



HAL
open science

Intégration des prévisions solaires probabilistes dans le contrôle de systèmes énergétiques : application à un microréseau

Faly Hobitokiniaina Ramahatana Andriamasomanana

► **To cite this version:**

Faly Hobitokiniaina Ramahatana Andriamasomanana. Intégration des prévisions solaires probabilistes dans le contrôle de systèmes énergétiques : application à un microréseau. Energie électrique. Université de la Réunion, 2021. Français. NNT : 2021LARE0029 . tel-03891061

HAL Id: tel-03891061

<https://theses.hal.science/tel-03891061>

Submitted on 9 Dec 2022

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.

UNIVERSITÉ DE LA RÉUNION

ÉCOLE DOCTORALE SCIENCES, TECHNOLOGIES ET SANTÉ

LABORATOIRE DE PHYSIQUE ET INGÉNIERIE MATHÉMATIQUE POUR L'ÉNERGIE,
L'ENVIRONNEMENT ET LE BÂTIMENT - PIMENT

THÈSE

Pour obtenir le titre de

DOCTEUR DE L'UNIVERSITÉ DE LA RÉUNION

Spécialité : PHYSIQUE ÉNERGÉTIQUE

INTÉGRATION DES PRÉVISIONS SOLAIRES PROBABILISTES DANS LE
CONTRÔLE DE SYSTÈMES ÉNERGÉTIQUES :
APPLICATION À UN MICRORÉSEAU

présentée par

Faly H. RAMAHATANA A.

Le 08 décembre 2021

Xavier ROBOAM	Directeur de recherche CNRS	INP-ENSEEIH	Rapporteur
Bruno FRANCOIS	Professeur	École Centrale de Lille	Rapporteur
Philippe LAURET	Professeur	Université de La Réunion	Examineur
Richard PEREZ	Professeur	University at Albany	Examineur
Laurent BRIDIER	Docteur	Région Réunion	Invité
Mathieu DAVID	MCF H.D.R.	Université de La Réunion	Directeur

Remerciements

Ces travaux ont bénéficié d'un soutien financier sous forme d'une allocation régionale de recherche de la Région Réunion et de l'Union européenne.

Cette thèse a été réalisée grâce notamment à :

- Mathieu DAVID, Docteur H.D.R., enseignant à l'École Supérieure d'Ingénieurs Réunion Océan Indien (ESIROI) et Directeur du laboratoire PIMENT de l'Université de la Réunion, ami et soutien dans cette thèse. Mathieu m'a donné l'opportunité de réaliser ce travail de recherche dans ce laboratoire. Cette thèse est le fruit de plusieurs années de collaboration avec Mathieu. En tant que directeur de thèse, Mathieu m'a accompagné et encouragé surtout dans les phases critiques de cette thèse. Et malgré ma tendance à être en roue libre, à m'attarder sur certains aspects annexes de ma thèse, parfois même en dehors du cadre de ma thèse, Mathieu a su me réorienter correctement pour la réalisation de ce manuscrit.
- Jean Philippe PRAËNE, Docteur H.D.R., enseignant au département Sciences du Bâtiment et de l'Environnement (SBE) de l'UFR Science de l'Homme et de l'Environnement (SHE) de l'Université de la Réunion, qui est aussi un ami et soutien dans cette thèse.
- Aux membres du jury qui ont bien voulu évaluer mes travaux de thèse
 - Bruno FRANÇOIS, Professeur des Universités à Centrale Lille (INP-ENSEEIH), Laboratoire d'Électrotechnique et d'Électronique de Puissance (L2EP), Rapporteur,
 - Xavier ROBOAM, Directeur de Recherche au CNRS, Laboratoire Plasma et Conversion d'énergie (LAPLACE), Rapporteur.
 - Richard PEREZ, Professeur des Universités à State University of New York, Albany, Atmospheric Sciences Research Center (ASRC), Examineur,
 - Philippe LAURET, Professeur des Universités à l'Université de La Réunion, laboratoire PIMENT, Examineur,
 - Laurent BRIDIER, Docteur, Chargé de mission à la région Réunion, Invité.
- À tous mes collègues doctorants et enseignants du laboratoire PIMENT.
- Une pensée pour toute l'équipe du département SBE du Tampon, de la spécialité Bâtiment et Énergie de l'ESIROI et du département Génie Civil et Construction Durable de l'IUT de La Réunion. Vous m'avez accueilli et m'avez permis d'avoir un environnement de travail exceptionnel. Grâce à vous, j'ai également pu donner des cours magistraux, travaux dirigés et travaux pratiques dans le domaine de l'énergie, de la physique, de la programmation, etc. Sans oublier les techniciens et ingénieurs du laboratoire PIMENT avec qui j'ai noué des liens d'amitié.

- Un grand merci à toute l'équipe de l'Université de La Réunion, plus particulièrement l'équipe de l'école doctorale STS, l'équipe du service de médiation scientifique et le personnel du CROUS de la Réunion.

Je tiens particulièrement à remercier ma famille et mes amis. Votre soutien m'a donné la force et la motivation pour terminer ce travail. Merci aussi à ceux avec qui j'ai travaillé et vécu pendant ces années de thèse, plus particulièrement à l'équipe RAI : Oseana, Miangaly, Hasina, Vanessa, Misa, Lovaniaina, Cathucia & co, Zo et Myrasoa, Laurencia & co, Toky & co, Jordy & co, Tsiory, Nalitiana, Youssouf, Karim, Paulisimone, Mahery, sans oublier les résidents du CROUS du Tampon. Sans vous, cela aurait été plus difficile. Vous êtes ma seconde famille, de véritables soutiens dans mes moments de folie, de bêtise et de doute, merci d'avoir cru en moi.

Et merci à tous ceux qui ont contribué de près ou de loin à la réalisation de cet ouvrage.

Thank you very Much, I enjoyed myself (Richard P. Feynman)

Faly H. Ramahatana A.

Nomenclature

α	Probabilité d'occurrence d'un événement
η^{ESS}	ESS efficiency
η^{inv}	inverter efficiency
η^{PV}	conversion efficiency of the solar cell array
γ	Coefficient de variation de la valeur d'une monnaie au fil du temps
κ	Coefficient de compromis entre la moyenne et la variabilité de l'esperance du coût
λ	PV array derating factor
\mathbb{S}	Distribution de probabilité d'un espace Ξ
μ	Multiplicateur Simplex
ν^P	PV temperature coefficient of power
Ω^{ESS}	Nombre de cycles annuel
\bar{U}	Uncertainty
θ	Paramètre de tuning d'une fonction
φ	Solar transmittance of the PV array
ϑ^{auto}	Autonomie du système
ϑ^{Export}	injection to the grid rate (exportation rate)
ϑ^{Grid}	Appel/importation d'énergie depuis le réseau
ϑ^{sc}	self consumption rate
ϑ^{sp}	self production rate
Ξ	Ensemble de variable aléatoire
ξ	Variable aléatoire
A^{PV}	PV field area
$C_t(x_t)$	Contribution au coût total de l'action x_t
Ca_{ref}	ESS capacity
$CRPS_{pot}$	Potential CRPS

Egp_t	Variable grid cost
$eps_{t+h,k}$	Members of an EPS available at time t and for a forecast horizon h
$ESS_t^{Charge/Discharge}$	energy that flows in and out to the ESS
Fit	Feed-in-tariff
Gr_t	Energy supplied or injected to the main grid
H	Matrice de technologie
Ir	Incident radiation
L_t	Building energy consumption
$L_{h,D}$	Energy consumed by the building at time h for the week day D
p	probabilité de se trouver à l'état S_{t+1}
PV^{max}	Rated capacity of the PV array
PV_t	PV production
Q_τ	Quantile forecast for probability level τ
$Reli$	Reliability
S_t	État (state)
T^a	Ambient temperature
T^c	PV cell temperature
U_t^{grid}	Unit cost of grid energy at time t
V_t	Valeur de la somme de la fonction objectif à l'étape t
W	Matrice de recours
x_t	Décision/action $t \rightarrow t + 1$
Z	ESS's aging coefficient

Acronyms

AC	Courant Alternatif 32, 103, 104, 138
ACO	Ant Colony Optimization 55
ADP	Approximative Dynamic Programming 58, 66–68, 80
ANN	Artificial Neural Network 19, 21, 66, 77
AR	AutoRegressive models 19, 23
ARIMA	AutoRegressive Integrated Moving Average models 19, 20, 56
ARMA	AutoRegressive Moving Average models 16, 19, 25, 60, 76
ARMAX	AutoRegressive Moving Average models with eXogenous inputs 19, 23
AROME	Application of Research to Operations at Mesoscale 20
ARX	AutoRegressive models with eXogenous inputs 19
B&B	Branch and Bound 51, 56
BiPV	Building integrated PhotoVoltaics 28, 138, 149
CARIMA	Controlled AutoRegressive Integrated Moving Average 56
CCHP	Combined Cooling, Heating and Power 55
CDF	Cumulative Distribution Function 22, 25, 26, 129–134, 142, 143
CFA	Cost Function Approximation 79, 80
CMA	China Meteorological Administration 20
CMP	Contraction Mapping Point 142
CNN	Convolutional Neural Network 19
CRPS	Continuous Ranked Probability Score 23, 24, 128, 136–138, 150–152, 154, 155, 157, 158, 168, 174
CSI	Clear Sky Index 133
CTA	Centrales de Traitement d’Air 29
DC	Courant Continu 32, 103, 104, 138
DG	Distributed Generator 129
DP	Dynamic Programming 16, 34, 49, 56, 61–67, 77, 79–81, 83, 100–102, 106, 109, 128–131, 141–143, 146, 167, 168, 172
DWD	Deutscher Wetterdienst 20

ECMWF European Centre for Medium-Range Weather Forecasts 20–22, 100–103, 116, 126, 129, 132–134, 168

ELM Extreme Learning Machine 23

EMS Energy Management System 14, 16, 50, 138, 139, 148, 150

EnerPos Énergie Positive 28–32, 100, 110, 111, 126, 131, 167, 171, 172, 174

ENN Elman Neural Network 16, 56

EnR Energies Renouvelables 1, 3–6, 8, 9, 11, 14–19, 25–27, 33, 34, 50–56, 60–62, 81, 83, 85, 100, 126, 167, 169, 171, 172, 174

EP Evolutionary Programming 55

EPF Electricity Price Forecasting 23

EPS Ensemble Prediction System iv, 22, 60, 128, 130, 132–136, 138, 147–149, 152, 153, 158, 174

ESS Energy Storage System iii, iv, 53, 99, 101, 102, 104–110, 112, 114, 116, 117, 128, 129, 131, 138–146, 148, 149, 173

FF Firefly 55

GA Genetic Algorithm 55, 56

GARCH Generalized AutoRegressive Conditional Heteroskedasticity 23

GEFCom Global Energy Forecasting Competition 18, 24, 152

GHI Global Horizontal Irradiance 131, 135

GRAPES Global/Regional Assimilation and PrEdiction System 20

HASP Hybrid Ant System Priority List 55

HC Hill Climbing 55

HJB Hamilton-Jacobi-Bellman 63, 141, 142

ICA Imperialist Competition Algorithm 55

ICON Icosahedral Nonhydrostatic 20

IFS Integrated Forecasting System 103, 132

IRENA International Renewable ENergy Agency 6–8, 139, 140, 168

ISE Institute for Solar Energy Systems 10, 171

k-NN Nearest Neighbor Neural Network 19

LCOE Levelized Cost Of Electricity 107, 140

LFM Local Forecast Model 20

LFP Lithium Iron Phosphate battery ($LiFePO_4$) 33, 139

LP Linear Programming 68, 69, 77, 83, 84

LQR Linear Quantile Regression 134, 136, 138, 144, 147–149, 152, 153, 173

LR Lagrange Relaxation [51](#), [61](#)
 LTLF Long Term Load Forecasting [23](#)

MA Moving Average models [55](#)
 MAE Mean Absolute Error [23](#), [24](#), [104](#), [115](#), [135](#)
 MBE Mean Bias Error [23](#), [24](#), [104](#), [118](#), [135](#), [168](#)
 MC Markov Chain [23](#)
 MDP Markov Decision Process [68](#), [81](#), [142](#)
 MILP Mixed Integer Linear Programming [56](#), [102](#), [106](#), [128](#)
 MPC Model Predictive Control [55–59](#), [66](#), [71](#), [77](#), [78](#), [80](#), [141](#),
[169](#), [172](#)
 MSC Meteorological Service of Canada [20](#)
 MSM Meso-Scale Model [20](#)

NCEP National Centers for Environmental Prediction [21](#)
 NEA Niching Evolutionary Algorithm [55](#)
 NERC North American Reliability Corporation [12](#)
 NetZeb Net Zero Energy Building [28](#), [29](#), [33](#), [131](#), [149](#), [167](#), [171](#)
 NH Normal Hour [111](#)
 NLP Non Linear Programming [56](#)
 NOCT Nominal Operating Cell Temperature [132](#)
 NWP Numerical Weather Prediction [20](#), [60](#), [126](#), [128](#), [130–133](#)

PDF Probability Density Function [22](#), [25](#)
 PDP Probabilistic Dynamic Programming [34](#), [49](#), [67](#), [68](#), [80](#),
[81](#), [83](#), [85](#), [86](#), [100](#), [128](#), [131](#), [139](#), [142](#), [143](#), [145–147](#), [149](#),
[173](#), [174](#)

PFAs Policy Function Approximations [79](#), [80](#)
 PLF Pinball Loss Function [24](#), [152](#), [154](#), [158](#)
 PSO Particle Swarm Optimization [55](#)
 PV PhotoVoltaïque [iii](#), [iv](#), [5](#), [7](#), [11](#), [12](#), [15](#), [16](#), [18](#), [19](#), [27](#),
[28](#), [30–32](#), [34](#), [53](#), [56](#), [57](#), [77](#), [85](#), [86](#), [100–104](#), [107–110](#),
[112–118](#), [126](#), [128–132](#), [138–140](#), [142](#), [143](#), [145](#), [148](#), [157](#),
[167–169](#), [171](#), [172](#), [174](#)

QP Quadratic Programming [56](#), [68](#), [128](#)
 QR Quantile Regression [60](#)

RES Renewable Energy Source [101](#), [102](#), [128–131](#), [149](#), [150](#)
 RH Rank Histogram [135](#), [136](#), [138](#)
 RMSE Root Mean Square Error [23](#), [24](#), [104](#), [115](#), [135](#)
 RO Robust Optimization [128](#), [130](#)

SA Stimulated Annealing [55](#)
 SARIMA Seasonal AutoRegressive Integrated Moving Average models [19](#)

SDDP	Stochastic Dual Dynamic Programming 53 , 54 , 66 , 77 , 83–85 , 100 , 125 , 139 , 143–146 , 169 , 172–174
SDP	Stochastic Dynamic Programming 53 , 58 , 67 , 130 , 142
Sic	Storage Investment Cost 117 , 140
SOC	State Of Charge 102 , 105 , 106 , 108 , 138 , 139 , 141–143 , 146
SOH	State Of Health 105 , 106 , 108 , 139
SP	Stochastic Programming 53 , 54 , 58 , 62 , 66–72 , 74 , 79 , 83 , 128 , 130 , 172
SPF	Solar Power Forecasting 23
STC	Standard Test Conditions 132
STLF	Short Term Load Forecasting 23
SVM	Support Vector Machine 19
TS	Tabu Search 55
VAR	Vector AutoRegression 23
VD	Variance Deficit 134 , 136 , 138 , 147–149 , 152 , 153
VFA	Value Function Approximation 80 , 81
VRV	Volume de Réfrigérant Variable 29
WMO	World Meteorological Organization 131
WNN	Wavelet Neural Network 16 , 56
WPF	Wind Power Forecasting 23
WRF	Weather Research and Forecasting 20

Buffer	Systeme de stockage avec convertisseur et filtre, couplé à un générateur intermittent pour obtenir une rampe de puissance contrôlée (système servant d'amortisseur de puissance). 11
CAES	<i>Compressed-air energy storage</i> . Stockage d'énergie à air comprimé. En mode de charge, l'énergie électrique est convertie en air sous pression dans un réservoir. En décharge, l'air sous pression contenu dans le réservoir alimente une turbine pour produire de l'électricité. 11
Charges non critiques	Désignent les équipements et appareils électriques qui peuvent être soumis à une variation assez importante de leur tension d'alimentation (radiateurs électriques, réfrigérateurs, systèmes d'éclairage, moteurs asynchrones, machines outils). 14
Electric spring	Un ressort électrique est un dispositif électrique qui peut être utilisé pour fournir un support de tension électrique, stocker de l'énergie électrique et amortir les oscillations électriques. 14
PHS	<i>Pumped hydroelectric energy storage</i> . L'énergie électrique est convertie en énergie potentielle gravitaire. L'eau est pompée vers un réservoir surélevé, lorsque l'électricité est nécessaire, l'eau alimente une turbine au point le plus bas et produit de l'électricité. 11
Power-to-X	Conversion de l'énergie électrique sous une autre forme telle que la chaleur, l'hydrogène ou autre. Ce type de système est utilisé pour stocker de l'énergie pendant une longue période et constitue une alternative aux réductions (écrêtage) des productions d'énergie intermittentes. 8 , 9 , 171
Réactive	Puissance permettant d'évaluer les charges capacitatives et inductives des équipement 14

réserve	Capacité de puissance réelle qui peut être donnée ou prise dans la période de temps de fonctionnement pour aider à la production, à l'équilibre de la charge et au contrôle de la fréquence. 10–12 , 16
Super-réseaux	Réseaux connectés à d'autres réseaux sur de longues distances avec un nouveau système de transport d'énergie (énergie et information). 6
UC	<i>Unit commitment</i> . Correspond aux processus de répartition des sources de production au plus bas coût. 14–16 , 18 , 25 , 50–53 , 55–62 , 80 , 81 , 83 , 85 , 100 , 128–131 , 169 , 171 , 172

Abstract

The issue of global warming has been on the political, scientific, economic and societal agenda for nearly thirty years. Many countries have committed to decarbonize their energy production in order to achieve security and sustainability of supply. In order to achieve these objectives, one of the first levers is to increase the penetration of intermittent renewable energies (solar, wind, wave) in the energy production mix. Intermittent renewable energies are abundant, but they are very fluctuating. Indeed, their production is generally very dependent on climatic hazards (clouds, wind, temperature). Because of this high variability, the massive integration of this type of energy in the electrical grids makes it difficult to maintain the balance between production and consumption.

To achieve a massive integration of intermittent renewable energies in the grids, various solutions are considered. First, it is possible to adapt consumption to the production profile (load shifting). This demand management involves, for example, consuming as the sun goes by in the case of solar generation. Another possible solution is to oversize the production system and to clip the overproduction. Unfortunately, this solution alone does not guarantee continuous production when the resource is non-existent. The most common solution is the use of storage systems. It guarantees the adaptation of production to consumption. Indeed, the energy stored during moments of overproduction can be used later. Unlike storage, which is a costly solution, it is possible to anticipate fluctuations in production and consumption by using forecasts. Each of these solutions considered alone does not lead to a viable technical or economic response. It is therefore necessary to adopt a combination of these solutions in order to consider a massive integration of intermittent renewable energies into the electrical networks.

In order to ensure a balance between production and consumption with a minimum operating cost, it is necessary to plan in advance the commitment of the production means (unit commitment). This planning is achieved through the technical and economic optimization of the future generation mix. It is therefore necessary to have reliable forecasts of consumption and production. As the generation of conventional production systems (thermal, nuclear, hydroelectric) is controllable, it is not really a question of forecasting, but of availability. On the other hand, as with consumption, the random nature of intermittent renewable energy production requires the use of forecasts.

In this thesis, we propose to address the problem of using forecasts of intermittent renewable energy production in planning the operation of energy systems, such as storage, within a power system.

The point forecast, also known as deterministic, is the most commonly used forecast. This forecast provides a single value for the future generation level. Because forecasting intermittent renewable energy generation is weather dependent, it has a significant random component. Deterministic forecasts are therefore uncertain. The use of this type of forecasting in energy sys-

tem management is handled either by ignoring forecast errors or by using an error propagation method. Even in the latter case, taking uncertainty into account is not always relevant.

Probabilistic forecasts were designed to provide information about the uncertainty associated with the forecast. Probabilistic forecasts take the form of a probability distribution or a representative set of possible values of the predicted variable. These forms make the integration of forecasts into optimization more complex. Moreover, techniques for generating probabilistic forecasts on renewable energy are relatively new. The state-of-the-art on their use for optimization of generation commitment planning is almost non-existent.

A review of the literature has been done, on the one hand, on deterministic and probabilistic forecasting methods used to forecast the production of intermittent renewable energies, and on the other hand, on optimization techniques, especially stochastic ones. This state-of-the-art has proposed a new approach to integrate probabilistic forecasts in the optimization of generation resources planning based on probabilistic dynamic programming. This new approach is able to avoid the scenario generation step while benefiting from the advantages of time-correlated probabilistic forecasts. A benchmark method for optimization has also been selected to evaluate the effectiveness of the proposed method.

The methodology developed in this thesis is applied to a real microgrid consisting of a positive energy building located in Reunion Island. This case study includes a university building with a photovoltaic array integrated on the roof and coupled to an energy storage, which will be fictive. The optimization of the storage operation will first be considered with deterministic forecasts, then with probabilistic forecasts.

This work will attempt to provide answers to the following scientific problems :

- the use of deterministic forecasting interesting for reducing the operating costs of an energy system ? Is this management better than rule-based management ?
- Is it better to use probabilistic forecasting than deterministic forecasting to reduce the cost of operating an energy system ?
- Is there a relationship between the indicators assessing the quality of forecasts and the technical and economic gains associated with their use ?

This work has proposed a methodology for using probabilistic forecasts of intermittent renewable energy production in the management of energy systems. The work clearly shows that the use of probabilistic forecasts leads to better economic gains than deterministic forecasts. This work contributes to demonstrate the benefits of using probabilistic forecasts to the energy sector.

Résumé

La question du réchauffement climatique s’invite depuis près de trente ans à la table des débats politiques, scientifiques, économiques ou sociétaux. De nombreux pays se sont engagés dans une décarbonation de leur production énergétique, visant ainsi une sécurité et une durabilité de l’approvisionnement. Afin d’atteindre ces objectifs, l’un des premiers leviers est l’augmentation de la pénétration des énergies renouvelables intermittentes (solaire, éolien, houle) dans les mix de production énergétique. Les énergies renouvelables intermittentes sont abondantes, mais elles sont très fluctuantes. En effet, leur production est en général très dépendante des aléas climatiques (nuages, vents, températures). À cause de cette forte variabilité, l’intégration massive de ce type d’énergie dans les réseaux électriques complexifie le maintien de l’équilibre entre la production et la consommation.

Pour parvenir à une intégration massive des énergies renouvelables intermittentes dans les réseaux, diverses solutions sont envisagées. Premièrement, il est possible d’adapter la consommation au profil de production. Cette gestion de la demande implique par exemple de consommer au fil du soleil dans le cas d’une production d’origine solaire. Une autre solution possible est de surdimensionner le système de production et d’écarter la surproduction. Malheureusement, cette solution à elle seule ne permet pas d’assurer une production continue lorsque la ressource est inexistante. La solution la plus répandue est l’utilisation de systèmes de stockage. Elle permet d’adapter la production à la consommation. En effet, l’énergie stockée lors des moments de surproduction peut être utilisée ultérieurement. Contrairement au stockage qui est une solution coûteuse, il est aussi possible d’anticiper les fluctuations de production et de consommation en utilisant des prévisions. Chacune de ces solutions envisagées seules n’aboutit pas à une réponse technique ou économique viable. Il est donc nécessaire d’adopter une combinaison de ces solutions afin d’envisager une intégration massive des énergies renouvelables intermittentes dans les réseaux électriques.

Afin d’assurer l’équilibre entre la production et la consommation avec un coût minimal de fonctionnement, il est nécessaire de planifier à l’avance l’engagement des moyens de production. Cette planification est obtenue par l’optimisation technique et économique du mix de production futur. Il est donc nécessaire de disposer de prévisions fiables de la consommation et des productions. La génération des systèmes conventionnels de production (centrale thermique, nucléaire, hydroélectrique) étant contrôlable, il ne s’agit pas réellement de prévision, mais de disponibilité. Par contre, à l’instar de la consommation, le caractère aléatoire de la production des énergies renouvelables intermittentes requiert l’utilisation de prévisions.

Dans ce travail de thèse, nous proposons d’aborder la problématique de l’utilisation des prévisions de production des énergies renouvelables intermittentes dans la planification du fonctionnement de systèmes énergétiques, tel que le stockage, au sein d’un réseau électrique.

La prévision point, aussi appelée déterministe, est la prévision la plus couramment utilisée.

Cette prévision donne une valeur unique du niveau futur de la production. La prévision de la production des énergies renouvelables intermittentes étant dépendante de phénomènes météorologiques, elle a une composante aléatoire importante. Les prévisions déterministes sont donc incertaines. L'utilisation de ce type de prévision dans la gestion des systèmes énergétiques se fait, soit en ne tenant pas compte des erreurs de prévision, soit en utilisant une méthode de propagation d'erreur. Même dans ce dernier cas, la prise en compte de l'incertitude n'est pas toujours pertinente.

Les prévisions probabilistes ont été conçues pour donner une information sur l'incertitude associée aux prévisions. Les prévisions probabilistes prennent la forme d'une distribution de probabilités ou d'un ensemble représentatif des valeurs possibles de la variable prédite. Ces formes rendent plus complexe l'intégration des prévisions dans l'optimisation. De plus, les techniques de génération de prévisions de production des énergies renouvelables intermittentes probabilistes sont relativement nouvelles. L'état de l'art sur leur utilisation pour l'optimisation de la planification de l'engagement des moyens de production est quasi inexistant.

Une revue de la littérature a été faite, d'une part, sur les méthodes de prévisions déterministes et probabilistes utilisées pour prédire la production des énergies renouvelables intermittentes, et d'autre part, sur les techniques d'optimisation, notamment stochastiques. Cet état de l'art a permis de proposer une nouvelle approche pour intégrer des prévisions probabilistes dans l'optimisation de la planification des moyens de production s'appuyant sur la programmation dynamique probabiliste. Cette nouvelle approche permet de s'affranchir de l'étape de génération de scénarios en bénéficiant des avantages des prévisions probabilistes corrélées temporellement. Une méthode de référence pour l'optimisation a aussi été sélectionnée pour évaluer les performances de la méthode proposée.

La méthodologie développée dans ce travail de thèse est appliquée à un microréseau réel constitué d'un bâtiment à énergie positive situé sur l'île de La Réunion. Ce cas d'étude comporte un bâtiment universitaire disposant d'un générateur photovoltaïque intégré en toiture et couplé à un stockage d'énergie, qui lui sera fictif. L'optimisation de la planification du fonctionnement du stockage sera dans un premier temps envisagée avec des prévisions déterministes et dans un second temps avec des prévisions probabilistes.

Ces travaux tenteront d'apporter des réponses aux verrous scientifiques suivants :

- L'utilisation de la prévision déterministe est-elle intéressante pour réduire le coût de fonctionnement d'un système énergétique ? Cette gestion est-elle meilleure qu'une gestion basée sur des règles expertes ?
- L'utilisation de prévisions probabilistes est-elle plus performante que l'utilisation de prévisions déterministes pour réduire le coût de fonctionnement d'un système énergétique ?
- Existe-t-il une relation entre les indicateurs évaluant la qualité des prévisions et les gains techniques et économiques liés à leur utilisation ?

Ce travail a proposé une méthodologie pour utiliser des prévisions probabilistes de production des énergies renouvelables intermittentes dans la gestion de systèmes énergétiques. Les travaux montrent clairement que l'utilisation des prévisions probabilistes conduit à de meilleurs gains économiques que les prévisions déterministes. Ce travail contribue à démontrer aux acteurs du secteur de l'énergie les avantages liés à l'utilisation de prévisions probabilistes.

Introduction

The formulation of the problem is often more essential than its solution, which may be merely a matter of mathematical or experimental skill.

Albert Einstein

A mesure que la population augmente, les besoins énergétiques ne cessent d'augmenter. Actuellement, la recherche sur l'efficacité énergétique et les moyens de production sont mis en avant par la majorité des pays. Cette recherche se concentre dans le domaine des transports, de la gestion de l'énergie ou de la production de matière première. Dans le domaine de la production d'énergie électrique, l'objectif affiché par la majorité des pays est de réduire la génération de gaz à effet de serre tout en assurant la sécurité de cette énergie. Suivant les ressources disponibles dans chaque pays, ces 2 objectifs ne vont pas souvent de pair, la préservation de la planète d'un côté, la production d'énergie de l'autre. Les questions récurrentes sont toujours les mêmes : Quelles énergies utiliser ? Comment les utiliser et surtout, à quels prix ? La tendance actuelle mise sur l'exploitation massive des énergies renouvelables, mais en 2016, seulement 24.5% de la production mondiale d'électricité provenait d'une source renouvelable. Lorsqu'on aborde la notion d'énergie renouvelable, il est important de distinguer si cette énergie renouvelable est intermittente ou non. Les énergies renouvelables non intermittentes sont des énergies très fiables et stables comme l'hydro-électricité, la géothermie ou la bioénergie. Les énergies renouvelables non intermittentes nécessitent souvent d'importants investissements ou des transformations significatives, à l'instar de l'utilisation de la géothermie qui nécessite des infrastructures complexes. De plus, suivant le territoire, la disponibilité de ressources non intermittentes est très variable. Par exemple, la Norvège tire 93.4% de son électricité de ces centrales hydroélectriques alors qu'à La Réunion, même si le potentiel est presque totalement exploité, l'hydro-électricité ne représente que 14% de la production électrique.

L'autre type d'énergie renouvelable est celle dite intermittente. L'intermittence fait référence au fait que la production soit fluctuante ou variable comme le cas de l'énergie solaire, éolienne ou de la houle. En effet, la production d'énergie de ces sources varie en fonction des conditions climatiques, comme la vitesse du vent, la position du soleil ou le passage de nuage. Pour maintenir l'équilibre avec la demande, ces fluctuations contraignent les acteurs de l'énergie à coupler ces énergies renouvelables intermittentes avec d'autres dispositifs ou source d'énergie. En outre, à l'inverse de l'hydro-électricité ou de la géothermie, ces énergies sont très abondantes dans le monde. Même dans les déserts, il y a du vent ou du soleil. De plus, les systèmes utilisant les énergies intermittentes sont plus faciles à installer et à déployer. En effet, la mise en place d'une centrale photovoltaïque ou d'un parc d'éoliennes nécessite des infrastructures beaucoup

plus légères que leur homologue hydroélectrique, thermique ou géothermique.

À la question du type d'énergie à utiliser, la réponse est probablement l'utilisation de ressources renouvelables intermittentes couplées avec d'autres dispositifs. Quant à l'utilisation, elle est liée intrinsèquement aux coûts d'investissement et d'exploitation. En matière d'investissement, la majorité des systèmes de production utilisant des énergies renouvelables intermittentes déjà construites ou à venir sont des centrales photovoltaïques ou des parcs éoliens. De plus, depuis la libéralisation du marché de l'énergie, le secteur privé joue un rôle important dans la fourniture d'énergie. Aujourd'hui, des producteurs d'énergie indépendants fournissent l'énergie aux réseaux de transport ou de distribution via des contrats de productions. En ce qui concerne l'exploitation, comme toute marchandise, l'énergie est régie par l'équilibre entre l'offre et la demande. Dans ce schéma d'offre et de demande, plusieurs acteurs entrent en jeu, à savoir, l'exploitant ou gestionnaire du réseau, le producteur d'énergie ou le consommateur.

Pour l'exploitant du réseau électrique, il y a un besoin de visibilité sur la consommation et sur le coût de l'énergie. Ces informations lui permettent d'évaluer les ressources disponibles qui conduisent à une gestion optimale de l'énergie et qui contribuent à la stabilité du réseau dans sa globalité. Pour le producteur d'énergie, l'objectif est de maximiser les profits. Et pour le dernier acteur, le consommateur, s'il dispose de système de micro-production, son objectif est de diminuer sa dépendance au réseau. En outre, le besoin commun de tous ces acteurs est la connaissance de la ressource disponible. Lorsque la ressource est intermittente, il est donc nécessaire de disposer de prévisions pour mettre en œuvre une gestion optimale des systèmes.

Afin d'atteindre ces objectifs, il est nécessaire de disposer d'une prévision de la production des systèmes utilisant les énergies renouvelables intermittentes. Les prévisions peuvent être de 2 natures. D'une part, elles peuvent être déterministes, notamment si le phénomène à prévoir est lui-même déterministe. D'autre part, elles peuvent être probabilistes, ce qui permet de capturer les incertitudes liées à la prévision. La précision des prévisions est généralement quantifiée par sa qualité qui correspond à la correspondance entre les observations et les prévisions.

Par contre, pour l'utilisateur, l'information la plus importante n'est pas la qualité de la prévision, mais la valeur ajoutée qu'elle apporte par son utilisation. En d'autres termes, une prévision peut avoir de très bons scores évaluant sa consistance avec les observations, mais conduire à un coût d'exploitation élevé.

Ce travail de thèse propose une méthodologie de prise en compte des prévisions probabilistes de la production d'énergies renouvelables intermittentes dans la gestion optimale des systèmes énergétiques. L'application de cette méthode à la planification du fonctionnement d'un système de stockage d'énergie présent dans un microréseau permettra de mettre en avant l'intérêt d'utiliser des prévisions probabilistes. Enfin, cette application donnera aussi un aperçu de la valeur ajoutée de l'utilisation des prévisions dans le contrôle des systèmes énergétiques.

Table des matières

Remerciements	i
Acronymes	v
Glossaire	ix
Introduction	xv
1 EnR intermittentes dans les réseaux d'électrique	1
1.1 Problématique de l'intégration des EnR intermittentes	1
1.2 Stratégies d'intégration	5
1.3 Prédiction de production d'EnR intermittentes	18
1.4 Un cas d'étude en zone non interconnectée (ZNI)	26
1.5 Positionnement et apport de la thèse	33
2 Intégration des prévisions dans l'optimisation du fonctionnement des systèmes énergétiques	49
2.1 Optimisation en gestion de l'énergie	50
2.2 Optimisation stochastique	62
2.3 Conclusion	85
3 Microréseau et prévisions déterministes	99
3.1 Introduction	100
3.2 Economic optimization of a micro-grid operations by dynamic programming with real energy forecast	101
Faly Ramahatana, Mathieu David	
3.3 Conclusion	118
4 Microréseau et prévisions probabiliste	125
4.1 Introduction	126
4.2 Integration of probabilistic solar forecasts in the optimization of a microgrid operation	128
Faly Ramahatana, Josselin Le Gal La Salle, Philippe Lauret, Mathieu David	
4.3 Indices de performance complémentaires	151
4.4 Relations entre la qualité des prévisions et les performances technico-économiques	152
4.5 Conclusion	158

5	Conclusions et perspectives	167
5.1	Conclusion générale	167
5.2	Limitations de l'étude	168
5.3	Perspectives	169

CHAPITRE 1

EnR intermittentes dans les réseaux d'électrique

A theory has only the alternative of being right or wrong. A model has a third possibility : it may be right, but irrelevant.

Manfred Eigen

Sommaire

1.1	Problématique de l'intégration des EnR intermittentes	1
1.2	Stratégies d'intégration	5
1.2.1	Dispositifs de compensations avec stockage d'énergie	9
1.2.2	Dispositifs de compensations sans stockage	12
1.2.3	Utilisation de la prévision dans les réseaux d'énergie	14
1.3	Prévision de production d'EnR intermittentes	18
1.3.1	Techniques de prévision des ressources EnR intermittentes	19
1.3.2	Prévision déterministe et probabiliste	22
1.3.3	Évaluation des prévisions	23
1.3.4	Limites actuelles	24
1.4	Un cas d'étude en zone non interconnectée (ZNI)	26
1.4.1	Enjeux des EnR intermittentes en milieu insulaire	26
1.4.2	Enerpos un NetZEB sous les tropiques	28
1.4.2.1	Caractéristiques du bâtiment	28
1.4.2.2	Configuration du microréseau	31
1.4.3	Intérêt de la prévision	33
1.5	Positionnement et apport de la thèse	33

1.1 Problématique de l'intégration des EnR intermittentes

Il existe de nombreuses sources d'énergie qui peuvent être converties en électricité comme le charbon, la force de l'eau, le vent, le soleil ou le pétrole. À la fin du 19^{ème} siècle, du fait de l'isolement des villes et villages, chaque agglomération disposait de son propre réseau de distribution et de production électrique.

Or, depuis l'invention de la *machine dynamoélectrique* plus communément appelée dynamo

par Gramme en 1869 [1], la génération de l'électricité est principalement due à des machines tournantes. Avec l'arrivée du courant alternatif, les dynamos ont évolué en alternateurs (ce sont des machines synchrones ou asynchrones). Les réseaux isolés avaient principalement la configuration de la figure 1.1. Pour pouvoir garantir l'approvisionnement en énergie, ces centrales de productions étaient le plus souvent surdimensionnées et présentaient des problèmes de gaspillages en cas de diminution des besoins due à la non-utilisation.




FIGURE 1.1 – Schéma de principe d'un réseau isolé avec un seul générateur

De plus, l'utilisation du courant alternatif a permis le transport de l'énergie sur de grandes distances. Non seulement ceci a permis d'électrifier les périphéries des villes, mais aussi d'alimenter d'autres villes distantes de centaines ou de milliers de kilomètres. Ces liaisons ont permis de relier entre elles les villes et leurs générateurs, on parle d'interconnexions. Avec cette interconnexion (fig. 1.2), les villes et pays sont aujourd'hui reliés. La nouvelle configuration du réseau électrique possède une multitude de générateurs et de charges.

Néanmoins, comme pour tout système, il faut assurer l'équilibre offre-demande. Dans le cas de la fourniture d'électricité, l'offre (production) doit nécessairement être égale à la demande (consommation) à tout moment. Dans le cas d'un réseau isolé, le générateur doit être flexible et doit être capable d'absorber directement les fluctuations de la charge. En cas de panne, des systèmes de secours disposant de la même capacité que le générateur sont ainsi nécessaires. Dans le cas du réseau interconnecté, les risques sont distribués sur tous les générateurs. Les systèmes de secours sont néanmoins nécessaires, mais leur capacité est largement inférieure à la puissance requise pour alimenter la charge. Un autre concept important concernant la génération de l'énergie électrique est la valeur de la fréquence. La fréquence (et implicitement la tension dans des cas particuliers à l'exemple de Guinée et al. [2]) de fonctionnement du système est dépendante de l'équilibre production-demande. Si la demande est supérieure à la production, il y a chute de la fréquence, et inversement. De plus, les équipements électroménagers sont conçus pour fonctionner sur des plages fixes de tension et de fréquences. Les variations de fréquence ou de tension risquent donc d'endommager ces appareils. De même, dans le réseau, les dispositifs de conversion, comme les transformateurs, ou de transports, comme les lignes, ont des limites de fonctionnement. Outre ces problèmes techniques, lorsque l'équilibre offre-demande n'est pas satisfait, il y a des implications économiques. À titre d'exemple, la surproduction est un gaspillage d'énergie et aussi un gaspillage d'argent.

Du côté de la consommation, les acteurs peuvent être des collectivités, des entreprises ou des particuliers. Ces acteurs ont des besoins très différents. Par exemple, les écoles et le tertiaire consomment l'essentiel de leur énergie pendant la journée. En revanche, les ménages ont davantage besoin d'énergie tôt le matin et en soirée. De même, les besoins d'un village agricole ne correspondent pas aux besoins d'un village touristique. Chaque acteur a des besoins à différentes échelles de temps, à différents niveaux d'énergie et à différents moments de la journée. En connectant tous ces consommateurs ensemble, un effet de lissage se produit par foisonnement.

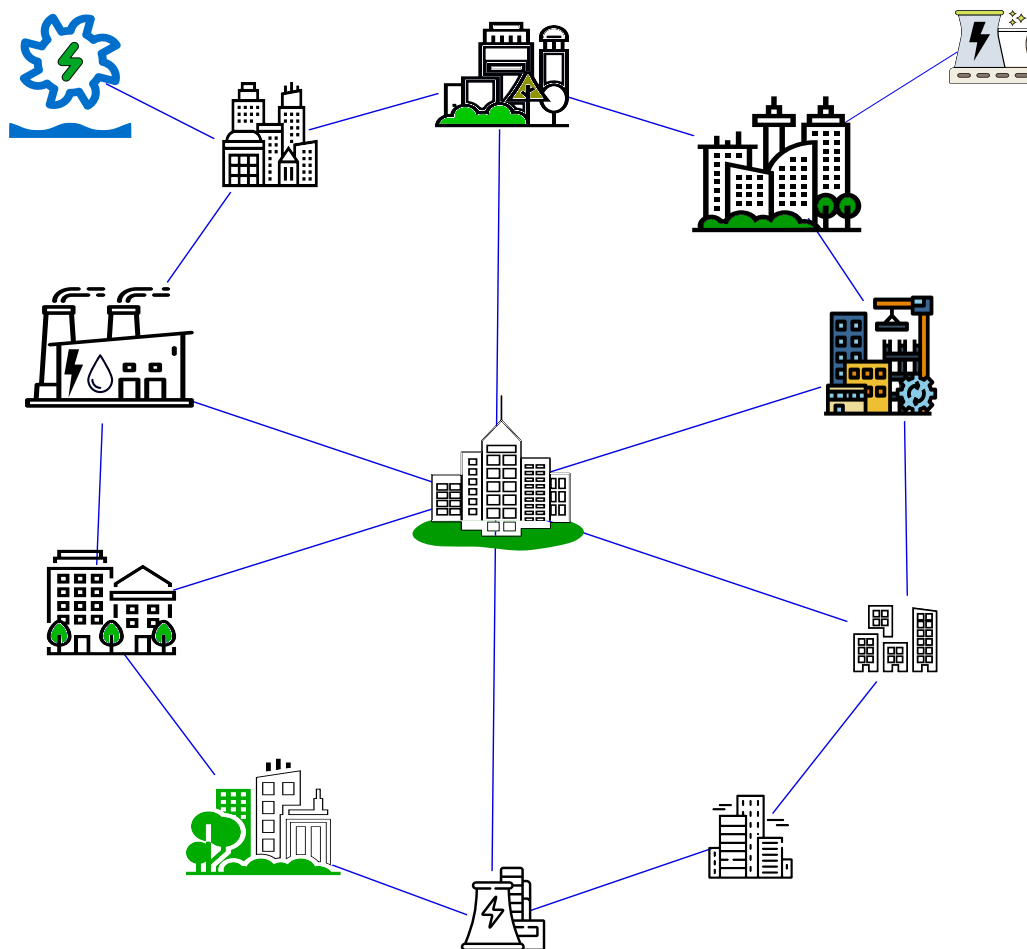


FIGURE 1.2 – Schéma de principe d'un réseau interconnecté

Cet effet génère un profil total de consommation plus uniforme et moins variable. En effet, le fait d'agrèger les charges rend la consommation totale plus lisse.

Avec la libéralisation du marché de l'électricité dans les années 90, les acteurs de l'énergie ont porté un intérêt croissant pour l'intégration des énergies renouvelables (EnR) dans la production. Il existe divers types d'EnR. Nous nous intéresserons ici aux EnR dites intermittentes, tels que le solaire, l'éolien ou la houle, dont la ressource est non contrôlable et fortement variable dans le temps et dans l'espace. En raison de la transition énergétique, les études menées par Praene et al. [4], Hansen et al. [5] montre que les EnR intermittentes sont les meilleures alternatives pour augmenter la production et diminuer la dépendance aux énergies fossiles. En effet, les EnR intermittentes sont des ressources largement disponibles. La part grandissante du niveau d'investissement mondial dans les EnR intermittentes reflète cette évolution. Comme le montre la figure 1.3 présentant l'évolution entre 2013 à 2018, l'investissement pour le renouvelable dans le monde est largement dominée par le solaire et l'éolien.

Or, les énergies renouvelables intermittentes sont générées par des flux naturels qui ne sont pas contrôlables et présentent une grande variabilité. Le fait d'intégrer ce type d'énergie à forte variation dans le réseau (fig. 1.4) rajoute de la complexité. D'un côté, la charge est déjà variable, avec l'intégration des énergies renouvelables intermittentes, la production devient, elle aussi, variable. Et quoi qu'il en soit, l'équilibre offre-demande doit toujours être maintenu. Les autres




FIGURE 1.3 – Investissement mondial pour les énergies renouvelables (IRENA et CPI [3])

caractéristiques des énergies renouvelables intermittentes sont dues à leur nature. Selon Gross et al. [6], leurs fluctuations présentent de très grandes amplitudes et la disponibilité de l'énergie n'est pas fiable contrairement aux groupes électrogènes classiques (groupe électrogène diesel, hydroélectrique). Avec l'ajout de ces nouvelles variabilités, des mesures supplémentaires sont obligatoires pour sécuriser l'approvisionnement énergétique. Il est donc nécessaire d'adopter des stratégies de gestion nouvelles afin d'intégrer massivement ces EnR intermittentes dans le réseau.

Dans les réseaux électriques, la fréquence est utilisée comme mesure du déséquilibre entre la production et la consommation. Si un réseau est composé uniquement de générateurs conventionnels (charbon, diesel, nucléaire, hydroélectrique), la régulation de la fréquence est assurée par ces machines tournantes. L'inertie de ces machines tournantes permet de stabiliser la fréquence malgré les fluctuations rapides observées du côté de la demande. En d'autres termes, la fréquence est définie par les vitesses de rotation des rotors de ces générateurs. L'intégration croissante de générateurs EnR intermittentes dans les réseaux implique de nouveaux défis dus aux intermittences. Ces défis concernent notamment les systèmes de transport, les systèmes de protection et l'équilibre offre-demande [7, 8]. Ces 3 enjeux représentent des axes de recherche majeurs dans la gestion des réseaux électriques. Dans le cadre de ce travail de thèse, nous avons choisi de nous concentrer plus spécifiquement sur la problématique du maintien de l'équilibre offre-demande d'un réseau en présence d'énergies renouvelables intermittentes.




FIGURE 1.4 – Schéma de principe d'un réseau interconnecté intégrant une production distribuée d'EnR

1.2 Stratégies d'intégration

La dispersion et le foisonnement constituent la toute première des stratégies d'intégration. Elle est implicite à la répartition spatiale des systèmes de production EnR intermittents. En effet, plus deux systèmes utilisant une ressource intermittente sont éloignés, plus leur production est décorrélée. Il en résulte un lissage automatique de leur puissance agrégée. En pratique, il s'agit de répartir spatialement les centrales de production d'électricité d'origine intermittente (par exemple PV ou éoliennes). En tenant en compte des dispositions géographiques, pour une puissance PV uniformément répartie, Hoff et Perez [9] ont montré que la relation de variabilité entre deux points peut être évaluée par un facteur de dispersion. L'extension de ces travaux [10] montre que ce facteur de dispersion est caractéristique des conditions climatiques. En suivant la même méthodologie, David et al. [11] ont montré que l'effet de foisonnement se réalise à des distances plus courtes pour les cas insulaires que continentaux. Et, il a été démontré que la variabilité est minimisée lorsque le nombre de systèmes est égal au facteur de dispersion.

Dans le cas d'une intégration massive du photovoltaïque dans le réseau, la dispersion et le foisonnement peuvent être associés à des systèmes de stockage. Un exemple d'utilisation de la dispersion combinée avec du stockage réparti est proposé dans le cas continental par Perez et al. [12] pour atténuer l'intermittence de la puissance PV. Dans le même type d'exemple, Tapaches

et al. [13] ont appliqué cette méthodologie dans un cas insulaire, mais combinée à un système de stockage centralisé.

Au-delà de l'effet de foisonnement, de nouvelles mesures pour maintenir l'équilibre offre-demande d'un réseau doivent être définies lorsque la part des EnR intermittentes devient significative. Ces mesures peuvent être un ensemble de solutions prises au niveau du réseau. Une des plus complètes est celle proposée par l'agence internationale pour les énergies renouvelables (IRENA) dont la solution recommandée est une flexibilité à tous les niveaux [14], l'offre, la demande, le réseau et même à l'échelle du système :

- La flexibilité de l'offre (la production) est obtenue en diminuant l'incertitude de la production d'énergie renouvelable. Cette diminution est obtenue avec l'utilisation des prévisions météorologiques avancées et de systèmes de productions flexibles capables de limiter la variabilité. Cette flexibilité peut aussi passer par l'adaptation des centrales électriques conventionnelles. Par exemple, les centrales au charbon modernes peuvent fonctionner à des niveaux de charge minimum de 25% à 40% de la charge nominale, alors que les centrales d'il y a 20 ans nécessitaient une charge minimale de 40% à 60%. Avec une faible charge minimale de fonctionnement, ce type de centrale peut offrir une grande flexibilité, car il est possible d'adapter leur production à la variation de la production d'énergie renouvelable intermittente.
- Pour le réseau, la flexibilité est assurée par l'interconnexion et les marchés régionaux.
 - L'utilisation de **Super-réseaux** à grande échelle permettrait d'établir des interconnexions à de très grandes distances et même à l'échelle mondiale comme le propose Chatzivasileiadis et al. [15]. Un exemple concret est le projet de câble sou-marin de 3200km décrit par edm [16], Gordonnat et Hunt [17] pour le transport de l'énergie photovoltaïque (10GW) entre l'Australie et Singapour.
 - L'utilisation de système de batteries et de stockages (mécaniques, électrochimiques et électriques) qui limite les pertes de surproduction d'EnR.
- Du côté de la demande, le consommateur est une des clés de la flexibilité. Grâce à une meilleure gestion de sa consommation et de sa production, en fonction de la tarification (achat, revente), il pourrait réduire sa demande sur le réseau et absorber les surplus d'énergie en rechargeant, par exemple, les véhicules électriques.
- La génération distribuée et les microréseaux sont des solutions qui concernent à la fois la flexibilité de la production et du réseau. La génération distribuée est basée sur l'utilisation des ressources renouvelables intermittentes directement au niveau des consommateurs (dans les quartiers ou sur les bâtiments par exemple). Dans le cas où les générations distribuées bénéficient d'une meilleure visibilité pour les opérateurs du réseau et du système, elles peuvent contribuer à l'équilibre du réseau, fournir des services auxiliaires, éviter la congestion des lignes de distribution ou de transmission et minimiser les besoins de renforcement du réseau. En outre, les microréseaux peuvent à la fois fonctionner de manière indépendante et offrir une flexibilité au réseau.

Sans tenir compte de l'effet de foisonnement et des dispositions spatiales des générateurs, Hatziargyriou et al. [18] préconise l'adoption de **généralisations distribuées**. Généralement, ce sont des systèmes de production de faible ou moyenne puissance connectés aux réseaux de moyenne et basses tensions. Contrairement aux productions centralisées, les générateurs d'énergie intermittente sont dispersés dans l'espace, mais non regroupés sur

un seul site. Les analyses d’Alanne et Saari [19] mettent en avant les gains en flexibilité et en fiabilité du réseau en présence de ces générations distribuées d’origine renouvelable et intermittente.

Par contre, pour le cas de réseau déjà existant, les connexions des générations distribuées présentent des problèmes, les fluctuations des énergies renouvelables intermittentes génèrent des noeuds ou des lignes à risque dans le réseau. Néanmoins, des solutions existent, à l’exemple de Konishi et Takahashi [20] qui proposent des stratégies pour l’allocation optimale des générateurs PV.

Selon Hatziargyriou [21], le microréseau est une forme particulière de génération distribuée, en plus de sa propre source de production, il dispose d’une charge et de son système de stockage intégré. En d’autres termes, le microréseau consiste à créer localement une production adaptée aux besoins du client et fournir une production pour le réseau principal. Et d’après Mei et al. [22], le microréseau devrait disposer d’un mode de gestion propre indépendant de la gestion centralisée du réseau. La configuration inclut ainsi un contrôle local (fig. 1.5) du système (non centralisé au niveau du gestionnaire du réseau). Pour une




FIGURE 1.5 – Structure d’un microréseau

plus grande intégration d’énergie intermittente, la solution proposée par Hatziargyriou et al. [23] est d’avoir le réseau principal comme étant l’agrégation de plusieurs microréseaux. Et cette agrégation de microréseaux figure parmi les recommandations de l’IRENA [14] afin de réduire la congestion du réseau et améliorer la gestion de la consommation. Par contre, pour les microréseaux agrégés, il est nécessaire de déployer des infrastructures d’instrumentations et de protocoles de communication innovants [24].




FIGURE 1.6 – Exemple de Power-to-X pour le stockage d’EnR et la capture de carbone proposé par Buffo et al. [25]

— À ces solutions s’ajoutent l’utilisation de stockage par convention ou **Power-to-X**. D’après les travaux de Buffo et al. [25], la grande majorité des dispositifs de stockage d’énergie ont été développés pour des besoins à court et moyen terme (maximum 1 mois), le besoin de stockage à long terme et de grande dimension a donné naissance à ce nouveau concept. L’idée principale du Power-to-X est de stocker l’électricité sous forme d’énergie chimique. Le Power-to-X génère principalement de l’hydrogène (H_2), mais peut également co-générer d’autres gaz tels que le dioxyde de carbone (CO_2) et l’oxygène (O_2).

L’objectif du Power-to-X est de générer des gaz de synthèses (*Syngas*) qui seront utilisables comme combustible ultérieurement.

La figure 1.6 montre le principe général du processus de fabrications des gaz pour le Power-to-X. Premièrement, l’énergie est transformée en gaz par électrolyse de l’eau (H_2O), ce qui génère de l’hydrogène (H_2) et de l’oxygène (O_2). En combinant ces gaz avec la capture de carbone (CO, CO_2), d’autres gaz de synthèse comme le méthane ou le méthanol peuvent être produits. Les principaux concepts du Power-to-X passent par les transformations suivantes :

- Énergie en hydrogène (*PtH₂*)
- Énergie en gaz (*PtG*)
- Énergie en carburant liquide (*PtL*)
- Énergie en produits chimiques (*PtC*)

Pour l’utilisation du Power-to-X, l’IRENA [26] propose un schéma simplifié qui est présenté sur la figure 1.7. Le Power-to-X peut être appliqué dans tous les domaines nécessitant de l’énergie, à savoir, le transport, l’industrie, le bâtiment ou l’électricité en soi.

Les solutions proposées par l’IRENA constituent un ensemble de solutions idéales. Mais dans la pratique, seules certaines combinaisons de solutions sont considérées et elles dépendent du

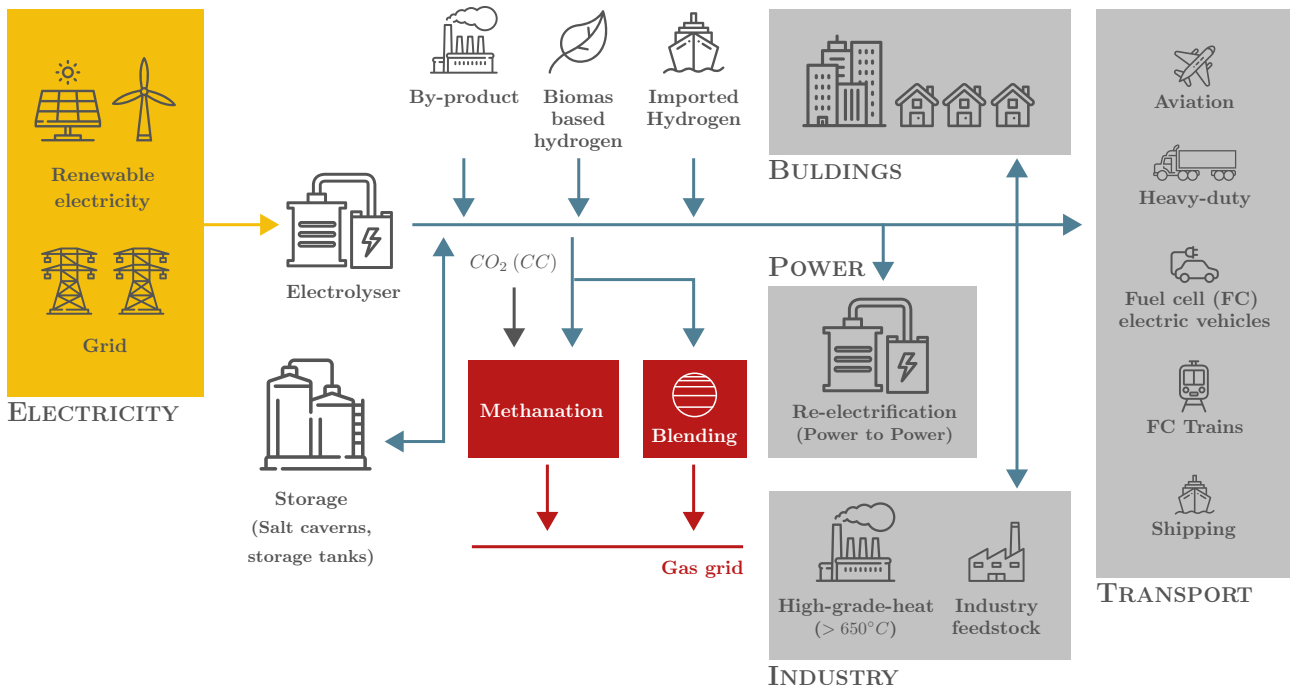


FIGURE 1.7 – Intégration des EnR intermittents dans les usages finaux grâce au Power-to-X (hydrogène) proposée par l’IRENA [26]

niveau du système où est géré l’équilibre production-demande. Les solutions peuvent être abordées soit du point de vue des dispositifs à installer, soit des stratégies d’intégration et bien entendu, l’installation et le dimensionnement des équipements sont aussi le résultat des stratégies adoptées.

Pour mettre en oeuvre cette flexibilité, autant au niveau du réseau de transport que de distribution, deux piliers fondamentaux ont été identifiés : des informations précises sur les disponibilités et besoins en énergie (la prévision) et des capacités à accumuler ou à déplacer de l’énergie (système de stockage).

1.2.1 Dispositifs de compensations avec stockage d’énergie

Dans l’idée d’une intégration massive des énergies renouvelables intermittentes, Anees [27] et Castillo et Gayme [28] montrent clairement que les dispositifs de stockages sont les principaux éléments de compensations utilisés dans le réseau. Les systèmes de stockages sont des dispositifs permettant de conserver l’énergie électrique pour une utilisation ultérieure. La conservation de l’énergie peut se faire sous différentes formes : chimique (batterie électrochimique, supercondensateur), mécanique (volant d’inertie), potentielle gravitationnelle (station de transfert d’énergie par pompage), d’air comprimé (stockage à air comprimé) ou de gaz (pile à combustible type hydrogène) et autres. Une classification selon la forme de stockage de l’énergie est présentée sur la figure 1.8.

Selon les auteurs, les caractéristiques des stockages sont diverses et variées, elles dépendent de la technologie, de la nature (stockage chimique, stockage mécanique, etc) ou même des concepteurs. Plus généralement, la littérature est assez étendue concernant le stockage dans le réseau. À titre d’exemple, les travaux de Dunn et al. [30] ou Gür [31], sont des références sur les




FIGURE 1.8 – Classification des systèmes de stockage d'énergie électrique selon la forme d'énergie par le Fraunhofer ISE (Institute for Solar Energy Systems) [29]

propriétés et/ou les utilisations du stockage dans le réseau de transport. Et à la suite des travaux de Frost et Sullivan [32], Ibrahim et al. [33], puis Luo et al. [34] ont lié les caractéristiques en fonction des dimensions, des densités d'énergie ainsi que de la durée de vie des systèmes de stockage. Néanmoins, en se basant sur les travaux de Castillo et Gayme [28], pour les stockages fonctionnant à l'échelle du réseau de transport, les principaux indicateurs de caractérisation sont au nombre de 9 :

- La capacité utilisable (kWh) : La quantité d'énergie qui peut être délivrée par le stockage selon les caractéristiques établies par le constructeur. Elle est souvent associée au ratio de capacité utilisable et de capacité installée.
- Densité d'énergie (Wh/L ou Wh/kg) : Énergie nominale par unité de volume ou de masse, parfois appelée densité d'énergie volumétrique ou massique.
- Densité de puissance (W/L ou W/kg) : Énergie maximale disponible par unité de volume ou de masse.
- Durée de charge/décharge : Temps nécessaire pour une charge (ou décharge) complète.
- Puissance de sortie (MW) : Puissance de décharge en fonctionnement nominal.
- Temps de réponse : Temps nécessaire à un système de stockage pour atteindre la puissance nominale après une période de veille.
- Durée de vie (années/cycles) : Nombre de cycles ou d'années de fonctionnement nominal du stockage.
- Rendement (%) : Ratio entre l'énergie de décharge et de charge intégrant les pertes.
- Coût ($Euro/kW$ ou $Euro/kWh$) : Coûts d'investissement initiaux du stockage par unité de puissance de décharge ou par unité de capacité de stockage d'énergie.

Dans un réseau électrique, le stockage peut être utilisé de 2 manières, soit pour le déplacement temporel de la production, soit comme une **réserve** de puissance.

Dans le cas où l'énergie produite est supérieure aux besoins et qu'elle n'est pas absorbée par la demande, il est possible de stocker cette énergie pour une utilisation ultérieure. Cet usage est appelé déplacement d'énergie. Pour le cas de l'éolien, Díaz-González et al. [35] présentent les différentes technologies et modes d'utilisation des stockages. Le déplacement d'énergie est aussi appelé par Ibrahim et al. [33] transfert d'énergie. Le transfert d'énergie consiste à stocker de l'énergie à faible coût qui sera ensuite utilisée à un moment approprié, par exemple pour remplacer un achat d'énergie coûteuse pendant les périodes de forts besoins. Lund et al. [36] présentent les apports de l'utilisation de systèmes de stockage dans le cas du déplacement d'énergie. L'utilisation du stockage dans ce cas permet le suivi de la consommation (stockage de l'énergie pendant les périodes de faible demande et utilisation en forte demande), le fonctionnement des centrales de productions à des rendements plus élevés (*load leveling*), la limitation de l'écrêtage de la surproduction et une meilleure planification de l'utilisation des systèmes de générations. La planification permet d'avoir un échange optimal avec le réseau en fonction de la demande et des règles régissant le marché de l'énergie. Un exemple d'étude de l'utilisation du stockage en ordonnancement a été réalisé par Korpaas et al. [37] dans le cas de l'injection d'énergie éolienne dans le réseau électrique en fonction du marché de l'énergie. À l'échelle du réseau, pour Barnes et Levine [38], ce sont surtout les stockages à air comprimé (CAES) et les stations de transfert d'énergie par pompage (PHS) qui sont jugés pertinents. En effet, ils permettent de déplacer une quantité importante d'énergie de quelques minutes à plusieurs jours.

En raison de la fluctuation des systèmes de production dits variables, telles que les EnR intermittentes et des fluctuations de la demande, le gestionnaire de réseau a besoin de marges de manoeuvre pour assurer l'équilibre production-demande. Ces marges correspondent à la zone de contrôle et dans ce cas précis le stockage sert de réserve de puissance. Les réserves sont généralement des systèmes sûrs et coûteux. Pour les réseaux avec génération centralisés, le stockage est nécessaire pour compenser les fluctuations de la demande ou en cas de pannes d'équipements. À mesure que les systèmes d'alimentation en courant alternatif évoluent, des nouvelles configurations des réseaux apparaissent. Dans le cas de réseaux intégrant de la génération (conventionnelle) distribuée, Srivastava et al. [39] ont montré que l'utilisation de stockages permet de maintenir la fréquence du réseau. De même, dans les réseaux dominés par une régulation assurée par de l'électronique de puissance tels que les onduleurs de centrales PV, d'après Kroppski et al. [40], le stockage permet d'avoir un réseau stable avec 100% d'énergies renouvelables (majoritairement intermittentes).

En outre, d'autres dispositifs intégrant le stockage existent, comme les générateurs intermittents flexibles ou contrôlables. Par exemple, un générateur intermittent (solaire ou éolien) peut être couplé avec un système de stockage (ou *Buffer*). Ce stockage est de type batterie dans le cas d'étude de Wang et al. [41], ou de type capacité pour celui de Morjaria et al. [42]. Le stockage emmagasine assez d'énergie pour s'adapter aux fluctuations et générer une puissance de sortie suivant une rampe de variation prédéfinie par le gestionnaire du réseau. Cette technique permet d'obtenir une puissance moins fluctuante et plus lisse comme le préconise l'analyse de Bai et al. [43]. La stratégie d'utilisation de ce type de dispositif est détaillée par Alam et al. [44] et des versions plus performantes incluant la prévision comme outil de contrôle sont proposées par Huotari et al. [45] ou Gong et al. [46]. Par contre, comme Marcos et al. [47] le présente, l'objectif est de garder la taille de stockage aussi petite que possible. L'énergie stockée assurera l'équilibre de l'offre et de la demande, mais seulement à très court terme. Étant donné que la taille du stockage est petite, en cas de congestion au niveau du réseau de transport, l'excès d'énergie qui ne peut pas être stocké par le stockage est perdu.

La classification de ce qui relève du transfert d'énergie ou de la réserve de puissance dépend des auteurs. La classification des systèmes de stockage d'énergie considérée dans ce travail se rapporte à celle utilisée par Milligan et al. [48] et qui reprend les définitions proposées par le NERC (North American Reliability Corporation). La figure 1.9 résume les principaux choix technologiques en fonction du niveau de puissance, d'énergie et des besoins du réseau [48, 34]. Les différentes technologies de stockage sont classées en fonction du temps de réaction et de la nature des événements considérés. Ce temps de réaction peut être très rapide (microsecondes) ou lent (de l'ordre de l'heure). Quant à la nature de l'événement, on en distingue 3 types :

- Événement d'urgence : Ce sont des perturbations majeures, imprévues et inconnues, comme l'augmentation brusque de la demande d'énergie au-delà de la plage de régulation de la fréquence.
- Événement aléatoire : Phénomènes courants comme la variation de la consommation ou de la production dans une plage fixée.
- Événement à plus longue échéance : Dans le cas de panne d'un système ou pour équilibrer la variation de puissance pendant de longues périodes, par exemple lors de journées nuageuses.

Enfin, il est à noter que, le stockage a de nombreuses utilisations dans la gestion des réseaux, et selon les services utilisés, la taille et le temps de réponse varient. Dans la littérature, le stockage en lui-même n'est pas une solution pour intégrer les énergies renouvelables intermittentes. Par exemple, Tapaches et al. [13] montre que sans gestion optimale avec prévision, la capacité nécessaire de stockage est beaucoup plus grande, ce qui entraîne un coût de production énergétique plus élevé. Ainsi, comme le suggèrent les travaux de Castillo et Gayme [28], le stockage doit être associé à la gestion de la réponse à la demande, à la sobriété énergétique ou à l'utilisation de prévisions de production avancées. De même, les solutions pour réduire l'intermittence proposées par Faunce et al. [49], utilisent le stockage avec des prévisions. Par exemple, en couplant la prévision de la demande à différentes échelles de temps (jour, heures) avec le stockage, on peut réduire sensiblement le coût de l'énergie.

1.2.2 Dispositifs de compensations sans stockage

Outre le stockage, d'autres dispositifs permettent d'assurer l'équilibre production-consommation du réseau électrique. Le premier dispositif est un générateur renouvelable intermittent avec des sorties de puissance fixes ou flexibles, le second consiste au déplacement de charge et le dernier dispositif met en oeuvre des appareils consommateurs intelligents.

- **Générateur surdimensionné et écrêtage** : Les PV est aujourd'hui le système de génération d'énergies parmi les moins coûteux. La puissance de sortie des systèmes PV étant très variables, la stratégie consiste à surdimensionner l'installation. D'une part, en cas de périodes de faible production (passage de nuages, hiver), la puissance de sortie du PV est au moins égale à une valeur fixée au préalable. D'autre part, la puissance de sortie est limitée à un seuil au-delà duquel un écrêtage est effectué. C'est-à-dire que la puissance au-dessus du seuil est perdue. L'écrêtage de puissance est utilisé pour avoir un profil de production plus stable, ce qui réduit grandement l'intermittence, donc le besoin en stockage. Des exemples d'utilisation de ces générateurs ont été présentés et analysés par Bird et al. [50] et Perez et al. [51, 52].




FIGURE 1.9 – Domaine d’application des systèmes de stockage selon l’énergie stockée, la puissance fournie ainsi que de la durée d’utilisation (indiquée en bleu) (Luo et al. [34], Milligan et al. [48])

Cependant, le surdimensionnement d’un système de production est une solution fonctionnelle, mais ne fonctionne qu’à l’échelle globale. Il présente l’avantage de la nécessité d’une capacité de stockage plus faible pour assurer l’équilibre production-consommation. D’un point de vue économique, ce système est très intéressant, car il permet d’avoir un coût d’investissement plus faible et donc un coût de production d’énergie plus faible. Par contre, à cause de l’écrêtage, une partie de l’énergie est perdue et ne peut être récupérée que dans certains cas. De plus, l’écrêtage ne peut résoudre que les fluctuations de puissance à la hausse. Les fluctuations vers le bas restent donc un problème pour l’opérateur du réseau.

- **Déplacements de charge** (Load shifting) : Les profils de consommation sont adaptés en fonction de la production d’énergie. Le déplacement de charge consiste à connecter et

déconnecter des charges en fonction de la disponibilité de l'énergie ou des fluctuations du prix de l'énergie. Cette stratégie est améliorée dans le cas de son utilisation avec des dispositifs de stockages comme présenté par Bao et al. [53].

- **Charge intelligente** : Ce sont des appareils consommateurs capables de s'adapter aux fluctuations de la production intermittente sans avoir besoin d'informations ou de données pour le contrôle du système. Ces appareils sont en général des **Charges non critiques** (machine à laver, réfrigérateurs, machine asynchrone). Les Charges non critiques peuvent être couplées à des ressorts électriques (**Electric spring**). Kanjiya et Khadkikar [54] ont analysé leurs utilisations. Ces ressorts électriques sont des compensateurs de tension, de puissance **Réactive** et aussi des correcteurs de facteur de puissance. Les études menées par Lee et Hui [55] concluent qu'à l'échelle du réseau de distribution, les ressorts électriques permettent de réduire les besoins en stockages, car la puissance régulée par les ressorts électriques est constante et peut suivre le profil variable de la production d'électricité intermittente.

Par contre, actuellement, les charges intelligentes ne concernent que le niveau industriel ou le réseau de distribution. Or, les principales charges qui sont à l'origine de la variabilité des charges restent à usage domestique (électroménager, éclairage).

1.2.3 Utilisation de la prévision dans les réseaux d'énergie

Les EnR intermittentes ne pouvant être contrôlées, les prévisions sont nécessaires pour une meilleure gestion énergétique du réseau. Les prévisions sont aujourd'hui principalement utilisées dans deux domaines, le processus de répartition des sources de production au plus bas coût (Unit Commitment (**UC**)) et le marché de l'électricité.

L'UC est une opération très importante dans la gestion du réseau. L'UC concerne toutes les configurations de réseau, à savoir les réseaux de transport, comme présenté par AbuJarad et al. [56] ou les microréseaux, à l'exemple des travaux de Hawkes et Leach [57]. L'UC consiste à planifier de manière optimale à chaque pas de temps une combinaison des ressources disponibles (stockages, groupes thermiques, éolien, solaire, etc) dans le réseau pour avoir le coût de fonctionnement le plus faible. Dans la revue de littérature de Padhy [58], en dehors des processus de démarrage et d'arrêt des systèmes de production, lorsque l'UC porte aussi sur le contrôle des stockages, elle est confondue à la gestion de système énergétique (**EMS (Energy Managment System)**).

La prévision peut être utilisée avec ou sans stockage :

- **Prévisions sans stockage** : Dans ce travail, la prévision sans stockage fait référence au fait que le stockage n'est pas directement géré à partir de la prévision.
 - Pour le marché de l'électricité, la prévision peut affecter le prix de l'énergie ou le gain du producteur. Il est important de noter que les effets de la prévision sont étroitement liés aux réglementations qui régissent le marché. Les travaux de Klessmann et al. [59] montrent qu'il y a une grande différence entre les risques et gains des producteurs d'EnR intermittentes selon les règles du marché. Par exemple, pour le Royaume-Uni, les producteurs doivent payer des pénalités conséquentes en cas de non-respect de leur engagement. Alors que pour le cas Espagnol, les producteurs paient des pénalités relativement faibles pour les écarts par rapport à leur planning.

Pour le Danemark, il a été montré par Jónsson et al. [60] que les prévisions éoliennes ont un impact significatif sur le prix spot de l'électricité pour la journée à venir. En effet, les prévisions de puissance éoliennes ont un effet de seuil sur le comportement des prix et aident à comprendre une certaine non-linéarité et le changement de régime du comportement du prix.

Du côté de la production, les coûts dépendent des réglementations du marché. En Amérique du Nord, l'étude de Luoma et al. [61] portant sur 63 systèmes PV situés en Californie a montré que même des prévisions biaisées ont une valeur marchande élevée. Ce n'est pas le cas pour l'Espagne. D'après Antonanzas et al. [62] une prévision PV plus précise représente un gain plus important. En revanche, ces deux études s'accordent pour dire que dans le cas où les réglementations du marché prévoient des pénalités pour les engagements de production non respectés, les erreurs de prévision entraînent un coût plus élevé (pertes) pour le producteur d'énergie. Un autre aspect du marché concerne les transactions boursières. Zug [63] montrent que l'utilisation de prévisions probabilistes permet d'augmenter le gain pour le producteur.

- Pour l'UC, les prévisions sont principalement utilisées pour la planification des ressources pour le lendemain (à $j+1$). Dans ce cas, des stockages peuvent être présents sur le réseau, mais ces stockages ne sont pas directement pilotés en utilisant des prévisions de productions d'EnR intermittentes. La production d'EnR intermittente est considérée comme équivalente à d'autres sources d'énergie telles que les centrales thermiques dans un problème d'optimisation combinatoire. Par exemple, pour l'UC du réseau de Tokyo, les travaux d'Udagawa et al. [64] indiquent que l'utilisation des prévisions à $j+1$ permet de réduire le taux d'énergie non utilisé ainsi que le taux d'écrêtage de la production PV. En outre, les travaux de Brancucci Martinez-Anido et al. [65] pour le cas de l'*Independent System Operator-New England*, suggèrent qu'avec des prévisions plus précises, une réduction de l'utilisation des autres sources d'énergie (groupes thermiques notamment) est obtenue.

Enfin, pour évaluer l'impact des prévisions d'EnR intermittente sur les coûts de fonctionnement de système, Lowery et O'Malley [66] ont utilisé une production éolienne comme générateur supplémentaire dans un système. L'UC a été résolu par optimisation stochastique avec la génération de scénarios. Lowery et O'Malley [66] ont mis en évidence que le coût de fonctionnement du système est lié à la variance de l'erreur de prévision de la puissance éolienne. Ainsi, le plus bas coût de production du mix énergétique est obtenu lorsque la variance de l'erreur de prévision est minimale.

- **Prévisions avec stockage** : Quelle que soit la taille du stockage ou bien sa durée de vie, le système doit être économiquement viable. La disponibilité et les fluctuations de la ressource sont modélisées avec des prévisions qui permettent d'approximer plus ou moins bien la valeur de la génération future. Comme le montre les études d'Ekman et Jensen [67] ou d'Hedegaard et Meibom [68], les prévisions ne peuvent être parfaites et des systèmes de stockage sont utilisés pour compenser les erreurs de prévision. Dans cette optique, le stockage est contrôlé de manière optimale à partir de la prévision, à l'exemple des travaux de McPherson et Tahseen [69]. Ce type d'approche peut être appliqué aux microréseaux comme le propose Hatzigiorgiou [21] ou bien dans le cas de génération flexible comme illustrée par l'étude de Haessig et al. [70] sur la génération d'énergie éolienne. Ces derniers ont montré que la taille optimale du stockage peut être liée aux autocorrélations des

erreurs de prévisions à $j+1$. En l’associant au stockage, la prévision peut être utilisée directement sur le contrôle des transferts d’énergie entre le stockage et le réseau et/ou pour déterminer les niveaux de réserve nécessaires.

- En ce qui concerne l’EMS des systèmes de stockages pour l’UC, l’intégration directe de la prévision dans la gestion du stockage n’est pas traitée par beaucoup d’auteurs. Par exemple, dans le cas du contrôle optimal d’un stockage pour l’intégration du PV dans le réseau électrique, Riffonneau et al. [71] utilisent une prévision solaire synthétique et non réaliste avec une programmation dynamique (DP). Dans le même esprit, Yang et al. [72] ont testé 5 modèles de prévision solaire de l’état de l’art (persistance, ENN, WNN, ARMA) avec une programmation linéaire.
- De la même manière, pour le contrôle du niveau de réserve comme le cas de Matos et Bessa [73], la prévision éolienne est utilisée pour le contrôle du stockage. Il est important de noter que plus l’incertitude quant à la production future est élevée, plus le besoin de réserve est important.

Les principales options selon l’utilisateur sont présentées sur la figure 1.10.

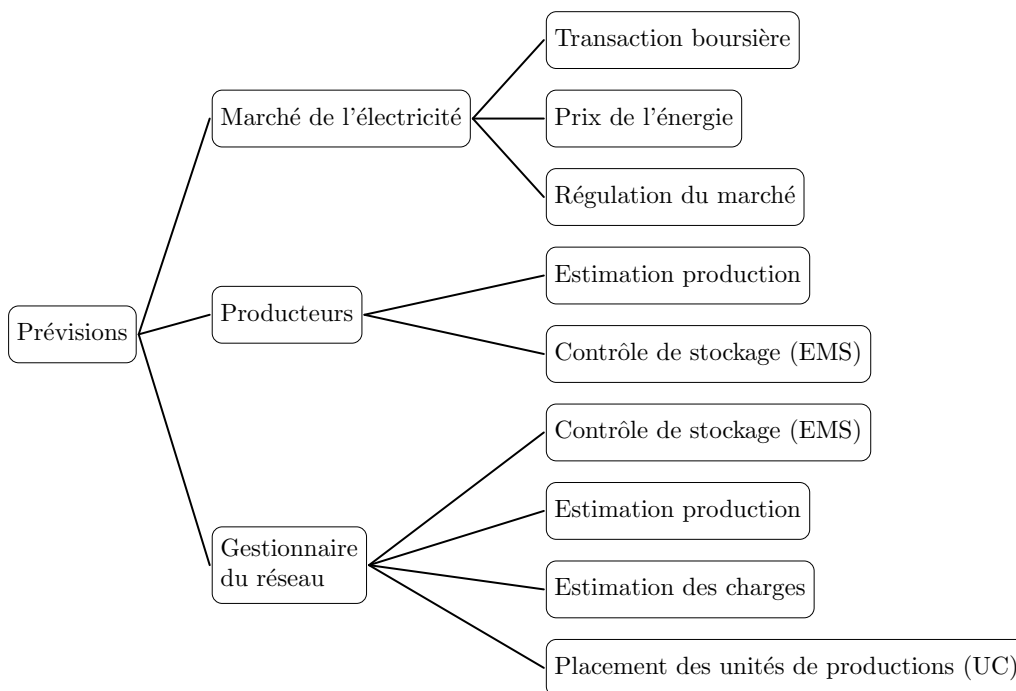


FIGURE 1.10 – Utilisation des prévisions dans les réseaux d’énergie selon l’acteur

Pour atteindre 100% d’EnR, selon Blakers et al. [74], la prévision est une clé majeure dans la gestion des réseaux et la stabilité du marché de l’électricité. En raison de la grande variabilité de la production, la disponibilité des données prévisionnelles permet d’anticiper les actions à entreprendre pour assurer l’approvisionnement. Les prévisions sont largement utilisées dans le domaine de la gestion d’énergie, que ce soit au niveau de l’offre et de la demande ou bien de la régulation, des prix sur le marché. Elle peut être utilisée avec ou sans système de stockage.

TABLE 1.1 – Stratégies d’intégration des EnR intermittentes avec avantage et inconvénients

<i>Dispositifs</i>	<i>Conséquences / Effets</i>	<i>Inconvénients</i>
Producteur		
Surdimensionnement + écrêtage	<ul style="list-style-type: none"> - Puissance de sortie plafonnée - Réduction de la variabilité 	Énergie au-dessus du seuil gaspillée
Production flexible : Générateur + Stockage	<ul style="list-style-type: none"> - Rampe de puissance limitée - Réduction de la plage de variation - Production garantie - Possibilité de transfert d’énergie 	<ul style="list-style-type: none"> - Perte d’énergie en cas de congestion du réseau (cas du buffer) - Besoin de prévisions fiables pour le contrôle (transfert d’énergie)
Intermédiaire : Producteur ou Réseau		
Charge intelligente / Charge adaptative	<ul style="list-style-type: none"> - Puissance variable - Charge suit la production 	Limitées à certains équipements spécifiques
Microréseau	<ul style="list-style-type: none"> - Consommation plus faible pour le réseau principal - Meilleure visibilité des besoins du microréseau pour le gestionnaire principal du réseau - Services auxiliaires pour le réseau - Mêmes avantages que la production flexible - Réduction dépendance au réseau 	<ul style="list-style-type: none"> - Besoin de prévisions fiables - Besoins de nouvelles stratégies de contrôles
Réseau		
Dispersion et foisonnement (PV)	<ul style="list-style-type: none"> - Réduction de la variabilité - Puissance de sortie plus lisse - Puissance de sortie plus facile à prédire 	Dimensionnement et emplacement des générateurs EnR intermittents doivent être développés sur le territoire selon un plan de dispersion préétabli
Supergrid	<ul style="list-style-type: none"> - Déplacement d’énergie sur de grandes distances - Élimine la congestion - Déroutage de surproduction 	<ul style="list-style-type: none"> - Reconfiguration du réseau (ligne de transports et communications) - Fragile : Besoin de système centralisé : production / contrôle

1.3 Prédiction de production d’EnR intermittentes

En principe, l’équilibre entre consommation et production au moindre coût étant l’objectif principal de l’UC, la gestion des systèmes énergétiques est conditionnée par la disponibilité des ressources. Il est donc essentiel d’avoir la meilleure estimation possible de la ressource et de la consommation.

En outre, les énergies EnR intermittentes dépendent des aléas climatiques, ce qui est également le cas pour certains besoins énergétiques (climatisation, chauffage). Ainsi, selon la localisation géographique, pour les systèmes avec autoconsommation (microréseau), les travaux de Srinivasan et Gundam [75] ou de De Jong et al. [76] montrent qu’il existe une corrélation entre la production d’EnR intermittente et la consommation du système. De plus, pour un système combiné PV-éolien, les travaux de Li et al. [77] montrent qu’il existe une complémentarité entre la production d’EnR intermittente et la consommation du système.

Selon l’analyse d’Aburiyana et El-Hawary [78], de nombreuses techniques similaires ou presque identiques sont utilisées pour prévoir les productions solaires, éoliennes et pour prévoir les consommations. De plus, la revue de littérature d’Hong et al. [79] renforce cette conclusion selon laquelle des techniques de prévision similaires sont appliquées aux EnR ou à la consommation et étend également leur utilisation pour la prévision des prix de l’électricité.

Si le solaire et l’éolien ont tendance à être les énergies renouvelables actuellement privilégiées, le rapport de l’IRENA et CPI [3] montre que le solaire photovoltaïque domine le paysage financier des dernières années (2013-2018), avec 46% des investissements mondiaux dans le renouvelable alors que l’éolien ne représente que 29% de ces investissements. Par contre, les analyses d’Hong et al. [80] établies dans le cadre du [GEFCom \(Global Energy Forecasting Competition\)](#) montrent que par rapport à d’autres domaines de la prévision énergétique, la prévision solaire est la moins mature. De même, en termes de proportion de publications, la figure 1.11 montre que la quantité de publications concernant la prévision éolienne dépasse largement celle de la prévision solaire. Néanmoins, même si les prévisions utilisées dans ce travail se focaliseront sur le rayonnement solaire, de nombreux résultats issus du domaine de l’éolien seront pris en compte.




FIGURE 1.11 – Nombre de publications par an sur les prévisions (charge, prix, énergie solaire et énergie éolienne) selon Hong et al. [79]

1.3.1 Techniques de prévision des ressources EnR intermittentes

Lorsqu'on aborde le concept de prévision, il est important de définir les deux résolutions à considérer : la résolution temporelle et la résolution spatiale. La résolution temporelle représente l'horizon et la granularité des prévisions. Elle définit jusqu'où dans le futur l'estimation doit être faite et avec quel pas de temps (minutes, heures, jours, mois, etc.). La résolution spatiale, quant à elle, spécifie la taille et la discrétisation de la zone d'intérêt. En effet, une zone géographique est généralement subdivisée grâce à un maillage et les données sont jointes à chaque élément du maillage. La taille de la zone d'étude peut varier d'un point à une région entière, voire à la totalité de la planète.

Dans le domaine solaire, 3 grandes catégories de méthodes de prévision existent : les méthodes génériques, les méthodes spécifiques pour les EnR intermittentes et les méthodes spécifiques pour la prévision solaire PV.

1. **Méthodes de prévision génériques** : En ingénierie, l'utilisation de ces méthodes de prévision a été fortement influencée par les travaux de Ljung [81] sur l'identification des systèmes. Ses travaux présentent un large spectre d'outils, notamment des séries temporelles, des données du domaine fréquentiel, des interprétations du domaine fréquentiel et des techniques d'estimation récursives (adaptatives). Ces méthodes sont applicables pour la prévision de la production solaire et éolienne, de la demande ou du prix de l'électricité. Concernant le domaine du solaire, l'analyse de Hong et al. [79] indique que les plus utilisées sont les méthodes statistiques et les *machines learning*.

- **Méthodes statistiques** : Ce type de prévision est largement utilisé en prévision solaire comme le montrent les revues de littérature de Soman et al. [82], de Diagne et al. [83], de Hong et Fan [84] ou de Aggarwal et al. [85]. L'une des familles les plus populaires de ces méthodes statistiques est celle des séries temporelles, présentées par Chatfield [86] (famille de processus autorégressif, [AR](#), [ARX](#), [ARMA](#), [ARMAX](#), [ARIMA](#), [SARIMA](#), etc).

Par contre, il est important de noter que dans certains cas, il est nécessaire de fournir une prévision combinée, comme l'éolien et le solaire, la charge nette (production et consommation). Le principe est l'agrégation de plusieurs séries temporelles à différents niveaux, cette technique est appelée prévision hiérarchique. Pour ce type de prévision, les travaux de Hyndman et al. [87] sont la référence en la matière.

Enfin, comme ces méthodes sont facilement reproductibles, l'interprétation et l'analyse de ces modèles sont plus abordables par rapport aux méthodes utilisant l'apprentissage automatique (Machine learning).

- **Machine learning** : Avec l'augmentation de la puissance des ordinateurs, l'apprentissage automatique devient une tendance en matière de prévision. Comme l'a montré la revue de littérature de Voyant et al. [88] sur la prévision solaire, il existe un large éventail d'algorithmes de machine learning ([k-NN \(Nearest Neighbor Neural Network\)](#), [SVM \(Support Vector Machine\)](#), [ANN \(Artificial Neural Network\)](#), etc.). Cela est dû à la flexibilité de ces modèles et leur prise en compte des comportements non linéaires. Dans le domaine du solaire, des modèles ont été développés allant du plus simple comme les travaux de Voyant et al. [88] ([k-NN](#)) à un modèle plus complexe comme les travaux de Ghimire et al. [89] ([CNN \(Convolutional Neural Network\)](#)). En général, les modèles de machine learning offrent une amélioration de

la précision par rapport à leurs homologues statistiques présentées ci-avant (séries temporelles ARIMA et autres).

Néanmoins, le choix du modèle de machine learning est une tâche complexe. Tous ces modèles ont de nombreux paramètres de réglage et il est difficile de définir les critères de sélection. De plus, comme l'a souligné Ahmed et al. [90], les méthodes de pré-traitement ont des impacts différents sur les performances de chaque algorithme.

2. Prévision numérique du temps : L'irradiation solaire au sol et le vent sont inhérents à des phénomènes atmosphériques. Comme présenté par Buizza et al. [91], les méthodes de prévision numérique du temps (NWP) reposent sur des simulations approximatives des processus atmosphériques. Comme ces modèles simulent l'état de l'atmosphère, les sorties sont des données climatiques telles que le rayonnement solaire, la vitesse du vent, la pression atmosphérique, l'humidité, etc. Nous pouvons citer à titre d'exemple de NWP les prévisions du centre européen pour les prévisions météorologiques à moyen terme (ECMWF), qui ont été analysées par Buizza [92] et détaillées par Persson et Grazzini [93]. Pour les NWP, il existe 3 grandes familles de couvertures spatiales et les travaux de Saito et al. [94] donnent un aperçu des principales caractéristiques de ces familles :

- Le modèle de prévision local (LFM (Local Forecast Model)) est principalement utilisé pour les alertes, les avis météorologiques et l'aviation. Il donne des prévisions à très court terme et il peut fournir de nouvelles prévisions avec des horizons de 3 à 12 heures toutes les heures. La couverture prévisionnelle fournie est souvent une zone de la taille d'un pays. La maille de résolution spatiale des modèles locaux est souvent inférieure à $5km$ de côté. Des modèles locaux sont développés partout à travers le monde, par exemple AROME (Application of Research to Operations at Mesoscale) qui est celui maintenu par Météo France ou WRF (Weather Research and Forecasting) qui est un modèle ouvert très utilisé par la communauté scientifique.
- La mésoéchelle (MSM (Meso-Scale Model)) ou régionale est une échelle intermédiaire entre un modèle de prévision global (planétaire) et le modèle local. Il est utilisé pour prévoir le temps sur une région de grande dimension (par exemple l'Europe, les États-Unis ou la Chine). La taille de la grille est plus grande que le modèle local, avec des dimensions d'un ordre de grandeur de $10 \times 10km$. L'horizon de prévision est de 0 à plusieurs jours et la prévision a une granularité d'une à trois heures. ALADIN de Météo France, ICON (Icosahedral Nonhydrostatic) du DWD (Deutscher Wetterdienst) Allemand ou GRAPES (Global/Regional Assimilation and PRediction System) du CMA (China Meteorological Administration) sont des exemples de ce type de modèle.
- À l'échelle globale, les NWP couvrent toute la planète. La résolution spatiale est une grille qui varie de $0,125^\circ$ à $0,5^\circ$ de latitude selon le modèle. L'horizon de prévision de ce type de modèle peut aller de quelques heures à plusieurs semaines. Dans ce travail, nous utiliserons les prévisions du modèle maintenu par ECMWF. En effet, c'est un modèle global disposant d'une très haute résolution spatiale de $0,125^\circ$ en latitude (environ $12km$ à La Réunion) et d'une résolution temporelle de 1 heure pour les 90 premières heures de prévision pour sa version déterministe.

Cependant, le principal inconvénient de la prévision météorologique numérique du temps est qu'elle nécessite un coût et des temps de calcul très importants pour la simulation. Actuellement, seules les organisations étatiques (MSC (Meteorological Service of Canada),

NCEP (National Centers for Environmental Prediction)) ou des organisations régionales (ECMWF) peuvent se permettre de construire leurs propres modèles opérationnels.

3. **Techniques spécifiques de prévision de l'énergie solaire** : Comme dans d'autres domaines, les prévisionnistes ont développé des techniques spécifiques pour prévoir l'énergie solaire, comme présentée dans la revue de littérature proposée par Diagne et al. [83]. Par exemple, l'imagerie du ciel, orientée vers la voûte céleste, est une technique de prévision uniquement utilisée dans le domaine du solaire. Sachant que le rayonnement au sommet de l'atmosphère peut être prédit avec précision, la principale source de variabilité est le passage du rayonnement à travers l'épaisseur de l'atmosphère. Pour un ciel clair, l'atmosphère interagit avec la lumière tel un fluide, de sorte que seule une partie du rayonnement atteint le sol (en raison de la réflexion, de l'absorption, de la diffusion et de la réfraction). Néanmoins, le rayonnement solaire reçu au sol par ciel clair est très prévisible et de nombreux modèles présentant des résultats précis ont été développés à cet effet (Atwater [95], Bird[96], Solis [97], McClear, REST2 et autres [98]). La principale source de fluctuation est donc le passage des nuages. L'objectif des techniques d'imagerie est d'évaluer uniquement l'effet des nuages et les prévisions issues de ces méthodes sont basées sur le suivi du mouvement des nuages.

Comme les images brutes ne sont pas directement exploitables, des techniques de prétraitement d'images et de post-traitement statistique sont nécessaires pour la génération des prévisions. Les modalités de ces traitements sont décrites par Hammer et al. [99] pour le cas des images satellitaires et par Chow et al. [100] pour le cas de l'imagerie du ciel.

- **Imagerie satellite** : Comme les images satellites sont à l'échelle régionale, la résolution des images est souvent médiocre (un point pour $1km \times 1km$ [101]) pour un emplacement spécifique. De plus, la résolution temporelle dépend de la capacité du satellite. Cependant, avec les données dérivées d'images satellitaires, l'évaluation du potentiel solaire et de la variabilité peut être effectuée sur une vaste zone.
- **Imagerie du ciel** : L'image du ciel étant générée à un endroit précis, la prévision peut avoir la résolution temporelle très fine (d'1 seconde à 1 heure). Dans ce cas, l'image du ciel est enregistrée à l'aide d'un appareil spécifique (*Total Sky Imager*). Contrairement au satellite, la résolution de l'image est plus élevée, ce qui permet de générer des prédictions plus résolues spatialement. Néanmoins, la surface couverte par cette technique n'est pas très grande (rayon de 2 km environ selon Chow et al. [100]).

Les techniques de prévision énumérées ci-dessus ont été prises individuellement. Dans certains cas, la mise en oeuvre d'une combinaison de ces techniques surpasse la précision de chacune d'elle prise séparément. À titre d'exemple, pour la prévision à très court terme du rayonnement solaire, Wang et al. [102] ont combiné un réseau de neurones artificiels (ANN) avec des méthodes statistiques. Ils ont pu réduire considérablement leur erreur de prévision ($> 50\%$) par rapport à l'utilisation de l'ANN seul.

Diagne et al. [83] ont établi un état de l'art des techniques existantes dans le domaine du solaire selon l'échelle temporelle d'utilisation et l'échelle spatiale. Cet état de l'art définit les limites des modèles les plus utilisés. La figure 1.12 montre les zones opérationnelles des modèles de prévision, c'est-à-dire les limites en termes d'horizons de prévision et de résolutions spatiales.

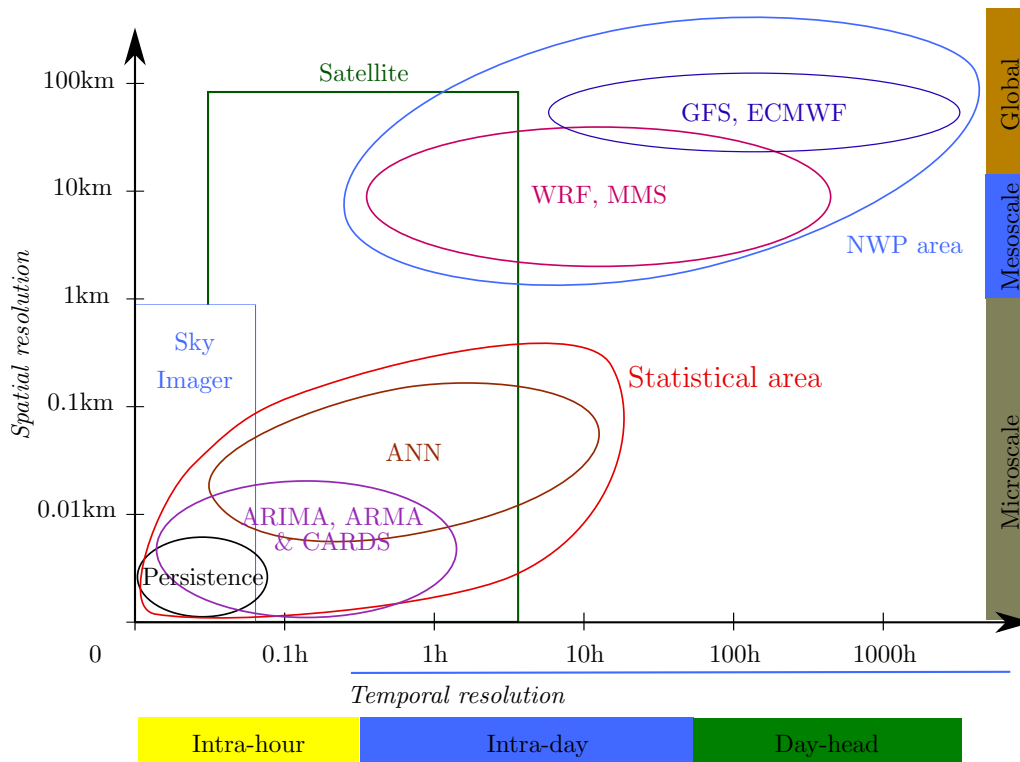


FIGURE 1.12 – Classification des modèles de prévision du rayonnement solaire en fonction de la résolution temporelle et spatiale (Diagne et al. [83])

1.3.2 Prévision déterministe et probabiliste

La prévision la plus couramment utilisée est la prévision déterministe, aussi appelée prévision point. Cette prévision consiste à attribuer une valeur unique à l'estimation de la variable à prédire. Lorsqu'on utilise une prévision point, on suppose que le phénomène à prévoir suit une évolution déterministe. La météorologie, tout comme de nombreux autres domaines, suit un processus chaotique, donc son évolution est intrinsèquement non déterministe.

Comme une prévision ne peut pas être parfaite, elle est donc incertaine. Les prévisions déterministes ne permettent pas d'évaluer les risques ou influences générées par ses propres erreurs. De ce fait, les prévisions probabilistes ont été développées afin de prendre en compte les incertitudes inhérentes à la prévision. La prévision probabiliste n'affecte pas une valeur unique à l'événement futur, mais une distribution de probabilité sous la forme d'une fonction de distribution (PDF) ou d'une fonction de probabilité cumulée (CDF).

Se référant aux travaux de David et Lauret [103], la classification des modèles probabilistes peut se faire en 3 grandes catégories :

- **Prévision d'ensemble** : C'est un ensemble de prévisions déterministes qui représentent les futurs états possibles de l'atmosphère. À titre d'exemple, l'EPS (Ensemble Prediction System)-ECMWF [93] propose un ensemble de 50 membres (états possibles de l'atmosphère). L'EPS-ECMWF est généré en exécutant un modèle numérique du temps 50 fois à partir de conditions initiales différentes. Les différences entre les conditions initiales sont des perturbations générées pour prendre en compte les incertitudes sur les entrées (observations de l'atmosphère), hypothèses et paramètres du modèle de simulation.

- **Modèle paramétrique** : Ce sont des prévisions auxquelles on associe des distributions connues, par exemple Gaussienne, pour évaluer l'incertitude sur l'évènement à prévoir. Par exemple, dans le domaine de la prévision solaire, David et al. [104] ont élaboré un modèle autorégressif à moyenne mobile (ARMAX) pour la génération de la prévision point, combiné avec un modèle à hétéroscédasticité conditionnelle autorégressive généralisée (GARCH) pour l'erreur. Pour ce travail, une distribution Gaussienne a été utilisée. Des démarches similaires ont été adoptées par Trombe et al. [105] pour le cas de la prévision de l'énergie éolienne et par Cifter [106] pour la prévision du prix de l'énergie. Dans ces 2 derniers cas, une chaîne de Markov (MC) couplée à un processus autorégressif (AR) et un modèle GARCH ont été utilisés pour générer la prévision probabiliste.
- **Modèle non paramétrique** : Aucune distribution particulière n'est associée à la prévision et la distribution de probabilités est obtenue de manière discrète pour un ensemble fini de quantiles. Dans le domaine du solaire par exemple, Golestaneh et al. [107] utilisent des prévisions point combinées avec un modèle de régression de type Extreme Learning Machine (ELM). Un autre cas intéressant utilisé pour la prévision solaire est l'agrégation de données de plusieurs mesures au sol avec une régression. Les prévisions déterministes sont générées par un modèle type vecteur autorégressif (VAR) pour tous les sites de mesures. Puis la partie probabiliste est générée par une méthode de régression dite "gradient boosting" Friedman [108].

La majorité des techniques de prévision existante peut être appliquée à l'éolien (WPF), le solaire (SPF), le prix de l'énergie sur le marché (EPF) ou à la prévision de la demande. Pour la prévision de la demande, il y a une différenciation entre le long (LTLF) et le court terme (STLF). Le long terme relève le plus souvent d'extensions ou de modifications des réseaux, alors que le court terme est lié à la planification ou la gestion en temps réels du réseau. Par contre, l'utilisation des prévisions est plus développée dans le domaine de l'éolien que celui du solaire, tel qu'illustré dans la figure 1.13. Les techniques de prévision solaire, que ce soit déterministe ou probabiliste, sont estimées moins matures.

1.3.3 Évaluation des prévisions

Pour évaluer les modèles de prévision, on se réfère souvent à des scores mathématiques. Pour le cas de la prévision déterministe, on utilise des métriques déterminant les erreurs de la prévision point par rapport à l'observation. Les principaux indicateurs utilisés pour la prévision ont été listés par David et al. [109]. Il s'agit de la racine de l'erreur quadratique moyenne (RMSE), l'erreur moyenne du biais (MBE) et l'erreur moyenne absolue (MAE).

Dans le cas de la prévision probabiliste, l'évaluation est un peu plus complexe, car il s'agit de comparer des fonctions de distribution. De plus, il est compliqué de définir une prévision probabiliste parfaite. De ce fait, l'évaluation se fait en combinant des représentations visuelles et des métriques. Pour l'évaluation visuelle de la fiabilité, le premier critère à regarder lors de l'évaluation de prévisions probabilistes, Lauret et al. [110] préconise l'utilisation du diagramme de fiabilité pour les prévisions paramétriques et non paramétriques et l'utilisation d'un histogramme à rang pour les prévisions d'ensemble. D'autre part, ils préconisent l'utilisation du (CRPS (Continuous Ranked Probability Score)) comme métrique, car c'est un score propre, de même unité que la variable à prévoir, définit positivement et correspondant au MAE d'une prévision déterministe. Messner et al. [111] ont repris les mêmes indicateurs que Lauret et al. [110] pour évaluer la qualité de prévisions probabilistes. En complément, ils ont proposé d'ajouter le

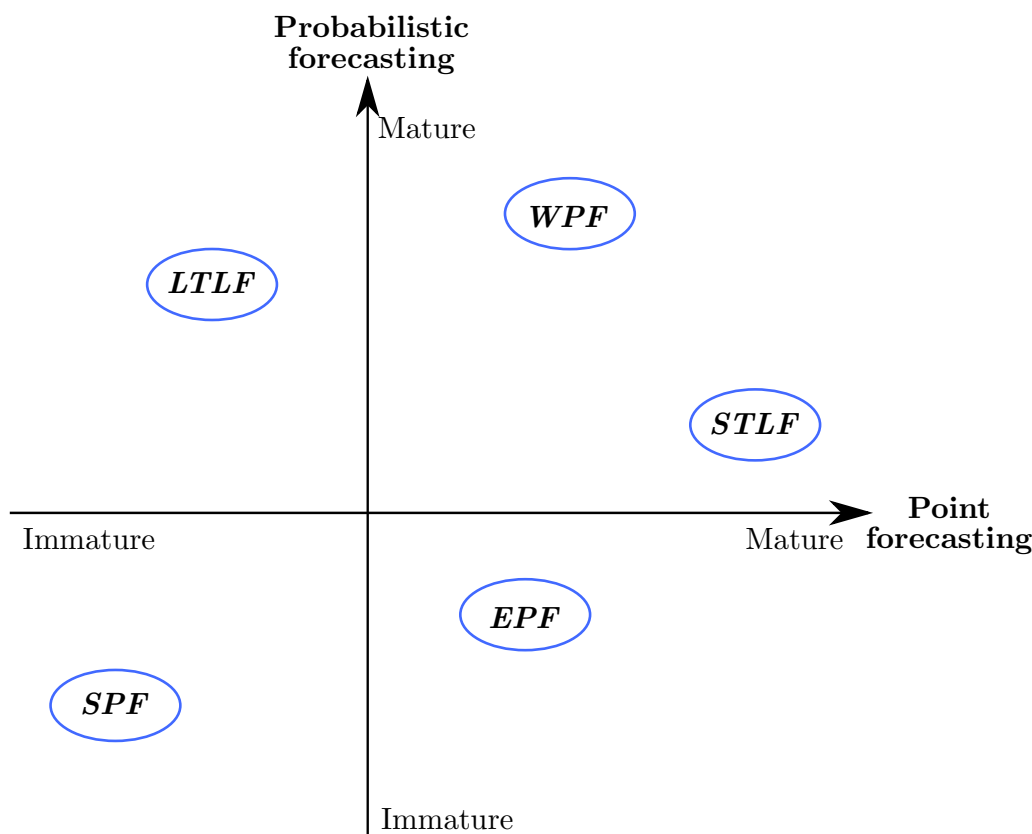


FIGURE 1.13 – Maturité des techniques de prévisions (Hong et al. [80])

score d’ignorance et les scores pour les prévisions probabilistes multivariées. Néanmoins, l’analyse de Hong et al. [80] réalisée pour le concours mondial de prévision énergétique (GEFCom) de 2014 montre que le score [PLF \(Pinball Loss Function\)](#) de Koenker et Basset est aussi très utilisé dans le domaine de la prévision de l’énergie éolienne.

1.3.4 Limites actuelles

Murphy [112] a défini que la prévision doit être analysée sur 3 aspects : la consistance, la qualité et la valeur. Premièrement, la consistance est la correspondance entre le jugement des prévisionnistes et leur prévision. Deuxièmement, la qualité est un indicateur relatif à la déviation entre l’observation et la prévision. Et enfin, la valeur représente l’effet de la prévision à travers son usage. Cependant, selon l’utilisateur des prévisions, ces 3 aspects de la prévision sont souvent considérés séparément et indépendamment. De ce fait, la prévision est évaluée différemment selon les acteurs.

Pour celui qui génère les prévisions, la qualité prime. Les indicateurs considérés par les fournisseurs de prévisions sont principalement des scores numériques tels que le RMSE, le MBE, MAE ou le CRPS qui quantifient l’erreur entre les observations et les prévisions.

Pour l’utilisateur final de la prévision, le plus important est généralement sa valeur. La valeur est souvent associée à des indicateurs techniques ou économiques liés au fonctionnement du système considéré.

D’un autre côté, contrairement à la consistance qui est le jugement d’un prévisionniste,

la qualité et la valeur d'une prévision représentent des valeurs quantifiables. L'existence d'un lien de causalité entre ces deux grandeurs permettrait de mettre en phase le prévisionniste et l'utilisateur. Donc, ce lien pourrait conduire tous les utilisateurs à de meilleurs critères pour choisir les prévisions à utiliser. Par exemple, une bonne prévision devrait conduire à un gain économique accru pour l'utilisateur. Dans la pratique, la relation entre la valeur et la qualité n'est pas simple à établir. Comme le font remarquer Messner et al. [111], une prévision avec un meilleur score n'implique pas forcément un gain supplémentaire pour l'utilisateur. Ils ont notamment proposé qu'il pourrait s'agir d'une combinaison d'indices qui servirait de base pour établir la relation entre la qualité et la valeur. Cette complexité de la relation entre la qualité et la valeur de la prévision pourrait s'expliquer par la nature même de la prévision. D'une part, les prévisions déterministes ne peuvent pas capturer les incertitudes dues aux erreurs qu'elles génèrent. D'autre part, les prévisions probabilistes qui intègrent des incertitudes sont assez récentes. De plus, les prévisions probabilistes sont compliquées à analyser et à interpréter. En conclusion, établir une bonne évaluation des prévisions reste un défi pour le prévisionniste.

Au-delà de l'évaluation, le défi lié à la prévision des EnR intermittente est son utilisation. Dans la gestion des réseaux, on s'attelle aux problèmes de planification du fonctionnement des systèmes de production ou d'allocation des unités (UC). Comme le montre le rapport de Zhou et al. [113] ou la revue de littérature de Abdou et Tkiouat [114], la prévision n'a pas toujours été prise en compte dans la résolution des problèmes d'UC. En effet, la part des EnR dans le mix était faible et l'intermittence de la production d'EnR a longtemps été considérée comme étant une perturbation, modélisée avec des distributions connues. Avec l'augmentation de la part de production des EnR intermittentes ainsi que de la libéralisation des marchés, la prévision est devenue incontournable.

Pour le problème d'UC, il existe 2 approches principales pour l'utilisation de la prévision dans la production d'énergie électrique : d'une part l'utilisation de prévision déterministe pour résoudre le problème d'UC et d'autre part par une optimisation stochastique prenant en compte les incertitudes.

En ce qui concerne les prévisions déterministes, les travaux de Riffonneau et al. [71] ou de Yang et al. [72] sont des références dans l'utilisation des prévisions déterministes pour résoudre des problèmes d'UC. Et comme les prévisions déterministes sont des prévisions ponctuelles (valeur unique), leur utilisation dans les problèmes UC n'est pas trop compliquée à mettre en oeuvre. Ce qui n'est pas le cas des prévisions probabilistes, car les prévisions probabilistes se présentent sous la forme de PDF ou CDF de variables continues et peuvent être corrélées dans le temps et dans l'espace.

Pour prendre en compte l'incertitude dans les problèmes d'UC, l'approche la plus répandue consiste à construire des scénarios et à les utiliser en entrée d'une optimisation stochastique. Dans leurs travaux, Barth et al. [115] ont utilisé un modèle ARMA pour prévoir l'énergie éolienne. Ils utilisent ensuite les erreurs générées par ce modèle ARMA pour construire des scénarios selon la méthode décrite par Ordoudis et al. [116]. Dans le même esprit, Pinson et al. [117] ont proposé une méthode de construction de scénarios à partir de prévisions probabilistes non corrélées. De même, une transformation de la prévision probabiliste en scénario est préconisée par Li et Zhang [118] dans leur revue de littérature sur l'intégration de la prévision solaire probabiliste dans les systèmes électriques. Cependant, les scénarios posent plusieurs problèmes, car ils sont difficiles à construire, à interpréter et parfois sujets à des jugements subjectifs comme l'indique Shapiro et Nemirovski [119].

En résumé, 3 aspects limitent l'utilisation correcte de la prévision : le choix des métriques

d'évaluation, la relation entre la qualité et la valeur des prévisions et l'intégration de la prévision probabiliste sous forme de CDF d'une variable continue dans un processus d'optimisation.

1.4 Un cas d'étude en zone non interconnectée (ZNI)

1.4.1 Enjeux des EnR intermittentes en milieu insulaire

Les travaux de Praene et al. [4], de Ioannidis et Chalvatzis [120] ou de Genave [121] soutiennent la même observation : les îles en général sont dépendantes des énergies fossiles qui sont généralement importées. Le cas de l'île de La Réunion (fig. 1.14), bien que disposant d'une part significative d'EnR dans sa production d'électricité, est un exemple de cette dépendance. Les données de l'Observatoire Énergie Réunion [122] indiquent que la production énergétique est principalement basée sur les hydrocarbures et le charbon. Pour assurer la sécurité énergétique au niveau de l'île, l'utilisation de ressources disponibles in-situ pour la production d'électricité reste la meilleure stratégie. Dans la recherche de cette production d'électricité, à l'exception des îles dotées de ressources en hydrocarbures, la première option est d'augmenter significativement la part de production d'énergie renouvelable disponible localement.




FIGURE 1.14 – Répartition des unités de production d'énergie électrique en puissance en 2019 pour l'île de la Réunion (Observatoire Énergie Réunion [122])

La revue de Kuang et al. [123] sur les énergies renouvelables installées dans les îles a souligné que la biomasse, l'hydroélectricité, l'énergie éolienne et solaire sont les principales sources d'énergie renouvelable utilisée dans les mix de production électriques. Mais, en plus des ressources mentionnées ci-avant, il existe plusieurs autres ressources renouvelables pour la production d'énergie potentiellement intéressante telle que l'énergie géothermique, l'énergie des vagues ou la combustion des déchets. La ressource renouvelable peut être classée selon deux catégories, non-intermittente et intermittente.

L'énergie hydraulique, géothermique, thermique des mers et la bioénergie sont des exemples de ressources non-intermittentes et sont décrites brièvement ci-après :

- La plupart des pays qui ont une capacité hydroélectrique choisissent généralement de l'utiliser comme source principale d'énergie renouvelable. Mais comme la capacité de la ressource est limitée, elle ne peut pas toujours à la totalité des besoins en électricité.

- Même s'il s'agit d'une technologie mature, la géothermie ne peut être utilisée que s'il existe un flux de chaleur exploitable. De plus, la perception de la géothermie par la population est mitigée. Comme le montre l'étude de Carr-Cornish et Romanach [124] sur l'installation de centrales géothermiques en Australie, la majorité des personnes interrogées y est favorable, mais souhaite que la centrale soit le plus loin possible de leur domicile, par crainte d'un éventuel tremblement de terre.
- L'énergie thermique marine est une technologie innovante. Par contre, cette technologie n'est pas encore totalement mature et son utilisation est encore limitée à quelques plateformes expérimentales.
- Les biocarburants, la valorisation directe de la biomasse et la valorisation des déchets sont les principales bioénergies.

Les biocarburants ont pour objectif de supplanter les hydrocarbures. Mais, en raison des énormes besoins pour le transport, des conflits surgissent sur l'utilisation des terres entre la nourriture et les biocarburants.

La valorisation énergétique directe de la biomasse comme le bois de feu ou la bagasse est une génération d'EnR contrôlable. Par contre, la quantité de matière nécessaire n'est généralement pas suffisante pour fournir les besoins énergétiques d'un territoire.

Pour la valorisation des déchets, il existe différents procédés tels que la combustion et la gazéification. En revanche, le besoin initial de tri, pour avoir la qualité et la quantité des déchets convertibles, reste un frein à leur utilisation.

Outre les aspects techniques, comme le montrent les travaux de Li et al. [125], un obstacle majeur pour les EnR non-intermittentes est qu'elles nécessitent un investissement initial élevé.

Les énergies intermittentes pourraient offrir la possibilité d'atteindre l'autonomie énergétique pour les îles. Entourée par la mer, une île a un fort potentiel éolien, ce qui implique que le potentiel énergétique des vagues est également très élevé. Dans une certaine mesure, l'intégration photovoltaïque peut aussi conduire à un mix énergétique fortement ou totalement renouvelable. Par exemple, selon les travaux de Tapaches et al. [13] pour la Réunion, des systèmes PV installés en toiture permettraient d'avoir un mix totalement renouvelable. Même si pour toutes les îles, un des facteurs limitants de l'expansion solaire est la disponibilité des terres. L'analyse de [126] concernant les technologies PV flottantes, en particulier la centrale flottante de 1MW_c de Singapour, montre que le PV flottant offre des performances similaires au PV terrestre. La vitesse d'installation de ce type de système (PV en toiture ou au sol) à grande échelle est relativement rapide. L'utilisation de ces derniers est davantage conditionnée par des facteurs sociaux et politiques que par des contraintes techniques ou de disponibilité. Comme l'a fait remarquer Selosse et al. [127] pour l'île de la Réunion, l'augmentation de la part de la production d'énergie solaire ou houlomotrice dans le mix électrique bénéficie d'un soutien politique plus important que l'éolien terrestre.

À La Réunion, de nombreuses stratégies ont été proposées pour atteindre 100% d'énergies renouvelables dans le mix électrique et il s'agit généralement d'approches hybrides combinant des énergies renouvelables intermittentes et non intermittentes. Par exemple, les travaux de Biscaglia et al. [128] aboutissent à un mix énergétique 100% renouvelables. En revanche, les travaux de Rakotoson [129] proposent une prévalence de la part des énergies intermittentes dans ce mix énergétique.

Cependant, l'analyse de Schmietendorf et al. [130] sur de fortes augmentations de la part des énergies renouvelables intermittentes dans le mix de la production d'énergie indique que cette

forte augmentation génère des risques pour la stabilité du réseau. Étant donné que le réseau électrique d'une île est un système isolé, les fluctuations ont un impact plus important sur la stabilité du réseau que pour les réseaux continentaux interconnectés. En effet, un réseau isolé ne bénéficie pas de l'effet de lissage et du partage des risques des systèmes interconnectés. Par exemple, pour un réseau interconnecté avec 10 générateurs, en cas de panne d'1 générateur, les 9 autres peuvent réguler le système, ce qui n'est pas le cas pour un système avec seulement 1 ou 2 sources d'énergie.

Le constat est que plusieurs systèmes dispersés et interconnectés offrent une plus grande flexibilité qu'un seul système à puissance équivalente. Donc, la meilleure configuration d'un réseau électrique serait un réseau composé d'une agrégation de plusieurs microréseaux.

1.4.2 Enerpos un NetZEB sous les tropiques

[EnerPos](#) est un bâtiment de l'Université de La Réunion disposant d'un suivi instrumenté du confort, des consommations et de la production énergétique. Le bâtiment se trouve sur le site universitaire de Saint-Pierre et il est le premier bâtiment tertiaire à énergie positive des Départements d'Outre-Mer français. Le développement des travaux de thèse s'appuiera sur le bâtiment EnerPos qui servira d'exemple réel de microréseau intégrant une charge et une production renouvelable intermittente.

1.4.2.1 Caractéristiques du bâtiment

Ce bâtiment universitaire dispose de plusieurs salles de cours et de locaux administratifs. Il est composé de 2 ailes distinctes et il est appelé EnerPos (Énergie Positive) car il produit annuellement plus d'énergie qu'il n'en consomme. L'article de Lenoir et al. [131] le décrivant en détail le classe comme étant un bâtiment à consommation énergétique nette nulle (Net Zero Energy Building, [NetZeb](#)). EnerPos est un bâtiment équipé d'une ferme photovoltaïque intégrée en sur-toiture qui permet d'apporter de l'ombrage au bâtiment. Il s'agit d'un système [BiPV](#) (Building Integarted PV) suivant la définition de Benemann et al. [132]. Une stratégie bioclimatique a été adoptée pour sa conception (fig : 1.15). Elle a nécessité la prise en compte des données climatiques du site et les principaux principes appliqués sont : une ventilation naturelle traversante, un éclairage naturel favorisé, des protections solaires, l'isolation des façades exposées et la végétalisation des abords. Cette conception permet d'obtenir un confort hygro-thermique à l'intérieur du bâtiment tout en minimisant la consommation énergétique. La méthodologie et les outils utilisés pour sa conception ont été détaillés par Garde et al. [133].

L'architecture du bâtiment adopte une sur-toiture apportant de l'ombrage à la toiture et aux façades. Dans la conception architecturale, la grande surface et la disposition des ouvertures permettent une ventilation naturelle traversante efficace. Les principales caractéristiques du bâtiment sont présentées dans le tableau 1.2.

Ce bâtiment dispose d'un suivi instrumenté permettant de collecter les données de consommation électrique par secteur et par poste. Les travaux de Lenoir [134] ont catégorisé les différents postes consommateurs par fonction :

- Éclairage intérieur,
- Éclairage extérieur,
- Brasseurs d'air,




FIGURE 1.15 – Méthodologie de conception d’un NetZeb en zone intertropicale

- Ventilo-convecteurs,
- Systèmes de climatisation individuels de type "Split" des locaux techniques,
- Groupe froid à Volume de Réfrigérant Variable (VRV),
- Centrales de Traitement d’Air (CTA),
- Prises de courant,
- Vidéo-projecteurs,
- Ascenseur.

Le niveau de puissance dans un microréseau étant relativement faible, l’étude utilisera une agrégation de tous les postes de consommation. L’acquisition des données est faite par pas de 1 minute. Des enregistrements étant manquants, une reconstruction minutieuse des données a été effectuée sur 2 années consécutives. La deuxième année correspond aux données de référence et la première année est utilisée comme source pour combler les données manquantes. Les données manquantes pour l’année 2 sont donc tirées de l’année 1. Par exemple, les données manquantes de consommations pour un jour particulier (lundi) seront remplies à partir du premier lundi de l’année précédente à la même période de l’année (donc à une date différente, mais à la même heure). Comme pour l’acquisition des données de consommation, les données de production sont collectées au pas de temps de 1 minute. Cependant, la production solaire pouvant être dérivée des données de rayonnement mesurées sur le site, la reconstruction des données manquantes s’est appuyée sur les travaux de Demirhan et Renwick [135] décrivant les méthodes d’interpolation d’irradiation.

Désignation	Valeur
Nombre de bâtiments	2
Nombre de niveaux par bâtiment	2
Surface hors œuvre nette	739m ²
Surface hors œuvre brute	1425m ²
Nombre de salles d’enseignement	7
Surface de bureaux	160m ²
Toiture photovoltaïque	370m ² /49kW

TABLE 1.2 – Caractéristiques du bâtiment EnerPos

Dans cette étude, toutes les analyses et optimisations seront appliquées sur des données agrégées de 1 heure. Ce choix de pas de temps est motivé par le fait qu'un pas de temps inférieur à 1 heure dans un réseau électrique est plus souvent associé à un problème de régulation que d'optimisation de la planification des moyens [48]. Les données de consommations et de productions du bâtiment utilisées dans ce travail ont été déposées sur la plateforme open-source Zenodo et sont accessibles en ligne [136].

La consommation du bâtiment suit la saisonnalité et le calendrier scolaire. Durant la saison sèche de juin à octobre et pendant les vacances de fin d'année, il y a une réduction significative (fig. 1.16) de la charge. De même, la même manière, la production PV suit une saisonnalité. La production est plus importante durant la saison estivale allant de décembre à mars (fig. 1.17).




FIGURE 1.16 – Consommation agrégée du bâtiment EnerPos pour l'année 2010 au pas de temps de la minute

Le champ PV couvre la totalité de la toiture pour apporter un maximum d'ombrage. Son dimensionnement n'est pas corrélé aux besoins du bâtiment. La comparaison des figures 1.16 et 1.17 montre en effet que la puissance appelée par le bâtiment ne dépasse pas les $8kW$, alors que la production PV a des pics pouvant aller jusqu'à $40kW$. En termes d'énergie annuelle, Lenoir [134] montre même que la ferme PV produit cinq fois la consommation du bâtiment.

Afin d'analyser l'équilibre instantané entre la production et la consommation du bâtiment EnerPos, je propose de regarder plus précisément les moments où la charge nette (*consommation - production*) est négative. En d'autres termes, la durée durant laquelle la consommation du bâtiment est supérieure à sa production (fig. 1.18). Les données de nuit se retrouvent à droite de la figure avec une moyenne de 800 min correspondant à la durée moyenne des nuits qui est de $13.3 heures$). Par contre, pour les données de jours (sur la gauche de la figure) un pic de fréquence est observé pour des durées d'environ 10 minutes. Cette courte durée indique, entre autres, que pendant la journée, le système a une production surdimensionnée. En effet, en journée, le réseau ne fournit uniquement que des appels de forte puissance de courte durée.

Pour le système existant, la somme de la production énergétique annuelle du générateur photovoltaïque est d'environ 5 fois la consommation du bâtiment. De plus, comme le montre la figure 1.18, la durée de la majeure partie des appels au réseau en journée n'est que de 10 minutes environ. Ce qui signifie que si un système de gestion est installé, ce contrôle se concentrera davantage sur la compensation de ces courts déséquilibres. À partir de la même




FIGURE 1.17 – Production du champ PV intégré en sur-toiture pour l’année 2010 au pas de temps de la minute




FIGURE 1.18 – Fréquence de la durée consécutive de charge nette négative en minutes

figure 1.18, on peut voir que le besoin de stockage est prédominant de nuit et que le champ PV est largement surdimensionné pour les appels de puissance en journée.

Pour cette étude, afin de s’assurer que les effets de la prévision soient sensibles autant pour les besoins de nuits que de jours, un système avec une taille de générateur PV plus petite que celui présent aujourd’hui sera considéré. De ce fait, les configurations du champ photovoltaïque utilisées auront un rapport production/consommation annuel proche de 1.

1.4.2.2 Configuration du microréseau

Le système actuel est un champ photovoltaïque avec un onduleur connecté au réseau. Le système considéré est directement connecté au bâtiment EnerPos. Le réseau est utilisé comme régulateur de puissance, si la production photovoltaïque est inférieure à la demande du bâtiment,

le réseau fournit la puissance supplémentaire nécessaire.

Pour l'étude, un système fictif de stockage sera couplé à l'existant. Avec cette configuration, le système aura les caractéristiques d'un microréseau avec son propre générateur, sa charge, son stockage et une connexion au réseau.

La majorité des microréseaux et aussi le système existant fonctionnent en courant alternatif. Le système fictif fonctionnera donc également en courant alternatif. Pour l'étude, un onduleur bidirectionnel supplémentaire sera incorporé pour le stockage. Avec cette configuration à 2 convertisseurs (uni et bidirectionnel), il est possible de simuler la majorité des microréseaux existants.

La configuration choisie pour l'étude est donc un microréseau avec un générateur PV, un système de stockage, un poste de consommation et un raccordement au réseau. La figure 1.19 présente les échanges de flux d'énergie dans le système étudié.

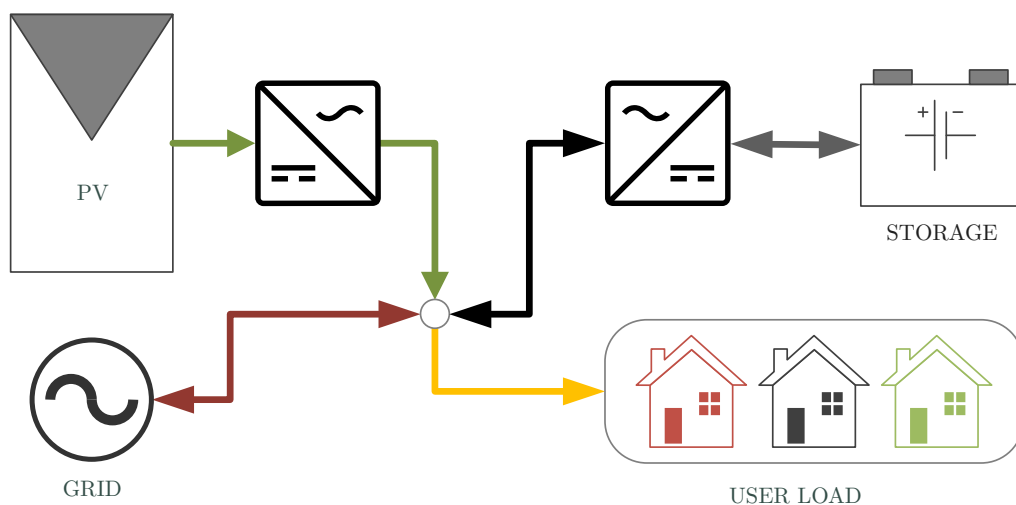


FIGURE 1.19 – Configuration du microréseau étudié

Les flux d'énergie transitent sur le nœud de contrôle qui relie les 2 convertisseurs, à la charge (le bâtiment EnerPos) et au réseau électrique principal.

- Le champ PV produit une énergie sous forme de courant **DC (Courant Continu)**.
- Le premier convertisseur est un onduleur **DC-AC** permettant de transformer en courant alternatif la génération PV.
- Le second convertisseur est un onduleur/chargeur bidirectionnel (**AC-DC, DC-AC**) qui permet de charger ou de décharger le système de stockage selon les instructions du système de contrôle.
- Le réseau principal est connecté microréseau via un transformateur d'isolement dont les pertes électriques sont supposées nulle.
- Le coût d'achat d'électricité au réseau varie en fonction du temps (heure creuse, heure pleine). D'une part, le stockage est utilisé pour réduire les pénalités dues à des dépassements de la puissance souscrite pouvant être observé lors de pics de consommation du bâtiment. D'autre part, le stockage réalise des transferts d'énergie afin de déplacer la surproduction solaire vers les périodes de pointe ou lorsque la demande d'énergie est élevée. Le dispositif de stockage dans cette étude est de type batterie. Deux technologies de

batterie seront étudiées. Cependant, la formulation du modèle de stockage reste la même, mais avec des caractéristiques différentes :

- La première est une batterie électrochimique au plomb comme celle utilisée dans les travaux de Riffonneau et al. [71] (rendement de charge 82%, plage de fonctionnement 40 – 90% de la capacité).
- La seconde est une batterie de type LFP (Lithium Iron Phosphate battery ($LiFePO_4$)) avec des caractéristiques de fonctionnement plus élevées (rendement de charge 95,5%, plage de fonctionnement 10 – 100% de la capacité). Les caractéristiques de cette batterie sont issues de l'outil d'analyse des systèmes de stockage de l'IRENA [137].

Il est à noter que ce microréseau est un système fictif déjà étudié dans la thèse de Simpore [138] et que l'objectif de cette étude de cas est de travailler sur la planification de son fonctionnement. Dans ce travail, la puissance réactive et les pertes en ligne ne sont pas prises en compte.

1.4.3 Intérêt de la prévision

Le bâtiment NetZeb a une production annuelle d'EnR intermittente supérieure à sa consommation, mais il doit encore être alimenté par le réseau principal. La prévision peut conduire à deux objectifs, une réduction de la consommation d'énergie provenant du réseau et une réduction des coûts d'exploitation.

La diminution de l'appel au réseau, voire l'effacement complet du microréseau, peut être obtenue en faisant correspondre la consommation et la production. La prévision peut donc servir à contrôler un stockage dont la capacité serait largement inférieure à celle d'un site isolé. De plus, la prévision peut être utilisée à d'autres fins que l'optimisation des transferts d'énergie. En effet, le contrôle prédictif du stockage peut aussi conduire à une réduction du coût d'exploitation. La structure des coûts de notre cas d'étude introduit des pénalités liées aux dépassements de la puissance souscrite. Donc, les prévisions pourraient encore permettre d'anticiper ces dépassements et réduire le coût d'exploitation du microréseau.

De plus, il est aussi intéressant d'exploiter simultanément la structure des coûts de l'électricité, la possibilité de revendre le surplus produit au réseau et le système de stockage tout en ayant un système moins vulnérable. De ce fait, comme mentionné plus haut, une meilleure prévision devrait améliorer significativement les performances technico-économiques du cas d'étude.

Cependant, comme la prévision est par nature incertaine, il est important de savoir quelle forme de prévision utiliser. À travers le cas d'étude présenté ci-avant, nous montrerons comment utiliser correctement, dans le contexte d'un microréseau électrique, des prévisions déterministes et probabilistes et nous établirons les différences résultantes de leur utilisation.

1.5 Positionnement et apport de la thèse

Avec l'augmentation de la part des EnR intermittentes dans les réseaux électriques, l'équilibre entre production et consommation est devenu une préoccupation majeure, et ce, parce que les EnR intermittentes n'offrent pas une production entièrement contrôlable (Dispatchable). D'autre part, si on se réfère à l'étude de Delarue et Morris [139], la relation entre la capacité d'EnR intermittente installée et la production d'EnR intermittente réellement absorbée montre que l'énergie réellement utilisée est bien inférieure à la capacité de production d'EnR intermittente du système, et ce, dans le cas où l'écrêtage est le seul mode de gestion lorsque

la production est supérieure à la consommation. Par exemple, pour une production combinée PV-éolienne, la part d'EnR intermittente absorbée ne peut excéder 40% de la capacité de la production, et il est difficile d'atteindre 30 à 40% si la production est uniquement d'origine PV.

Dans l'objectif de dépasser cette limite et d'obtenir un équilibre entre production et consommation, 2 approches existent : l'utilisation de stockage et la prévision de la production EnR intermittente. La meilleure stratégie consiste à combiner ces 2 leviers. Le cas d'étude illustrant les développements proposés dans ce travail de thèse sera une planification du fonctionnement d'un système de stockage intégré à un microréseau en prenant en compte la prévision de production d'un système PV. La prévision de cette EnR intermittente sera utilisée pour optimiser le contrôle du stockage afin de garantir l'équilibre production-consommation tout en assurant un coût d'exploitation minimal.

Les principales contributions envisagées pour cette thèse portent sur l'utilisation de prévisions solaires probabilistes dans le cadre d'un système fonctionnant en mode opérationnel :

- Proposer une méthodologie d'utilisation des prévisions probabilistes pour la gestion opérationnelle des systèmes énergétiques telle que le stockage.
- Fournir une méthode d'optimisation utilisant directement les fonctions de distribution issues de prévisions probabilistes sans passer par la génération de scénarios. L'utilisation directe des fonctions de distribution est motivée par la prise en compte des corrélations spatio-temporelles dans certaines prévisions solaires probabilistes.
- Rapprocher le domaine scientifique traitant de la prévision de production des EnR intermittentes avec celui traitant de l'optimisation du fonctionnement des systèmes énergétiques utilisant notamment des méthodes d'optimisation stochastique.
- Évaluer les gains techniques et économiques des prévisions probabilistes dans un système fonctionnel.

Le chapitre 2 propose un état de l'art à propos des méthodes d'optimisation en gestion de l'énergie, en particulier sur l'intégration des prévisions dans l'optimisation du fonctionnement des systèmes énergétiques.

Le chapitre 3 est consacré à l'utilisation de prévisions déterministes opérationnelles pour minimiser le coût de fonctionnement du microréseau décrit dans la partie 1.4.2. La gestion optimale du stockage est obtenue en intégrant les prévisions dans un problème formulé sous la forme d'une DP (Dynamic Programming). La méthode d'optimisation testée est comparée avec un fonctionnement du stockage suivant des règles simples de fonctionnement basées sur de l'expertise (heuristique). La relation entre la qualité de la prévision ainsi que l'influence de l'horizon de prévision y est aussi étudiée.

Dans le chapitre 4, une méthode d'utilisation directe de distributions issues de prévisions probabilistes dans un algorithme de programmation dynamique probabiliste (PDP) est proposée. Cette méthode montre la supériorité de l'utilisation de prévisions probabilistes par rapport aux prévisions déterministes. Ce chapitre met aussi en avant la complexité de la relation existant entre la valeur et la qualité des prévisions et il propose une piste sur les métriques de référence à adopter pour évaluer simultanément la qualité et la valeur de prévisions probabilistes de production PV.

La conclusion est consacrée aux limitations ainsi qu'aux perspectives que la méthode proposée ouvre dans le domaine de l'utilisation des prévisions probabilistes.

Bibliographie

- [1] M. Guarnieri, “The Beginning of Electric Energy Transmission : Part One [Historical],” *IEEE Industrial Electronics Magazine*, vol. 7, n^o. 1, p. 50–52, Mars 2013. [En line]. Disponible : <https://doi.org/10.1109/MIE.2012.2236484>
- [2] A. Guinane, G. M. Shafiullah, A. M. T. Oo, et B. E. Harvey, “Voltage fluctuations in PV penetration on SWER networks — A case study for regional Australia,” dans *2012 IEEE Power and Energy Society General Meeting*, Juill. 2012, p. 1–6, iSSN : 1944-9925. [En line]. Disponible : <https://doi.org/10.1109/PESGM.2012.6344630>
- [3] IRENA et CPI, *Global Landscape of Renewable Energy Finance 2020 : Methodology*. Abu Dhabi : International Renewable Energy Agency, 2020. [En line]. Disponible : <https://www.irena.org/publications/2020/Nov/Global-Landscape-of-Renewable-Energy-Finance-2020>
- [4] J. P. Praene, M. David, F. Sinama, D. Morau, et O. Marc, “Renewable energy : Progressing towards a net zero energy island, the case of Reunion Island,” *Renewable and Sustainable Energy Reviews*, vol. 16, n^o. 1, p. 426–442, Janv. 2012. [En line]. Disponible : <https://doi.org/10.1016/j.rser.2011.08.007>
- [5] K. Hansen, B. V. Mathiesen, et I. R. Skov, “Full energy system transition towards 100% renewable energy in Germany in 2050,” *Renewable and Sustainable Energy Reviews*, vol. 102, p. 1–13, Mars 2019. [En line]. Disponible : <https://doi.org/10.1016/j.rser.2018.11.038>
- [6] R. Gross, P. Heptonstall, M. Leach, D. Anderson, T. Green, et J. Skea, “Renewables and the grid : understanding intermittency,” *Proceedings of the Institution of Civil Engineers - Energy*, vol. 160, n^o. 1, p. 31–41, Févr. 2007. [En line]. Disponible : <https://doi.org/10.1680/ener.2007.160.1.31>
- [7] J. Hossain et H. R. Pota, *Robust Control for Grid Voltage Stability : High Penetration of Renewable Energy*, ser. Power Systems. Singapore : Springer Singapore, 2014. [En line]. Disponible : <https://doi.org/10.1007/978-981-287-116-9>
- [8] IRENA, *Innovation landscape for a renewable-powered future : Solutions to integrate variable renewables*. Abu Dhabi : International Renewable Energy Agency, 2019. [En line]. Disponible : <https://www.irena.org/publications/2019/Feb/Innovation-landscape-for-a-renewable-powered-future>
- [9] T. E. Hoff et R. Perez, “Quantifying PV power Output Variability,” *Solar Energy*, vol. 84, n^o. 10, p. 1782–1793, Oct. 2010. [En line]. Disponible : <https://doi.org/10.1016/j.solener.2010.07.003>
- [10] R. Perez, M. David, T. E. Hoff, M. Jamaly, S. Kivalov, J. Kleissl, P. Lauret, et M. Perez, “Spatial and Temporal Variability of Solar Energy,” *Foundations and Trends® in Renewable Energy*, vol. 1, n^o. 1, p. 1–44, 2016. [En line]. Disponible : <https://doi.org/10.1561/27000000006>

- [11] M. David, F. Ramahatana, et O. Liandrat, “Spatial and Temporal Variability of PV Output in an Insular Grid : Case of Reunion Island,” *Energy Procedia*, vol. 57, p. 1275–1282, 2014. [En line]. Disponible : <https://doi.org/10.1016/j.egypro.2014.10.117>
- [12] R. Perez, T. Hoff, J. Dise, D. Chalmers, et S. Kivalov, “The Cost of Mitigating Short-term PV Output Variability,” *Energy Procedia*, vol. 57, p. 755–762, 2014. [En line]. Disponible : <https://doi.org/10.1016/j.egypro.2014.10.283>
- [13] E. Tapaches, R. Perez, P. Lauret, M. Perez, et M. David, “Mitigation of the Variability of a PV Fleet via Geographical Dispersion and Energy Storage Systems on the Reunion Island Non-Interconnected Grid,” dans *2019 IEEE 46th Photovoltaic Specialists Conference (PVSC)*. Chicago, IL, USA : IEEE, Juin 2019, p. 2082–2086. [En line]. Disponible : <https://doi.org/10.1109/PVSC40753.2019.8981214>
- [14] IRENA, *Innovation landscape for a renewable-powered future : Solutions to integrate variable renewables*. Abu Dhabi : International Renewable Energy Agency, 2019. [En line]. Disponible : <https://www.irena.org/publications/2019/Feb/Innovation-landscape-for-a-renewable-powered-future>
- [15] S. Chatzivasileiadis, D. Ernst, et G. Andersson, “The Global Grid,” *Renewable Energy*, vol. 57, p. 372–383, Sept. 2013. [En line]. Disponible : <https://doi.org/10.1016/j.renene.2013.01.032>
- [16] “Intercontinental transmission of solar electric power by submarine cable : theory and constraints applied to Australian – East Asian links,” vol. 0. [En line]. Disponible : <https://doi.org/10.1080/14488388.2020.1809051>
- [17] J. Gondonnat et J. Hunt, “Subsea cable key challenges of an intercontinental power link : case study of Australia–Singapore interconnector,” *Energy Transitions*, vol. 4, n^o. 2, p. 169–188, Déc. 2020. [En line]. Disponible : <https://doi.org/10.1007/s41825-020-00032-z>
- [18] N. Hatziargyriou, H. Asano, R. Iravani, et C. Marnay, “Microgrids,” *IEEE Power and Energy Magazine*, vol. 5, n^o. 4, p. 78–94, Juill. 2007. [En line]. Disponible : <https://doi.org/10.1109/MPAE.2007.376583>
- [19] K. Alanne et A. Saari, “Distributed energy generation and sustainable development,” *Renewable and Sustainable Energy Reviews*, vol. 10, n^o. 6, p. 539–558, Déc. 2006. [En line]. Disponible : <https://doi.org/10.1016/j.rser.2004.11.004>
- [20] R. Konishi et M. Takahashi, “Optimal Allocation of Photovoltaic Systems and Energy Storage Systems based on Vulnerability Analysis,” *Energies*, vol. 10, n^o. 10, p. 1477, Sept. 2017. [En line]. Disponible : <https://doi.org/10.3390/en10101477>
- [21] N. Hatziargyriou, *Microgrids : Architectures and Control*. John Wiley & Sons, Mars 2014. [En line]. Disponible : <https://doi.org/10.1002/9781118720677>
- [22] S. Mei, R. Li, X. Xue, Y. Chen, Q. Lu, X. Chen, C. D. Ahrens, R. Li, et L. Chen, “Paving the way to smart micro energy grid : concepts, design principles, and engineering practices,” *CSEE Journal of Power and Energy Systems*, vol. 3, n^o. 4, p. 440–449,

- Déc. 2017, conference Name : CSEE Journal of Power and Energy Systems. [En line]. Disponible : <https://doi.org/10.17775/CSEEJPES.2016.01930>
- [23] N. Hatziargyriou, N. Jenkins, G. Strbac, J. P. Lopes, J. Ruela, A. Engler, J. Oyarzabal, G. Kariniotakis, et A. Amorim, “Microgrids—large scale integration of microgeneration to low voltage grids,” *CIGRE C6-309*, 2006. [En line]. Disponible : <http://www.microgrids.eu/micro2000/presentations/19.pdf>
- [24] IRENA, “Market integration of distributed energy resources,” dans *Market Design : Innovation Landscape briefs*. Abu Dhabi : International Renewable Energy Agency, Juin 2019. [En line]. Disponible : <https://www.irena.org/publications/2019/Jun/Market-Design-Innovation-Landscape-briefs>
- [25] G. Buffo, P. Marocco, D. Ferrero, A. Lanzini, et M. Santarelli, “Power-to-X and power-to-power routes,” dans *Solar Hydrogen Production*. Elsevier, 2019, p. 529–557. [En line]. Disponible : <https://linkinghub.elsevier.com/retrieve/pii/B9780128148532000151>
- [26] IRENA, *Hydrogen from renewable power : Technology outlook for the energy transition*. Abu Dhabi : International Renewable Energy Agency, Sept. 2018. [En line]. Disponible : <https://www.irena.org/publications/2019/May/Innovation-Outlook-Smart-Charging>
- [27] A. S. Anees, “Grid integration of renewable energy sources : Challenges, issues and possible solutions,” dans *2012 IEEE 5th India International Conference on Power Electronics (IICPE)*. Delhi, India : IEEE, Déc. 2012, p. 1–6. [En line]. Disponible : <https://doi.org/10.1109/IICPE.2012.6450514>
- [28] A. Castillo et D. F. Gayme, “Grid-scale energy storage applications in renewable energy integration : A survey,” *Energy Conversion and Management*, vol. 87, p. 885–894, Nov. 2014. [En line]. Disponible : <https://doi.org/10.1016/j.enconman.2014.07.063>
- [29] I. E. Commission, “Electrical energy storage : white paper,” *Geneva, Switzerland : International Electrotechnical Commission*, p. 1–78, 2011. [En line]. Disponible : <https://webstore.iec.ch/publication/22374>
- [30] B. Dunn, H. Kamath, et J.-M. Tarascon, “Electrical Energy Storage for the Grid : A Battery of Choices,” *Science*, vol. 334, n°. 6058, p. 928–935, Nov. 2011. [En line]. Disponible : <https://doi.org/10.1126/science.1212741>
- [31] T. M. Gür, “Review of electrical energy storage technologies, materials and systems : challenges and prospects for large-scale grid storage,” *Energy & Environmental Science*, vol. 11, n°. 10, p. 2696–2767, Oct. 2018, publisher : The Royal Society of Chemistry. [En line]. Disponible : <https://doi.org/10.1039/C8EE01419A>
- [32] Frost et Sullivan, “Emerging Energy Storage Technologies in Europe,” Frost & Sullivan Institute, Rapport technique, 2003.
- [33] H. Ibrahim, A. Ilinca, et J. Perron, “Energy storage systems—Characteristics and comparisons,” *Renewable and Sustainable Energy Reviews*, vol. 12, n°. 5, p. 1221–1250, Juin 2008. [En line]. Disponible : <https://doi.org/10.1016/j.rser.2007.01.023>

- [34] X. Luo, J. Wang, M. Dooner, et J. Clarke, “Overview of current development in electrical energy storage technologies and the application potential in power system operation,” *Applied Energy*, vol. 137, p. 511–536, Janv. 2015. [En line]. Disponible : <https://doi.org/10.1016/j.apenergy.2014.09.081>
- [35] F. Díaz-González, A. Sumper, O. Gomis-Bellmunt, et R. Villafáfila-Robles, “A review of energy storage technologies for wind power applications,” *Renewable and Sustainable Energy Reviews*, vol. 16, n^o. 4, p. 2154–2171, Mai 2012. [En line]. Disponible : <https://doi.org/10.1016/j.rser.2012.01.029>
- [36] P. D. Lund, J. Lindgren, J. Mikkola, et J. Salpakari, “Review of energy system flexibility measures to enable high levels of variable renewable electricity,” *Renewable and Sustainable Energy Reviews*, vol. 45, p. 785–807, Mai 2015. [En line]. Disponible : <https://doi.org/10.1016/j.rser.2015.01.057>
- [37] M. Korpaas, A. T. Holen, et R. Hildrum, “Operation and sizing of energy storage for wind power plants in a market system,” *International Journal of Electrical Power & Energy Systems*, vol. 25, n^o. 8, p. 599–606, Oct. 2003. [En line]. Disponible : [https://doi.org/10.1016/S0142-0615\(03\)00016-4](https://doi.org/10.1016/S0142-0615(03)00016-4)
- [38] F. S. Barnes et J. G. Levine, “Applications of Energy Storage to Generation and Absorption of Electrical Power,” dans *Large Energy Storage Systems Handbook*. CRC Press, Mars 2011.
- [39] A. K. Srivastava, A. A. Kumar, et N. N. Schulz, “Impact of Distributed Generations With Energy Storage Devices on the Electric Grid,” *IEEE Systems Journal*, vol. 6, n^o. 1, p. 110–117, Mars 2012. [En line]. Disponible : <https://doi.org/10.1109/JSYST.2011.2163013>
- [40] B. Kroposki, B. Johnson, Y. Zhang, V. Gevorgian, P. Denholm, B.-M. Hodge, et B. Hannegan, “Achieving a 100% Renewable Grid : Operating Electric Power Systems with Extremely High Levels of Variable Renewable Energy,” *IEEE Power and Energy Magazine*, vol. 15, n^o. 2, p. 61–73, Mars 2017, conference Name : IEEE Power and Energy Magazine. [En line]. Disponible : <https://doi.org/10.1109/MPE.2016.2637122>
- [41] X. Y. Wang, D. M. Vilathgamuwa, et S. S. Choi, “Determination of Battery Storage Capacity in Energy Buffer for Wind Farm,” *IEEE Transactions on Energy Conversion*, vol. 23, n^o. 3, p. 868–878, Sept. 2008, conference Name : IEEE Transactions on Energy Conversion. [En line]. Disponible : <https://doi.org/10.1109/TEC.2008.921556>
- [42] M. Morjaria, D. Anichkov, V. Chadliev, et S. Soni, “A Grid-Friendly Plant : The Role of Utility-Scale Photovoltaic Plants in Grid Stability and Reliability,” *IEEE Power and Energy Magazine*, vol. 12, n^o. 3, p. 87–95, Mai 2014, conference Name : IEEE Power and Energy Magazine. [En line]. Disponible : <https://doi.org/10.1109/MPE.2014.2302221>
- [43] X. Bai, K. Clark, G. A. Jordan, N. W. Miller, et R. J. Piwko, “Intermittency analysis project : Appendix B impact of intermittent generation on operation of California power grid,” California Energy Commission, USA, Rapport technique CEC-500-2007-081-APB, 2007, publisher : Citeseer. [En line]. Disponible : <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.446.3904&rep=rep1&type=pdf>

- [44] M. J. E. Alam, K. M. Muttaqi, et D. Sutanto, “A Novel Approach for Ramp-Rate Control of Solar PV Using Energy Storage to Mitigate Output Fluctuations Caused by Cloud Passing,” *IEEE Transactions on Energy Conversion*, vol. 29, n^o. 2, p. 507–518, Juin 2014. [En line]. Disponible : <https://doi.org/10.1109/TEC.2014.2304951>
- [45] M. Huotari, T. Tegnér, et N. Johansson, “Control of Energy Storage units to limit active power ramp-rates of renewable energy sources using non-ideal generation forecasts,” dans *North American Power Symposium (NAPS), 2015*. IEEE, 2015, p. 1–6. [En line]. Disponible : <https://doi.org/10.1109/NAPS.2015.7335126>
- [46] Y. Gong, Q. Jiang, et R. Baldick, “Ramp Event Forecast Based Wind Power Ramp Control With Energy Storage System,” *IEEE Transactions on Power Systems*, vol. 31, n^o. 3, p. 1831–1844, Mai 2016. [En line]. Disponible : <https://doi.org/10.1109/TPWRS.2015.2445382>
- [47] J. Marcos, O. Storkél, L. Marroyo, M. Garcia, et E. Lorenzo, “Storage requirements for PV power ramp-rate control,” *Solar Energy*, vol. 99, p. 28–35, Janv. 2014. [En line]. Disponible : <https://doi.org/10.1016/j.solener.2013.10.037>
- [48] M. Milligan, P. Donohoo, D. Lew, E. Ela, B. Kirby, H. Holttinen, E. Lannoye, D. Flynn, M. O’Malley, N. Miller, P. B. Eriksen, A. Gottig, B. Rawn, M. Gibescu, E. G. Lazaro, A. Robitaille, et I. Kamwa, “Operating Reserves and Wind Power Integration : An International Comparison,” National Renewable Energy Lab. (NREL), Golden, CO (United States), Rapport technique NREL/CP-5500-49019, Oct. 2010. [En line]. Disponible : <https://www.osti.gov/biblio/992809>
- [49] T. A. Faunce, J. Prest, D. Su, S. J. Hearne, et F. Iacopi, “On-grid batteries for large-scale energy storage : Challenges and opportunities for policy and technology,” *MRS Energy & Sustainability*, vol. 5, p. E11, 2018. [En line]. Disponible : <https://doi.org/10.1557/mre.2018.11>
- [50] L. Bird, D. Lew, M. Milligan, E. M. Carlini, A. Estanqueiro, D. Flynn, E. Gomez-Lazaro, H. Holttinen, N. Menemenlis, A. Orths, P. B. Eriksen, J. C. Smith, L. Soder, P. Sorensen, A. Altiparmakis, Y. Yasuda, et J. Miller, “Wind and solar energy curtailment : A review of international experience,” *Renewable and Sustainable Energy Reviews*, vol. 65, p. 577–586, Nov. 2016. [En line]. Disponible : <https://doi.org/10.1016/j.rser.2016.06.082>
- [51] M. Perez, R. Perez, K. Rabago, et M. Putnam, “Lowest-Cost, Firm PV Without Conventional Backup : Supply Shaping Through Curtailment,” dans *2018 IEEE 7th World Conference on Photovoltaic Energy Conversion (WCPEC) (A Joint Conference of 45th IEEE PVSC, 28th PVSEC 34th EU PVSEC)*, Juin 2018, p. 1609–1613, iSSN : 0160-8371. [En line]. Disponible : <https://doi.org/10.1109/PVSC.2018.8547791>
- [52] M. Perez, R. Perez, K. R. Rábago, et M. Putnam, “Overbuilding & curtailment : The cost-effective enablers of firm PV generation,” *Solar Energy*, vol. 180, p. 412–422, Mars 2019. [En line]. Disponible : <https://doi.org/10.1016/j.solener.2018.12.074>
- [53] G. Bao, C. Lu, Z. Yuan, et Z. Lu, “Battery energy storage system load shifting control based on real time load forecast and dynamic programming,” dans *2012 IEEE*

- International Conference on Automation Science and Engineering (CASE)*, Août 2012, p. 815–820. [En line]. Disponible : <https://doi.org/10.1109/CoASE.2012.6386377>
- [54] P. Kanjiya et V. Khadkikar, “Enhancing power quality and stability of future smart grid with intermittent renewable energy sources using electric springs,” dans *2013 International Conference on Renewable Energy Research and Applications (ICRERA)*, Oct. 2013, p. 918–922. [En line]. Disponible : <https://doi.org/10.1109/ICRERA.2013.6749882>
- [55] C. K. Lee et S. Y. Hui, “Reduction of energy storage requirements in future smart grid using electric springs,” *IEEE Transactions on Smart Grid*, vol. 4, n° 3, p. 1282–1288, Sept. 2013, conference Name : IEEE Transactions on Smart Grid. [En line]. Disponible : <https://doi.org/10.1109/TSG.2013.2252208>
- [56] S. Y. Abujarad, M. W. Mustafa, et J. J. Jamian, “Recent approaches of unit commitment in the presence of intermittent renewable energy resources : A review,” *Renewable and Sustainable Energy Reviews*, vol. 70, p. 215–223, Avr. 2017. [En line]. Disponible : <https://doi.org/10.1016/j.rser.2016.11.246>
- [57] A. D. Hawkes et M. A. Leach, “Modelling high level system design and unit commitment for a microgrid,” *Applied Energy*, vol. 86, n° 7, p. 1253–1265, Juill. 2009. [En line]. Disponible : <https://doi.org/10.1016/j.apenergy.2008.09.006>
- [58] N. Padhy, “Unit commitment-a bibliographical survey,” *IEEE Transactions on Power Systems*, vol. 19, n° 2, p. 1196–1205, Mai 2004. [En line]. Disponible : <https://doi.org/10.1109/TPWRS.2003.821611>
- [59] C. Klessmann, C. Nabe, et K. Burges, “Pros and cons of exposing renewables to electricity market risks—A comparison of the market integration approaches in Germany, Spain, and the UK,” *Energy Policy*, vol. 36, n° 10, p. 3646–3661, Oct. 2008. [En line]. Disponible : <https://doi.org/10.1016/j.enpol.2008.06.022>
- [60] T. Jónsson, P. Pinson, et H. Madsen, “On the market impact of wind energy forecasts,” *Energy Economics*, vol. 32, n° 2, p. 313–320, Mars 2010. [En line]. Disponible : <https://doi.org/10.1016/j.eneco.2009.10.018>
- [61] J. Luoma, P. Mathiesen, et J. Kleissl, “Forecast value considering energy pricing in California,” *Applied Energy*, vol. 125, p. 230–237, Juill. 2014. [En line]. Disponible : <https://doi.org/10.1016/j.apenergy.2014.03.061>
- [62] J. Antonanzas, D. Pozo-Vázquez, L. A. Fernandez-Jimenez, et F. J. Martinez-de Pison, “The value of day-ahead forecasting for photovoltaics in the Spanish electricity market,” *Solar Energy*, vol. 158, p. 140–146, Déc. 2017. [En line]. Disponible : <https://doi.org/10.1016/j.solener.2017.09.043>
- [63] “Trading wind energy on the basis of probabilistic forecasts both of wind generation and of market quantities,” vol. 16. [En line]. Disponible : <https://doi.org/10.1002/we.1531>

- [64] Y. Udagawa, K. Ogimoto, J. G. da Silva, F. Junior, H. Ohtake, et S. Fukutome, “Economic impact of photovoltaic power forecast error on power system operation in Japan,” dans *2017 IEEE Manchester PowerTech*. Manchester, United Kingdom : IEEE, Juin 2017, p. 1–6. [En line]. Disponible : <https://doi.org/10.1109/PTC.2017.7981080>
- [65] C. Brancucci Martinez-Anido, B. Botor, A. R. Florita, C. Draxl, S. Lu, H. F. Hamann, et B.-M. Hodge, “The value of day-ahead solar power forecasting improvement,” *Solar Energy*, vol. 129, p. 192–203, Mai 2016. [En line]. Disponible : <https://doi.org/10.1016/j.solener.2016.01.049>
- [66] C. Lowery et M. O’Malley, “Impact of Wind Forecast Error Statistics Upon Unit Commitment,” *IEEE Transactions on Sustainable Energy*, vol. 3, n° 4, p. 760–768, Oct. 2012. [En line]. Disponible : <https://doi.org/10.1109/TSTE.2012.2210150>
- [67] C. K. Ekman et S. H. Jensen, “Prospects for large scale electricity storage in Denmark,” *Energy Conversion and Management*, vol. 51, n° 6, p. 1140–1147, Juin 2010. [En line]. Disponible : <https://doi.org/10.1016/j.enconman.2009.12.023>
- [68] K. Hedegaard et P. Meibom, “Wind power impacts and electricity storage – A time scale perspective,” *Renewable Energy*, vol. 37, n° 1, p. 318–324, Janv. 2012. [En line]. Disponible : <https://doi.org/10.1016/j.renene.2011.06.034>
- [69] M. McPherson et S. Tahseen, “Deploying storage assets to facilitate variable renewable energy integration : The impacts of grid flexibility, renewable penetration, and market structure,” *Energy*, vol. 145, p. 856–870, Févr. 2018. [En line]. Disponible : <https://doi.org/10.1016/j.energy.2018.01.002>
- [70] P. Haessig, B. Multon, H. Ben Ahmed, S. Lascaud, et P. Bondon, “Energy storage sizing for wind power : impact of the autocorrelation of day-ahead forecast errors : Energy storage sizing for wind power,” *Wind Energy*, p. n/a–n/a, Oct. 2013. [En line]. Disponible : <https://doi.org/10.1002/we.1680>
- [71] Y. Riffonneau, S. Bacha, F. Barruel, et S. Ploix, “Optimal Power Flow Management for Grid Connected PV Systems With Batteries,” *IEEE Transactions on Sustainable Energy*, vol. 2, n° 3, p. 309–320, Juill. 2011. [En line]. Disponible : <https://doi.org/10.1109/TSTE.2011.2114901>
- [72] Y. Yang, S. Bremner, C. Menictas, et M. Kay, “A Mixed Receding Horizon Control Strategy for Battery Energy Storage System Scheduling in a Hybrid PV and Wind Power Plant with Different Forecast Techniques,” *Energies*, vol. 12, n° 12, p. 2326, Juin 2019. [En line]. Disponible : <https://doi.org/10.3390/en12122326>
- [73] M. A. Matos et R. J. Bessa, “Setting the Operating Reserve Using Probabilistic Wind Power Forecasts,” *IEEE Transactions on Power Systems*, vol. 26, n° 2, p. 594–603, Mai 2011. [En line]. Disponible : <https://doi.org/10.1109/TPWRS.2010.2065818>
- [74] A. Blakers, B. Lu, et M. Stocks, “100% renewable electricity in Australia,” *Energy*, vol. 133, p. 471–482, Août 2017. [En line]. Disponible : <https://doi.org/10.1016/j.energy.2017.05.168>

- [75] D. Srinivasan et S. Gundam, “Correlation analysis of solar power and electric demand,” dans *2013 International Conference on Renewable Energy and Sustainable Energy (ICRESE)*, Déc. 2013, p. 221–226. [En line]. Disponible : <https://doi.org/10.1109/ICRESE.2013.6927818>
- [76] P. De Jong, A. S. Sánchez, K. Esquerre, R. A. Kalid, et E. A. Torres, “Solar and wind energy production in relation to the electricity load curve and hydroelectricity in the northeast region of Brazil,” *Renewable and Sustainable Energy Reviews*, vol. 23, p. 526–535, Juill. 2013. [En line]. Disponible : <https://doi.org/10.1016/j.rser.2013.01.050>
- [77] Y. Li, V. G. Agelidis, et Y. Shrivastava, “Wind-solar resource complementarity and its combined correlation with electricity load demand,” dans *2009 4th IEEE Conference on Industrial Electronics and Applications*, Mai 2009, p. 3623–3628. [En line]. Disponible : <https://doi.org/10.1109/ICIEA.2009.5138882>
- [78] G. Aburiyana et M. E. El-Hawary, “An overview of forecasting techniques for load, wind and solar powers,” dans *2017 IEEE Electrical Power and Energy Conference (EPEC)*, Oct. 2017, p. 1–7. [En line]. Disponible : <https://doi.org/10.1109/EPEC.2017.8286192>
- [79] T. Hong, P. Pinson, Y. Wang, R. Weron, D. Yang, et H. Zareipour, “Energy Forecasting : A Review and Outlook,” *IEEE Open Access Journal of Power and Energy*, vol. 7, p. 376–388, 2020. [En line]. Disponible : <https://doi.org/10.1109/OAJPE.2020.3029979>
- [80] T. Hong, P. Pinson, S. Fan, H. Zareipour, A. Troccoli, et R. J. Hyndman, “Probabilistic energy forecasting : Global Energy Forecasting Competition 2014 and beyond,” *International Journal of Forecasting*, vol. 32, n^o. 3, p. 896–913, Juill. 2016. [En line]. Disponible : <https://doi.org/10.1016/j.ijforecast.2016.02.001>
- [81] L. Ljung, *System Identification : Theory for the User*. Pearson Education, Déc. 1998. [En line]. Disponible : <https://doi.org/10.1109/MRA.2012.2192817>
- [82] S. S. Soman, H. Zareipour, O. Malik, et P. Mandal, “A review of wind power and wind speed forecasting methods with different time horizons,” dans *North American Power Symposium 2010*. IEEE, 2010, p. 1–8. [En line]. Disponible : <https://doi.org/10.1109/NAPS.2010.5619586>
- [83] M. Diagne, M. David, P. Lauret, J. Boland, et N. Schmutz, “Review of solar irradiance forecasting methods and a proposition for small-scale insular grids,” *Renewable and Sustainable Energy Reviews*, vol. 27, p. 65–76, Nov. 2013. [En line]. Disponible : <https://doi.org/10.1016/j.rser.2013.06.042>
- [84] T. Hong et S. Fan, “Probabilistic electric load forecasting : A tutorial review,” *International Journal of Forecasting*, vol. 32, n^o. 3, p. 914–938, Juill. 2016. [En line]. Disponible : <https://doi.org/10.1016/j.ijforecast.2015.11.011>
- [85] S. K. Aggarwal, L. M. Saini, et A. Kumar, “Electricity price forecasting in deregulated markets : A review and evaluation,” *International Journal of Electrical Power & Energy Systems*, vol. 31, n^o. 1, p. 13–22, Janv. 2009. [En line]. Disponible : <https://doi.org/10.1016/j.ijepes.2008.09.003>

- [86] C. Chatfield, *Time-Series Forecasting*. CRC Press, Oct. 2000. [En line]. Disponible : <https://doi.org/10.1201/9781420036206>
- [87] R. J. Hyndman, R. A. Ahmed, G. Athanasopoulos, et H. L. Shang, “Optimal combination forecasts for hierarchical time series,” *Computational Statistics & Data Analysis*, vol. 55, n^o. 9, p. 2579–2589, Sept. 2011. [En line]. Disponible : <https://doi.org/10.1016/j.csda.2011.03.006>
- [88] C. Voyant, G. Notton, S. Kalogirou, M.-L. Nivet, C. Paoli, F. Motte, et A. Fouilloy, “Machine learning methods for solar radiation forecasting : A review,” *Renewable Energy*, vol. 105, p. 569–582, Mai 2017. [En line]. Disponible : <https://doi.org/10.1016/j.renene.2016.12.095>
- [89] S. Ghimire, R. C. Deo, N. Raj, et J. Mi, “Deep solar radiation forecasting with convolutional neural network and long short-term memory network algorithms,” *Applied Energy*, vol. 253, p. 113541, Nov. 2019. [En line]. Disponible : <https://doi.org/10.1016/j.apenergy.2019.113541>
- [90] N. K. Ahmed, A. F. Atiya, N. E. Gayar, et H. El-Shishiny, “An Empirical Comparison of Machine Learning Models for Time Series Forecasting,” *Econometric Reviews*, vol. 29, n^o. 5-6, p. 594–621, Août 2010. [En line]. Disponible : <https://doi.org/10.1080/07474938.2010.481556>
- [91] R. Buizza, P. L. Houtekamer, G. Pellerin, Z. Toth, Y. Zhu, et M. Wei, “A Comparison of the ECMWF, MSC, and NCEP Global Ensemble Prediction Systems,” *Monthly Weather Review*, vol. 133, n^o. 5, p. 1076–1097, Mai 2005. [En line]. Disponible : <https://doi.org/10.1175/MWR2905.1>
- [92] R. Buizza, “The value of probabilistic prediction,” *Atmospheric Science Letters*, vol. 9, n^o. 2, p. 36–42, Avr. 2008. [En line]. Disponible : <https://doi.org/10.1002/asl.170>
- [93] A. Persson et F. Grazzini, “ECMWF Forecast User Guide,” ECMWF, User manual, Mai 2018. [En line]. Disponible : <https://confluence.ecmwf.int/display/FUG/Forecast+User+Guide>
- [94] K. Saito, J.-i. Ishida, K. Aranami, T. Hara, T. Segawa, M. Narita, et Y. Honda, “Non-hydrostatic Atmospheric Models and Operational Development at JMA,” *Journal of Meteorological Society of Japan*, vol. 85B, p. 271–304, 2007. [En line]. Disponible : <https://doi.org/10.2151/jmsj.85B.271>
- [95] M. A. Atwater et J. T. Ball, “A numerical solar radiation model based on standard meteorological observations,” *Solar Energy*, vol. 21, n^o. 3, p. 163–170, Janv. 1978. [En line]. Disponible : [https://doi.org/10.1016/0038-092X\(78\)90018-X](https://doi.org/10.1016/0038-092X(78)90018-X)
- [96] R. E. Bird et R. L. Hulstrom, “Simplified clear sky model for direct and diffuse insolation on horizontal surfaces,” Solar Energy Research Inst., Golden, CO (USA), Rapport technique SERI/TR-642-761, Févr. 1981. [En line]. Disponible : <https://doi.org/10.2172/6510849>

- [97] P. Ineichen, “A broadband simplified version of the Solis clear sky model,” *Solar Energy*, vol. 82, n^o. 8, p. 758–762, Août 2008. [En line]. Disponible : <https://doi.org/10.1016/j.solener.2008.02.009>
- [98] M. J. Reno, C. W. Hansen, et J. S. Stein, “Global horizontal irradiance clear sky models : Implementation and analysis,” *SANDIA report SAND2012-2389*, 2012. [En line]. Disponible : <https://doi.org/10.2172/1039404>
- [99] A. Hammer, D. Heinemann, E. Lorenz, et B. Lückehe, “Short-term forecasting of solar radiation : a statistical approach using satellite data,” *Solar Energy*, vol. 67, n^o. 1-3, p. 139–150, 1999, iSBN : 0038-092X Publisher : Elsevier. [En line]. Disponible : [https://doi.org/10.1016/S0038-092X\(00\)00038-4](https://doi.org/10.1016/S0038-092X(00)00038-4)
- [100] C. W. Chow, B. Urquhart, M. Lave, A. Dominguez, J. Kleissl, J. Shields, et B. Washom, “Intra-hour forecasting with a total sky imager at the UC San Diego solar energy testbed,” *Solar Energy*, vol. 85, n^o. 11, p. 2881–2893, Nov. 2011. [En line]. Disponible : <https://doi.org/10.1016/j.solener.2011.08.025>
- [101] S. D. Miller, M. A. Rogers, J. M. Haynes, M. Sengupta, et A. K. Heidinger, “Short-term solar irradiance forecasting via satellite/model coupling,” *Solar Energy*, vol. 168, p. 102–117, Juill. 2018. [En line]. Disponible : <https://doi.org/10.1016/j.solener.2017.11.049>
- [102] F. Wang, Z. Mi, S. Su, et H. Zhao, “Short-Term Solar Irradiance Forecasting Model Based on Artificial Neural Network Using Statistical Feature Parameters,” *Energies*, vol. 5, n^o. 5, Mai 2012. [En line]. Disponible : <https://doi.org/10.3390/en5051355>
- [103] M. David et P. Lauret, “Solar Radiation Probabilistic Forecasting,” dans *Wind Field and Solar Radiation Characterization and Forecasting*, R. Perez, édit. Cham : Springer International Publishing, 2018, p. 201–227. [En line]. Disponible : https://doi.org/10.1007/978-3-319-76876-2_9
- [104] M. David, F. Ramahatana, P. Trombe, et P. Lauret, “Probabilistic forecasting of the solar irradiance with recursive ARMA and GARCH models,” *Solar Energy*, vol. 133, p. 55–72, Août 2016. [En line]. Disponible : <https://doi.org/10.1016/j.solener.2016.03.064>
- [105] P.-J. Trombe, P. Pinson, et H. Madsen, “A General Probabilistic Forecasting Framework for Offshore Wind Power Fluctuations,” *Energies*, vol. 5, n^o. 3, p. 621–657, Mars 2012. [En line]. Disponible : <https://doi.org/10.3390/en5030621>
- [106] A. Cifter, “Forecasting electricity price volatility with the Markov-switching GARCH model : Evidence from the Nordic electric power market,” *Electric Power Systems Research*, vol. 102, p. 61–67, Sept. 2013. [En line]. Disponible : <https://doi.org/10.1016/j.epsr.2013.04.007>
- [107] F. Golestaneh, P. Pinson, et H. B. Gooi, “Very Short-Term Nonparametric Probabilistic Forecasting of Renewable Energy Generation— With Application to Solar Energy,” *IEEE Transactions on Power Systems*, vol. 31, n^o. 5, p. 3850–3863, Sept. 2016, conference Name : IEEE Transactions on Power Systems. [En line]. Disponible : <https://doi.org/10.1109/TPWRS.2015.2502423>

- [108] J. H. Friedman, “Greedy Function Approximation : A Gradient Boosting Machine,” *The Annals of Statistics*, vol. 29, n^o. 5, p. 1189–1232, 2001, publisher : Institute of Mathematical Statistics. [En line]. Disponible : <https://www.jstor.org/stable/2699986>
- [109] M. David, M. Diagne, et P. Lauret, “Outputs and error indicators for solar forecasting models,” dans *Proceedings of the World Renewable Energy Forum (WREF)*, 2012, p. 13–17. [En line]. Disponible : <https://hal.archives-ouvertes.fr/hal-00918149>
- [110] P. Lauret, M. David, et P. Pinson, “Verification of solar irradiance probabilistic forecasts,” *Solar Energy*, vol. 194, p. 254–271, Déc. 2019. [En line]. Disponible : <https://doi.org/10.1016/j.solener.2019.10.041>
- [111] J. W. Messner, P. Pinson, J. Browell, M. B. Bjerregård, et I. Schicker, “Evaluation of wind power forecasts—An up-to-date view,” *Wind Energy*, vol. 23, n^o. 6, p. 1461–1481, 2020. [En line]. Disponible : <https://doi.org/10.1002/we.2497>
- [112] A. H. Murphy, “What Is a Good Forecast? An Essay on the Nature of Goodness in Weather Forecasting,” *Weather and Forecasting*, vol. 8, n^o. 2, p. 281–293, Juin 1993, publisher : American Meteorological Society Section : Weather and Forecasting. [En line]. Disponible : [https://doi.org/10.1175/1520-0434\(1993\)008<0281:WIAGFA>2.0.CO;2](https://doi.org/10.1175/1520-0434(1993)008<0281:WIAGFA>2.0.CO;2)
- [113] Z. Zhou, C. Liu, et A. Botterud, “Stochastic Methods Applied to Power System Operations with Renewable Energy : A Review,” Argonne National Lab. (ANL), Argonne, IL (United States), Rapport technique ANL/ESD-16/14, Août 2016. [En line]. Disponible : <https://doi.org/https://doi.org/10.2172/1307655>
- [114] I. Abdou et M. Tkiouat, “Unit Commitment Problem in Electrical Power System : A Literature Review,” *International Journal of Electrical and Computer Engineering (IJECE)*, vol. 8, n^o. 3, p. 1357, Juin 2018. [En line]. Disponible : <https://doi.org/10.11591/ijece.v8i3.pp1357-1372>
- [115] R. Barth, L. Söder, C. Weber, H. Brand, et D. J. Swider, “Wilmar : Methodology of the Scenario Tree Tool,” Institute of Energy Economics and the Rational Use of Energy, University of Stuttgart, Stuttgart, Germany, Documentation Deliverable 6.2 (d), Janv. 2006. [En line]. Disponible : http://www.wilmar.risoe.dk/Deliverables/Wilmar%20d6_2_d_ScenarioTree_doc.pdf
- [116] C. Ordoudis, P. Pinson, M. Zugno, et J. M. Morales, “Stochastic unit commitment via Progressive Hedging — extensive analysis of solution methods,” dans *2015 IEEE Eindhoven PowerTech*, Juin 2015, p. 1–6. [En line]. Disponible : <https://doi.org/10.1109/PTC.2015.7232629>
- [117] P. Pinson, H. Madsen, H. A. Nielsen, G. Papaefthymiou, et B. Klöckl, “From probabilistic forecasts to statistical scenarios of short-term wind power production,” *Wind Energy*, vol. 12, n^o. 1, p. 51–62, Janv. 2009. [En line]. Disponible : <https://doi.org/10.1002/we.284>
- [118] B. Li et J. Zhang, “A review on the integration of probabilistic solar forecasting in power systems,” *Solar Energy*, vol. 207, p. 777–795, 2020. [En line]. Disponible : <https://doi.org/10.1016/j.solener.2020.06.083>

- [119] A. Shapiro et A. Nemirovski, “On Complexity of Stochastic Programming Problems,” dans *Continuous Optimization : Current Trends and Modern Applications*, ser. Applied Optimization, V. Jeyakumar et A. Rubinov, édit. Boston, MA : Springer US, 2005, p. 111–146. [En line]. Disponible : https://doi.org/10.1007/0-387-26771-9_4
- [120] A. Ioannidis et K. J. Chalvatzis, “Energy Supply Sustainability For Island Nations : A Study on 8 Global Islands,” *Energy Procedia*, vol. 142, p. 3028–3034, Déc. 2017. [En line]. Disponible : <https://doi.org/10.1016/j.egypro.2017.12.440>
- [121] A. Genave, “Energy vulnerability in the Southwest Indian Ocean islands,” *Journal of the Indian Ocean Region*, vol. 15, n^o. 1, p. 40–57, Janv. 2019. [En line]. Disponible : <https://doi.org/10.1080/19480881.2019.1560760>
- [122] Observatoire Énergie Réunion, “Bilan énergétique de la Réunion 2019,” Observatoire Énergie Réunion, La Réunion, Technical Report, 2020. [En line]. Disponible : http://observation.energies-reunion.com/wp-content/uploads/2020/09/BER-2019-e%C3%81d-2020-Technique-V_comprese%C3%81.pdf
- [123] Y. Kuang, Y. Zhang, B. Zhou, C. Li, Y. Cao, L. Li, et L. Zeng, “A review of renewable energy utilization in islands,” *Renewable and Sustainable Energy Reviews*, vol. 59, p. 504–513, Juin 2016. [En line]. Disponible : <https://doi.org/10.1016/j.rser.2016.01.014>
- [124] S. Carr-Cornish et L. Romanach, “Differences in Public Perceptions of Geothermal Energy Technology in Australia,” *Energies*, vol. 7, n^o. 3, p. 1555–1575, Mars 2014, number : 3 Publisher : Multidisciplinary Digital Publishing Institute. [En line]. Disponible : <https://doi.org/10.3390/en7031555>
- [125] K. Li, H. Bian, C. Liu, D. Zhang, et Y. Yang, “Comparison of geothermal with solar and wind power generation systems,” *Renewable and Sustainable Energy Reviews*, vol. 42, p. 1464–1474, Févr. 2015. [En line]. Disponible : <https://doi.org/10.1016/j.rser.2014.10.049>
- [126] H. Liu, V. Krishna, J. Lun Leung, T. Reindl, et L. Zhao, “Field experience and performance analysis of floating PV technologies in the tropics,” *Progress in Photovoltaics : Research and Applications*, vol. 26, n^o. 12, p. 957–967, 2018, _eprint : <https://onlinelibrary.wiley.com/doi/pdf/10.1002/pip.3039>. [En line]. Disponible : <https://doi.org/10.1002/pip.3039>
- [127] S. Selosse, S. Garabedian, O. Ricci, et N. Maïzi, “The renewable energy revolution of reunion island,” *Renewable and Sustainable Energy Reviews*, vol. 89, p. 99–105, Juin 2018. [En line]. Disponible : <https://doi.org/10.1016/j.rser.2018.03.013>
- [128] S. Biscaglia, D. Chotard, A. Darbot, N. Mairet, F. Babonneau, et A. Haurie, “Vers l’autonomie énergétique en zone non interconnectée à la Réunion,” Ademe, Angers, Rapport technique, Mars 2018. [En line]. Disponible : <https://librairie.ademe.fr/energie-s-renouvelables-reseaux-et-stockage/452-vers-l-autonomie-energetique-en-zone-non-int-erconnectee-zni-sur-l-ile-de-la-reunion-a-l-horizon-2030.html>
- [129] V. Rakotoson, “Intégration de l’analyse de cycle de vie dans l’étude de la production électrique en milieux insulaires,” Thèse de doctorat, La Réunion, 2018. [En line]. Disponible : <https://tel.archives-ouvertes.fr/tel-02307247/document>

- [130] K. Schmietendorf, J. Peinke, et O. Kamps, “The impact of turbulent renewable energy production on power grid stability and quality,” *The European Physical Journal B*, vol. 90, n°. 11, p. 222, Nov. 2017. [En line]. Disponible : <https://doi.org/10.1140/epjb/e2017-80352-8>
- [131] A. Lenoir, F. Garde, E. Ottenwelter, A. Bornarel, et E. Wurtz, “Net zero energy building in France : from design studies to energy monitoring. A state of the art review,” dans *Eurosun 2010-International Conference on Solar Heating, Cooling and Buildings*, Sept. 2010. [En line]. Disponible : https://www.forum.iea-shc.org/data/sites/1/publications/Task40c-Net_Zero_Energy_Buildings_in_France_From_Design_Studies_to_Energy_Monitoring.pdf
- [132] J. Benemann, O. Chehab, et E. Schaar-Gabriel, “Building-integrated PV modules,” *Solar Energy Materials and Solar Cells*, vol. 67, n°. 1, p. 345–354, Mars 2001. [En line]. Disponible : [https://doi.org/10.1016/S0927-0248\(00\)00302-0](https://doi.org/10.1016/S0927-0248(00)00302-0)
- [133] F. Garde, M. David, A. Lenoir, et E. Ottenwelter, “Towards Net Zero Energy Buildings in Hot Climates : Part 1, New Tools and Methods.” *ASHRAE transactions*, vol. 117, n°. 1, 2011. [En line]. Disponible : <http://task40.iea-shc.org/data/sites/1/publications/DC-TP6-Garde-2011-11.pdf>
- [134] A. Lenoir, “On Comfort in Tropical Climates. The Design and Operation of Net Zero Energy Buildings.” Thèse de doctorat, Université de La Réunion, 2013. [En line]. Disponible : <https://tel.archives-ouvertes.fr/tel-01100526/>
- [135] H. Demirhan et Z. Renwick, “Missing value imputation for short to mid-term horizontal solar irradiance data,” *Applied Energy*, vol. 225, p. 998–1012, Sept. 2018. [En line]. Disponible : <https://doi.org/10.1016/j.apenergy.2018.05.054>
- [136] F. Ramahatana, J. Vigneron, S. Simapore, J. Le Gal La salle, P. Lauret, et M. David, “EnerPos simulation data,” Sept. 2020, publisher : Zenodo Version Number : 1. [En line]. Disponible : <https://doi.org/10.5281/zenodo.4028056>
- [137] IRENA, “Electricity storage and renewables : Costs and markets to 2030, Cost-of-service tool,” Abu Dhabi, Oct. 2017. [En line]. Disponible : <https://www.irena.org/publications/2017/Oct/Electricity-storage-and-renewables-costs-and-markets>
- [138] S. Simapore, “Modélisation, simulation et optimisation d’un système de stockage à air comprimé couplé à un bâtiment et à une production photovoltaïque,” Thèse de doctorat, Université de La Réunion, Sept. 2018. [En line]. Disponible : <https://tel.archives-ouvertes.fr/tel-02059339/document>
- [139] E. Delarue et J. Morris, “Renewables Intermittency : Operational Limits and Implications for Long-Term Energy System Models,” MIT Joint Program on the Science and Policy of Global Change, Technical Report, Mars 2015, accepted : 2015-03-03T19 :27 :43Z. [En line]. Disponible : <http://hdl.handle.net/1721.1/95762>

CHAPITRE 2

Intégration des prévisions dans l'optimisation du fonctionnement des systèmes énergétiques

Do mathematics have a relation to reality or are they only a mathematical symbol?

Fulton J. Sheen

Sommaire

2.1	Optimisation en gestion de l'énergie	50
2.1.1	Optimisation sans prévision	53
2.1.2	Optimisation et prévision	54
2.1.2.1	Approche purement déterministe	55
2.1.2.2	Commande prédictive de modèle (MPC)	56
2.1.2.3	Approches probabiliste et stochastique	57
2.1.3	Analyse critique	61
2.2	Optimisation stochastique	62
2.2.1	Principe d'optimalité et Programmation Dynamique	62
2.2.2	Exemple d'application de la DP : «Le plus court chemin».	64
2.2.3	La malédiction de la grande dimension	65
2.2.4	Programmation Dynamique et Programmation Stochastique	66
2.2.4.1	Familles de DP	67
2.2.4.2	Programmation Stochastique	68
2.2.4.3	Méthodes de construction de scénarios	74
2.2.5	Implémentation dynamique d'une optimisation	76
2.2.5.1	Forme de la politique	77
2.2.5.2	Off-line, Online	78
2.2.5.3	Choix d'une politique	79
2.2.6	Choix de la programmation dynamique probabiliste PDP	80
2.2.7	Méthode de référence SDDP	83
2.3	Conclusion	85

2.1 Optimisation en gestion de l'énergie

Les sources d'énergie intermittentes telles que le solaire ou le vent sont productrices d'une énergie très fluctuante. En effet, l'énergie fournie par ce type de ressources est très variable dans le temps et elle est non contrôlable. Cela implique que des stratégies de contrôle et de gestion sont nécessaires dans leur utilisation. Ces stratégies sont d'autant plus importantes que le réseau permettant leur distribution doit absolument être fiable, c'est-à-dire fournir et garantir la qualité de l'énergie. Cette fiabilité se mesure par exemple par la capacité d'un réseau électrique à maintenir sa tension et sa fréquence à des valeurs conformes aux tolérances réglementaires (par exemple : une tension de $230V \pm 10\%$ et une fréquence de $50Hz \pm 0.05Hz$ en France). Les réseaux électriques sont traditionnellement dominés par une production issue d'unités de production conventionnelles (nucléaire, thermique ou hydroélectrique). Ces unités conventionnelles utilisent des machines tournantes disposant d'inerties et permettant d'assurer en partie la stabilité du réseau électrique en cas d'incident. D'autres dispositifs de régulation tels que les systèmes de stockage et des réserves peuvent être présents sur le réseau.

Pour les réseaux électriques, les organes de régulation agissent sur des échelles de temps très courtes, allant de la microseconde à quelques minutes. Par contre, à des échelles de temps plus grandes, les opérations se concentrent sur l'équilibre énergétique entre la production et la demande. De plus, avec l'ouverture du marché de l'électricité, le prix de l'énergie est basé sur des tarifs variables (attractifs et/ou pénalisants) en fonction de la disponibilité d'énergie sur le réseau. De ce fait, les utilisateurs et producteurs d'énergie ont intérêt à optimiser leurs échanges énergétiques avec le réseau. Les travaux de cette thèse se concentreront sur l'optimisation des échanges d'énergie et ne couvriront pas le dimensionnement des dispositifs électriques.

L'objectif principal de toute opération des acteurs d'un système énergétique est de répondre simultanément à la demande d'énergie avec un coût minimum et un niveau de fiabilité acceptable. Pour atteindre ces objectifs, il est nécessaire de trouver une combinaison optimale des moyens de production et de consommation (ou *demand-side management*) en fonction de leur disponibilité et de leur coût d'utilisation. Cette action consiste à planifier à chaque instant la bonne combinaison. Dans le cas d'un microréseau où le seul moyen complètement contrôlable est un stockage d'énergie, ce processus est supervisé par un système de gestion de l'énergie (EMS). Dans le cas d'un réseau électrique disposant de multiples sources de production, ce processus consiste à planifier l'engagement des moyens de production et on utilise couramment sa dénomination anglophone « *Unit Commitment* » (UC) pour le décrire.

La planification de l'UC est un problème qui date des années 40 (fig 2.1). La production de base est essentiellement générée par des centrales hydroélectriques, à charbon, au fioul lourd ou nucléaire. Elle est complétée par des moyens d'appoint tels que des turbines diesel ou à gaz qui sont mobilisés lors des courts pics de consommations. Suite à la crise pétrolière dans les années 70, de nombreux gouvernements ont fait le choix de la sécurisation de l'approvisionnement de l'énergie en passant par le développement des systèmes exploitants les ressources renouvelables. En effet, les EnR ont été mises en avant comme étant une solution pour sortir de la dépendance vis-à-vis des pays producteurs de pétrole. Comme on le voit sur la figure 2.1, que ce soit le solaire ou l'éolien, la véritable intégration des EnR n'a commencé que dans les années 80. Après la libéralisation du secteur de la production d'énergie dans les années 90, l'accroissement de l'incorporation des énergies renouvelables intermittentes dans les mix de production a été plus marqué.

Le rapport de Zhou et al. [1] montre que les incertitudes dans la planification de l'UC ont

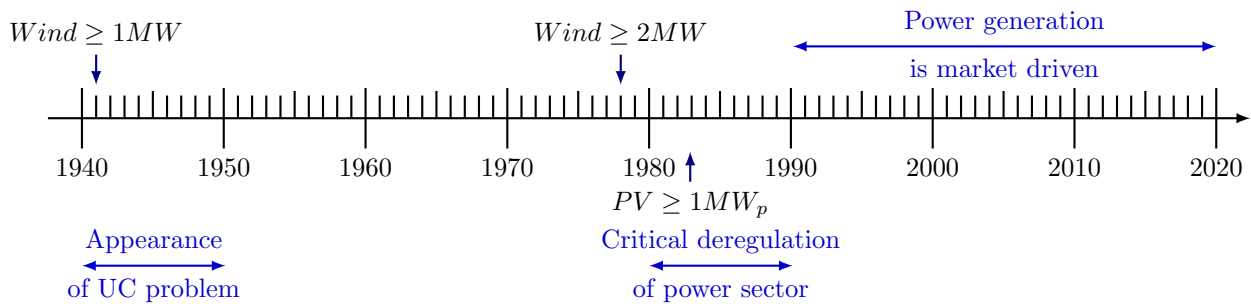


FIGURE 2.1 – Quelques références temporelles sur la prise en compte des EnR intermittentes dans les problèmes de planification d’UC

commencé à être prises en compte dans les années 1980. Pour compenser les fluctuations de la consommation, aussi appelée charge, les pertes dans les lignes de transport ou bien les pannes des équipements du réseau. Des travaux comme ceux de Dillon et al. [2] ont proposé le recours à des réserves probabilistes avec des méthodes d’optimisation type **B&B (Branch and Bound)**. Depuis, la quantification de cette réserve a ouvert la voie à d’autres types d’optimisation stochastique comme celle de Merlin et Sandrin [3] qui utilise la relaxation de Lagrange **LR**. L’approche la plus utilisée consiste à modéliser les incertitudes comme étant des distributions de probabilité. La majorité des méthodes mettant en œuvre l’optimisation stochastique telle que décrit par Zhou et al. [1], Abdou et Tkiouat [4] ou par Ruszczyński et Shapiro [5] utilise cette approche.

L’introduction des EnR intermittentes a rajouté de la complexité aux incertitudes déjà existantes. En effet, les EnR intermittentes ne sont pas contrôlables et présentent une forte variabilité temporelle à très court terme comparé aux autres EnR (géothermie, hydraulique, biomasse, etc.). Une bonne connaissance de la disponibilité future des EnR intermittentes permet d’anticiper leurs fluctuations. Des prévisions de qualité quantifiant les incertitudes associées à la production permettent donc de mieux les intégrer dans les réseaux d’énergie.

Au niveau des réseaux électriques de grandes dimensions, les EnR intermittentes ne constituent pas actuellement la part principale de la génération électrique. Avec les configurations traditionnelles du réseau, c’est-à-dire une production de base assurée par des moyens conventionnels utilisant des ressources fossiles, une limitation de la part d’EnR intermittentes est même fixée 30% de la puissance produite [6], en raison de l’absence d’inertie des systèmes de production utilisant ce type d’énergie renouvelable.

Le travail d’Abujarad et al. [7] propose 5 classes principales d’optimisation UC en présence d’une forte pénétration des EnR intermittentes comme présenté dans la figure 2.2. Selon les méthodes, l’incertitude due à l’intermittence est modélisée différemment. Les méthodes de résolution de l’UC peuvent être séparées en 2 groupes, avec et sans réserve. Comme ce travail concerne principalement l’utilisation de la prévision, les UC avec dispositifs de réserve ne seront pas considérés. Les options restantes sont l’UC stochastique et l’UC interval. Et puisque l’UC intervalle est un cas particulier de la stochastique, la formulation générale (stochastique) sera considérée.

Néanmoins, pour l’optimisation en présence d’incertitude, selon Sahinidis [8], il existe deux méthodes classiques principales, l’optimisation stochastique et l’optimisation floue. L’optimisation stochastique est largement étudiée dans la littérature des problèmes d’UC. En revanche, l’optimisation floue est quasiment inexistante pour résoudre ce type de problème. De plus,

l'ajout de l'ambiguïté et de l'imprécision dans la formulation d'un problème d'optimisation complexifie l'interprétation des résultats et des influences des prévisions pour un système, c'est pourquoi l'optimisation floue ne sera pas discutée plus avant.

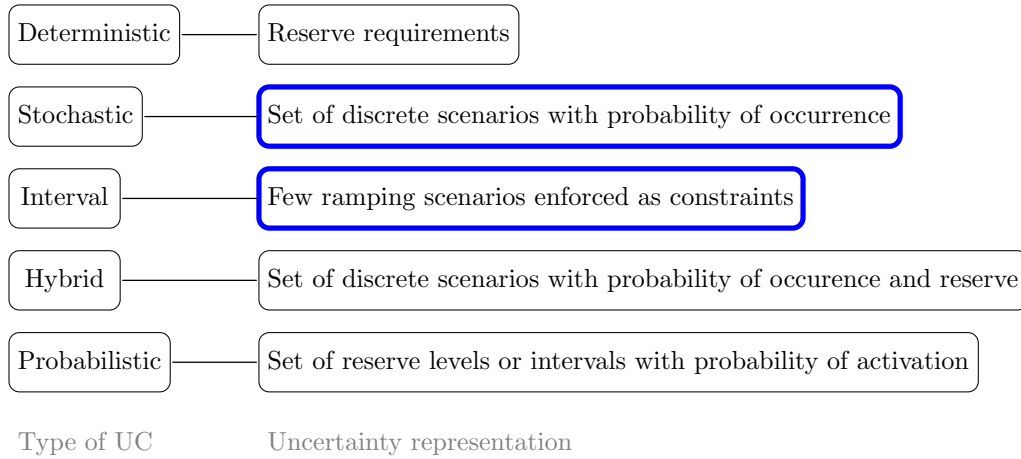


FIGURE 2.2 – Modèles UC prenant en compte la forte pénétration des EnR intermittentes suivant les travaux d'Abujarad et al. [7]

D'où, deux approches différentes (fig 2.3) coexistent dans la gestion des réseaux intégrant une part significative d'EnR intermittentes et leurs utilisations dépendent du gestionnaire du réseau :

1. L'approche la plus répandue qui modélise toutes les incertitudes de la même manière en générant des distributions à partir de données historiques comme celle de Takriti et al. [9] et considérant ces perturbations comme étant des variables indépendantes.
2. L'approche utilisant les prévisions à court terme comme entrées de modèles d'optimisation.

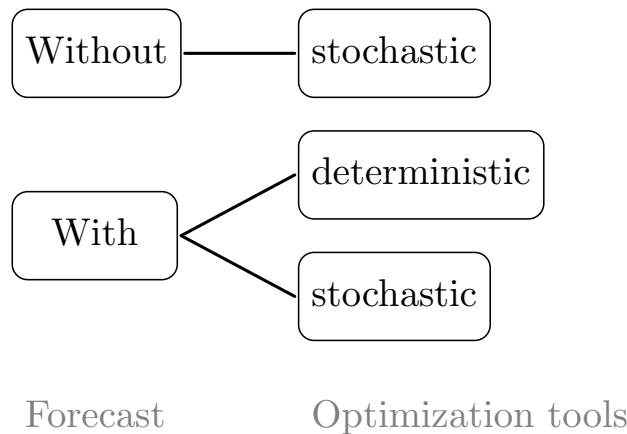


FIGURE 2.3 – Les deux méthodes de prises en compte de la production des EnR intermittentes pour l'optimisation des problèmes de planification d'UC dans les réseaux électriques.

Un autre aspect important est l'infrastructure du réseau. L'intégration massive de ces énergies intermittentes conduit à deux considérations pour le réseau existant :

1. **Le foisonnement** [10] qui consiste à disperser spatialement les EnR intermittentes afin d'obtenir une production plus lisse avec moins de fluctuation en bénéficiant de la variabilité spatiale de la ressource.
2. **La reconfiguration** [11] implique le remplacement, l'ajout de lignes de transmission et de dispositifs de stockage pour réduire la congestion et permettre le transport de l'énergie sur de grandes distances.

Cet aspect de la structure du réseau ne sera pas abordé dans ce travail, il se limitera à la gestion de l'énergie et à la prise en compte des incertitudes de la production des EnR intermittentes.

2.1.1 Optimisation sans prévision

Avant les années 80 [4], la génération était essentiellement basée sur des centrales thermiques. Les incertitudes considérées étaient les pertes en ligne et les charges. Ce même raisonnement a conduit à considérer les EnR intermittentes comme des perturbations que l'on peut modéliser avec des distributions de variables aléatoires.

Le profil de charge est une illustration de cette approche qui consiste à dire que chaque jour un profil moyen est perturbé par des incertitudes. Les incertitudes sont des variations aléatoires autour du profil de charge moyen. La procédure consiste alors à modéliser les incertitudes à partir de la distribution de la différence entre l'historique et le profil de charge moyen. Ce type de prise en compte des incertitudes s'apparente à ce qu'on appelle habituellement la "climatologie" dans le domaine des prévisions météorologiques.

L'optimisation stochastique est très utilisée dans le domaine de l'énergie comme le présente Wallace et Fleten [12], qui va de l'utilisation de l'électricité, du pétrole, à l'exploitation de gisements de gaz et Powell [13] a listé un nombre important de nom de méthode d'optimisation traitant de l'optimisation stochastique. Selon la nature de l'optimisation stochastique (considération du pire cas possible, de la chance qu'un évènement se produit, etc.), Ruszczynski et Shapiro [5] ont classé un certain nombre de ces méthodes dans ce qui est dénommée programmation stochastique (SP). Par contre, d'autres auteurs qui se sont appuyés sur les travaux de Bellman [14] ont recours à la programmation dynamique stochastique (SDP). La SP est basée sur la séparation de la résolution en un problème principal et des sous-problèmes. Les sous-problèmes prennent en compte les variables aléatoires. La SDP quant à elle décompose le problème en problèmes élémentaires et tous ces problèmes élémentaires sont résolus successivement. Pour la résolution, des problèmes de planification d'UC, (SP et SDP confondues), une méthode très répandue consiste à générer un ensemble de scénarios pour représenter la distribution de l'incertitude de l'entrée, comme la production éolienne ou la charge [1]. L'approche la plus populaire consiste à générer des scénarios avec une simulation de Monte-Carlo, afin de produire les réalisations de variables aléatoires à partir de fonctions de distributions paramétriques qui sont calibrées à partir de données historiques [1, 5].

Ce type d'optimisation stochastique offre un grand nombre d'applications. Par exemple, appliqué avec la programmation linéaire, la *programmation dynamique duale stochastique* (SDDP) a été utilisée pour contrôler plus de 39 générateurs hydroélectriques soumis à des variations de la pluviométrie [15], ou bien pour le contrôle d'une maison intelligente [16] avec un générateur PV et un système de stockage d'énergie (ESS). La SDP, quant à elle, a été utilisée afin de contrôler un stockage d'énergie associé à un houlo-générateur pour un lissage de puissance [17]. Par contre, il est à noter que ce type d'optimisation stochastique, basé sur des scénarios, présente quelques inconvénients :

- **Le temps de calcul** [18] : pour que l'optimisation soit réaliste, le nombre de scénarios doit être conséquent en raison de la *loi des grands nombres* [19]. Chaque scénario représente une résolution à effectuer.
- **L'échantillonnage** [20] : afin de reproduire fidèlement la distribution réelle des variables aléatoires, il est théoriquement nécessaire de générer une infinité de scénarios. La méthode d'échantillonnage influe donc beaucoup sur la qualité de l'échantillon généré. Les scénarios doivent être représentatifs des distributions réelles des variables aléatoires, être indépendants les uns des autres et distribués uniformément.
- **La décomposition** [21] : pour pouvoir résoudre une SP, on a recours à un modèle déterministe équivalent. Afin de construire la solution, le problème est divisé en 2 ou plusieurs étages à l'aide d'algorithmes de décomposition. On découple le problème, en une version déterministe qui constitue le premier étage, aussi appelé problème principal, et en une version intégrant les incertitudes (le second étage ou étages inférieurs). Les solutions des étages inférieurs doivent être des solutions du problème principal. L'existence d'une solution ou d'une convergence de solutions dans ce cas dépend du problème et de la technique de décomposition choisie.
- **Le principe de non-anticipation** [22] : ce principe postule que l'on ne peut pas voir le futur, de ce fait en SP, les incertitudes sont considérées comme étant des variables aléatoires indépendantes. Or dans le cas des EnR intermittentes, il existe une dépendance temporelle au niveau des fluctuations comme décrites les travaux de Pinson et al. [23].

Pour l'implémentation de la SDDP dans la gestion de l'énergie, le lecteur peut se référer à la section 2.2.4.

2.1.2 Optimisation et prévision

Lorsque le marché de la génération d'énergie a été ouvert à la libre concurrence, des producteurs indépendants pouvaient désormais fournir de l'énergie. En ce qui concerne les EnR intermittentes, le coût de vente au réseau dépend principalement de la disponibilité de la ressource, d'où l'intérêt croissant pour la prévision. Avec l'intégration progressive des EnR intermittentes à partir des années 80, la prévision a évolué (fig. 2.4). Elle est passée de prévisions déterministes, aussi appelées prévisions "point", vers des prévisions probabilistes. Le vent étant le précurseur des EnR intermittentes, l'état de l'art sur la prévision de ce dernier est plus abouti. Le solaire quant à lui est plus récent et la prévision probabiliste dans le solaire en est à son début.

Dans les années 2000, l'approche déterministe était la plus étudiée et la plus utilisée. Or, les méthodes déterministes génèrent une incertitude due à l'erreur des modèles. Le fait d'introduire les incertitudes dans les prévisions apporte une indication supplémentaire sur la disponibilité de la ressource et sur les risques liés à cette disponibilité. Ces incertitudes ont tout d'abord été modélisées à partir de loi normale comme l'illustre bien le travail de Lorenz et al. [27] qui est l'un des tout premiers dans le domaine du solaire. Plus récemment, on a eu recours à la modélisation des incertitudes avec des modèles non paramétriques [32] affichant une fiabilité croissante.

Sur la figure 2.1, on voit que le développement de l'éolien était en avance par rapport à celui du solaire. Cela a aussi été constaté au niveau des techniques de prévisions (fig. 2.4).

Dans la suite, les différentes approches utilisant la prévision seront abordées. Tout d'abord, nous nous focaliserons sur une approche purement déterministe. Ensuite, la commande pré-

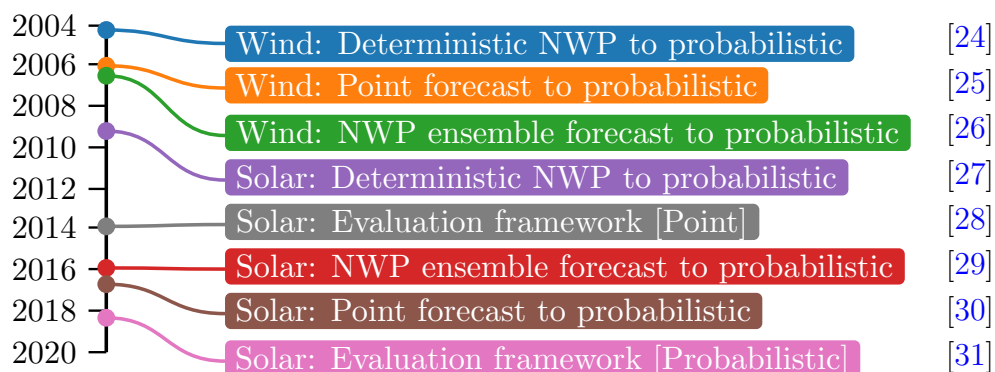


FIGURE 2.4 – Évolution des prévisions des EnR intermittentes au cours des 20 dernières années

dictive de modèle (MPC) sera présentée. Il s’agit d’une approche intermédiaire qui convient aussi bien à la résolution des problèmes déterministes que stochastiques. Enfin, les approches probabiliste et stochastique seront présentées.

2.1.2.1 Approche purement déterministe

Pour les problèmes de planification d’UC, l’optimisation peut être formulée avec ou sans prévision. L’approche déterministe est la plus simple et elle a fait l’objet de nombreuses applications [33, 1, 4]. Dans la littérature, que ce soit pour les microréseaux ou bien les réseaux de transport d’électricité, le principal objectif des optimisations est de réduire le coût de fonctionnement et plus précisément celui du fonctionnement des centrales thermiques (CCHP) [34, 35]. Pour la résolution des problèmes de planification d’UC avec une approche déterministe, deux principales méthodes sont présentes dans la littérature : les méthodes à méta-heuristique et les méthodes classiques. Les méthodes dites méta-heuristiques sont relativement simples d’utilisation, car elles ne nécessitent pas de conditions spécifiques (convexité, continuité, linéarité ou monotonie) pour optimiser le fonctionnement d’un système, en plus de permettre d’obtenir un optimum global sous certaines conditions. Une multitude d’algorithmes de ce type a été mise en œuvre pour les problèmes de planification d’UC : Recuit simulé (SA), ICA (Imperialist Competition Algorithm), Algorithme de colonies de fourmis (ACO), HASP (Hybrid Ant System Priority List), EP (Evolutionary Programming), Optimisation par essais particulaires (PSO), Algorithme mémétique (MA) [35], NEA (Niching Evolutionary Algorithm), Algorithme génétique (GA) [36], la recherche Taboue (TS), algorithme de Lucioles FF [7], HC (Hill Climbing) [34]. Par contre, ce type d’optimisation souffre d’un temps d’exécution élevé et incertain [7]. Par exemple, les GA utilisent des fonctions complexes dans les opérateurs de sélection et de croisement, et parfois le schéma d’encodage est difficile, car les solutions sont représentées en binaire sous forme de chaînes de 0 et 1 [37]. En outre, les techniques comme le PSO sont connues pour aboutir vers des solutions locales. Le véritable défi dans l’utilisation de ce type de méthodes réside dans le fait que ces algorithmes ont des paramètres de réglage qui doivent être calibrés selon l’optimisation à réaliser [37].

Il est important de noter que, bien que, ces outils s'appuient sur des opérateurs probabilistes dans leur fonctionnement et leur résolution, cette caractéristique est rarement exploitée dans la formulation du problème d'optimisation. Ces méthodes sont souvent utilisées comme *boîtes noires* pour l'optimisation globale. Par exemple, pour une optimisation avec une prévision déterministe, l'utilisation d'outils méta-heuristique type GA conduirait au même résultat que l'utilisation d'un outil d'optimisation globale comme la DP. En outre, selon Juan et al. [38], pour tenir compte des incertitudes des variables d'entrées à travers une optimisation méta-heuristique, l'hybridation est nécessaire. Souvent, l'hybridation est une amélioration de la méthode méta-heuristique en la couplant avec d'autres méthodes. La méthode méta-heuristique est couplée à la simulation ou à la construction de scénarios, telle est le cas des travaux de Jo et Kim [39] ou de Maghsudlu et Mohammadi [40] pour les problèmes d'UC. De plus, la revue de la littérature de Bianchi et al. [41] a montré que l'hybridation est principalement basée sur la sélection de scénarios. Cependant, la sélection de scénarios n'est qu'une variante des traitements de scénarios pour l'optimisation stochastique, qui sera discutée plus en détail dans la section 2.2.4.3. Par conséquent, l'approche d'optimisation dite méta-heuristique sera restreinte à sa version déterministe.

Suivant la classification d'Abujarad et al. [7], les méthodes purement déterministes les plus utilisées, que l'on a appelées classiques auparavant sont : la programmation linéaire avec nombres entiers (MILP), la programmation non linéaire (NLP), la programmation dynamique (DP), la programmation quadratique (QP) et le Branch and Bound (B&B). À notre connaissance, la DP et le MILP ont déjà été utilisés avec des prévisions déterministes d'EnR intermittentes pour résoudre des problèmes de planification d'UC. Par exemple, Riffonneau et al. [42] a montré que pour un microréseau disposant d'une centrale PV et d'un système de stockage par batteries, une prévision simulée (généré à partir d'une fonction sinusoïdale avec perturbation) de la production PV, la DP permet de réduire considérablement le coût de fonctionnement du système par rapport à un système sans commande prédictive. De même, avec des prévisions réalistes (ENN (Elman Neural Network), WNN (Wavelet Neural Network), ARIMA (AutoRegressive Integrated Moving Average models)), Yang et al. [43] ont montré qu'une optimisation utilisant un MILP permet d'obtenir un gain de 4.5% (ARIMA) sur le coût de fonctionnement d'un système de production hybride éolienne-PV couplé avec un système de stockage par batteries.

2.1.2.2 Commande prédictive de modèle (MPC)

Parallèlement, pour le contrôle optimal, une approche consiste à utiliser un modèle de contrôle en temps réel. L'approche dite *commande prédictive de modèle* MPC est très utilisée dans le contrôle de systèmes [44]. C'est une optimisation qui génère elle-même sa prévision et met à jour le modèle en fonction de l'arrivée de nouvelles mesures. Le MPC a été initialement créé pour le contrôle de trajectoire [44]. Le MPC utilise en général une méthode statistique de série temporelle pour générer les prévisions telles que le modèle CARIMA, qui à chaque pas de temps génère plusieurs horizons de prévisions ($t + 1, t + 2, t + n$) et plusieurs scénarios (fig. 2.5). Les scénarios sont généralement créés à partir de propagation des erreurs. Par contre, le MPC n'exécutera que la première décision obtenue par l'optimisation et le processus est répété à chaque pas de temps (fig. 2.6). Comme dans le cas d'un filtre de *Kalman récursif* [45], l'optimisation se fait par mise à jour d'une matrice de covariance A_t , lorsque de nouvelles données arrivent. Ensuite, le MPC met à jour la matrice de contrôle pour modifier la sortie.

Des versions stochastiques ont été implémentées dans cet esprit. Nous pouvons citer le cas du contrôle de l'état de charge d'un stockage d'énergie dans un système alimenté par un générateur éolien [46] ou par un générateur PV [47].

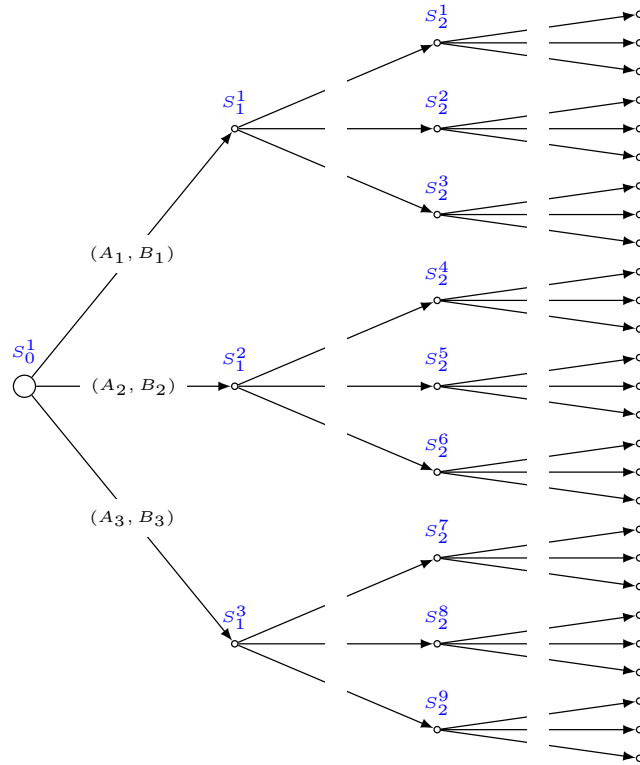


FIGURE 2.5 – Schéma de fonctionnement d'un MPC générant 3 scénarios pour chaque pas de temps futurs. Les S_i^j correspondent aux états du système à l'instant initial ($i = 0$) et pour les j scénarios représentant les futurs possibles ($i > 0$). A_t et B_t sont respectivement les matrices de covariances et les matrices d'incertitudes utilisées pour la construction de l'arbre

Le MPC est une solution efficace pour réaliser une régulation en temps réel, c'est-à-dire des contrôles avec des pas de temps très court (microsecondes-minute). En général, la fonction objective est une minimisation de la différence entre une consigne et la sortie d'une machine. De plus, cette fonction à minimiser est souvent quadratique. Le coût de fonctionnement peut prendre des valeurs négatives ou positives. Les changements de signes du coût conduisent le plus souvent à des décisions différentes pour le système. Comme dans le cas d'une gestion d'énergie où un coût positif correspondrait à un achat, alors qu'une valeur négative correspondrait à une vente. Une fonction objective de forme quadratique considèrera de la même manière les écarts négatifs et positifs. De ce fait, le MPC n'est pas la méthode la plus adaptée pour optimiser un coût de fonctionnement en utilisant des prévisions réelles à court terme (plusieurs heures ou jours à l'avance).

2.1.2.3 Approches probabiliste et stochastique

Les problèmes de planification d'UC font obligatoirement face à des incertitudes. Ces incertitudes sont dues aux erreurs de prévisions (consommations, productions, météorologies), à des aléas prévisibles ou non (défaillance des équipements, pertes en ligne) ou bien au comportement




FIGURE 2.6 – Fonctionnement du MPC pour une optimisation de t à $t + 3$, à chaque pas de temps il exécute une optimisation identique à celle de la figure 2.5

des acteurs interagissant sur le réseau (fluctuation du marché de l'énergie, cotation en bourse). La prise en compte de ces incertitudes se traduit par l'utilisation d'algorithmes d'optimisation dite stochastiques ou probabilistes. La littérature sur l'intégration de ces incertitudes dans la résolution des problèmes de planification d'UC est vaste [1, 4, 7, 48, 49]. De même, la classification des problèmes d'UC en présence d'incertitudes diffère très largement selon les auteurs. Ce qui amène par exemple à l'existence de problèmes d'UC stochastique, probabiliste, à intervalle, robuste, contraint par hasard, à heuristiques qui incluent la probabilité de l'occurrence du besoin en réserve, soumise à des contraintes de sécurité ou basée sur le prix. En réalité, les classements des problèmes de planification d'UC ont été largement inspirés par la combinaison entre l'objectif du gestionnaire du réseau et la méthode d'optimisation utilisée pour la résolution du problème. À l'exemple de la méthode robuste, qui fait référence à un problème de planification d'UC dont l'objectif est d'assurer la sécurité de l'approvisionnement en utilisant un algorithme d'optimisation robuste.

Or, dans le domaine de l'optimisation stochastique, il existe une multitude de méthodes et d'algorithmes dont la classification même reste très compliquée et sujette à interprétation [50]. Les problèmes de planification d'UC stochastiques peuvent par exemple référer à une programmation dynamique stochastique (SDP) [17], une programmation dynamique approximative (ADP) [33], à l'utilisation de la programmation stochastique (SP) [51], à une utilisation de la décomposition «Progressive Hedging» [52], ou bien à l'assouplissement des contraintes dites de non-anticipation avec résolution déterministe de tous les scénarios [48]. Certains auteurs comme Shiina et Birge [53] ou Håberg [49] ont classé les problèmes de planification d'UC suivant la structure de l'équation à résoudre. En reprenant la classification de la programmation stochastique de Ruszczyński et Shapiro [5], pour Håberg [49], il n'existe plus que 2 classes d'UC : une formulation en 2 étages et une formulation en étages multiples. En s'affranchissant des méthodes d'optimisation et suivant le travail de van Ackooij et al. [48] nous proposons une structuration en 3 classes :

- **Stochastique.** Pour l'optimisation stochastique, il est supposé que les distributions des incertitudes sont connues. Les incertitudes sont modélisées par des distributions ou par des scénarios. Souvent, cette optimisation s'apparente à la planification pour le lendemain ou bien au contrôle en temps réel.

- **Robuste.** Dans un souci de sécurité, on a recours à ce type de résolution. Elle existe en raison de simplifications et dans le cas où la distribution n'est pas forcément connue. Les scénarios ou distributions ne reflètent plus les tous les états possibles des incertitudes. Les scénarios générés se limitent à des intervalles [54] ou à des scénarios avec probabilité. Dans certains cas, comme l'intervalle, elle permet d'utiliser un ensemble d'incertitudes prédéfinies comme sûres. Les intervalles représentent souvent les états extrêmes (pires cas). Ce type d'optimisation offre une sécurité accrue pour le gestionnaire du réseau, mais engendre des coûts de fonctionnement plus important par rapport à l'optimisation stochastique, car il aboutit fréquemment à un surdimensionnement des réserves.
- **Probabiliste.** Le principe réside sur des échantillonnages ou sélections de scénarios pour approximer la distribution réelle des variables aléatoires. Comme pour le cas robuste, on se retrouve avec un nombre réduit de scénarios [55], mais les variables d'entrées du modèle sont modélisées par leurs quantiles. Cette méthode regroupe aussi les méthodes appelées optimisations de contrainte par hasard. Le vrai problème de l'utilisation de ce dernier est l'interprétation des résultats, car ils correspondent à des probabilités calculées. Pour ce troisième cas, les méthodes robuste et probabiliste ont quasiment la même formulation du problème de planification d'UC.

Comme vue précédemment, dans un problème de planification d'UC, un ensemble de scénarios est utilisé pour représenter la distribution d'intrants incertains. Les scénarios peuvent être des distributions de probabilité (PDF) ou des scénarios discrets en nombre fini [1]. Dans le cas d'optimisation à étages multiples [49], il est nécessaire de construire un arbre de scénarios (fig. 2.7). Une probabilité est assignée à chaque scénario. Et comme dans le cas du MPC, à chaque pas de temps, lorsque de nouvelles mesures sont disponibles, l'optimisation est relancée ou mise à jour.




FIGURE 2.7 – Exemple d'arbre de scénarios : 5 scénarios avec 10 noeuds pour une optimisation multi-étape (4 étapes)

Pour que ces méthodes utilisant les scénarios soient valides, il est impératif que l'arbre de scénarios capture la corrélation et l'évolution des incertitudes entre les pas de temps (entre les étapes). À partir de l'historique des données ou de prévisions, une loi de distribution empirique

est construite. La génération de scénarios peut se faire avec des simulations Monte-Carlo pour produire la réalisation de variables aléatoires suivant cette loi.

Le cas utilisant uniquement des données historiques correspond à l'optimisation sans prévision décrite dans la partie (2.1.1). Dans la majorité des cas, une simulation de Monte-Carlo permet de générer les scénarios comme décrits par Shiina et Birge [53]. L'inconvénient de l'approche utilisant uniquement des données historiques réside dans la sous-estimation, voire la non-prise en compte, des effets des corrélations et des évolutions des variables aléatoires. Pour Shapiro et Nemirovski [56], l'utilisation de données historiques ne permet pas d'estimer avec précision la distribution de probabilité ou son évolution dans le temps. En effet, les scénarios sont associés à des probabilités attribuées par un jugement subjectif.

Afin de considérer simultanément les évolutions temporelles et les corrélations des variables aléatoires, le recours à des prévisions déterministes ou probabilistes est une solution :

- À partir des prévisions point, des scénarios sont construits par la méthode de Monte-Carlo directement à partir des erreurs de prévision [1]. Il existe des outils tels que celui proposé par Barth et al. [57] qui permet de générer directement des arbres de scénarios. L'arbre est construit à partir de simulations de Monte-Carlo des erreurs de prévision d'une série chronologique de moyennes mobiles autorégressives (ARMA(1, 1)). La dépendance temporelle est représentée par une décomposition de Cholesky de la matrice gaussienne corrélée d'une série temporelle ARMA multidimensionnelle. Ce type d'outil a largement démontré son efficacité dans la gestion à court terme (planification toutes les 3 heures) [58, 59, 60, 61, 62] de la production éolienne à grande échelle pour les cas d'optimisation stochastique.
- Pour le cas de prévisions solaires [31], il existe 3 classes de prévisions probabilistes : les prévisions d'ensemble (EPS), les prévisions qui suivent des lois de distribution paramétrique (loi normale ou gamma par exemple) et les prévisions issues de modèles non paramétriques. Or, pour les problèmes de planification d'UC, les meilleures candidates sont les prévisions corrélées spatio-temporellement comme les prévisions par images satellites, par imagerie au sol (*sky imagers*), multivariées ou ensemblistes issues de modèles numériques du temps (NWP). Ces dernières sont générées à partir des sorties de modèles physiques de l'état de l'atmosphère.

Pour les prévisions suivant des lois de distribution paramétriques, l'approche proposée par Botterud et al. [63] ou Wang et al. [64] consiste à construire les scénarios en 2 étapes. Tout d'abord, à partir des erreurs de prévision point du jour à venir, des prévisions probabilistes sont construites. Ensuite, ces prévisions permettent la construction de scénarios. Par exemple, Wang et al. [64] ont utilisé une régression quantile (QR) pour construire la prévision probabiliste du vent pour le jour à venir à partir d'une prévision déterministe. Pour la régression quantile, les 2 prévisions consécutives sont produites indépendamment. Ce qui implique que, la corrélation de l'erreur de prévision des pas de temps consécutif n'est pas prise en compte. Une étape supplémentaire comme la transformation proposée par Pinson et al. [65] est donc nécessaire pour générer des scénarios à partir de prévisions probabilistes. Cette méthode de transformation repose sur un échantillonnage de Monte-Carlo. L'interdépendance temporelle est représentée par une matrice de covariance obtenue en considérant que les prévisions suivent un processus gaussien multivarié.

Les méthodes de génération et d'intégration des prévisions probabilistes de production d'EnR intermittentes sont schématisées dans la figure 2.8.




FIGURE 2.8 – Génération et utilisation de prévisions probabilistes d’EnR intermittentes dans les problèmes d’optimisation (Li et Zhang [66])

2.1.3 Analyse critique

L’intégration des variables aléatoires dans la planification se fait de 2 manières. La plus commune passe par la création de scénarios. Or, les fluctuations des EnR intermittentes comme le solaire ou l’éolien sont très fortement corrélées dans le temps et dans l’espace. Les interdépendances et corrélations dans le cas des scénarios sont représentées par des matrices de probabilités. Ces matrices de probabilités sont construites à partir de matrices de covariance des erreurs de prévision [57], de matrices de corrélations des variables aléatoires [67] ou encore de la corrélation temporelle des prévisions [65]. De plus, la majorité des méthodes d’optimisation stochastique appliquées aux problèmes de planification d’UC est soumise à la contrainte de non-anticipation, donc une considération des variables aléatoires comme indépendantes. Cette contrainte conduit à l’utilisation d’approximations telle que la relaxation lagrangienne LR.

Or, certaines prévisions probabilistes, de par leur nature, sont supposées être capables de capturer les dépendances et corrélations temporelles. Une intégration directe de ce type de prévisions dans l’optimisation pourrait donc permettre d’aboutir à de meilleurs résultats dans la résolution des problèmes de planification d’UC.

Dans ce qui suit, l’accent sera mis sur les méthodes d’optimisation stochastique et notamment sur :

- Le principe d’optimalité et les fondements de la programmation dynamique (DP),
- L’utilisation de l’optimalité avec un exemple de DP,
- Les familles d’optimisation stochastiques,

- La généralisation des classes d’optimisation stochastique,
- Le choix de la méthode d’optimisation retenue pour intégrer les prévisions des EnR intermittentes dans la résolution de problème d’UC,
- La définition d’une méthode d’optimisation de référence, dite de *benchmark*, qui n’utilisera pas les prévisions.

2.2 Optimisation stochastique

Afin de considérer de manière correcte tout système réel, il est important de tenir compte des incertitudes. Il existe de nombreuses sources d’incertitudes, le comportement des utilisateurs (charge), les variations climatiques (vent, rayonnement solaire, niveau de précipitations), les fluctuations du marché de l’énergie ou encore le risque de défaillance des équipements. Une large revue de la littérature [35, 33, 7, 49, 66] sur la prise en compte de l’incertitude existe. Dans le cas des EnR, la programmation stochastique SP [1, 4, 53] est une des méthodes les plus utilisées.

Le terme optimisation stochastique désigne un grand nombre de méthodes d’optimisation ayant attrait à la probabilité ou à l’incertitude. La différenciation entre ce qui est stochastique ou non stochastique dépend de l’utilisation. Dans le domaine de l’énergie [1, 66] par exemple, on différencie les méthodes robustes, min-max regret, intervalle, ou stochastique probabiliste alors que leur formulation mathématique et leur résolution appartiennent à une même famille de programmation stochastique.

2.2.1 Principe d’optimalité et Programmation Dynamique

Développée initialement par Bellman [14], la programmation dynamique (DP) est très utilisée dans de nombreux domaines, tels que la gestion des réservoirs dont l’application sur la gestion de l’eau a été revue par Yakowitz [68] et les limites par Nandalal et Bogardi [69], le remplacement d’équipement dans les exemples de Winston [70] sur la recherche opérationnelle, le contrôle aérien présenté par Powell [71], les processus d’ordonnancement dans la collection de Gulli [72] sur les DP résolus en C++, l’allocation de ressources uni/multidimensionnelle traitée par Bellman et Dreyfus [73], pour un problème à espace continu comme la solution au *brachistochrone* proposée par Roberts [74] ou la gestion de systèmes de stockage électrique traitée par Riffonneau et al. [42] dans le cas de l’énergie photovoltaïque et par Haessig et al. [17] dans le cas d’houlo-générateurs. Son extension au contrôle optimal des systèmes a été vulgarisée par Bertsekas [75].

La philosophie de la DP consiste à décomposer un problème en sous-problèmes qui peuvent être résolus récursivement (figure 2.9). La méthode s’appuie sur le principe d’optimalité. « *An optimal policy has the property that whatever the initial state and initial decision are, the remaining decisions must constitute an optimal policy with regard to the state resulting from the first decision* » [14]. En d’autres termes, l’objectif de la DP est de trouver la *politique* optimale pour chaque sous-structure (ou état S_t) du problème et de résoudre le problème de manière récursive.

La plupart des optimisations avancent de la première étape ($t = 1$) à la dernière étape ($t = T$). Pour la DP, ce processus est appelé récursivité vers l’avant (*Forward recursion*), mais la plupart des problèmes impliquant des incertitudes sont traités avec la récursivité vers




FIGURE 2.9 – Principe de récursion de la DP de l'étape $T \rightarrow 1$

l'arrière, plus communément appelé en anglais *Bakward recursion*. À partir de maintenant, tous les processus de la DP de ce travail utiliseront la *Bakward recursion*, ce qui signifie que la première étape résolue est la dernière ($t = T$) et récursivement jusqu'à la première ($t = 1$).

Si on considère un problème de minimisation décomposable en T étapes, tel que décrit par l'équation 2.1, à chaque valeur de la décision x_t ($t = 1, \dots, T$) correspond une contribution $C_t(x_t)$ au coût total, aussi appelé *cost-to-go*. Donc, pour se trouver dans un état S_t , une décision x_t a été prise et un coût R_t est généré. La fonction objective J à minimiser correspond à la somme des coûts R_t de chacune des étapes.

$$J = \min \sum_{t=1}^T R_t = \min \sum_{t=1}^T C_t(x_t) \tag{2.1}$$

Dans le cadre de la minimisation, la *politique* optimale consiste à trouver toutes les décisions optimales qui conduisent à la valeur la plus faible de la somme des coûts. De manière récursive, l'équation 2.1 est écrite sous la forme générale par l'équation d'optimalité 2.2. Deux termes, γ et p , apparaissent dans cette formulation générale. Ils permettent de prendre en compte respectivement l'importance de la temporalité des décisions et les incertitudes liées à l'optimisation. Dans le domaine du contrôle optimal, cette équation est appelée *Hamilton - Jacobi - Bellman* (HJB). Pour le contrôle, dans certains cas, comme le cas de l'évitement d'obstacle de Sundar et Shiller [76], la résolution de l'équation HJB peut être effectuée par la méthode des gradients. D'autres auteurs comme Powell [50] nomment l'équation 2.2 *Forme canonique de l'équation de Bellman*. C'est cette formulation du problème d'optimisation, sous sa forme canonique, qui sera retenue et discutée dans ce travail.

$$V_t(S_t) = \min (C_t(x_t) + \gamma \times p \times V_{t+1}(S_{t+1})). \tag{2.2}$$

Avec :

- S_t état,
- x_t décision/action pour passer de l'étape t à l'étape $t + 1$
- γ se réfère à la perte de valeur d'une monnaie ou d'un actif financier au fil du temps (généralement $\gamma \leq 1$), plus la décision est loin dans le temps, plus l'effet sur la valeur finale est faible,
- p la probabilité de se trouver dans l'état S_{t+1} ,
- V_t valeur de la fonction objectif à l'étape t ,
- $C_t(x_t)$ Contribution de l'action x_t au coût en anglais cette fonction est communément appelée *cost-to-go*.

La combinaison des équations 2.1 et 2.2, pose la résolution du problème d'optimisation par récursion dite *backward* comme suit :

$$J = \min \sum_{t=1}^T R_t = \min \sum_{t=1}^T C_t(x_t) = V_1(S_1) \tag{2.3}$$

La DP peut être utilisée pour résoudre la majorité des problèmes d'optimisation. Par contre, son utilisation nécessite une formulation particulière du problème pour être solvable dans le cadre de cette dernière [70] :

- Le problème doit être subdivisé en étapes, une décision est requise à chaque étape,
- Chaque étape à un nombre d'états possibles qui lui est associée,
- La décision prise à une étape décrit l'évolution vers l'étape suivante,
- La décision optimale prise à une étape ne dépend pas des décisions prises aux étapes précédentes,
- Quand le nombre d'états N du problème est fini, il existe une récursion entre les coûts obtenus à chaque étape.

La DP est à la fois un outil d'optimisation et une méthode de résolution de problème.

2.2.2 Exemple d'application de la DP : «Le plus court chemin».

Pour bien comprendre la philosophie de la DP, je vous propose de l'illustrer avec l'exemple simple et bien connu du chemin le plus court (fig. 2.10). La personne à plusieurs choix de chemins possibles en visitant des villes appelées nœuds. L'objectif est d'aller de la ville A à la ville K par le plus court chemin possible. La récursion «*backward*», c'est-à-dire en partant de la ville d'arrivée vers la ville de départ, sera utilisée pour résoudre le problème. On part donc de l'état final vers l'état initial.




FIGURE 2.10 – Schéma de principe du problème du plus court chemin

Dans un cas purement déterministe, on utilise l'équation 2.2 avec $\gamma = 1$ et $p = 1$. L'étape 4 étant triviale, car les coûts (distances parcourues) sont déjà connus ($V_4(H) = 1030$, $V_4(I) = 1390$ et $V_4(J) = 1180$), la récursion commence réellement à l'étape 3 où les états E et F correspondent aux équations 2.4 et 2.5.

$$V_3(E) = \min \begin{cases} C_3(EH) + V_4(H) = 610 + 1030 = 1640, & E \rightarrow H \\ C_3(EI) + V_4(I) = 280 + 1390 = 1670, & E \rightarrow I \\ C_3(EJ) + V_4(J) = 500 + 1180 = 1680, & E \rightarrow J \end{cases} \quad (2.4)$$

$$V_3(F) = \min \begin{cases} C_3(FH) + V_4(H) = 540 + 1030 = 1570, & F \rightarrow H \\ C_3(FI) + V_4(I) = 940 + 1390 = 2330, & F \rightarrow I \\ C_3(FJ) + V_4(J) = 735 + 1180 = 1915, & F \rightarrow J \end{cases} \quad (2.5)$$

En appliquant la résolution «*Backward*» donnée par l'équation 2.2, le tableau 2.1 donne les distances et le chemin le plus court.

États	Valeur	Chemin
$V_3(E)$	1640	$E \rightarrow H$
$V_3(F)$	1570	$F \rightarrow H$
$V_3(G)$	1660	$G \rightarrow I$
$V_2(B)$	2320	$B \rightarrow E$
$V_2(C)$	2220	$C \rightarrow E$
$V_2(D)$	2150	$D \rightarrow E$
$V_1(A)$	2910	$A \rightarrow B$
$V_1(A)$	2910	$A \rightarrow D$

TABLE 2.1 – Valeurs aux états

Dans l'exemple proposé, l'optimisation aboutie à 2 chemins les plus courts possibles :

- $A \rightarrow B \rightarrow E \rightarrow H \rightarrow K$,
- $A \rightarrow D \rightarrow E \rightarrow H \rightarrow K$.

Le nombre de chemins optimaux est généralement réduit en augmentant le nombre de contraintes ou d'objectifs.

2.2.3 La malédiction de la grande dimension

La majorité des problèmes d'optimisation peut être résolue avec la DP, par contre il est nécessaire que les états des variables de décisions puissent être énumérés à chaque itération. Pour un intervalle $[0, 1]$ avec un pas de 0.01, on a 100 états possibles. Dans un espace $[0, 1]^{10}$ à 10 dimensions, avec un pas de discrétisation 10^{-n} on se retrouve avec $10^{n(10-1)}$ états possibles. La résolution directe de ce type de problème n'est pas tractable d'un point de vue informatique. C'est ce qu'on appelle la malédiction de la grande dimension ou en anglais «*curse of dimensionality*» [77]. Pour résoudre ce problème de grande dimension, on a recours à des méthodes de réduction de dimension [71, 75]. Il existe 3 types de malédictions [71] de la grande dimension :

- Les états possibles de l'espace de discrétisation : La variable d'état peut être un nombre réel ou un vecteur. Dans le cas où l'état serait un vecteur, la discrétisation des éléments caractérisant l'état peut être une matrice et le nombre d'éléments de cette matrice peut augmenter exceptionnellement.
- Les sorties possibles : Dans le cas où la sortie serait dépendante des variables aléatoires $\xi \in \Xi$ de dimension K et que chaque variable ξ peut prendre m valeurs différentes, on peut se retrouver avec une espace de solution de taille m^K .
- Les variables de décisions : La DP est un outil d'optimisation qui donne un optimum global, ce qui implique que même pour 1 seule variable de décision, le nombre de solutions potentielles peut être multiple. Pour de multiples variables, le nombre de solutions peut ainsi devenir très grand.

Pour contourner la malédiction de la grande dimension, des approximations [71] sont possibles. Les espaces ou états peuvent être approximés à l'aide de fonctions afin que le problème puisse être tractable. Il existe un grand nombre d'approximations possibles, mais qui varient en fonction de la nature du problème à résoudre, comme la neuro-DP de Bertsekas et Tsitsiklis [78] qui utilise des réseaux de neurones pour approcher les fonctions d'état, le Q-learning de Watkins et Dayan [79] qui échantillonne l'espace pour sa résolution, la programmation linéaire de Farias et Van Roy [80, 81] ou la méthode du gradient proposée par Foufoula-Georgiou et Kitanidis [82] pour l'approximation de l'espace de recherche dans un problème d'allocation multidimensionnelle de ressources.

2.2.4 Programmation Dynamique et Programmation Stochastique

Comme le principe d'optimalité et la récursion de la DP sont des philosophies pour résoudre des problèmes d'optimisation stochastique, il est normal que la programmation stochastique SP [5, 71, 50] utilise aussi ces principes. Que ce soit pour la SP ou la DP, l'objectif principal de l'optimisation est de trouver une *politique*, sous forme d'une *fonction*, qui satisfait toutes les contraintes et atteint un optimum.

La DP est très présente dans la résolution des problèmes de contrôle optimal [83]. La *politique* (ou loi de contrôle) peut-être représentée avec une table de contrôle [84] ou un réseau de neurones artificiel ANN [78]. Par contre, pour la résolution de problème de recherche opérationnelle, la SP est plus courante. La *politique*, pour la SP, peut être par exemple un *polynôme quadratique* ou une *fonction linéaire paramétrable* [71].

La différenciation entre ce qui relève de la SP ou de la DP est compliquée à établir. En réalité, l'utilisation de l'appellation DP ou SP semble dépendre du problème à résoudre. Les différences sont plutôt sémantiques et ont été introduites par les développeurs de modèles. On peut citer l'exemple de la programmation dynamique stochastique duale SDDP [15] qui est une SP à 2 étages [85]. De plus, les travaux de Powell [50] concernant les optimisations stochastiques et la DP approximative (ADP) conduisent à la conclusion que ces deux approches font parties de la même famille d'optimisation et que la distinction entre elles repose davantage sur un formalisme d'écriture. En effet, les fondements et les méthodes de résolution sont quasi identiques. Il en est de même pour le MPC et la DP. Et Bertsekas [83] a montré que la majorité des MPC sont des algorithmes de déploiement (*rollout*) et sont liés aux méthodes d'itération de *politique* de la DP.

Afin de proposer une vision claire de ces concepts qui portent souvent à confusion, nous allons d’abord nous intéresser aux familles de SP et de DP, puis proposer un concept de généralisation et une classification.

2.2.4.1 Familles de DP

Si on considère la DP comme un outil, il existe une multitude de types d’algorithme d’optimisation, comme la DP différentielle, la DP avec incrémentation d’état [68], la DP probabiliste [70], la DP neurale [78] ou bien la DP abstraite [86]. La majorité des DP (figure 2.11) sont basées sur un processus de décision Markovien [87] et se regroupent dans la famille dite programmation dynamique approximative ADP [71].

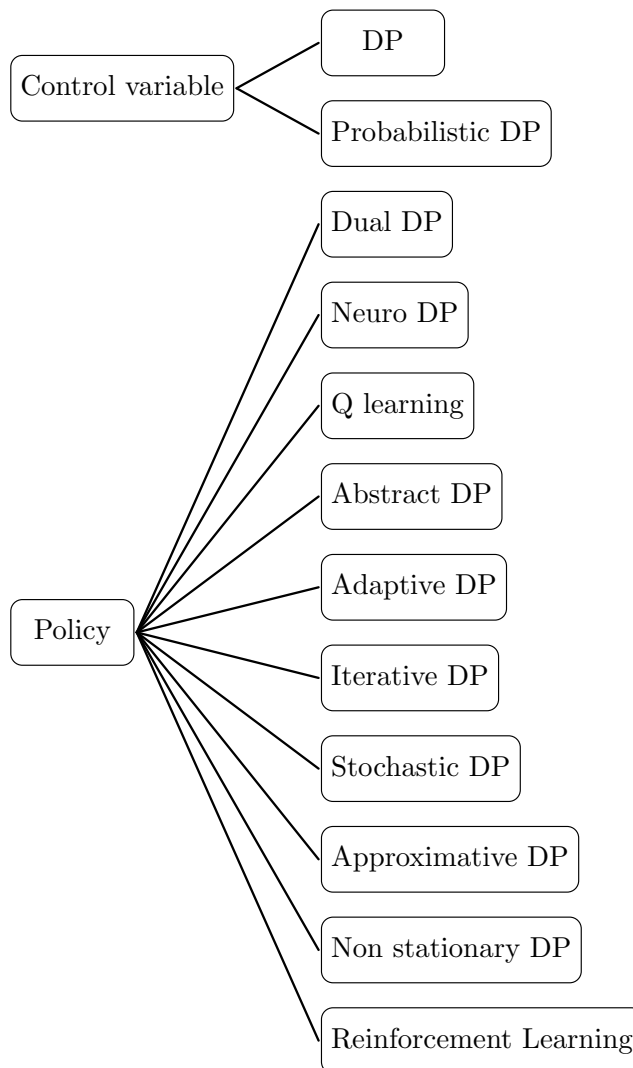


FIGURE 2.11 – Vue d’ensemble des différentes familles de programmation dynamique (DP)

Pour un horizon fini, c’est-à-dire un nombre fini de pas de temps ou une fenêtre d’horizon fixe, la formulation de l’équation d’optimalité (éq. 2.2) est associée à la programmation dynamique probabiliste (PDP) ou à la programmation dynamique stochastique SDP. La PDP est utilisée dans le cas où le nombre d’états serait défini (possible d’être énuméré ou solvable

par une machine). Par contre, le coût associé à chaque état est incertain ou il dépend d'une probabilité [70, 71]. L'objectif est de minimiser l'espérance mathématique ($p \times V_{t+1}(S_{t+1})$) de la valeur de la fonction objective à chaque étape. Ainsi l'équation 2.2 est réécrite en introduisant l'espérance de la valeur (éq. 2.6). Plusieurs méthodes de résolution permettent de résoudre la PDP, par exemple la fenêtre (*Time window*) utilisée par Ioachim et al. [88] pour leur plus court chemin ou bien l'algorithme de Dijkstra [89]. Dans les cas déterministes et probabilistes (PDP), si on considère une optimisation dans le temps, c'est-à-dire que les étapes sont des pas de temps, la *politique* optimale prend en général la forme d'une série chronologique de variables de contrôle.

$$V_t(S_t) = \min (C_t(x_t) + \mathbb{E}V_{t+1}(S_{t+1})). \tag{2.6}$$

Dans le cas où la résolution porterait sur un horizon lointain ou horizon infini, la Programmation dynamique approximative (ADP), qui se réfère à la formulation générale du problème d'optimisation donnée par l'équation 2.2, est préconisée par Powell [71]. La majorité des ADP, utilise le processus de décision markovien (MDP) combiné avec la théorie du point fixe. L'utilisation du MDP sert à la construction de la *matrice de transition de probabilité*. Cette matrice de transition représente les probabilités de passage entre les états du système. Par exemple, pour un système à 2 états choisis arbitrairement pour illustrer la MDP (fig. 2.12), la matrice de transition est une matrice carrée de dimension 2×2 définie comme suit : $P = \begin{pmatrix} 0.6 & 0.4 \\ 0.3 & 0.7 \end{pmatrix}$. À l'état S_1 , le système à plusieurs choix, passer vers l'état S_2 avec une probabilité $p = 0.4$ ou rester à l'état S_1 avec une probabilité $p = 0.6$. Les probabilités p dans l'équation 2.2 sont représentées par cette matrice de transition.




FIGURE 2.12 – Système à 2 états possibles avec les probabilités de changement d'état, par exemple, on a une probabilité de $p = 0.4$ de passer de l'état S_1 vers l'état S_2

2.2.4.2 Programmation Stochastique

Le développement de la programmation stochastique (SP) s'est appuyé sur l'exploitation des structures des problèmes convexes, de la programmation linéaire (LP) et de la programmation quadratique (QP). Par conséquent, les familles de SP portent obligatoirement sur des problèmes d'optimisation convexes.

Supposons un problème purement déterministe avec une formulation prenant la forme d'une fonction linéaire à 2 décisions telles que définies par l'équation 2.7. Cette dernière s'apparente à un problème linéaire (LP) équivalent à l'équation 2.1. Le problème concerne le contrôle d'une production hydrothermale comme présenté par Pereira et Pinto [90]. Dans la version de l'équation 2.7, le problème est réduit à la prise de décision sur 2 pas de temps (t et $t + 1$) pour le même dispositif. Les variables x_1 et x_2 sont des variables de décisions (ex : niveau de production) aux pas de temps t et $t+1$. Les coûts associés aux décisions x_1 et x_2 sont représentés

par cx_1 et cx_2 . Au pas de temps t , $A_1x_1 \geq b$ représente la contrainte (ex : niveau inférieur) liée à la décision x_1 . Et au pas de temps $t + 1$, $E_1x_1 + A_2x_2 \geq \xi$ représente la contrainte de x_2 mais dépendant de la décision x_1 .

$$\begin{aligned}
 J = \min \sum_{t=1}^T C_t(x_t) &= \min_x c_1x_1 + c_2x_2 \\
 \text{s.t. } &A_1x_1 \geq b_1, \\
 &E_1x_1 + A_2x_2 \geq \xi
 \end{aligned} \tag{2.7}$$

En posant $c = [c_1, c_2]$, $x = [x_1, x_2]$, $A = \begin{pmatrix} A_1 & 0 \\ E_1 & A_2 \end{pmatrix}$, $b = [b_1, \xi]$, et, par extension, en considérant un nombre quelconque de variable de décision, l'équation 2.7 peut s'écrire sous la forme matricielle (LP) suivante :

$$\begin{aligned}
 J &= \min_x c^\top x \\
 \text{s.t. } &Ax \geq b \\
 &x \geq 0
 \end{aligned} \tag{2.8}$$

Dans l'équation ci-dessus, \cdot^\top est l'opérateur transposition.

Dans sa version stochastique, c'est-à-dire dans le cas où ξ est une variable aléatoire prenant les valeurs $\{\xi_1, \xi_2, \dots, \xi_j, \dots, \xi_m\}$ avec $j = \{1, \dots, m\}$, la partie de droite des contraintes de l'équation 2.8 et $b = [b_1, \xi]$. La formulation stochastique et linéaire du problème d'optimisation donnée par l'équation 2.7 est reprise en y ajoutant les probabilités p_j associées aux valeurs possibles ξ_j de la variable aléatoire ξ . À chaque réalisation ξ_j , une décision x_{2j} est associée. Pereira et Pinto [15] propose une version probabiliste de l'équation 2.7 pour une seule variable aléatoire ξ :

$$\begin{aligned}
 J &= \min_x c_1x_1 + p_1c_2x_{21} + p_2c_2x_{22} + \dots + p_m c_2x_{2j} + \dots + p_m c_2x_{2m} \\
 \text{s.t. } &A_1x_1 \geq b_1, \\
 &E_1x_1 + A_2x_{21} \geq \xi_1, \\
 &E_1x_1 + A_2x_{22} \geq \xi_2, \\
 &\vdots \\
 &E_1x_1 + A_2x_{2j} \geq \xi_j, \\
 &\vdots \\
 &E_1x_1 + A_2x_{2m} \geq \xi_m.
 \end{aligned} \tag{2.9}$$

Pour généraliser cette formulation stochastique, on remplace les termes associés aux probabilités p_j dans l'équation 2.9 ci-dessus par l'espérance du coût de réalisation de la variable aléatoire ξ , soit $\mathbb{E}[Q(x_1, \xi)] = \sum_{j=1}^m p_j c_2 x_{2j}$. Avec le même raisonnement utilisé pour passer de l'équation 2.7 à l'équation 2.8, on obtient ainsi l'équation 2.10 qui est une forme plus générale du problème d'optimisation (éq. 2.1) associé à une formulation linéaire de la SP. Dans cette forme générale, on considère un ensemble Ξ de variable aléatoire ξ^j avec $j \in \{1, K\}$.

$$\begin{aligned}
 J &= \min_x c^\top x + \mathbb{E}[Q(x, \Xi)] \\
 \text{s.t. } &Ax \geq b \\
 &x \geq 0
 \end{aligned} \tag{2.10}$$

Suivant la formulation du problème, selon Ruszczyński et Shapiro [5], Birge et Louveaux [91], la SP peut être divisé en 5 familles différentes (fig. 2.13) :




FIGURE 2.13 – Les différentes familles de programmation stochastique (SP) tel que définit par Ruszczyński et Shapiro [5] et Birge et Louveaux [91]

1. Processus en deux étages : Le problème est décomposé en deux étages. La solution de cette minimisation est une somme de 2 valeurs.

$$J = \min_x c^\top x + \mathbb{E}[Q(x, \Xi)] \tag{2.11}$$

Dans l'équation 2.11, $c^\top x$ correspond à la partie déterministe. $Q(x, \Xi)$ est la valeur optimale obtenue à l'étage 2 et qui dépend des décisions x prises pour l'étage 1. Les variables aléatoires ξ se retrouvent dans le sous-problème (éq. 2.12). Avec x et y les variables de décision des étages 1 et 2. Par exemple, dans le cas du problème avec 2 variables de décisions, x correspond à x_1 et y aux réalisations possibles de x_2 , soit $y = \{x_{21}, x_{2j}, \dots, x_{2m}\}$. Pour la formulation avec 2 variables de décisions (x_1 et x_2), la variable aléatoire ξ se trouve uniquement du côté droit des contraintes (éq. 2.9). A_1 correspond au coefficient de la contrainte affecté uniquement au premier étage et à la décision x_1 . En décomposant la matrice $A = H + W$, on peut intégrer les variables aléatoires Ξ des deux côtés des contraintes. Les éléments de la matrice H correspondant aux coefficients liés aux décisions x présent au niveau de l'étage 1 est appelé matrice de technologie et la matrice W est appelée matrice de recours.

$$\begin{aligned}
 Q(x, \xi) = \min_y \quad & q^\top y \\
 \text{s.t.} \quad & Hx + Wy \geq h, \\
 & y \geq 0.
 \end{aligned}
 \tag{2.12}$$

La résolution de ce processus en 2 étages consiste tout d'abord à choisir des variables de décisions x de $c^\top x$ puis de résoudre le ou les sous-problèmes (éq. 2.12) correspondant au deuxième étage. Ensuite, on utilise les solutions obtenues dans ce deuxième étage pour résoudre le problème principal (premier étage). C'est une résolution itérative, car dans le cas où les décisions x (qui sont des bases de solutions de l'équation 2.11) prises ne sont pas des solutions de l'étage 2, on change de base de solutions.

2. Processus à étages multiples : le processus à étages multiples est une généralisation du processus à 2 étages. Dans le processus à 2 étages, l'ensemble des variables aléatoires (Ξ) est considéré comme étant statique. Ici, l'évolution temporelle de la variable aléatoire

est prise en compte de manière dynamique dans l'optimisation. À chaque étape t , les décisions sont prises. Lorsque de nouvelles mesures sont disponibles, elles sont utilisées dans l'optimisation, comme dans le cas d'un MPC.

3. Optimisation Robuste, Min-Max et Probabiliste : la différence avec les familles de SP présentées précédemment est que l'on considère les pires cas possibles.

- En considérant une manière plus prudente d'optimiser, on peut définir un coefficient $\kappa \geq 0$ qui permet d'obtenir un compromis entre l'espérance ($\mathbb{E}[Q(x, \Xi)]$) et la variabilité ($\text{Var}[Q(x, \Xi)]$) de la fonction coût. Plus exactement, ce coefficient est affecté à la variance comme suit $\kappa \text{Var}[Q(x, \Xi)]$. Ce compromis s'appelle l'optimisation robuste formalisée par l'équation suivante :

$$\begin{aligned} J = \min_y \quad & c^\top x + \psi(Q(x, \xi_1), \dots, Q(x, \xi_m)) \\ \text{s.t.} \quad & Ax \geq b, \\ & x \geq 0. \end{aligned} \tag{2.13}$$

avec $\psi(Q(x, \xi_1), \dots, Q(x, \xi_m)) = \mathbb{E}[Q(x, \Xi)] + \kappa \text{Var}[Q(x, \Xi)]$

- Au lieu de considérer la variabilité ou l'espérance de la fonction $Q(x, \Xi)$, la formulation *min-max* peut être directement utilisée pour estimer le pire des cas possibles. Avec la variable aléatoire ξ appartenant à l'espace Ξ , \mathbb{S} étant la distribution de probabilité de cet espace, les probabilités p correspondantes peuvent être calculées directement. On minimise directement l'espérance conditionnelle $\mathbb{E}_p[Q(x, \Xi)]$ de l'éq. 2.14 en considérant seulement les événements ξ avec les plus grandes probabilités $p \in \mathbb{S}$ (maximisation de p sur \mathbb{S}).

$$\begin{aligned} J = \min_x \quad & c^\top x + \min_{x \in \mathcal{X}} \max_{p \in \mathbb{S}} \mathbb{E}_p[Q(x, \Xi)] \\ \text{s.t.} \quad & Ax \geq b, \\ & x \geq 0. \end{aligned} \tag{2.14}$$

- Optimisation probabiliste [92]. Pour une minimisation, dans une SP à 2 ou plusieurs étages, l'objectif est de déterminer les décisions x associées à un coût optimal. Dans certains cas, le coût doit être inférieur à un seuil (τ). La réalisation de la variable aléatoire n'étant pas connue à l'avance, le coût réel ($Q(x, \xi)$) pourrait être plus élevé. Pour limiter les risques liés aux variables aléatoires, on peut imposer un coût de référence maximum tel que, quelles que soient les valeurs de ξ , le coût soit inférieur à cette limite. L'objectif est donc de déterminer les décisions x telles que le coût soit inférieur à une limite τ avec un risque de probabilité α .

$$\text{Prob}\{Q(x, \Xi) \leq \tau\} \geq 1 - \alpha \tag{2.15}$$

Pour bien comprendre le fonctionnement de la SP, je vous propose ici de l'appliquer à un problème d'optimisation convexe. Cette illustration est tirée des travaux de Shapiro et Philpott [93]. Le problème consiste à minimiser la fonction G qui est une fonction linéaire par partie (éq. 2.16) où la décision x dépend de la variable aléatoire $\xi = \{\xi_1, \xi_2, \dots, \xi_j, \dots, \xi_m\}$ avec $j = \{1, 2, \dots, m\}$ et à laquelle est associée une fonction de distribution. Pour chaque occurrence de l'évènement ξ_j , il existe une probabilité p_j .

$$J = \min_x G(x, \Xi) \quad (2.16)$$

$$G(x, \xi) = \begin{cases} (c - d)x + d\xi, & \text{if } x < \xi \\ (c + h)x - h\xi, & \text{if } x \geq \xi. \end{cases} \quad (2.17)$$

La fonction coût G à minimiser (éq. 2.16) est présentée par l'équation 2.17. Pour améliorer la compréhension, des valeurs numériques arbitrairement choisies seront utilisées pour la représentation graphique et l'application numérique : $c = 1.0$, $d = 1.5$ et $h = 0.1$. En utilisant ces valeurs, l'équation 2.17 devient :

$$G(x, \xi) = \begin{cases} -0.5x + 1.5\xi, & \text{if } x < \xi \\ 1.1x - 0.1\xi, & \text{if } x \geq \xi. \end{cases}$$

Dans un premier temps, le problème (éq. 2.16) est supposé purement déterministe. C'est-à-dire que la valeur de ξ est connue. Ainsi, pour une valeur fixe de $\xi = 50$, la solution correspond à l'intersection des 2 droites $-0.5x + 1.5 \times 50$ et $1.1x - 0.1 \times 50$ (fig. 2.14a). Pour cette application numérique, la résolution de l'optimisation 2.16 donne une valeur de $x = 50$.

L'objectif du problème d'optimisation stochastique est de résoudre le même problème, mais en considérant que la réalisation de la variable aléatoire ξ n'est pas connue. Le problème revient à trouver le minimum de fonction représentant l'espérance du coût ($\min_x \mathbb{E}[G(x, \xi)]$) pour toutes les valeurs possibles de ξ . L'intégration de la distribution de $\xi = \{\xi_1, \xi_2, \dots, \xi_j, \dots, \xi_m\}$ avec les probabilités correspondantes $p = \{p_1, p_2, \dots, p_j, \dots, p_m\}$ dans l'équation 2.16 donne l'équation suivante :

$$\begin{aligned} J &= \min_x \mathbb{E}[G(x, \xi)] \\ &= \min_x \sum_{j=1}^m p_j G(x, \xi_j) \end{aligned} \quad (2.18)$$

En posant $G(x, \xi_j) = \mu_j$, en reformulant l'équation 2.17 sous forme de contraintes et avec $c = 0$, le problème peut être réécrit sous la forme générale et linéaire de la SP (éq. 2.10) comme suit :

$$\begin{aligned} J &= \min_x 0^\top x + \sum_{j=1}^m p_j \mu_j \\ \text{s.t.} \quad & 1.5x - \mu_j \leq -1.5\xi, \quad j = \{1, \dots, m\} \\ & 1.1x - \mu_j \leq 0.1\xi, \quad j = \{1, \dots, m\} \\ & x \geq 0 \end{aligned} \quad (2.19)$$

Pour illustrer la résolution de l'équation 2.18, les hypothèses suivantes sont posées : ξ suit une distribution uniforme dans l'intervalle $[0, 100]$ ($\xi \sim \mathcal{U}(0, 100)$) et $x \in [0, 100]$. Shapiro et Philpott [93] ont montré que l'expression analytique de l'espérance du coût (éq. 2.18) peut être obtenue explicitement :

$$\begin{aligned} \mathbb{E}[G(x, \xi)] &= d \times \mathbb{E}[\xi] + (c - d)x + (d + h) \int_0^x F(z) dz \\ &= 75 - 0.5x + 0.008x^2. \end{aligned} \quad (2.20)$$

Dans le cas général, l'espérance du coût ($\mathbb{E}[G(x, \xi)]$) du problème de minimisation n'est pas formulable de manière analytique. L'espérance du coût (éq. 2.18) doit donc être approchée par

une fonction définie à partir de scénarios. En utilisant directement l'équation 2.18, on peut construire des approximations de la fonction espérance (éq. 2.20) dans l'espace $x \in [0, 100]$ à partir de scénarios comme illustré ci-après :

- 2 scénarios : 2 scénarios de réalisation de la variable ξ avec des probabilités identiques sont produits. Pour cet exemple, nous prendrons $\xi_{j=1,2} = \{20, 80\}$ avec des probabilités $p_{j=1,2} = \{1/2, 1/2\}$. À partir de l'équation 2.18 la fonction $f_2(x)$ (éq. 2.21) peut être construite avec les scénarios ξ_j .

$$f_2(x) = \sum_{j=1}^2 p_j G(x, \xi_j) = \frac{1}{2} G(x, 20) + \frac{1}{2} G(x, 80) \quad (2.21)$$

L'espérance du premier scénario $\xi_1 = 20 \mid p_1 = 1/2$ correspond à l'équation 2.22 et celle du second $\xi_2 = 80 \mid p_2 = 1/2$ à l'équation 2.23.

$$\frac{1}{2} G(x, 20) = \begin{cases} 0.5 \times (-0.5x + 1.5 \times 20) = -0.25x + 15, & \text{if } x < 20 \\ 0.5 \times (1.1x - 0.1 \times 20) = 0.55x - 1, & \text{if } x \geq 20. \end{cases} \quad (2.22)$$

$$\frac{1}{2} G(x, 80) = \begin{cases} 0.5 \times (-0.5x + 1.5 \times 80) = -0.25x + 60, & \text{if } x < 80 \\ 0.5 \times (1.1x - 0.1 \times 80) = 0.55x - 4, & \text{if } x \geq 80. \end{cases} \quad (2.23)$$

En sommant les équations 2.22 et 2.23, l'équation 2.24 est obtenue. $f_2(x)$ est une fonction linéaire par morceau correspondant à l'approximation de l'espérance du coût (fig. 2.14b) obtenue à partir de 2 scénarios.


$$f_2(x) = \begin{cases} (-0.25x + 15) + (-0.25x + 60) = -0.5x + 75, & \text{if } x < 20 \\ (0.55x - 1) + (-0.25x + 60) = 0.3x + 59, & \text{if } 20 \leq x < 80 \\ (0.55x - 1) + (0.55x - 4) = 1.1x - 5, & \text{if } x \geq 80. \end{cases} \quad (2.24)$$

- 3 scénarios : De même que dans le cas de 2 scénarios, pour 3 scénarios de réalisation de la variable ξ , avec $\xi_{j=1,2,3} = \{20, 50, 80\} \mid p_{j=1,2,3} = \{1/3, 1/3, 1/3\}$, à partir de l'équation 2.18, la fonction $f_3(x)$ (fig. 2.14b) est obtenue.

La figure 2.14b montre l'évolution de la valeur de l'espérance du coût, qui est représentée par la fonction «*Expectation*». Le minimum de cette fonction ($\bar{x} = 31.25 \forall \xi$) est différent de la solution obtenue dans le cas déterministe ($x = 50 \mid \xi = 50$).

La figure 2.14b montre que plus il y a de scénarios, plus l'approximation de la fonction espérance est précise. En effet, pour l'exemple choisi, le cas avec le plus grand nombre de scénarios (3 scénarios) auxquels sont associées des probabilités identiques $p_j = 1/3$, l'approximation de la fonction espérance est plus fidèle.

Au-delà du nombre de scénarios, la qualité de la représentation de la distribution réelle des variables aléatoires par les scénarios a une forte influence sur le résultat de l'optimisation stochastique. Pour illustrer cette influence, la figure fig. 2.15 montre l'approximation de l'espérance du coût pour le cas à deux scénarios. La fonction d'approximation f_2 est obtenue comme précédemment en associant des probabilités identiques aux deux réalisations ($\xi_{j=1,2} = \{20, 80\}$) et $p_{j=1,2} = \{1/2, 1/2\}$. Par contre, la fonction d'approximation f_{2a} est obtenue pour les mêmes réalisations ($\xi_{j=1,2} = \{20, 80\}$) mais avec des probabilités différentes ($p_{j=1,2} = \{0.6, 0.4\}$). On



(a) Cas déterministe (éq. 2.17) avec $\xi = 50$

(b) Cas probabiliste pour $\xi \sim \mathcal{U}(0, 100)$ montrant la solution analytique (éq. 2.20) et des solutions approchées pour différents nombres de scénarios (f_2 et f_3)

FIGURE 2.14 – Solution du problème d’optimisation posé par l’équation 2.16 dans les cas déterministe (a) et probabiliste (b) [93]

observe clairement que la fonction d’approximation f_{2a} , qui s’appuie sur des scénarios dont les probabilités s’écartent de la loi uniforme sous-jacente à la variable aléatoire ξ , aboutie à un résultat plus éloigné. Donc, le véritable défi dans la résolution de la SP provient de la construction des scénarios. Ils doivent être en nombre suffisant et représenter fidèlement les distributions des variables aléatoires prises en comptes dans le problème d’optimisation.

2.2.4.3 Méthodes de construction de scénarios

Comme mentionné ci-avant et dans la section 2.1.2.3, la résolution de la SP repose sur la construction de scénarios. Les scénarios doivent être capables de capturer les évolutions et les corrélations temporelles des variables aléatoires d’entrée de la SP. Kaut [94] a classé la génération de scénarios en 5 catégories (résumées dans le tableau 2.2) :

1. *Échantillonnage conditionnel* : La méthode de Monte-Carlo est utilisée directement pour réaliser l’échantillonnage. Cette méthode ne tient pas compte des corrélations. Dans le cas de variables multivariées, un nombre important de scénarios sont nécessaires pour approximer correctement les distributions.

Afin de prendre en compte les corrélations dans le cas de variables multivariées, des méthodes de décomposition comme l’analyse en composantes principales proposée par Loretan [95] ont été développées. L’échantillonnage se fait sur les composantes, mais pas sur les variables aléatoires originales.




FIGURE 2.15 – Estimation de l’espérance du coût à partir de 2 scénarios ($\xi_{j=1,2} = \{20, 80\}$) dont les probabilités sont différentes.

Pour avoir une meilleure approximation, Pennanen et Koivu [96] proposent d’utiliser des points de quadratures. Ces points sont obtenus à partir d’une transformation par quadrature de Gauss des variables originales. Et enfin, Cariño et al. [97] ont proposé l’utilisation de prévisions combinées avec un échantillonnage de Monte-Carlo pour la génération de scénarios respectant l’interdépendance temporelle des variables.

2. *Échantillonnage et corrélation* : Des transformations sont appliquées aux différentes distributions pour obtenir des variables aléatoires multivariées et corrélées. La matrice de corrélation peut être calculée à partir de prévisions comme proposées par Cario et Nelson [98], en passant d’abord par une transformation en distribution normale.
3. *Moment matching* : Les corrélations sont obtenues à partir des moments principaux des distributions (moyenne, variance, kurtosis, asymétrie). La procédure de génération de

scénarios à partir des moments statistiques est détaillée dans les travaux de Høyland et al. [99].

4. *Chemin vers scénario* : Dupačová et al. [100] proposent la construction des scénarios à partir de probabilités conditionnelles. Ces probabilités conditionnelles permettent la prise en compte des corrélations des variables aléatoires.
5. *Discrétisation optimale* : Un arbre de scénarios est généré pour une variable univariée. Cette méthode proposée par Pflug [101] consiste à estimer avec des prévisions des probabilités et des variables aléatoires pour chaque branche de scénario.

À ces modèles, d'autres procédures de génération de scénarios ont été proposées et analysées par Di Domenica et al. [102] :

6. *Chaînes de Markov* : Popularisées par Puterman [103], elles génèrent des séquences de nombres aléatoires (ou scénarios) interdépendants.
7. *Bootstrap* : Développé par Mooney et Duval [104], il s'agit d'un processus similaire la méthode d'échantillonnage de Monte-Carlo, mais celui-ci génère des intervalles de confiances.

Méthode	Donnée d'entrées	Processus	Représentations
Échantillonnage conditionnelles	Historiques	Monte-Carlo [105] Monte-Carlo par la méthode Box-Muller [106]	Équiprobabilité Matrice de corrélation [107]
Échantillonnage corrélés	Prévision points [98] Prévision probabiliste [65]	Transformations des variables en distribution gaussienne multivariées	Matrice de corrélation Matrice de covariance [65]
Moment matching	Historique	Transformation cubique des moments	Matrice de corrélation
Chemin vers scénario	Série temporelle multivariée	Calcule et mesure de dissimilarité [100]	Matrice de transition
Discrétisation optimale	Distribution de probabilité	Estimation de trajectoire	Probabilité de chaque noeud
Chaîne de Markov	Historique	Monte-Carlo	Matrice de transition
Bootstrapping	Historique Prévision ARMA [108]	Bloques d'intervalles par Monte-Carlo [104]	Équiprobabilité

TABLE 2.2 – Synthèse des méthodes de génération de scénarios précisant les entrées et les étapes principales

Dans les cas où les probabilités des scénarios ne sont pas équiprobables (tab. 2.2), il est nécessaire de construire une matrice représentant les dépendances des variables aléatoires. Cette matrice peut être une matrice de covariance, de corrélation ou bien matrice de transition. Cette dernière est aussi utilisée dans le cadre de la Programmation Dynamique (cf. 2.2.1).

2.2.5 Implémentation dynamique d'une optimisation

Même avec l'amélioration des modèles de prévision, il est impossible de connaître précisément le futur. De plus, tout système de commande ou de contrôle subit les effets ou dynamiques

des variables aléatoires comme celles liées au climat, au comportement des utilisateurs, aux accidents, etc. L'intérêt du gestionnaire du réseau est donc de mettre en place un programme de CONTRÔLE EN TEMPS RÉEL de son système qui prend en compte ces deux aspects. Pour atteindre cet objectif, il a recours à ce que Powell [50] définit comme **Programme Dynamique** : « *A dynamic program is a sequential (and for our purposes, stochastic) decision problem* ». Il s'agit de la formulation d'un problème prenant en compte la dynamique *séquentielle* présente et aussi future du système. Dans le cas du contrôle prédictif, des variables interviennent et influencent le système. Pour un programme dynamique, à ne pas confondre avec la DP, les *politiques* ou règles de contrôle mises en oeuvre doivent atteindre les objectifs du contrôle en temps réel.

2.2.5.1 Forme de la politique

La *politique* ou politique de gestion est la solution du problème d'optimisation. Dans un programme dynamique, la forme de la solution dépend de la méthode de construction de la solution ou de la structure du problème. Les politiques dans un programme dynamique peuvent se présenter sous plusieurs formes :

1. Les *politiques* peuvent être construites au préalable et ensuite testées en temps réel sur les systèmes. Par exemple, Bertsekas et Tsitsiklis [78] proposent la construction d'un réseau de neurones artificiel (ANN) aussi appelé neural-DP, ou bien la définition d'une table de contrôle (*lookup table*) pour le contrôle optimal de Bertsekas [84]. De la même manière, Dowson et Kapelevich [109] proposent de construire un programme linéaire (LP) à résoudre à chaque étape pour une SDDP. Une fois construite, une *politique* est considérée comme étant valable, quelles que soient les variations des incertitudes entrant en jeu dans le système. La figure 2.16 montre un exemple de table de contrôle. Elle a été établie par Haessig et al. [17] afin de commander l'injection d'énergie dans le réseau électrique à partir d'un système de stockage couplé à un houle-générateur. La *politique* est préétablie. Lors du fonctionnement en temps réel, la puissance injectée dans le réseau (P_{Grid}) est déterminée directement à partir de la *politique* en fonction de l'énergie disponible (S_t), de la vitesse et de l'accélération de la houle comme montrée dans la figure 2.16.
2. Une autre forme de la *politique* peut être une série d'actions ou de décisions représentées par des valeurs discrètes. Par exemple, dans un microréseau alimenté par un système PV, Riffonneau et al. [42] fixent les niveaux de charge d'un stockage pour chaque heure de la journée à venir en utilisant des prévisions de production. Ensuite, la gestion en temps réel du stockage est assurée par un MPC pour atteindre les consignes définies la veille.
3. D'autres auteurs comme Barto et al. [110] construisent des *politiques* de manière dynamique. Généralement, la *politique* est une fonction dont les coefficients n'ont pas de valeurs fixes. La construction se fait en même temps que la prise de décision. La *politique* s'améliore progressivement avec le nombre de décisions prises, pour les premiers pas de temps, la *politique* donne des résultats très approximatifs, mais au bout de plusieurs itérations, la *politique* converge vers la *politique optimale*. Ce type de construction en temps réel de la *politique* est appelée par Powell et Ryzhov [111] « *Optimal learning* ».

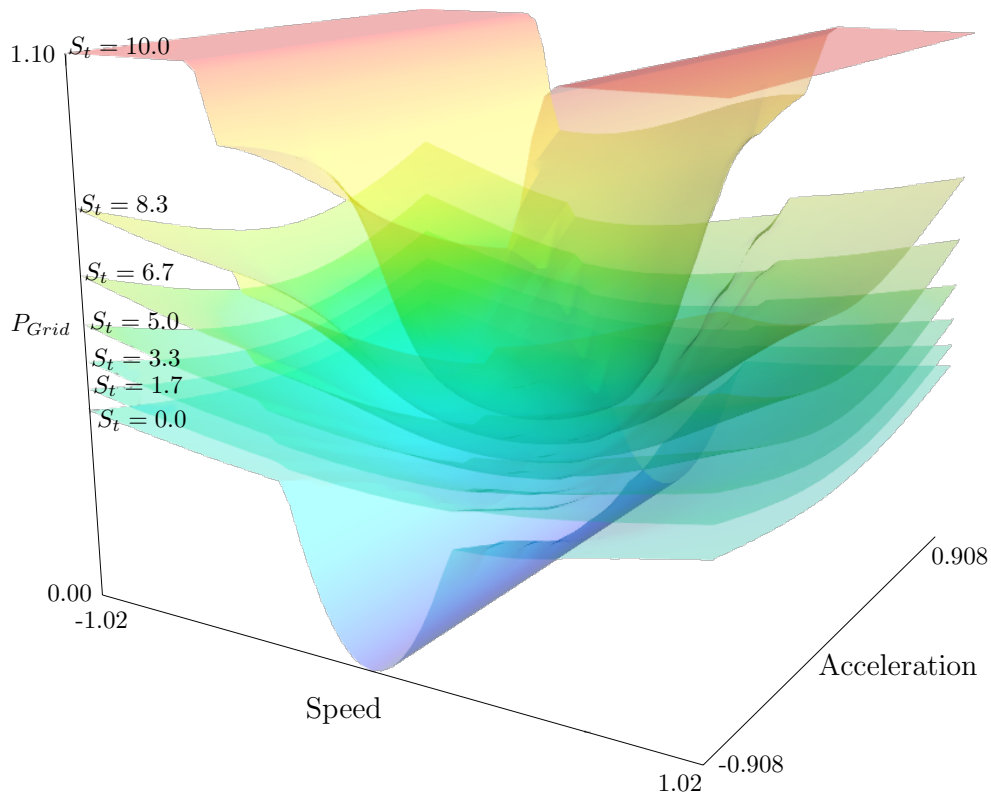


FIGURE 2.16 – Politique de contrôle d’un stockage couplé à un houle-générateur sous la forme d’une table de contrôle : la puissance à injecter (P_{Grid}) est déterminée à partir de la vitesse et de l’accélération du vent pour 7 niveaux d’énergie contenue dans le stockage [17]

2.2.5.2 Off-line, Online

Lorsqu’on développe un programme dynamique, les notions de *Off-line* et de *Online* sont très importantes. Le mode *Off-line* correspond à une simulation ou une construction de la *politique* optimale par anticipation et sans prise en compte des réalisations. Pour le mode *Online*, il s’agit de prendre en compte les réalisations lorsqu’elles se produisent. Le MPC est un exemple d’optimisation *Online*, à chaque arrivée de nouvelles données, le modèle est mis à jour et les décisions prises. Une optimisation *Online* s’effectue donc en temps réel. La mise en œuvre d’une optimisation *Off-line* ou *Online* dépend généralement de la stratégie adoptée. Je vous propose ci-après une description du lien entre les notions d’optimisation *Off-line* et *Online* et les trois formes de *politique* définies précédemment :

1. Pour le cas d’une *politique* prenant la forme d’une heuristique comme dans les travaux d’Haessig et al. [17], la *politique* est construite en mode *Off-line*. L’exécution de cette *politique* en temps réel correspond pour ce cas à l’optimisation *Online*.
2. Pour le cas d’une série de décisions discrètes, la *politique* est construite en mode *Off-line* la veille pour lendemain. Cette *politique* définit les trajectoires pour l’optimisation en temps réel. Une seconde *politique* est ensuite construite en mode *Online* ou en temps réel à partir des trajectoires établies par la *politique* définie la veille. Par exemple, dans le travail de Riffonneau et al. [42], l’optimisation *Off-line* produit une série horaire de l’état de charge du stockage pour le jour à venir. Ensuite, un MPC assure l’optimisation *Online* qui

détermine en temps réel les décisions à prendre tout en respectant les trajectoires définies la veille. Cette stratégie en 2 phases présente un avantage certain pour le contrôle en temps réel d'un système tel qu'un microréseau électrique. Par exemple, les centrales thermiques ou les stations de transfert d'énergie par pompage nécessitent un temps de démarrage et un temps d'arrêt relativement long. Ils ne peuvent donc pas interagir instantanément avec le réseau et ont besoin d'un planning de démarrages et d'arrêts fixé longtemps en avance.

3. Lorsque la *politique* est construite de manière dynamique [110], l'optimisation est réalisée uniquement en mode *Online*. Au lieu d'obtenir une *politique* fixe comme dans le cas des heuristiques, la *politique* est améliorée avec l'arrivée de nouvelles mesures. Comme exposé plus haut, lors des premières itérations, la *politique* obtenue est très approximative, mais elle tend à s'améliorer. Le nombre d'itérations nécessaires pour que la *politique* converge vers une solution optimale correspond à une phase d'initialisation. Cette phase peut être vue comme une supplantation du mode *Off-line*.

2.2.5.3 Choix d'une politique

Toutes les formes de *politique* peuvent être utilisées comme solutions dans la majorité des optimisations stochastiques. Par contre, en fonction de la disponibilité des données, des modèles, des hypothèses et des contraintes, il est important de définir les classes de *politique* à utiliser.

À titre d'exemple, pour les jeux vidéo, l'optimisation n'a pas à anticiper le prochain coup du joueur. Toutes les décisions possibles sont construites en même temps après l'exécution de l'optimisation. Une table de contrôle liste les solutions pour l'ordinateur pour chaque mouvement possible effectué par le joueur. Dans ce cas, la solution est une table statique, ce qui signifie que l'optimisation ne peut pas gérer un événement imprévu.

L'exemple inverse des jeux vidéo est la gestion des actifs boursiers dans un marché déréglementé. L'optimisation est conditionnée par l'état futur du marché. Une bonne prévision des prix sur le marché peut conduire à une meilleure solution. Dans ce cas, la solution optimale ne peut pas être une table statique, mais évolue dynamiquement avec le marché.

Pour l'implémentation d'un programme dynamique, Powell [50, 13] propose 4 catégories de stratégies pour faire le choix d'une *politique* (X^π étant l'ensemble des décisions possibles obtenues pour la *politique* optimale) :

1. *Approximations des fonctions de contrôle (PFAs)*. L'hypothèse est que la *politique* est une fonction (cas de la SP) ou une table de contrôle (cas de la DP). Un grand nombre de jeux vidéo utilisent une table de contrôle comme « Tetris » proposé par Tsitsiklis et Van Roy [112], en fonction des actions du joueur, des décisions préétablies sont exécutées. L'hypothèse est que la forme de la fonction (éq. 2.25) est déjà connue. L'optimisation consiste à la construction de cette fonction.

$$X^\pi(S_t|\theta) = \theta_0 + \theta_1 S_t + \theta_2 S_t^2 \tag{2.25}$$

Avec θ , un paramètre à déterminer qui peut être une matrice, un vecteur ou même un polynôme.

2. *Approximation de la fonction de coût (CFA)*. Il existe des cas où une approximation de la fonction coût, souvent par une simplification, est faite (éq. 2.26). La fonction est

utilisée sans considération des décisions futures, mais donne des résultats satisfaisants dans certains cas [50].

$$X_t^\pi(S_t|\theta) = \arg \min_{x \in \mathcal{X}_t} (\bar{C}^\pi(S_t, x|\theta)) = \arg \min_{x \in \mathcal{X}_t} \left(C(S_t, x) + \sum_{f \in \mathcal{F}} \theta_f \phi_f(S_t, x) \right) \quad (2.26)$$

Avec, $(\phi_f(S_t, x))_{f \in \mathcal{F}}$ un ensemble de *bases de fonctions* définit par l'ADP [71] qui servent de termes de correction et θ_f un paramètre de tuning de l'approximation.

3. *Approximation de la fonction de valeur (VFA)*. Cette *politique* est la plus associée à la DP. L'équation 2.2 de la DP peut aussi s'écrire sous la forme de l'équation 2.27. L'objectif est de trouver les politiques optimales en estimant les valeurs de la fonction coût.

$$X_t^\pi(S_t|\theta) = \arg \min_{x \in \mathcal{X}_t} \left(C(S_t, x) + \mathbb{E}\{\tilde{V}_{t+1}(S_{t+1}|\theta)|S_t\} \right) \quad (2.27)$$

Dans le cas où il n'est pas possible, de calculer explicitement la fonction objective, la valeur $V_{t+1}(S_{t+1})$ de l'équation 2.2 devient $\tilde{V}_{t+1}(S_{t+1}|\theta)|S_t$. Le terme θ est l'ensemble des paramètres de tuning utilisé pour la résolution. La valeur $V_{t+1}(S_{t+1})$ est approximée par une fonction $\phi_f(S_t^x)$ capable de capturer la structure de la fonction et un paramètre de tuning θ_f est appliqué à la fonction (éq. 2.28).

$$X_t^\pi(S_t|\theta) = \arg \min_{x \in \mathcal{X}_t} \left(C(S_t, x) + \mathbb{E}\left\{ \sum_{f \in \mathcal{F}} \theta_f \phi_f(S_t^x) \right\} \right) \quad (2.28)$$

4. *Look-ahead policies* : Ce type d'optimisation se base sur le principe d'optimiser dans le futur et de ne prendre que les décisions utiles. Le MPC est un exemple de ce type d'optimisation, il optimise sur des pas de temps $t + n$ et ne prend que la première valeur de la sortie $t + 1$. Pour la construction des MPC, Camacho et Bordons [44] utilisent le *Look-ahead* qui est aussi appelé *receding horizon*.

2.2.6 Choix de la programmation dynamique probabiliste PDP

L'objectif de ce travail de thèse est d'utiliser des prévisions pour trouver la solution optimale à un problème, la planification d'UC. Avec l'hypothèse que la forme de la *politique* optimale n'est pas connue, le PFAs n'est pas une bonne candidate. De plus, la planification en elle-même devrait prendre en compte, non seulement l'instant d'exécution de la planification, mais aussi les futurs plus lointains, la CFA est donc à exclure aussi, car elle ne prend pas en considération les effets des décisions futures. Pour résoudre ce type de problème d'UC, une solution pertinente est l'hybridation du VFA avec un *look-ahead*. Avec cette approche, l'optimisation se fait sur une fenêtre de temps plus longue que la planification à fournir, par contre les décisions retenues ne s'exécuteront que sur les pas de temps correspondant à planification à fournir. Cette approche fréquemment retenue dans les problèmes de planification utilisant des prévisions opérationnelles comme pour Yang et al. [43].

Avec l'hypothèse qu'il est possible de calculer de manière analytique la fonction coût, il n'y a pas de raison de procéder à une estimation de celle-ci comme proposée par la méthode VFA. En effet, une non-priorisation de solution permet de s'affranchir du paramètre θ de l'équation

2.27 et l'équation à résoudre prend ainsi la forme canonique de la DP (éq. 2.2) que l'on rappelle ici :

$$V_t(S_t) = \min (C_t(x_t) + \gamma \times p \times V_{t+1}(S_{t+1})). \quad (2.29)$$

Dans le cas stochastique, que ce soit pour une programmation stochastique ou une programmation dynamique stochastique, la probabilité p est obtenue à partir d'une matrice de transition de probabilité [65, 86]. Or, la matrice de transition a pour objectif de capturer l'interdépendance temporelle (évolutions, variations et corrélations) des variables aléatoires. Néanmoins, de nombreuses prévisions déterministes comme probabilistes prennent en compte les dépendances temporelles et certaines fois spatiales des variables à prédire. C'est le cas des prévisions d'ensemble issues de prévisions numériques du temps, des modèles de mouvement des nuages issus d'images satellites ou du ciel ou bien encore de modèles statistiques multivariés. Donc leur utilisation ne rend pas nécessaire la construction de matrices de transition par MDP ou la mise en œuvre de simulation du type Monte-Carlo. Les probabilités p utilisées lors de l'optimisation sont les probabilités des quantiles des prévisions probabilistes.

Considérant tous ces aspects, la méthode retenue sera donc une VFA sans approximation, avec des probabilités extraites directement des prévisions probabilistes. Il s'agit d'une forme associée à un membre de la famille de DP : la *Programmation Dynamique Probabiliste* PDP comme dans les travaux de Winston [70].

La PDP propose un avantage certain pour la résolution de l'optimisation. En effet, la résolution peut être obtenue directement par une récursion arrière (*backward recursion*). En outre, un des autres avantages majeurs de la PDP est qu'il s'agit d'une méthode globale permettant d'optimiser des problèmes non convexes et non linéaires. Par contre, comme tout problème de DP, elle souffre de la malédiction de la grande dimension et des techniques d'approximation existent pour essayer d'y remédier.

La mise en œuvre de la PDP dans ce travail de thèse permettra d'intégrer directement des prévisions probabilistes de production d'EnR intermittentes dans un problème de planification d'UC de la veille pour le lendemain. D'autre part, la PDP sera testée en mode OFF-LINE dans le cadre d'une *politique* de contrôle de type *look-ahead*.

L'implémentation de la PDP est la même pour la version déterministe et la version probabiliste. La fonction a été implémentée en langage **R** [113]. L'équation 2.2 ne peut être résolue directement que par une *backward recursion* dans les cas où $\gamma \leq 1$ ou $p \leq 1$, nous avons donc utilisé une résolution utilisant la méthode *Bellman-Ford backward* [114]. La particularité de notre implémentation est l'utilisation de tableaux. Inspirée par le *look-up table*, elle permet de résoudre en même temps tous les chemins possibles en partant des destinations finales.

La *politique* optimale consiste à trouver à chaque itération la combinaison ayant le coût minimal.

Pour cette optimisation globale, le nombre de solutions permettant d'atteindre l'optimum est rarement unique. Une contrainte additionnelle liée au niveau de variation de la variable de décision a été incluse afin de choisir la solution qui sollicitera le moins le système. Dans le cas où plusieurs solutions présenteraient les mêmes coûts, la solution retenue est donc celle qui admet la plus faible variation de la valeur de variable de décision entre deux étapes.

La structure du listing 2.1 est assez simple, elle permet la résolution d'une PDP en *Backward Recursion* pour une fonction coût $Cost_0$.

Listing 2.1 – Code R pour la résolution d’une PDP en BACKWARD RECURSION

```

1 # /*=====
2 # =          backward PDP          =
3 # =====*/
4 back0pdp <- function(St, T, Cost0, ...) {
5 # Entrées:
6   #  $S_t = \{S_{min}, \dots, S_{max}\}$  est le vecteur de tout les états possibles
7     de longueur n.
8   # T est le nombre d'étapes à résoudre.
9   # Cost0 est la fonction coût à minimiser ou maximiser
10 # Sorties: Matrices de dimension  $n \times (T+1)$ 
11   # Table des Valeurs ( $V_t$ )
12   # Table des chemins ( $X_t$ )
13
14   l0 <- length(St) # Nombre d'état possibles
15    $V_t$  <- matrix(0, nrow = l0, ncol = T) # Table des coûts
16    $X_t$  <- matrix(0, nrow = l0, ncol = T) # Table des chemins
17   u0 <- numeric(T) + 1 # Vecteur unité pour calcul de coût
18   u0[T] <- 0 # Coût nul pour l'état final
19   for (t in seq(T, 1)) {
20     for (n in seq(l0)) {
21        $\Delta S_t$  <- St[n] - St # Variations des  $S_t$  possibles
22        $C_{t0}$  <- Cost0( $\Delta S_t$ , t, ...) # Coûts correspondant aux
23         variation de  $S_t$ 
24        $C_t$  <-  $C_{t0}$ [[1]] # Contributions aux coût
25        $V_{t0}$  <-  $C_t + V_t[, t + 1 * u_0[t]]$  # Évolution de la fonction
26         valeur
27        $V_t[n, t]$  <- min( $V_{t0}$ ) # Affecter la valeur minimale a la
28         table
29       idmin <- which( $V_{t0} ==$  min( $V_{t0}$ )) # Recherche des valeurs
30         minimales
31        $X_{min}$  <- ( $C_{t0}$ [[2]][idmin]) # Liste des valeurs minimales
32         selon la puissance
33       id0 <- which( $X_{min} ==$  min( $X_{min}$ ))[1] # Première valeur
34         minimale
35        $X_t[n, t]$  <- idmin[id0] # Mise à jour de la table des
36         chemins
37     }
38   }
39   out1 <- list( $V_t$ ,  $X_t$ )
40   names(out1) <- c("values", "indexes.table")
41   return(out1)
42 }
43 back0pdp <- cmpfun(back0pdp)
44 # /*===== Backward DP =====*/

```

2.2.7 Méthode de référence SDDP

Les caractéristiques et contraintes du problème de planification d'UC choisi ont conduit au choix de la PDP. Même si en théorie cette approche semble adaptée et prometteuse, rien ne garantit qu'elle soit plus efficace que d'autres méthodes déjà développées pour ce type de problème. Il est donc nécessaire de disposer d'une méthode de référence afin d'évaluer de manière comparative les performances de l'approche par PDP que nous proposons. Cette méthode de référence doit être largement utilisée par la communauté et elle doit prendre en compte les incertitudes de la production EnR.

La méthode de résolution comparative sélectionnée dans ce travail sera la programmation dynamique stochastique duale (SDDP). Le SDDP est à la fois une programmation dynamique (DP) et une programmation stochastique (SP) comme l'a fait remarquer Shapiro [85].

Proposée par Pereira et Pinto [15], la SDDP a par exemple été appliquée pour la planification de l'énergie dans la gestion de 39 générateurs hydroélectriques en prenant en compte l'incertitude de production. Dans ce premier exemple, le problème d'optimisation était formulé de manière linéaire. De même, Hjelmeland et al. [115] ont utilisé une extension de la SDDP pour planifier le fonctionnement de générateurs hydroélectriques, cette fois-ci pour une formulation non-linéaire du problème. Nous pouvons aussi citer le travail de Cerisola et al. [116] qui a mis en oeuvre la SDDP pour le contrôle de générateurs hydrothermales (hydro-électrique et thermique). Dans le cas des EnR intermittentes, la SDDP a permis à Papavasiliou et al. [117] de gérer l'injection d'énergie sur le réseau à partir d'un stockage. Enfin, Zou et al. [118] ont appliqué une extension de la SDDP pour un problème de planification d'UC en y incluant les contraintes du réseau de transport (réseau testé : IEEE 118-bus). La SDDP correspond donc une méthode largement utilisée pour la résolution de problèmes de planification d'UC prenant en compte l'incertitude sur la production d'énergie.

Dans les travaux de Dowson et Kapelevich [109], la *politique* générée par la SDDP se présente sous une forme de programmes linéaires à résoudre à chaque étape. Pour définir l'action à prendre à une étape $t + 1$, le programme a tout d'abord besoin de connaître l'état du système S_t ainsi que la réalisation de la variable aléatoire ξ_t . Une solution approximative du programme linéaire est obtenue avec ces valeurs.

Pour la résolution proprement dite, la SDDP sélectionnée [15] correspond à une LP à 2 étages (cf. 2.2.4). La SDDP exploite la forme en L (L -shaped) du problème de la LP [119]. Le programme linéaire à 2 étages à résoudre, qui vous a déjà été présenté dans la section 2.2.4, vous est donné à nouveau ici :

$$J = \min_x \quad c^\top x + \mathbb{E}[Q(x, \Xi)] \quad (2.11)$$

Les variables y du deuxième étage (*recourse*), donné dans l'équation 2.12 présentée à nouveau ci-dessous, correspondent à tous les scénarios simulés. Ces scénarios sont considérés comme n'ayant pas de corrélation entre eux ou n'étant pas liés. Les sous-problèmes qui composent l'étage 2 peuvent être résolus indépendamment une fois que les variables x de l'étage 1 sont fixées. Dans ce cas, le deuxième étage peut être perçu comme une espérance de l'agrégation de la fonction coût, mais dépendante des variables de l'étage 1. La décomposition de Benders permet de faire des approximations basées sur les plans de coupe pour la résolution du problème

principale (éq. 2.10).

$$\begin{aligned}
 Q(x, \xi) = \min_y \quad & q^\top y \\
 \text{s.t.} \quad & Ux + Wy \geq h, \\
 & y \geq 0.
 \end{aligned} \tag{2.12}$$

Pour la résolution de la SDDP, le problème est donc divisé en 2 étages (fig .2.17). Avec des méthodes d'échantillonnage, un nombre M de scénarios sont générés à partir de la distribution de l'incertitude des variables aléatoires. Ces M scénarios correspondent aux M sous-problèmes à résoudre au niveau du deuxième étage.




FIGURE 2.17 – Décomposition du problème SDDP [15] en 2 étages avec M scénarios générés

Avec l'hypothèse que le côté droit « b » de la contrainte de l'équation 2.10 est un vecteur constitué de variables aléatoires indépendantes $b = [b_1, \xi^1, \xi^2, \dots, \xi^K] = [b_1, \Xi]$ et chaque étape ξ_t peut être discrétisée en M scénarios avec des probabilités p_{tj} . Le nombre de scénarios est alors de $M \times K$. Pour une décision x_t , l'espérance du coût futur est $\mathbb{E}(Q(x, \Xi)) = \bar{\beta}_t(x_t)$, d'où l'équation 2.30. La résolution proprement dite est réalisée avec l'algorithme SDDP de Pereira et Pinto [15] (list. 2.2).

Listing 2.2 – Algorithme de résolution de la SDDP [15]

1. Définir un ensemble de décisions \hat{x}_{ti} for $i = \{1, \dots, n\}$ & $t = \{1, \dots, T\}$
2. Répéter pour $t = \{T, T - 1, \dots, 2\}$ (BAKWARD RECURSION)
 - Répéter pour chaque élément de décision \hat{x}_{ti} $i = \{1, \dots, n\}$
 - Répéter pour chaque scénario ξ_{tj} , $j = \{1, \dots, M\}$
 - Résoudre l'optimisation pour t , \hat{x}_{t-1i} , et ξ_{tj}

$$\begin{aligned}
 \min \quad & c_t x_t + \bar{\beta}_t(x_t) \\
 \text{s.t.} \quad & A_t x_t \geq b_{tj} - E_{t-1} \hat{x}_{t-1i}
 \end{aligned} \tag{2.30}$$

Soit, μ_{t-1ij} , le multiplicateur associé aux contraintes de l'équation 2.30 à sa solution optimale. Le multiplicateur μ est le MULTIPLICATEUR SIMPLEX [120] dans le cas de la LP. A_t et E_{t-1} les éléments de la matrices A (coté gauche de la contrainte) de l'équation 2.10 .
 Calculer l'espérance $\bar{\mu}_{t-1i} = \sum_{j=1}^M p_{tj} \mu_{t-1ij}$, et construire un

hyperplan de support de l'espérance approximative de la
fonction coût future pour $t - 1$, $\bar{\beta}_{t-1}(x_{t-1})$.

3. Retour à l'étape 1

Il est à noter que l'utilisation de la SDDP nécessite obligatoirement que la fonction objective soit convexe. De plus, la condition de non-anticipation implique que les variables aléatoires soient indépendantes dans le temps. Enfin, pour les cas d'études qui suivront dans les chapitres suivants, les résolutions SDDP du système ont été réalisées sous **Julia** [121] à l'aide du package «SDDP.JL» de Dowson et Kapelevich [109].

2.3 Conclusion

Dans cette section, nous avons proposé un état de l'art sur les méthodes d'optimisation en gestion de l'énergie, avec un intérêt particulier sur l'intégration des prévisions de production de systèmes utilisant des sources d'énergie renouvelable intermittente. L'accent était mis principalement sur les problèmes d'allocations de ressources, en particulier le problème de planification prédictive de ressource dans les réseaux électriques, que nous avons appelé UC. L'objectif est d'avoir une vision claire des approches développées pour résoudre les problèmes d'optimisation de la planification d'UC en présence d'incertitudes dues aux EnR intermittentes.

Dans la littérature, nous avons pu constater que les incertitudes ont été prises en compte dans les problèmes de planification d'UC depuis les années 1980 par le recours à l'optimisation stochastique. Nous avons mis en avant 2 approches possibles pour intégrer les incertitudes liées à la production des EnR intermittentes : avec et sans prévision. Lorsque la prévision n'est pas prise en compte, les variables aléatoires (incertitudes) sont considérées comme indépendantes et elles sont modélisées par leur historique. Dans le cas où la prévision est considérée, il est souvent nécessaire de construire des scénarios intégrant les corrélations temporelles, voire spatiales, des variables aléatoires. Les travaux cités dans ce chapitre montrent que la prévision est progressivement devenue une clé majeure dans la problématique d'intégration massive des EnR intermittentes dans les réseaux d'énergie.

À partir de notre analyse des techniques de prévision à court terme de la production d'EnR intermittentes et des méthodes d'optimisation stochastiques existantes, nous avons sélectionné la programmation dynamique probabiliste (PDP). En effet, cette méthode nous semble être un outil pertinent pour incorporer les prévisions probabilistes d'EnR intermittentes dans la résolution de problèmes de planification d'UC. D'autre part, nous avons aussi choisi la programmation dynamique duale stochastique (SDDP) comme méthode de référence. Cette technique d'optimisation stochastique est largement utilisée dans les problèmes de planification énergétique soumise à des incertitudes. La version que nous utiliserons s'appuiera sur les historiques de production pour modéliser les incertitudes.

Afin de tester les performances de la méthode d'optimisation stochastique sélectionnée, la PDP, des simulations numériques seront effectuées sur un cas d'études réel. Le système sur lequel nous réaliserons les tests est un microréseau connecté au réseau électrique de l'île de La Réunion. Il est constitué d'un bâtiment universitaire à très faible consommation énergétique couplé à un générateur PV intégré en toiture. Les simulations auront pour objectif de minimiser le coût de fonctionnement de ce microréseau en planifiant les charges et les décharges d'un stockage d'énergie par batterie. La première application de la méthode d'optimisation se

concentrera sur l'utilisation de la programmation dynamique avec des prévisions déterministes de la production du champ PV. La seconde, mettra en oeuvre la PDP en considérant des prévisions probabilistes.

Bibliographie

- [1] Z. Zhou, C. Liu, et A. Botterud, "Stochastic Methods Applied to Power System Operations with Renewable Energy : A Review," Argonne National Lab. (ANL), Argonne, IL (United States), Rapport technique ANL/ESD-16/14, Août 2016. [En line]. Disponible : <https://doi.org/https://doi.org/10.2172/1307655>
- [2] T. S. Dillon, K. W. Edwin, H.-D. Kochs, et R. J. Taud, "Integer Programming Approach to the Problem of Optimal Unit Commitment with Probabilistic Reserve Determination," *IEEE Transactions on Power Apparatus and Systems*, vol. PAS-97, n^o. 6, p. 2154–2166, Nov. 1978. [En line]. Disponible : <https://doi.org/10.1109/TPAS.1978.354719>
- [3] A. Merlin et P. Sandrin, "A New Method for Unit Commitment at Electricite De France," *IEEE Transactions on Power Apparatus and Systems*, vol. PAS-102, n^o. 5, p. 1218–1225, Mai 1983, conference Name : IEEE Transactions on Power Apparatus and Systems. [En line]. Disponible : <https://doi.org/10.1109/TPAS.1983.318063>
- [4] I. Abdou et M. Tkiouat, "Unit Commitment Problem in Electrical Power System : A Literature Review," *International Journal of Electrical and Computer Engineering (IJECE)*, vol. 8, n^o. 3, p. 1357, Juin 2018. [En line]. Disponible : <https://doi.org/10.11591/ijece.v8i3.pp1357-1372>
- [5] A. Ruszczyński et A. Shapiro, "Stochastic Programming Models," dans *Handbooks in Operations Research and Management Science*, ser. Stochastic Programming. Elsevier, Janv. 2003, vol. 10, p. 1–64. [En line]. Disponible : [https://doi.org/10.1016/S0927-0507\(03\)10001-1](https://doi.org/10.1016/S0927-0507(03)10001-1)
- [6] E. Delarue et J. Morris, "Renewables Intermittency : Operational Limits and Implications for Long-Term Energy System Models," MIT Joint Program on the Science and Policy of Global Change, Technical Report, Mars 2015, accepted : 2015-03-03T19 :27 :43Z. [En line]. Disponible : <http://hdl.handle.net/1721.1/95762>
- [7] S. Y. Abujarad, M. W. Mustafa, et J. J. Jamian, "Recent approaches of unit commitment in the presence of intermittent renewable energy resources : A review," *Renewable and Sustainable Energy Reviews*, vol. 70, p. 215–223, Avr. 2017. [En line]. Disponible : <https://doi.org/10.1016/j.rser.2016.11.246>
- [8] N. V. Sahinidis, "Optimization under uncertainty : state-of-the-art and opportunities," *Computers & Chemical Engineering*, vol. 28, n^o. 6, p. 971–983, Juin 2004. [En line]. Disponible : <https://doi.org/10.1016/j.compchemeng.2003.09.017>
- [9] S. Takriti, J. R. Birge, et E. Long, "A stochastic model for the unit commitment problem," *IEEE Transactions on Power Systems*, vol. 11, n^o. 3, p. 1497–1508, Août 1996, conference Name : IEEE Transactions on Power Systems. [En line]. Disponible : <https://doi.org/10.1109/59.535691>

- [10] R. Perez, M. David, T. E. Hoff, M. Jamaly, S. Kivalov, J. Kleissl, P. Lauret, et M. Perez, “Spatial and Temporal Variability of Solar Energy,” *Foundations and Trends® in Renewable Energy*, vol. 1, n° 1, p. 1–44, 2016. [En line]. Disponible : <https://doi.org/10.1561/27000000006>
- [11] IRENA, *Innovation landscape for a renewable-powered future : Solutions to integrate variable renewables*. Abu Dhabi : International Renewable Energy Agency, 2019. [En line]. Disponible : <https://www.irena.org/publications/2019/Feb/Innovation-landscape-for-a-renewable-powered-future>
- [12] S. W. Wallace et S.-E. Fleten, “Stochastic Programming Models in Energy,” dans *Handbooks in Operations Research and Management Science*. Elsevier, 2003, vol. 10, p. 637–677. [En line]. Disponible : [https://doi.org/10.1016/S0927-0507\(03\)10010-2](https://doi.org/10.1016/S0927-0507(03)10010-2)
- [13] W. B. Powell, “A Unified Framework for Optimization Under Uncertainty,” dans *Optimization Challenges in Complex, Networked and Risky Systems*, ser. INFORMS TutORials in Operations Research. INFORMS, Oct. 2016, p. 45–83, section : 3. [En line]. Disponible : <https://doi.org/10.1287/educ.2016.0149>
- [14] R. E. Bellman, *Dynamic Programming*, ser. Princeton Landmarks in Mathematics and Physics. Princeton University Press, 1957. [En line]. Disponible : <https://press.princeton.edu/books/paperback/9780691146683/dynamic-programming>
- [15] M. V. F. Pereira et L. M. V. G. Pinto, “Multi-stage stochastic optimization applied to energy planning,” *Mathematical Programming*, vol. 52, n° 1, p. 359–375, Mai 1991. [En line]. Disponible : <https://doi.org/10.1007/BF01582895>
- [16] F. Pacaud, P. Carpentier, J.-P. Chancelier, et M. De Lara, “Stochastic optimal control of a domestic microgrid equipped with solar panel and battery,” *arXiv :1801.06479 [math]*, Janv. 2018. [En line]. Disponible : <https://doi.org/10.48550/arXiv.1801.06479>
- [17] P. Haessig, T. Kovaltchouk, B. Multon, H. B. Ahmed, et S. Lascaud, “Computing an Optimal Control Policy for an Energy Storage,” *arXiv :1404.6389 [cs]*, Avr. 2014, arXiv : 1404.6389. [En line]. Disponible : <https://doi.org/10.48550/arXiv.1404.6389>
- [18] A. Shapiro, D. Dentcheva, et A. Ruszczyński, *Lectures on stochastic programming : modeling and theory*. SIAM, 2014. [En line]. Disponible : <https://doi.org/10.1137/1.9781611973433>
- [19] L. A. Korf et R. J.-B. Wets, “An Ergodic Theorem for Stochastic Programming Problems,” dans *Optimization : Proceedings of the 9th Belgian-French-German Conference on Optimization Namur, September 7–11, 1998*, ser. Lecture Notes in Economics and Mathematical Systems, V. H. Nguyen, J.-J. Strodiot, et P. Tossings, édit. Berlin, Heidelberg : Springer, 2000, p. 203–217. [En line]. Disponible : https://doi.org/10.1007/978-3-642-57014-8_14
- [20] A. Shapiro, “Monte Carlo Sampling Methods,” dans *Handbooks in Operations Research and Management Science*. Elsevier, 2003, vol. 10, p. 353–425. [En line]. Disponible : [https://doi.org/10.1016/S0927-0507\(03\)10006-0](https://doi.org/10.1016/S0927-0507(03)10006-0)

- [21] A. Ruszczyński, “Decomposition Methods,” dans *Stochastic Programming*, ser. Handbooks in Operations Research and Management Science, A. Ruszczyński et A. Shapiro, édit. Elsevier Science B.V., 2003, vol. 10. [En line]. Disponible : <https://doi.org/10.1007/BF02614323>
- [22] R. T. Rockafellar et R. J.-B. Wets, “Nonanticipativity and L^1 -martingales in stochastic optimization problems,” dans *Stochastic Systems : Modeling, Identification and Optimization, II*, ser. Mathematical Programming Studies, R. J.-B. Wets, édit. Berlin, Heidelberg : Springer, 1976, p. 170–187. [En line]. Disponible : <https://doi.org/10.1007/BFb0120750>
- [23] P. Pinson, P. McSharry, et H. Madsen, “Reliability diagrams for non-parametric density forecasts of continuous variables : Accounting for serial correlation,” *Quarterly Journal of the Royal Meteorological Society*, vol. 136, n°. 646, p. 77–90, 2010. [En line]. Disponible : <https://doi.org/10.1002/qj.559>
- [24] J. B. Bremnes, “Probabilistic wind power forecasts using local quantile regression,” *Wind Energy*, vol. 7, n°. 1, Mars 2004. [En line]. Disponible : <https://doi.org/https://doi.org/10.1002/we.107>
- [25] H. A. Nielsen, H. Madsen, et T. S. Nielsen, “Using quantile regression to extend an existing wind power forecasting system with probabilistic forecasts,” *Wind Energy*, vol. 9, n°. 1-2, p. 95–108, Janv. 2006. [En line]. Disponible : <https://doi.org/https://doi.org/10.1002/we.180>
- [26] H. A. Nielsen, T. S. Nielsen, H. Madsen, G. Giebel, J. Badger, L. Landberg, K. Sattler, L. Voulund, et J. Tofting, “From wind ensembles to probabilistic information about future wind power production – results from an actual application,” dans *2006 International Conference on Probabilistic Methods Applied to Power Systems*, Juin 2006, p. 1–8. [En line]. Disponible : <https://doi.org/10.1109/PMAPS.2006.360289>
- [27] 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*, vol. 2, n°. 1, p. 2–10, Mars 2009, conference Name : IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing. [En line]. Disponible : <https://doi.org/10.1109/JSTARS.2009.2020300>
- [28] M. Diagne, M. David, P. Lauret, J. Boland, et N. Schmutz, “Review of solar irradiance forecasting methods and a proposition for small-scale insular grids,” *Renewable and Sustainable Energy Reviews*, vol. 27, p. 65–76, Nov. 2013. [En line]. Disponible : <https://doi.org/10.1016/j.rser.2013.06.042>
- [29] M. Abuella et B. Chowdhury, “Solar power probabilistic forecasting by using multiple linear regression analysis,” dans *SoutheastCon 2015*. Fort Lauderdale, FL, USA : IEEE, Avr. 2015, p. 1–5. [En line]. Disponible : <https://doi.org/10.1109/SECON.2015.7132869>
- [30] M. David, F. Ramahatana, P. Trombe, et P. Lauret, “Probabilistic forecasting of the solar irradiance with recursive ARMA and GARCH models,” *Solar Energy*, vol. 133, p. 55–72, Août 2016. [En line]. Disponible : <https://doi.org/10.1016/j.solener.2016.03.064>

- [31] M. David et P. Lauret, “Solar Radiation Probabilistic Forecasting,” dans *Wind Field and Solar Radiation Characterization and Forecasting*, R. Perez, édit. Cham : Springer International Publishing, 2018, p. 201–227. [En line]. Disponible : https://doi.org/10.1007/978-3-319-76876-2_9
- [32] F. Golestaneh, P. Pinson, et H. B. Gooi, “Very Short-Term Nonparametric Probabilistic Forecasting of Renewable Energy Generation— With Application to Solar Energy,” *IEEE Transactions on Power Systems*, vol. 31, n^o. 5, p. 3850–3863, Sept. 2016, conference Name : IEEE Transactions on Power Systems. [En line]. Disponible : <https://doi.org/10.1109/TPWRS.2015.2502423>
- [33] Q. P. Zheng, J. Wang, et A. L. Liu, “Stochastic Optimization for Unit Commitment—A Review,” *IEEE Transactions on Power Systems*, vol. 30, n^o. 4, p. 1913–1924, Juill. 2015, conference Name : IEEE Transactions on Power Systems. [En line]. Disponible : <https://doi.org/10.1109/TPWRS.2014.2355204>
- [34] W. Gu, Z. Wu, R. Bo, W. Liu, G. Zhou, W. Chen, et Z. Wu, “Modeling, planning and optimal energy management of combined cooling, heating and power microgrid : A review,” *International Journal of Electrical Power & Energy Systems*, vol. 54, p. 26–37, Janv. 2014. [En line]. Disponible : <https://doi.org/10.1016/j.ijepes.2013.06.028>
- [35] B. Saravanan, S. Das, S. Sikri, et D. P. Kothari, “A solution to the unit commitment problem—a review,” *Frontiers in Energy*, vol. 7, n^o. 2, p. 223–236, Juin 2013. [En line]. Disponible : <https://doi.org/10.1007/s11708-013-0240-3>
- [36] L. I. Minchala-Avila, L. E. Garza-Castañón, A. Vargas-Martínez, et Y. Zhang, “A Review of Optimal Control Techniques Applied to the Energy Management and Control of Microgrids,” *Procedia Computer Science*, vol. 52, p. 780–787, Janv. 2015. [En line]. Disponible : <https://doi.org/10.1016/j.procs.2015.05.133>
- [37] “A review of population-based meta-heuristic algorithms,” vol. 5, n^o. 1. [En line]. Disponible : https://www.researchgate.net/publication/270750820_A_review_of_population-based_meta-heuristic_algorithm
- [38] A. A. Juan, J. Faulin, S. E. Grasman, M. Rabe, et G. Figueira, “A review of simheuristics : Extending metaheuristics to deal with stochastic combinatorial optimization problems,” *Operations Research Perspectives*, vol. 2, p. 62–72, Déc. 2015. [En line]. Disponible : <https://doi.org/10.1016/j.orp.2015.03.001>
- [39] K.-H. Jo et M.-K. Kim, “Improved Genetic Algorithm-Based Unit Commitment Considering Uncertainty Integration Method,” *Energies*, vol. 11, n^o. 6, p. 1387, Juin 2018. [En line]. Disponible : <https://doi.org/10.3390/en11061387>
- [40] S. Maghsudlu et S. Mohammadi, “Optimal scheduled unit commitment considering suitable power of electric vehicle and photovoltaic uncertainty,” *Journal of Renewable and Sustainable Energy*, vol. 10, n^o. 4, p. 043705, Juill. 2018. [En line]. Disponible : <https://doi.org/10.1063/1.5009247>

- [41] L. Bianchi, M. Dorigo, L. M. Gambardella, et W. J. Gutjahr, “A survey on metaheuristics for stochastic combinatorial optimization,” *Natural Computing*, vol. 8, n^o. 2, p. 239–287, Juin 2009. [En line]. Disponible : <https://doi.org/10.1007/s11047-008-9098-4>
- [42] Y. Riffonneau, S. Bacha, F. Barruel, et S. Ploix, “Optimal Power Flow Management for Grid Connected PV Systems With Batteries,” *IEEE Transactions on Sustainable Energy*, vol. 2, n^o. 3, p. 309–320, Juill. 2011. [En line]. Disponible : <https://doi.org/10.1109/TSTE.2011.2114901>
- [43] Y. Yang, S. Bremner, C. Menictas, et M. Kay, “A Mixed Receding Horizon Control Strategy for Battery Energy Storage System Scheduling in a Hybrid PV and Wind Power Plant with Different Forecast Techniques,” *Energies*, vol. 12, n^o. 12, p. 2326, Juin 2019. [En line]. Disponible : <https://doi.org/10.3390/en12122326>
- [44] E. F. Camacho et C. Bordons, *Model Predictive Control in the Process Industry*, ser. Advances in Industrial Control. London : Springer-Verlag, 1995. [En line]. Disponible : <https://doi.org/10.1007/978-1-4471-3008-6>
- [45] L. Ljung, *System Identification : Theory for the User*. Pearson Education, Déc. 1998. [En line]. Disponible : <https://doi.org/10.1109/MRA.2012.2192817>
- [46] P. Kou, F. Gao, et X. Guan, “Stochastic predictive control of battery energy storage for wind farm dispatching : Using probabilistic wind power forecasts,” *Renewable Energy*, vol. 80, p. 286–300, Août 2015. [En line]. Disponible : <https://doi.org/10.1016/j.renene.2015.02.001>
- [47] D. van der Meer, G. C. Wang, et J. Munkhammar, “An alternative optimal strategy for stochastic model predictive control of a residential battery energy management system with solar photovoltaic,” *Applied Energy*, p. 116289, Déc. 2020. [En line]. Disponible : <https://doi.org/10.1016/j.apenergy.2020.116289>
- [48] W. van Ackooij, I. Danti Lopez, A. Frangioni, F. Lacalandra, et M. Tahanan, “Large-scale unit commitment under uncertainty : an updated literature survey,” *Annals of Operations Research*, vol. 271, n^o. 1, p. 11–85, Déc. 2018. [En line]. Disponible : <https://doi.org/10.1007/s10479-018-3003-z>
- [49] M. Håberg, “Fundamentals and recent developments in stochastic unit commitment,” *International Journal of Electrical Power & Energy Systems*, vol. 109, p. 38–48, Juill. 2019. [En line]. Disponible : <https://doi.org/10.1016/j.ijepes.2019.01.037>
- [50] W. B. Powell, “Clearing the Jungle of Stochastic Optimization,” dans *Bridging Data and Decisions*, A. M. Newman, J. Leung, J. C. Smith, et H. J. Greenberg, édit. INFORMS, Sept. 2014, p. 109–137. [En line]. Disponible : <https://doi.org/10.1287/educ.2014.0128>
- [51] N. Zhang, C. Kang, Q. Xia, Y. Ding, Y. Huang, R. Sun, J. Huang, et J. Bai, “A Convex Model of Risk-Based Unit Commitment for Day-Ahead Market Clearing Considering Wind Power Uncertainty,” *IEEE Transactions on Power Systems*, vol. 30, n^o. 3, p. 1582–1592, Mai 2015, conference Name : IEEE Transactions on Power Systems. [En line]. Disponible : <https://doi.org/10.1109/TPWRS.2014.2357816>

- [52] C. Ordoudis, P. Pinson, M. Zugno, et J. M. Morales, “Stochastic unit commitment via Progressive Hedging — extensive analysis of solution methods,” dans *2015 IEEE Eindhoven PowerTech*, Juin 2015, p. 1–6. [En line]. Disponible : <https://doi.org/10.1109/PTC.2015.7232629>
- [53] T. Shiina et J. R. Birge, “Stochastic unit commitment problem,” *International Transactions in Operational Research*, vol. 11, n^o. 1, p. 19–32, 2004. [En line]. Disponible : <https://doi.org/https://doi.org/10.1111/j.1475-3995.2004.00437.x>
- [54] Y. Dvorkin, H. Pandžić, M. A. Ortega-Vazquez, et D. S. Kirschen, “A Hybrid Stochastic/Interval Approach to Transmission-Constrained Unit Commitment,” *IEEE Transactions on Power Systems*, vol. 30, n^o. 2, p. 621–631, Mars 2015, conference Name : IEEE Transactions on Power Systems. [En line]. Disponible : <https://doi.org/10.1109/TPWRS.2014.2331279>
- [55] A. Kalantari, J. F. Restrepo, et F. D. Galiana, “Security-Constrained Unit Commitment With Uncertain Wind Generation : The Loadability Set Approach,” *IEEE Transactions on Power Systems*, vol. 28, n^o. 2, p. 1787–1796, Mai 2013, conference Name : IEEE Transactions on Power Systems. [En line]. Disponible : <https://doi.org/10.1109/TPWRS.2012.2230029>
- [56] A. Shapiro et A. Nemirovski, “On Complexity of Stochastic Programming Problems,” dans *Continuous Optimization : Current Trends and Modern Applications*, ser. Applied Optimization, V. Jeyakumar et A. Rubinov, édit. Boston, MA : Springer US, 2005, p. 111–146. [En line]. Disponible : https://doi.org/10.1007/0-387-26771-9_4
- [57] R. Barth, L. Söder, C. Weber, H. Brand, et D. J. Swider, “Wilmar : Methodology of the Scenario Tree Tool,” Institute of Energy Economics and the Rational Use of Energy, University of Stuttgart, Stuttgart, Germany, Documentation Deliverable 6.2 (d), Janv. 2006. [En line]. Disponible : http://www.wilmar.risoe.dk/Deliverables/Wilmar%20d6_2_d_ScenarioTree_doc.pdf
- [58] A. Tuohy, P. Meibom, E. Denny, et M. O’Malley, “Benefits of Stochastic Scheduling for Power Systems with Significant Installed Wind Power,” dans *Proceedings of the 10th International Conference on Probabilistic Methods Applied to Power Systems*, Mai 2008, p. 1–7.
- [59] —, “Unit Commitment for Systems With Significant Wind Penetration,” *IEEE Transactions on Power Systems*, vol. 24, n^o. 2, p. 592–601, Mai 2009, conference Name : IEEE Transactions on Power Systems. [En line]. Disponible : <https://doi.org/10.1109/TPWRS.2009.2016470>
- [60] E. Ela, M. Milligan, P. Meibom, R. Barth, et A. Tuohy, “Advanced Unit Commitment Strategies for the U.S. Eastern Interconnection,” National Renewable Energy Lab. (NREL), Golden, CO (United States), Rapport technique NREL/CP-5500-49106, Oct. 2010. [En line]. Disponible : <https://www.osti.gov/biblio/991977>
- [61] P. Meibom, R. Barth, B. Hasche, H. Brand, C. Weber, et M. O’Malley, “Stochastic Optimization Model to Study the Operational Impacts of High Wind Penetrations in

- Ireland,” *IEEE Transactions on Power Systems*, vol. 26, n^o. 3, p. 1367–1379, Août 2011, conference Name : IEEE Transactions on Power Systems. [En line]. Disponible : <https://doi.org/10.1109/TPWRS.2010.2070848>
- [62] A. Sturt et G. Strbac, “Efficient Stochastic Scheduling for Simulation of Wind-Integrated Power Systems,” *IEEE Transactions on Power Systems*, vol. 27, n^o. 1, p. 323–334, Févr. 2012, conference Name : IEEE Transactions on Power Systems. [En line]. Disponible : <https://doi.org/10.1109/TPWRS.2011.2164558>
- [63] A. Botterud, Z. Zhou, J. Wang, J. Valenzuela, J. Sumaili, R. J. Bessa, H. Keko, et V. Miranda, “Unit commitment and operating reserves with probabilistic wind power forecasts,” dans *2011 IEEE Trondheim PowerTech*, Juin 2011, p. 1–7. [En line]. Disponible : <https://doi.org/10.1109/PTC.2011.6019263>
- [64] J. Wang, A. Botterud, R. Bessa, H. Keko, L. Carvalho, D. Issicaba, J. Sumaili, et V. Miranda, “Wind power forecasting uncertainty and unit commitment,” *Applied Energy*, vol. 88, n^o. 11, p. 4014–4023, Nov. 2011. [En line]. Disponible : <https://doi.org/10.1016/j.apenergy.2011.04.011>
- [65] P. Pinson, H. Madsen, H. A. Nielsen, G. Papaefthymiou, et B. Klöckl, “From probabilistic forecasts to statistical scenarios of short-term wind power production,” *Wind Energy*, vol. 12, n^o. 1, p. 51–62, Janv. 2009. [En line]. Disponible : <https://doi.org/10.1002/we.284>
- [66] B. Li et J. Zhang, “A review on the integration of probabilistic solar forecasting in power systems,” *Solar Energy*, vol. 207, p. 777–795, 2020. [En line]. Disponible : <https://doi.org/10.1016/j.solener.2020.06.083>
- [67] E. Du, N. Zhang, C. Kang, et Q. Xia, “Scenario Map Based Stochastic Unit Commitment,” *IEEE Transactions on Power Systems*, vol. 33, n^o. 5, p. 4694–4705, Sept. 2018, conference Name : IEEE Transactions on Power Systems. [En line]. Disponible : <https://doi.org/10.1109/TPWRS.2018.2799954>
- [68] S. Yakowitz, “Dynamic programming applications in water resources,” *Water Resources Research*, vol. 18, n^o. 4, p. 673–696, Août 1982. [En line]. Disponible : <https://doi.org/10.1029/WR018i004p00673>
- [69] K. D. W. Nandalal et J. J. Bogardi, *Dynamic Programming Based Operation of Reservoirs : Applicability and Limits*, ser. International Hydrology Series. Cambridge University Press, Mai 2007. [En line]. Disponible : <https://doi.org/10.1017/CBO9780511535710>
- [70] W. L. Winston, *Operations Research : Applications and Algorithms*, 4^e éd. Belmont, Calif. : Duxbury Press, Juill. 2003. [En line]. Disponible : <https://itslearningakarmazyan.files.wordpress.com/2015/09/operation-research-applications-and-algorithms.pdf>
- [71] W. B. Powell, *Approximate Dynamic Programming : Solving the Curses of Dimensionality*. John Wiley & Sons, Oct. 2011. [En line]. Disponible : <https://doi.org/10.1002/9781118029176>

- [72] A. Gulli, *A Collection of Dynamic Programming Interview Questions Solved in C++*. Createspace Independent Pub, Mars 2014.
- [73] R. E. Bellman et S. E. Dreyfus, *Applied Dynamic Programming*. Princeton University Press, Déc. 2015. [En line]. Disponible : <https://press.princeton.edu/books/hardcover/9780691651873/applied-dynamic-programming>
- [74] S. M. Roberts, *Dynamic Programming in Chemical Engineering and Process Control*. Elsevier, Janv. 1964. [En line]. Disponible : <https://www.elsevier.com/books/dynamic-programming-in-chemical-engineering-and-process-control-by-sanford-m-roberts/roberts/978-0-12-589450-0>
- [75] D. P. Bertsekas, *Dynamic Programming and Stochastic Control*, ser. Mathematics in Science and Engineering. New York, San Francisco and London : Academic Press, Nov. 1976, n°. 125.
- [76] S. Sundar et Z. Shiller, “Optimal obstacle avoidance based on the Hamilton-Jacobi-Bellman equation,” *IEEE Transactions on Robotics and Automation*, vol. 13, n°. 2, p. 305–310, Avr. 1997, conference Name : IEEE Transactions on Robotics and Automation. [En line]. Disponible : <https://doi.org/10.1109/70.563653>
- [77] E. Keogh et A. Mueen, “Curse of Dimensionality,” dans *Encyclopedia of Machine Learning and Data Mining*, C. Sammut et G. I. Webb, édit. Boston, MA : Springer US, 2017, p. 314–315. [En line]. Disponible : https://doi.org/10.1007/978-1-4899-7687-1_192
- [78] D. P. Bertsekas et J. N. Tsitsiklis, *Neuro-dynamic Programming*. Athena Scientific, 1996. [En line]. Disponible : <http://athenasc.com/ndpbook.html>
- [79] C. J. Watkins et P. Dayan, “Q-learning,” *Machine learning*, vol. 8, n°. 3-4, p. 279–292, 1992, iSBN : 0885-6125 Publisher : Springer. [En line]. Disponible : <https://doi.org/10.1007/BF00992698>
- [80] D. P. de Farias et B. Van Roy, “On Constraint Sampling in the Linear Programming Approach to Approximate Dynamic Programming,” *Mathematics of Operations Research*, vol. 29, n°. 3, p. 462–478, Août 2004. [En line]. Disponible : <https://doi.org/10.1287/moor.1040.0094>
- [81] —, “The Linear Programming Approach to Approximate Dynamic Programming,” *Operations Research*, vol. 51, n°. 6, p. 850–865, Déc. 2003. [En line]. Disponible : <https://doi.org/10.1287/opre.51.6.850.24925>
- [82] E. Foufoula-Georgiou et P. K. Kitanidis, “Gradient dynamic programming for stochastic optimal control of multidimensional water resources systems,” *Water Resources Research*, vol. 24, n°. 8, p. 1345–1359, 1988. [En line]. Disponible : <https://doi.org/10.1029/WR024i008p01345>
- [83] D. P. Bertsekas, “Dynamic Programming and Suboptimal Control : A Survey from ADP to MPC*,” *European Journal of Control*, vol. 11, n°. 4, p. 310–334, Janv. 2005. [En line]. Disponible : <https://doi.org/10.3166/ejc.11.310-334>

- [84] ———, *Dynamic programming and optimal control*, 4^e éd., ser. Athena scientific optimization and computation series. Belmont, Massachusetts : Athena scientific, 1995, vol. 1. [En line]. Disponible : <http://athenasc.com/dpbook.html>
- [85] A. Shapiro, “Analysis of stochastic dual dynamic programming method,” *European Journal of Operational Research*, vol. 209, n^o. 1, p. 63–72, Févr. 2011. [En line]. Disponible : <https://doi.org/10.1016/j.ejor.2010.08.007>
- [86] D. P. Bertsekas, *Abstract Dynamic Programming*. Belmont, Massachusetts : Athena Scientific, Avr. 2013. [En line]. Disponible : https://web.mit.edu/dimitrib/www/abstractdp_MIT.html
- [87] J. Rust, “Chapter 14 Numerical dynamic programming in economics,” dans *Handbook of Computational Economics*. Elsevier, Janv. 1996, vol. 1, p. 619–729. [En line]. Disponible : [https://doi.org/10.1016/S1574-0021\(96\)01016-7](https://doi.org/10.1016/S1574-0021(96)01016-7)
- [88] I. Ioachim, S. Gelinas, F. Soumis, et J. Desrosiers, “A dynamic programming algorithm for the shortest path problem with time windows and linear node costs,” *Networks : An International Journal*, vol. 31, n^o. 3, p. 193–204, 1998, iSBN : 0028-3045 Publisher : Wiley Online Library. [En line]. Disponible : [https://doi.org/10.1002/\(SICI\)1097-0037\(199805\)31:3<193::AID-NET6>3.0.CO;2-A](https://doi.org/10.1002/(SICI)1097-0037(199805)31:3<193::AID-NET6>3.0.CO;2-A)
- [89] M. Sniedovich, “Dijkstra’s algorithm revisited : the dynamic programming connexion,” *Control and cybernetics*, vol. 35, n^o. 3, p. 599–620, 2006, iSBN : 0324-8569. [En line]. Disponible : <http://matwbn.icm.edu.pl/ksiazki/cc/cc35/cc3536.pdf>
- [90] M. V. F. Pereira et L. M. V. G. Pinto, “Stochastic Optimization of a Multireservoir Hydroelectric System : A Decomposition Approach,” *Water Resources Research*, vol. 21, n^o. 6, p. 779–792, 1985. [En line]. Disponible : <https://doi.org/10.1029/WR021i006p00779>
- [91] J. R. Birge et F. Louveaux, *Introduction to Stochastic Programming*. Springer New York, Juin 2011. [En line]. Disponible : <https://doi.org/10.1007/978-1-4614-0237-4>
- [92] A. Prékopa, “Probabilistic Programming,” dans *Handbooks in Operations Research and Management Science*, ser. Stochastic Programming, A. P. Ruszczyński et A. Shapiro, édit. Elsevier, Janv. 2003, vol. 10, p. 267–351. [En line]. Disponible : [https://doi.org/10.1016/S0927-0507\(03\)10005-9](https://doi.org/10.1016/S0927-0507(03)10005-9)
- [93] A. Shapiro et A. Philpott, “A tutorial on stochastic programming,” *Manuscript. Available at www2.isye.gatech.edu/ashapiro/publications.html*, vol. 17, 2007. [En line]. Disponible : <https://www-m9.ma.tum.de/foswiki/pub/SS2014/StochPro/TutorialSP.pdf>
- [94] M. Kaut, “Evaluation of scenario-generation methods for stochastic programming,” *Humboldt-Universität zu Berlin, Mathematisch-Naturwissenschaftliche Fakultät*, p. 14, 2003. [En line]. Disponible : <https://edoc.hu-berlin.de/bitstream/handle/18452/8948/100.pdf?sequence=1>

- [95] M. Loretan, “Generating market risk scenarios using principal components analysis : methodological and practical considerations,” *Manuscript, Federal Reserve Board*, 1997, publisher : Citeseer. [En line]. Disponible : <https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.617.2633&rep=rep1&type=pdf>
- [96] T. Pennanen et M. Koivu, *Integration quadratures in discretization of stochastic programs*. Humboldt-Universität zu Berlin, Mathematisch-Naturwissenschaftliche Fakultät II, Institut für Mathematik, Juin 2002, accepted : 2017-06-16T19 :48 :19Z. [En line]. Disponible : <https://doi.org/10.18452/8275>
- [97] D. R. Cariño, T. Kent, D. H. Myers, C. Stacy, M. Sylvanus, A. L. Turner, K. Watanabe, et W. T. Ziemba, “The Russell-Yasuda Kasai Model : An Asset/Liability Model for a Japanese Insurance Company Using Multistage Stochastic Programming,” *INFORMS Journal on Applied Analytics*, vol. 24, n^o. 1, p. 29–49, Févr. 1994, publisher : INFORMS. [En line]. Disponible : <https://doi.org/10.1287/inte.24.1.29>
- [98] M. C. Cario et B. L. Nelson, “Modeling and generating random vectors with arbitrary marginal distributions and correlation matrix,” Citeseer, Rapport technique, 1997. [En line]. Disponible : <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.48.281&rep=rep1&type=pdf>
- [99] K. Høyland, M. Kaut, et S. W. Wallace, “A Heuristic for Moment-Matching Scenario Generation,” *Computational Optimization and Applications*, vol. 24, n^o. 2, p. 169–185, Févr. 2003. [En line]. Disponible : <https://doi.org/10.1023/A:1021853807313>
- [100] J. Dupačová, G. Consigli, et S. W. Wallace, “Scenarios for Multistage Stochastic Programs,” *Annals of Operations Research*, vol. 100, n^o. 1, p. 25–53, Déc. 2000. [En line]. Disponible : <https://doi.org/10.1023/A:1019206915174>
- [101] G. Pflug, “Scenario tree generation for multiperiod financial optimization by optimal discretization,” *Mathematical Programming*, vol. 89, n^o. 2, p. 251–271, Janv. 2001. [En line]. Disponible : <https://doi.org/10.1007/PL00011398>
- [102] N. Di Domenica, C. Lucas, G. Mitra, et P. Valente, “Scenario generation for stochastic programming and simulation : a modelling perspective,” *IMA Journal of Management Mathematics*, vol. 20, n^o. 1, p. 1–38, Août 2007. [En line]. Disponible : <https://doi.org/10.1093/imaman/dpm027>
- [103] M. L. Puterman, *Markov Decision Processes : Discrete Stochastic Dynamic Programming*, ser. Wiley Series in Probability and Statistics. John Wiley & Sons, Ltd, Avr. 1994. [En line]. Disponible : <https://doi.org/10.1002/9780470316887>
- [104] C. Z. Mooney et R. D. Duval, *Bootstrapping : A Nonparametric Approach to Statistical Inference*. SAGE, Août 1993. [En line]. Disponible : <https://dx.doi.org/10.4135/9781412983532>
- [105] D. P. Morton et E. Popova, “Monte-Carlo simulations for stochastic optimization Monte—Carlo Simulations for Stochastic Optimization,” dans *Encyclopedia of Optimization*, C. A. Floudas et P. M. Pardalos, édit. Boston, MA : Springer US, 2001, p. 1529–1537. [En line]. Disponible : https://doi.org/10.1007/0-306-48332-7_305

- [106] W. J. Thistleton, J. A. Marsh, K. Nelson, et C. Tsallis, “Generalized Box–Müller Method for Generating q -Gaussian Random Deviates,” *IEEE Transactions on Information Theory*, vol. 53, n° 12, p. 4805–4810, Déc. 2007, conference Name : IEEE Transactions on Information Theory. [En line]. Disponible : <https://doi.org/10.1109/TIT.2007.909173>
- [107] P. M. Lurie et M. S. Goldberg, “An Approximate Method for Sampling Correlated Random Variables from Partially-Specified Distributions,” *Management Science*, vol. 44, n° 2, p. 203–218, Févr. 1998, publisher : INFORMS. [En line]. Disponible : <https://doi.org/10.1287/mnsc.44.2.203>
- [108] O. F. Demirel et T. R. Willemain, “Generation of Simulation Input Scenarios Using Bootstrap Methods,” *The Journal of the Operational Research Society*, vol. 53, n° 1, p. 69–78, 2002, publisher : Palgrave Macmillan Journals. [En line]. Disponible : <https://www.jstor.org/stable/822880>
- [109] O. Dowson et L. Kapelevich, “SDDP.jl : A Julia Package for Stochastic Dual Dynamic Programming,” *INFORMS Journal on Computing*, p. ijoc.2020.0987, Août 2020. [En line]. Disponible : <https://doi.org/10.1287/ijoc.2020.0987>
- [110] A. G. Barto, S. J. Bradtke, et S. P. Singh, “Learning to act using real-time dynamic programming,” *Artificial Intelligence*, vol. 72, n° 1-2, p. 81–138, Janv. 1995, publisher : Elsevier. [En line]. Disponible : [https://doi.org/10.1016/0004-3702\(94\)00011-O](https://doi.org/10.1016/0004-3702(94)00011-O)
- [111] W. B. Powell et I. O. Ryzhov, “Optimal Learning and Approximate Dynamic Programming,” dans *Reinforcement Learning and Approximate Dynamic Programming for Feedback Control*, F. L. Lewis et D. Liu, édit. Hoboken, NJ, USA : John Wiley & Sons, Inc., Févr. 2013, p. 410–431. [En line]. Disponible : <https://doi.org/10.1002/9781118453988.ch18>
- [112] J. N. Tsitsiklis et B. Van Roy, “Feature-Based Methods for Large Scale Dynamic Programming,” *Machine Learning*, vol. 22, n° 1, p. 59–94, Janv. 1996. [En line]. Disponible : <https://doi.org/10.1023/A:1018008221616>
- [113] R Core Team, *R : A Language and Environment for Statistical Computing*, R Foundation for Statistical Computing, Vienna, Austria, 2018. [En line]. Disponible : <http://www.R-project.org/>
- [114] B. V. Cherkassky, A. V. Goldberg, et T. Radzik, “Shortest paths algorithms : Theory and experimental evaluation,” *Mathematical Programming*, vol. 73, n° 2, p. 129–174, Mai 1996, 1158. [En line]. Disponible : <https://doi.org/10.1007/BF02592101>
- [115] M. N. Hjelmeland, J. Zou, A. Helseth, et S. Ahmed, “Nonconvex Medium-Term Hydropower Scheduling by Stochastic Dual Dynamic Integer Programming,” *IEEE Transactions on Sustainable Energy*, vol. 10, n° 1, p. 481–490, Janv. 2019, conference Name : IEEE Transactions on Sustainable Energy. [En line]. Disponible : <https://doi.org/10.1109/TSTE.2018.2805164>
- [116] S. Cerisola, J. M. Latorre, et A. Ramos, “Stochastic dual dynamic programming applied to nonconvex hydrothermal models,” *European Journal of Operational*

- Research*, vol. 218, n^o. 3, p. 687–697, Mai 2012. [En line]. Disponible : <https://doi.org/10.1016/j.ejor.2011.11.040>
- [117] A. Papavasiliou, Y. Mou, L. Cambier, et D. Scieur, “Application of Stochastic Dual Dynamic Programming to the Real-Time Dispatch of Storage Under Renewable Supply Uncertainty,” *IEEE Transactions on Sustainable Energy*, vol. 9, n^o. 2, p. 547–558, Avr. 2018, conference Name : IEEE Transactions on Sustainable Energy. [En line]. Disponible : <https://doi.org/10.1109/TSTE.2017.2748463>
- [118] J. Zou, S. Ahmed, et X. A. Sun, “Multistage Stochastic Unit Commitment Using Stochastic Dual Dynamic Integer Programming,” *IEEE Transactions on Power Systems*, vol. 34, n^o. 3, p. 1814–1823, Mai 2019, conference Name : IEEE Transactions on Power Systems. [En line]. Disponible : <https://doi.org/10.1109/TPWRS.2018.2880996>
- [119] R. M. Van Slyke et R. Wets, “L-Shaped Linear Programs with Applications to Optimal Control and Stochastic Programming,” *SIAM Journal on Applied Mathematics*, vol. 17, n^o. 4, p. 638–663, 1969, publisher : Society for Industrial and Applied Mathematics. [En line]. Disponible : <https://www.jstor.org/stable/2099310>
- [120] G. B. Dantzig et M. N. Thapa, *Linear programming*, ser. Springer series in operations research, P. W. Glynn et S. M. Robinson, édit. New York : Springer, 1997. [En line]. Disponible : <https://www.springer.com/gp/book/9780387986135>
- [121] J. Bezanson, A. Edelman, S. Karpinski, et V. B. Shah, “Julia : A Fresh Approach to Numerical Computing,” *SIAM Review*, vol. 59, n^o. 1, p. 65–98, Janv. 2017, publisher : Society for Industrial and Applied Mathematics. [En line]. Disponible : <https://doi.org/10.1137/141000671>

CHAPITRE 3

Microréseau et prévisions déterministes

All models are wrong, but some are useful

George E. P. Box

Sommaire

3.1	Introduction	100
3.2	Economic optimization of a micro-grid operations by dynamic programming with real energy forecast	101
3.2.1	Introduction	101
3.2.2	Methods and tools	102
3.2.2.1	Load forecasts	102
3.2.2.2	PV forecasts	103
3.2.2.3	Forecast quality	104
3.2.2.4	ESS model	104
3.2.2.5	Optimization	106
3.2.2.6	Dynamic Programming applied to ESS management	106
3.2.2.7	Objective function	106
3.2.2.8	Constraints	107
3.2.3	Implementation	108
3.2.3.1	Ruled based management	108
3.2.3.2	Controlled system with forecast	109
3.2.3.3	Performance indicators	109
3.2.4	Data	110
3.2.5	Results and discussion	112
3.2.5.1	Daily optimization	112
3.2.5.2	Forecasting window size	113
3.2.5.3	Forecast quality	114
3.2.5.4	Annual indexes	115
3.2.5.5	Conclusion	116
3.2.6	Nomenclature	117
3.3	Conclusion	118

3.1 Introduction

Le précédent chapitre a présenté les différents types de prévisions, ainsi que leurs modes d'intégration dans la gestion des systèmes énergétiques. Dans ce chapitre, il est fourni une version longue de l'article « Economic optimization of a micro-grid operations by dynamic programming with real energy forecast » [1] présenté au CISBAT 2019 à Lausanne Suisse et publié dans *Journal of Physics : Conference Series*. À partir de notre analyse des techniques de prévision à court terme de la production d'EnR intermittentes et des méthodes d'optimisation stochastiques existantes, nous avons sélectionné la programmation dynamique probabiliste (PDP). En effet, cette méthode nous semble être un outil pertinent pour incorporer les prévisions probabilistes d'EnR intermittentes dans la résolution de problèmes de planification d'UC. D'autre part, nous avons aussi choisi la programmation dynamique duale stochastique (SDDP) comme méthode de référence. Cette technique d'optimisation stochastique est largement utilisée dans les problèmes de planification énergétique soumise à des incertitudes. La version que nous utiliserons s'appuiera sur les historiques de production pour modéliser les incertitudes.

À notre connaissance, il n'existe pas dans la littérature de travaux présentant une méthode d'optimisation utilisant des prévisions solaires opérationnelles pour la gestion énergétique d'un microréseau. La particularité de ce travail consiste donc en l'utilisation de prévisions opérationnelles pour la gestion du microréseau présenté dans le chapitre d'introduction (cf. partie 1.4). Une combinaison de prévision déterministe avec l'algorithme de programmation dynamique (DP) a été choisie, car la DP permet de traiter des problèmes d'optimisation non-linéaires. Cette étude est une première application de la méthode d'optimisation sélectionnée dans le chapitre précédent pour un cas purement déterministe. Son application à des prévisions probabilistes sera abordée au chapitre 4. Pour ce cas d'application, le microréseau est constitué du bâtiment EnerPos avec un stockage électrochimique de type batteries plomb-acide.

Une description des prévisions déterministes utilisées sera effectuée dans un premier temps. D'une part, les prévisions de la production du champ PV pour les 3 prochains jours à venir ont été obtenues à partir des prévisions météorologiques fournies par ECMWF. D'autre part, les prévisions de consommation, générée sur une base hebdomadaire, ont été obtenues avec un modèle utilisant les analogues. Ensuite, les caractéristiques du microréseau et le modèle de stockage sont détaillés. Enfin, la formulation du problème d'optimisation, c'est-à-dire la fonction objectif et les contraintes associées, sera présentée. L'optimisation, qui est purement économique, a pour but de minimiser le coût de fonctionnement du microréseau.

Ce chapitre a pour objectif de montrer l'efficacité liée à l'utilisation de prévisions opérationnelles pour la gestion d'un microréseau, mais aussi de montrer les capacités de la DP en optimisation opérationnelle. Une comparaison avec une gestion basée sur des règles expertes («*rule-based*») et basée sur des critères techniques et économiques mettra en avant ces deux aspects.

Ce chapitre constituera une application purement déterministe de la méthode de programmation dynamique sélectionnée dans le chapitre précédent. Il mettra notamment en évidence le lien entre le coût d'exploitation du microréseau et les erreurs des prévisions déterministes de la consommation nette (Net-Load) correspondant à la différence entre la consommation du bâtiment et la production de la ferme PV. Il pointera aussi l'influence de l'horizon de prévision sur le coût de fonctionnement.

3.2 Economic optimization of a micro-grid operations by dynamic programming with real energy forecast

Faly Ramahatana¹, Mathieu David¹

1 – PIMENT Laboratory, University of Reunion Island, 97430 France

Abstract

The transition towards 100% renewables in energy production promotes the local production and use of energy through the development of micro-grids, i.e. small grids with renewable production, local loads (building, e-transportation, etc.) and frequently an Energy Storage System (ESS). Optimal management of micro-grids integrating ESS requires anticipating the unbalance between the demand and the supply of energy. This work aims at developing a method to integrate day-ahead deterministic forecasts of photovoltaic (PV) production and of system loads in the management of an ESS. Dynamic Programming (DP) has been chosen to optimize of the economic cost of the micro-grid operation. The predictions used to manage the micro-grid are day-ahead forecasts with hourly granularity. For the PV production, they are derived from the ECMWF predictions. For load, a simplified analogue approach is carried out. To test the developed method, a real educational Net Zero Energy Building equipped with a PV roof and full monitoring of electricity flows is considered. Compared to a ruled-based method, which balances supply-demand without using available forecasts of PV production and building loads, the developed method decreases the operating cost of the system for both daily and yearly time scales.

3.2.1 Introduction

Microgrids are rising worldwide because they contribute to better integrate renewables in energy systems [2]. A microgrid [3] is a system with its own generation means, loads and frequently an energy storage system (ESS). It can work on grid and off grid mode depending on the availability of resources and the strategies of control. The microgrid's architecture goal is to improve energy production and delivery to load [3]. In existing grid systems, small size intermittent renewable energy systems (RES) like PV rooftops are considered as distributed energy generators [4, 5]. By their variable nature, intermittent RES generate fluctuations that destabilize supply and demand balance, reduce the power quality and therefore the system reliability. The main challenge facing the microgrids is to find the most effective way to manage the generation and the load.

Microgrids are extensively studied in the literature [4, 6, 7]. These systems can work on a medium or low voltage [8] and the control of their power and of other factors, like voltage profile, is independent from the main grid management. The economic viability is related to the type of microgrid. Two main types exist depending on the control mode : centralized [9] or agents-based [10, 11, 12]. The agent-based control mode needs more complex information infrastructure [13] because every individual system is considered as an agent and can play independently to reach the objectives. The main factors restraining the development of microgrids are the investment costs and the associated costs of operation. However, with the increase prices from conventional generation connected to the main grid and the recent prices drop of RES such as PV and ESS,

microgrids are more and more cost effective. The smart management of microgrids depends on the user behavior and on the generation sources. This work focuses on a centralized microgrid with few controllable devices.

Considering non-dispatchable RES such as PV, the use of an ESS allows balancing the supply-demand of electricity and add flexibility [14] to the system. The main objective is to reduce the operation costs and increase the local self-consumption. Regarding recent works [9, 15, 16, 17, 18], the management of the ESS state of charge (SOC) is one of the most used methods.

Scheduling of the SOC while taking into account the future loads and production permit to reach the lowest operating cost. In the state of the art [9], this operational problem is commonly divided in two optimization loops : predictive scheduling of the production systems (PV and ESS) commitment and real-time control of the system. This work only addresses the predictive scheduling step. Optimization techniques like dynamic programming [9, 19, 20] (DP) or Mixed integer linear programming (MILP) [21, 22, 23] are widely used to elaborate the optimal predictive scheduling. The inputs are typically the daily loads and energy generation profiles. Unfortunately, perfect future profiles of generations and loads data may not be available before the scheduling computation. To overcome this problem, Riffonneau et al. [9] propose to use simulated forecast data. But, most of the works on the topic [9, 24] use unrealistic forecasts from perturbed measured data. The use of the perfect forecasts as input of the optimization process permits to evaluate the maximum expected improvement, as instance they allow decreasing the peak demand from the grid and can cut off by 13% the system operating cost of a small microgrid with PV, lead-acid batteries and a local electricity demand.

This work proposes a strategy based on the integration of operational day-ahead forecasts into the optimization process required to generate an optimal scheduling of the ESS charges and discharges. Then, an analysis of the contribution of the forecasts on the operation of the microgrid is carried out. DP is used to optimize the control of the ESS using operational forecast retrieved from the European Centre of Medium range Weather Forecasts (ECMWF) with a 1-hour time step for several days ahead. Gains on daily a year operation costs are highlighted. A PV farm, loads from an educational building [25], an ESS and a connection to the main grid composed the considered microgrid. The remainder of this paper is organized as follows. First, forecasting techniques, storage models, optimization tools and implementations of the optimization problem is presented. Then, the loads, PV generation data and the associated forecasts are detailed. Finally, the results are analyzed to show the effect of the forecasts quality on the microgrid control and operation costs.

3.2.2 Methods and tools

In this section, we detailed the forecasting models for the building load and for PV generation, the chosen optimization method and the ESS model. The aim of this work is to address energy scheduling, with an integration time of one hour ($\Delta t = 1h$). Thus, the time resolution step is also 1 hour.

3.2.2.1 Load forecasts

The building load forecasts are based on average week days. $L_{h,D}$ is the energy consumed by the building for the week day D (i.e. Monday to Sunday) and hour h . The forecasted load

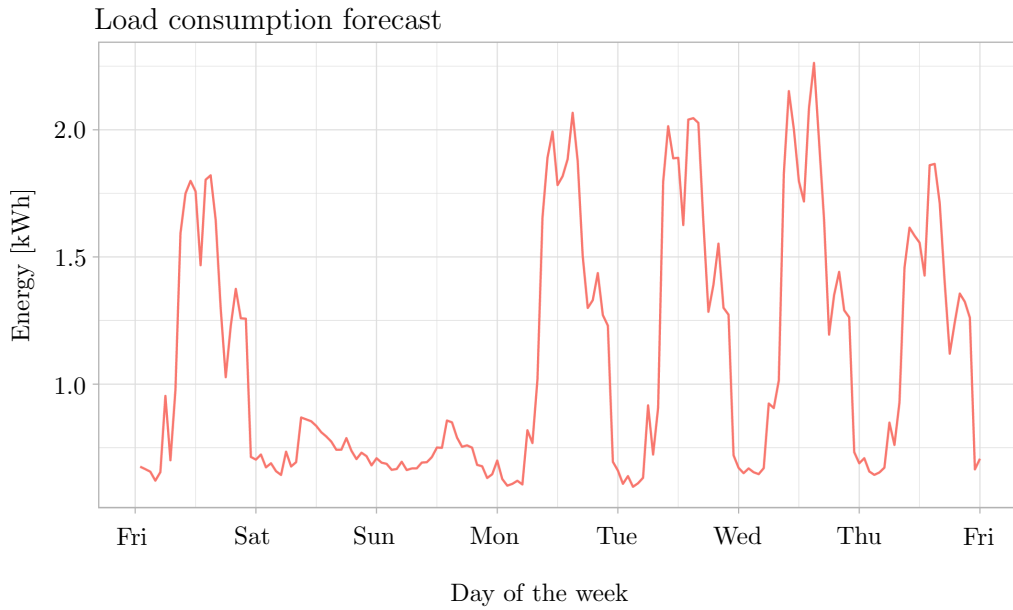


FIGURE 3.1 – Typical week of hourly load forecasts

$\widehat{L}_{h,D}$ corresponds to the average load of the building over the N weeks of the year as follow :

$$\widehat{L}_{h,D} = \frac{1}{N} \sum_1^N L_{h,D} \quad (3.1)$$

with $h \in (1, \dots, 24)$, $D \in (1, \dots, 7)$, $N = 51$

Using this method, we generate 7 averages week days which are representative of the building schedule use during an average week. As a consequence, all forecasted weeks are identical. This simple technique allows reproducing realistic load profiles of the considered educational building, which is almost low and flat at nights and weekends (fig. 3.1).

3.2.2.2 PV forecasts

PV generation depends mainly on the incident solar irradiance, on the temperature of the modules and on the efficiency of the inverter. Therefore, to forecast the PV output, day ahead forecasts with a 1-hour granularity of relevant weather parameters, i.e. solar irradiance and dry-bulb air temperature are retrieved from the IFS run launched at midnight and available at the ECMWF portal [26]. The simplified model proposed by Chen et al. [27] is used to compute the generation of the PV plant :

$$\widehat{P}_t^{PV} = \eta^{PV} \times A^{PV} \times \widehat{GHI}^{ECMWF} \times \left(1 - \nu^P \times \left(\widehat{T}^{ECMWF} - 25\right)\right) \quad (3.2)$$

Where η^{PV} is the conversion efficiency of the solar cell array, the temperature coefficient of the PV module, A^{PV} the PV field area, \widehat{T}^{ECMWF} and \widehat{GHI}^{ECMWF} are respectively the forecasted dry-bulb temperature and the global solar irradiance.

Regarding the inverter, which converts DC PV power to AC, the efficiency is calculated using the model proposed by Riffonneau et al. [9], which depends on the PV DC power P^{PV} and the converter rated power $P^{inv,rated}$.

$$\eta^{inv} = 1 - \frac{1}{In} \times (0.0094 + 0.043 \times In + 0.04 \times In^2) \quad (3.3)$$

$$In = \frac{P^{PV}}{P^{inv,rated}} \quad (3.4)$$

Finally, the forecasted PV generation is

$$\widehat{PV}_t = \widehat{P}_t^{PV} \times \eta^{inv} \times \Delta t \quad (3.5)$$

3.2.2.3 Forecast quality

The most relevant and used metrics to assess the quality of solar deterministic forecasts [28] are the Mean Bias Error (MBE) (eq. 3.8), the Root Mean Square Error (RMSE) (eq. 3.6) and the Mean Absolute Error (MAE) (eq. 3.7). In the following equations, which give the method to derive the evaluation metrics \hat{y}_j , y_j and are respectively the forecasted and the measured data. The root means square error, sensitive to large errors :

$$RMSE = \sqrt{\frac{1}{N} \sum_{j=1}^N (\hat{y}_j - y_j)^2} \quad (3.6)$$

The Mean absolute error, less sensitive to large errors :

$$MAE = \frac{1}{N} \sum_{j=1}^N |\hat{y}_j - y_j| \quad (3.7)$$

The Mean biased error, which evaluate the average overestimation or underestimation of the forecasts :

$$MBE = \frac{1}{N} \sum_{j=1}^N \hat{y}_j - y_j \quad (3.8)$$

The relative counterparts of these metrics are commonly used to allow comparing forecasting methods for different locations and configuration of the PV system. In this work, the relative error indicators are obtained by dividing the metrics presented above by installed PV peak power.

3.2.2.4 ESS model

The architecture of the system (fig. 3.2) is based on the model introduced by Riffoneau, composed by a load, a PV generator, an ESS and a connection to the main grid. The micro-grid components are taken from Riffonneau et al. [9].

A lead-acid batterie is used for this work, with the assumption that no self-discharge occurs over time. For the AC-DC (bidirectional) conversion, we will use the same type of converter as the one used for the PV generator and its efficiency is given by see eq. 3.3. The charge efficiency [29] or the round-trip efficiency of the battery is the ratio of the charged input energy to the output discharged energy. The round-trip efficiency $\eta^{inv,ESS}$ of the lead-acid batteries is estimated to be a constant value of 82% [30].




FIGURE 3.2 – Microgrid architecture

The State of Charge (SOC) is the ratio of the current capacity ESS_t to the reference capacity Ca_{ref} :

$$SOC_t = \frac{ESS_t}{Ca_{ref}} \quad (3.9)$$

$$\Delta SOC_t = SOC_{t-\Delta t} - SOC_t \quad (3.10)$$

The energy that flows in and out to the ESS is given by equation 3.11. The ESS is charging when $\Delta SOC_t < 0$ and discharging if $\Delta SOC_t > 0$.

$$\begin{aligned} ESS_t^{Charge} &\equiv -\Delta SOC_t \times Ca_{ref} \\ ESS_t^{Discharge} &\equiv \Delta SOC_t \times Ca_{ref} \end{aligned} \quad (3.11)$$

From a technical point of view, the lifespan of this type of storage is linked to the number and the depth of the cycles of charges and discharges. The considered model estimates the deterioration of the state of health SOH of the ESS that depends only on the depth of the discharges. As a consequence, the SOH can only decrease. The SOH is a linear relationship between the depth of the discharge and the coefficient of aging $Z \times \Delta SOH$ wich corresponds to the diminution of the SOH after a discharge, is negative. The following equation gives the value of when a discharge occurs :

$$\begin{aligned} \Delta SOH_t &= Z \times \Delta SOC_{\{\Delta SOC < 0\}}, \\ &= Z \times (SOC_{t-1} - SOC_t)_{\{SOC_{t-1} - SOC_t < 0\}}. \end{aligned} \quad (3.12)$$

3.2.2.5 Optimization

In energy planning, there are numerous methods dedicated to the operating cost optimization [31, 32, 33]. For resource allocation problems, the Mixed integer linear programming (MILP) [21, 23] is often proposed but the problem must be linearized to be solved. Thus, the objective function must be a linear function. In grid management, due the nature of the assets and of the decision variables, objective functions are nonlinear.

The population-based solver like genetic algorithms [34] requires a significant number of sampling which greatly increases the calculation time. Those methods do not necessarily guarantee the completion of a global solution [35].

We chose the Dynamic programming (DP) because our problem can be convex or concave [36]. Furthermore, the following works of Nguyen et al. [19], Grillo et al. [37], Haessig et al. [38], Riffonneau [39], Pereira and Pinto [40] showed that DP is a good candidate for the optimal management of an ESS. Last, as forecasts could be probabilistic, i.e. provided with their uncertainty, the use of the stochastic version of the DP will be the next step to achieve a robust ESS management.

3.2.2.6 Dynamic Programming applied to ESS management

The DP used in this work is the version proposed by Bellman [36]. In the literature, the Bellman-Ford's algorithm is one of the less computationally intensive methods [41]. As the problem can be divided in small problems, the optimal policy rules can be applied operationally. With this method one can obtain an ensemble of solutions. The number of solutions can be drastically reduced by the augmentation of the number of constraints. The drawback of this method is the curse of dimensionality [42] because it provides all the possible solutions. As a consequence, when the number of decisions variable increases, the problem becomes numerically extensive and difficult to solve.

Our aim is to solve a discrete space and time dependent problem. We try to find the optimal decision for each discrete time that minimizes the operating cost of the micro-grid. The method consists in finding the minimum cost for all the decisions that have to be made. Our problem is almost similar to the well-known shortest path problem. By analogy, the arc length of the shortest path problem corresponds the cost associated with the SOC variation over two successive time steps.

3.2.2.7 Objective function

The current SOH of a battery does not only depend on the variation of the *SOC* as assumed by the model of Riffonneau et al. [9] used in this work. It may also depend on various random factors such as manufacturing variance [43]. For example, considering the same batch of batteries operating under the same conditions, the state of integrity of each battery can be different. Since our hypothesis does not take into account these random processes, it is assumed that the degradation is simply a function of the SOH. If the SOH reaches the minimum value SOH_{min} , the ESS is disabled. The operating cost of the ESS (C_{ESS}) depends on its SOH and on the investment cost of the ESS.

$$R_t = \begin{cases} Sic \times Ca_{ref} \times \frac{-\Delta SOH_t}{1 - SOH_{min}}, & \text{if } SOC_{t-1} - SOC_t < 0 \\ 0, & \text{otherwise,} \end{cases} \quad (3.13)$$

that the sum of the energy flows is null. Thus, the building load corresponds to the sum of the energy supplied by the PV, the ESS and the grid. One can see in this equation that the round trip efficiency of the ESS (η^{ESS}) is applied to the charge.

$$\widehat{Gr}_t - \frac{ESS_t^{Charge}}{\eta^{inv,ESS} \times \eta^{ESS}} + \eta^{inv,ESS} \times ESS_t^{Discharge} + \widehat{PV}_t = \widehat{L}_t, \quad (3.17)$$

The system also experiences technical constraints related to ESS limitations and to the grid contribution. Considering an electro-chemical battery, the technology itself implies that it is not possible to use the storage in the extremums (totally empty or full). As a result, an operating range between a minimum SOC_{min} and a maximum SOC_{max} is necessary to avoid damaging the ESS.

$$SOC_{min} \leq SOC_t \leq SOC_{max} \quad (3.18)$$

As described in section 3.2.2.4, the SOH of the ESS gradually decreases with the depths of the discharges. To keep the system working, a minimal level of SOH of the ESS, SOH_{min} is required.

$$SOH_t > SOH_{min} \quad (3.19)$$

3.2.3 Implementation

The control of the ESS consists in scheduling the SOC of the ESS. The ESS can be on charging or discharging mode. For the energy management, the time of integration is *1hour*. Therefore, the SOC of the ESS is scheduled every hour of the next day. For the study, there will be two modes : instantaneous management and controlled with forecasts. In order to make the models comparable the following basic rules are applied for all management modes :

- Because we used day ahead forecast, the begin of day in simulations is fixed at 12 PM (local time).
- At the begin of the simulation, the initial state of charge is 50%.
- There are no limitations of power rates for the charge and discharge of the ESS.

3.2.3.1 Ruled based management

The ruled based is an instantaneous management, depending on the SOC of the battery, the energy imbalance and the charges / discharges the ESS.

It follows simple rules (see fig. 3.4) :

- The PV can only charge the ESS when PV output excess the load.
- The ESS supplies the energy to the load when the PV is not enough.
- If the ESS is empty, the grid supplies the load.
- If the ESS is full, the excess of energy is injected to the grid.

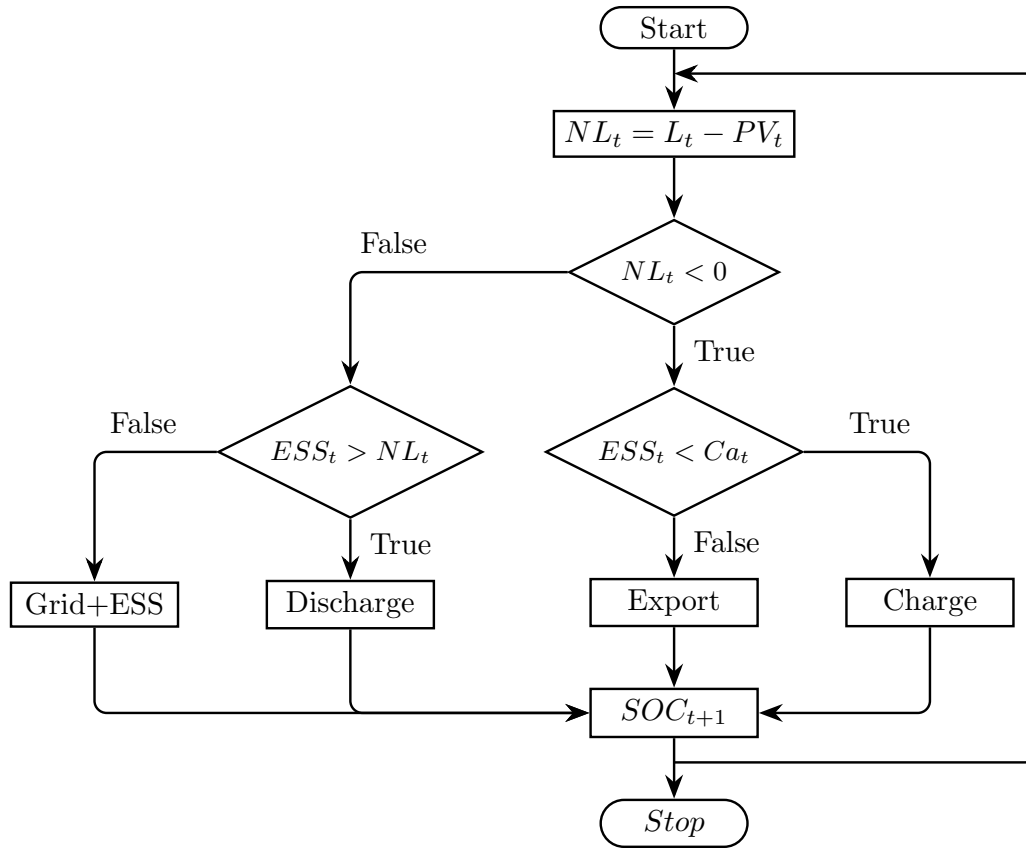


FIGURE 3.4 – Rule based management

3.2.3.2 Controlled system with forecast

This second management mode uses forecasts as input of the decision-making. At the beginning of simulated day D , up to 3 days of forecast are produced. A rolling horizon with size of $72h$ and with a $1 - hour$ granularity of the PV output and of the building load are generated. For each daily forecast, the optimization can produce up to 72 hourly optimal SOC of the ESS. The DP performs an evaluation of the value of the final $SOC_{f[72]}$ corresponding to the minimum cost for up to 3 days ahead. For the studied day, the first 24 SOC are considered and the initial SOC for the next day is the 24th SOC of the day $SOC_{f[24]}$. Two forecasts will be used to carry out the optimization. First, perfect forecasts, corresponding to the recorded historical data, will provide an assessment of the best performance that could be achieved while introducing forecasts to elaborate the scheduling of the ESS. Second, real forecasts, as described in section 3.2.2, will give realistic results.

3.2.3.3 Performance indicators

The economic cost, which is also the cost function of our optimization problem, is obviously the first indicator generated by the optimization. The expected economic cost of the successive decisions will be directly available using the rule-based management or at the end of the optimization using the forecasts as input. The realized cost will be derived from the application of the decisions to the real building load and PV production. Beside the economic assessment, the evaluation of the quality of the management of the micro-grid, will be done by the following

indicators proposed by Simpore [45] :

- Self-consumption (ϑ^{sc}) (eq. 3.20) is the ratio between the sum of the energy absorbed (supplied by the photovoltaic generator to the load and the energy absorbed by the ESS) and the energy produced by the photovoltaic generator.

$$\vartheta^{sc} = \frac{\sum_{t=1}^T (E_t^{PV-load} + ESS_t^{Charge})}{\sum_{t=1}^T PV_t} \quad (3.20)$$

- The self-production (ϑ^{sp}) rate is the ratio between the sum of the energy produced for the system (provided by the photovoltaic generator and the load supplied and the energy supplied by the ESS) and the energy required for the load.

$$\vartheta^{sp} = \frac{\sum_{t=1}^T (E_t^{PV-load} + ESS_t^{Discharge})}{\sum_{t=1}^T L_t} \quad (3.21)$$

- The rate of injections to the grid (ϑ^{Export}) is defined by the energy the micro-grid transfer to the main grid, it can be from the PV or the ESS.

$$\vartheta^{Export} = \frac{\sum_{t=1}^T (E_t^{PV-grid} + E_t^{ESS-grid})}{\sum_{t=1}^T PV_t} \quad (3.22)$$

3.2.4 Data

The load data come from a building called EnerPos which is located in St-Pierre in the island of Reunion, a French overseas territory in the Indian Ocean. It is a building in a tropical environment of the southern hemisphere. It is a Net zero energy building [46] with integrated photovoltaic systems and a low energy consumption. The annual PV output of this building is greater than its consumption. This building is connected to the grid. The meteorological data comes from a meteorological station installed on the same site. The building is intended for administrative and school uses (fig. 3.5), which explains the almost flat load profile at nights and weekends (see fig. 3.6). The peak power is located during daytime and in the evening after 7PM. In Figure 3.5, one can see that the PV production follows the seasons, it decreases in winter and increase in summer. The load consumption follows the same trend, but during the annual vacancies (mid-July to mid-August and mid-December to Mid-January), the load consumptions are at their lowest levels.

The cost of electricity in Reunion Island is subsidized by the state and they are strongly lower than the real cost of electricity production. Considering these artificially low tariffs, the development of renewables must be grant-aid. In this work, we shifted the current prices applied to the studied building to correspond to the annual and real cost of energy provided by the unique local distribution operator (Table 3.1), including taxes. Table 3.2 gives the timetable of the peak, off peak and normal hours used to compute the electricity bill of the building..

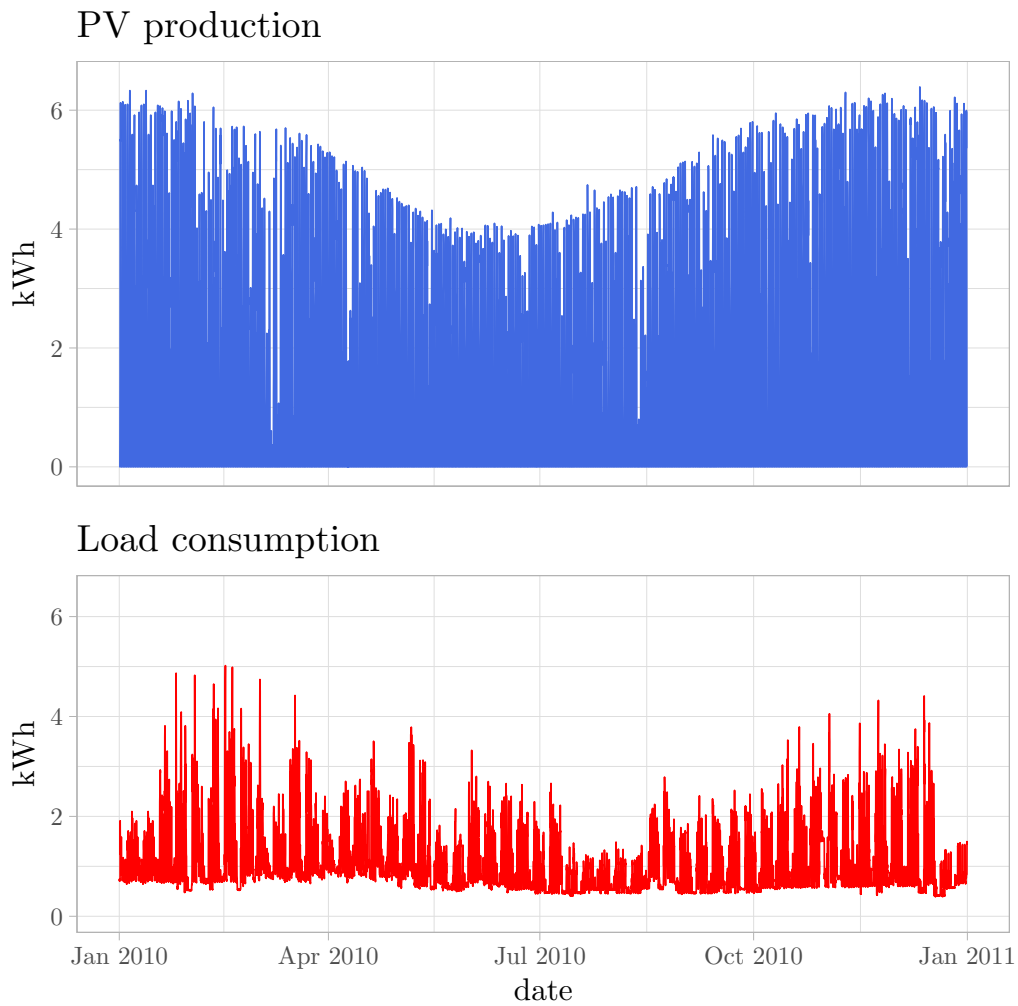


FIGURE 3.5 – Overview of the annual consumption and production of the EnerPos Building

TABLE 3.1 – French context electricity price from extrapolated value at January 2018

Fixed part (€/kW)	Peak hours (c€/kWh)	Summer (c€/kWh)		Winter (c€/kWh)	
		Off-peak hours	NH	Off-peak hours	NH
47.64	41.49	13.83	15.17	18.38	25.87

Fixed part : depending on the subscribed power on the electrical grid.
 NH (Normal Hour)

TABLE 3.2 – Peak switch hours

01 may to 30 September (Winter)		10 October to 30 April (Summer)	
Peak hours	Off-peak hours	Peak hours	Off-peak hours
11h AM - 1h PM*	10h PM – 6h AM	11h AM – 1h PM	10h PM – 6h AM
6h PM – 9h PM*	10h PM – 6h AM	6h PM – 9h PM*	10h PM – 6h AM




FIGURE 3.6 – Week of PV production and building consumption

3.2.5 Results and discussion

3.2.5.1 Daily optimization

The main goal here is to present the evolution of the SOC based on economic optimization. For a sample day (fig. 3.7, 3.8) we can see that the evolution of the ESS of the ruled based strategy differs significantly with the control with forecasts. In terms of daily costs, with the same start constraints ($SOC = 0.5$), the forecast outperforms the ruled based method. The optimization tends to use the grid at its maximum to maximize the gains provided by the difference of prices between peak and off-peak hours.

As expected, in case of supply-demand imbalance of the microgrid, the rule-based strategy systematically charges or discharges the ESS. As a consequence, the storage accumulates the extended of energy from the PV till its full and when the PV is not enough, the storage discharges to compensate the deficit. The ruled-based management focus only on the energy imbalance and the storage is intensely used to limit the need of the main grid. So, the operation cost is relatively important because of strong and frequent discharges.

Considering the management with forecasts, the storage only stores the energy required to avoid to purchase electricity from the grid during the peak hours. The combination of the optimization and the forecasts optimizes the use of the grid and the storage depending on the hour of the day. At peak hours, this approach schedule to use the storage to avoid the use of the main grid. Regarding more specifically the use of real forecasts, the behavior of the ESS and the SOC profile is almost the same as for perfect forecasts. But due to forecasting error, mismatch in supply-demand balance occurs. The energy delivered by the storage could be lower than the real consumption or the storage discharges when the grid is at its lowest price (low rate hour). Compared to the use of perfect forecasts, these mismatches increase the operating cost.




FIGURE 3.7 – Rule-based management (without control)

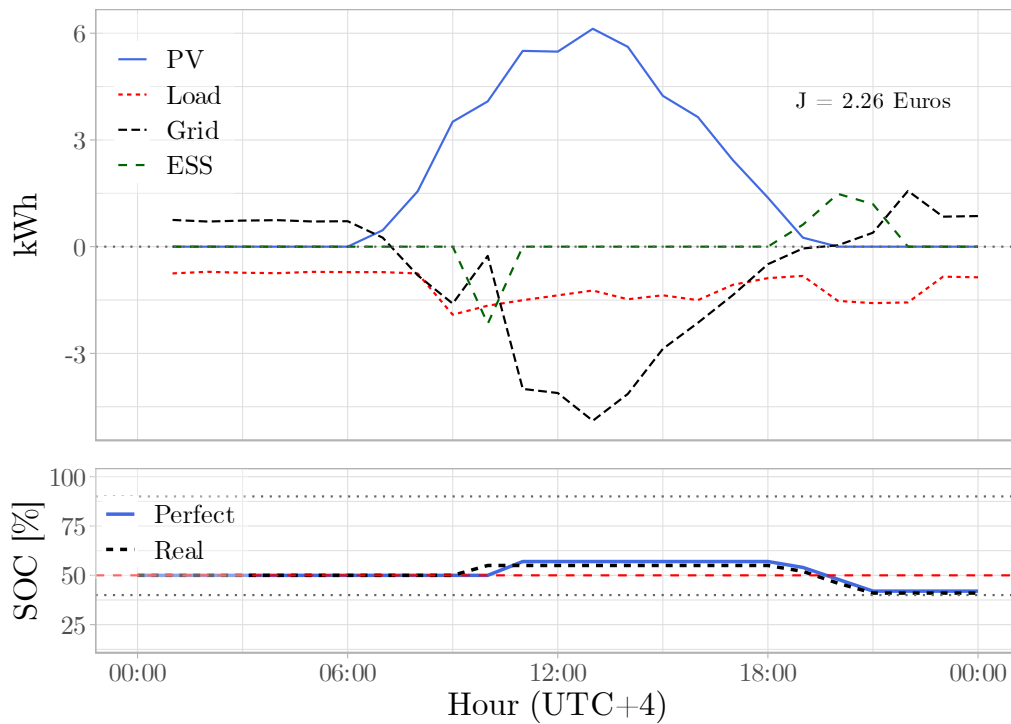


FIGURE 3.8 – Real forecast scheduling for day 1

3.2.5.2 Forecasting window size

Up to 3 days of hourly forecast of both PV production and building consumption are available as input of the optimization process. As the accuracy of the forecasts decreases when

the horizon increases, it is obvious to test if it is necessary to use the whole 3 days of forecasts to obtain the optimal scheduling of the ESS for the first 24 hours. Thus, we evaluate the effect of the forecasting window size on the annual operation cost. We performed successive optimization with a window size ranging from 24 hours to 72 hours ahead. Figure 3.8 shows the results for the perfect and the real forecasts. The optimal window size is a little bit less than 3 days ahead. This lag with an entire day is due to the evening peak-hours (with a high cost of electricity) which occurs 3 hours before midnight. The 2 drops in the curves happening during the evening peak-hours indicate a strong cost improvement.

For the perfect and real forecasts, the optimal window size is the same. But the behaviour is not exactly the same due to the error of forecast. There is only one major improvement (only drop in the curve) for the real forecasted data, which indicates that the forecasts in daytime does not follow the comportment of the real data.




FIGURE 3.9 – Impact of forecast horizon window size on the optimal cost of operation

3.2.5.3 Forecast quality

The objective is to study the effect of forecast quality on the gain for the controlled system. The forecast quality is computed for an entire year of operation of the building. Table 3.3 gives the yearly metrics of error for the PV, the load and the net-load forecasts. This for-

mer corresponds to the net consumption of the building when considering the PV production ($E_t^{Net-load} = L_t - PV_t$). The forecasts experience a low bias. One can also notice that the PV forecasts are less accurate than the load forecasts with lower RMSE and MAE. Finally, the net-load forecasts are strongly worse than both PV and load forecasts.

TABLE 3.3 – Annual error metrics

Designation	RMSE <i>kWh</i>	MAE <i>kWh</i>	MBE <i>kWh</i>
Load	0.469	0.305	-0.003
PV	0.909	0.332	-0.107
Net-load	2.499	1.834	0.104

The evolution of the hourly operation cost as a function of the hourly forecasting error of the net-load (see fig. 3.10) indicates that an overestimation of the net-load leads to an increase of the operation cost. Moreover, if the error is close to 0, there are high cost values, which means that at some points, we have to exploit the storage or the network as much as possible.




FIGURE 3.10 – Relationship between hourly forecast error and operation cost of the microgrid

3.2.5.4 Annual indexes

In table 3.4, annual indexes show that the knowledge of the future can reduce the operating cost by 22% using perfect forecast and 15% with real forecast. So, the quality of the forecast increases the economic gains. Regarding the self-consumption rate, the values are almost the same for the perfect and real forecasts. However, the ruled-based has higher self-consumption

rate and level of autonomy because the ESS is systematically charged when there is a surplus of PV production and then this surplus is shifted to the night hours to supply the building.

Considering the control with forecasts, the microgrid is allowed to sell the extra energy to the grid, so the optimization tend to sell more to reduce the cost and thus the injection to the grid is higher than the rule-based management.

TABLE 3.4 – Performances of the microgrid for 1 year of operation

Model	Self-Consumption ϑ^{sc} [%]	Self-Production ϑ^{sp} [%]	Injection ϑ^{Export} [%]	Gr^{max} %	Operating Cost J €
Perfect	52.41	49.48	38.75	10.49	1086.05
Forecast	46.62	48.22	44.24	14.26	1189.50
Rule-based	67.87	55.76	9.43	3.53	1402.97

3.2.5.5 Conclusion

This work sets up the optimal control of an ESS with the aim to minimize the operating cost of a real microgrid. The specificity of the approach is to use real forecasts for the load and for the PV production. The use of the forecasts permits establishing the day-ahead schedule of the ESS and to minimize the operating cost.

First, the results show that dynamic programming optimization allows detailing efficiently the microgrid features even if they assume non-linear behaviour. Second, the use of the ECMWF forecasts to predict the PV production improves significantly the yearly gain compared to a rule-based management strategy. Then, this study highlights that an underestimation of the future resources (PV) has less effects on the operating cost reduction than an overestimation.

Finally, this work shows that the rolling horizon of the scheduling (24h in our case) does not correspond to the optimal window size for the optimization (3 days). Indeed, even a poor knowledge of the future, which occurs after the rolling horizon, can generate significant cost savings.

This work only focused on the day-ahead scheduling of the ESS operation. Future works will perform a two-step optimization considering the coupling with a real-time control loop which will allow to work on very short time steps (near real-time) and to set-up a more realistic behaviour of the ESS. A next is also the evaluation of capacity of the forecast to minimize the exchange between the microgrid and the main grid by integrating power limitations constraints. Finally, we plan to use probabilistic forecasts of the PV production as input of the storage management in order to assess their ability to provide a better reliability of microgrids energy supply.

3.2.6 Nomenclature

TABLE 3.5 – Nomenclature

	Variable	Value	Units	References
Time step	Δ_t	1.00	Hour	
Building energy consumption during Δ_t at time t	L_t		kWh	
Analog data of the load	$\hat{L}_{h,D}$		kWh	
PV production during Δt at time t	PV_t		kWh	
Normalized converter input	I_n		-	
Surface PV	A^{PV}	60	m^2	
PV efficiency	η^{PV}	10	%	
PV temperature coefficient	ν^P	0.005	-	
Minimum SOC	SOC_{min}	40	%	
Maximum SOC	SOC_{max}	90	%	
Initial SOC	SOC_i	50	%	
Current ESS capacity	ESS_t	30	kWh	
ESS energy generated or absorbed by the ESS during Δt at time t	ESS_t		kWh	
ESS inverter nominal power	$P^{inv,rated}$	25	kW	
ESS round-trip efficiency	η^{ESS}	82	%	
ESS aging coefficient	Z	2.10^{-4}	-	
Minimum SOH	SOH_{min}	70	%	
Cost of operating ESS	R_t			
ESS investment cost	Sic	130.00	$\text{€}/kWh$	
PV production cost	$LCOE^{PV}$	0.069	$\text{€}/kWh$	
PV system life time	T	30	years	Branker et al. [44]
PV investment cost	I_t	4000	$\text{€}/kWh$	IRENA [47]
Yearly PV production	S_t	11100	$kWh/year$	PVGIS 5 [48]
PV Degradation factor	d	1	% /year	Skoczek et al. [49]
Operation and maintenance cost	$O_t + M_t$	20	%	IRENA [50]
Discount rate	r	4	%	[51]
Interest expenditure	F_t	0	-	
Energy supplied or injected to the main grid during Δt at time t	Gr_t		kWh	
Feed-in tariff for the grid	Fit		$\text{€}/kWh$	
Unit cost price for selling energy to the grid	Egp_t		$\text{€}/kWh$	
Energy supplied to the load from the PV generator	$E_t^{PV-load}$		kWh	
Energy injected to the grid by PV generator	$E_t^{PV-grid}$		kWh	
Energy injected to the grid by the ESS	$E_t^{ESS-grid}$		kWh	

3.3 Conclusion

Cette partie mettant en oeuvre une approche purement déterministe des prévisions et de leur intégration dans le contrôle optimal du microréseau valide l'efficacité de la stratégie adoptée : la combinaison de l'algorithme de programmation dynamique avec un horizon glissant et des prévisions opérationnelles de la production renouvelable intermittente et de la consommation.

L'optimisation économique intégrant des prévisions est utilisée pour le contrôle du système de stockage. Elle permet un gain économique significatif par rapport à la stratégie de gestion à base de règles expertes.

Pour le microréseau étudié, le MBE de la prévision de la consommation nette peut être utilisé pour évaluer l'effet de l'erreur de prévision sur les coûts d'exploitation. En effet, cet indicateur montre qu'une sous-estimation de la production a un effet positif sur la réduction des coûts et inversement.

En conditions réelles, une contrainte sur la puissance appelée au réseau électrique est très fréquemment présente et elle dépend du contrat de fourniture d'électricité. Cette contrainte ajoute des pénalités au tarif d'achat lors des dépassements de la puissance souscrite et elle engendre plus de complexité dans la gestion du stockage. Cette contrainte sur la puissance souscrite sera intégrée dans la suite de ce travail.

Dans le chapitre qui suit, une approche utilisant des prévisions probabilistes de la production du système PV sera détaillée. Ce chapitre démontrera que l'utilisation de prévisions probabilistes pour la minimisation des coûts de fonctionnement du microréseau est plus intéressante que l'utilisation de prévisions déterministes.

Bibliographie

- [1] F. Ramahatana and M. David, "Economic optimization of micro-grid operations by dynamic programming with real energy forecast," in *Journal of Physics : Conference Series*, vol. 1343, Nov. 2019, p. 012067. [Online]. Available : <https://doi.org/10.1088/1742-6596/1343/1/012067>
- [2] P. Asmus, "Microgrids, Virtual Power Plants and Our Distributed Energy Future," *The Electricity Journal*, vol. 23, no. 10, pp. 72–82, Dec. 2010. [Online]. Available : <https://doi.org/10.1016/j.tej.2010.11.001>
- [3] N. Hatziaargyriou, *Microgrids : Architectures and Control*. John Wiley & Sons, Mar. 2014. [Online]. Available : <https://doi.org/10.1002/9781118720677>
- [4] P. Basak, S. Chowdhury, S. Halder nee Dey, and S. Chowdhury, "A literature review on integration of distributed energy resources in the perspective of control, protection and stability of microgrid," *Renewable and Sustainable Energy Reviews*, vol. 16, no. 8, pp. 5545–5556, Oct. 2012. [Online]. Available : <https://doi.org/10.1016/j.rser.2012.05.043>
- [5] H. Jiayi, J. Chuanwen, and X. Rong, "A review on distributed energy resources and MicroGrid," *Renewable and Sustainable Energy Reviews*, vol. 12, no. 9, pp. 2472–2483, Dec. 2008. [Online]. Available : <https://doi.org/10.1016/j.rser.2007.06.004>

-
- [6] N. W. A. Lidula and A. D. Rajapakse, “Microgrids research : A review of experimental microgrids and test systems,” *Renewable and Sustainable Energy Reviews*, vol. 15, no. 1, pp. 186–202, Jan. 2011. [Online]. Available : <https://doi.org/10.1016/j.rser.2010.09.041>
- [7] A. H. Fathima and K. Palanisamy, “Optimization in microgrids with hybrid energy systems – A review,” *Renewable and Sustainable Energy Reviews*, vol. 45, pp. 431–446, May 2015. [Online]. Available : <https://doi.org/10.1016/j.rser.2015.01.059>
- [8] N. Hatziargyriou, N. Jenkins, G. Strbac, J. P. Lopes, J. Ruela, A. Engler, J. Oyarzabal, G. Kariniotakis, and A. Amorim, “Microgrids–large scale integration of microgeneration to low voltage grids,” *CIGRE C6-309*, 2006. [Online]. Available : <http://www.microgrids.eu/micro2000/presentations/19.pdf>
- [9] Y. Riffonneau, S. Bacha, F. Barruel, and S. Ploix, “Optimal Power Flow Management for Grid Connected PV Systems With Batteries,” *IEEE Transactions on Sustainable Energy*, vol. 2, no. 3, pp. 309–320, Jul. 2011. [Online]. Available : <https://doi.org/10.1109/TSTE.2011.2114901>
- [10] A. Dimeas and N. Hatziargyriou, “Operation of a multiagent system for microgrid control,” *IEEE Transactions on Power Systems*, vol. 20, no. 3, pp. 1447–1455, Aug. 2005. [Online]. Available : <https://doi.org/10.1109/TPWRS.2005.852060>
- [11] C.-X. Dou, X.-B. Jia, H. Li, and M.-F. Lv, “Multi-agent System Based Energy Management of Microgrid on Day-ahead Market Transaction,” *Electric Power Components and Systems*, vol. 44, no. 12, pp. 1330–1344, Jul. 2016. [Online]. Available : <https://doi.org/10.1080/15325008.2016.1158216>
- [12] T. Logenthiran, D. Srinivasan, and D. Wong, “Multi-agent coordination for DER in Micro-Grid,” in *2008 IEEE International Conference on Sustainable Energy Technologies*. IEEE, 2008, pp. 77–82.
- [13] M. Yun and B. Yuxin, “Research on the architecture and key technology of Internet of Things (IoT) applied on smart grid,” in *2010 International Conference on Advances in Energy Engineering*, Jun. 2010, pp. 69–72. [Online]. Available : <https://doi.org/10.1109/ICAEE.2010.5557611>
- [14] A. S. Anees, “Grid integration of renewable energy sources : Challenges, issues and possible solutions,” in *2012 IEEE 5th India International Conference on Power Electronics (IICPE)*. Delhi, India : IEEE, Dec. 2012, pp. 1–6. [Online]. Available : <https://doi.org/10.1109/IICPE.2012.6450514>
- [15] A. Bhattacharya, J. P. Kharoufeh, and B. Zeng, “Managing Energy Storage in Microgrids : A Multistage Stochastic Programming Approach,” *IEEE Transactions on Smart Grid*, vol. 9, no. 1, pp. 483–496, Jan. 2018. [Online]. Available : <https://doi.org/10.1109/TSG.2016.2618621>
- [16] P. Bolduc, D. Lehmicke, and J. Smith, “Performance of a grid-connected PV system with energy storage,” in *Conference Record of the Twenty Third IEEE Photovoltaic Specialists Conference - 1993 (Cat. No.93CH3283-9)*. Louisville, KY, USA : IEEE, 1993, pp. 1159–1162. [Online]. Available : <https://doi.org/10.1109/PVSC.1993.346959>
-

- [17] P. Malysz, S. Sirouspour, and A. Emadi, “An Optimal Energy Storage Control Strategy for Grid-connected Microgrids,” *IEEE Transactions on Smart Grid*, vol. 5, no. 4, pp. 1785–1796, Jul. 2014. [Online]. Available : <https://doi.org/10.1109/TSG.2014.2302396>
- [18] R. Zamora and A. K. Srivastava, “Controls for microgrids with storage : Review, challenges, and research needs,” *Renewable and Sustainable Energy Reviews*, vol. 14, no. 7, pp. 2009–2018, Sep. 2010. [Online]. Available : <https://doi.org/10.1016/j.rser.2010.03.019>
- [19] M. Y. Nguyen, Y. T. Yoon, and N. H. Choi, “Dynamic programming formulation of Micro-Grid operation with heat and electricity constraints,” in *2009 Transmission Distribution Conference Exposition : Asia and Pacific*, Oct. 2009, pp. 1–4. [Online]. Available : <https://doi.org/10.1109/TD-ASIA.2009.5356870>
- [20] N. A. Luu, Q.-T. Tran, and S. Bacha, “Optimal energy management for an island microgrid by using dynamic programming method,” in *2015 IEEE Eindhoven PowerTech*, Jun. 2015, pp. 1–6. [Online]. Available : <https://doi.org/10.1109/PTC.2015.7232678>
- [21] H. Morais, P. Kádár, P. Faria, Z. A. Vale, and H. M. Khodr, “Optimal scheduling of a renewable micro-grid in an isolated load area using mixed-integer linear programming,” *Renewable Energy*, vol. 35, no. 1, pp. 151–156, Jan. 2010. [Online]. Available : <https://doi.org/10.1016/j.renene.2009.02.031>
- [22] A. Parisio and L. Glielmo, “A mixed integer linear formulation for microgrid economic scheduling,” in *2011 IEEE International Conference on Smart Grid Communications (SmartGridComm)*, Oct. 2011, pp. 505–510. [Online]. Available : <https://doi.org/10.1109/SmartGridComm.2011.6102375>
- [23] C. Wouters, E. S. Fraga, and A. M. James, “An energy integrated, multi-microgrid, MILP (mixed-integer linear programming) approach for residential distributed energy system planning – A South Australian case-study,” *Energy*, vol. 85, pp. 30–44, Jun. 2015. [Online]. Available : <https://doi.org/10.1016/j.energy.2015.03.051>
- [24] K. Abdulla, J. de Hoog, V. Muenzel, F. Suits, K. Steer, A. Wirth, and S. Halgamuge, “Optimal Operation of Energy Storage Systems Considering Forecasts and Battery Degradation,” *IEEE Transactions on Smart Grid*, pp. 1–1, 2016. [Online]. Available : <https://doi.org/10.1109/TSG.2016.2606490>
- [25] A. Lenoir, F. Garde, E. Ottenwelter, A. Bornarel, and E. Wurtz, “Net zero energy building in France : from design studies to energy monitoring. A state of the art review,” in *Eurosun 2010-International Conference on Solar Heating, Cooling and Buildings*, Sep. 2010. [Online]. Available : https://www.forum.iea-shc.org/data/sites/1/publications/Task40c-Net_Zero_Energy_Buildings_in_France_From_Design_Studies_to_Energy_Monitoring.pdf
- [26] H. Setchell, “Forecasts,” Aug. 2017. [Online]. Available : <https://www.ecmwf.int/en/forecasts>
- [27] S. X. Chen, H. B. Gooi, and M. Q. Wang, “Sizing of Energy Storage for Microgrids,” *IEEE Transactions on Smart Grid*, vol. 3, no. 1, pp. 142–151, Mar.

- 2012, conference Name : IEEE Transactions on Smart Grid. [Online]. Available : <https://doi.org/10.1109/TSG.2011.2160745>
- [28] M. David, M. Diagne, and P. Lauret, “Outputs and error indicators for solar forecasting models,” in *Proceedings of the World Renewable Energy Forum (WREF)*, 2012, pp. 13–17. [Online]. Available : <https://hal.archives-ouvertes.fr/hal-00918149>
- [29] T. Reddy, *Linden’s Handbook of Batteries*, 4th ed. New York, United States : McGraw Hill Professional, Jan. 2011. [Online]. Available : <https://www.accessengineeringlibrary.com/content/book/9780071624213>
- [30] IRENA, “Electricity storage and renewables : Costs and markets to 2030, Cost-of-service tool,” Abu Dhabi, Oct. 2017. [Online]. Available : <https://www.irena.org/publications/2017/Oct/Electricity-storage-and-renewables-costs-and-markets>
- [31] A. Khatamianfar, M. Khalid, A. V. Savkin, and V. G. Agelidis, “Improving Wind Farm Dispatch in the Australian Electricity Market With Battery Energy Storage Using Model Predictive Control,” *IEEE Transactions on Sustainable Energy*, vol. 4, no. 3, pp. 745–755, Jul. 2013. [Online]. Available : <https://doi.org/10.1109/TSTE.2013.2245427>
- [32] V. Marano, G. Rizzo, and F. A. Tiano, “Application of dynamic programming to the optimal management of a hybrid power plant with wind turbines, photovoltaic panels and compressed air energy storage,” *Applied Energy*, vol. 97, pp. 849–859, Sep. 2012. [Online]. Available : <https://doi.org/10.1016/j.apenergy.2011.12.086>
- [33] A. Chaouachi, R. M. Kamel, R. Andoulsi, and K. Nagasaka, “Multiobjective Intelligent Energy Management for a Microgrid,” *IEEE Transactions on Industrial Electronics*, vol. 60, no. 4, pp. 1688–1699, Apr. 2013. [Online]. Available : <https://doi.org/10.1109/TIE.2012.2188873>
- [34] C. Chen, S. Duan, T. Cai, B. Liu, and G. Hu, “Smart energy management system for optimal microgrid economic operation,” *IET Renewable Power Generation*, vol. 5, no. 3, pp. 258–267, May 2011. [Online]. Available : <https://doi.org/10.1049/iet-rpg.2010.0052>
- [35] S. Kazarlis, A. Bakirtzis, and V. Petridis, “A genetic algorithm solution to the unit commitment problem,” *IEEE Transactions on Power Systems*, vol. 11, no. 1, pp. 83–92, Feb. 1996. [Online]. Available : <https://doi.org/10.1109/59.485989>
- [36] R. E. Bellman, *Dynamic Programming*, ser. Princeton Landmarks in Mathematics and Physics. Princeton University Press, 1957. [Online]. Available : <https://press.princeton.edu/books/paperback/9780691146683/dynamic-programming>
- [37] S. Grillo, M. Marinelli, S. Massucco, and F. Silvestro, “Optimal Management Strategy of a Battery-Based Storage System to Improve Renewable Energy Integration in Distribution Networks,” *IEEE Transactions on Smart Grid*, vol. 3, no. 2, pp. 950–958, Jun. 2012, conference Name : IEEE Transactions on Smart Grid. [Online]. Available : <https://doi.org/10.1109/TSG.2012.2189984>

- [38] P. Haessig, T. Kovaltchouk, B. Multon, H. B. Ahmed, and S. Lascaud, “Computing an Optimal Control Policy for an Energy Storage,” *arXiv :1404.6389 [cs]*, Apr. 2014, arXiv : 1404.6389. [Online]. Available : <https://doi.org/10.48550/arXiv.1404.6389>
- [39] Y. Riffonneau, “Gestion des flux énergétique dans un système photovoltaïque avec stockage connecter au réseau—Application à l’habitat,” Ph.D. dissertation, Université Joseph-Fourier-Grenoble I, 2009. [Online]. Available : <https://tel.archives-ouvertes.fr/tel-00459539/>
- [40] M. V. F. Pereira and L. M. V. G. Pinto, “Multi-stage stochastic optimization applied to energy planning,” *Mathematical Programming*, vol. 52, no. 1, pp. 359–375, May 1991. [Online]. Available : <https://doi.org/10.1007/BF01582895>
- [41] B. Golden, “Technical Note—Shortest-Path Algorithms : A Comparison,” *Operations Research*, vol. 24, no. 6, pp. 1164–1168, Dec. 1976. [Online]. Available : <https://doi.org/10.1287/opre.24.6.1164>
- [42] W. B. Powell, *Approximate Dynamic Programming : Solving the Curses of Dimensionality*. John Wiley & Sons, Oct. 2011. [Online]. Available : <https://doi.org/10.1002/9781118029176>
- [43] J. Cao, N. Schofield, and A. Emadi, “Battery balancing methods : A comprehensive review,” in *2008 IEEE Vehicle Power and Propulsion Conference*. Harbin, Hei Longjiang, China : IEEE, Sep. 2008, pp. 1–6. [Online]. Available : <https://doi.org/10.1109/VPPC.2008.4677669>
- [44] K. Branker, M. J. M. Pathak, and J. M. Pearce, “A review of solar photovoltaic levelized cost of electricity,” *Renewable and Sustainable Energy Reviews*, vol. 15, no. 9, pp. 4470–4482, Dec. 2011. [Online]. Available : <https://doi.org/10.1016/j.rser.2011.07.104>
- [45] S. Simpure, “Modélisation, simulation et optimisation d’un système de stockage à air comprimé couplé à un bâtiment et à une production photovoltaïque,” Ph.D. dissertation, Université de La Réunion, Sep. 2018. [Online]. Available : <https://tel.archives-ouvertes.fr/tel-02059339/document>
- [46] I. Sartori, A. Napolitano, and K. Voss, “Net zero energy buildings : A consistent definition framework,” *Energy and Buildings*, vol. 48, pp. 220–232, May 2012. [Online]. Available : <https://doi.org/10.1016/j.enbuild.2012.01.032>
- [47] IRENA, *Renewable power generation costs in 2018*. Abu Dhabi. : International Renewable Energy Agency, May 2019. [Online]. Available : <https://www.irena.org/publications/2019/May/Renewable-power-generation-costs-in-2018>
- [48] PVGIS 5, “PV potential estimation utility,” Feb. 2019. [Online]. Available : <http://re.jrc.ec.europa.eu/pvgis/apps4/pvest.php>
- [49] A. Skoczek, T. Sample, and E. D. Dunlop, “The results of performance measurements of field-aged crystalline silicon photovoltaic modules,” *Progress in Photovoltaics : Research and Applications*, vol. 17, no. 4, pp. 227–240, 2009. [Online]. Available : <https://doi.org/10.1002/pip.874>

-
- [50] IRENA, *Electricity storage and renewables : Costs and markets to 2030*. Abu Dhabi : International Renewable Energy Agency, Oct. 2017. [Online]. Available : <https://www.irena.org/publications/2017/Oct/Electricity-storage-and-renewables-costs-and-markets>
- [51] strategie.gouv.fr, “Le taux d’actualisation dans l’évaluation des projets d’investissement public,” Feb. 2019. [Online]. Available : <https://www.strategie.gouv.fr/debats/taux-dactualisation-levaluation-projets-dinvestissement-public>

CHAPITRE 4

Microréseau et prévisions probabiliste

As far as the laws of mathematics refer to reality, they are not certain; and as far as they are certain, they do not refer to reality.

Albert Einstein

Sommaire

4.1	Introduction	126
4.2	Integration of probabilistic solar forecasts in the optimization of a microgrid operation	128
4.2.1	Introduction	128
4.2.2	Case study : Enerpos a NetZeb in the tropics	131
4.2.2.1	Monitoring system and records	131
4.2.2.2	Forecast	132
	Deterministic forecast	133
	Probabilistic forecasts	133
4.2.2.3	Forecast quality	135
	Deterministic forecast	135
	Probabilistic forecast	135
4.2.3	Microgrid model	138
4.2.4	Optimization problem	139
4.2.4.1	Problem formulation	140
4.2.4.2	Dynamic programming (DP)	141
4.2.4.3	Implementation of the PDP with Probabilistic Forecasts	142
4.2.4.4	Implementation of the reference method : SDDP	143
4.2.5	Results and discussion	145
4.2.5.1	SDDP versus PDP	145
4.2.5.2	Deterministic versus probabilistic	147
4.2.5.3	Link between quality and value	148
4.2.6	Conclusion	149
4.3	Indices de performance complémentaires	151
4.3.1	Indices de performance technique	151
4.3.2	PLF	152
4.4	Relations entre la qualité des prévisions et les performances technico-économiques	152

4.4.1	Coût de fonctionnement et pénalités	153
4.4.1.1	Résultats avec la puissance souscrite initiale (1kW)	153
4.4.1.2	Résultats avec une variation de la puissance souscrite	154
4.4.2	Indices de performance techniques	154
4.4.2.1	Taux d'utilisation du réseau	154
4.4.2.2	Nombre de cycles du stockage	156
4.4.2.3	Exportation vers le réseau	157
4.5	Conclusion	158

4.1 Introduction

À fin d'accroître l'utilisation de la production d'énergie renouvelable dans les réseaux électriques, les investisseurs privés et les politiques publiques encouragent le développement de la microproduction renouvelable intermittente tel que le PV. En raison de l'importance croissante de la microproduction dans la production d'électricité, le microréseau est devenu presque incontournable. Ces microréseaux intègrent leur propre production d'énergie renouvelable parfois intermittente, des charges et du stockage d'énergie.

Or, l'énergie intermittente génère des fluctuations importantes. Dans le chapitre 1 nous avons vu que l'utilisation des prévisions fait partie de la solution pour faire face à ces fluctuations. Il existe plusieurs techniques pour prévoir la production d'une EnR intermittente et ces prévisions peuvent prendre des formes déterministes ou probabilistes. La qualité de ces prévisions a une influence sur le coût de fonctionnement d'un système énergétique les utilisant. Dans ce travail, nous nous questionnons donc sur la relation entre la qualité d'une prévision et sa valeur ajoutée pour son utilisateur. Dans le chapitre précédent, nous avons montré qu'une prévision déterministe de la production d'une centrale PV permet de réduire le coût de fonctionnement d'un microréseau par rapport à une stratégie de contrôle basée sur des règles expertes.

De par sa nature même, la prévision déterministe n'est pas adaptée à la gestion des incertitudes inhérentes aux prévisions. Par contre, la prévision probabiliste intègre intrinsèquement cette notion d'incertitude. Mais dans le monde industriel, le potentiel des prévisions probabilistes est actuellement sous-exploité. En effet, les travaux décrivant l'usage des prévisions probabilistes de la production d'EnR intermittentes dans la gestion des systèmes énergétiques sont compliqués à reproduire ou à interpréter. Enfin, dans ces travaux, le manque de quantification des apports des prévisions probabilistes ne permet pas d'évaluer le potentiel de ce type de prévision.

Ce chapitre constitue l'essence de cette thèse. Ce travail est motivé par l'absence d'un cadre clair et détaillé pour l'utilisation des prévisions probabilistes de production d'EnR intermittentes dans la gestion des systèmes énergétiques et notamment du stockage. Ce travail vise à motiver l'utilisation de prévisions probabilistes dans l'exploitation des systèmes énergétiques. À l'instar du chapitre précédent sur l'apport de la prévision déterministe, la stratégie proposée est appliquée à la planification de l'état de charge d'un stockage intégré dans un microréseau. Le système considéré est composé de la charge du bâtiment EnerPos associée à un stockage de type Li-Ion et à un générateur photovoltaïque. La planification se fait un jour à l'avance. Les prévisions sont dérivées de prévisions numériques du temps (NWP) fournies par ECMWF.

Ce chapitre s'articule autour d'un article scientifique en cours d'évaluation par la revue Sustainable Energy, Grids and Networks. Cet article propose une méthodologie d'intégration

des prévisions probabilistes pour résoudre un problème d'optimisation et une comparaison entre l'utilisation des prévisions probabilistes et déterministes est proposée. À la suite de ce chapitre, des compléments sont proposés pour une meilleure compréhension de certains aspects de ce travail. Ils fournissent la description d'autres indicateurs pour évaluer la qualité de la prévision et le fonctionnement du microréseau. Enfin, ces compléments concluront sur la recherche de relations entre la qualité des prévisions probabilistes et ces indicateurs technico-économiques.

4.2 Integration of probabilistic solar forecasts in the optimization of a microgrid operation

Faly Ramahatana¹, Josselin Le Gal La Salle¹, Philippe Lauret¹, Mathieu David¹

1 – PIMENT Laboratory, University of Reunion Island, 97430 France

Abstract

This work proposes a methodology based on the probabilistic dynamic programming (PDP) to integrate operational probabilistic forecasts of a photovoltaic (PV) plant into the optimization of the day-ahead schedule of an energy storage system (ESS). The proposed approach is tested on a microgrid based on a real educational building, a PV farm and Li-ion batteries. The objective is to minimize the operating cost of the microgrid. The operational day-ahead forecasts are derived from the Ensemble Prediction System (EPS) provided by a well-known Numerical Weather Prediction (NWP) model.

The use of probabilistic forecasts into the optimization, even the worst one tested in this work, significantly outperforms the optimization based on a deterministic forecast. Indeed, the knowledge of the uncertainty of the future generation of the PV plant limits the cost of electricity purchase from the grid. In addition, and considering the specific case study of this work, the Continuous Rank Probability Score (CRPS) which is used to assess the quality of the probabilistic forecasts seems to be a good indicator of the value of the forecasts.

4.2.1 Introduction

For the grid manager, the unit commitment (UC) is an important operation for grid and microgrid management. The objective of the UC is to schedule the operation of the production units with a minimum cost and at a reliable level. The optimization of unit commitment is extensively studied in the literature, as described by Saravanan et al. [1] and by Abdou and Tkiouat [2]. Indeed, numerous optimization techniques are proposed to solve the unit commitment problem, like DP (Dynamic Programming), MILP (Mixed Integer Linear Programming), SP (Stochastic Programming), RO (Robust Optimization), QP (Quadratic Programming) and others. The use of those optimization methods depends on the system characteristics, the constraints and the objectives of the grid manager. For example, considering worst-case operating scenarios, Jiang et al. [3] used a RO (Robust Optimization) to solve the UC problem.

With the seek of decarbonization and energy supply security, the actual trend is on increasing renewable energy productions in the energy mix. Wind and solar energy are abundant RES (Renewable Energy Source) and the associated conversion systems, such as photovoltaics (PV) or wind turbines, are mature technologies. But those intermittent RES are highly variable in both space and time. In this work, we will focus on the PV production. Indeed, this technology is currently the most affordable RES and also the most used worldwide[4]. Furthermore, unlike conventional generators, intermittent energy plants are non-dispatchable production units. These two characteristics of intermittent RES result in an important uncertainty of their generation. As a consequence, the increase of the intermittent renewable share in the production mix adds more complexity to the grid management, especially to take these new uncertainties into account in the UC problem. To solve the UC problem in the presence of uncertainty, two

complementary approaches exist : the use of forecasts and the stochastic optimization called stochastic UC.

First, the use of point forecast, which gives a single value to predict a future level of production and which assumes a deterministic dynamic of the system, allows improving the scheduling. For example, Yang et al. [5] show that the use of PV and wind forecasts lead to better decisions in the UC problem. A lot of forecasting techniques exists to predict the future production of solar renewables. Diagne et al. [6], Antonanzas et al. [7] or Sobri et al. [8] propose reviews of solar forecasting methods and they highlight that the suitable techniques depend on the spatial scale and also on the temporality.

In the literature, one can find several works dealing with the integration of deterministic forecasts of renewable generation in UC problems for grids and microgrids [9, 10]. For example, relying on a Dynamic Programming (DP) approach, Grillo et al. [11] used a perfect forecast to optimize the control of a non-ideal storage (with a non-linear behavior such as the temperature of the cells and the variation of their resistances). Ramahatana and David [12] used deterministic solar irradiance predictions provided by the ECMWF (European Centre for Medium-Range Weather Forecasts) as input of a DP to optimize the day-ahead operation of an ESS (Energy Storage System) embodied in a microgrid.

The major drawback of deterministic solar forecasts is their nature. Indeed, they are intrinsically uncertain because the weather is a chaotic process. So a surge of interest is observed for the probabilistic forecasts, which quantify the uncertainty associated to the predictions [13, 14, 15]. The utilization of probabilistic forecasts could increase the value of the forecasts for the users. They provide an information that quantifies the uncertainty associated with the forecasts and that can be used to improve decision-making. Unlike a binary event such as the rainfall probability, the RES generation is a continuous variable. More precisely, the probabilistic forecast of an RES is a cumulative distribution function (CDF) that gives the probability associated to the level of production (i.e. power or energy). However, the physical and the economical interpretation of the results of such forecasts are complex to understand. Indeed, the contribution of the probabilistic information is difficult to interpret and the added value to the operation of energy systems is still poorly understood in the domain of smart-grids and grids.

Only a few works deal with the use of probabilistic forecasts of variable RES for the optimization of grid operation. The work of Zhou et al. [16], for example, shows the potential value of probabilistic wind production forecasts in power system operations through construction of scenarios. The forecasts can be incorporated into deterministic UC through probabilistic reserve requirements or can provide scenarios as input to stochastic UC. Furthermore, most of these works propose to associate the uncertainty to a point forecast rather than using the probabilities given by a probabilistic forecast. The two main methods proposed to take into account the forecasting error are to build scenarios or to use the correlation of the error between the simulation time steps as detailed by Pinson et al. [17]. Alharbi and Raahemifar [18] used the former approach. They created scenarios for the day-ahead scheduling of controllable DG (Distributed Generator) (Wind, PV and storage). In their work, the scenarios are derived from non-realistic forecast errors associated with arbitrarily chosen probabilities. Among others, as presented by Botterud et al. [19, 20], probabilistic forecasts, such as predictions of wind generation quantiles, can be used in reserve sizing or operation to reduce operating cost. For demand-side management, as shown by El-Baz et al. [21, 22], the use of probabilistic solar forecasts can increase the self-sufficiency of a microgrid by 24%. However, in those cases, the selected approach does not capture the effect of the serial correlation of the wind power forecast errors.

Another issue of the UC problem is to handle uncertainties through the optimization. An important number of stochastic methods exists to solve UC problems as described by Dai et al. [23], [2] or Zheng et al. [24]. The 3 main classes of methods are the SP (Stochastic Programming), the RO (Robust Optimization) and the methods based on the SDP (Stochastic Dynamic Programming). The review of Zhou et al. [25] details techniques and strategies based on stochastic methods applied to the optimization of power system operation in presence of RES. In the field of stochastic optimization, the distributions of the random variables, which corresponds to the inputs, are generally supposed to be known and the optimization requires the generation of scenarios derived from these distributions. Thus, as showed by Bayraksan and Morton [26] or by Nesterov and Vial [27], the solution of the optimization depends on the sampling techniques used to generate the scenarios, which implicitly relies on the knowledge of the distributions of the random variables. Furthermore, as the actual distributions of the random variables are frequently unknown, a first method propose to use approximations based on parametric distribution laws such as Beta distribution [28], truncated Normal distribution [29, 30] or Gamma distribution [31]. Another approach relies on historical data, and it is equivalent to use a climatological forecast. Indeed, empirical distributions are calibrated thanks to the historical data. Different variant of this approach are discussed by Linderoth et al. [32]. This strategy avoid the need of knowledge of the real distribution. But as stated by Kaut [33] or Shapiro and Nemirovski [34], the long-term trends could not be suitable to represent the near future. As variable RES are very fluctuant, because they result from chaotic weather systems, the use of the climatology as a description of the short-term future is not the best answer. For example, for two successive days that experience very different sky condition (e.g. overcast then clear), a unique distribution based on the whole historical data will give a very approximative estimation of the real distribution for these specific days. Finally, to the best of our knowledge, it seems that there is no framework to evaluate the effect of the approximation of the input distributions on the quality of the solution obtained by a stochastic optimization.

In the realm of solar forecasting, most of the studies focus on the evaluation of the quality of the probabilistic forecasts and a few or even no works are devoted to the assessment of their value. Let us recall that quality refers to the correspondence between the forecasts and the corresponding observations, while value is the benefit (economical or others) gained from the use of the forecasts in an operational context. This work attempt to fill the gap between the community that develops probabilistic solar forecasts and the stochastic optimization domain. More precisely, this work proposed a methodology to assess the link between the quality of probabilistic solar forecasts, like the CDF derived from an EPS generated by a NWP, and the results of a stochastic optimization applied to a UC problem. Furthermore, regarding the current state of the art, it is not clear how improving the quality of probabilistic solar forecasts, in terms of improved scores or increased reliability, may lead to added value for the decision-makers. Thus, the goal of this work is two-fold. First, it aims at proposing a method to integrate probabilistic forecasts of PV production to minimize the operation cost of a microgrid. Second, this work will highlight the opportunity of using probabilistic forecasts instead of deterministic ones to optimally schedule the UC one-day ahead.

As presented by Powell [35], the DP is the best candidate to optimize a computable value function under uncertainty and to solve problems with low dimensions. Furthermore, DP is one of the most successful approach used to solved UC problems Lowery [36], Snyder et al. [37], Ouyang and Shahidehpour [38], Abdou and Tkiouat [2] because it works on convex and non-convex cost functions. Considering probabilistic solar forecasts as input, a probabilistic

version of the DP [39] will be used. In order to avoid going through intermediate processes, such as scenario generation that add more complexity and inaccuracies in the optimization, the choice fell on the direct use of CDF provided by the forecasting models. Thus, we selected the Probabilistic Dynamic Programming (PDP) framework to solve a UC problem by taking into account probabilistic forecasts of intermittent RES production.

A case study based on a real building, a PV production, records of a weather station and operational weather forecasts will serve as support for the proposed method. The considered microgrid is composed with a net-zero energy building (**NetZeb**), Li-ion batteries and a connection to the main grid. The objective is to use day-ahead probabilistic solar forecasts to schedule the commitment of the ESS and to minimize the operation cost of the microgrid.

This work is organized in 4 parts. Section 4.2.2 describes the case study and the corresponding data. Section 4.2.3 details the microgrid model. Then, section 4.2.4 gives an extensive description of the implementation of the probabilistic forecasts inside the optimization framework. Finally, the results are discussed in section 4.2.5.

4.2.2 Case study : Enerpos a NetZeb in the tropics

The considered case study is a NetZeb university building located in Reunion Island [40]. The NetZeb has an annual PV production greater than its energy consumption. Indeed, passive solutions ensure the thermal comfort of the users and a Building Integrated PV (BIPV) farm covers the building needs.

4.2.2.1 Monitoring system and records

The EnerPos building has a complete monitoring system that records the weather parameters, the electricity consumption and the PV generation. The on-site weather station complies with the WMO standards and records the main weather variables (solar irradiance, dry bulb temperature, relative humidity, rainfall, wind, etc.). Energy meters measure the PV generation and the electricity consumption for the different usages of this educational building : cooling, lights, fans, appliances, lift, etc. The recording time step is of 1 minute for all the parameters and for the considered period (2010-2011). Unfortunately, it is hard to maintain a continuous flow of 1-min measurements and the time-series of data experience an important number of gaps. The consideration of the correlations between the load, the weather and the NWP production is necessary to simulate the microgrid. As a consequence, traditional gap-filling methods, such as interpolation, could not be used in our case. Thus, we built a 2-years time series of 1-min data by aggregating entire days without gaps from the years 2010, 2011 and 2012. The resulting files can be download at [41]. For our case study, hourly averages of the 1-min data have been used. Furthermore, year 2010 will be used to train the calibration procedures described in the next subsection and year 2011 will be used to test the models.

The PV output power is computed from the meteorological data as shown in (4.1). The computation of the PV power output [10] takes into account the global horizontal irradiance (GHI), the ambient temperature (T^a) and the operating characteristics of the PV modules given in Table 4.1.

$$\begin{aligned}
 PV_t &= \lambda \times PV^{max} \times \left(\frac{GHI_t}{I_r^{STC}} \right) \times \left(1 - \nu \times (T_t^c - T^{c,STC}) \right), \\
 T_t^c &= \frac{T^a + (T^{c,NOCT} - T^{a,NOCT}) \times \left(\frac{GHI_t}{I_r^{NOCT}} \right) \times \left(1 - \frac{\eta^{STC} \times (1 - \nu \times T^{c,STC})}{\varphi \times \zeta} \right)}{1 + (T^{c,NOCT} - T^{a,NOCT}) \times \left(\frac{GHI_t}{I_r^{STC}} \right) \times \left(\frac{\nu \times \eta^{STC}}{\varphi \times \zeta} \right)}.
 \end{aligned} \tag{4.1}$$

TABLE 4.1 – PV array characteristics used for the case study

Symbol	Designation	Value	Unit
PV^{max}	Rated capacity of the PV array	6	kW
η^{STC}	Maximum PV efficiency at STC	15.46	%
ν	PV temperature coefficient of power	-0.43	$\%/^{\circ}K$
T^a	Ambient temperature	25	$^{\circ}C$
$T^{a,NOCT}$	Ambient temperature at NOCT	20	$^{\circ}C$
λ	PV derating factor (wiring losses, shading factor)	95	%
I_r^{STC}	Incident radiation at STC	1	kW
I_r^{NOCT}	Incident radiation at NOCT	0.8	kW
$T^{c,STC}$	PV cell temperature at STC	25	$^{\circ}C$
$T^{c,NOCT}$	Nominal operating cell temperature at NOCT	45	$^{\circ}C$
φ	Solar transmittance of PV array	90	%
ζ	Solar absorptance of PV array	90	%
$LCOE^{PV}$	Levelized cost of PV production	3.35	$c\text{€}/kWh$

4.2.2.2 Forecast

In this work, we focus on the integration of the PV forecasts in the optimization of the microgrid operation. The future loads of the microgrid (i.e. the different usages of the building) are assumed to be known. Thus, the load forecasts are perfect forecasts corresponding to the measured data.

The probabilistic weather forecasts used here are provided by the Ensemble Prediction System of the European Centre of Medium-range Weather Forecasts (ECMWF-EPS) [42]. They consist in up to 10 days ahead of forecasts with a 3-hours granularity. The ECMWF-EPS has 50 members obtained by running 50 times the Integrated Forecasting System (IFS), which is the NWP model used at the ECMWF. Indeed, a small deviation in error analysis can lead to strong differences in the results of the stochastic physics of the atmospheric model. Thus, to take into account uncertainty, initial conditions of the NWP are perturbed and 50 different forecasts are generated simultaneously [43]. Because the raw ECMWF-EPS represents the extremes and the repartition of the possible outcomes, the sorted member can be interpreted as a set of quantiles of a cumulative distribution function (CDF) [44].

The probabilistic forecast used for the optimization of the grid operation is more precisely the ensemble forecasts generated at midnight with an initial time resolution of 3 hours and a

horizon of up to 72 hours. As we plan to optimize the hourly schedule of the storage operation, a down-scaling of the original ECMWF-EPS is required. The probabilistic forecasts with an hourly granularity are obtained with an oversampling method. The process takes place in two stages :

- Oversampling : The method was developed during the ENDORSE project [45] by the Mines Paristech’s team. The method generates a linear interpolation at higher time resolution of the solar irradiance time series assuming energy conservation from shorter to longer samples. It is worth noting that the oversampling procedure can change the order of the EPS members.
- Sorting : The probabilistic forecast, which corresponds to a CDF, is obtained by ordering the M members of the EPS. This commonly used method defines a cumulative distribution function with a probability jump of $1/(M+1)$ between the members. This way to associate the sorted members of the EPS to a CDF is called "uniform" by [44].

In this work, we will use 1 deterministic forecast and 5 probabilistic forecasts. The following subsections detail how they are generated.

Deterministic forecast One can easily create a deterministic forecast by taking the mean of the members of the EPS. This deterministic forecast will be referred as "Mean(EPS)". The mean $\widehat{GHI}_{t+h}^{eps}$ (eq. 4.2) is the average value of the 50 members available at time t and for a forecast horizon h . The mean is considered as the most consistent forecast when the evolution of perturbations in the NWP is nonlinear [43]. However, when the evolution of the perturbations in the model is linear, the mean forecast is almost equal to the deterministic forecast provided by ECMWF. Thus, the mean of the EPS commonly outperforms the control run, and it can be considered as a good challenger of the probabilistic forecasts.

$$\widehat{GHI}_{t+h}^{eps} = \frac{1}{M} \sum_{k=1}^{M=50} eps_{t+h,k}. \tag{4.2}$$

Probabilistic forecasts In addition to the oversampled EPS derived from the ECMWF-EPS, four probabilistic forecasts will be considered in this work. First, a deseasonalized climatology $\widehat{GHI}_{t+h}^{Clim}$ is proposed (4.4). Its predictive CDF summarized by a set of quantiles with probability levels τ spanning the unit interval is derived from the whole clear sky indices CSI (4.3) of the training data set sorted in ascending order. The CSI is the ratio $\frac{GHI}{GHI^{ClearSky}}$ between the measured GHI and the GHI observed under a clear sky. The clear sky irradiances $GHI^{ClearSky}$ required to compute the clear sky indices are provided by the McClear model [46]. The climatology will be used as a reference because it is perfectly reliable and has no resolution (i.e. the forecasted CDF $\widehat{F}(CSI^{train})$ is always the same). The choice to use the CSI for the construction of the climatology is motivated by the elimination of the seasonal and diurnal variation of the GHI along the year. For instance, in winter, a raw climatology based on raw GHI records will misrepresent the possible values of GHI and the higher quantiles will overestimate the occurrence of the GHI outcomes.

$$CSI(\tau) = inf\{CSI^{train} \mid \widehat{F}(CSI^{train}) \geq \tau\}, \tag{4.3}$$

$$\tau \in \{0, 1\},$$

$$\widehat{GHI}_{t+h}^{Clim}(\tau) = CSI(\tau) \times GHI_{t+h}^{ClearSky}. \quad (4.4)$$

Second, we use three calibrated ensemble forecasts derived from the oversampled ECMWF-EPS. Indeed, the literature shows that calibration [47] is necessary to increase reliability and consequently the overall quality assessed by proper scores such as the CRPS (see section 4.2.2.3). The calibrated forecasts are generated by three different methods namely the Variance Deficit ("VD"), the analog ensemble, and the Linear Quantile Regression ("LQR"). These three methods are non-parametric, meaning that there is no need for an *ex-ante* assumption on the characteristics of the forecast distribution.

The variance deficit is a procedure specially designed to answer the lack of variance of the forecast distribution, the most prominent well-known weakness of ensemble forecasts [48]. This is a member-by-member adjustment. It transforms individually each member of an ensemble, in such a way that the calibrated ensemble meets a required condition, i.e. that its variance equals the mean error of the mean of the ensemble. The VD method is exhaustively described by David and Lauret [15].

The second technique used in this study, the linear quantile regression ("LQR"), estimates each quantile of the predictive CDF separately. The quantile forecast Q_τ for each probability level τ is calculated linearly from the mean μ_R and the standard deviation S_R of the raw ensemble :

$$Q_\tau = \alpha_\tau \times \mu_R + \beta_\tau \times S_R + \gamma_\tau. \quad (4.5)$$

This formulation implies that both the mean and the variance of the raw ensemble are assumed to be linearly related to the level of the quantile forecasts. The parameters α_τ , β_τ , and γ_τ are calculated by a minimization of the loss function over the training period (see [47] for details).

Finally, the third calibration method is based on the analog ensemble technique which is widely used by the solar forecasting research community [49, 50]. The idea of this method is to associate to a new forecast the closest forecasts in the training period (relatively to some metric). The corresponding measurements of the training period constitute the new ensemble. In this study a very simple method of analog ensemble has been implemented, from the complete procedure explained by Le Gal La Salle et al. [51]. In this version, only the mean of the raw ensemble members is considered as a predictor. It is worth noting the strong differences in the philosophy of the three considered models : when analog ensemble only takes into consideration the mean of the raw ensemble members, linear quantile regression adds the variance to the set of the predictors. Conversely, the variance deficit method considers all the members to build the predictive CDF.

For all the five probabilistic forecasts used in this work, the predictive distributions are given by a set of $M = 50$ discrete quantiles with probabilities spanning the unit interval. In other words, the quantiles range from a probability level of $\tau_1 = 0.02$ to $\tau_{50} = 0.98$ with a step of $\frac{0.98 - 0.02}{50 - 1}$. We chose this distribution of the quantiles to be consistent with the EPS, which has 50 members. Indeed, the EPS can be seen as a CDF with each member corresponding to a quantile and a uniform spacing of the corresponding probabilities (see [44]). The extreme probabilities of 1 and 0 will not be required by the optimization process because their corresponding expectations are null. Indeed, the expectation is the product of the probability with the outcome. And for instance, a probability of 1 corresponds to an outcome of *0Wh* (i.e at least a production of *0Wh*) and a null probability gives a null expectation.

4.2.2.3 Forecast quality

A forecast is characterized by three attributes namely consistency, quality and value [52]. Consistency refers to the agreement between the forecaster’s judgement and his forecast. Quality evaluates the correspondence between forecasts and observations. Value quantifies the benefits (economical or others) for the users of the forecasts. In this section, we will detail the main metrics defined in the literature to assess the quality of deterministic and probabilistic forecasts. The value will be addressed through the case study and its computation will be detailed in section 4.2.4.

Deterministic forecast A well-known evaluation framework, which is described in numerous works [53, 54, 55], is used here to assess the quality of the deterministic solar forecasts. Among all the error metrics available in this evaluation framework, we selected three main ones because they are widely used and readers that do not belong to the solar forecasting community can easily understand them. These metrics are namely the Mean Bias Error (MBE) (4.7), the Mean Absolute Error (MAE) (4.6) and the Root Mean Square Error (RMSE) (4.8). These metrics are based on the difference between the forecasts \hat{y} and the observations y for a set of N forecast/observation pairs. Their relative counterparts, given in percent, are the ratio between the considered error and the yearly average of the GHI.

$$MAE = \frac{1}{N} \sum_{j=1}^N | \hat{y}_j - y_j |, \tag{4.6}$$

$$MBE = \frac{1}{N} \sum_{j=1}^N \hat{y}_j - y_j, \tag{4.7}$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{j=1}^N \hat{y}_j - y_j}. \tag{4.8}$$

TABLE 4.2 – Error metrics for the deterministic forecast Mean(EPS)

	MAE	MBE	RMSE	units
Absolute	91.89	22.65	142.32	Wh/m^2
Relative	19.85	4.89	30.74	%

Probabilistic forecast The evaluation of the quality of a probabilistic forecast is more complex. However, a recent article clearly defines an evaluation framework to carry out a comprehensive assessment of solar probabilistic forecasts [44]. The quality of a probabilistic forecast is characterized by two attributes. First, reliability refers to the statistical consistency between forecasts and observations. Also called calibration, this attribute of the forecast is the most important one. Indeed, non-reliable forecasts would lead to a systematic bias in subsequent decision-making processes [56].

Ensemble calibration can be visually assessed through the use of rank histograms (RH). This graphical tool gives a qualitative assessment of the reliability and it will be used here

to characterize the different probabilistic forecasts provided in this work. A RH also gives relevant information about the bias of the forecasts. Their construction is detailed by Lauret et al. [44]. A forecast can be stated as reliable if the histogram of the ranks remains inside the consistency bands. In the case where statistical consistency is not verified, the different possible other interpretations of a RH are given below. A U-shape RH corresponds to an over-confident probabilistic model (i.e. under-dispersion of the set of forecasts) meaning that the observation is often an outlier in the distribution of forecasts. Conversely, a RH with hump shape means an under-confident model (i.e. distribution of forecasts consistently too large). It indicates that the observation may too often be in the middle of the set of forecasts. Also, asymmetric (or triangle shape) RH is an indication of unconditional forecast biases. Furthermore, overpopulation of the smallest (resp. highest) ranks will correspond to an overforecasting (resp. underforecasting) bias.

Figure 4.1 shows the rank histograms of the five considered probabilistic forecasts. As expected, the climatology is perfectly reliable and exhibits a flat rank histogram, which laid inside the consistency lines (dotted lines). It is well known that the EPS produces too sharp prediction intervals and the resulting rank histogram has a U-shape, which indicates a lack of spread of the members. The three calibrated forecasts (i.e. LQR, Analog and VD) have a better reliability than the raw EPS. However, the highest rank of the VD and of the LQR is overpopulated and indicates an underforecasting. For these two forecasts we can also observe a bias highlighted by an asymmetric shape of their respective RH. The Analog forecast seems to have the best calibration.

The second attribute is the resolution that measures the ability of a model to generate case dependent forecasts. In other words, a highly resolute forecast is the opposite of the climatological forecast defined in section 4.2.2.2, which generates a single predictive distribution irrespective of the different forecast situations. A high resolution also ensures sharp prediction intervals. Unfortunately, no visual tool exists to evaluate the resolution. However, the resolution can be quantified by the decomposition of the Continuous Rank Probability Score (CRPS) presented hereafter. The overall quality of a probabilistic forecast can be evaluated with the CRPS [57]. This score is appealing because it corresponds to the MAE for a deterministic forecast. It is expressed with the same units as the forecast and it can be decomposed into reliability and resolution. Equation 4.9 gives the general formulation for a set of N forecast/observation ($\hat{F}_j^{fst} | F_j^{obs}$) pairs :

$$\overline{CRPS} = \frac{1}{N} \sum_{j=1}^N \int_{-\infty}^{\infty} [\hat{F}_j^{fst}(x) - F_j^{obs}(x)]^2 dx. \quad (4.9)$$

To compute the CRPS and its decomposition, we used the R package called “Verification” [58] based on CRPS estimation defined by Gneiting et al. [47]. Equation (4.10) gives the CRPS decomposition used in this package and initially proposed by Hersbach [57], where \overline{Reli} is the reliability, \overline{Resol} is the resolution and \overline{U} is the uncertainty, which is a constant term that depends only on the observations. In this work we prefer to use the potential CRPS ($\overline{CRPSpot} = \overline{U} - \overline{Resol}$), also proposed by Hersbach [57]. Indeed, as the uncertainty is constant, the $\overline{CRPSpot}$ is equivalent to the resolution, and it has the advantage to be negatively oriented (lower values are better) like the reliability and the CRPS.

$$\overline{CRPS} = \overline{Reli} - \overline{Resol} + \overline{U} = \overline{Reli} + \overline{CRPSpot}. \quad (4.10)$$

For scores like CRPS that are negatively oriented, the goal of a forecasting model is to minimize as much as possible the *Reli* and the *CRPSPot* terms. In fact, a forecasting model

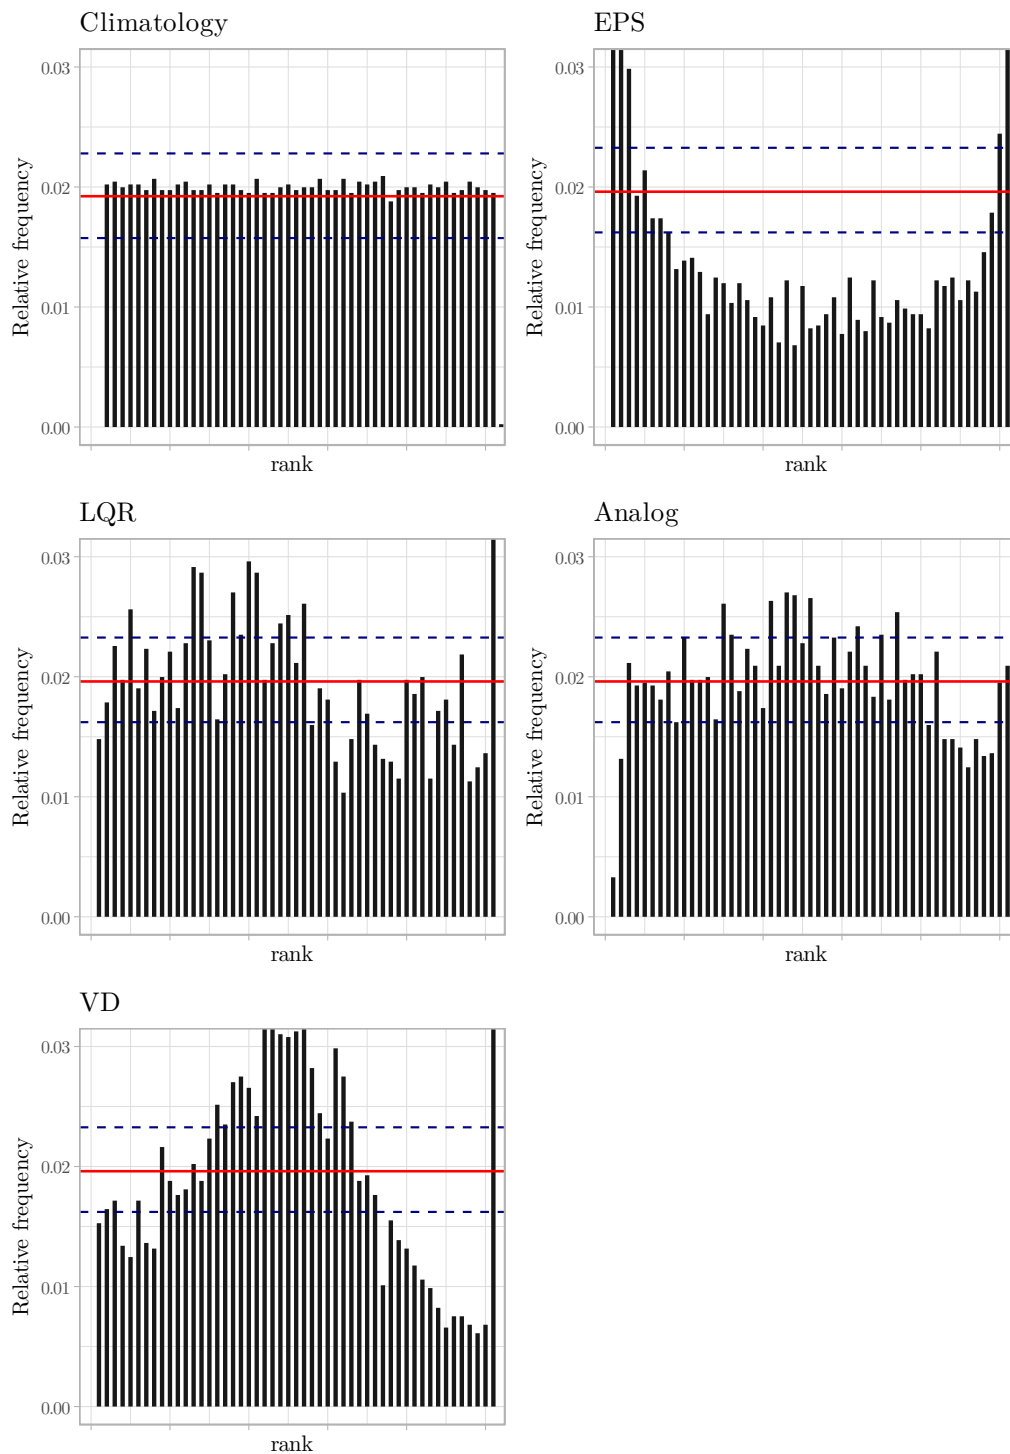


FIGURE 4.1 – Rank histograms of the five probabilistic forecasts. For sake of clarity, the relative frequency axis has been bound to 3.2%

with a high resolution term means that the model has captured the maximum of the variability present in the data (which variability is measured by the uncertainty term). Table 4.3 shows the CRPS of the five forecasts with their respective decomposition.

The values of the reliability confirm the assessment done with the RH. The Analog forecast has the best reliability, which is equal to the reliability of the Climatology forecast. According to the CRPS, the Analog and the LQR forecasts have the best quality. The relationships between these indicators and the value of the forecasts will be analyzed in detail in section 4.2.5.

TABLE 4.3 – The CRPS and its decomposition for 5 considered probabilistic forecasts

Models	CRPS (Wh/m ²)	CRPSpot (Wh/m ²)	Reliability (Wh/m ²)
Climatology	70.14	69.86	0.29
EPS	73.61	64.76	8.85
LQR	65.86	65.39	0.46
Analog	68.69	68.41	0.29
VD	73.00	70.42	2.57

4.2.3 Microgrid model

The considered microgrid is a building load, a building integrated PV (BiPV) farm, an ESS, a connection to the grid and an Energy Management System (EMS) as described in section 1. Energy flows (plain lines) and data transmissions (dashed lines) are illustrated in Figure 4.2. The BiPV generation (PV_t), the ESS (ESS_t) and the main grid (Gr_t) are supposed to meet at each time t the load (L_t). However, when there is an excess of production of the microgrid, the energy can be fed into the grid. The balance at time t between the supply and the demand is given by equation (4.11) below :

$$Gr_t + ESS_t + PV_t = L_t. \quad (4.11)$$

Because the PV farm and the batteries work with direct current (DC) and the building with alternating current (AC), the microgrid has two inverters. Here we assume that they have the same efficiency curve, defined in equation (4.12). The inverter efficiency η^{inv} is computed with the model proposed by Riffonneau et al. [10]. The efficiency depends only on the ratio In between the input power and the nominal power of the converter.

$$\eta^{inv} = \frac{1}{In} (0.0094 + 0.043 \times In + 0.04 \times In^2), \quad (4.12)$$

The state of charge (SOC) defines the level of energy stored in the ESS. In this work, we assume that the SOC of the ESS can be measured and calculated deterministically. At time t , the SOC depends on the current energy stored in the ESS (ESS_t) and on the nominal capacity Ca_{ref} :

$$SOC_t = \frac{ESS_t}{Ca_{ref}}. \quad (4.13)$$

Considering a variation ΔSOC_t of the SOC between two time step (t and $t - 1$), equation 4.14 gives the relationships that rule the energy transfers during discharge ($\Delta SOC_t > 0$) and charge ($\Delta SOC_t < 0$) of the ESS.

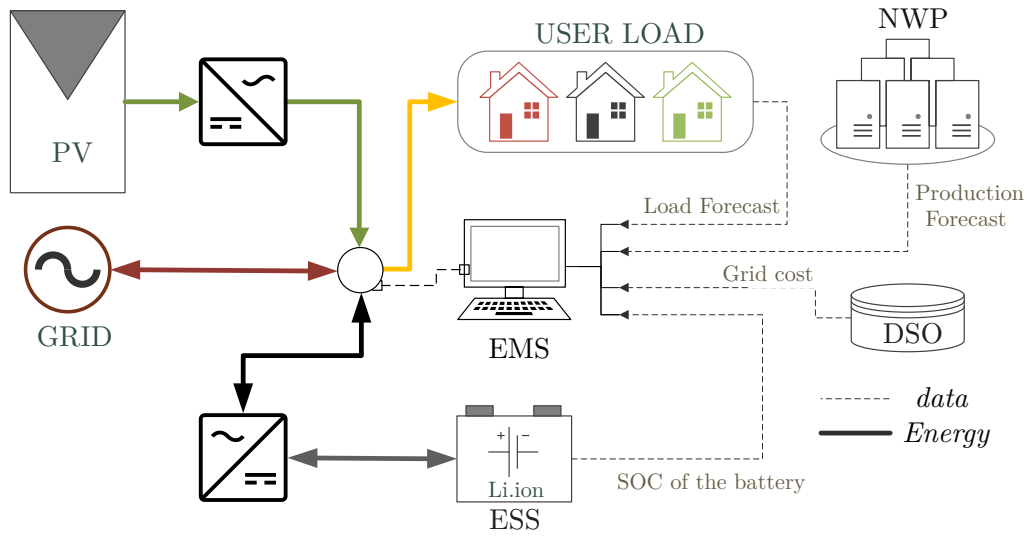


FIGURE 4.2 – Microgrid energy flows and control diagram

$$\begin{aligned}
 ESS_t^{Charge} &\equiv -\Delta SOC_t \times C_{a_{ref}} \\
 ESS_t^{Discharge} &\equiv \Delta SOC_t \times C_{a_{ref}}
 \end{aligned}
 \tag{4.14}$$

The degradation model of the ESS used in this work has also been inspired by Riffonneau et al. [10]. This simple model, initially designed for lead-acid batteries, assumes a linear degradation of the ESS capacity ($C_{a_{ref}}$) and it is suitable for many different technologies. The state of health (SOH) quantifies the level of degradation of the ESS capacity. The SOH variation i.e. ΔSOH is proportional to the SOC variation ΔSOC but only when a discharge occurs. Equation (4.15) details the degradation model where Z is the aging coefficient that can be derived from the ESS lifetime expressed in number of full cycles and from the corresponding reduction of the state of health of the ESS. The ESS in this study is an lithium iron phosphate battery (LFP). The characteristics of this ESS come from the IRENA cost-of-service tool [59] with reference data from 2020. The full characteristics of the Li-ion batteries used in this work are given in Table 4.4.

$$\begin{aligned}
 \Delta SOH_t &= Z \times \Delta SOC_{\{\Delta SOC < 0\}}, \\
 &= Z \times (SOC_{t-1} - SOC_t)_{\{(SOC_{t-1} - SOC_t) < 0\}}.
 \end{aligned}
 \tag{4.15}$$

4.2.4 Optimization problem

The aim of the EMS is to minimize the operation cost of the microgrid thanks to day-ahead forecasts of the load and of the PV generation. The ESS is the unique controllable device of the system. As a consequence, the objective is to optimize the charging and discharging schedule of the ESS. The following subsections detail the formulation of the optimization problem and how it is implemented in the probabilistic dynamic programming (PDP) and in the selected method of reference (i.e. SDDP).

TABLE 4.4 – Characteristics of the Li-ion batteries considered in the study case

Symbol	Designation	Value	Unit
$C_{a_{ref}}$	Storage nominal capacity	13.5	kWh
$ESS_{max}^{Discharge}$	Maximal energy discharge hourly (1C)	13.5	kWh
ESS_{max}^{Charge}	Maximal energy charge hourly (1C)	13.5	kWh
SOC_{min}, SOC_{max}	Minimal and maximal state of charge	10 – 100	%
SOH_{min}	Minimal state of health	80	%
Z	Ageing coefficient of the storage	8.31^{-5}	
η^{ESS}	Round Trip Efficiency	95.5	%
$P_{inv,ESS}$	ESS Inverter / Chargers rated power	13.5	kW
Sic	Total invest per usable kWh of storage	443.62	$\text{€}/kWh$

4.2.4.1 Problem formulation

The objective of the optimization is to minimize the annual operating cost of the microgrid (4.16). The operating cost is the sum of the costs of the 3 sources of energy : the PV ($LCOE^{PV} \times PV_t$), the storage (R_t) and the Grid ($U_t^{grid} \times G_t$).

$$J(SOC) = \min \sum_{t=0}^T (R_t + U_t^{grid} \times Gr_t + LCOE^{PV} \times PV_t). \quad (4.16)$$

The unit cost of the PV production is constant and corresponds to the levelized cost of energy ($LCOE^{PV}$) of the PV plant. Here, we compute the **LCOE** using the method proposed by the IRENA [60]. The cost of the storage at time t (R_t) is derived from the aging model proposed by Riffonneau et al. [10]. As stated above, the degradation of the ESS is proportional to the discharged energy. Furthermore, the storage replacement occurs when the minimal state of health SOH_{min} is reached. Thus, the storage cost is computed considering a linear degradation of the capacity due to the aging process as described in the following equation :

$$R_t = \begin{cases} Sic \times C_{a_{ref}} \times \frac{-\Delta SOH_t}{1 - SOH_{min}}, & \text{if } SOC_{t-1} - SOC_t < 0 \\ 0, & \text{otherwise,} \end{cases} \quad (4.17)$$

where SOH_{min} is the minimal state of health of the storage and Sic the storage investment costs obtained from the IRENA projections [59]. Depending on the direction of the energy flow, the grid U_t^{grid} can generate costs or revenues for the microgrid (4.18). For the considered case study, the price of electricity (E_{gp_t}) is the sum of the unit cost and of the penalties that depends on hours and seasons [61]. Table 4.5 gives an insight of the unit cost of energy and also of the penalties applied in case of overpower. Here, we have set up the power limit at $1kW$ which is the average power demand of the building and corresponds to a peak reduction of a factor of 7. The aim is to significantly reduce the impact of the microgrid on the main grid.

Conversely, when the electricity is fed into the grid because the microgrid produces more energy than required, the system generates incomes. In this second case, the electricity is sold to the grid with a constant feed-in-tariff FiT (6.90c€/kWh) according to the current regulation.

$$U_t^{grid} = \begin{cases} Fit, & \text{if } Gr_t < 0 \\ Egp_t, & \text{if } Gr_t \geq 0. \end{cases} \quad (4.18)$$

TABLE 4.5 – Purchased tariff, taxes included, of electricity and penalties applied in case of overpower for the considered study case

Designation	Peak	c€/kWh			
		normal		low	
		summer	winter	summer	winter
Unit cost	21.60	11.42	5.71	5.08	7.38
Penalties	1,704.54	715.91	51.14	85.23	34.09

The optimization is subject to 5 constraints. The first one is the energy balance of the microgrid (4.11). The two following constraints relate to the ESS limitations. The storage capacity is limited by its minimum and maximum SOC, respectively SOC_{min} and SOC_{max} (4.19). Then, if the minimal state of health SOH_{min} is reached (4.20), the ESS cannot operate anymore and must be replaced. Furthermore, the charge and discharge must not exceed the maximum energy that can flow in and out to the ESS due to the limitation of the power unit (4.21). The last constraint (eq. 4.22) rules the exportation of energy towards the grid ($Gr_t \leq 0$). Indeed, the exportation is allowed only if the microgrid has a excess of production.

$$SOC_{min} \leq SOC_t \leq SOC_{max} \quad (4.19)$$

$$SOH_t \geq SOH_{min} \quad (4.20)$$

$$ESS_{max}^{Charge} \geq ESS_{max}^{Discharge} \quad (4.21)$$

$$Gr_t \leq 0 \quad \text{if} \quad PV_t - L_t + ESS_t^{Discharge} \geq 0 \quad (4.22)$$

4.2.4.2 Dynamic programming (DP)

In the literature, several methods are proposed to optimize the schedule of a microgrid operation. Among these techniques, one can cite Multi-agent algorithms [62, 63, 64, 65], Model Predictive Controller (MPC) optimizer [66, 67, 68] and others [69, 70] that mainly carry out local optimization. The dynamic programming, which allows reaching a global optimum, is also widely used [10, 71, 72, 73]. In this work, we rely on the Hamiltonian Jacobi Bellman equation (HJB) [74] that is a recursive equation depending on the future value of the cost function. The definition of the state refers to the work of Bertsekas [75] : "State variable is the minimally dimensioned function of history that is necessary and sufficient to compute the decision function, the transition function, and the contribution function". Thus, the cost function is computed recursively and backward (i.e. $t + 1$ toward t) for each state change. The following equation gives the general formulation of DP where the $V_t(S_t)$ is the value of the objective function at time t , depending on the action x_t to reach the state S_t :

$$V_t(S_t) = \min(C_t(x_t) + \gamma \times \mathbb{E}V_{t+1}(S_{t+1})). \quad (4.23)$$

x_t is the action taken to switch between state t and state $t + 1$ from the policy space π . In our case the action is a charge or a discharge of the ESS that respects the maximum and minimum capacity of the ESS. $C_t(x_t)$ is the contribution to the cost of the decision x_t , where C is a function depending on the state at time t and at time $t + 1$. Obviously, S_t and S_{t+1} are the state (i.e. the SOC) of the ESS at t and $t + 1$ and $\mathbb{E}V_{t+1}(S_{t+1})$ is the expectation of the value for a change between state S_{t+1} and state S_t . Finally, γ represents the time value of money. It relates on the weight that a future decision has less influence in the total cost [76]. Considering an infinite horizon, γ is inferior to 1. Because the problem is solved numerically, the state needs to be a real value and will be discretized.

Equation (4.23) refers to the general formulation of dynamic programming. To take into account the uncertainty, two variants of the DP have been proposed : stochastic dynamic programming (SDP) and Probabilistic Dynamic Programming (PDP)[39]. Most of the works dealing with grid management use the SDP [10, 71, 77]. For the SDP, many formulations of the Bellman optimal policy are available. For instance, Powell [76] proposed a SDP that uses a stochastic forecast based on a tree search (i.e. a scenario) and roll-out heuristics. Furthermore, the SDP is frequently associated with a Monte Carlo sampling or a Markov Decision process (MDP) [78] to reduce the dimension of the research space and thus to cope with the curse of dimensionality. In this work we propose to use the PDP algorithm. The HJB equation presented above will not be solved with a Contraction Mapping Point (CMP) [75] method or a differentiation because we assume that the cost-to-go function is not necessarily monotonous or a contraction ($\gamma < 1$). The actual problem is restricted to a 1-dimension problem and it can be solved directly without any sampling techniques. More precisely, we use the Bellman-Ford [79] backward resolution without space reduction or sampling. This resolution eludes the use of the transition matrix between states, but relies on the known probability distribution of the input data.

4.2.4.3 Implementation of the PDP with Probabilistic Forecasts

As a remainder, the objective of the case study is to schedule the SOC of the storage one day ahead. This problem is also called look-ahead policies [76], because we need to solve future problems with the knowledge of future information (forecasts). To guarantee the effectiveness of this method, we chose to optimize the schedule for the next 3 days but only the first day will be used to operate the ESS. This rolling horizon procedure [80, 5] has been studied extensively for finite or infinite horizon problems.

Furthermore, the storage cost depends only on a decision of discharge (4.17). As a consequence, the future states of the ESS do not rely on the PV production forecast which is a CDF in our case. This assumption implies that the costs, which are computed by the DP for every possible SOC variations of the ESS, are not probabilistic. In our probabilistic framework, the PV production outcome (\widehat{PV}) is a probabilistic distribution of the expected generation. Thus, the grid outcome \widehat{Gr} depends on \widehat{PV} and on the SOC. As a consequence, the apparent cost of a $\widehat{PV} | \widehat{Gr}$ pair is computed for each quantile \widehat{PV}_{τ_q} of the PV forecast and each possible future SOC of the ESS.

It is important to note that a quantile with a probability level τ_q of a PV forecast namely \widehat{PV}_{τ_q} corresponds to the minimum value of the PV production that is expected. Indeed, we have a probability τ_q to have a PV production, which corresponds to the quantile \widehat{PV}_{τ_q} , that

is the minimum expected value. In our case, we are interested by the contrary event, that is to say the probability to exceed the forecasted quantile, as defined in the following equation :

$$\begin{aligned} Prob(\widehat{PV}_t > \widehat{PV}_{\tau_q}) &= 1 - \tau_q \\ &= 1 - CDF(\widehat{PV}_t). \end{aligned} \quad (4.24)$$

As the energy balance of the microgrid depends on the variation of storage SOC (i.e. ΔSOC) and on the forecast, the transition between states is implicit. So the probability of transition between states in the general DP formulation (eq. 4.23) is equal to $p = 1$. As a consequence, the constraint resulting from the energy balance of the microgrid (Eq. 4.11) is formulated as follow :

$$\widehat{Gr}_{i,t,q} - \frac{ESS_t^{Charge}}{\eta^{inv,ESS} \times \eta^{ESS}} + \eta^{inv,ESS} \times ESS_t^{Discharge} + \widehat{PV}_{t,\tau_q} = L_t, \quad (4.25)$$

where i corresponds to the state of the ESS (i.e. the SOC) and $\widehat{G}_{i,t,q}$ is the energy exchanged with the grid. As mentioned previously, the state of the SOC is discretized. In our case, we chose a step of discretization of 1%, such as $i \in \{SOC_{min}, SOC_{min} + 0.01, \dots, SOC_{max}\}$. The predictive CDF of the PV production is also discretized in $M = 50$ quantiles. One can see in this equation that the round trip efficiency of the ESS (η^{ESS}) is applied to the charge.

The cost-to-go function C_t for the problem is an expectation \mathbb{E} that depends on the probability τ_q to exceed the quantile \widehat{PV}_{τ_q} given by the PV generation forecasts :

$$\mathbb{E}[C_t(x_t)] = R_{i,t} + \frac{1}{M} \sum_{q=1}^M \tau_q \times \left(U_t^{grid} \times \widehat{Gr}_{i,t,q} + LCOE^{PV} \times \widehat{PV}_{t,\tau_q} \right), \quad (4.26)$$

Regarding more precisely the implementation of the deterministic forecast, we simply defined a Heaviside step function with a probability jump of 1 at the forecast value.

Finally, the generated predictive schedule has an 1-hour time step. The receding horizon produces a schedule of the ESS charges and discharges for the next 24 hours based on an optimization done with a horizon of 72 hours. Figures 4.3 and 4.4 show respectively an example of the implementation of the deterministic forecast and of the probabilistic forecast for the same day. In both cases, the ESS runs as scheduled by the lookahead optimization. For the selected day, the deterministic forecast experiences an important overestimation of the PV generation for the second part of the daytime while the probabilistic forecast indicates a significant probability of a lower production in the afternoon. Thus, the fulfillment of the schedule of the ESS obtained with the deterministic forecast results in a purchase of energy from the grid at the end of the afternoon to compensate the error and obviously at a high operating cost. Conversely, the high risk of under-production detected by the probabilistic forecast leads the optimization to slightly discharge the ESS at the end of the afternoon and thus to avoid an important purchase from the grid. As a consequence, the cost of operation is lower.

4.2.4.4 Implementation of the reference method : SDDP

To schedule the day-ahead operation of the ESS, we propose to use a well-known stochastic optimization method, i.e. the SDDP, as reference. Here we reproduce the implementation of the SDDP proposed by Kumar et al. [81] that also used a receding horizon. Even if this implementation of the SDDP is close to the one used to implement the PDP some modifications in




FIGURE 4.3 – Example of the microgrid operation when using the deterministic forecast to generate the optimal schedule of the ESS.




FIGURE 4.4 – Example of the microgrid operation when using the LQR probabilistic forecast to generate the optimal schedule of the ESS. The grey-scale color shows the quantiles given by the probabilistic forecast.

the problem formulation are required. Indeed, to use the SDDP, the problem must be convex, linear and the objective function has to be positive. To ensure the linearity of the problem, the inverter efficiency (η^{inv}) is fixed to a constant value of 0.9. Furthermore, the state of the system is now the energy stored in the ESS (ESS_t). A change of the state comes from charging and

discharging operations and the system cannot do both at the same time :

$$ESS_t = ESS_{t-1} + ESS_t^{Charge} - ESS_t^{Discharge}. \quad (4.27)$$

The constraint resulting from the energy balance (eq. 4.11) of the microgrid becomes :

$$Gr_t - \frac{ESS_t^{Charge}}{\eta^{inv,ESS} \times \eta^{ESS}} + \eta^{inv,ESS} \times ESS_t^{Discharge} + \overline{PV}_t \times \xi_t = L_t, \quad (4.28)$$

where the mean PV production (\overline{PV}_t) is associated with a perturbation parameter ξ_t that takes the uncertainty into account. Here, the distribution of the historical PV generation (i.e. the training dataset) is used to assess the mean and the uncertainty of the PV production. More precisely, they are both derived from the historical distribution of the clear sky index. Indeed, the clear sky index captures the seasonal variability of the solar resource, which is deterministic, and, in the field of solar energy, distributions derived from clear sky indices are known to outperform the ones directly computed from GHI [82]. Thus, to reproduce the uncertainty of the PV production, the SDDP considered in this work uses the distribution called climatology, which is also used with the PDP and detailed in section 4.2.2.2.

The linearization of the constraint relative to the exportation rules (eq. 4.22) is given by the following equation :

$$-Gr_t \leq \begin{cases} \eta^{inv,ESS} \times ESS_t^{Discharge} + PV_t - L_t, & \text{if } PV_t - L_t \geq 0 \\ \eta^{inv,ESS} \times ESS_t^{Discharge} - L_t, & \text{otherwise.} \end{cases} \quad (4.29)$$

To ensure the tractability of the calculation, the sampling method proposed by Shapiro [83] is used to generate a limited number of disturbance values ξ_t (i.e. scenarios with equal probabilities). It is important to note that the sample size and the sampling technique could influence the solution of the optimization. Tests were carried out with sample size ranging from 50 to 200. For the considered case study, the sample size does not significantly change the resulting operating cost and all the results presented below are obtained for a sample size of 50.

Finally, the SDDP was implemented thanks to the **SDDP.jl** package [84] based on the **JuMP** modeling [85].

4.2.5 Results and discussion

4.2.5.1 SDDP versus PDP

A comparison of the operating costs obtained with the PDP and the SDDP approaches implemented as detailed above will result in a better performance of the SDDP in all cases (see operating costs given in tables 4.6 and 4.7). Indeed, the real efficiency (fig. 4.5) of the inverters used in the case study depends on the input power ratio (eq. 4.12). Thus, the assumption of a constant efficiency of 0,9 done with the SDDP leads to significantly underestimate the losses due to storage charges and discharges. As a consequence the energy flowing through the ESS is overestimated when the input power is lower than 20% of the rated power of the inverter. Finally, as the inverter runs frequently at low input power, the SDDP underestimate the operating cost of the microgrid. This result shows that it is very important to take the non-linearity of the inverters into account to produce relevant optimization results.

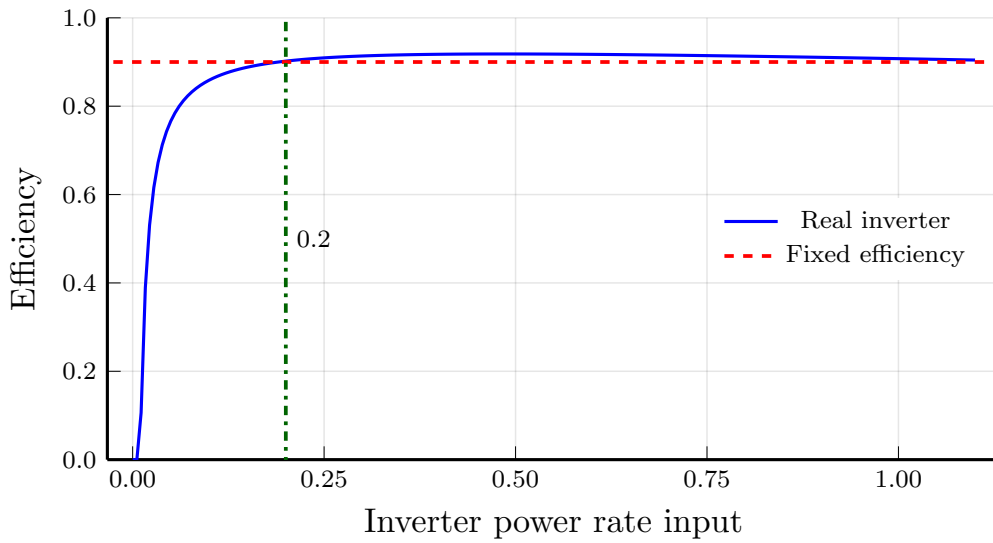


FIGURE 4.5 – Visual representation of inverter efficiency used for with the PDP (blue line) and with the SDDP (red dashed line)

However, a fair comparison between the PDP and the well-known stochastic optimization SDDP is required to assess the performance of the methodology proposed in this work. In this subsection, we propose to run the PDP with a constant efficiency of the inverters. Table 4.6 shows the optimization results for the reference method (i.e. SDDP) and for the proposed PDP approach with this constant efficiency of 0.9 for both approaches. Not all the forecasts associated with the PDP are able to outperform the SDDP. Only the optimizations done with the Analog and LQR forecasts give lower operating cost than the reference method. As the same climatology forecast has been used for both approach, we could expect that the PDP and SDDP results will be fairly close. The difference observed between the two approaches likely results from the control of the ESS done during the online step. Indeed, for the online step of the SDDP, a linear function of the real SOC and of a persistence of the PV production controls the commitment of the ESS. Whereas the PDP predefines the operation of the ESS the day before without any possibility to adjust the planning online.

TABLE 4.6 – Annual operating obtained with the SDDP (first row) and with the PDP (other rows) costs using a constant efficiency of the inverters for both approaches

DP	Forecasting model	Operating cost €
SDDP	Climatology(CSI)	1595.06
PDP	Perfect	332.86
PDP	Mean(EPS)	2259.47
PDP	EPS	1771.74
PDP	LQR	1506.44
PDP	Climatology(CSI)	1753.80
PDP	VD	1997.31
PDP	Analog	1482.07

4.2.5.2 Deterministic versus probabilistic

TABLE 4.7 – Economic and technical annual performance indices [86] of the PDP using a quadratic efficiency curve for the inverters

Forecasting Model	Operating cost €	Autonomy rate %
Perfect	389.75	55.63
Mean(EPS)	3059.92	55.03
EPS	2428.20	56.05
LQR	1897.28	54.69
Climatology	2356.44	49.15
VD	2442.90	53.73
Analog	1939.48	51.95

From an economic point of view (table 4.7), the probabilistic forecasts, even the worst one (i.e. EPS) clearly outperforms the deterministic forecast. Indeed, the operating cost of the microgrid obtained with the deterministic forecast is reduced by approximately 20% for the worst probabilistic forecast (i.e. EPS) and by 38% for the best ones (i.e. LQR and Analog). Even the climatology, which is a naïve model used in this work as a reference, performs better than the deterministic forecast. Unfortunately, the technical indicators do not provide relevant information to understand the big gap in terms of operating costs between the probabilistic and deterministic approach. Indeed, the value of those indicators are rather similar and do not highlight relationships between the economic gain and the exportation or the autonomy.




FIGURE 4.6 – Decomposition by time-of-use rates of the annual cost of the microgrid operation for the PDP results

In Figure 4.6, which presents a decomposition of the operating cost by electricity time-of-use rates, we can observe that the perfect forecast purchases little electricity to the grid and

mainly during low hours (i.e. mainly at night). During the daytime, the microgrid is nearly an autonomous system. In the case of the deterministic forecast (Mean(EPS)), the additional operating cost corresponds to the compensation of the forecast errors. These errors are observed only during the normal and peak hours. Obviously, the PV plant produces only on daytime and the low hours occur at night. As a consequence, most of the total cost is normal and peak hours. Using probabilistic forecasts, the EMS tends to counter balance the forecast inaccuracies by purchasing energy mainly during low and normal hours. It allows reducing the overall microgrid demand during peak hours. Finally, as shown in Figure 4.7, the costs due to exceeding the power demand constraint (i.e. the penalties) of the electrical grid are considerably reduced with probabilistic forecasts.




FIGURE 4.7 – Decomposition of the annual cost of the microgrid operation by type of expense

4.2.5.3 Link between quality and value

Several error metrics used to assess the quality of probabilistic and deterministic forecasts exist. All these scores are statistically relevant. However, in the field of solar forecasting, there is no clear framework for choosing the metric which will lead to the best microgrid management. In table 4.3, the CRPS of EPS and VD are almost identical (around $73Wh/m^2$) and the microgrid operation cost is almost the same. The VD calibration improves the reliability of the EPS but decreases the resolution of the forecasts. Thus, the gain in reliability is counterbalanced by the loss in resolution. Regarding the 5 probabilistic forecasts considered in this work, the LQR and Analog methods generate the lowest operating costs. In Figure 4.7, the cost is decomposed by type of expenses (i.e. purchase from the grid, penalties, ESS operation and exportation to the grid). The penalties due to overpower are the most important part of the total cost. Indeed, the selected power limit is restrictive because we chose to reduce at its maximum the impact of the microgrid on the main grid by avoiding high peak power demands. Thus in this study case, the best probabilistic forecast is the one that generates the fewest penalties (i.e. LQR and Analog methods).

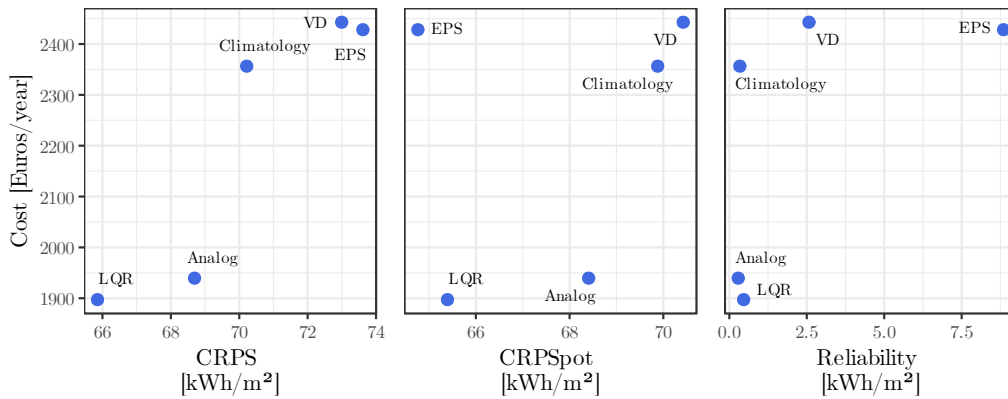


FIGURE 4.8 – Annual operating cost as a function of the CRPS and its two components, reliability and resolution (CRPSpot)

One can also note that, except the VD method, the calibration of the EPS leads to forecasts of increased quality and consequently to a better ESS schedule. First, the reliability is significantly improved. Second, the resolution (i.e. CRPSpot) increases. But, the loss in resolution is less important than the gain in reliability. We can conclude that the more efficient methods improve the reliability without deteriorating the resolution. Figure 4.8 shows how the three indicators (i.e. CRPS, Resolution, Reliability) are linked to the operating cost. For this case study, the CRPS seems to be a good score to select the best forecast. Indeed, except for the VD technique, a lower CRPS value leads to a reduction of the operating costs. Even if the EPS has the lowest CRPSpot, it has one of the highest cost. LQR and Analog models have roughly the same operating cost, but their CRPS are different. The CRPS of the LQR is lower than the CRPS of the Analog. But the reliability of the Analog is slightly better.

However, when the resolution and the reliability are analysed separately, no clear relationship between quality and value appears. For instance one can see in Figure 4.8 that climatology, which experiences the best reliability, results in a higher cost than the LQR or the Analog. Similarly, the EPS, which has the best resolution, has one of the highest costs. If we look in details the two worst probabilistic forecasts (i.e. EPS and VD), the differences in CRPS and operating costs are very small. Even if the VD has a better reliability, the EPS somehow compensates this lack with a better CRPSpot (i.e. resolution). For this specific case study, we can conclude that the value of the forecast is linked to a good combination between reliability and resolution, that is to say the CRPS. Here the decomposition only gives a better insight into the skills of the different calibrations techniques.

4.2.6 Conclusion

This work proposes a method for using probabilistic forecasts of intermittent RES, which take the form of discrete quantiles, in order to minimize the operating cost of a microgrid. Our approach combines the (PDP) with a receding horizon to solve an optimization problem of scheduling. The PDP can solve linear and non-linear problems and is specifically suitable for the integration of predictive distributions arranged in discrete quantiles. The proposed method has been applied to a microgrid energy management to plan the ESS operation one day ahead. Our case study was a microgrid with a NetZeb building, a BiPV plant and Li-ion batteries.

With this method and for this specific case study, the integration of the probabilistic forecasts in the optimization process results in a more efficient microgrid management and lower operating costs than the use of a deterministic forecast. The probabilistic approach allows anticipating the risk of penalties due to overpower. Indeed, in our case, the power limit is highly restrictive and the operating cost is mainly driven by the penalties.

This work shows that the CRPS seems to be a good candidate for establishing a link between quality and value. In our case, the value of the forecasts given by the operating cost decreases when the CRPS is better.

The approach and tools proposed in this work can be extended to other applications of the EMS in an operational framework. For instance, it can be used for the integration of other intermittent RES, such as wind and wave. However, the study was carried on 1-hour time steps. It will be interesting to test it in real condition with real-time data and a control loop for adjustment and correction.

4.3 Indices de performance complémentaires

Dans la section précédente, 2 indices de performance (le CRPS et l'autonomie) ont été utilisés pour évaluer la relation entre la qualité de la prévision et sa valeur.

Étant donné que le système est connecté au réseau électrique principal et dispose de son propre stockage, il semble intéressant d'étudier les flux d'énergie entre le réseau électrique et le système avec des critères supplémentaires. Ces critères pourraient évaluer l'effet de la stratégie de contrôle sur les composants du système (par exemple le vieillissement du stockage) et dans quelle mesure la qualité de la prévision affecte le fonctionnement du système. Ces critères sont des mesures de la performance technique et de la qualité de la prévision.

4.3.1 Indices de performance technique

Les indices techniques additionnels suivants ont été choisis pour évaluer la qualité de la prévision en fonction de la performance technique du système :

- Le taux d'utilisation du réseau (ϑ^{Grid}) correspond à la quantité d'énergie que le système importe du réseau par rapport à l'énergie consommée par le microréseau :

$$\vartheta^{Grid} = \frac{\sum_{t=1}^T Gr_t | \{Gr_t > 0\}}{\sum_{t=1}^T L_t}; \quad (4.30)$$

- Inversement à l'utilisation du réseau, l'autonomie (ϑ^{auto}), correspondant au ratio entre l'énergie consommée ne provenant pas du réseau électrique et la consommation du microréseau. L'autonomie quantifie la capacité du système à produire l'énergie qu'il consomme :

$$\vartheta^{auto} = 1 - \vartheta^{Grid}; \quad (4.31)$$

- Le taux d'exportation (ϑ^{Export}) a déjà été établi à l'équation 3.22, il quantifie la capacité du système à fournir de l'énergie au réseau électrique ;
- Le nombre de cycles annuels du stockage (Ω^{ESS}) permet d'évaluer le niveau de fatigue du stockage :

$$\Omega^{ESS} \equiv \frac{\sum_{t=1}^T ESS_t | \{\Delta SOC_t > 0\}}{(SOC_{max} - SOC_{min}) \times Ca_{ref}}; \quad (4.32)$$

Dans le tableau 4.8, nous pouvons remarquer qu'il n'y a pas de lien apparent entre le niveau d'autonomie, le taux d'exportation et le vieillissement du stockage (Ω^{ESS}). Les niveaux d'exportation sont très proches quelle que soit la prévision utilisée pour commander le stockage. Par contre, le nombre de cycles indique que l'utilisation de la prévision probabiliste a tendance à solliciter davantage le stockage que la prévision déterministe. Concernant l'autonomie, les niveaux sont assez proches (4.10% d'écart maximal entre les différentes prévisions), ce qui signifie que la consommation d'énergie moyenne provenant du réseau résultant de tous les types de prévision testés est également similaire. Les coûts sont donc étroitement liés aux pénalités qui varient selon les horaires (heures creuses, normales et pointe). Par conséquent, il semble important d'examiner l'appel d'énergie sur le réseau pendant les différentes périodes de tarification.

TABLE 4.8 – Performances techniques annuelles du microréseau

Prévision	Autonomie $\vartheta^{auto}[\%]$	Taux d'exportation $\vartheta^{Export}[\%]$	Utilisation du réseau $\vartheta^{Grid}[\%]$	Nombre de Cycles Ω^{ESS}
Perfect	55.63	44.53	44.37	152.56
Mean(EPS)	55.03	45.28	44.97	149.61
EPS	56.05	43.64	43.95	158.84
LQR	54.69	43.24	45.31	172.34
Climatology	49.15	46.66	50.85	173.42
VD	53.73	43.82	46.27	178.09
Analog	51.95	44.51	48.05	174.21

4.3.2 PLF

Même si le CRPS [57] est utilisé par beaucoup de prévisionnistes comme Lauret et al. [44], Messner et al. [87] ou Le Gal La Salle et al. [82] pour l'évaluation de la qualité des prévisions probabilistes, il n'y a pas de consensus au sein de la communauté des prévisionnistes sur les scores d'évaluations probabilistes à utiliser.

Un autre score de prévision probabiliste très populaire, qui mérite d'être inclus dans cette étude est le **PLF (Pinball Loss Function)** de Koenker and Bassett [88]. Il a notamment été utilisé dans l'estimation de la performance des méthodes de Machine Learning mettant en oeuvre une régression quantile [89]. La compétition **GEFCom (Global Energy Forecasting Competition) 2014** [90] a choisi le PLF comme score pour la comparaison des prévisions probabilistes. Le PLF est une métrique pouvant être interprétée comme étant la précision d'une prévision quantile. Tout comme le CRPS, le PLF est défini strictement positif. Plus le PLF est faible, plus le modèle est supposé performant. L'équation 4.33 suivante donne la formulation du PLF :

$$PLF_q(\hat{y}_{t,q}, y_t) = \begin{cases} (1 - q) \times (\hat{y}_{t,q} - y_t), & y_t < \hat{y}_{t,q} \\ q \times (y_t - \hat{y}_{t,q}), & y_t \geq \hat{y}_{t,q} \end{cases} \quad (4.33)$$

avec $\hat{y}_{t,q}$ la prévision, y_t la mesure et q le quantile cible.

4.4 Relations entre la qualité des prévisions et les performances technico-économiques

Dans la section 4.2.5.3, nous avons essayé d'observer une relation entre la qualité d'une prévision et sa valeur économique pour notre cas d'étude. Dans cette partie, nous essaierons d'établir la relation entre les indices de performance et la qualité d'une prévision probabiliste. Les indices de performance étudiés sont de deux natures :

1. **Le coût** : principal indice de référence qui détermine la valeur économique de la qualité de la prévision,
2. **Indices de fonctionnement technique** : l'utilisation du réseau, l'autonomie, le nombre de cycles et le taux d'exportation.

La relation entre la qualité d'une prévision et le coût de fonctionnement du microréseau dépend de la puissance souscrite, à la base du calcul des pénalités. Pour l'étude de la relation

entre la qualité et la valeur, nous utiliserons les 5 modèles de prévisions probabilistes décrits ci-avant, par contre nous effectuerons une variation progressive de la puissance souscrite.

4.4.1 Coût de fonctionnement et pénalités

Une décomposition de l'énergie prise sur le réseau et notamment celle consommée lors des dépassements de puissance souscrite Gr_{max} permet de mieux comprendre les apports de la prévision probabiliste dans la gestion du microréseau. À l'instar du ratio d'utilisation du réseau (ϑ^{Grid}), l'équation suivante donne le taux de dépassement qui correspond au ratio entre l'énergie provenant des dépassements de puissance sur l'énergie totale consommée par le microréseau :

$$\Lambda^{Grid} = \frac{\sum_{t=1}^T Gr_t - Gr_{max} \mid \{Gr_t \geq Gr_{max}\}}{\sum_{t=1}^T L_t} \tag{4.34}$$

4.4.1.1 Résultats avec la puissance souscrite initiale (1kW)

Tout d'abord, il est important de noter que les plages horaires du tarif heures creuses correspondant uniquement à des heures de nuit. La centrale PV du microréseau ne produit donc jamais en heures creuses. La figure 4.9 montre que la prévision déterministe "Mean(EPS)" a le coût le plus élevé pour les heures de pointe, suivi de l'EPS.




FIGURE 4.9 – Décomposition du coût de fonctionnement du microréseau en fonction des plages horaires tarifaires (Low = heures creuses ; Normal = tarif normal ; Peak = heures de pointe)

Avec une prévision parfaite, le système ne dépasse jamais la limite de puissance pendant les heures de pointe, par contre il fait plus d'appels au réseau aux heures creuses. Les deux meilleures prévisions probabilistes suivent la même logique. Les prévisions issues des modèles Analogie et LQR ont le plus faible taux de dépassement de la puissance souscrite pendant les heures de pointe ($\Lambda^{Grid} = 0.09 - 0.12\%$). Malgré un faible taux de dépassement lors des heures de pointe ($\Lambda^{Grid} = 0.13\%$), les prévisions obtenues avec le modèle VD ont le coût de fonctionnement élevé. Ce coût s'explique par le fait que le modèle VD conduit au taux de dépassement moyen le plus élevé ($\Lambda^{Grid} = 2.81\%$), quelle que soit la tranche tarifaire.

4.4.1.2 Résultats avec une variation de la puissance souscrite

La figure 4.10 montre l'évolution des coûts de fonctionnement (4.10a) du microréseau et des pénalités (4.10b) pour une variation de puissance souscrite allant de $0.5kW$ à $1.5kW$ et en fonction de la qualité de la prévision évaluée par le PLF. Pour des questions de lisibilité, une interpolation a été faite pour établir les figures à partir des 5 valeurs de PLF correspondant respectivement aux 5 prévisions probabilistes considérées dans ce travail.




FIGURE 4.10 – Évolution du coût annuel de fonctionnement du microréseau (a) et des pénalités (b) en fonction du PLF et de la puissance souscrite

Le coût de fonctionnement est principalement composé des pénalités. Il a tendance à augmenter avec le PLF , par contre pour les valeurs maximum du PLF, le coût a tendance à diminuer légèrement. On observe même un maximum proche d'une valeur du PLF de 36. De la même manière, la figure 4.11, montre l'évolution du coût de fonctionnement et des pénalités en fonction du CRPS. Exactement les mêmes observations que pour le PLF en ressortent. Pour comprendre cette dépendance entre les coûts et la qualité, nous proposons de regarder la décomposition du CRPS en fiabilité (4.11a) et résolution (4.11b). Avec des prévisions plus fiables (valeur de la fiabilité < 2), le coût de fonctionnement est plus faible. Pour ce qui est du maximum observé précédemment, il apparaît nettement sur la représentation de la résolution. Il correspond à la climatologie qui par nature est la moins résolue. Le fait de ne disposer que de 6 prévisions pour établir les figures précédentes explique en grande partie les observations décrites précédemment.

4.4.2 Indices de performance techniques

4.4.2.1 Taux d'utilisation du réseau

L'évolution du taux d'utilisation du réseau est divisée en 2 plages différentes, dépendant du niveau de la contrainte sur la puissance souscrite :




FIGURE 4.11 – Évolution du coût annuel de fonctionnement du microréseau (a) et des pénalités (b) en fonction du CRPS et de la puissance souscrite




FIGURE 4.12 – Évolution du coût annuel de fonctionnement du microréseau en fonction de la fiabilité (a) et de la résolution (b) résultant de la décomposition du CRPS

1. **Zone 1** ($Gr_{max} \in [0.5kW; 1kW]$). On observe peu d'accroissement de l'utilisation du réseau avec l'augmentation de la puissance souscrite. Dans cette zone, l'évolution de l'utilisation du réseau présente une faible corrélation avec les scores évaluant la qualité des prévisions ($CRPS$, $CRPS_{spot}$, $Reli$, PLF). Comme pour le coût de fonctionnement, on observe à nouveau un maximum pour les valeurs de CRPS proche de $70W/m^2$ correspondant à la climatologie.
2. **Zone 2** ($Gr_{max} \in [1kW; 1.5kW]$). La présence du pic maximal d'utilisation est à nouveau

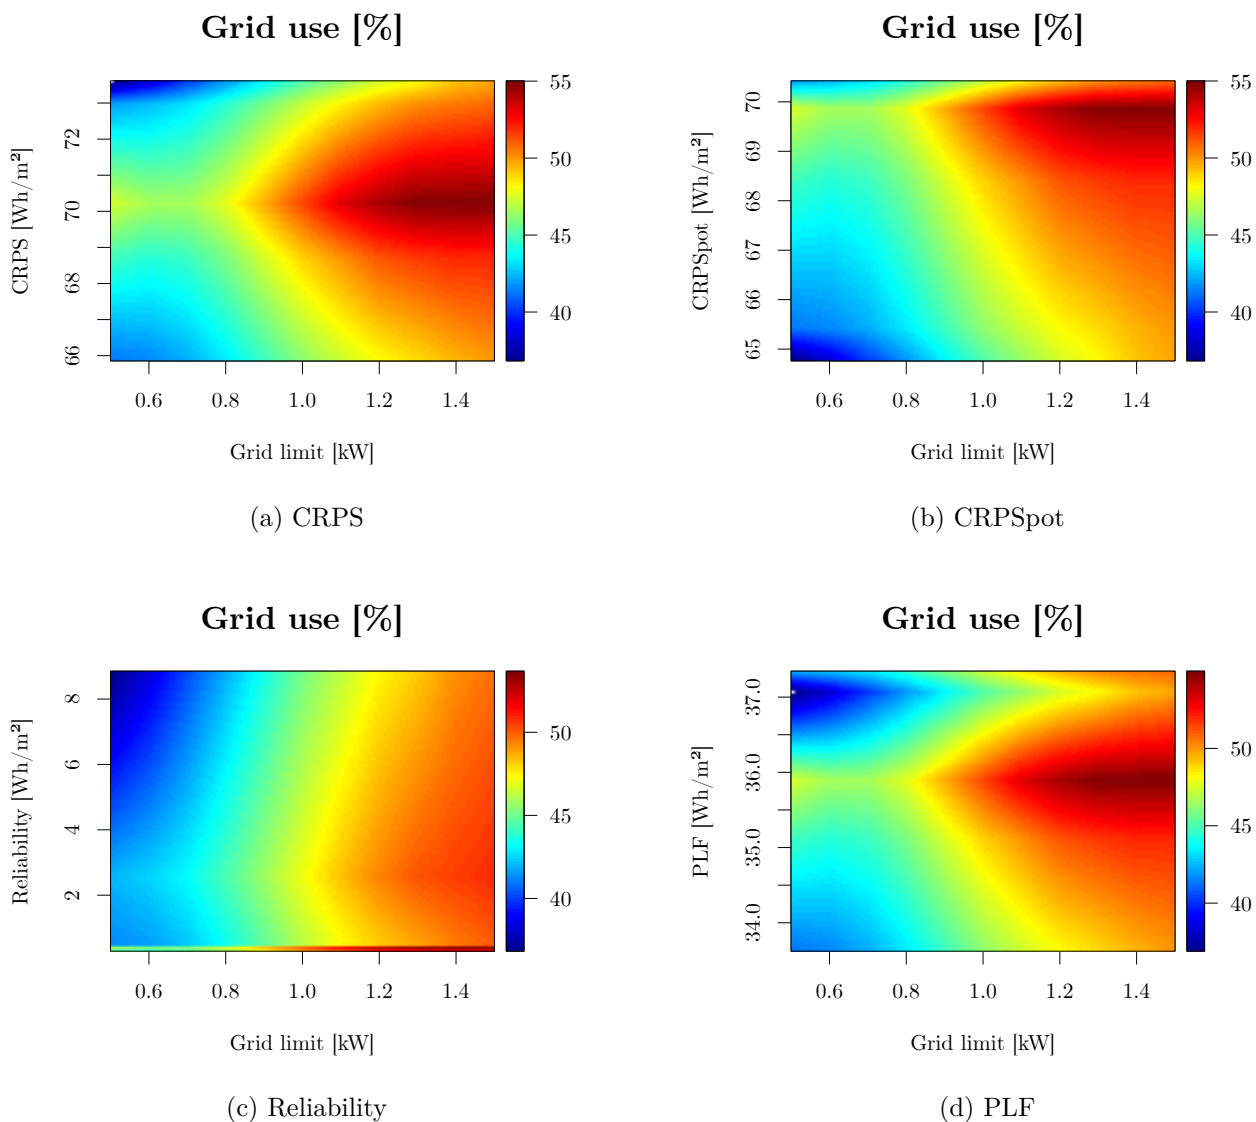


FIGURE 4.13 – Évolution du taux d’utilisation du réseau en fonction du CRPS (a), de sa décomposition en résolution (b) et fiabilité (c) et du PLF

observée dans cette zone. Au-delà d’une puissance souscrite de 1kW, le taux d’utilisation du réseau augmente fortement. En effet, les pénalités diminuant l’optimisation conduit à s’approvisionner à plus forte puissance dans le réseau.

4.4.2.2 Nombre de cycles du stockage

Le vieillissement du stockage est évalué à partir du nombre de cycles qu’il a effectués. Plus le nombre de cycles est élevé, plus le stockage a été sollicité.

Les figures 4.14a-4.14b montrent qu’il n’y a aucune relation apparente entre la sollicitation du stockage et les scores des prévisions. Par contre, à partir d’une certaine puissance souscrite, le stockage est moins sollicité. Ce qui s’explique par l’augmentation du taux d’utilisation du réseau.




FIGURE 4.14 – Cycle du stockage

4.4.2.3 Exportation vers le réseau

Étonnamment, l’augmentation de la puissance souscrite s’accompagne d’un taux d’exportation plus important. En effet, le stockage étant moins utilisé et la production PV qui était dédiée au transfert d’énergie est revendue directement sur le réseau.




FIGURE 4.15 – Injection vers le réseau

Pour conclure sur les 2 indices d’évaluation de la qualité des prévisions probabilistes testées, j’ai une préférence pour le CRPS. En effet, grâce à sa décomposition, nous avons pu expliquer l’évolution des indicateurs technico-économiques du microréseau lors de la variation de la puissance souscrite.

4.5 Conclusion

Dans ce chapitre, nous avons démontré que l'utilisation de prévisions probabilistes offre un gain économique significatif par rapport à l'utilisation de la prévision déterministe. Même l'utilisation de la plus mauvaise prévision probabiliste (EPS) conduit à un coût de fonctionnement du microréseau plus faible que la prévision déterministe. Puisque le coût est lié à la pénalité, l'utilisation de la prévision probabiliste réduit considérablement la pénalité, donc l'appel de puissance au réseau est limité. Dans ce cas précis, la prévision a en quelque sorte effectuée un lissage de l'appel de puissance (côté réseau).

Dans la recherche de métriques pour évaluer les prévisions probabilistes, une tentative d'établissement de relations entre les indicateurs évaluant la valeur technique et économique avec les scores évaluant la qualité des prévisions a été faite. Malgré le fait que le PLF soit très utilisé comme métrique pour évaluer la qualité des prévisions probabilistes éoliennes [91], il ne semble pas adapté pour évaluer la valeur des prévisions probabilistes solaires dans notre cas d'étude. Par contre, un lien existe entre la valeur (coût de fonctionnement) et la qualité évaluée par le CRPS et sa décomposition (surtout la fiabilité). Le coût et le CRPS présentent pour notre cas d'étude une relation presque linéaire. Donc, le CRPS semble être un bon candidat pour être la métrique de référence afin d'évaluer la qualité des prévisions probabilistes.

Bibliographie

- [1] B. Saravanan, S. Das, S. Sikri, and D. P. Kothari, "A solution to the unit commitment problem—a review," *Frontiers in Energy*, vol. 7, no. 2, pp. 223–236, Jun. 2013. [Online]. Available : <https://doi.org/10.1007/s11708-013-0240-3>
- [2] I. Abdou and M. Tkiouat, "Unit Commitment Problem in Electrical Power System : A Literature Review," *International Journal of Electrical and Computer Engineering (IJECE)*, vol. 8, no. 3, p. 1357, Jun. 2018. [Online]. Available : <https://doi.org/10.11591/ijece.v8i3.pp1357-1372>
- [3] R. Jiang, J. Wang, and Y. Guan, "Robust Unit Commitment With Wind Power and Pumped Storage Hydro," *IEEE Transactions on Power Systems*, vol. 27, no. 2, pp. 800–810, May 2012, conference Name : IEEE Transactions on Power Systems. [Online]. Available : <https://doi.org/10.1109/TPWRS.2011.2169817>
- [4] IRENA, *Electricity storage and renewables : Costs and markets to 2030*. Abu Dhabi : International Renewable Energy Agency, Oct. 2017. [Online]. Available : <https://www.irena.org/publications/2017/Oct/Electricity-storage-and-renewables-costs-and-markets>
- [5] Y. Yang, S. Bremner, C. Menictas, and M. Kay, "A Mixed Receding Horizon Control Strategy for Battery Energy Storage System Scheduling in a Hybrid PV and Wind Power Plant with Different Forecast Techniques," *Energies*, vol. 12, no. 12, p. 2326, Jun. 2019. [Online]. Available : <https://doi.org/10.3390/en12122326>
- [6] H. M. Diagne, P. Lauret, and M. David, "Solar irradiation forecasting : state-of-the-art and proposition for future developments for small-scale insular grids,"

- in *WREF 2012-World Renewable Energy Forum*, 2012, p. . [Online]. Available : <https://hal.archives-ouvertes.fr/hal-00918150/>
- [7] J. Antonanzas, N. Osorio, R. Escobar, R. Urraca, F. J. Martinez-de Pison, and F. Antonanzas-Torres, “Review of photovoltaic power forecasting,” *Solar Energy*, vol. 136, pp. 78–111, Oct. 2016. [Online]. Available : <https://doi.org/10.1016/j.solener.2016.06.069>
- [8] S. Sobri, S. Koochi-Kamali, and N. A. Rahim, “Solar photovoltaic generation forecasting methods : A review,” *Energy Conversion and Management*, vol. 156, pp. 459–497, Jan. 2018. [Online]. Available : <https://doi.org/10.1016/j.enconman.2017.11.019>
- [9] A. Tuohy, P. Meibom, E. Denny, and M. O’Malley, “Unit Commitment for Systems With Significant Wind Penetration,” *IEEE Transactions on Power Systems*, vol. 24, no. 2, pp. 592–601, May 2009, conference Name : IEEE Transactions on Power Systems. [Online]. Available : <https://doi.org/10.1109/TPWRS.2009.2016470>
- [10] Y. Riffonneau, S. Bacha, F. Barruel, and S. Ploix, “Optimal Power Flow Management for Grid Connected PV Systems With Batteries,” *IEEE Transactions on Sustainable Energy*, vol. 2, no. 3, pp. 309–320, Jul. 2011. [Online]. Available : <https://doi.org/10.1109/TSTE.2011.2114901>
- [11] S. Grillo, M. Marinelli, S. Massucco, and F. Silvestro, “Optimal Management Strategy of a Battery-Based Storage System to Improve Renewable Energy Integration in Distribution Networks,” *IEEE Transactions on Smart Grid*, vol. 3, no. 2, pp. 950–958, Jun. 2012, conference Name : IEEE Transactions on Smart Grid. [Online]. Available : <https://doi.org/10.1109/TSG.2012.2189984>
- [12] F. Ramahatana and M. David, “Economic optimization of micro-grid operations by dynamic programming with real energy forecast,” in *Journal of Physics : Conference Series*, vol. 1343, Nov. 2019, p. 012067. [Online]. Available : <https://doi.org/10.1088/1742-6596/1343/1/012067>
- [13] S. Alessandrini, L. Delle Monache, S. Sperati, and G. Cervone, “An analog ensemble for short-term probabilistic solar power forecast,” *Applied Energy*, vol. 157, pp. 95–110, Nov. 2015. [Online]. Available : <https://doi.org/10.1016/j.apenergy.2015.08.011>
- [14] R. Bessa, A. Trindade, C. S. Silva, and V. Miranda, “Probabilistic solar power forecasting in smart grids using distributed information,” *International Journal of Electrical Power & Energy Systems*, vol. 72, pp. 16–23, Nov. 2015. [Online]. Available : <https://doi.org/10.1016/j.ijepes.2015.02.006>
- [15] M. David and P. Lauret, “Solar Radiation Probabilistic Forecasting,” in *Wind Field and Solar Radiation Characterization and Forecasting*, R. Perez, Ed. Cham : Springer International Publishing, 2018, pp. 201–227. [Online]. Available : https://doi.org/10.1007/978-3-319-76876-2_9
- [16] Z. Zhou, A. Botterud, J. Wang, R. Bessa, H. Keko, J. Sumaili, and V. Miranda, “Application of probabilistic wind power forecasting in electricity markets,” *Wind Energy*, vol. 16, no. 3, pp. 321–338, 2012. [Online]. Available : <https://doi.org/10.1002/we.1496>

- [17] P. Pinson, H. Madsen, H. A. Nielsen, G. Papaefthymiou, and B. Klöckl, “From probabilistic forecasts to statistical scenarios of short-term wind power production,” *Wind Energy*, vol. 12, no. 1, pp. 51–62, Jan. 2009. [Online]. Available : <https://doi.org/10.1002/we.284>
- [18] W. Alharbi and K. Raahemifar, “Probabilistic coordination of microgrid energy resources operation considering uncertainties,” *Electric Power Systems Research*, vol. 128, pp. 1–10, Nov. 2015. [Online]. Available : <https://doi.org/10.1016/j.epsr.2015.06.010>
- [19] A. Botterud, Z. Zhou, J. Wang, J. Valenzuela, J. Sumaili, R. J. Bessa, H. Keko, and V. Miranda, “Unit commitment and operating reserves with probabilistic wind power forecasts,” in *2011 IEEE Trondheim PowerTech*, Jun. 2011, pp. 1–7. [Online]. Available : <https://doi.org/10.1109/PTC.2011.6019263>
- [20] A. Botterud, Z. Zhou, J. Wang, J. Sumaili, H. Keko, J. Mendes, R. J. Bessa, and V. Miranda, “Demand Dispatch and Probabilistic Wind Power Forecasting in Unit Commitment and Economic Dispatch : A Case Study of Illinois,” *IEEE Transactions on Sustainable Energy*, vol. 4, no. 1, pp. 250–261, Jan. 2013. [Online]. Available : <https://doi.org/10.1109/TSTE.2012.2215631>
- [21] W. El-Baz, P. Tzscheutschler, and U. Wagner, “Day-ahead probabilistic PV generation forecast for buildings energy management systems,” *Solar Energy*, vol. 171, pp. 478–490, Sep. 2018. [Online]. Available : <https://doi.org/10.1016/j.solener.2018.06.100>
- [22] W. El-Baz, M. Seufzger, S. Lutzenberger, P. Tzscheutschler, and U. Wagner, “Impact of probabilistic small-scale photovoltaic generation forecast on energy management systems,” *Solar Energy*, vol. 165, pp. 136–146, May 2018. [Online]. Available : <https://doi.org/10.1016/j.solener.2018.02.069>
- [23] H. Dai, N. Zhang, and Wencong Su, “A Literature Review of Stochastic Programming and Unit Commitment,” *Journal of Power and Energy Engineering*, vol. 03, no. 04, p. 206, Apr. 2015, number : 04 Publisher : Scientific Research Publishing. [Online]. Available : <https://doi.org/10.4236/jpee.2015.34029>
- [24] Q. P. Zheng, J. Wang, and A. L. Liu, “Stochastic Optimization for Unit Commitment—A Review,” *IEEE Transactions on Power Systems*, vol. 30, no. 4, pp. 1913–1924, Jul. 2015, conference Name : IEEE Transactions on Power Systems. [Online]. Available : <https://doi.org/10.1109/TPWRS.2014.2355204>
- [25] Z. Zhou, C. Liu, and A. Botterud, “Stochastic Methods Applied to Power System Operations with Renewable Energy : A Review,” Argonne National Lab. (ANL), Argonne, IL (United States), Tech. Rep. ANL/ESD-16/14, Aug. 2016. [Online]. Available : <https://doi.org/https://doi.org/10.2172/1307655>
- [26] G. Bayraksan and D. P. Morton, “A Sequential Sampling Procedure for Stochastic Programming,” *Operations Research*, vol. 59, no. 4, pp. 898–913, Aug. 2011. [Online]. Available : <https://doi.org/10.1287/opre.1110.0926>
- [27] Y. Nesterov and J. P. Vial, “Confidence level solutions for stochastic programming,” *Automatica*, vol. 44, no. 6, pp. 1559–1568, Jun. 2008. [Online]. Available : <https://doi.org/10.1016/j.automatica.2008.01.017>

- [28] J. F. Restrepo and F. D. Galiana, “Assessing the Yearly Impact of Wind Power Through a New Hybrid Deterministic/Stochastic Unit Commitment,” *IEEE Transactions on Power Systems*, vol. 26, no. 1, pp. 401–410, Feb. 2011. [Online]. Available : <https://doi.org/10.1109/TPWRS.2010.2048345>
- [29] H. Wu, M. Shahidehpour, Z. Li, and W. Tian, “Chance-Constrained Day-Ahead Scheduling in Stochastic Power System Operation,” *IEEE Transactions on Power Systems*, vol. 29, no. 4, pp. 1583–1591, Jul. 2014. [Online]. Available : <https://doi.org/10.1109/TPWRS.2013.2296438>
- [30] A. Alabdulwahab, A. Abusorrah, X. Zhang, and M. Shahidehpour, “Coordination of Interdependent Natural Gas and Electricity Infrastructures for Firming the Variability of Wind Energy in Stochastic Day-Ahead Scheduling,” *IEEE Transactions on Sustainable Energy*, vol. 6, no. 2, pp. 606–615, Apr. 2015. [Online]. Available : <https://doi.org/10.1109/TSTE.2015.2399855>
- [31] A. Turk, Q. Wu, M. Zhang, and J. Østergaard, “Day-ahead stochastic scheduling of integrated multi-energy system for flexibility synergy and uncertainty balancing,” *Energy*, vol. 196, p. 117130, Apr. 2020. [Online]. Available : <https://doi.org/10.1016/j.energy.2020.117130>
- [32] J. Linderoth, A. Shapiro, and S. Wright, “The empirical behavior of sampling methods for stochastic programming,” *Annals of Operations Research*, vol. 142, no. 1, pp. 215–241, Feb. 2006. [Online]. Available : <https://doi.org/10.1007/s10479-006-6169-8>
- [33] M. Kaut, “Evaluation of scenario-generation methods for stochastic programming,” *Humboldt-Universität zu Berlin, Mathematisch-Naturwissenschaftliche Fakultät*, p. 14, 2003. [Online]. Available : <https://edoc.hu-berlin.de/bitstream/handle/18452/8948/100.pdf?sequence=1>
- [34] A. Shapiro and A. Nemirovski, “On Complexity of Stochastic Programming Problems,” in *Continuous Optimization : Current Trends and Modern Applications*, ser. Applied Optimization, V. Jeyakumar and A. Rubinov, Eds. Boston, MA : Springer US, 2005, pp. 111–146. [Online]. Available : https://doi.org/10.1007/0-387-26771-9_4
- [35] W. B. Powell, “Clearing the Jungle of Stochastic Optimization,” in *Bridging Data and Decisions*, A. M. Newman, J. Leung, J. C. Smith, and H. J. Greenberg, Eds. INFORMS, Sep. 2014, pp. 109–137. [Online]. Available : <https://doi.org/10.1287/educ.2014.0128>
- [36] P. G. Lowery, “Generating Unit Commitment by Dynamic Programming,” *IEEE Transactions on Power Apparatus and Systems*, vol. PAS-85, no. 5, pp. 422–426, May 1966. [Online]. Available : <https://doi.org/10.1109/TPAS.1966.291679>
- [37] W. L. Snyder, H. D. Powell, and J. C. Rayburn, “Dynamic Programming Approach to Unit Commitment,” *IEEE Transactions on Power Systems*, vol. 2, no. 2, pp. 339–348, May 1987. [Online]. Available : <https://doi.org/10.1109/TPWRS.1987.4335130>
- [38] Z. Ouyang and S. Shahidehpour, “An intelligent dynamic programming for unit commitment application,” *IEEE Transactions on Power Systems*, vol. 6, no. 3, pp. 1203–1209, Aug. 1991. [Online]. Available : <https://doi.org/10.1109/59.119267>

- [39] W. L. Winston, *Operations Research : Applications and Algorithms*, 4th ed. Belmont, Calif. : Duxbury Press, Jul. 2003. [Online]. Available : <https://itslearningakarmazyan.files.wordpress.com/2015/09/operation-research-applications-and-algorithms.pdf>
- [40] A. Lenoir and F. Garde, “Tropical NZEB,” *High Performing Building Journal*, no. Summer, pp. 43–55, 2012. [Online]. Available : <https://hal.archives-ouvertes.fr/hal-00918159/>
- [41] F. Ramahatana, J. Vigneron, S. Simpoire, J. Le Gal La salle, P. Lauret, and M. David, “EnerPos simulation data,” Sep. 2020, publisher : Zenodo Version Number : 1. [Online]. Available : <https://doi.org/10.5281/zenodo.4028056>
- [42] M. Leutbecher and T. N. Palmer, “Ensemble forecasting,” *Journal of Computational Physics*, vol. 227, no. 7, pp. 3515–3539, Mar. 2008. [Online]. Available : <https://doi.org/10.1016/j.jcp.2007.02.014>
- [43] A. Persson and F. Grazzini, “ECMWF Forecast User Guide,” ECMWF, User manual, May 2018. [Online]. Available : <https://confluence.ecmwf.int/display/FUG/Forecast+User+Guide>
- [44] P. Lauret, M. David, and P. Pinson, “Verification of solar irradiance probabilistic forecasts,” *Solar Energy*, vol. 194, pp. 254–271, Dec. 2019. [Online]. Available : <https://doi.org/10.1016/j.solener.2019.10.041>
- [45] B. Espinar, L. Wald, P. Blanc, C. Hoyer-Klick, Marion Schroedter-Homscheidt, and T. Wanderer, “Report on the harmonization and qualification of meteorological data,” Project ENDORSE, Armines, Paris, Tech. Rep. 1, Aug. 2011.
- [46] M. Lefèvre, A. Oumbe, P. Blanc, B. Espinar, B. Gschwind, Z. Qu, L. Wald, M. S. Homscheidt, C. Hoyer-Klick, and A. Arola, “McClear : a new model estimating downwelling solar radiation at ground level in clear-sky conditions,” *Atmospheric Measurement Techniques*, vol. 6, pp. 2403–2418, 2013. [Online]. Available : <https://doi.org/10.5194/amt-6-2403-2013>
- [47] T. Gneiting, A. E. Raftery, A. H. Westveld III, and T. Goldman, “Calibrated probabilistic forecasting using ensemble model output statistics and minimum CRPS estimation,” *Monthly Weather Review*, vol. 133, no. 5, pp. 1098–1118, 2005. [Online]. Available : <https://doi.org/10.1175/MWR2904.1>
- [48] T. M. Hamill, “Interpretation of Rank Histograms for Verifying Ensemble Forecasts,” *Monthly Weather Review*, vol. 129, no. 3, pp. 550–560, Mar. 2001, publisher : American Meteorological Society Section : Monthly Weather Review. [Online]. Available : [https://doi.org/10.1175/1520-0493\(2001\)129<0550:IORHFV>2.0.CO;2](https://doi.org/10.1175/1520-0493(2001)129<0550:IORHFV>2.0.CO;2)
- [49] L. D. Monache, F. A. Eckel, D. L. Rife, B. Nagarajan, and K. Searight, “Probabilistic Weather Prediction with an Analog Ensemble,” *Monthly Weather Review*, vol. 141, no. 10, pp. 3498–3516, Oct. 2013, publisher : American Meteorological Society Section : Monthly Weather Review. [Online]. Available : <https://doi.org/10.1175/MWR-D-12-00281.1>

- [50] T. M. Hamill and J. S. Whitaker, “Probabilistic Quantitative Precipitation Forecasts Based on Reforecast Analogs : Theory and Application,” *Monthly Weather Review*, vol. 134, no. 11, pp. 3209–3229, Nov. 2006, publisher : American Meteorological Society Section : Monthly Weather Review. [Online]. Available : <https://doi.org/10.1175/MWR3237.1>
- [51] J. Le Gal La Salle, J. Badosa, M. David, P. Pinson, and P. Lauret, “Added-value of ensemble prediction system on the quality of solar irradiance probabilistic forecasts,” *Renewable Energy*, vol. 162, pp. 1321–1339, Dec. 2020. [Online]. Available : <https://doi.org/10.1016/j.renene.2020.07.042>
- [52] A. H. Murphy, “What Is a Good Forecast? An Essay on the Nature of Goodness in Weather Forecasting,” *Weather and Forecasting*, vol. 8, no. 2, pp. 281–293, Jun. 1993, publisher : American Meteorological Society Section : Weather and Forecasting. [Online]. Available : [https://doi.org/10.1175/1520-0434\(1993\)008<0281:WIAGFA>2.0.CO;2](https://doi.org/10.1175/1520-0434(1993)008<0281:WIAGFA>2.0.CO;2)
- [53] C. F. M. Coimbra, J. Kleissl, and R. Marquez, “Overview of Solar-Forecasting Methods and a Metric for Accuracy Evaluation,” in *Solar Energy Forecasting and Resource Assessment*, J. Kleissl, Ed. Boston : Academic Press, Jan. 2013, pp. 171–194. [Online]. Available : <https://doi.org/10.1016/B978-0-12-397177-7.00008-5>
- [54] T. Stoffel, D. Renne, D. Myers, S. Wilcox, M. Sengupta, R. George, and C. Turchi, “Concentrating Solar Power : Best Practices Handbook for the Collection and Use of Solar Resource Data (CSP),” National Renewable Energy Lab. (NREL), Golden, CO (United States), Tech. Rep. NREL/TP-550-47465, Sep. 2010. [Online]. Available : <https://doi.org/10.2172/989017>
- [55] M. Sengupta, A. Habte, S. Wilbert, C. Gueymard, and J. Remund, “Best Practices Handbook for the Collection and Use of Solar Resource Data for Solar Energy Applications : Third Edition,” National Renewable Energy Lab. (NREL), Golden, CO (United States), Tech. Rep. NREL/TP-5D00-77635, Apr. 2021. [Online]. Available : <https://doi.org/10.2172/1778700>
- [56] P. Pinson, H. A. Nielsen, J. K. Møller, H. Madsen, and G. N. Kariniotakis, “Non-parametric probabilistic forecasts of wind power : required properties and evaluation,” *Wind Energy*, vol. 10, no. 6, pp. 497–516, 2007, _eprint : <https://onlinelibrary.wiley.com/doi/pdf/10.1002/we.230>. [Online]. Available : <https://doi.org/10.1002/we.230>
- [57] H. Hersbach, “Decomposition of the Continuous Ranked Probability Score for Ensemble Prediction Systems,” *Weather and Forecasting*, vol. 15, no. 5, pp. 559–570, Oct. 2000, publisher : American Meteorological Society Section : Weather and Forecasting. [Online]. Available : [https://doi.org/10.1175/1520-0434\(2000\)015<0559:DOTCRP>2.0.CO;2](https://doi.org/10.1175/1520-0434(2000)015<0559:DOTCRP>2.0.CO;2)
- [58] M. E. Gilleland, *Package ‘verification’*. CRAN, 2015.
- [59] IRENA, “Electricity storage and renewables : Costs and markets to 2030, Cost-of-service tool,” Abu Dhabi, Oct. 2017. [Online]. Available : <https://www.irena.org/publications/2017/Oct/Electricity-storage-and-renewables-costs-and-markets>

- [60] IRENA, *Renewable power generation costs in 2018*. Abu Dhabi. : International Renewable Energy Agency, May 2019. [Online]. Available : <https://www.irena.org/publications/2019/May/Renewable-power-generation-costs-in-2018>
- [61] EDF Reunion, “Tarifs et catalogues de prestations,” Apr. 2018. [Online]. Available : <https://reunion.edf.fr/entreprises/decouvrir-nos-tarifs-et-services/tarifs-et-catalogues-de-prestations-2>
- [62] A. Dimeas and N. Hatziargyriou, “Operation of a multiagent system for microgrid control,” *IEEE Transactions on Power Systems*, vol. 20, no. 3, pp. 1447–1455, Aug. 2005. [Online]. Available : <https://doi.org/10.1109/TPWRS.2005.852060>
- [63] T. Logenthiran, D. Srinivasan, A. M. Khambadkone, and H. N. Aung, “Multiagent System for Real-Time Operation of a Microgrid in Real-Time Digital Simulator,” *IEEE Transactions on Smart Grid*, vol. 3, no. 2, pp. 925–933, Jun. 2012. [Online]. Available : <https://doi.org/10.1109/TSG.2012.2189028>
- [64] C.-X. Dou, X.-B. Jia, H. Li, and M.-F. Lv, “Multi-agent System Based Energy Management of Microgrid on Day-ahead Market Transaction,” *Electric Power Components and Systems*, vol. 44, no. 12, pp. 1330–1344, Jul. 2016. [Online]. Available : <https://doi.org/10.1080/15325008.2016.1158216>
- [65] J. Achara, M. Mohiuddin, W. Saab, R. Rudnik, and J.-Y. Le Boudec, “T-RECS : A software testbed for multi-agent real-time control of electric grids,” in *2017 22nd IEEE International Conference on Emerging Technologies and Factory Automation (ETFA)*. Limassol : IEEE, Sep. 2017, pp. 1–4. [Online]. Available : <https://doi.org/10.1109/ETFA.2017.8247706>
- [66] M. Zachar and P. Daoutidis, “Nonlinear Economic Model Predictive Control for Microgrid Dispatch,” *IFAC-PapersOnLine*, vol. 49, no. 18, pp. 778–783, Jan. 2016. [Online]. Available : <https://doi.org/10.1016/j.ifacol.2016.10.260>
- [67] G. Bruni, S. Cordiner, V. Mulone, V. Sinisi, and F. Spagnolo, “Energy management in a domestic microgrid by means of model predictive controllers,” *Energy*, vol. 108, pp. 119–131, Aug. 2016. [Online]. Available : <https://doi.org/10.1016/j.energy.2015.08.004>
- [68] M. Arnold and G. Andersson, “Model predictive control of energy storage including uncertain forecasts,” in *Power Systems Computation Conference (PSCC), Stockholm, Sweden*, vol. 23. Citeseer, 2011, pp. 24–29. [Online]. Available : <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.722.6663&rep=rep1&type=pdf>
- [69] B. Zhao, Y. Shi, X. Dong, W. Luan, and J. Bornemann, “Short-Term Operation Scheduling in Renewable-Powered Microgrids : A Duality-Based Approach,” *IEEE Transactions on Sustainable Energy*, vol. 5, no. 1, pp. 209–217, Jan. 2014. [Online]. Available : <https://doi.org/10.1109/TSTE.2013.2279837>
- [70] E. C. Umeozor and M. Trifkovic, “Operational scheduling of microgrids via parametric programming,” *Applied Energy*, vol. 180, pp. 672–681, Oct. 2016. [Online]. Available : <https://doi.org/10.1016/j.apenergy.2016.08.009>

- [71] M. Y. Nguyen, Y. T. Yoon, and N. H. Choi, “Dynamic programming formulation of Micro-Grid operation with heat and electricity constraints,” in *2009 Transmission Distribution Conference Exposition : Asia and Pacific*, Oct. 2009, pp. 1–4. [Online]. Available : <https://doi.org/10.1109/TD-ASIA.2009.5356870>
- [72] N. A. Luu, Q.-T. Tran, and S. Bacha, “Optimal energy management for an island microgrid by using dynamic programming method,” in *2015 IEEE Eindhoven PowerTech*, Jun. 2015, pp. 1–6. [Online]. Available : <https://doi.org/10.1109/PTC.2015.7232678>
- [73] M. V. F. Pereira and L. M. V. G. Pinto, “Multi-stage stochastic optimization applied to energy planning,” *Mathematical Programming*, vol. 52, no. 1, pp. 359–375, May 1991. [Online]. Available : <https://doi.org/10.1007/BF01582895>
- [74] D. P. Bertsekas, *Dynamic programming and optimal control*, 4th ed., ser. Athena scientific optimization and computation series. Belmont, Massachusetts : Athena scientific, 1995, vol. 1. [Online]. Available : <http://athenasc.com/dpbook.html>
- [75] ———, *Dynamic Programming and Stochastic Control*, ser. Mathematics in Science and Engineering. New York, San Francisco and London : Academic Press, Nov. 1976, no. 125.
- [76] W. B. Powell, *Approximate Dynamic Programming : Solving the Curses of Dimensionality*. John Wiley & Sons, Oct. 2011. [Online]. Available : <https://doi.org/10.1002/9781118029176>
- [77] F. Borghesan, “Approximate dynamic programming techniques for microgrid energy management,” PhD Thesis, Polytechnic University of Milan, Milan, 2013.
- [78] M. L. Puterman, *Markov Decision Processes : Discrete Stochastic Dynamic Programming*, ser. Wiley Series in Probability and Statistics. John Wiley & Sons, Ltd, Apr. 1994. [Online]. Available : <https://doi.org/10.1002/9780470316887>
- [79] B. V. Cherkassky, A. V. Goldberg, and T. Radzik, “Shortest paths algorithms : Theory and experimental evaluation,” *Mathematical Programming*, vol. 73, no. 2, pp. 129–174, May 1996, 1158. [Online]. Available : <https://doi.org/10.1007/BF02592101>
- [80] S. Chand, V. N. Hsu, and S. Sethi, “Forecast, Solution, and Rolling Horizons in Operations Management Problems : A Classified Bibliography,” *Manufacturing & Service Operations Management*, vol. 4, no. 1, pp. 25–43, Jan. 2002. [Online]. Available : <https://doi.org/10.1287/msom.4.1.25.287>
- [81] R. Kumar, M. J. Wenzel, M. J. Ellis, M. N. ElBsat, K. H. Drees, and V. M. Zavala, “A Stochastic Dual Dynamic Programming Framework for Multiscale MPC,” *IFAC-PapersOnLine*, vol. 51, no. 20, pp. 493–498, 2018. [Online]. Available : <https://doi.org/10.1016/j.ifacol.2018.11.041>
- [82] J. Le Gal La Salle, M. David, and P. Lauret, “A new climatology reference model to benchmark probabilistic solar forecasts,” *Solar Energy*, vol. 223, pp. 398–414, Jul. 2021. [Online]. Available : <https://doi.org/10.1016/j.solener.2021.05.037>

- [83] A. Shapiro, “Monte Carlo Sampling Methods,” in *Handbooks in Operations Research and Management Science*. Elsevier, 2003, vol. 10, pp. 353–425. [Online]. Available : [https://doi.org/10.1016/S0927-0507\(03\)10006-0](https://doi.org/10.1016/S0927-0507(03)10006-0)
- [84] O. Dowson and L. Kapelevich, “SDDP.jl : A Julia Package for Stochastic Dual Dynamic Programming,” *INFORMS Journal on Computing*, p. ijoc.2020.0987, Aug. 2020. [Online]. Available : <https://doi.org/10.1287/ijoc.2020.0987>
- [85] I. Dunning, J. Huchette, and M. Lubin, “JuMP : A Modeling Language for Mathematical Optimization,” *SIAM Review*, vol. 59, no. 2, pp. 295–320, Jan. 2017, publisher : Society for Industrial and Applied Mathematics. [Online]. Available : <https://doi.org/10.1137/15M1020575>
- [86] S. Simpure, “Modélisation, simulation et optimisation d’un système de stockage à air comprimé couplé à un bâtiment et à une production photovoltaïque,” Ph.D. dissertation, Université de La Réunion, Sep. 2018. [Online]. Available : <https://tel.archives-ouvertes.fr/tel-02059339/document>
- [87] J. W. Messner, P. Pinson, J. Browell, M. B. Bjerregård, and I. Schicker, “Evaluation of wind power forecasts—An up-to-date view,” *Wind Energy*, vol. 23, no. 6, pp. 1461–1481, 2020. [Online]. Available : <https://doi.org/10.1002/we.2497>
- [88] R. Koenker and G. Bassett, Jr., “Regression Quantiles,” *Econometrica*, vol. 46, no. 1, pp. 33–50, Jan. 1978. [Online]. Available : <https://doi.org/10.2307/1913643>
- [89] I. Steinwart and A. Christmann, “Estimating conditional quantiles with the help of the pinball loss,” *Bernoulli*, vol. 17, no. 1, pp. 211–225, Feb. 2011, publisher : Bernoulli Society for Mathematical Statistics and Probability. [Online]. Available : <https://doi.org/10.3150/10-BEJ267>
- [90] T. Hong and S. Fan, “Probabilistic electric load forecasting : A tutorial review,” *International Journal of Forecasting*, vol. 32, no. 3, pp. 914–938, Jul. 2016. [Online]. Available : <https://doi.org/10.1016/j.ijforecast.2015.11.011>
- [91] T. Hong, P. Pinson, S. Fan, H. Zareipour, A. Troccoli, and R. J. Hyndman, “Probabilistic energy forecasting : Global Energy Forecasting Competition 2014 and beyond,” *International Journal of Forecasting*, vol. 32, no. 3, pp. 896–913, Jul. 2016. [Online]. Available : <https://doi.org/10.1016/j.ijforecast.2016.02.001>

CHAPITRE 5

Conclusions et perspectives

I have approximate answers and possible beliefs and different degrees of certainty about different things, but I'm not absolutely sure about anything. And there are many things I don't know anything about. It doesn't frighten me!

Richard Feynman

Sommaire

5.1 Conclusion générale	167
5.2 Limitations de l'étude	168
5.3 Perspectives	169

5.1 Conclusion générale

LE but initial de cette thèse était d'évaluer l'apport des prévisions probabilistes de production d'EnR intermittentes dans la gestion des flux d'énergie d'un microréseau électrique. Les résultats obtenus suggèrent que l'utilisation de prévisions probabilistes améliore les performances et offre un gain économique sur le coût d'exploitation du microréseau.

Dans un premier temps, nous nous sommes concentrés sur les aspects théoriques et les capacités offertes par l'optimisation stochastique. Cette étude de la littérature a permis d'identifier la DP comme étant un des plus puissants algorithmes d'optimisation permettant d'atteindre un optimum global pour des problèmes qui peuvent ne pas être linéaires. Nous avons choisi de combiner la DP avec une approche de «*rolling horizon*» pour optimiser le contrôle d'un système dynamique. Le noyau de cette thèse est donc une combinaison de l'optimisation par DP avec l'utilisation de prévisions probabilistes EnR intermittentes.

Le cas d'étude utilisé pour implémenter la méthode proposée est le contrôle d'un microréseau constitué d'un bâtiment NetZeb à but éducationnel (EnerPos) avec un système PV intégré en toiture et un stockage d'énergie. L'objectif de l'optimisation est la planification du fonctionnement du stockage (charge / décharge/ niveau de charge).

Dans un deuxième temps, une prévision déterministe a été utilisée et comparée avec des règles heuristiques de contrôle. Cette implémentation a permis de mettre en évidence que l'utilisation d'une fenêtre de prévision plus longue dans le processus d'optimisation conduit à un

coût de fonctionnement du microréseau plus faible. Au-delà de compenser les erreurs de la prévision, l'anticipation résultant de la connaissance du futur permet d'optimiser les transferts d'énergie. Cette potentialité est difficile à mettre en oeuvre avec des heuristiques, car elles ne disposent pas d'information sur le futur. Pour ce cas d'étude, l'utilisation de la prévision est économiquement avantageuse par rapport aux règles heuristiques.

Une autre contribution de cette thèse est la proposition d'une méthode d'intégration directe des prévisions probabilistes dans l'optimisation du fonctionnement d'un système énergétique. La prévision utilisée est une prévision opérationnelle fournie par [ECMWF](#). À nouveau, un «*rolling horizon*» est utilisée. La méthode proposée combine la DP probabiliste avec des prévisions probabilistes de production PV. Cette méthode permet un gain économique important par rapport à l'utilisation de prévisions déterministes, même dans le cas de la prévision probabiliste la plus mauvaise.

Le dernier enjeu de cette thèse est de mettre en évidence l'existence de relations entre la qualité d'une prévision et sa valeur ajoutée pour les utilisateurs. Cette recherche a été menée autant pour le cas déterministe que probabiliste avec des indicateurs appropriés. Plus précisément, la valeur des prévisions a été évaluée par le gain obtenu sur le coût de fonctionnement du microréseau. Pour notre cas d'étude et l'utilisation d'une prévision déterministe, le [MBE](#) a présenté une corrélation marquée avec la variation du coût. Pour le cas probabiliste, le [CRPS](#) semble présenter une relation presque linéaire avec le coût. D'autre part, sa décomposition en fiabilité (*Reli*) et résolution (*CRPS_{spot}*) permet de mieux comprendre quelles sont les caractéristiques à améliorer dans la qualité d'une prévision probabiliste.

5.2 Limitations de l'étude

L'étude a pour but de présenter une méthode d'utilisation des prévisions probabilistes ainsi que leurs potentielles. Il est à noter que la prévision de consommation n'a pas été prise en compte afin de faciliter la compréhension de la méthode et de démontrer l'efficacité de l'utilisation des prévisions probabilistes de production PV. Mais, dans la réalité, la prévision de la consommation doit être intégrée.

Pour les microréseaux à venir, l'[IRENA](#) [1] préconise que la consommation nette (*Net-Load*) soit utilisée comme prévisions afin d'augmenter la visibilité des variations du côté de la demande. Comme il a été présenté dans la figure 3.10 (section 3.2.5.3), les erreurs de prévision sur le *Net-Load* peuvent être corrélées aux coûts de fonctionnement. Tout comme Wilks [2], notre étude montre qu'il est difficile d'établir une relation claire entre les métriques évaluant la qualité des prévisions probabilistes existantes et leur valeur. Même si ce travail met en avant quelques pistes pour lier la valeur à la qualité des prévisions probabilistes, il est encore nécessaire d'approfondir le sujet.

Enfin, uniquement 1 seul site et 5 modèles de prévisions probabilistes ont été utilisés pour tester la méthode proposée. Afin de valider les résultats obtenus dans notre cas d'étude, il semble nécessaire d'élargir le spectre des conditions d'implémentation de notre méthode. Par exemple en utilisant d'autres modèles de prévision, d'autres types de microréseaux, dans des régions climatiques différentes, etc.

5.3 Perspectives

Dans cette thèse, la **SDDP** a été utilisée pour résoudre une formulation linéaire du problème d'optimisation de la planification d'**UC**. La solution optimale a été obtenue en mode *Off-line* à partir de la distribution climatologique de la production PV. Ensuite, en mode *Online*, la persistance est utilisée pour déterminer les décisions à prendre. Cette approche semble avoir un grand potentiel et elle est très compétitive par rapport à la méthode proposée. Il serait donc intéressant de proposer une implémentation de la SDDP intégrant des prévisions probabilistes opérationnelles dans les modes *Off-line* et *Online*.

Pour ce travail, les planifications et contrôles ont été établis avec un pas de temps horaire. Afin de reproduire la réalité avec plus de fidélité, il est nécessaire de mettre en place un système fonctionnant en temps réel avec une boucle de régulation (par exemple de type **MPC**). Un pas de temps largement inférieur à l'heure devra donc être utilisé.

Parallèlement, la méthode d'intégration de la prévision probabiliste proposée est une méthode indépendante du système étudié. La fonction coût ainsi que le système pourraient être différents. Une réplique de la méthode proposée sur d'autres types de systèmes serait intéressante. Par exemple, ces systèmes pourraient être des microréseaux ou des réseaux intégrant un stockage de nature différente (stockage à air comprimé, station de transfert d'énergie par pompage ou autre). La finalité d'utilisation du stockage pourrait, elle aussi, être différente. Par exemple, il pourrait servir pour la compensation des charges ou pour le lissage de puissance d'EnR intermittentes. Enfin, la méthode proposée pourrait être aussi testée pour optimiser les gains des opérateurs exploitants des EnR intermittentes sur le marché de l'énergie.

Bibliographie

- [1] IRENA, "Market integration of distributed energy resources," dans *Market Design : Innovation Landscape briefs*. Abu Dhabi : International Renewable Energy Agency, Juin 2019. [En ligne]. Disponible : <https://www.irena.org/publications/2019/Jun/Market-Design-Innovation-Landscape-briefs>
- [2] D. S. Wilks, "A skill score based on economic value for probability forecasts," *Meteorological Applications*, vol. 8, n° 2, p. 209–219, Juin 2001. [En ligne]. Disponible : <https://doi.org/10.1017/S1350482701002092>

Liste des figures

1.1	Schéma de principe d'un réseau isolé avec un seul générateur	2
1.2	Schéma de principe d'un réseau interconnecté	3
1.3	Investissement mondial pour les énergies renouvelables (IRENA et CPI [3])	4
1.4	Schéma de principe d'un réseau interconnecté intégrant une production distribuée d'EnR	5
1.5	Structure d'un microréseau	7
1.6	Exemple de Power-to-X pour le stockage d'EnR et la capture de carbone proposé par Buffo et al. [25]	8
1.7	Intégration des EnR intermittents dans les usages finaux grâce au Power-to-X (hydrogène) proposée par l'IRENA [26]	9
1.8	Classification des systèmes de stockage d'énergie électrique selon la forme d'énergie par le Fraunhofer ISE (Institute for Solar Energy Systems) [29]	10
1.9	Domaine d'application des systèmes de stockage selon l'énergie stockée, la puissance fournie ainsi que de la durée d'utilisation (indiquée en bleu) (Luo et al. [34], Milligan et al. [48])	13
1.10	Utilisation des prévisions dans les réseaux d'énergie selon l'acteur	16
1.11	Nombre de publications par an sur les prévisions (charge, prix, énergie solaire et énergie éolienne) selon Hong et al. [79]	18
1.12	Classification des modèles de prévision du rayonnement solaire en fonction de la résolution temporelle et spatiale (Diagne et al. [83])	22
1.13	Maturité des techniques de prévisions (Hong et al. [80])	24
1.14	Répartition des unités de production d'énergie électrique en puissance en 2019 pour l'île de la Réunion (Observatoire Énergie Réunion [122])	26
1.15	Méthodologie de conception d'un NetZeb en zone intertropicale	29
1.16	Consommation agrégée du bâtiment EnerPos pour l'année 2010 au pas de temps de la minute	30
1.17	Production du champ PV intégré en sur-toiture pour l'année 2010 au pas de temps de la minute	31
1.18	Fréquence de la durée consécutive de charge nette négative en minutes	31
1.19	Configuration du microréseau étudié	32
2.1	Quelques références temporelles sur la prise en compte des EnR intermittentes dans les problèmes de planification d'UC	51
2.2	Modèles UC prenant en compte la forte pénétration des EnR intermittentes suivant les travaux d'Abujarad et al. [7]	52

2.3 Les deux méthodes de prises en compte de la production des EnR intermittentes pour l’optimisation des problèmes de planification d’UC dans les réseaux électriques. 52

2.4 Évolution des prévisions des EnR intermittentes au cours des 20 dernières années 55

2.5 Schéma de fonctionnement d’un MPC générant 3 scénarios pour chaque pas de temps futurs. Les S_i^j correspondent aux états du système à l’instant initial ($i = 0$) et pour les j scénarios représentant les futurs possibles ($i > 0$). A_t et B_t sont respectivement les matrices de covariances et les matrices d’incertitudes utilisées pour la construction de l’arbre 57

2.6 Fonctionnement du MPC pour une optimisation de t à $t + 3$, à chaque pas de temps il exécute une optimisation identique à celle de la figure 2.5 58

2.7 Exemple d’arbre de scénarios : 5 scénarios avec 10 noeuds pour une optimisation multi-étape (4 étapes) 59

2.8 Génération et utilisation de prévisions probabilistes d’EnR intermittentes dans les problèmes d’optimisation (Li et Zhang [66]) 61

2.9 Principe de récursion de la DP de l’étape $T \rightarrow 1$ 63

2.10 Schéma de principe du problème du plus court chemin 64

2.11 Vue d’ensemble des différentes familles de programmation dynamique (DP) 67

2.12 Système à 2 états possibles avec les probabilités de changement d’état, par exemple, on a une probabilité de $p = 0.4$ de passer de l’état S_1 vers l’état S_2 . . . 68

2.13 Les différentes familles de programmation stochastique (SP) tel que définit par Ruszczyński et Shapiro [5] et Birge et Louveaux [91] 70

2.14 Solution du problème d’optimisation posé par l’équation 2.16 dans les cas déterministe (a) et probabiliste (b) [93] 74

2.15 Estimation de l’espérance du coût à partir de 2 scénarios ($\xi_{j=1,2} = \{20, 80\}$) dont les probabilités sont différentes. 75

2.16 Politique de contrôle d’un stockage couplé à un houle-générateur sous la forme d’une table de contrôle : la puissance à injecter (P_{Grid}) est déterminée à partir de la vitesse et de l’accélération du vent pour 7 niveaux d’énergie contenue dans le stockage [17] 78

2.17 Décomposition du problème SDDP [15] en 2 étages avec M scénarios générés . . . 84

3.1 Typical week of hourly load forecasts 103

3.2 Microgrid architecture 105

3.3 Possible trajectory of the SOC 107

3.4 Rule based management 109

3.5 Overview of the annual consumption and production of the EnerPos Building . . 111

3.6 Week of PV production and building consumption 112

3.7 Rule-based management (without control) 113

3.8 Real forecast scheduling for day 1 113

3.9 Impact of forecast horizon window size on the optimal cost of operation 114

3.10 Relationship between hourly forecast error and operation cost of the microgrid . 115

4.1 Rank histograms of the five probabilistic forecasts. For sake of clarity, the relative frequency axis has been bound to 3.2% 137

4.2 Microgrid energy flows and control diagram 139

4.3 Example of the microgrid operation when using the deterministic forecast to generate the optimal schedule of the ESS. 144

4.4 Example of the microgrid operation when using the LQR probabilistic forecast to generate the optimal schedule of the ESS. The grey-scale color shows the quantiles given by the probabilistic forecast. 144

4.5 Visual representation of inverter efficiency used for with the PDP (blue line) and with the SDDP (red dashed line) 146

4.6 Decomposition by time-of-use rates of the annual cost of the microgrid operation for the PDP results 147

4.7 Decomposition of the annual cost of the microgrid operation by type of expense 148

4.8 Annual operating cost as a function of the CRPS and its two components, reliability and resolution (CRPSpot) 149

4.9 Décomposition du coût de fonctionnement du microréseau en fonction des plages horaires tarifaires (Low = heures creuses ; Normal = tarif normal ; Peak = heures de pointe) 153

4.10 Évolution du coût annuel de fonctionnement du microréseau (a) et des pénalités (b) en fonction du PLF et de la puissance souscrite 154

4.11 Évolution du coût annuel de fonctionnement du microréseau (a) et des pénalités (b) en fonction du CRPS et de la puissance souscrite 155

4.12 Évolution du coût annuel de fonctionnement du microréseau en fonction de la fiabilité (a) et de la résolution (b) résultant de la décomposition du CRPS 155

4.13 Évolution du taux d'utilisation du réseau en fonction du CRPS (a), de sa décomposition en résolution (b) et fiabilité (c) et du PLF 156

4.14 Cycle du stockage 157

4.15 Injection vers le réseau 157

Liste des tableaux

1.1	Stratégies d'intégration des EnR intermittentes avec avantage et inconvénients .	17
1.2	Caractéristiques du bâtiment EnerPos	29
2.1	Valeurs aux états	65
2.2	Synthèse des méthodes de génération de scénarios précisant les entrées et les étapes principales	76
3.1	French context electricity price from extrapolated value at January 2018	111
3.2	Peak switch hours	111
3.3	Annual error metrics	115
3.4	Performances of the microgrid for 1 year of operation	116
3.5	Nomenclature	117
4.1	PV array characteristics used for the case study	132
4.2	Error metrics for the deterministic forecast Mean(EPS)	135
4.3	The CRPS and its decomposition for 5 considered probabilistic forecasts	138
4.4	Characteristics of the Li-ion batteries considered in the study case	140
4.5	Purchased tariff, taxes included, of electricity and penalties applied in case of overpower for the considered study case	141
4.6	Annual operating obtained with the SDDP (first row) and with the PDP (other rows)costs using a constant efficiency of the inverters for both approaches	146
4.7	Economic and technical annual performance indices [86] of the PDP using a quadratic efficiency curve for the inverters	147
4.8	Performances techniques annuelles du microréseau	152

