3061. DOI : [10.1109/TSG.2018.2884323](https://doi.org/10.1109/TSG.2018.2884323). visité le 8 avr. 2021. adresse : <https://ieeexplore.ieee.org/document/8554167/>.
-

- [114] A. BHATTACHARYA, J. P. KHAROUFEH et B. ZENG, “Managing Energy Storage in Microgrids : A Multistage Stochastic Programming Approach,” *IEEE Transactions on Smart Grid*, t. 9, n° 1, p. 483-496, jan. 2018, ISSN : 1949-3053, 1949-3061. DOI : [10.1109/TSG.2016.2618621](https://doi.org/10.1109/TSG.2016.2618621). visité le 6 juill. 2022. adresse : <http://ieeexplore.ieee.org/document/7592939/>.
- [115] D. BERTSIMAS, E. LITVINOV, X. A. SUN, J. ZHAO et T. ZHENG, “Adaptive Robust Optimization for the Security Constrained Unit Commitment Problem,” *IEEE Transactions on Power Systems*, t. 28, n° 1, p. 52-63, fév. 2013, ISSN : 0885-8950, 1558-0679. DOI : [10.1109/TPWRS.2012.2205021](https://doi.org/10.1109/TPWRS.2012.2205021). visité le 23 mars 2021. adresse : <http://ieeexplore.ieee.org/document/6248193/>.
- [116] R. BELLMAN, *Dynamic programming*, Dover ed. Mineola, N.Y : Dover Publications, 2003, ISBN : 978-0-486-42809-3.
- [117] A. LORCA et X. A. SUN, “Multistage Robust Unit Commitment With Dynamic Uncertainty Sets and Energy Storage,” *IEEE Transactions on Power Systems*, t. 32, n° 3, p. 1678-1688, mai 2017, ISSN : 0885-8950, 1558-0679. DOI : [10.1109/TPWRS.2016.2593422](https://doi.org/10.1109/TPWRS.2016.2593422). visité le 29 avr. 2024. adresse : <http://ieeexplore.ieee.org/document/7516653/>.
- [118] B. ZHAO et al., “Energy Management of Multiple Microgrids Based on a System of Systems Architecture,” *IEEE Transactions on Power Systems*, t. 33, n° 6, p. 6410-6421, nov. 2018, ISSN : 0885-8950, 1558-0679. DOI : [10.1109/TPWRS.2018.2840055](https://doi.org/10.1109/TPWRS.2018.2840055). visité le 29 avr. 2024. adresse : <https://ieeexplore.ieee.org/document/8364617/>.
- [119] Y. GUO et C. ZHAO, “Islanding-Aware Robust Energy Management for Microgrids,” *IEEE Transactions on Smart Grid*, t. 9, n° 2, p. 1301-1309, mars 2018, ISSN : 1949-3053, 1949-3061. DOI : [10.1109/TSG.2016.2585092](https://doi.org/10.1109/TSG.2016.2585092). visité le 29 avr. 2024. adresse : <http://ieeexplore.ieee.org/document/7500056/>.
- [120] G. C. CALAFIORE et L. EL GHAOU, *Optimization Models*. Cambridge University Press, 2014.
- [121] D. BIENSTOCK, M. CHERTKOV et S. HARNETT, “Chance-Constrained Optimal Power Flow : Risk-Aware Network Control under Uncertainty,” en, *SIAM Review*, t. 56, n° 3, p. 461-495, jan. 2014, ISSN : 0036-1445, 1095-7200. DOI : [10.1137/130910312](https://doi.org/10.1137/130910312). visité le 29 avr. 2024. adresse : <http://epubs.siam.org/doi/10.1137/130910312>.
- [122] H. WU, M. SHAHIDEHPOUR, Z. LI et W. TIAN, “Chance-Constrained Day-Ahead Scheduling in Stochastic Power System Operation,” *IEEE Transactions on Power Systems*, t. 29, n° 4, p. 1583-1591, juill. 2014, ISSN : 0885-8950, 1558-0679. DOI : [10.1109/TPWRS.2013.2296438](https://doi.org/10.1109/TPWRS.2013.2296438). visité le 29 avr. 2024. adresse : <http://ieeexplore.ieee.org/document/6714594/>.
- [123] L. ROALD, T. KRAUSE et G. ANDERSSON, “Integrated balancing and congestion management under forecast uncertainty,” in *2016 IEEE International Energy Conference (ENERGYCON)*, Leuven, Belgium : IEEE, avr. 2016, p. 1-6, ISBN : 978-1-4673-8463-6. DOI : [10.1109/ENERGYCON.2016.7513980](https://doi.org/10.1109/ENERGYCON.2016.7513980). visité le 29 avr. 2024. adresse : <https://ieeexplore.ieee.org/document/7513980>.
- [124] Y. HUANG, H. LAN, Y.-Y. HONG, S. WEN et H. YIN, “Optimal generation scheduling for a deep-water semi-submersible drilling platform with uncertain renewable power generation and loads,” en, *Energy*, t. 181, p. 897-907, août 2019, ISSN : 03605442. DOI : [10.1016/j.energy.2019.05.157](https://doi.org/10.1016/j.energy.2019.05.157). visité le 8 avr. 2021. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0360544219310394>.

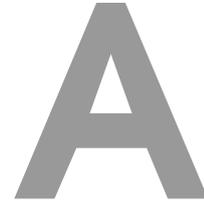
-
- [125] H. HU, S. S. YU et H. TRINH, “A Review of Uncertainties in Power Systems Modeling, Impact, and Mitigation,” en, *Designs*, t. 8, n° 1, p. 10, jan. 2024, ISSN : 2411-9660. DOI : [10.3390/designs8010010](https://doi.org/10.3390/designs8010010). visité le 30 avr. 2024. adresse : <https://www.mdpi.com/2411-9660/8/1/10>.
- [126] O. CIFTCI, M. MEHRTASH, F. SAFDARIAN et A. KARGARIAN, “Chance-Constrained Microgrid Energy Management with Flexibility Constraints Provided by Battery Storage,” in *2019 IEEE Texas Power and Energy Conference (TPEC)*, College Station, TX, USA : IEEE, fév. 2019, p. 1-6, ISBN : 978-1-5386-9284-4. DOI : [10.1109/TPEC.2019.8662200](https://doi.org/10.1109/TPEC.2019.8662200). visité le 29 avr. 2024. adresse : <https://ieeexplore.ieee.org/document/8662200/>.
- [127] M. R. EBRAHIMI et N. AMJADY, “Adaptive robust optimization framework for day-ahead microgrid scheduling,” en, *International Journal of Electrical Power & Energy Systems*, t. 107, p. 213-223, mai 2019, ISSN : 01420615. DOI : [10.1016/j.ijepes.2018.11.029](https://doi.org/10.1016/j.ijepes.2018.11.029). visité le 29 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0142061518304964>.
- [128] H. AHN, D. RIM, G. S. PAVLAK et J. D. FREIHAUT, “Uncertainty analysis of energy and economic performances of hybrid solar photovoltaic and combined cooling, heating, and power (CCHP + PV) systems using a Monte-Carlo method,” en, *Applied Energy*, t. 255, p. 113 753, déc. 2019, ISSN : 03062619. DOI : [10.1016/j.apenergy.2019.113753](https://doi.org/10.1016/j.apenergy.2019.113753). visité le 29 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0306261919314400>.
- [129] S. Y. DERAKHSHANDEH, M. E. HAMEDANI GOLSHAN, M. S. GHAZIZADEH et M. A. SHERKAT MASOUM, “Stochastic scenario-based generation scheduling in industrial microgrids,” en, *International Transactions on Electrical Energy Systems*, t. 27, n° 11, e2404, nov. 2017, ISSN : 20507038. DOI : [10.1002/etep.2404](https://doi.org/10.1002/etep.2404). visité le 5 mai 2021. adresse : <http://doi.wiley.com/10.1002/etep.2404>.
- [130] ACER, *Market rules for different electricity market timeframes*. adresse : <https://www.acer.europa.eu/electricity/market-rules/market-rules-different-electricity-market-timeframes>.
- [131] M. ZACHAR et P. DAOUTIDIS, “Microgrid/Macrogrid Energy Exchange : A Novel Market Structure and Stochastic Scheduling,” *IEEE Transactions on Smart Grid*, t. 8, n° 1, p. 178-189, jan. 2017, ISSN : 1949-3053, 1949-3061. DOI : [10.1109/TSG.2016.2600487](https://doi.org/10.1109/TSG.2016.2600487). visité le 29 avr. 2024. adresse : <http://ieeexplore.ieee.org/document/7544607/>.
- [132] L. SHI, Y. LUO et G. TU, “Bidding strategy of microgrid with consideration of uncertainty for participating in power market,” en, *International Journal of Electrical Power & Energy Systems*, t. 59, p. 1-13, juill. 2014, ISSN : 01420615. DOI : [10.1016/j.ijepes.2014.01.033](https://doi.org/10.1016/j.ijepes.2014.01.033). visité le 29 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0142061514000465>.
- [133] B. ZHANG, Q. LI, L. WANG et W. FENG, “Robust optimization for energy transactions in multi-microgrids under uncertainty,” en, *Applied Energy*, t. 217, p. 346-360, mai 2018, ISSN : 03062619. DOI : [10.1016/j.apenergy.2018.02.121](https://doi.org/10.1016/j.apenergy.2018.02.121). visité le 29 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0306261918302526>.
- [134] L. ALVARADO-BARRIOS, A. RODRÍGUEZ DEL NOZAL, J. BOZA VALERINO, I. GARCÍA VERA et J. L. MARTÍNEZ-RAMOS, “Stochastic unit commitment in microgrids : Influence of the load forecasting error and the availability of energy storage,” en, *Renewable Energy*, t. 146, p. 2060-2069, fév. 2020, ISSN : 09601481. DOI : [10.1016/j.renene.2019.08.032](https://doi.org/10.1016/j.renene.2019.08.032). visité le 29 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0960148119312194>.
-

- [135] E. MONNOT, Y. REBOURS et S. STERPU, “Réglage de la fréquence dans un environnement libéralisé : pratique en France,” fr, *Réseaux électriques et applications*, nov. 2010. DOI : [10.51257/a-v2-d4095](https://doi.org/10.51257/a-v2-d4095). visité le 30 avr. 2024. adresse : <https://www.techniques-ingenieur.fr/doi/10.51257/a/v2/d4095>.
- [136] D. SOUQUE, L. CHATONNET et E. MONNOT, “Réglage de tension - Rôles, obligations et organisation du producteur pour les besoins du système électrique en France,” fr, *Réseaux électriques et applications*, nov. 2013. DOI : [10.51257/a-v1-d4096](https://doi.org/10.51257/a-v1-d4096). visité le 30 avr. 2024. adresse : <https://www.techniques-ingenieur.fr/doi/10.51257/a/v1/d4096>.
- [137] C. Commission de Régulation de L'ENERGIE, *Services système et mécanisme dajustement*. adresse : <https://www.cre.fr/electricite/reseaux-deelectricite/services-systeme-et-mecanisme-dajustement.html>.
- [138] M. QUASHIE, C. MARNAY, F. BOUFFARD et G. JOÓS, “Optimal planning of micro-grid power and operating reserve capacity,” en, *Applied Energy*, t. 210, p. 1229-1236, jan. 2018, ISSN : 03062619. DOI : [10.1016/j.apenergy.2017.08.015](https://doi.org/10.1016/j.apenergy.2017.08.015). visité le 30 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0306261917310309>.
- [139] J. WANG et al., “Optimal bidding strategy for microgrids in joint energy and ancillary service markets considering flexible ramping products,” en, *Applied Energy*, t. 205, p. 294-303, nov. 2017, ISSN : 03062619. DOI : [10.1016/j.apenergy.2017.07.047](https://doi.org/10.1016/j.apenergy.2017.07.047). visité le 29 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0306261917309212>.
- [140] X. WEN, “Stochastic optimization for generation scheduling in a local energy community under renewable energy uncertainty,” Issue : 2020CLIL0017, Theses, Centrale Lille Institut, déc. 2020. adresse : <https://theses.hal.science/tel-03269581>.
- [141] X. YAN, D. ABBES et B. FRANCOIS, “Uncertainty analysis for day ahead power reserve quantification in an urban microgrid including PV generators,” en, *Renewable Energy*, t. 106, p. 288-297, juin 2017, ISSN : 09601481. DOI : [10.1016/j.renene.2017.01.022](https://doi.org/10.1016/j.renene.2017.01.022). visité le 30 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0960148117300228>.
- [142] A. J. WOOD, B. F. WOLLENBERG et G. B. SHEBLÉ, *Power generation, operation, and control*, eng, 3rd ed. Hoboken, New Jersey : Wiley-Interscience, 2014, OCLC : 1136409849, ISBN : 978-1-5231-1100-8.
- [143] A. ESMAELI, M. ABEDINI et M. H. MORADI, “A novel power flow analysis in an islanded renewable microgrid,” en, *Renewable Energy*, t. 96, p. 914-927, oct. 2016, ISSN : 09601481. DOI : [10.1016/j.renene.2016.04.077](https://doi.org/10.1016/j.renene.2016.04.077). visité le 30 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0960148116303792>.
- [144] J. S. GIRALDO, J. C. LOPEZ, J. A. CASTRILLON, M. J. RIDER et C. A. CASTRO, “Probabilistic OPF Model for Unbalanced Three-Phase Electrical Distribution Systems Considering Robust Constraints,” *IEEE Transactions on Power Systems*, t. 34, n° 5, p. 3443-3454, sept. 2019, ISSN : 0885-8950, 1558-0679. DOI : [10.1109/TPWRS.2019.2909404](https://doi.org/10.1109/TPWRS.2019.2909404). visité le 30 avr. 2024. adresse : <https://ieeexplore.ieee.org/document/8681440/>.
- [145] O YUGESWAR REDDY, J JITHENDRANATH, A. K. CHAKRABORTY et J. M. GUERRERO, “Stochastic optimal power flow in islanded DC microgrids with correlated load and solar PV uncertainties,” en, *Applied Energy*, t. 307, p. 118 090, fév. 2022, ISSN : 03062619. DOI : [10.1016/j.apenergy.2021.118090](https://doi.org/10.1016/j.apenergy.2021.118090). visité le 30 avr. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S0306261921013726>.

-
- [146] W. F. S. SOUZA, A. H. R. DE OLIVEIRA, L. F. M. RODRIGUES, R. KUIAVA et G. V. LEANDRO, “Stochastic Optimal Power Flow Applied in Day-Ahead Planning of Isolated Microgrids,” in *2020 IEEE Power & Energy Society General Meeting (PESGM)*, Montreal, QC, Canada : IEEE, août 2020, p. 1-5, ISBN : 978-1-72815-508-1. DOI : [10.1109/PESGM41954.2020.9281943](https://doi.org/10.1109/PESGM41954.2020.9281943). visité le 30 avr. 2024. adresse : <https://ieeexplore.ieee.org/document/9281943/>.
- [147] A. CABRERA-TOBAR, A. MASSI PAVAN, G. PETRONE et G. SPAGNUOLO, “A Review of the Optimization and Control Techniques in the Presence of Uncertainties for the Energy Management of Microgrids,” en, *Energies*, t. 15, n° 23, p. 9114, déc. 2022, ISSN : 1996-1073. DOI : [10.3390/en15239114](https://doi.org/10.3390/en15239114). visité le 30 avr. 2024. adresse : <https://www.mdpi.com/1996-1073/15/23/9114>.
- [148] E. MOHAMMADI, M. ALIZADEH, M. ASGARIMOGHADDAM, X. WANG et M. G. SIMOES, “A Review on Application of Artificial Intelligence Techniques in Microgrids,” *IEEE Journal of Emerging and Selected Topics in Industrial Electronics*, t. 3, n° 4, p. 878-890, oct. 2022, ISSN : 2687-9735, 2687-9743. DOI : [10.1109/JESTIE.2022.3198504](https://doi.org/10.1109/JESTIE.2022.3198504). visité le 30 avr. 2024. adresse : <https://ieeexplore.ieee.org/document/9855853/>.
- [149] M. MATSUMOTO et T. NISHIMURA, “Mersenne twister : a 623-dimensionally equidistributed uniform pseudo-random number generator,” *ACM Transactions on Modeling and Computer Simulation (TOMACS)*, t. 8, n° 1, p. 3-30, 1998, Publisher : ACM New York, NY, USA.
- [150] L. DEVROYE, *Non-uniform random variate generation*, eng. New York Heidelberg : Springer, 1986, ISBN : 978-1-4613-8645-2 978-3-540-96305-9 978-0-387-96305-1.
- [151] S. KOTZ, N. L. JOHNSON, N. BALAKRISHNAN et N. L. JOHNSON, *Continuous multivariate distributions* (Wiley series in probability and statistics), 2nd ed. New York : Wiley, 2000, ISBN : 978-0-471-18387-7.
- [152] G. SAPORTA, *Probabilités, analyse des données et statistique*. Éd. Technip, 2006, ISBN : 978-2-7108-0814-5.
- [153] A. C. CAMERON et P. K. TRIVEDI, *Microeconometrics : methods and applications*. Cambridge ; New York : Cambridge University Press, 2005, ISBN : 978-0-521-84805-3.
- [154] J. D. ANGRIST et J.-S. PISCHKE, *Mostly harmless econometrics : an empiricist’s companion*, eng. Princeton, New Jersey Oxford : Princeton University Press, 2009, ISBN : 978-1-4008-2982-8 978-0-691-12034-8 978-0-691-12035-5.
- [155] X. DHAULTFUILLE et P. GIVORD, “La régression quantile en pratique,” Institut National de la Statistique et des Études Économiques, Document de travail M2013/01, juill. 2013. adresse : <https://www.insee.fr/fr/statistiques/1381107>.
- [156] Y. LIU et Y. WU, “Stepwise multiple quantile regression estimation using non-crossing constraints,” en, *Statistics and Its Interface*, t. 2, n° 3, p. 299-310, 2009, ISSN : 19387989, 19387997. DOI : [10.4310/SII.2009.v2.n3.a4](https://doi.org/10.4310/SII.2009.v2.n3.a4). visité le 28 sept. 2021. adresse : <http://www.intlpress.com/site/pub/pages/journals/items/sii/content/vols/0002/0003/a004/>.
- [157] WIKIPEDIA CONTRIBUTORS, *Spline interpolation* *Wikipedia, The Free Encyclopedia*, 2024. adresse : https://en.wikipedia.org/w/index.php?title=Spline_interpolation&oldid=1195463638.
- [158] A. BOWMAN et A. AZZALINI, *Applied Smoothing Techniques for Data Analysis : The Kernel Approach with S-Plus Illustrations* (Oxford Statistical Science Series). OUP Oxford, 1997, ISBN : 978-0-19-154569-6. adresse : <https://books.google.fr/books?id=7WBMrZ9umRYC>.
-

- [159] S. LIU, B. WANG, W. ZHUANG et W. ZHAO, "Intraday PV-storage power reporting model considering temporal correlation of forecast error," in *2022 IEEE 5th International Electrical and Energy Conference (CIEEC)*, 2022, p. 2349-2354. DOI : [10.1109/CIEEC54735.2022.9846462](https://doi.org/10.1109/CIEEC54735.2022.9846462).
- [160] E. BOUYÉ, V. DURRLEMAN, A. NIKEGHBALI, G. RIBOULET et T. RONCALLI, "Copulas for finance-a reading guide and some applications," *Available at SSRN 1032533*, 2000.
- [161] R. A. FISHER, "On the mathematical foundations of theoretical statistics," *Philosophical transactions of the Royal Society of London. Series A, containing papers of a mathematical or physical character*, t. 222, n° 594-604, p. 309-368, 1922, Publisher : The Royal Society London.
- [162] D. KUROWICKA et H. JOE, éd., *Dependence modeling : vine copula handbook*, eng. Singapore : World Scientific, 2011, ISBN : 978-981-4299-87-9.
- [163] B. CHOLESKY, "Note sur une méthode de résolution des équations normales provenant de l'application de la méthode des moindres carrés à un système d'équations linéaires en nombre inférieur à celui des inconnues - Application de la méthode à la résolution dun système défini déquations linéaires," *Bulletin géodésique*, t. 2, n° 1, p. 67-77, avr. 1924, ISSN : 1432-1394. DOI : [10.1007/BF03031308](https://doi.org/10.1007/BF03031308). adresse : <https://doi.org/10.1007/BF03031308>.
- [164] T. MCSWEENEY, "Modified Cholesky decomposition and applications," PhD Thesis, University of Manchester, 2017.
- [165] G. A. F. SEBER, *Multivariate observations* (Wiley series in probability and mathematical statistics Probability and mathematical statistics), eng. New York, NY : Wiley, 1984, ISBN : 978-0-471-88104-9.
- [166] J. DUPACOVÁ, N. GRÖWE-KUSKA et W. RÖMISCH, *Scenario reduction in stochastic programming : An approach using probability metrics*. Humboldt-Universität zu Berlin, Mathematisch-Naturwissenschaftliche Fakultät , 2000.
- [167] H. HEITSCH et W. RÖMISCH, "Scenario Reduction Algorithms in Stochastic Programming," *Computational Optimization and Applications*, t. 24, n° 2/3, p. 187-206, 2003, ISSN : 09266003. DOI : [10.1023/A:1021805924152](https://doi.org/10.1023/A:1021805924152). visité le 11 mai 2021. adresse : <http://link.springer.com/10.1023/A:1021805924152>.
- [168] L. KAUFMAN et P. J. ROUSSEEUW, *Finding Groups in Data : An Introduction to Cluster Analysis* (Wiley Series in Probability and Statistics), en, 1^{re} éd. Wiley, mars 1990, ISBN : 978-0-471-87876-6 978-0-470-31680-1. DOI : [10.1002/9780470316801](https://doi.org/10.1002/9780470316801). visité le 11 fév. 2024. adresse : <https://onlinelibrary.wiley.com/doi/book/10.1002/9780470316801>.
- [169] H.-S. PARK et C.-H. JUN, "A simple and fast algorithm for K-medoids clustering," en, *Expert Systems with Applications*, t. 36, n° 2, p. 3336-3341, mars 2009, ISSN : 09574174. DOI : [10.1016/j.eswa.2008.01.039](https://doi.org/10.1016/j.eswa.2008.01.039). visité le 12 fév. 2024. adresse : <https://linkinghub.elsevier.com/retrieve/pii/S095741740800081X>.
- [170] M. L. EATON, *Multivariate statistics : a vector space approach* (Wiley series in probability and mathematical statistics), eng. New York : Wiley, 1983, ISBN : 978-0-471-02776-8.
- [171] P. DING, "On the Conditional Distribution of the Multivariate t Distribution," en, *The American Statistician*, t. 70, n° 3, p. 293-295, juill. 2016, ISSN : 0003-1305, 1537-2731. DOI : [10.1080/00031305.2016.1164756](https://doi.org/10.1080/00031305.2016.1164756). visité le 4 juill. 2023. adresse : <https://www.tandfonline.com/doi/full/10.1080/00031305.2016.1164756>.
- [172] R. DE MAESSCHALCK, D. JOUAN-RIMBAUD et D. L. MASSART, "The mahalanobis distance," *Chemometrics and intelligent laboratory systems*, t. 50, n° 1, p. 1-18, 2000, Publisher : Elsevier.

- [173] A. H. M. SMETS, K. JÄGER, O. ISABELLA, R. v. SWAAIJ et M. ZEMAN, *Solar energy : the physics and engineering of photovoltaic conversion, technologies and systems*, eng. Cambridge, England : UIT Cambridge, 2016, ISBN : 978-1-906860-32-5.
- [174] V. MATHIEU, G. PICHENOT et Q. T. TRAN, “Optimal Management of Microgrid Under PV Forecast Uncertainty Using Stochastic Programming,” in *2023 IEEE International Conference on Environment and Electrical Engineering and 2023 IEEE Industrial and Commercial Power Systems Europe (EEEIC / I&CPS Europe)*, Madrid, Spain : IEEE, juin 2023, p. 1-6. DOI : [10.1109/EEEIC/ICPSEurope57605.2023.10194797](https://doi.org/10.1109/EEEIC/ICPSEurope57605.2023.10194797).
- [175] V. MATHIEU, G. PICHENOT et Q. T. TRAN, “From Probabilistic PV Power Forecasting to Stochastic Programming : a Method for Microgrid Planning Under Uncertainty,” in *2022 Workshop on Blockchain for Renewables Integration (BLORIN)*, Palermo, Italy : IEEE, sept. 2022, p. 128-131. DOI : [10.1109/BLORIN54731.2022.10028583](https://doi.org/10.1109/BLORIN54731.2022.10028583).
- [176] WIKIPEDIA CONTRIBUTORS, *Variable aléatoire Wikipedia, The Free Encyclopedia*, 2024. adresse : <http://fr.wikipedia.org/w/index.php?title=Variable%20al%C3%A9atoire&oldid=218192497>.



Bases de la théorie des probabilités

Cette annexe permet de faire une introduction à la théorie des probabilité afin de mieux appréhender la partie II du manuscrit.

Sommaire

A.1	Espaces de probabilités, variables aléatoires	XXIV
A.1.1	L'espace de probabilité	XXIV
A.1.2	La variable aléatoire	XXIV
A.1.3	La loi de variable aléatoire	XXIV
A.2	Fonctions associées à une variable aléatoire	XXIV
A.2.1	Fonction de répartition	XXIV
A.2.2	Densité de probabilité	XXV
A.3	Autres concepts	XXVI
A.3.1	Covariance	XXVI

A.1 Espaces de probabilités, variables aléatoires

A.1.1 L'espace de probabilité

L'objet de base de la théorie des probabilités est un espace de probabilités, noté

$$(\Omega, \mathcal{F}, \mathbb{P}),$$

qui est un espace mesuré, où \mathbb{P} est une mesure de probabilités sur (Ω, \mathcal{F}) , c'est à-dire une mesure positive telle que $\mathbb{P}(\Omega) = 1$. Les éléments de Ω , appelés "événements élémentaires", correspondent aux issues possibles d'une expérience aléatoire donnée, et les parties mesurables $A \subset \mathcal{F}$ sont appelés des événements. La quantité $\mathbb{P}(A)$ désigne la probabilité que l'événement A soit observé : l'événement A est certain si $\mathbb{P}(A) = 1$ et impossible si $\mathbb{P}(A) = 0$.

A.1.2 La variable aléatoire

Une variable aléatoire sur l'espace de probabilités $(\Omega, \mathcal{F}, \mathbb{P})$ est une application mesurable $X : (\Omega, \mathcal{F}) \rightarrow (E, \mathcal{E})$ où (E, \mathcal{E}) est un ensemble mesurable.

A.1.3 La loi de variable aléatoire

La loi (ou distribution) de la variable aléatoire X est alors la mesure image $\mathbb{P}_X = X_*\mathbb{P}$ de \mathbb{P} par X , définie par

$$\mathbb{P}_X(A) = \mathbb{P}(X^{-1}(A)), \quad A \in \mathcal{E}.$$

C'est une mesure de probabilités sur (E, \mathcal{E}) , définissant un nouvel espace de probabilités $(E, \mathcal{E}, \mathbb{P}_X)$.

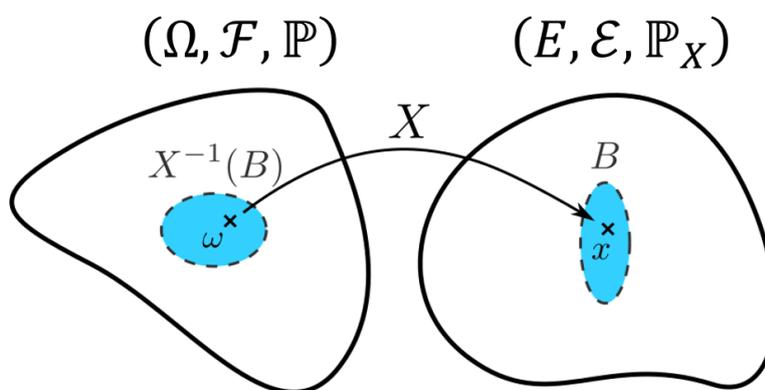


FIGURE A.1 – Illustration du concept de variable et de loi aléatoire d'un espace inconnu vers un espace d'état connu [176]

A.2 Fonctions associées à une variable aléatoire

A.2.1 Fonction de répartition

Définition A.1 Soit X une variable aléatoire réelle. On appelle fonction de répartition de X la fonction $F : \mathbb{R} \rightarrow [0, 1]$, parfois notée F_X , définie par $F(x) = \mathbb{P}(X \leq x)$ pour tout $x \in \mathbb{R}$.

Le proposition suivante donne des propriétés de la fonction de répartition.

Proposition A.1 La fonction de répartition F_X d'une variable aléatoire réelle X a les propriétés caractéristiques suivantes :

1. F_X est croissante ;
2. Elle est partout continue à droite ;
3. Elle a pour limite 0 en $-\infty$, i.e. $\lim_{x \rightarrow -\infty} F_X(x) = 0$;
4. Elle a pour limite 1 en $+\infty$, i.e. $\lim_{x \rightarrow +\infty} F_X(x) = 1$.

L'inverse généralisé de la fonction de répartition permet d'introduire la notion de quantile très utilisée en statistique.

Définition A.2 Soit X une variable aléatoire réelle de fonction de répartition F et F^{-1} l'inverse généralisé de F . Pour $\alpha \in]0, 1]$, la quantité $F^{-1}(\alpha)$ s'appelle le quantile ou fractile d'ordre α de la loi de X , noté q^α :

$$q^\alpha(X) = \inf \{x : F(X) \geq \alpha\}$$

Dans le cas de la continuité de la fonction F on note usuellement :

$$P(X < q^\alpha(X)) = \alpha$$

Le résultat suivant est à la base de la méthode d'inversion de la fonction de répartition qui permet de simuler des variables aléatoires réelles.

Théorème A.1 (de la réciproque) Soit F une fonction définie sur \mathbb{R} à valeurs dans $[0, 1]$, croissante et continue à droite et d'inverse généralisé F^{-1} .

1. La fonction F^{-1} est croissante et continue à gauche. On a l'équivalence suivante pour tout $x \in \mathbb{R}, p \in]0, 1]$:

$$F(x) \geq p \Leftrightarrow x \geq F^{-1}(p).$$

2. Pour tout $p \in]0, 1]$, on a $F(F^{-1}(p)) \geq p$ avec égalité si $F^{-1}(p) > -\infty$ et si F est continue en $F^{-1}(p)$.
3. Soit U une variable aléatoire de loi uniforme sur $[0, 1]$. La fonction F est la fonction de répartition de la variable aléatoire $F^{-1}(U)$.
4. Soit X une variable aléatoire à valeurs dans \mathbb{R} de fonction de répartition F . Si F est continue, alors $F(X)$ est de loi uniforme sur $[0, 1]$.

A.2.2 Densité de probabilité

Dans le cas particulier de variable aléatoire réelle, il est possible de définir le concept de densité et la fonction associée.

Définition A.3 Une variable aléatoire réelle X est dite à densité s'il existe une fonction f positive et intégrable sur \mathbb{R} , appelée fonction de densité, telle que pour tout $(a, b) \in \mathbb{R}^2$ on ait

$$\mathbb{P}(a \leq X \leq b) = \int_a^b f(t) dt$$

Propriété A.1 La fonction de densité ainsi définie possède les propriétés suivantes :

- Pour tout réel a on trouve $\mathbb{P}(X = a) = 0$.
- La fonction de répartition $F : x \mapsto \int_{-\infty}^x f(t) dt$ est continue et même presque partout dérivable, et sa dérivée est alors presque partout égale à la fonction de densité f .
- $\int_{-\infty}^{+\infty} f(t) dt = 1$

A.3 Autres concepts

A.3.1 Covariance

La covariance entre deux variables aléatoires X et Y est un nombre permettant de quantifier leurs écarts conjoints par rapport à leurs espérances respectives, c'est une extension de la notion de variance.

Définition A.4 $Cov(X, Y) = E[(X - E(X))(Y - E(Y))]$

Par généralisation du théorème de König-Huygens, on peut écrire la propriété ci-dessous.

Propriété A.2 $Cov(X, Y) = E(XY) - E(X)E(Y)$

B

Données d'entrée

Cette annexe permet de détailler les données utilisées pour les travaux décrits dans le manuscrit : à la fois pour la génération de scénario (partie II) et pour la planification du micro-réseau défini dans le cas d'étude (partie III).

Sommaire

B.1 Prévisions PV	XXVIII
B.2 Réalisations	XXVIII
B.2.1 PV	XXVIII
B.2.2 Charge	XXVIII
B.2.3 Disponibilité des données	XXVIII
B.3 Diversité des distribution de production PV	XXVIII

Pour l'ensemble des données, on travaille avec des données horaires sur l'échelle de temps [Coordinated Universal Time \(UTC\)](#). Les données n'étant pas au pas horaire ont été moyennées pour obtenir une valeur pour chaque pas de temps voulu.

B.1 Prévisions PV

Les prévisions PV permettant d'effectuer la régression quantile de la section [3.1.1](#) et ainsi obtenir des prévisions probabilistes sont fournies par un prévisionniste ([SteadySun](#)).

B.2 Réalisations

B.2.1 PV

Les données de production PV observée ont été mesurées par l'exploitant de la centrale et récupérée sur une période de plus de 30 mois.

B.2.2 Charge

Les données de charge comprenant du foisonnement sont obtenues grâce aux données ouvertes d'ENEDIS. Pour une question de concordance météo (corrélation entre production PV et charge), on choisi un jeu de donnée de consommation avec une proximité géographique de la centrale PV considérée.

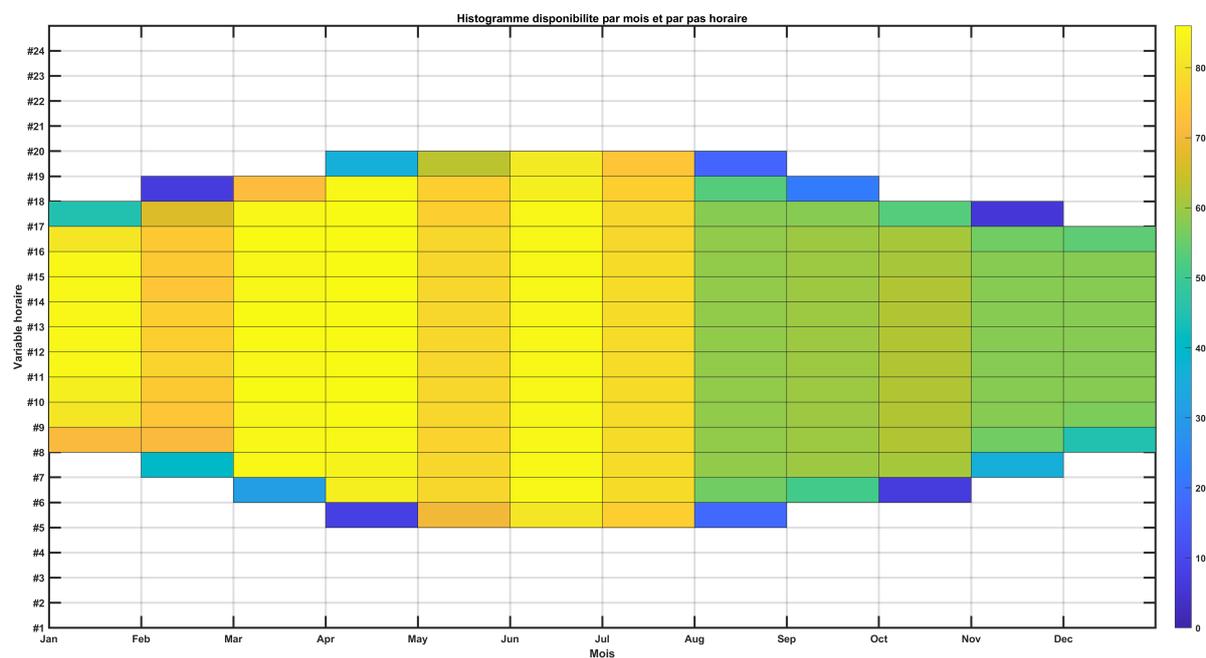
B.2.3 Disponibilité des données

Les figures ci-dessous représentent la disponibilité croisée (lorsqu'à la fois prévision et observations sont disponibles) des données utilisées. La première figure [B.1a](#) permet de voir qu'il manque 5 mois de données pour avoir 3 années complètes. On aperçoit aussi la différence entre les mois de l'année : les données ont une amplitude horaire plus faible en hiver du fait de la course hivernale du soleil plus basse. La seconde figure [B.1b](#) nous permet de se rendre compte de la régularité horaire de la disponibilité des mesures sur l'intervalle de temps complet.

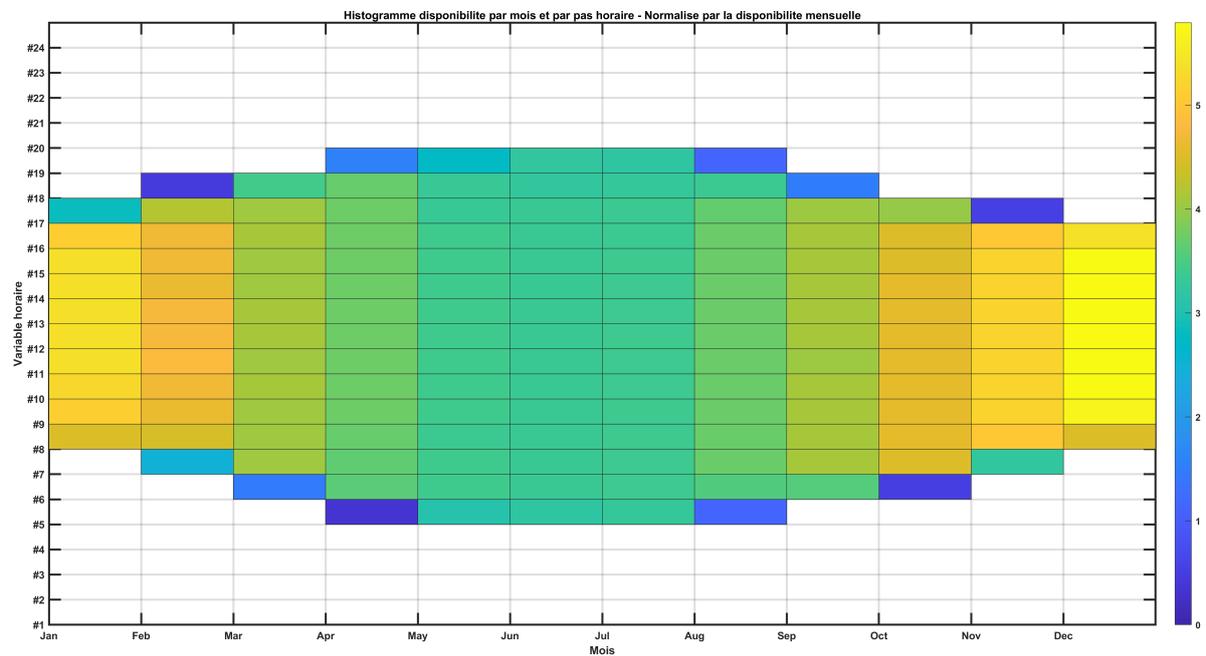
B.3 Diversité des distribution de production PV

Les figures [B.2](#) et [B.3](#) représentent des distributions de production PV issues des prévisions.

B.3. Diversité des distribution de production PV



(a) Données de prévision et de mesure PV disponible en fonction de l'horaire et du mois



(b) Données de prévision et de mesure PV disponible en fonction de l'horaire et du mois - normalisées par la disponibilité mensuelle

FIGURE B.1 – Disponibilité des données de prévision et de mesure PV

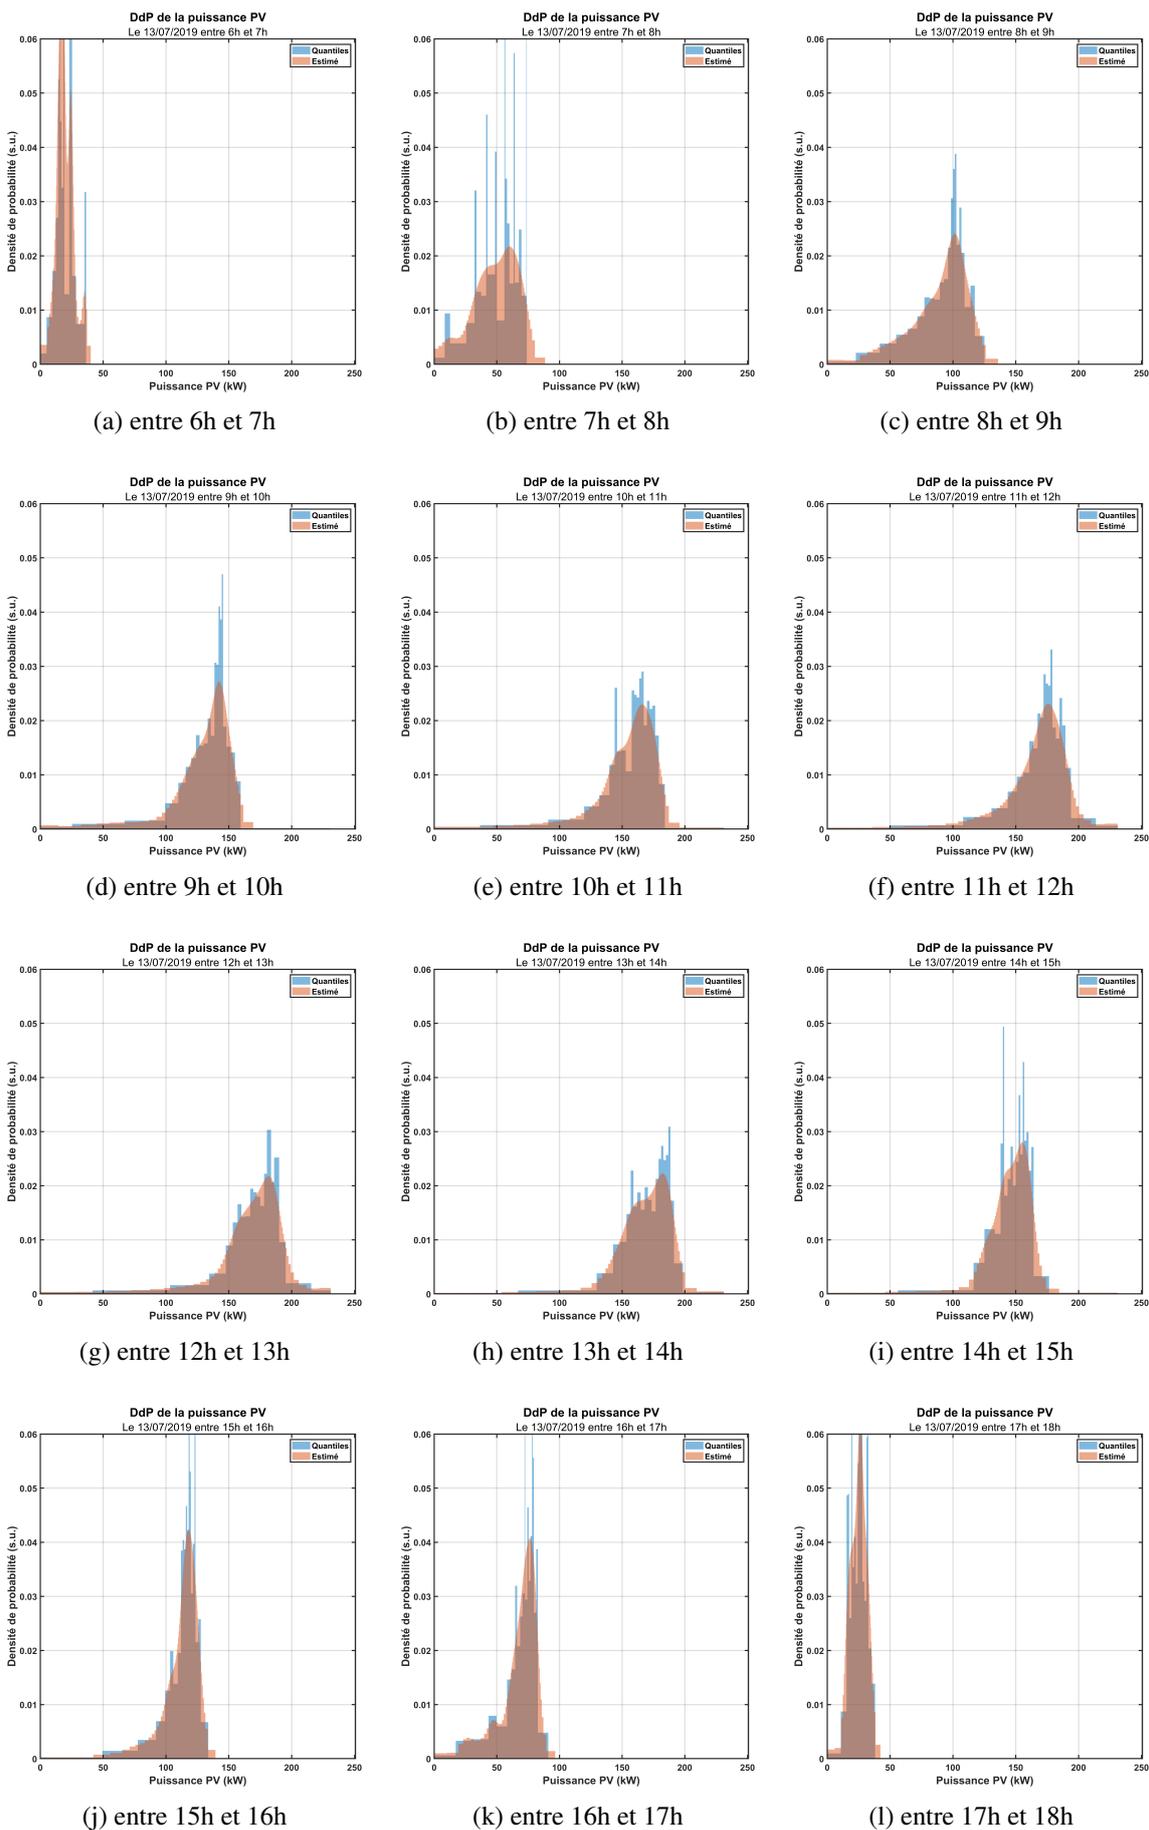


FIGURE B.2 – Distributions de production PV horaire sur la journée du 13/07/2019

B.3. Diversité des distribution de production PV

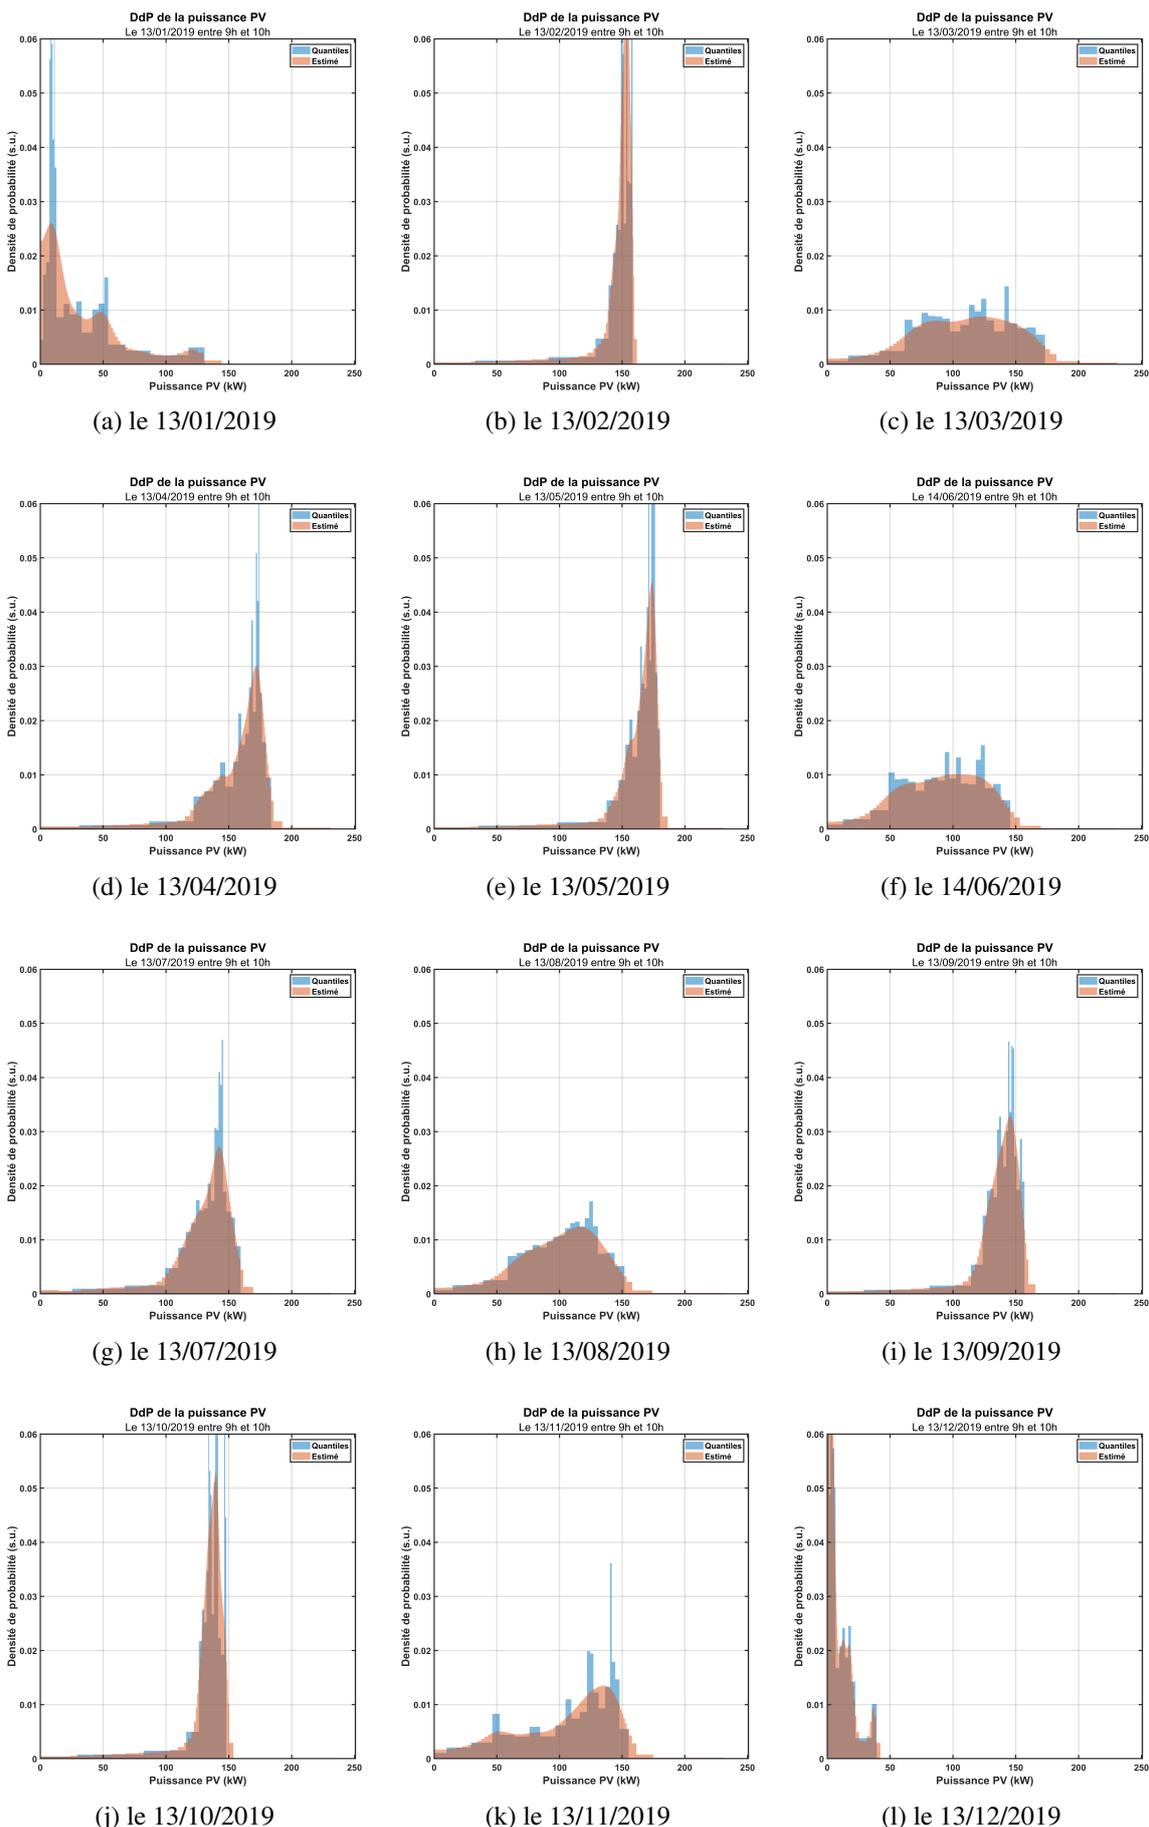
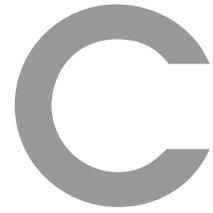
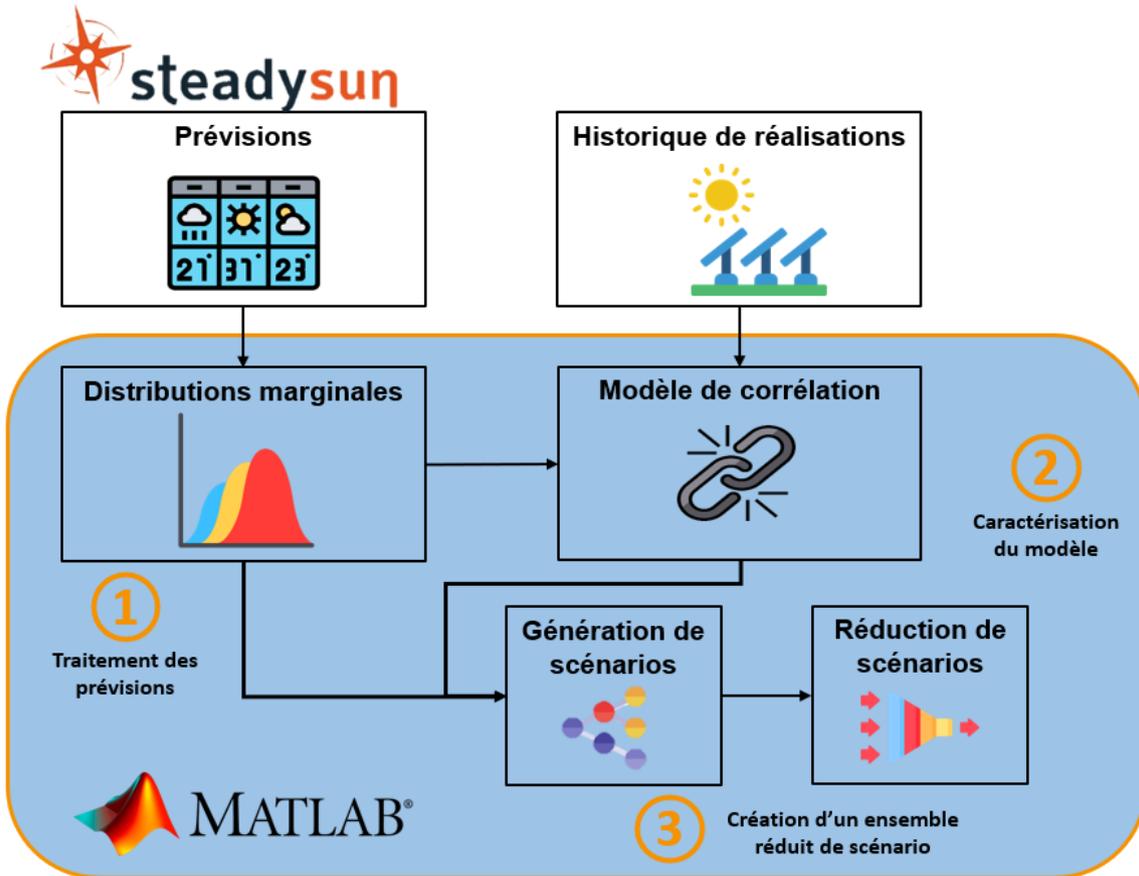


FIGURE B.3 – Distributions de production PV entre 9h et 10h pour différentes journées issues de mois différents

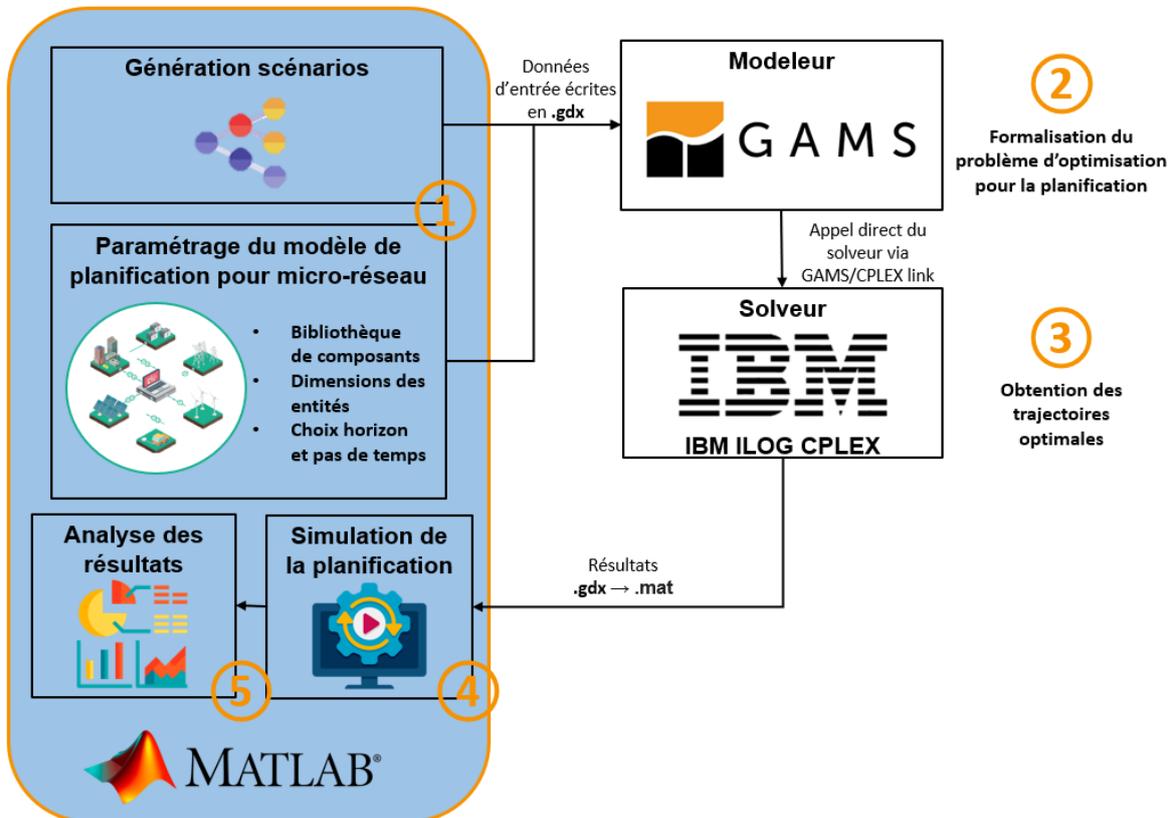


Diagrammes de blocs

Cette annexe contient les diagrammes de blocs de processus informatiques mis en place durant ces travaux de doctorat.



(a) Processus de génération de scénarios



(b) Processus de simulation de planification

FIGURE C.1 – Diagrammes de blocs des processus développés durant les travaux

D

Résultats de la planification

Cette annexe permet de détailler les résultats de la planification.

Sommaire

D.1 Plan détaillé de la planification stochastique	XXXVI
D.1.1 Cas 1	XXXVI
D.1.2 Cas 2	XLII
D.2 Résultats globaux de la planification stochastique	XLVIII
D.2.1 Distribution horaire des écarts planifiés	XLVIII
D.2.2 Distribution horaire des écarts réalisés	XLIX

D.1 Plan détaillé de la planification stochastique

D.1.1 Cas 1

a) Contrainte explicite

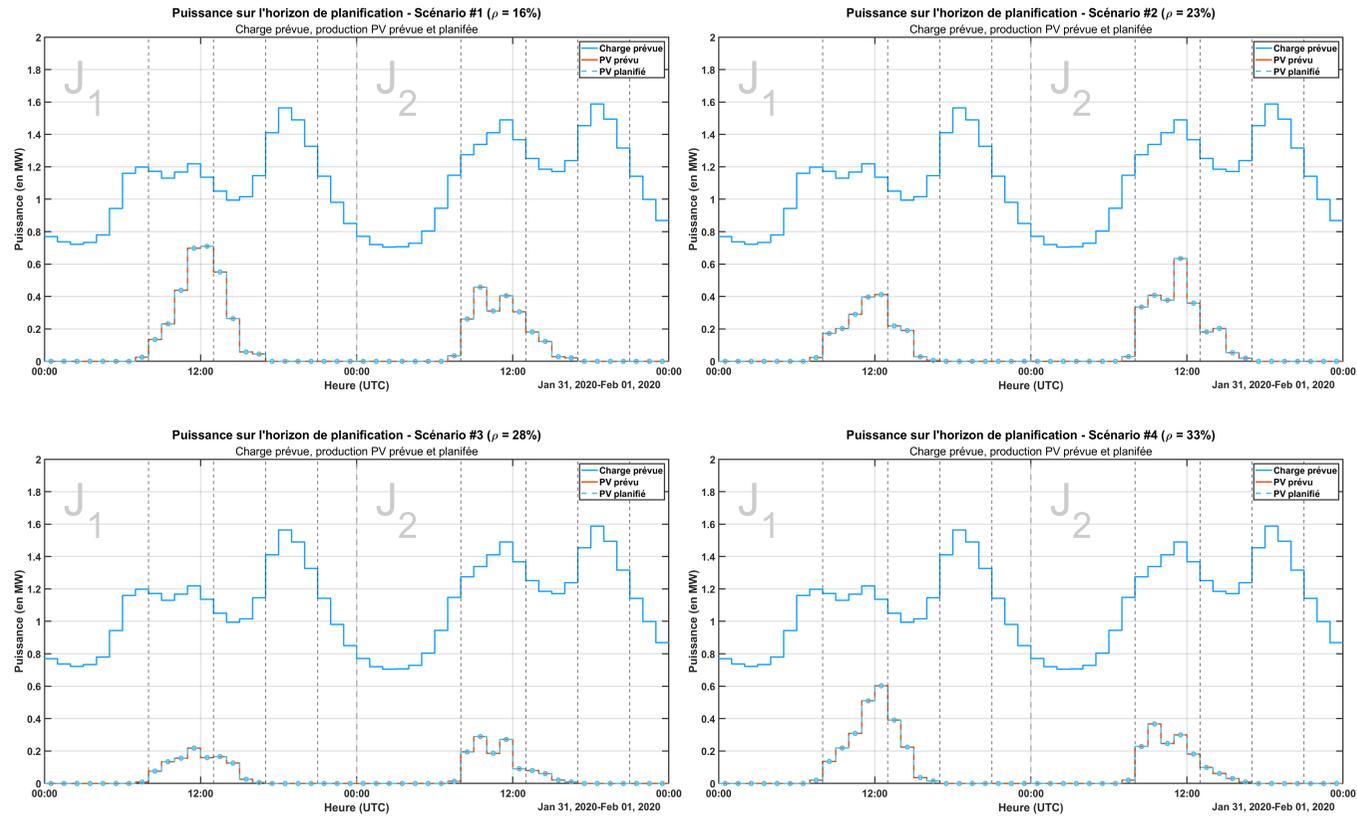


FIGURE D.1 – Résumé des trajectoires de PV et charge prévues issues du pilotage prédictif à partir de 4 scénarios - Contrainte explicite - 31/01/2020

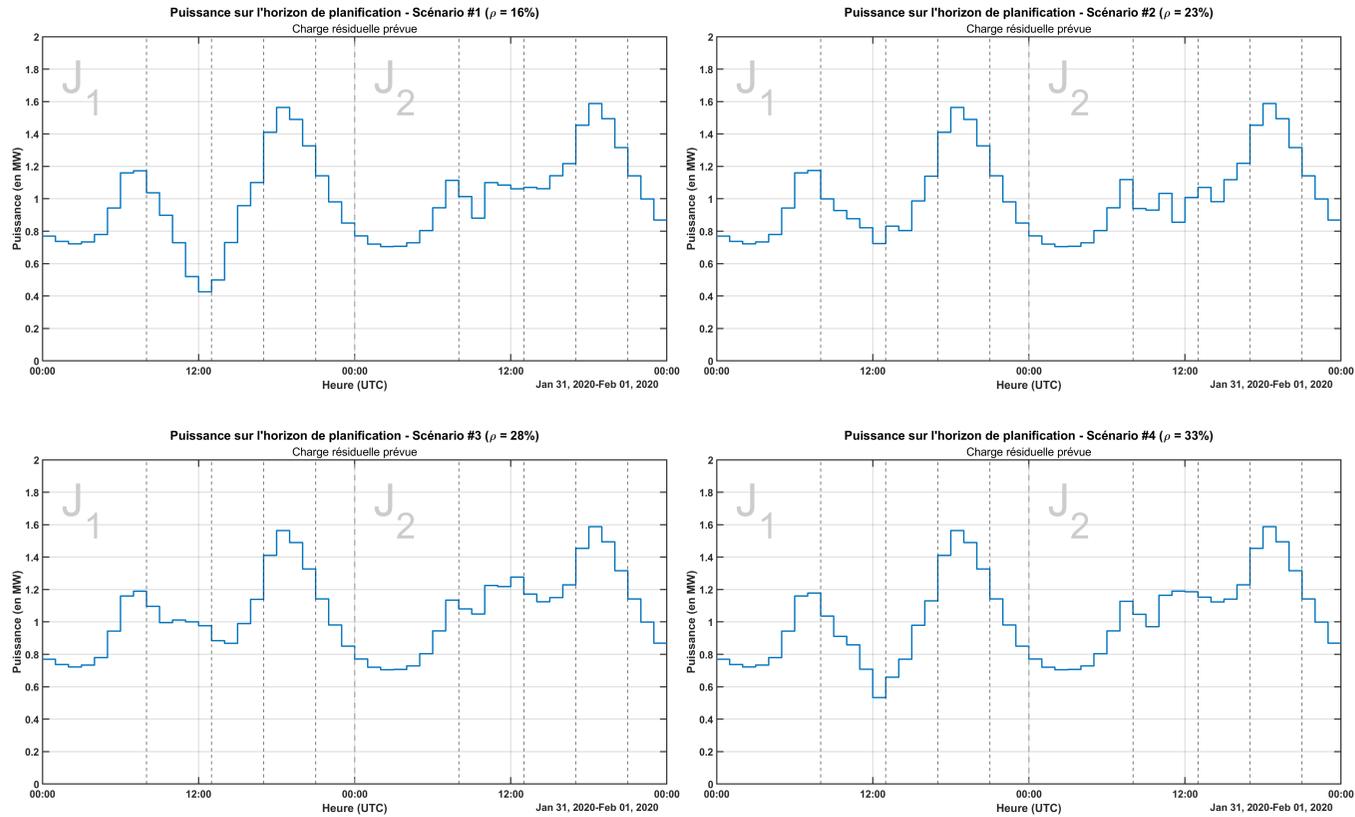


FIGURE D.2 – Résumé des trajectoires de charge résiduelle prévues issues du pilotage prédictif à partir de 4 scénarios - Contrainte explicite - 31/01/2020

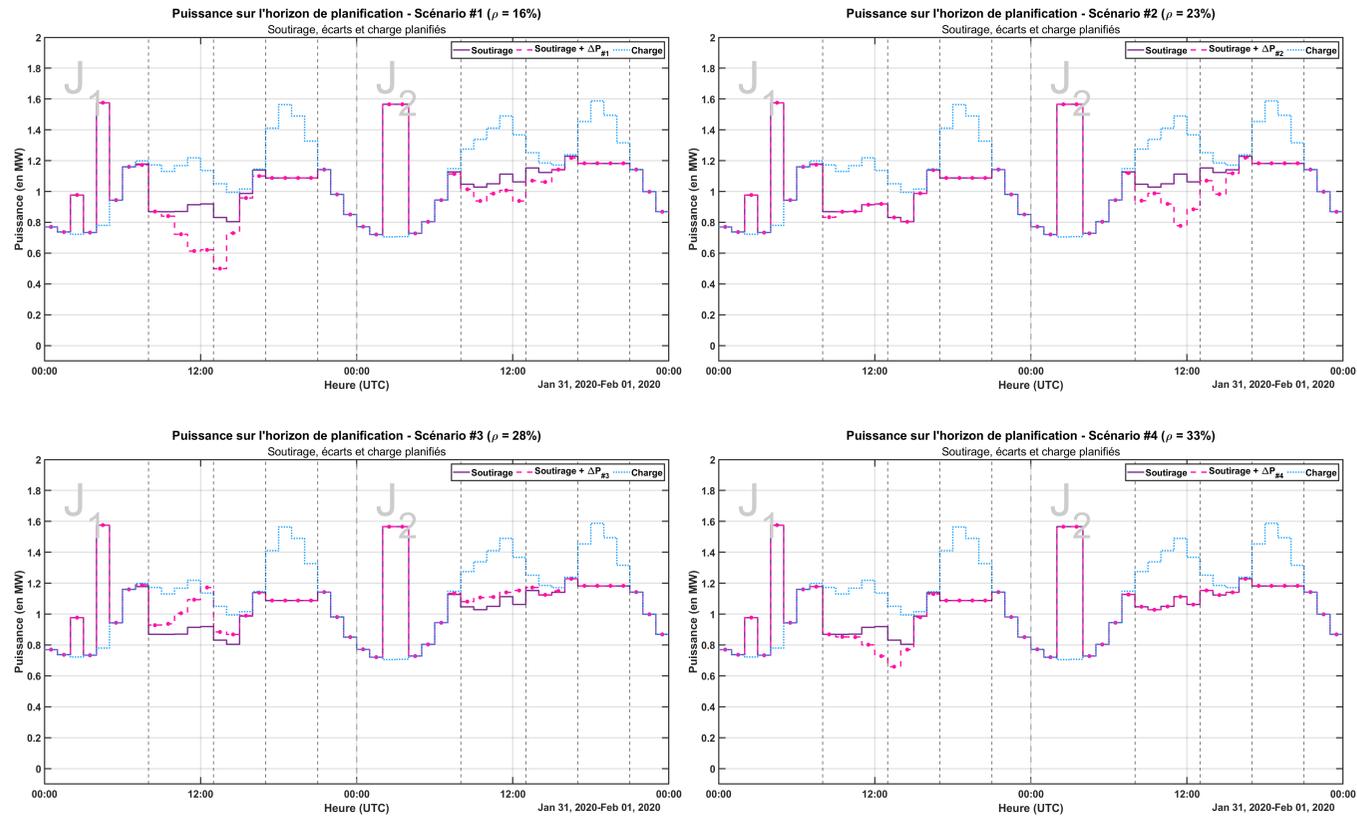


FIGURE D.3 – Résumé des trajectoires de charge résiduelle prévues issues du pilotage prédictif à partir de 4 scénarios - Contrainte explicite - 31/01/2020

b) Contrainte implicite

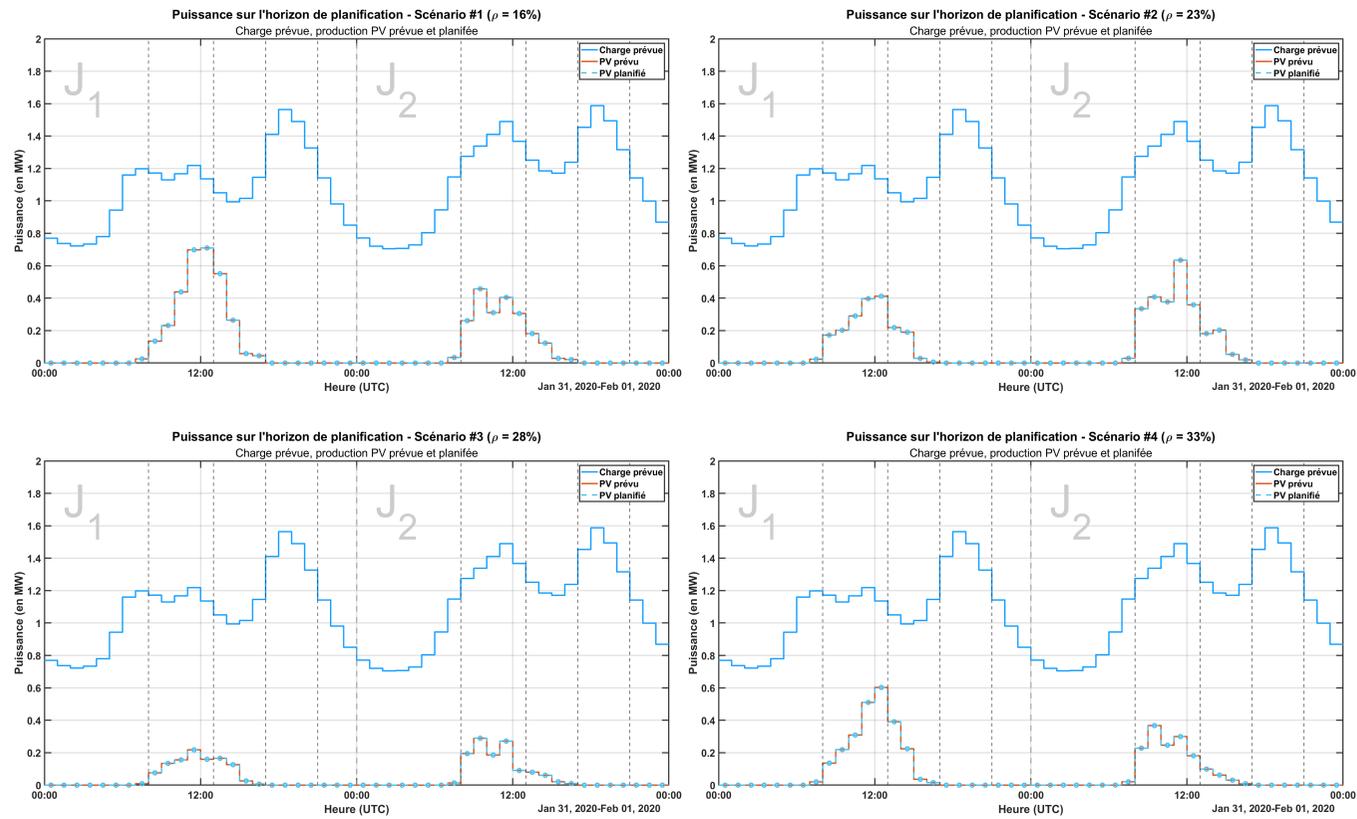


FIGURE D.4 – Résumé des trajectoires de PV et charge prévues issues du pilotage prédictif à partir de 4 scénarios - Contrainte implicite - 31/01/2020

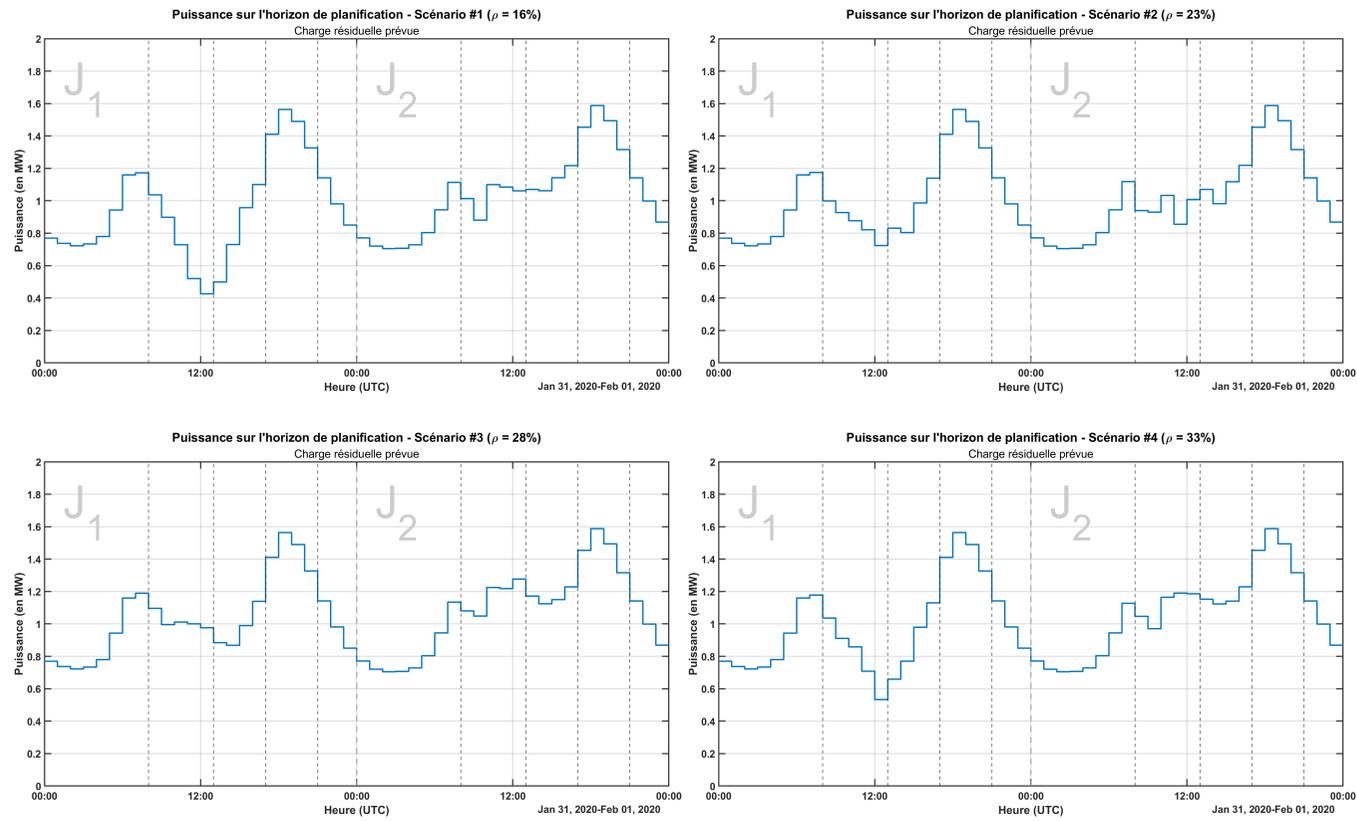


FIGURE D.5 – Résumé des trajectoires de charge résiduelle prévues issues du pilotage prédictif à partir de 4 scénarios - Contrainte implicite - 31/01/2020

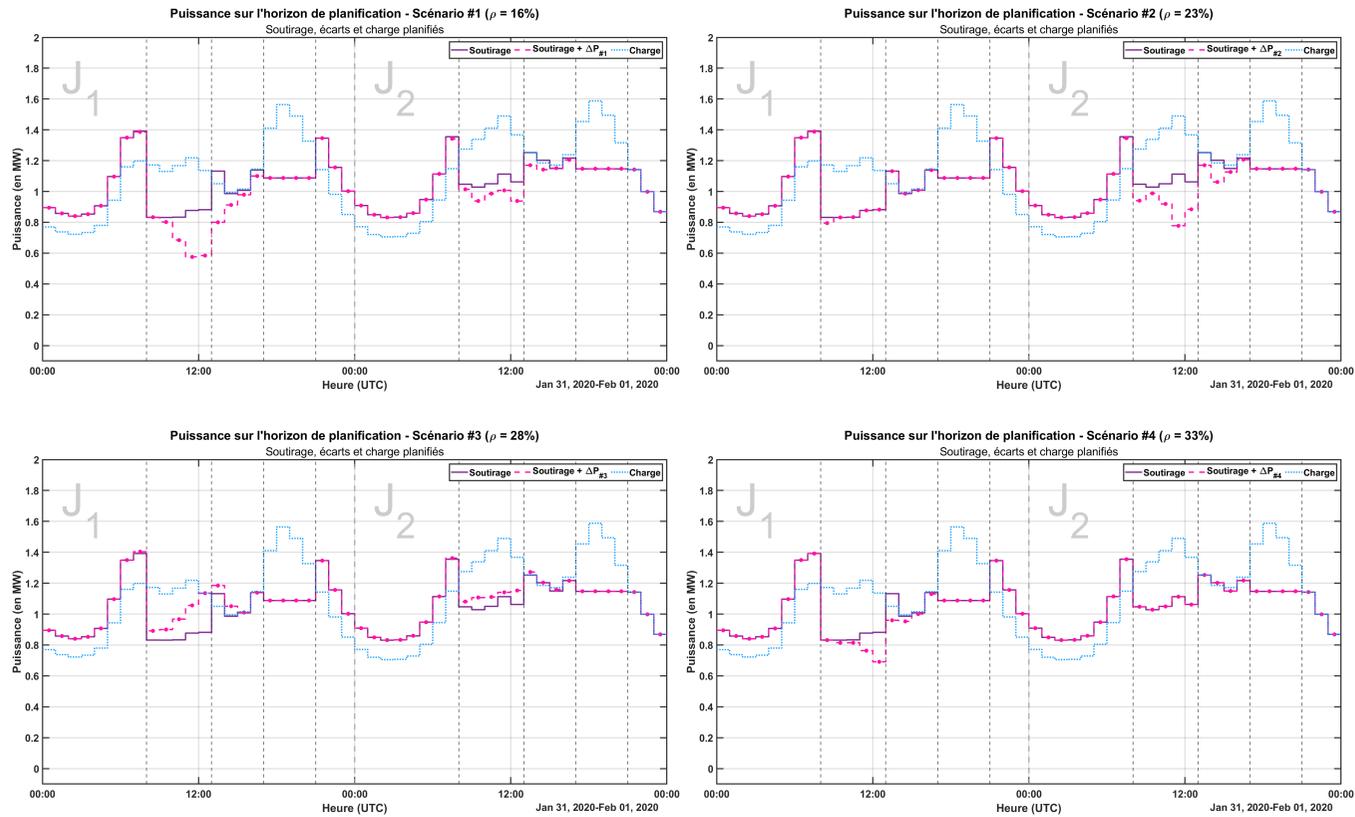


FIGURE D.6 – Résumé des trajectoires de charge résiduelle prévues issues du pilotage prédictif à partir de 4 scénarios - Contrainte implicite - 31/01/2020

D.1.2 Cas 2

a) Contrainte explicite

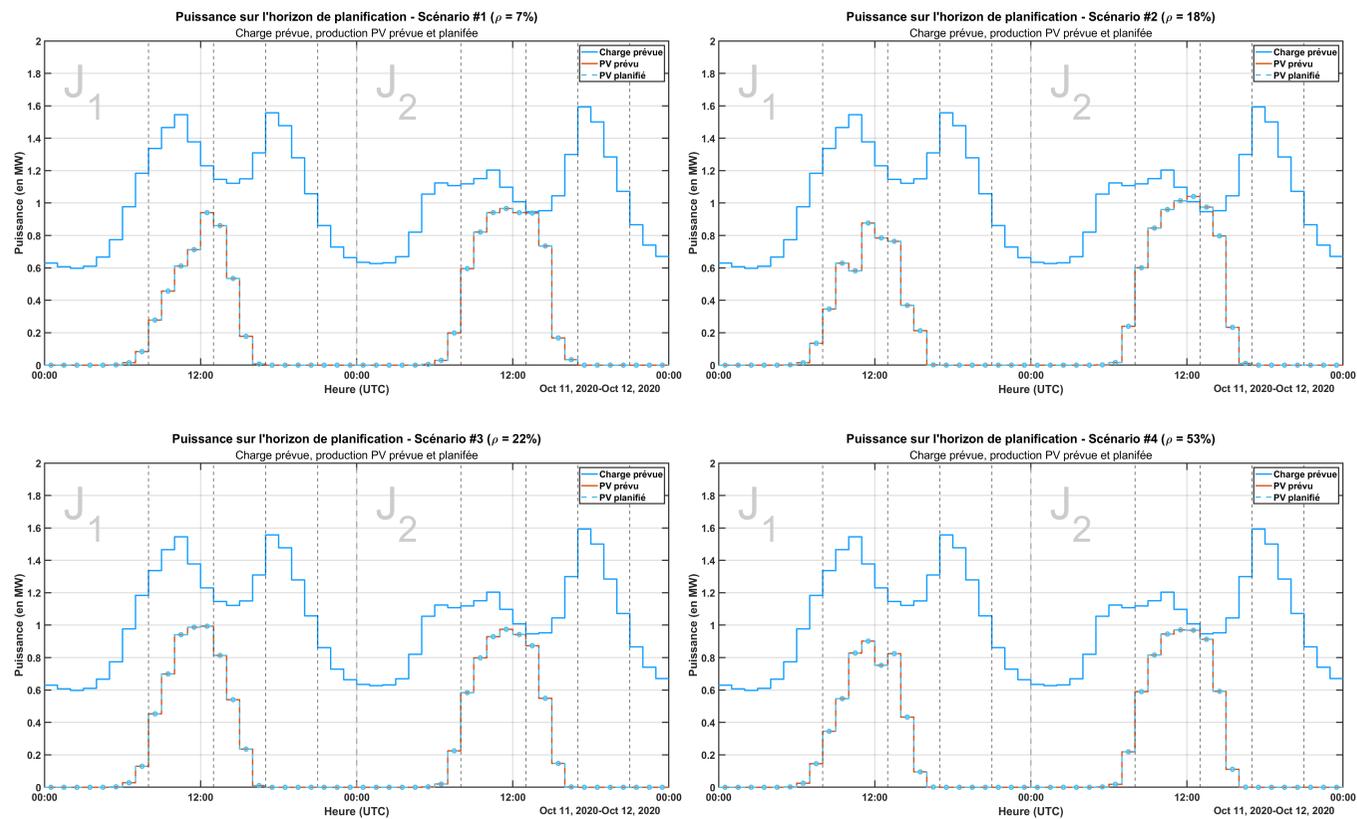


FIGURE D.7 – Résumé des trajectoires de PV et charge prévues issues du pilotage prédictif à partir de 4 scénarios - Contrainte explicite - 11/10/2020

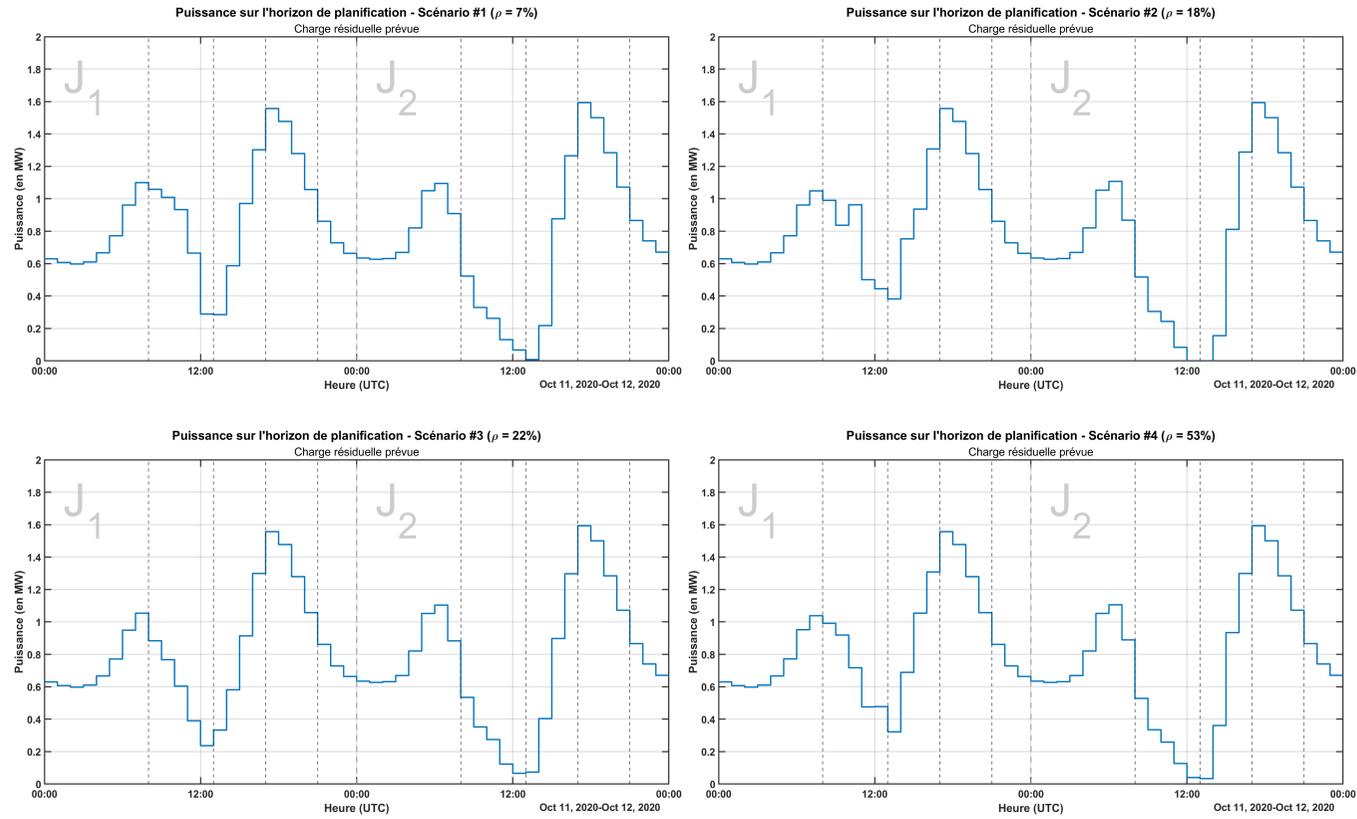


FIGURE D.8 – Résumé des trajectoires de charge résiduelle prévues issues du pilotage prédictif à partir de 4 scénarios - Contrainte explicite - 11/10/2020

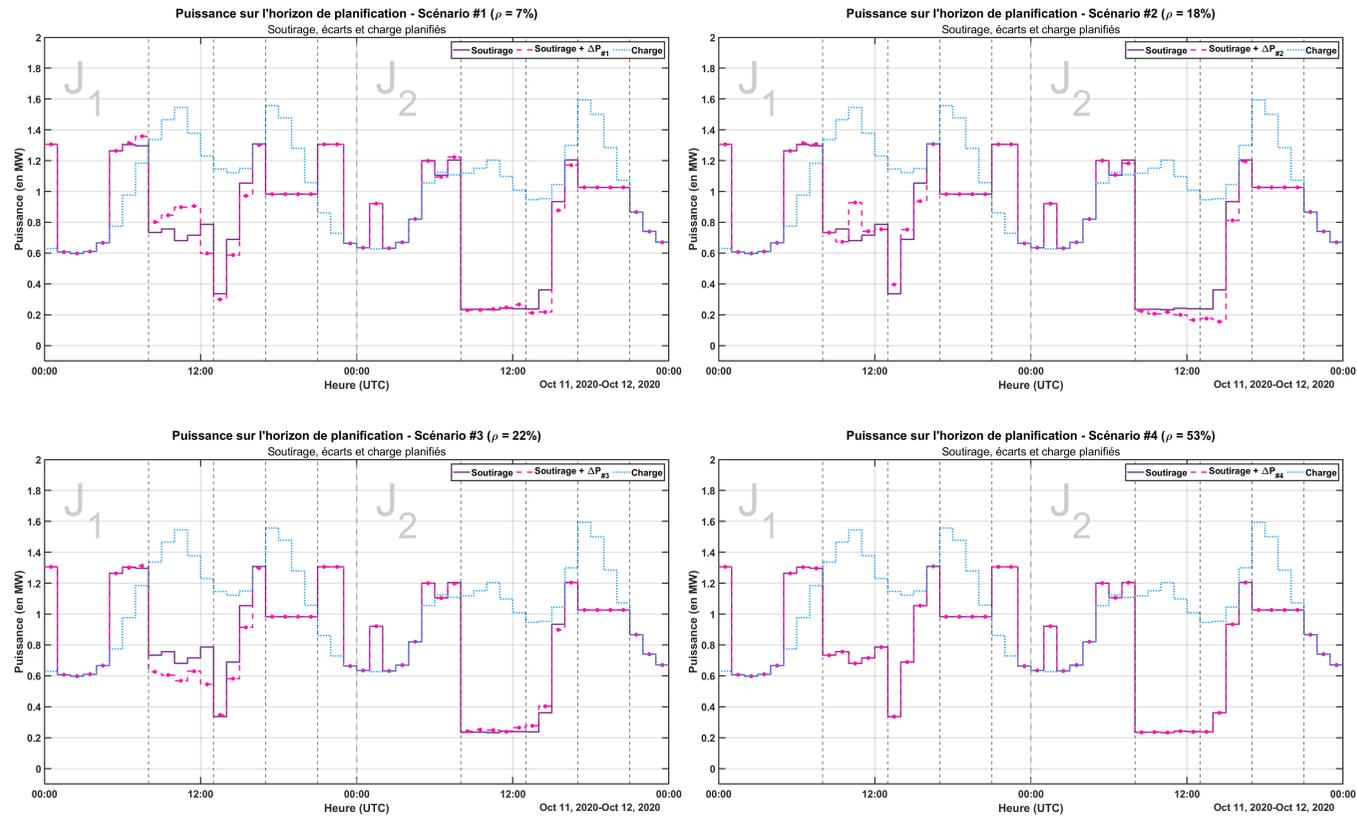


FIGURE D.9 – Résumé des trajectoires de charge résiduelle prévues issues du pilotage prédictif à partir de 4 scénarios - Contrainte explicite - 11/10/2020

b) Contrainte implicite

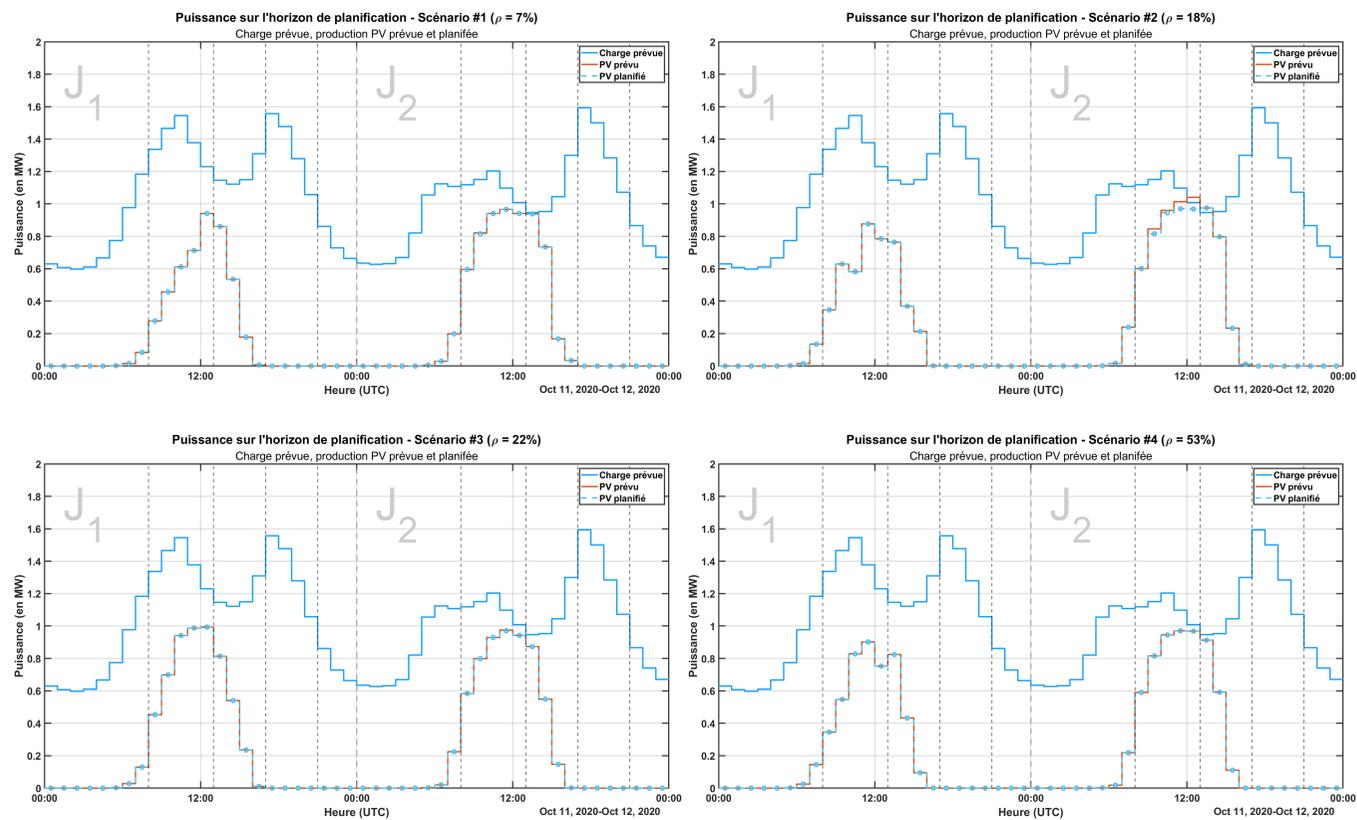


FIGURE D.10 – Résumé des trajectoires de PV et charge prévues issues du pilotage prédictif à partir de 4 scénarios - Contrainte implicite - 11/10/2020

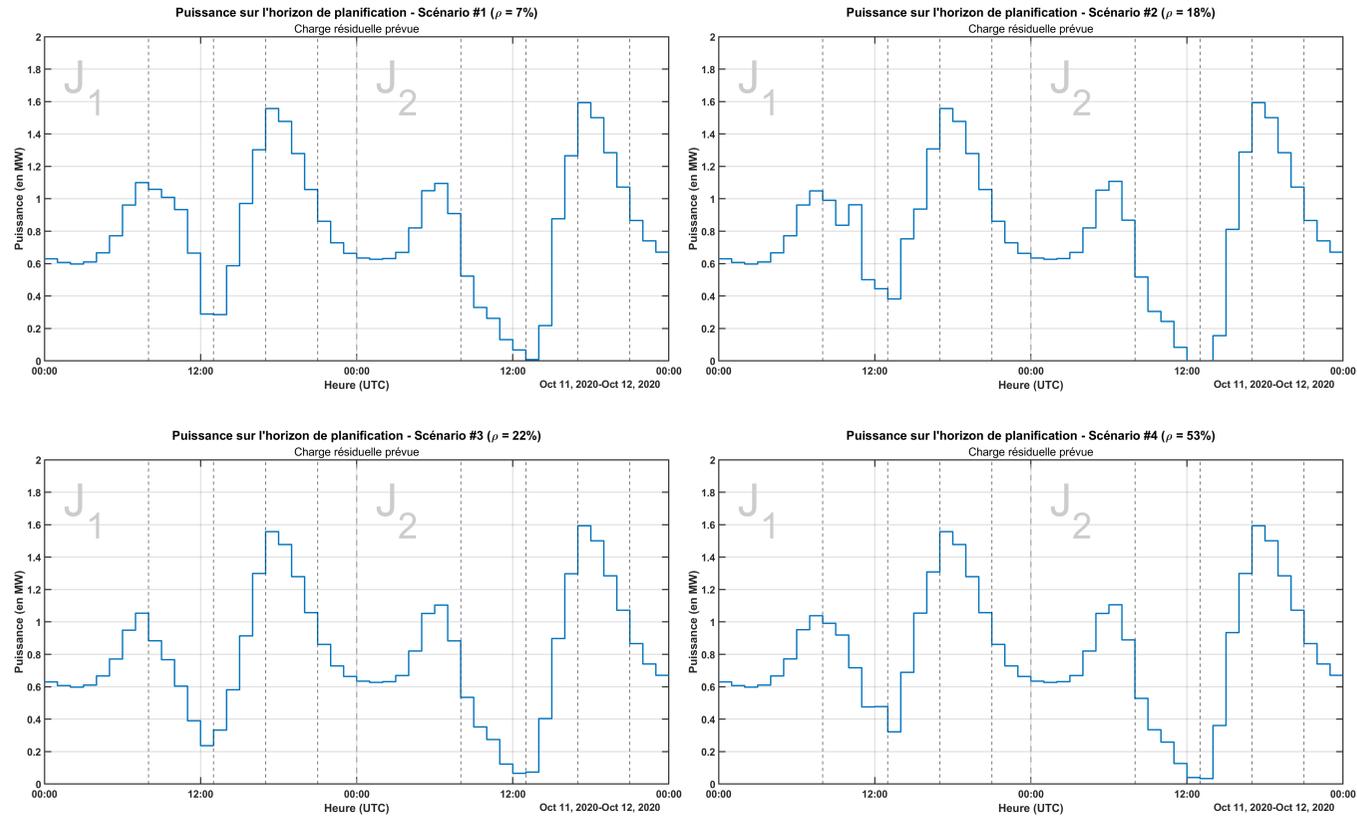


FIGURE D.11 – Résumé des trajectoires de charge résiduelle prévues issues du pilotage prédictif à partir de 4 scénarios - Contrainte implicite - 11/10/2020

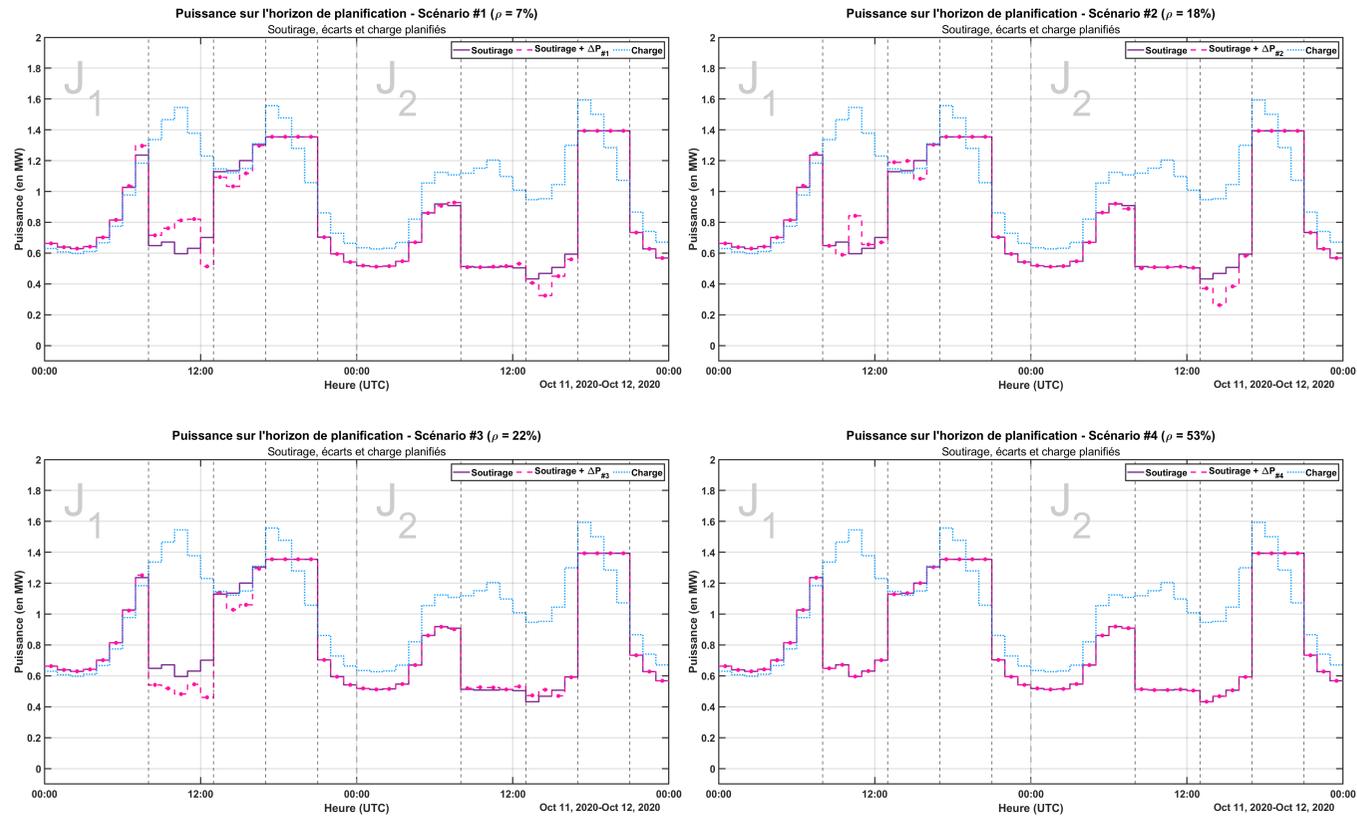


FIGURE D.12 – Résumé des trajectoires de charge résiduelle prévues issues du pilotage prédictif à partir de 4 scénarios - Contrainte implicite - 11/10/2020

D.2 Résultats globaux de la planification stochastique

D.2.1 Distribution horaire des écarts planifiés

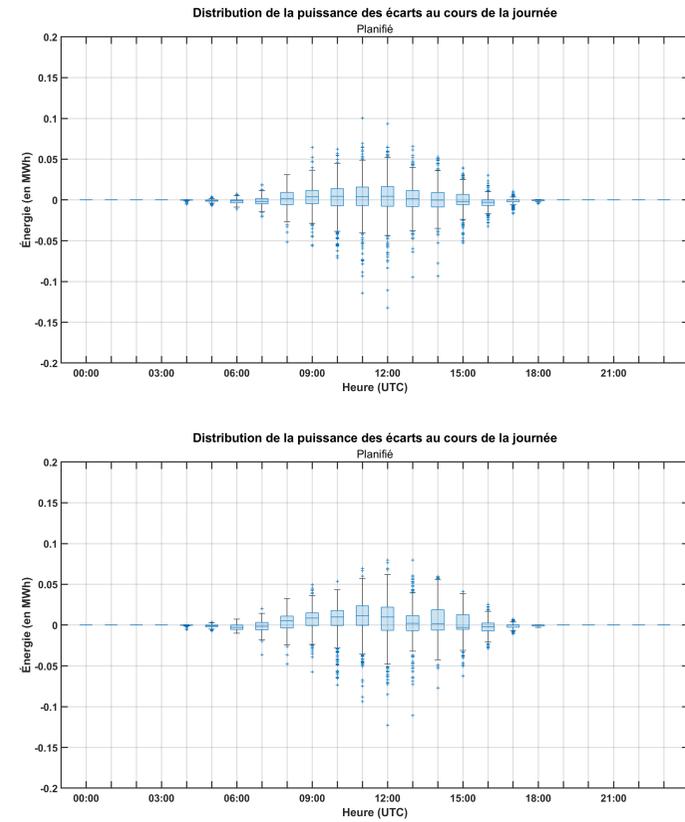
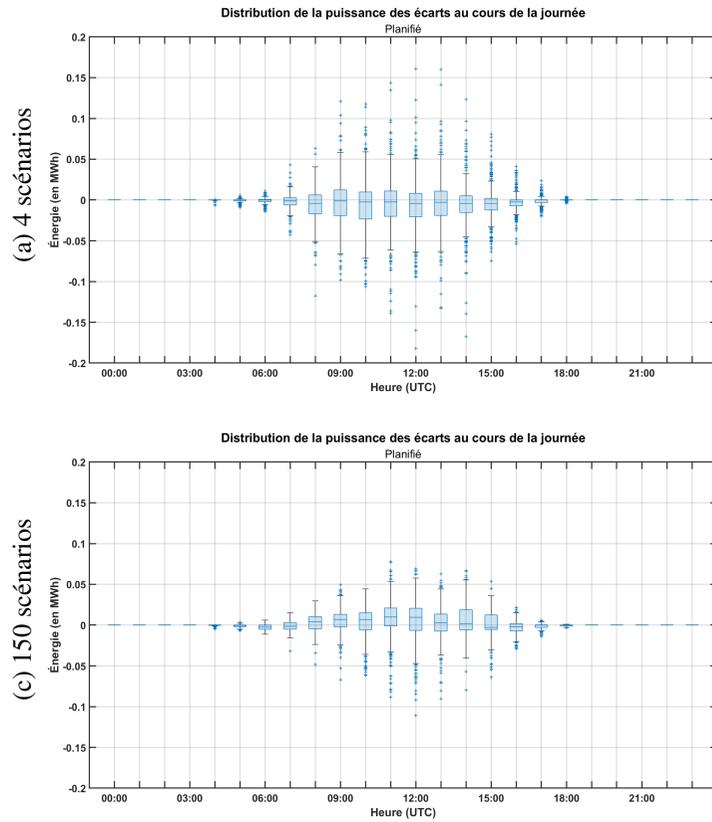


FIGURE D.13 – Distributions des écarts planifiés en fonction du nombre de scénario initial - Synthèse planification stochastique - Contrainte incitative

D.2.2 Distribution horaire des écarts réalisés

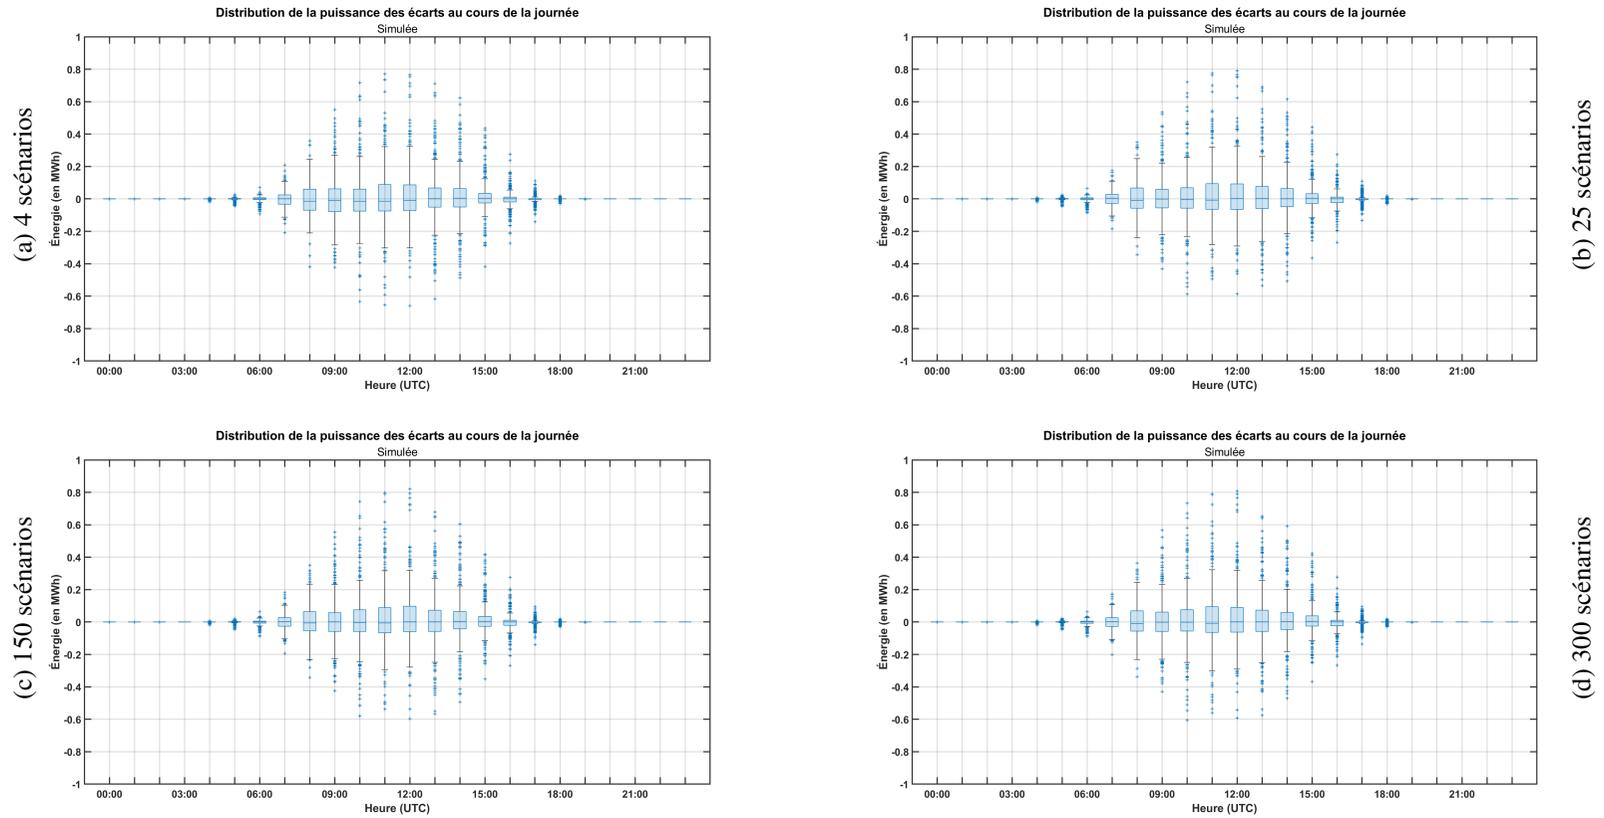


FIGURE D.14 – Distributions des écarts réalisés en fonction du nombre de scénario initial - Synthèse planification stochastique - Contrainte incitative

Solutions avancées de gestion pour les micro-réseaux à fort taux de pénétration des sources renouvelables sous incertitude

Résumé

Dans un contexte d'évolution du système électrique, une attention particulière est portée sur l'intégration des énergies renouvelables dans les réseaux. L'objectif principal du projet de thèse est de développer des solutions pour le pilotage des micro-réseaux à forte pénétration d'énergie renouvelable. Ce projet de recherche explore comment planifier et anticiper le fonctionnement des entités d'un micro-réseau et en particulier son système de stockage, en intégrant les incertitudes liées à la production photovoltaïque. Pour cela, des modèles stochastiques sont proposés pour optimiser la gestion de ces réseaux, améliorer la fiabilité et la qualité de l'énergie, tout en réduisant les coûts opérationnels à partir de prévisions probabilistes.

Les travaux présentent des méthodes pour modéliser l'incertitude dans la production photovoltaïque et démontrent l'efficacité des approches stochastiques. Ils montrent notamment comment ces méthodes peuvent réduire les risques économiques associés au soutirage depuis le réseau principal et offrir un service système précieux en diminuant l'amplitude journalière de puissance soutirée. La thèse propose également une méthode de génération d'ensemble de scénarios réduits pour la planification stochastique, contribuant ainsi à une meilleure opération des micro-réseaux. Cette approche, basée sur la modélisation de la distribution et la dépendance entre les variables étudiées, permet également d'améliorer les prévisions en assimilant des données observées.

Mots-clés : Prévision PV, optimisation stochastique, incertitudes, micro-réseau, planification, gestion de l'énergie

Abstract

In the context of the evolving electrical system, particular attention is given to the integration of renewable energy into the grids. The main objective of the thesis project is to develop solutions for the management of microgrids with a high penetration of renewable energy. This research project explores how to plan and anticipate the operation of the entities within a microgrid, particularly its storage system, by incorporating the uncertainties associated with photovoltaic production. To achieve this, stochastic models are proposed to optimize the management of these networks, enhance the reliability and quality of energy, and reduce operational costs using probabilistic forecasts.

The work presents methods to model the uncertainty in photovoltaic production and demonstrates the effectiveness of stochastic approaches. It notably shows how these methods can reduce the economic risks associated with drawing power from the main grid and provide a valuable system service by decreasing the daily amplitude of drawn power. The thesis also proposes a method for generating a reduced set of scenarios for stochastic planning, thus contributing to better microgrid operation. This approach, based on modeling the distribution and dependence between the studied variables, also improves forecasts by assimilating observed data.

Keywords : Photovoltaic forecasting, stochastic optimization, uncertainties, microgrid, scheduling, energy management

