



HAL
open science

Dimensionnement et gestion d'un stockage d'énergie pour l'atténuation des incertitudes de production éolienne

Pierre Haessig

► **To cite this version:**

Pierre Haessig. Dimensionnement et gestion d'un stockage d'énergie pour l'atténuation des incertitudes de production éolienne. Energie électrique. École normale supérieure de Cachan - ENS Cachan, 2014. Français. NNT : 2014DENS0030 . tel-01126946

HAL Id: tel-01126946

<https://theses.hal.science/tel-01126946v1>

Submitted on 6 Mar 2015

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

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

THÈSE DE DOCTORAT
DE L'ÉCOLE NORMALE SUPÉRIEURE DE CACHAN

présentée par

Pierre Haessig

pour obtenir le grade de


DOCTEUR DE L'ÉCOLE NORMALE SUPÉRIEURE DE CACHAN

Domaine : Électronique - Électrotechnique - Automatique

Dimensionnement & gestion d'un stockage d'énergie pour l'atténuation des incertitudes de production éolienne

Soutenue le 17 juillet 2014 à Bruz devant le jury composé de :

M. Benoît ROBYNS , Professeur, HEI, Lille	Président
M. Seddik BACHA , Professeur des Universités, IUT UJF, Grenoble	Rapporteur
M. Bruno SARENI , Professeur des Universités, ENSEEIHT, Toulouse	Rapporteur
M. Hervé GUÉGUEN , Professeur, Supélec, Rennes	Examineur
M. Hamid BEN AHMED , Maître de Conférences HDR, ENS Rennes, Bruz	Co-directeur de thèse
M. Stéphane LASCAUD , Chef de projet Senior, EDF R&D LME, Écuellen	Co-encadrant
M. Bernard MULTON , Professeur des Universités, ENS Rennes, Bruz	Directeur de thèse



Résumé

Le contexte de nos travaux de thèse est l'intégration de l'énergie éolienne sur les réseaux insulaires. Ces travaux sont soutenus par EDF SEI, l'opérateur électrique des îles françaises. Nous étudions un système éolien-stockage où un système de stockage d'énergie doit aider un producteur éolien à tenir, vis-à-vis du réseau, un engagement de production pris un jour à l'avance. Dans ce contexte, nous proposons une démarche pour l'optimisation du dimensionnement et du contrôle du système de stockage (gestion d'énergie). Comme les erreurs de prévision J+1 de production éolienne sont fortement incertaines, la gestion d'énergie du stockage est un problème d'optimisation stochastique (contrôle optimal stochastique).


Pour le résoudre, nous étudions tout d'abord la modélisation des composants du système (modélisation énergétique du stockage par batterie Li-ion ou Sodium-Soufre) ainsi que des entrées (modélisation temporelle stochastique des entrées incertaines). Nous discutons également de la modélisation du vieillissement du stockage, sous une forme adaptée à l'optimisation de la gestion.

Ces modèles nous permettent d'optimiser la gestion de l'énergie par la méthode de la programmation dynamique stochastique (SDP). Nous discutons à la fois de l'algorithme et de ses résultats, en particulier de l'effet de la forme des pénalisations sur la loi de gestion. Nous présentons également l'application de la SDP sur des problèmes complémentaires de gestion d'énergie (lissage de la production d'un houlogénérateur, limitation des rampes de production éolienne).

Cette étude de l'optimisation de la gestion permet d'aborder l'optimisation du dimensionnement (choix de la capacité énergétique). Des simulations temporelles stochastiques mettent en évidence le fort impact de la structure temporelle (autocorrélation) des erreurs de prévision sur le besoin en capacité de stockage pour atteindre un niveau de performance donné. La prise en compte de paramètres de coût permet ensuite l'optimisation du dimensionnement d'un point de vue économique, en considérant les coûts de l'investissement, des pertes ainsi que du vieillissement. Nous étudions également le dimensionnement du stockage lorsque la pénalisation des écarts à l'engagement comporte un seuil de tolérance.

Nous terminons ce manuscrit en abordant la question structurelle de l'interaction entre l'optimisation du dimensionnement et celle du contrôle d'un système de stockage, car ces deux problèmes d'optimisation sont couplés.

Mots-clés : Énergie éolienne, Stockage d'énergie, Garantie de production électrique, Erreurs de prévision météorologique, Dimensionnement de stockage, Gestion d'énergie, Contrôle optimal stochastique, Programmation dynamique.



Abstract

*Sizing & control of an energy storage system
to mitigate wind power uncertainty*

The context of this PhD thesis is the integration of wind power into the electricity grid of small islands. This work is supported by EDF SEI, the system operator for French islands. We study a wind-storage system where an energy storage is meant to help a wind farm operator fulfill a day-ahead production commitment to the grid. Within this context, we propose an approach for the optimization of the sizing and the control of the energy storage system (energy management). Because day-ahead wind power forecast errors are a major source of uncertainty, the energy management of the storage is a stochastic optimization problem (stochastic optimal control).

To solve this problem, we first study the modeling of the components of the system. This include energy-based models of the storage system, with a focus on Lithium-ion and Sodium-Sulfur battery technologies. We then model the system inputs and in particular the stochastic time series like day-ahead forecast errors. We also discuss the modeling of storage aging, using a formulation which is adapted to the control optimization.

Assembling all these models enables us to optimize the energy management of the storage system using the stochastic dynamic programming (SDP) method. We introduce the SDP algorithms and present our optimization results, with a special interest for the effect of the shape of the penalty function on the energy control law. We also present additional energy management applications with SDP (mitigation of wind power ramps and smoothing of ocean wave power).

Having optimized the storage energy management, we address the optimization of the storage sizing (choice of the rated energy). Stochastic time series simulations show that the temporal structure (autocorrelation) of wind power forecast errors have a major impact on the need for storage capacity to reach a given performance level. Then we combine simulation results with cost parameters, including investment, losses and aging costs, to build a economic cost function for sizing. We also study storage sizing when the penalization of commitment deviations includes a tolerance threshold.

We finish this manuscript with a structural study of the interaction between the optimizations of the sizing and the control of an energy storage system, because these two optimization problems are coupled.

Keywords: Wind power, Energy storage, Guaranteed electricity production, Weather forecast errors, Storage sizing, Energy management, Stochastic optimal control, Dynamic programming.

Remerciements

Ce manuscrit est le résultat de trois années de travaux de recherche, fruits de la collaboration entre le laboratoire SATIE et EDF. Pour ces trois années passionnantes, j'aimerais tout d'abord remercier les responsables d'EDF qui ont initié ce projet, à savoir Joseph MAIRE et Pascal RIOUAL. Le démarrage de mon travail doit également beaucoup à Pascal BONDON qui m'a accueilli en stage de Master 2 au LSS à Supélec. Ces mois préparatoires m'ont permis d'acquérir de bonnes bases en statistiques et en séries temporelles qui ont fortement enrichi ma compréhension et ma façon de traiter mon sujet de thèse.

Je remercie ensuite les membres du jury qui ont examiné ma thèse, en particulier Seddik BACHA et Bruno SARENI pour le travail de relecture critique. J'ai beaucoup apprécié le regard extérieur qu'ils m'ont apportés, car il m'a permis de prendre du recul sur mon travail. Je remercie également Benoît ROBYNS qui a accepté de présider ce jury.

Je remercie les collègues de EDF avec qui j'ai pu interagir, notamment Damien DEVILLAIN puis Vincent GRELLIER de EDF SEI qui m'ont aidé à saisir les enjeux opérationnels du problème posé. Je remercie particulièrement les collègues de EDF R&D de Clamart qui m'ont accueilli et permis de m'initier à la programmation dynamique. À la R&D des Renardières, un merci spécial à Lionel JAMY qui m'a beaucoup aidé pour la modélisation des batteries NaS. Enfin, je remercie Stéphane LASCAUD, mon encadrant d'EDF, qui m'a laissé une très grande liberté dans mon travail de recherche, tout en m'apportant un regard global sur les enjeux industriels du sujet ainsi que sur les batteries électrochimiques que je connaissais mal.

Je voudrais également remercier les partenaires industriels Vergnet et Aérowatt (devenu Quadran), qui ont non seulement accepté de partager leurs données, mais m'ont aussi permis de découvrir les points de vue complémentaires de ces différents acteurs sur le problème de l'éolien-stockage.

Mes plus vifs remerciements vont aux collègues enseignants et chercheurs du département Mécatronique de l'ENS Rennes, ainsi qu'à tous les personnels de l'école avec qui j'ai vécu ces trois années dans les meilleures conditions. Mon travail à l'antenne rennais du laboratoire SATIE s'inscrit dans la suite de travaux de thèse précédents, et en particulier ceux de Olivier GERGAUD et Yaël THIAUX dont je salue le travail.

J'ai beaucoup apprécié de travailler avec des co-bureaux "électriciens" et "mécaniciens" très sympathiques, en particulier Thibaut KOVALTCHOUK et Roman LE GOFF LATIMIER, avec qui les échanges ont été nombreux. J'ai été heureux de participer aux discussions quotidiennes, scientifiques et non scientifiques, qui ont eu lieu dans une ambiance très conviviale.

→

Remerciements

Enfin, mes plus grands remerciements vont à mes encadrants Hamid BEN AHMED et Bernard MULTON qui m'ont accueilli dans l'ambiance sympathique et bienveillante qu'ils ont su créer autour d'eux. Scientifiquement, ils ont eu le courage d'ouvrir le cadre d'étude vers les contrées, au départ bien mystérieuses, d'une "approche probabiliste" aux contours nébuleux. Grâce la grande liberté d'exploration qu'ils m'ont laissée, nous avons pu plonger dans un océan stochastique et trouver quelques pagaiés pour avancer. Au delà des questions techniques des outils d'optimisation, ils ont également su me transmettre un recul critique, voire éthique, qui a donné du sens au sujet.

Je termine en remerciant mes parents qui ont su éveiller et encourager ma curiosité scientifique, et en faisant un gros bisou à ma femme Pauline. C'est aussi ensemble que nous avons payé, dans une dernière année de thèse joyeusement chargée !

Table des matières

1	Présentation du problème et état de l'art	13
1.1	Contexte de l'insertion des EnR dans les réseaux insulaires	13
1.1.1	Les réseaux insulaires	13
1.1.2	Traitement actuel de la variabilité	15
1.1.3	Nouveaux moyens de traitement de la variabilité	16
1.2	Présentation & cadre du système éolien-stockage étudié	17
1.2.1	Généralités sur le stockage sur le réseau	17
1.2.2	Cadre du problème	17
1.2.3	Les questions à résoudre	19
1.3	Difficultés du problème, état de l'art, contribution	21
1.3.1	Méconnaissance des modèles	21
1.3.2	Méconnaissance des entrées	22
1.3.3	Dimensionnement et gestion sous incertitude	25
2	Modélisations	29
2.1	Modélisations énergétiques de systèmes de stockage	30
2.1.1	Stockage idéal	30
2.1.2	Batterie Lithium-ion	31
2.1.3	Batterie Sodium-Soufre (NaS)	37
2.2	Modélisation du vieillissement	42
2.2.1	Tour d'horizon	42
2.2.2	Formalisation du vieillissement en cyclage	44
2.2.3	Modélisation dynamique du cyclage	48
2.3	Modélisation stochastique de l'erreur de prévision	53
2.3.1	Modélisation statique	55
2.3.2	Modélisation temporelle	57
2.3.3	Génération de scénarios stochastiques de production	61
2.4	Modélisation des variations rapides de puissance éolienne	62
2.4.1	Analyse de la variabilité d'une ferme	62
2.4.2	Modélisation simpliste	64
2.4.3	Analyse spectrale et bruit fractionnaire	66
2.5	Intégration logicielle des modèles : StorageSim	69
3	Gestion optimale de l'énergie stockée	73
3.1	Présentation de la Programmation Dynamique Stochastique	73
3.1.1	Utilisation de la (S)DP pour la gestion d'énergie	74
3.1.2	Mise en œuvre de la méthode SDP	75

Table des matières

3.1.3	Optimisation d'un coût moyen (horizon infini)	81
3.1.4	Implémentation logicielle : StoDynProg	84
3.2	Discussion sur l'applicabilité, critique et comparaison	85
3.2.1	Démarche générale de mise en œuvre	85
3.2.2	Discretisation de l'état, Curse of dimensionality	86
3.2.3	Comparaison aux autres méthodes	89
3.3	Gestion optimale pour la garantie d'engagement J+1	91
3.3.1	Effet de la forme du coût	92
3.3.2	Effet de la capacité et de la corrélation des erreurs	99
3.3.3	Paramétrisation de la gestion avec tolérance	103
3.4	Autres applications de gestion optimale de stockage	104
3.4.1	Lissage de la production d'un houlogénérateur (SEAREV)	104
3.4.2	Lissage des rampes de production éolienne	105
4	Dimensionnement d'un stockage d'énergie	113
4.1	Méthode	113
4.2	Garantie d'un engagement de production J+1	115
4.2.1	Effet de la corrélation des erreurs de prévision	115
4.2.2	Dimensionnement économique, sans tolérance d'écart	120
4.2.3	Dimensionnement avec tolérance d'écart	127
4.3	Interaction dimensionnement – gestion	133
4.3.1	Contexte et enjeux	133
4.3.2	Démarche de l'étude	134
4.3.3	Résultats de sensibilité	137
4.3.4	Conclusion et pistes d'amélioration	140
5	Conclusion et perspectives	143
5.1	Bilan du travail effectué	143
5.2	Prolongements possibles	145
5.3	Perspectives	147
A	Sources des données	149
A.1	Production & prévision éolienne en Guadeloupe (Quadrant)	149
A.2	Production éolienne à haute fréquence (projet Pégase)	149
A.3	Bonneville Power Administration (BPA)	150
B	IPython Notebooks	151
B.1	Simple storage simulation	151
B.1.1	Create the simulation objects	151
B.1.2	Running a simulation	152
B.1.3	Plots	152
B.2	A StoDynProg usage example	155
B.2.1	System description	155
B.2.2	Control optimization with SDP	158
B.2.3	Plot the energy manangement policy	161

Liste des symboles

A	État de vieillissement d'une batterie (State of Aging, SoA)
C_{dev}	Coût des pénalités des écarts à l'engagement
C_{sto}	Coût total du système de stockage (investissement et fonctionnement)
C_{th}	Capacité thermique d'un module de batterie NaS
C_{tot}	Coût total du système ($C_{sto} + C_{dev}$), à minimiser
\tilde{C}_{xxx}	Coût C_{xxx} , normalisé par l'énergie éolienne produite (\rightarrow €/MWh)
DoD	Amplitude d'un cycle de décharge de batterie, pour compter le vieillissement calendaire
E_{life}	Énergie échangeable sur la vie d'une batterie
E_{rated}	Capacité énergétique utile d'un système de stockage
E_{sto}	Énergie utile stockée dans un système de stockage
I_{cell}	Courant absorbé par une cellule électrochimique
J	Coût total subit par le système, à minimiser. J^* si coût optimal
$\tilde{J}(x)$	Coût relatif, fonction de l'état du système (optimisation à horizon infini)
N_{cycles}	Nombre de "cycles pleins équivalents" qui représente le vieillissement en cyclage d'un stockage
N_{life}	Nombre de cycles de décharge pleine avant fin de vie d'une batterie
N_{max}	Nombre de cycles de décharge, à DoD donnée, avant fin de vie d'une batterie
P_{clim}	Puissance électrique absorbée pour climatiser une batterie
P_{cur}	Délestage de production éolienne
P_{dev}	Écart à l'engagement d'un système éolien-stockage : $P_{grid} - P_{grid}^*$
P_{grid}	Puissance injectée sur le réseau, par un système éolien-stockage
P_{grid}^*	Engagement de production (à fournir un jour à l'avance) envers le gestionnaire réseau
P_{heat}	Puissance électrique absorbée pour chauffer un module de batterie NaS
P_{loss}	Puissance dissipée par le système de stockage
P_{mis}	Écart entre la productible éolien et l'engagement de production
P_{pre}	Prévision J+1 de la production éolienne P_{prod}

Liste des symboles

P_{prod}	Puissance produite par une ferme éolienne (ou productible si délestage)
P_{rated}	Puissance maximale d'un système de stockage
P_{sto}	Puissance absorbée par un système de stockage
P_{sto}^*	Puissance de "consigne idéale" de stockage (si réalisée, elle donne un écart P_{dev} nul)
P_{tol}	Seuil de tolérance pour la non pénalisation des faibles écarts P_{dev}
Q_{cell}	Charge d'une cellule électrochimique
R_{cell}	Résistance interne d'une cellule de batterie électrochimique
R_{mod}	Résistance interne d'un module de batterie NaS
SoE	État d'énergie d'un système de stockage : E_{sto}/E_{rated}
T	Température d'une batterie, d'un module de batterie
T_{out}	Température extérieure (environnement d'une batterie)
V	Tension aux bornes d'une cellule de batterie
V_0	Tension à vide aux bornes d'une cellule de batterie (notée e_{cell} pour le modèle NaS)
ΔV	Chute de tension aux bornes d'une cellule de batterie ($V - V_0$)
ΔG	Incrément de la puissance P_{grid} entre deux instants successifs
ΔP	Incrément de la production P_{prod} entre deux instants successifs
Δ_t	Pas de temps, pour les modèles à temps discret
$\mu(x)$	Loi de gestion (retour d'état) du système. μ^* si gestion optimale
ϕ	Coefficient d'autorégression d'un processus AR(1)
ρ_X	Fonction d'autocorrélation du processus stochastique stationnaire $\{X(k)\}$
$c(x,u,w)$	Coût subit à chaque instant par le système à optimiser
c_{batt}	Prix unitaire énergétique (€/kWh) d'une batterie électrochimique
c_{dev}	Prix des pénalités des écarts à l'engagement (dépend du critère d'écart)
c_{elec}	Prix de vente de l'électricité du système éolien-stockage (€/MWh)
dam	Facteur d'endommagement en cyclage, pour compter le vieillissement calendaire
$f(x,u,w)$	Fonction décrivant la dynamique du système à optimiser
t_{life}	Durée de vie d'un système de stockage (vieillessement calendaire)
x, u, w	Notation générique des variables d'état, de commande et de perturbation d'un système dynamique

Chapitre 1

Présentation du problème et état de l'art

Sommaire

1.1	Contexte de l'insertion des EnR dans les réseaux insulaires	13
1.2	Présentation & cadre du système éolien-stockage étudié	17
1.3	Difficultés du problème, état de l'art, contribution	21

Nos travaux sur le dimensionnement et la gestion de stockage d'énergie s'inscrivent dans une problématique plus large : l'intégration d'énergies renouvelables (EnR) intermittentes dans les réseaux électriques insulaires *non interconnectés*, donc de "faible puissance". Pour le cas de la France, il s'agit de la Corse et les îles d'outre-mer telles que la Guadeloupe et La Réunion.

Nous commençons par présenter le contexte des réseaux insulaires (partie 1.1). Ensuite, nous délimitons le domaine, forcément restreint, de nos travaux (partie 1.2), car le stockage d'énergie est un sujet vaste et qui existe d'ailleurs largement hors du cadre des réseaux insulaires,. Enfin, nous explicitons les enjeux techniques & scientifiques du problème (partie 1.3).

1.1 Contexte de l'insertion des EnR dans les réseaux insulaires

1.1.1 Les réseaux insulaires

Les réseaux insulaires non interconnectés se caractérisent par leur "faible puissance" comparée au réseau électrique européen. Pour l'année 2012, la puissance électrique consommée varie entre 150 et 250 MW en Guadeloupe, 200 et 450 MW pour La Réunion [33, 34]. En comparaison, la consommation de la France métropolitaine varie entre 30 et 100 GW et celle de l'Europe¹ entre 230 et 550 GW [36].

Deuxième différence saillante, chaque groupe de production (typiquement 20–40 MW) représente une fraction importante de la consommation de l'île, bien plus que sur le continent. Ainsi, la fragilité associée à un incident sur une unité de production est bien plus grande.

De par leur spécificité, les réseaux insulaires sont gérés de manière intégrée par EDF SEI², à l'inverse du modèle découpé et libéralisé appliqué sur le continent. Ainsi, SEI produit ou rachète l'intégralité de la production électrique d'une île, et assure son transport, sa distribution et sa commercialisation.

1. L'Europe au sens des 34 pays inclus dans le consortium ENTSOE-E
2. EDF Systèmes Énergétiques Insulaires

1 Présentation du problème et état de l'art

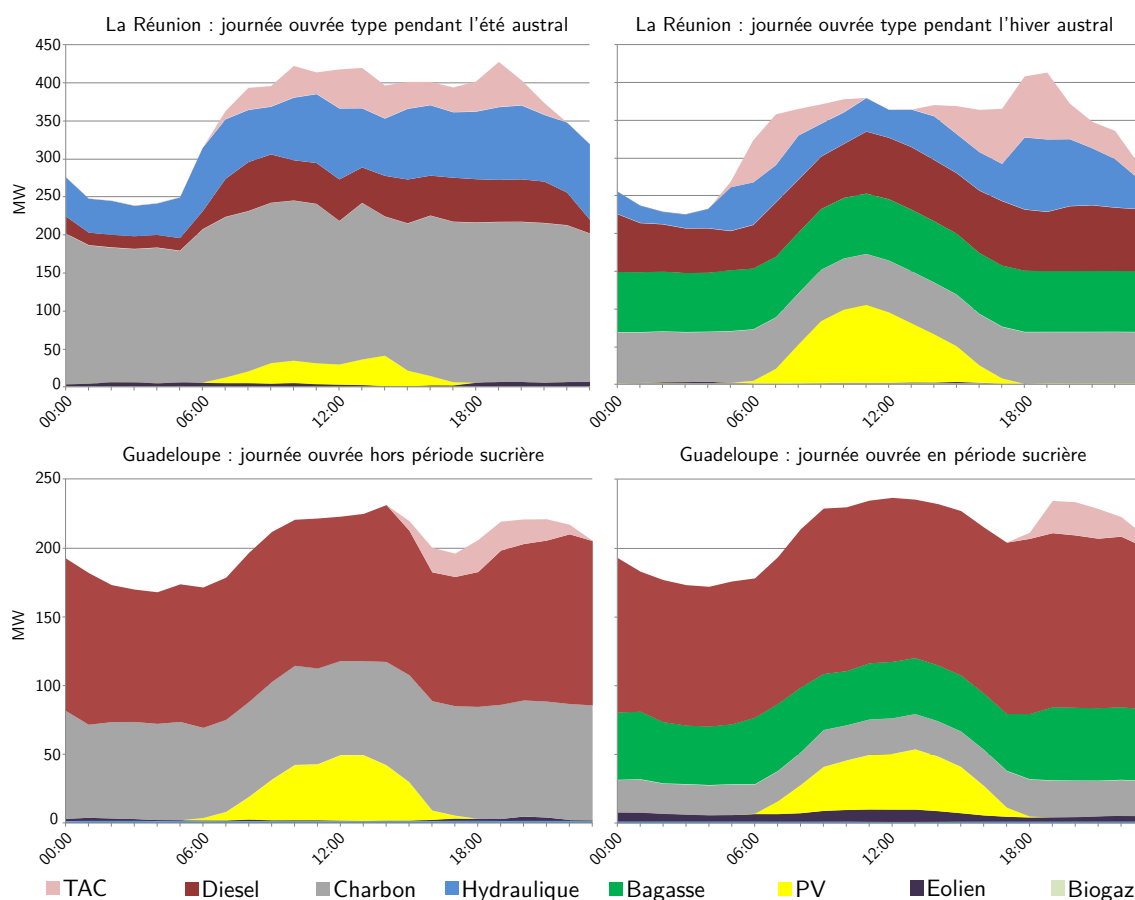


FIGURE 1.1 – Empilements journaliers de production à La Réunion et en Guadeloupe issus de EDF SEI [33, 34, p. 11]

Entre autres spécificités, la puissance éolienne et photovoltaïque installée³ est, en proportion, plus importante qu'en métropole :

- en Guadeloupe : parc de production de 500 MW, dont 27 MW éolien et 64 MW PV. Le ratio de capacité intermittente est donc de **18%**.
- à La Réunion : parc de production de 900 MW, dont 15 MW éolien et 152 MW PV. Le ratio de capacité intermittente est donc de **19%**.
- en métropole : parc de production de 130 GW, dont 7.5 GW éolien et 3.5 GW PV. Le ratio de capacité intermittente est donc de **8%**. Les interconnexions permettent en outre d'échanger ± 10 GW environ.

Ainsi, les réseaux insulaires non interconnectés sont plus exposés à la variabilité des sources intermittentes. Pour compléter ces chiffres, la figure 1.1 montre des productions journalières typiques à La Réunion et en Guadeloupe.

Par ailleurs, les coûts de production de l'électricité sont plus élevés que sur le continent. Voici quelques ordres de grandeur des moyens d'usage courant :

- Charbon : 100 €/MWh (le moins cher mais le moins flexible)
- Moteur Diesel : 130 €/MWh

3. chiffres 2012 issus des rapports de EDF SEI [33, 34, p. 9] et de RTE [90]

- Turbine à Combustion au fioul (TAC) : 300 €/MWh (le plus flexible mais le plus cher)

Tous ces coûts de production sont supérieurs au prix de vente aux consommateurs (50 €/MWh hors taxes), car le prix de l'électricité se doit d'être uniforme sur le territoire national par principe républicain. En conséquence, la CSPE⁴ compense le déficit du gestionnaire EDF SEI.

En corolaire, les coûts élevés de la production électrique par voie fossile augmentent la pertinence économique des productions EnR, en particulier éoliennes.

1.1.2 Traitement actuel de la variabilité

Les deux sources principales de variabilité de l'équilibre production/consommation sont la charge (la consommation n'est qu'imparfaitement prévue) et les EnR intermittentes (très imparfaitement prévues, et qui peuvent varier très brusquement). Ainsi, la variabilité augmente à mesure que la pénétration de l'éolien et du PV progresse. Actuellement, cette variabilité est traitée par l'ajustement des moyens de production, pour ceux qui sont ajustables, et dans la limite de leur flexibilité :

- Turbine à Combustion (TAC), moyen très réactif (démarrage en 10–15 minutes, et passage à puissance nominale en quelques secondes une fois démarré) mais très cher.
- Diesel, moins réactif (le démarrage d'un groupe de 15 MW coûte 3000 € et dure 30 minutes).
- Barrage hydro-électrique, bien adapté pour les variations à l'échelle de la minute, mais dans la limite du stock d'eau (et d'autres contraintes d'exploitation).

Dans tous les cas, la présence de variabilité dans le système électrique engendre une *augmentation du coût de fonctionnement global* (on se trouve dans une situation de "compromis optimalité vs robustesse"). On peut attribuer l'augmentation du coût à trois causes :

1. Production avec des moyens flexibles mais plus onéreux, par exemple une TAC.
2. Utilisation de moyens hors de leur plage de fonctionnement optimal, par exemple un moteur Diesel utilisé à bas régime.
3. Déviation du plan de production prévu initialement.

Sur ce dernier point, il faut savoir que la production est planifiée la veille pour le lendemain afin d'obtenir une *minimisation* du coût de fonctionnement de la journée. Ainsi, toute déviation du plan initial engendre a priori une *hausse* du coût. Exemple : l'utilisation anticipée d'un barrage pendant la journée le rend indisponible pour assurer la "pointe du soir". Il faut alors faire appel à un moyen plus onéreux. Parfois, il peut y avoir l'illusion d'une baisse, si par exemple la consommation d'une journée plus faible que prévue, car moins de carburant est consommé. Cependant, le coût de fonctionnement de la journée aurait pu être encore plus bas si cette sous-consommation avait été anticipée la veille.

Limite des 30% Dans le but de limiter les risques de déséquilibre, un arrêté du 23 avril 2008 fixe pour la France une "limite des 30%" au taux de pénétration des EnR intermittentes : à chaque instant, si la production EnR excède 30% de la consommation du moment, le gestionnaire du réseau peut procéder à des déconnexions. Dans ce cas, le producteur n'est pas rémunéré pour l'énergie qu'il aurait "potentiellement pu produire".

4. Contribution au Service Public de l'Électricité. Taxe fixée à 13,5 €/MWh au 1er janvier 2013. 30% servent au financement de la "péréquation tarifaire", soit 1,4 G€/an. Source <http://www.cre.fr/operateurs/service-public-de-l-electricite-cspe/montant>.

Cette limite a été atteinte en Guadeloupe et à La Réunion en 2012 [33, 34, p 9]. Pour le moment, les déconnexions ne se font que quelques heures par an, lorsqu'une faible consommation se conjugue à un ciel clair ou un vent puissant.

Notons que les déconnexions se font sur la base du "dernier raccordé, premier déconnecté", ce qui fragilise la rentabilité de nouvelles installations. Pourtant, la part *énergétique* de l'éolien + PV qui est de 8% (en Guadeloupe de même qu'à La Réunion) aurait encore vocation à augmenter. Cette augmentation se justifie à la fois par le potentiel exploitable (alisez dans les Antilles) et par les objectifs nationaux et européens d'augmenter la part renouvelable du mix énergétique⁵.

1.1.3 Nouveaux moyens de traitement de la variabilité

Appels d'offres EnR-Stockage Pour "franchir la limite des 30%" sans trop dégrader la garantie de l'équilibre du réseau, la CRE⁶ a lancé en 2009-2011 une série d'appels d'offres pour des systèmes *éoliens et photovoltaïques avec stockage*. Pour les deux technologies, il s'agit de diminuer la variabilité et d'augmenter la prévisibilité de la puissance produite.

Plus particulièrement pour l'éolien, on retient du cahier des charges [28, p. 26] trois règles qui ne peuvent être satisfaites par un système éolien *conventionnel*. Nous les résumons ici schématiquement :

1. **Engagement de production J+1** : le producteur doit fournir au gestionnaire de réseau une prévision de sa production pour les 24 heures du lendemain. Cette prévision constitue un *engagement* qu'il devra respecter à chaque instant avec une plage de tolérance de $\pm 15\%$ de la puissance nominale (P_{nom}).
2. **Variations de la puissance** : La production doit être maintenue stable sur les plages de 30 minutes correspondantes à l'engagement. Entre ces paliers, la vitesse de montée et de descente de la puissance est encadrée ($v_{\downarrow} \leq dP/dt \leq v_{\uparrow}$, où les vitesses de variation sont de l'ordre de $P_{nom}/10'$).
3. **Réserve primaire 15'** : La puissance injectée doit être ajustée jusqu'à $\pm 10\%$ en fonction de la fréquence du réseau. Cette réserve primaire doit être disponible pendant 15 minutes.

Si ces règles ne sont pas respectées, des *pénalités* sont appliquées. En particulier pour l'engagement de production, toute excursion de la production (mesurée "en instantané") hors de la plage de tolérance entraîne une décote de 50% du prix d'achat de l'électricité.

Les lauréats de l'appel d'offres éolien-stockage ont été désignés en février 2012 (pour un total de 95 MW), avec des tarifs de rachat de l'électricité autour de 180 €/MWh. Pour comparaison, le tarif sans stockage est à 84 €/MWh pour les éoliennes terrestres en métropole et 113 €/MWh en outre-mer [46]. Depuis l'annonce des résultats, les projets se développent, sachant qu'un tarif de rachat spécial "éolien-stockage" à 231 €/MWh a été créé en 2013 avec un cahier des charges similaire [47].

Autres solutions Les appels d'offres EnR-stockage se basent sur une approche "pollueur-payeur", car c'est le producteur EnR, générateur de variabilité, qui prend en charge l'investissement et la gestion d'un stockage d'énergie. Cependant, d'autres approches sont envisageables/envisagées pour le traitement de la variabilité.

5. La France doit par exemple porter la part de renouvelable à 23% de sa consommation d'énergie finale en 2020, partant de 10% en 2005 [79, p 46].

6. Commission de Régulation de l'Énergie, "autorité administrative indépendante chargée de veiller au bon fonctionnement des marchés de l'électricité et du gaz en France".

Tout d'abord, le stockage d'énergie ne doit pas nécessairement être localisé et géré chez le producteur EnR. Il peut aussi être soit *centralisé* par le gestionnaire réseau ou à l'opposé être réparti de façon *diffuse* chez les consommateurs (quitte à être géré de façon centralisée).

L'effacement diffus (parmi d'autres mécanismes de "demand response") est également une solution envisagée et qui ne nécessite pas d'investissement dans de nouveaux moyens de stockage.

1.2 Présentation & cadre du système éolien-stockage étudié

Nos travaux se concentrent essentiellement sur le dimensionnement et la gestion de stockage pour *garantir l'engagement de production $J+1$* d'une ferme éolienne. Nous étudions ainsi un des points clés de l'appel d'offres éolien-stockage en endossant le *point de vue d'un producteur*. Il s'agit alors de *minimiser les coûts* dans le cadre des contraintes du cahier des charges.

Comme les intérêts du producteur et ceux du gestionnaire réseau sont potentiellement *divergents*, nous prenons également le *point de vue du gestionnaire*. Il s'agit alors d'évaluer comment des stratégies d'optimisation du producteur peuvent impacter négativement le réseau (cf. partie 3.3.1 sur les effets de la forme de la pénalisation des écarts à l'engagement). Cet aspect reste néanmoins qualitatif et ne se base pas sur de véritables "études de réseau".

1.2.1 Généralités sur le stockage sur le réseau

Actuellement, le stockage de l'énergie électrique se fait très majoritairement dans les barrages hydro-électriques réversibles (STEP). Cependant, le besoin de plus de réactivité et le développement de nombreuses technologies électrochimiques (batteries) ou autres (e.g. les volants d'inertie) ont fait nettement grandir l'idée de stocker l'électricité autrement. Ainsi, l'EPRI⁷ a publié dès 2002 un panorama des différentes technologies de stockage utilisables sur le réseau [37] et en particulier pour l'éolien [38]. D'autres rapports ciblent spécifiquement la question cruciale de la valeur, donc de la rentabilité d'un stockage sur le réseau [41, 39]. La valeur apportée par un stockage dépend de la fonction qu'il remplit ("peak shaving", "energy shifting") et éventuellement du cadre réglementaire qui fixe les rémunérations (e.g. la régulation de la fréquence). Pour ces travaux, nous nous sommes concentrés sur les fonctions spécifiquement demandées par l'appel d'offres éolien-stockage, et en particulier l'engagement de production $J+1$.

1.2.2 Cadre du problème

Si le contexte de l'appel d'offres éolien-stockage est spécifique aux îles françaises, celui-ci se relie aisément à des cadres plus généraux. EPRI [38, p 3-3] nomme par exemple "Forecast Hedging" le fait de garantir un engagement de production à l'aide d'un stockage dans le cadre de *marchés de l'électricité*. Dans l'appel d'offres de la CRE, le marché est remplacé par un contrat de 20 ans où les règles tarifaires (rémunération et pénalités) sont *fixées*. Ainsi, nous n'étudions aucunement les questions de fluctuations (et éventuellement de prévision) des prix ou des pénalités. En outre, nous nous concentrons sur un engagement $J+1$, sachant que dans le cadre des marchés, l'horizon et le pas d'engagement varient d'un marché à l'autre (ex : day-ahead vs intraday).

La figure 1.2 présente l'architecture du système éolien-stockage que l'on considère pour garantir un engagement. Nous y trouvons 3 éléments qui échangent de l'énergie :

7. The Electric Power Research Institute, Inc.

1 Présentation du problème et état de l'art

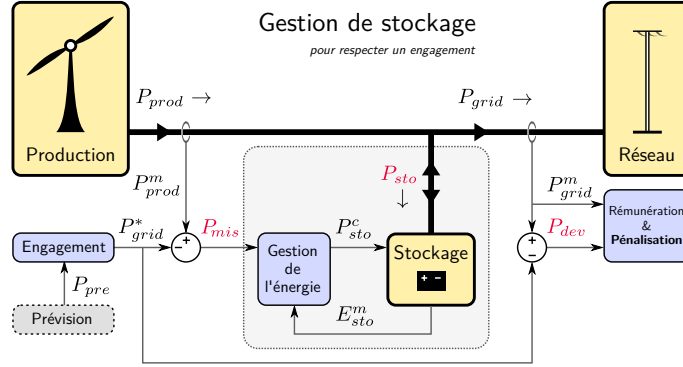


FIGURE 1.2 – Architecture du système éolien-stockage pour garantir un engagement. Les exposants m et c dénotent respectivement des *mesures* et des *consignes*.

- Une source renouvelable à *caractère incertain* produit une puissance $P_{prod}(t)$.
Nous considérons le cas d'une ferme éolienne, mais la source peut être un système photovoltaïque ou houlogénérateur (abordé partie 3.4.1). Chaque cas présente une structure d'incertitude nettement différente.
- Un stockage capable d'absorber une puissance $P_{sto}(t)$.
Stockage en convention récepteur : $P_{sto} > 0$ en charge, $P_{sto} < 0$ en décharge.
- Le réseau sur lequel le système éolien-stockage injecte une puissance $P_{grid}(t)$.
Le cas îloté (non connecté au réseau) où une source incertaine alimenterait directement des charges n'est pas étudié.

La puissance P_{sto} absorbée par le stockage est le seul degré de liberté⁸ qui permet d'ajuster la puissance renvoyée au réseau :

$$P_{grid}(t) = P_{prod}(t) - P_{sto}(t) \quad (1.1)$$

Nous introduisons l'énergie stockée E_{sto} régie, en ne tenant pas compte des pertes, par :

$$\frac{dE_{sto}}{dt} = P_{sto} \quad (1.2)$$

Relevons alors que P_{sto} , le degré d'ajustement de l'équation (1.1), est limité par 2 contraintes :

- Limitation de puissance :

$$-P_{rated} \leq P_{sto}(t) \leq P_{rated} \quad (1.3)$$

où P_{rated} est la puissance nominale du système de stockage.

Il s'agit ici d'une écriture schématisée, car certaines technologies de stockage ont des contraintes de puissance qui dépendent de l'état d'énergie ou d'autres paramètres. Parfois, ces contraintes sont même asymétriques en charge et en décharge.

- Limitation d'énergie :

$$0 \leq E_{sto}(t) \leq E_{rated} \quad (1.4)$$

où E_{rated} est la capacité énergétique *utile* du système de stockage.

8. Nous discutons ensuite d'un degré de liberté supplémentaire : la possibilité de délester la production P_{prod} , par exemple en agissant sur le calage des pales des turbines. À ce propos, un rapport récent du NREL [35] discute à des possibilités de gérer la puissance des éoliennes pour fournir des services au réseau.

La limite en énergie se réécrit plus simplement en introduisant l'état d'énergie :

$$SoE = E_{sto}/E_{rated} \in [0,1] \quad (1.5)$$

Mécanisme d'engagement Le producteur éolien dispose d'une prévision de production $P_{pre}(t)$ basée sur des données météo (cf. partie 1.3.2). Sur la base de cette prévision, le producteur construit un profil d'engagement $P_{grid}^*(t)$ par pas demi-horaire. Il fournit ce profil au gestionnaire réseau chaque jour à 17h pour le lendemain (0h–23h30). Le gestionnaire peut alors s'en servir pour planifier la production totale en tenant compte de la contribution du parc éolien. Lorsque la production est réalisée, on observe l'écart à l'engagement :

$$P_{dev}(t) = P_{grid}(t) - P_{grid}^*(t) \quad (1.6)$$

et cet écart a vocation à être *faible* au sens d'un critère (ex : moyenne quadratique) à préciser. Cet écart sera généralement non nul, car la prévision météo est *imparfaite*. C'est donc en jouant sur la puissance stockée que l'on peut influencer sur cet écart.

Nous faisons également apparaître l'écart *production – engagement* (“*mis*” pour mismatch)

$$P_{mis}(t) = P_{prod}(t) - P_{grid}^*(t) \quad (1.7)$$

que nous nommerons parfois *consigne idéale de stockage*. En effet, en combinant (1.6) avec (1.1) l'écart à l'engagement peut se réécrire

$$P_{dev}(t) = P_{mis}(t) - P_{sto}(t) \quad (1.8)$$

et ainsi, si le stockage est capable de réaliser la consigne $P_{sto} = P_{mis}$, alors l'écart à l'engagement est nul ($P_{dev} = 0$).

1.2.3 Les questions à résoudre

Nos travaux de thèse s'articulent autour de 2 questions imbriquées :

“Comment *dimensionner* et comment *gérer* le système éolien-stockage ?”

et plus précisément :

- Quel dimensionnement (capacité E_{rated} & puissance P_{rated}) de stockage permet d'assurer un engagement J+1 de façon optimisée (au sens d'un critère à préciser) ? Il s'agit donc de choisir les bornes des contraintes (1.3) et (1.4) qui pèsent sur la puissance stockée.
- Quelle gestion appliquer, une fois les contraintes fixées, pour tirer le meilleur parti de la quantité limitée d'énergie stockée ? Il s'agit de choisir à *chaque instant* la puissance P_{sto} à stocker, ainsi que les éventuelles autres variables de contrôle telles que l'écrêtage.

Ces deux questions sont posées dans le contexte spécifique d'une production éolienne *imparfaitement prédite*, c'est-à-dire un écart $P_{prod} - P_{pre}$ à caractère aléatoire. En effet, on va voir que les prévisions à 24 heures sont nettement entachées d'erreur (cf. parties 1.3.2 et 2.3).

Pour ces deux questions, le “bon choix” sera défini par rapport à des critères d'optimisation définis d'après l'appel d'offres éolien-stockage ou inspirés de celui-ci. Il s'agit donc de deux *problèmes d'optimisation*.




FIGURE 1.3 – Structure simplifiée du système “éolien-stockage avec engagement” pour la gestion d’énergie

Dimensionnement C’est a priori la première question à résoudre puisqu’on achète d’abord le système (fixation des contraintes) puis on doit gérer le système tel qu’il est. Cependant, l’optimisation du dimensionnement nécessite une mesure (par simulation) de la performance du système “en service”. Cette performance dépend de la qualité de la loi de gestion utilisée, elle-même tributaire du dimensionnement initial. Il y a donc un *couplage* entre la gestion (boucle interne) et le dimensionnement (boucle externe). Nous avons donc choisi de présenter l’étude du dimensionnement plus tard, au chapitre 4, après l’étude de la gestion.

Stratégie d’engagement Un des aspects de la gestion du système éolien-stockage est de déterminer un jour à l’avance un profil d’engagement $P_{grid}^*(t)$ tirant parti au mieux de l’information disponible, en particulier la prévision de production $P_{pre}(t)$ basée sur la météo. On conçoit que l’engagement a vocation à être proche de la prévision : $P_{grid}^* \approx P_{pre}$, car la prévision est l’espérance de la production future. Cependant, au moins deux raisons peuvent pousser à décaler l’engagement de la prévision :

- le profil prévu ne respecte pas les gabarits d’un profil de production acceptable
- le stockage se trouve dans un état d’énergie extrême. Par exemple, si le stockage est presque vide, on peut vouloir promettre moins que la prévision pour avoir plus de chances de rétablir le stock le lendemain.

Pour notre étude, nous nous restreindrons cependant à la politique simple “engagement = prévision” ($P_{grid} = P_{pre}$). Des études distinctes sont menées chez EDF R&D sur l’optimisation de cette politique d’engagement.

Stratégie de gestion Comme nous avons simplifié la politique d’engagement, nous pouvons considérer l’écart production-engagement P_{mis} comme l’unique variable d’entrée subie par le système de stockage (cf. figure 1.2), sans prendre en compte le couple (P_{prod}, P_{grid}^*) comme ces deux variables sont elles-mêmes non contrôlées. On simplifie la représentation du problème de gestion en travaillant uniquement avec les *variables d’écarts*, tel que représenté sur la figure 1.3.

Sur cette figure, nous avons altéré la définition de P_{mis} en écart “productible-engagement” ce qui permet d’ajouter le degré de liberté du *délestage de production* $P_{cur} > 0$. Au final, l’écart à l’engagement sur lequel le producteur est pénalisé est réécrit sur le modèle de (1.8) :

$$P_{dev}(t) = P_{mis}(t) - P_{cur}(t) - P_{sto}(t) \quad (1.9)$$

L’utilisation optimale du ou des degrés de liberté (P_{sto} et P_{cur}) des équations (1.8) ou (1.9) est traitée au chapitre 3.

Ouverture du cadre d’étude En gardant la structure des flux de puissance des figures 1.2 et 1.3, quitte à redéfinir la nature de l’entrée (P_{prod} ou P_{mis}) et de la sortie (P_{grid} ou P_{dev}), il est possible de traiter des problèmes de gestion d’énergie autres que la garantie d’engagement J+1 pour l’éolien. Par exemple, nous avons étudié le lissage de production éolienne (§3.4.2) et l’atténuation des fluctuations de production d’un houlogénérateur [50, fig. 1], traitée partie 3.4.1.

1.3 Difficultés du problème, état de l’art, contribution

La partie 1.2.3 a défini la problématique de cette thèse. Nous allons maintenant décrire les principales difficultés rencontrées pour y répondre. Nous tenterons de dresser pour chacune un état de l’art et décrire notre contribution.

1.3.1 Méconnaissance des modèles

Comme nous approchons le dimensionnement et la gestion sous l’angle de l’optimisation, il nous faut des *modèles d’optimisation*⁹ du système à optimiser, en l’occurrence le système de stockage d’énergie (ESS).

Il importe en particulier de bien modéliser les phénomènes qui ont un fort impact sur la *fonction coût* (et sur les contraintes), alors que certains sont mal connus. Pour le stockage, nous identifions trois phénomènes soupçonnés d’être influents, mais mal connus (par ordre de méconnaissance croissante) :

- **Les pertes énergétiques** pèsent par le coût de l’énergie non produite ou bien qu’il faut acheter. Nous englobons ici les pertes internes au stockage (e.g. par effet Joule) ainsi que la consommation des auxiliaires, en particulier la gestion thermique. La modélisation des pertes nécessite des modélisations spécifiques des éléments d’un système de stockage (e.g. batteries et onduleur).
- **Le coût du stockage** est incertain pour de nombreuses raisons : politiques commerciales des fabricants changeantes dans un contexte de marché incertain ; technologies en évolution ; coût des “accessoires” (onduleur, câblage) ; coût du génie civil et enfin incertitude sur les changements réglementaires (e.g. réglementation environnementale).
- **Le vieillissement du stockage** pèse à la fois par la dégradation de la performance au fil du temps et par l’éventuel remplacement du stockage usé.

Pour la modélisation énergétique des systèmes de stockage, nous avons mis en œuvre des modèles suffisamment simples pour servir en optimisation et intelligibles pour permettre au concepteur d’interpréter les résultats. L’exigence de simplicité nous a fait préférer des modèles *électriques quasi statiques* à des modèles physiques plus complexes (e.g. faisant intervenir des EDP de diffusion d’ions). Nous présentons partie 2.1 la modélisation d’un stockage “idéal” ainsi que des technologies Lithium-ion NCA et Sodium-Soufre. Soulignons simplement que l’objectif de calculer les pertes énergétiques nous a poussé à implémenter un modèle de cellule électrochimique *générique* dont la tension est une fonction *arbitraire* de la charge et du courant. Cela

9. Un modèle est dit “d’optimisation” s’il est assez simple pour être utilisable dans une boucle d’optimisation, mais en même temps assez fidèle pour pouvoir guider correctement l’optimiseur. Ce caractère de “simplicité” du modèle est partiellement relatif, car il dépend de l’algorithme d’optimisation employé.

permet par exemple de modéliser des chutes de tension non linéaires ou des augmentations de résistance en fin de charge et décharge.

Une grande part de ce travail s'est concrétisée dans le développement de ces modèles sous formes de briques logicielles dans le cadre d'un programme unifié de simulation. Le but d'une telle unification logicielle est d'améliorer la *réutilisation du code et des modèles*. L'outil ainsi créé, nommé "StorageSim", sera présenté partie 2.5.

Pour le vieillissement, nous avons voulu formaliser l'écriture des modèles de comptage de cycles pour en étudier les propriétés. En particulier, nous avons montré (avec le stage de Master1 de Samy Biyadi [13]) que l'algorithme de "Comptage d'Amplitude Simple" [4, §5.3 Simple-Range Counting] sous-estime le vieillissement en présence de micro-cycles. Ce défaut est absent d'un autre algorithme courant dit "Rainflow". Nous présentons ces modèles de vieillissement dans la partie 2.2.

Enfin, nous avons cherché à évaluer l'impact de certains paramètres incertains tels que le coût unitaire du stockage par des *études de sensibilité*. Remarquons que nous n'avons pas cherché à aborder la question de l'optimisation face à de l'incertain sous l'angle de l'optimisation robuste ou la théorie de la décision.

1.3.2 Méconnaissance des entrées

En plus de la méconnaissance des modèles, nous avons sur la figure 1.2 deux entrées *incertaines* et en partie *méconnues* : la production éolienne P_{prod} et la prévision de la production P_{pre} . Nous différencions ici le caractère incertain du caractère méconnu :

- entrée incertaine : entrée dont le comportement est modélisé par une *variable aléatoire*, suivant un modèle (loi de probabilité) qui peut être parfaitement connu.
Contraire : entrée certaine
- entrée méconnue : entrée pour laquelle il n'y pas (ou partiellement pas) de modèle.
Contraire : entrée parfaitement modélisée.

La difficulté de modélisation principale dans un contexte de stockage est la nécessité de modéliser la *structure temporelle* des entrées. Nous utilisons pour cela les outils statistiques des *séries temporelles*, en particulier l'ouvrage "classique" de Brockwell *et al.* [21].

Méconnaissance de la production éolienne La production éolienne est, d'un point de vue marginal (moyennée au fil du temps), bien modélisée pour peu que l'on dispose de suffisamment de données. Ainsi, une série de données de quelques années permet de connaître la répartition de la production, par exemple sous forme d'un histogramme. La figure 1.4 donne un exemple de production éolienne tiré de 3 ans de données de la Bonneville Power Administration (BPA) (cf. annexe A.3 pour plus de détails sur ces données). On observe en particulier la distribution fortement *non gaussienne*, avec une proportion importante de valeurs nulles (20%) correspondant aux périodes de faible vent.

Avec ce type d'histogramme, il est aisé de procéder à des tirages aléatoires de *valeurs ponctuelles* de la puissance produite. Pourtant, c'est de *scénarios temporels* de production dont les outils de simulations de stockage ont besoin. Il n'y a malheureusement pas de modèle aléatoire universel pour modéliser temporellement une production éolienne, car la structure temporelle est compliquée. En particulier, l'outil classique des processus autorégressifs à moyenne mobile (ARMA) n'est pas applicable, en tout cas tel quel, ne serait-ce qu'à cause de la non-gaussianité des données.




FIGURE 1.4 – Exemple d’histogramme de production éolienne : données à pas de 5 minutes de la région de la BPA (Nord-ouest américain) sur la période 2010–2012

Un rapport du Risø de Sørensen *et al.* [94] donne un aperçu de la question de la simulation des fluctuations de puissance éolienne. Nous retenons que les méthodes de génération de scénarios éoliens (en vitesse de vent ou en puissance) se classent en 2 approches :

- l’approche spectrale consiste à analyser et modéliser la densité spectrale de puissance (PSD) des données. Cette approche est supportée par un argument théorique issu de la statistique des écoulements turbulents. Dans le cadre de cette théorie développée par Kolmogorov [65], le spectre de la vitesse d’un fluide décroît en $f^{-5/3}$. L’exposant fractionnaire est associé au caractère fractal du phénomène. L’article de Apt [3] montre un bon exemple de cette décroissance sur 4 décades (spectre de la puissance).
- l’approche temporelle, qui fait souvent usage de processus avec *changement de régime*. En effet, les modèles ARMA simples ne capturent pas bien les phénomènes de bouffées de variabilités. Nous retenons de la littérature (e.g. Ailliot *et al.* [1], Pinson *et al.* [82]) que les modèles autorégressifs avec chaîne de Markov cachée (MSAR) semblent bien adaptés. Ces modèles MSAR ont également l’avantage d’être facilement interprétables : on peut associer l’état caché à la notion de régime météorologique. Une autre voie consiste à utiliser la famille des processus (G)ARCH¹⁰ [40], mais il n’y a alors plus de régimes interprétables.

La question de la modélisation de production éolienne est donc particulièrement ardue, surtout si l’on souhaite couvrir une large plage fréquentielle. Nous nous sommes contentés d’observer la littérature et de conduire quelques analyses fréquentielles. Celles-ci corroborent la décroissance de la PSD en $1/f^\alpha$, avec α proche de, mais pas forcément égal à, 5/3.

Partie 2.4, nous présentons notre modélisation de production qui s’est focalisée, de façon très simplifiée, sur les *fluctuations rapides* (de l’ordre de quelques secondes à quelques minutes). En effet, cette modélisation alimente l’optimisation de la gestion d’un stockage pour le *lissage* de ces fluctuations.

Une question reste pour nous en suspens : l’approche fréquentielle n’analyse que les caractéristiques d’ordre deux (moyenne et autocovariance) d’un signal, ce qui n’est suffisant que pour un processus gaussien. Comme les signaux ne sont pas gaussiens, comment doit-on alors fixer les

10. (Generalized) Autoregressive Conditional Heteroskedasticity models, utilisés couramment sur les séries financières pour modéliser les bouffées de variabilité.




FIGURE 1.5 – Extrait d'une semaine de prévision J+1 à pas d'une heure pour la ferme de Grand Maison (Guadeloupe)

autres caractéristiques (i.e. les corrélations d'ordre supérieur) ? Nous n'avons pas pour l'instant de réponses satisfaisantes à cette question.

Prévision éolienne Comme présentée dans la partie 1.2, la conduite d'un système éolien-stockage nécessite des prévisions de production sur un horizon de 1 ou 2 jours. Les prévisions se basent sur les sorties de modèles météo (NWP¹¹ en anglais), à part pour des horizons courts (quelques heures) où des méthodes statistiques suffisent (persistance, processus autorégressifs, réseaux de neurones, ...). La figure 1.5 montre un exemple opérationnel de prévision sur une ferme en Guadeloupe (données présentées en annexe A.1).

La question de la prévision éolienne a fait l'objet d'un intense effort de recherche, en particulier sur la décennie 2000 avec plusieurs projets européens tels qu'ANEMOS. Un état de l'art poussé sur la prévision se trouve dans un des livrables du projet ANEMOS.plus [45]. Nous résumerons les approches employées par le terme de "modèle boîte grise" : les modèles météo issus de la physique fournissent des prévisions de vitesse de vent et d'autres paramètres météo. Un bloc non linéaire transforme alors ces prévisions de vent (m/s) en puissance (W). Ce bloc (par exemple un réseau de neurones) est calibré avec des historiques de données pour "apprendre" la relation vitesse-puissance d'une ferme éolienne. L'utilisation d'historiques permet aussi, voire surtout, de corriger les biais des modèles météo, car ceux-ci utilisent un maillage spatial lâche (quelques km) qui ne peut pas prendre en compte les particularités topographiques locales.

La qualité de la prévision, souvent qualifiée en NMAE (erreur en moyenne valeur absolue, relativement à la puissance nominale), peut passer de 10 % à 30 % selon la "difficulté" du terrain (ex : présence ou absence de reliefs) et dépend aussi de l'horizon temporel. Au-delà de ce niveau d'erreur moyen, le niveau d'incertitude dépend fortement des conditions du moment (phénomène amplifié par l'effet saturant la courbe $P(v)$ d'une éolienne). Un effort supplémentaire a donc été fait pour caractériser à chaque instant l'incertitude de prévision, par exemple en utilisant la régression de quantiles comme Nielsen *et al.* [76]. Cela complète la prévision *ponctuelle* par des *intervalles de confiance*.

Cependant, la gestion de stockage (ainsi que d'autres processus de décision) nécessite une caractérisation probabiliste encore plus complète : la *structure temporelle* de l'erreur. Cela permet par exemple de générer des *scénarios* de production prévue comme le font Pinson *et al.* [83]. Cependant, il semble que la mise au point de ce type d'outil reste difficile. En effet, la dimension de l'espace d'état étant très grande, il faut énormément de données pour une bonne calibration

11. Numerical Weather Prediction

(dimension qui augmente encore si l’on ajoute une structure *spatiale* pour étudier le foisonnement entre différentes fermes !).

Contribution Comme la structure, en particulier temporelle, de la production et de la prévision éoliennes est complexe et donc mal connue, nous avons essentiellement cherché à réduire cette complexité en travaillant sur le signal *différence* : $P_{prod} - P_{pre}$, l’erreur de prévision.

La motivation est double : d’une part, c’est ce signal différence qui est l’entrée principale de la gestion d’un stockage pour garantir un engagement, comme expliqué partie 1.2.3, § Stratégie de gestion. D’autre part, il y a l’idée, très empirique, qu’une partie de la complexité des deux processus s’annule lorsqu’on considère la différence (par exemple, annulation de l’asymétrie de distribution constatée figure 1.4).

Partie 2.3, nous présentons notre modélisation par un processus AR(1) qui capture, de façon simplifiée, la structure temporelle de la *corrélation des erreurs de prévision*. La corrélation positive des erreurs est visible sur la figure 1.5 : les erreurs sont souvent de même signe pendant plusieurs heures consécutives. Le caractère corrélé des erreurs de prévision est connu depuis longtemps (mais pas forcément de tous !) et apparaît par exemple dans un rapport pionnier de Söder [92, p. 43-131] sur l’intégration de l’éolien. L’effet de la corrélation sur le stockage a d’ailleurs été souligné très pédagogiquement par Pinson *et al.* [84, fig. 3]. Nous avons *quantifié* l’impact de cette corrélation sur le dimensionnement de stockage dans un article de journal [52], et nous y revenons partie 4.2.1.

1.3.3 Dimensionnement et gestion sous incertitude

La gestion et le dimensionnement du système éolien-stockage constituent le cœur de notre étude et seront abordés respectivement aux chapitres 3 et 4. Nous soulignons ici certains aspects du problème qui nous ont paru saillants et qui ont fortement influencé nos méthodes de résolution.

Caractère *dynamique* de l’optimisation Vu le prix relativement élevé des technologies de stockage de l’électricité, nous avons abordé l’optimisation de la loi de gestion (pour “tirer le meilleur parti de la quantité limitée d’énergie stockée”, cf. 1.2.3). Nous relevons que ce problème d’optimisation est de nature *dynamique*, c’est-à-dire que des variables du problème (en particulier l’énergie E_{sto}) sont gouvernées par des équations dynamiques¹² qui créent un couplage (contraintes égalités) entre les instants. Ainsi, la décision de (dé)stocker de l’énergie à un instant donné influe sur la possibilité d’en (dé)stocker aux instants suivants. On peut faire l’analogie avec une situation de la vie courante qu’est la gestion d’un budget : on évite de dépenser tout l’argent de son compte courant sans penser aux mois suivants.

La gestion optimale d’énergie entre donc dans la classe des problèmes d’*optimisation dynamique* aussi appelée *contrôle optimal*. La résolution peut donc faire appel à un certain nombre de méthodes spécialisées, en particulier basées sur le principe du maximum de Pontryagin et sur le principe d’optimalité de Bellman (Programmation Dynamique). Nous ne détaillerons pas ces méthodes, car nous allons voir immédiatement que le caractère *stochastique* du problème le spécialise davantage et élimine donc un grand nombre de méthodes.

Prise en compte de l’incertitude des entrées Nous avons considéré les erreurs de prévisions comme une entrée incertaine de nos modèles, en utilisant des modèles probabilistes (cf. 1.3.2).

12. équations différentielles telles que (1.2) en temps continu ou bien équations aux différences en temps discret

En effet, le niveau d'erreur moyen que l'on constate généralement semble trop grand (5 à 30% de la puissance nominale) pour permettre un traitement déterministe. Le caractère *stochastique* des entrées influe sur deux activités qui sous-tendent nos études : la simulation et l'optimisation.

1. Les simulations temporelles, nécessaires pour évaluer la performance d'un système non linéaire tel qu'un stockage, deviennent des simulations *Monte Carlo*. Il s'agit de les répéter un grand nombre de fois pour collecter non plus *une valeur* des variables d'intérêt, mais des *échantillons de valeurs* de ces variables. Ces échantillons sont analysés statistiquement, en particulier avec des calculs de moyennes et de quantiles.
2. L'optimisation ne cherche plus à minimiser la valeur d'une fonction coût, mais son *espérance*, car le coût devient une variable aléatoire. Nous avons abordé ce problème dit d'optimisation dynamique stochastique (aussi appelé contrôle stochastique) par la méthode de la Programmation Dynamique de Bellman [8] car elle se décline très naturellement dans le cas stochastique (abrégée SDP). Nous détaillerons cette méthode, ses algorithmes, ainsi que certaines méthodes alternatives dans la partie 3.1.

Nous pointons donc l'impact algorithmique fort qu'a la prise en compte de l'incertitude des entrées. Pour la partie simulation, nous avons développé "StorageSim", un petit outil logiciel dédié à la simulation vectorisée de trajectoires pour des systèmes de stockage (outil présenté en 2.5). Pour l'optimisation, nous avons implémenté des algorithmes de la SDP dans "StoDynProg", une petite bibliothèque d'optimisation dynamique présentée à la conférence EuroSciPy [50] et au chapitre 3.

Interaction entre dimensionnement & gestion Les méthodes usuelles du contrôle optimal proposent de maximiser la performance d'un système donné en jouant sur sa commande, mais sans toucher au modèle du système : la conception est considérée comme fixe. Pourtant, lors du dimensionnement d'un stockage, la conception est, par principe, ouverte au changement. Ainsi, obtenir la meilleure performance nécessite de résoudre un problème d'*optimisations couplées* : optimiser le dimensionnement et la gestion. D'un point de vue théorique, Fathy *et al.* [42] montrent que l'optimum d'un problème générique de "plant/controller optimization" ne peut être atteint que par une approche couplée, et non séquentielle. D'un point de vue pratique, la co-optimisation peut se conduire de deux manières, toutes deux validées théoriquement :

- co-optimisation *simultanée* : approche décrite par Fathy *et al.* [42] comme difficile, au moins du point de vue analytique, car le problème est à la fois statique et dynamique. Du point de vue numérique, nous ne connaissons pas d'algorithmes permettant de mettre en œuvre l'approche simultanée.
- co-optimisation *imbriquée* : le dimensionnement est optimisé en "boucle externe" de la gestion, c'est-à-dire que, pour chaque dimensionnement considéré, il faut optimiser une loi de gestion ("boucle interne"). Cette approche se met donc en œuvre avec une structure algorithmique simple : deux boucles d'optimisation imbriquées (mais indépendantes).

Structurellement simple, la co-optimisation imbriquée est pourtant rarement mise œuvre, car elle *multiplie* la complexité calculatoire de chacune des deux optimisations. Le temps de calcul peut donc devenir prohibitif. Par conséquent, les systèmes de stockage sont couramment dimensionnés avec une loi de gestion donnée, quitte à itérer¹³. C'est d'ailleurs ce que nous avons fait pour une bonne part de notre travail [52, 53]. L'idée empirique sous-jacente est que si la loi de

13. co-optimisation *itérative* pour laquelle Fathy *et al.* [42] montrent que la convergence vers l'optimum n'est pas garantie

gestion fixée a priori est “assez bonne”, alors le résultat obtenu ne doit pas être “trop loin” de l’optimum.

À la suite de ces travaux, nous avons voulu sonder la validité de cette approche empirique. Pour cela, nous avons étudié quantitativement l’effet du couplage dimensionnement-gestion sur un exemple simple de problème de stockage [51]. Dans ce travail présenté partie 4.3, nous observons que, selon la façon dont le problème est posé (choix du critère de dimensionnement), le choix d’une loi de gestion non optimale pour le dimensionnement peut avoir *ou non* un fort impact sur le résultat.

Parfois, le dimensionnement est tout de même co-optimisé avec la gestion, souvent en réduisant la complexité du problème de gestion. Comme Rigo-Mariani *et al.* [89], on peut choisir de *négliger l’aspect stochastique*, ce qui aboutit à un problème d’optimisation dynamique déterministe, certes de grande taille, mais dont on ajuste la structure pour que le calcul de l’optimum soit efficace (avec des routines de programmation linéaire ou quadratique par exemple). Une autre approche courante est de *paramétrer* la loi de gestion comme Aubry *et al.* [5] le font pour la loi de couple de récupération d’un houlogénérateur. La paramétrisation a pour défaut de forcer la loi de gestion à appartenir à une famille arbitraire. L’approche de Kim *et al.* [61] pour un véhicule hybride hydrogène + batterie va un cran plus loin : leur loi de gestion est paramétrisée suivant une forme issue de résultats d’optimisation dynamique (contrôleur “pseudo SDP”). Cette approche nous paraît très intéressante, car elle permet une (quasi) optimalité du résultat tout en gardant une complexité calculatoire raisonnable. C’est l’approche retenue pour la gestion avec tolérance d’écart à l’engagement (§3.3.3 et 4.3).

Nous avons décrit le contexte de l’insertion des EnR dans les réseaux insulaires, et plus spécifiquement le contexte industriel suscité par l’appel d’offres éolien-stockage de la CRE. Nous avons ainsi dégagé la problématique d’étude suivante : “Comment *dimensionner* et comment *gérer* le système éolien-stockage?”, pour garantir un engagement de production à fournir un jour à l’avance au gestionnaire du réseau.

Nous avons ensuite décrit les enjeux et difficultés associés à cette problématique. Ainsi, nous avons organisé les chapitres à venir pour répondre graduellement à ces difficultés :

- Chapitre 2, nous abordons toutes les modélisations qui servent dans les chapitres suivants. Ces modélisations concernent des *composants* (systèmes de stockage d’énergie), des *phénomènes* (vieillessement en cyclage des batteries) et des *entrées du système* (production éolienne, erreur de prévision de production). Pour les entrées, nous focalisons notre étude sur la modélisation de leur caractère stochastique.
- Chapitre 3, nous abordons la gestion optimale de l’énergie d’un système de stockage, en prenant en compte le caractère incertain des entrées. Cela nous amène à traiter la gestion d’énergie dans un cadre d’optimisation dynamique stochastique. Nous présentons la méthode de résolution de la programmation dynamique stochastique (SDP).
- Chapitre 4, nous abordons pour finir le dimensionnement d’un système de stockage, toujours dans un contexte éolien où les entrées sont incertaines. Nous y ajoutons une étude du *couplage* entre gestion et dimensionnement.

Chapitre 2

Modélisations

“Quand la main tient un marteau, même les vis ressemblent à des clous”¹

Sommaire

2.1	Modélisations énergétiques de systèmes de stockage	30
2.2	Modélisation du vieillissement	42
2.3	Modélisation stochastique de l’erreur de prévision	53
2.4	Modélisation des variations rapides de puissance éolienne	62
2.5	Intégration logicielle des modèles : StorageSim	69

Nous présentons dans ce chapitre différentes briques de modélisation utiles pour gérer (chapitre 3) et dimensionner (chapitre 4) un système de stockage d’énergie (abrégé ci-après par “stockage”). Nous suivons les besoins établis au chapitre précédent (§ 1.3.1 et 1.3.2) : modélisation énergétique des systèmes de stockage, en particulier des batteries (§2.1), modélisation du vieillissement des batteries (§2.2) et modélisation des entrées incertaines (production et prévision éoliennes) aux parties 2.3 et 2.4.

Comme nous souhaitons réaliser des simulations numériques et des calculs numériques d’optimisation dynamique, nos modèles de systèmes dynamiques sont essentiellement :

- *temporels* (par opposition à fréquentiels) à cause du caractère non linéaire des systèmes modélisés. La saturation d’un stockage est un exemple de non-linéarité fondamentale de notre problème. En outre, nos problèmes d’optimisation s’expriment temporellement.
- à *temps discret* (par opposition à temps continu) pour s’intégrer directement dans une boucle de simulation (au lieu de passer par une routine d’intégration d’ODE²). De plus, l’optimisation par la Programmation Dynamique s’écrit et se met en œuvre aisément en temps discret. Enfin, les processus stochastiques à temps continu nécessitent des outils analytiques (e.g. l’intégrale d’Itô) qui nous semblent nettement plus compliqués.

Nous terminons ce chapitre par une présentation de l’outil logiciel StorageSim que nous avons créé pour rassembler la plupart de nos modèles. Ce code de simulation de stockage a pour objectif la modularité et la souplesse. Il permet par exemple de passer facilement d’un modèle de batterie idéal à un modèle avec pertes non linéaires.

1. variation en forme de proverbe chinois sur le “Marteau de Maslow” (*I suppose it is tempting, if the only tool you have is a hammer, to treat everything as if it were a nail.* Abraham Maslow (1966), *The Psychology of Science.*)

2. Ordinary Differential Equation : équation différentielle ordinaire, c’est-à-dire à une seule variable (pas de dérivées partielles), donnée sous forme explicite (e.g. sans contraintes algébriques).

2.1 Modélisations énergétiques de systèmes de stockage

Comme indiqué partie 1.3.1, nous avons utilisé des modèles de stockage relativement simplifiés. Nous les séparons en deux types :

- un modèle idéal, où le système n’est représenté que comme un stock d’énergie limité par deux bornes ($0 \leq E_{sto} \leq E_{rated}$), avec éventuellement une limite de puissance ($-P_{rated} \leq P_{sto} \leq P_{rated}$). Ce modèle permet d’étudier le comportement d’un stockage du seul point de vue de ses dimensions nominales (E_{rated}, P_{rated}), faisant abstraction de toutes pertes (d’où le caractère “idéal”).
- des modèles électriques quasi statiques, où la tension aux bornes d’une cellule est une fonction (de forme quelconque) de la charge Q_{cell} , du courant I_{cell} et éventuellement de la température T .

Ces modèles, plus détaillés, permettent de calculer des pertes réalistes, car basées sur une connaissance technologique, plutôt que d’appliquer un coefficient de pertes fixe (“rendement constant”) de valeur arbitraire.

Par ailleurs, nous n’avons pas pris en compte les effets d’assemblage qui peuvent apparaître lors de la mise en série-parallèle de cellules pour construire un module : déséquilibre des cellules, variabilité des cellules, gradient de température au sein du module. Nous supposons donc implicitement une *homogénéité* parfaite : toutes les cellules d’un module sont à la même température, ont la même charge et la même tension.

2.1.1 Stockage idéal

Il s’agit d’un modèle dynamique avec une seule variable d’état : l’énergie stockée E_{sto} . L’équation dynamique correspond à la discrétion de l’équation (1.2) :

$$E_{sto}(k+1) = E_{sto}(k) + P_{sto}(k)\Delta_t \quad (2.1)$$

où $P_{sto}(k)$ représente la puissance moyenne absorbée entre les instants k et $k+1$.

La contrainte (1.4) qui limite l’énergie stockable dans l’intervalle $[0, E_{rated}]$ se traduit alors par une limite sur la puissance absorbable :

$$\frac{-E_{sto}(k)}{\Delta_t} \leq P_{sto}(k) \leq \frac{E_{rated} - E_{sto}(k)}{\Delta_t} \quad (2.2)$$

À cette contrainte énergétique, il faut ajouter éventuellement la contrainte sur la puissance maximale (1.3). $P_{sto}(k)$ doit alors appartenir à l’union de l’intervalle autorisé par (2.2) et de $[-P_{rated}, P_{rated}]$.

Nous avons retenu cette écriture où $P_{sto}(k)$ est *explicitement* limitée pour l’utilisation en optimisation (chapitre 3), car cela permet de restreindre naturellement l’espace de recherche d’un optimum de puissance à absorber.

Écriture sans contrainte explicite Dans une utilisation en simulation [52], nous avons trouvé plus simple, voire plus “physique”, d’utiliser une écriture ne faisant pas mention explicite de la contrainte énergétique (2.2). Nous faisons émerger la notion de “*consigne idéale de stockage*”, qui est la puissance que l’on souhaiterait voir absorbée si le stock d’énergie n’était pas limité. Nous la notons P_{sto}^* . L’équation dynamique du stockage s’écrit alors :

$$E_{sto}(k+1) = f_{sat}\left(E_{sto}(k) + P_{sto}^*(k)\Delta_t\right) \quad (2.3)$$

où f_{sat} est une fonction de saturation définie par :

$$f_{sat}(E) = \begin{cases} 0 & \text{si } E < 0 \\ E & \text{si } 0 \leq E \leq E_{rated} \\ E_{rated} & \text{si } E > E_{rated} \end{cases} \quad (2.4)$$

Cette fonction peut être vue comme une boucle de régulation rapprochée qui assure que l'énergie stockée ne sort pas de sa plage autorisée. Au final, la puissance P_{sto} qui est effectivement absorbée doit être calculée *a posteriori* :

$$P_{sto}(k) = \frac{E_{sto}(k+1) - E_{sto}(k)}{\Delta_t} \quad (2.5)$$

et il y a égalité entre la consigne P_{sto}^* et sa réalisation P_{sto} tant que la saturation (batterie pleine ou vide) n'est pas atteinte.

Intérêt du modèle Malgré l'apparente simplicité d'une dynamique linéaire (2.1), la limite en énergie (1.4) rend le modèle *non linéaire* (2.3). Cette non-linéarité empêche beaucoup d'études analytiques. Nous pensons que ce caractère *limité* du stock d'énergie est au fondement du problème du stockage. À défaut d'études analytiques, nous procédons donc à des simulations numériques (présentées au chapitre 4) qui mettent en évidence des propriétés associées à la seule capacité E_{rated} .

Prise en compte des pertes Avec ce modèle idéal, la prise en compte de pertes peut se faire avec un coefficient de pertes fixe ($P_{loss} = \alpha |P_{sto}|$, avec par exemple $\alpha = 10\%$). Cependant, les technologies de stockage ont souvent des pertes qui dépendent de l'état de charge ou bien qui ne sont pas proportionnelles à la puissance absorbée (e.g. les pertes par effet Joule). Enfin, et surtout, les pertes sont très souvent dépendantes de la capacité du stockage.

Ainsi, pour la prise en compte des pertes, il nous a semblé plus naturel de reformuler le problème en faisant intervenir la variable d'état qui est sous-jacente à l'énergie stockée : la charge Q_{cell} d'une cellule. C'est, par opposition à l'énergie E_{sto} , la variable usuelle pour modéliser les stockages de type électrochimique.

2.1.2 Batterie Lithium-ion

Nous avons modélisé une batterie Lithium-ion d'après les relevés expérimentaux effectués par Yaël Thiaux pendant ses travaux de thèse [95]. Comme le modèle est basé numériquement sur ces relevés, il est spécifique à la technologie³ et au modèle étudié. Par contre, le modèle est *générique* dans sa structure. En effet, nous l'avons conçu pour qu'il puisse représenter sans modifications structurelles une large palette de systèmes de stockage d'électricité, y compris les super-condensateurs. Il suffit à l'utilisateur de fournir la fonction $V(I_{cell}, Q_{cell})$ qui caractérise la tension aux bornes d'un élément. Nous commençons par présenter la structure du modèle avant de présenter les données associées aux batteries Lithium-ion.

3. technologie Lithium-ion NCA du fabricant SAFT : oxyde de Lithium Nickel Cobalt Aluminium à la cathode, graphite à l'anode.




FIGURE 2.1 – Assemblage de cellules et modèle électrique

Structure du modèle Le modèle de batterie est construit autour d'une cellule électrochimique qui est modélisée électriquement (tension, courant et charge). Cette cellule a une capacité fixe. Pour rendre le dimensionnement énergétique (E_{rated}) du stockage *ajustable*, nous considérons que la batterie est un assemblage homogène de n cellules (cf. figure 2.1). Ce nombre ajustable de cellules n'est pas nécessairement entier ($n \in \mathbb{R}_+$), car il s'agit d'une *mise à l'échelle* purement *numérique*, sans prise en compte d'une organisation physique (série-parallèle) des cellules.

Modèle électrique de cellule Électriquement, le modèle est *quasi statique*, c'est-à-dire que nous ne modélisons pas de chute de tension capacitive (associée à des phénomènes de diffusion). Autrement dit, le modèle n'a qu'une seule variable d'état : la charge Q_{cell} , ou de façon équivalente l'énergie stockée E_{sto} (cf. relation entre les deux ci-après : (2.10)). Cela suppose que la batterie soit utilisée en un régime quasi statique : pas de fluctuations rapides du courant. En particulier, le pas de temps Δ_t du modèle est supposé égal à quelques minutes ou plus.

En cohérence avec notre modèle énergétique idéal, nous utilisons la *convention récepteur* pour orienter le courant. L'évolution de la charge est donc analogue à celle de l'énergie (2.1) :

$$Q_{cell}(k+1) = Q_{cell}(k) + I_{cell}(k)\Delta_t \quad (2.6)$$

La tension V aux bornes d'une cellule, conformément à l'hypothèse quasi statique, est une fonction de la charge et du courant absorbé par la cellule. Cette caractéristique de tension, fournie par l'utilisateur, est généralement séparée en deux termes : la *tension à vide*⁴ et la *chute de tension*⁵ due au passage du courant :

$$V(I_{cell}, Q_{cell}) = V_0(Q_{cell}) + \Delta V(I_{cell}, Q_{cell}) \quad (2.7)$$

Cette décomposition est représentée schématiquement figure 2.1. Elle a un fort sens *énergétique* : la source de tension V_0 échange de l'énergie de façon réversible (sans pertes) alors que la chute de tension dissipe une puissance $\Delta V \times I$. On peut donc établir la relation énergétique suivante, en prenant en compte la mise à l'échelle par le nombre n de cellules :

$$P_{sto} = nV \times I = \underbrace{nV_0 \times I}_{\text{puissance stockée}} + \underbrace{n\Delta V \times I}_{\text{puissance dissipée } P_{loss}} \quad (2.8)$$

4. aussi appelée force électromotrice (fém, emf en anglais), ou open-circuit voltage (ocv) en anglais

5. aussi appelée polarisation ou surtension dans un contexte électrochimiste, mais ce dernier terme est ambigu dans un contexte électricien

Nous avons souhaité que la fonction $V(I_{cell}, Q_{cell})$ soit arbitraire, car cela correspond bien aux relevés expérimentaux présentés après. Cela n'exclut pas d'utiliser des formes particulières. Par exemple, un cas usuel est celui d'une chute de tension ohmique, c'est-à-dire *proportionnelle* au courant : $\Delta V(I_{cell}, Q_{cell}) = R_{cell}(Q_{cell}) \times I_{cell}$. La résistance interne R_{cell} peut dépendre de l'état de charge, comme c'est le cas pour la batterie Sodium-Soufre (§2.1.3).

Modèle thermique Pour l'aspect thermique, nous nous plaçons dans le cadre des batteries *thermorégulées*. En effet, les batteries stationnaires sont souvent placées dans des enceintes climatisées, afin de fixer leur comportement (e.g. leur résistance interne) et d'augmenter leur durée de vie. En conséquence, nous supposons que la température est *constante*, ce qui explique qu'elle n'apparaisse pas dans l'équation de la tension (2.7). Si l'on souhaite modéliser l'effet de la température, car il est souvent important avec les batteries, il suffit d'étendre ce modèle en ajoutant la température comme variable d'état supplémentaire : c'est le cas du modèle de la batterie Sodium-Soufre. La difficulté est moins dans la programmation que dans l'accès à des données qui indiquent *comment* les paramètres (fém et chute de tension) varient avec la température.

Comme nous supposons la batterie thermorégulée, nous modélisons la puissance électrique absorbée par le système de climatisation. Celui-ci doit extraire la puissance dissipée P_{loss} ainsi que le flux thermique provenant de l'extérieur $(T_{out} - T)/R_{th}$, comme illustré figure 2.2. Pour extraire ces flux, le bloc de climatisation doit absorber une puissance électrique

$$P_{clim} = \frac{1}{EER} \left(P_{loss} + \frac{1}{R_{th}} (T_{out} - T) \right) \quad (2.9)$$

où EER^6 représente le coefficient d'efficacité de la climatisation. Il dépend de l'appareil ainsi que de ses conditions de fonctionnement (e.g. les températures). Même s'il n'y a pas de véritable modélisation thermique dans notre modèle, l'estimation de P_{clim} est importante, car cette consommation s'ajoute aux pertes de la batterie P_{loss} pour calculer le *coût de l'énergie perdue* par le système de stockage dans son ensemble.

Conversion énergie ↔ charge, puissance ↔ courant Le fait de travailler en parallèle avec des grandeurs énergétiques (E_{sto} , P_{sto}) et coulombiennes (Q_{cell} , I_{cell}) oblige à définir comment passer des unes aux autres, car cette conversion est nécessaire en permanence (à chaque pas de simulation).

Nous définissons l'énergie stockée dans une batterie comme l'énergie *utile*. Ainsi, supposant que la charge est limitée dans un intervalle $[Q_{min}, Q_{max}]$, nous posons

$$E_{sto}(Q_{cell}) = n \int_{Q_{min}}^{Q_{cell}} V_0(Q) dQ \quad (2.10)$$

ce qui implique que $E_{sto}(Q_{min}) = 0$ et que $E_{sto}(Q_{max}) = E_{rated}$. Comme la tension à vide V_0 est une fonction arbitraire de l'état de charge, l'intégrale est calculée numériquement pour former une table $Q_{cell} \mapsto E_{sto}$. Cette table, interpolée linéairement, est alors utilisée pour calculer l'énergie stockée à partir de la charge (et réciproquement).

Pour la conversion puissance ↔ courant, l'équation (2.8) nous en donne directement la relation $I_{cell} \mapsto P_{sto}$ (relation qui dépend de la charge). Obtenir la réciproque est plus difficile, car il faut résoudre l'équation non linéaire

6. Energy Efficiency Ratio, qui figure sur l'étiquette-énergie l'Union Européenne

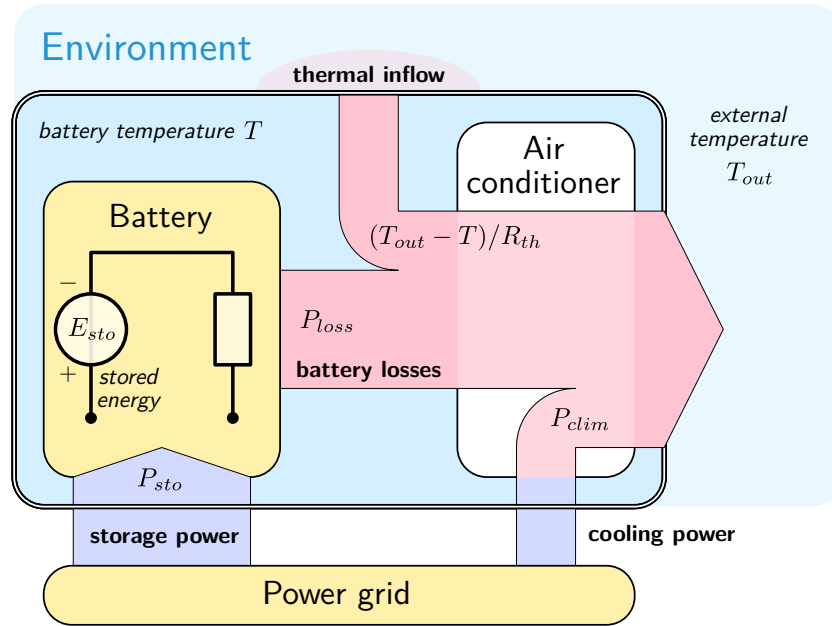


FIGURE 2.2 – Flux d'énergie d'une batterie avec climatisation (les fuites thermiques sont représentées dans le cas d'une température extérieure supérieure à la température du conteneur)

$$I_{cell} = \frac{P_{sto}}{nV(I_{cell}, Q_{cell})} \quad (2.11)$$

On obtient facilement une solution approchée en approximant la tension de cellule par la tension à vide : $I_{cell} \approx \frac{P_{sto}}{nV_0(Q_{cell})}$. Comme l'équation (2.11) doit être résolue à chaque pas de simulation⁷, il ne nous a pas paru opportun de faire appel à une routine de résolution numérique (temps de calcul, risque de non-convergence). Par contre, nous avons poussé la solution approximative un cran plus loin par une approche itérative du type "point fixe". Il suffit pour cela de remarquer que l'équation est, à charge fixée, du type " $I_{cell} = f(I_{cell})$ " et l'approximation par la fém correspond à $f(0)$. Si la solution est un point attracteur, alors on sait que l'application itérée de la fonction f converge vers la solution. Nous avons validé empiriquement que la convergence se passe bien. En fixant $I_{cell} = f^4(0) = f(f(f(f(0))))$, l'erreur commise dans le pire cas (courant de décharge "C/1h" avec batterie vide) est inférieure à 1 % dans le cas des données Lithium-ion que nous présentons à présent.

Analyse des données expérimentales Le modèle présenté nécessite que soit fournie la fonction $V(I_{cell}, Q_{cell})$, ce qui est en cohérence avec les données disponibles grâce aux essais expérimentaux effectués par Yaël Thiaux pendant sa thèse [95, pp 113–124]. Les essais ont porté sur des modules "Intensium 3" de SAFT (48 V / 45 Ah / 2 kWh / 25 kg) qui sont composés de 14 cellules en série "VL 45 E" (3,6 V / 45 Ah / 150 Wh / 1 kg) et incluent des protections électriques ainsi qu'un module de supervision. Les cellules sont de technologie Lithium-ion Nickel Cobalt Aluminium (NCA). Ce sont ces cellules que nous modélisons, ou pour être exact, une cellule moyenne correspondant à un quatorzième de module, ce qui prend en compte la connectique interne du module.

7. comme nos simulations Monte-Carlo sont vectorisées, avec 10^3 à 10^5 échantillons, il est très intéressant d'avoir une résolution vectorisée




FIGURE 2.3 – Mesures de la tension d’une cellule Lithium-ion, fonction de l’état de charge pour différentes valeurs du courant de charge/décharge, ainsi que la tension à vide (OCV)

Pour notre modélisation, nous avons récupéré les données de deux types d’expériences :

- un relevé de la tension à vide V_0 pour différents états de charge (répartis linéairement par incréments de 5%)
- des relevés de l’évolution de la tension lors de charge et de décharge à différents niveaux de courant (le plus faible : C/45h, le plus fort : C/5h)

Nous avons synthétisé ces relevés temporels de charge/décharge en un réseau de courbes $V^{(I_{cell})}(Q_{cell})$ présentées figure 2.3. On observe que la tension à vide (courbe grise) varie presque linéairement entre 3,3 V (état vide) et 4,0 V (état plein). Autour de la tension à vide, le courant augmente la tension (en charge) ou la diminue (en décharge) de ± 100 mV environ pour un courant C/5h, soit 9 A. Enfin, on observe une chute marquée de la tension en fin de décharge (SoC < 0.1).

L’étude fine de ces relevés montre que la tension à vide (fém) ne passe pas exactement au milieu des courbes de charge et de décharge. Cette légère incohérence tient à plusieurs raisons. Tout d’abord, la fém est difficile à mesurer précisément : le relevé consiste en une décharge par paliers et il est nécessaire de laisser relaxer la batterie après chaque variation de la charge. Ensuite, la définition de la tension à vide est rendue floue par la présence d’effets d’hystérésis : la mesure ne donne pas forcément le même résultat selon que le relevé se fait par paliers de charge ou décharge. On trouvera une discussion des différentes méthodes de mesures de la fém chez Pop *et al.* [85].

L’incertitude sur la mesure de fém n’est pas anodine lorsqu’il s’agit de calculer la chute de tension $\Delta V = V - V_0$. On observe par exemple que le calcul direct de cette différence aboutit à une résistance interne qui varie fortement avec l’état de charge et peut devenir négative [95, fig 5.14, p 120]. Nous pensons que ces variations de résistance sont pour partie des artefacts. Nous avons donc cherché une méthode de modélisation de la chute de tension qui s’affranchisse de la donnée incertaine de tension à vide.

Pour ce faire, nous avons retracé les données de tension sous forme de courbes $V^{(Q_{cell})}(I_{cell})$ (figure 2.4, à gauche). Cela permet de visualiser la dépendance au courant de la tension, à diffé-




FIGURE 2.4 – Tension de cellule Lithium-ion, fonction du courant pour différentes valeurs de l'état de charge. À droite, la chute de tension pour mettre en valeur la dépendance au courant

rents états de charge. La visualisation est meilleure lorsqu'on retranche l'ordonnée à l'origine⁸ pour observer la chute de tension $\Delta V^{(Q_{cell})}(I_{cell})$, calculée sans utiliser la fém (figure 2.4, à droite). Constatons que la variation due au courant est assez insensible à l'état de charge, sauf pour l'état le plus déchargé ($SoC = 0.1$).

La chute de tension semble une fonction non linéaire du courant : un modèle ohmique n'est pas adapté. Par contre, on observe une linéarité dans le domaine de la charge ($I > 0$) et dans le domaine de la décharge ($I < 0$). Enfin, il y a un décrochement en $I = 0$. D'après ces observations, nous choisissons donc le modèle suivant :

$$V(I_{cell}, Q_{cell}) = V_0(Q_{cell}) + \begin{cases} R_{ch}I_{cell} + V_\delta & \text{si } I_{cell} \geq 0 \\ R_{dis}I_{cell} - V_\delta & \text{si } I_{cell} < 0 \end{cases} \quad (2.12)$$

où les résistances R_{ch} et R_{dis} valent respectivement $5 \text{ m}\Omega$ (en charge) et $9 \text{ m}\Omega$ (en décharge). Le décalage de tension V_δ vaut 20 mV . Par analyse visuelle de l'adéquation du modèle aux données, la précision des valeurs de résistance est estimée empiriquement à $\pm 1 \text{ m}\Omega$ et la précision absolue du modèle de chute de tension à $\pm 10 \text{ mV}$. Ce modèle est valable sur la plage de SoC [10%, 100%] et sur la plage de courant $\pm 9 \text{ A}$ (C/5h). Pour le modèle de fém $V_0(Q_{cell})$, nous choisissons une *interpolation* linéaire des données de tension à vide disponibles.

Finalement, nous traçons les courbes de tension issues du modèle (2.12) sur la figure 2.5. Nous observons une bonne adéquation aux données (fig. 2.3), à la fois en termes de tension absolue et aussi en chute de tension. Il y a, comme prévu, une mauvaise modélisation des décharges à faible état de charge, car l'augmentation de la résistance à faible état de charge n'est pas prise en compte.

Pour comparer, nous avons ajouté une courbe de tension issue de la datasheet SAFT de 2005 pour les cellules VL45E (figure 2.6). Remarquons que les courants utilisés sont beaucoup plus grands que ceux de Thiaux [95] (C/5h max). Analysons par exemple les courbes de décharge C/1h (45 A) et C/3h (15 A) : la chute de tension entre les deux courbes est d'environ 100 mV . Pourtant, notre modèle avec résistance de décharge à $9 \text{ m}\Omega$ prévoit $9 \cdot 10^3 \times (45 - 15) = 270 \text{ mV}$.

8. précisément, nous retranchons le coefficient constant a_0 d'une régression linéaire $V \sim a_0 + a_1 I$, conduite pour chaque état de charge. On peut interpréter le coefficient a_0 comme une définition "statistique" de la fém.




FIGURE 2.5 – Modèle de tension de cellule Lithium-ion fonction de l'état de charge pour différentes valeurs du courant de charge/décharge, à comparer aux données expérimentales de la figure 2.3




FIGURE 2.6 – Tension de cellule Lithium-ion, fonction de l'état de charge pour différents courants de décharge, d'après la datasheet du fabricant SAFT

Nous déduisons donc que notre modèle surestime la chute de tension (et donc les pertes) pour les forts courants, même s'il y a sans doute des différences de conditions expérimentales. Nous n'avons malheureusement pas de données supplémentaires pour prendre en compte ces régimes intenses ($I_{cell} > C/3h$).

2.1.3 Batterie Sodium-Soufre (NaS)

Présentation rapide Démarré à la fin des années 60 pour des véhicules électriques, le développement des batteries NaS a été poursuivi dans les années 80 par Tokyo Electric Power Company (TEPCO) pour un usage stationnaire. Elles sont aujourd'hui commercialisées par le fabricant NGK Insulators, Ltd., partenaire de TEPCO, et de nombreuses mises en service ont eu lieu dans les années 2000 [12]. Parmi les plus grosses installations, signalons un système éolien-stockage de pas moins de 34 MW, pour une ferme de 51 MW au nord de Honshū au Japon[60]. Il s'agit de *batteries chaudes*, fonctionnant autour de 300–350 °C.



FIGURE 2.7 – Batterie NaS de 7.2 MWh/1 MW installée en 2009 par EDF sur l'île de La Réunion. (on aperçoit les 20 modules de 350 kWh à l'intérieur du bâtiment)

Source : Stéphane Lascaud, EDF R&D

Nous avons implémenté un modèle de batterie Sodium-Soufre, car EDF dispose depuis 2009 d'une batterie NaS NGK de 7.2 MWh/1 MW à La Réunion (photo en figure 2.7). Ce modèle a été présenté à la conférence PowerTech [53].

Notre modélisation, de type thermo-électrique, est basée sur les articles de Hussien *et al.* [58] qui ont travaillé avec des données de TEPCO en Malaisie. Nous utilisons des données NGK fournies à EDF sous accord de non-divulgateion et il peut donc y avoir quelques légères différences avec les courbes de Hussien, mais l'esprit reste le même. Toutefois, nous donnons plus de précisions sur la modélisation thermique par recoupement avec d'autres sources. De par la confidentialité, l'implémentation que nous avons réalisée de ce modèle n'est pas disponible dans notre programme StorageSim et nous omettons ici quelques aspects et valeurs numériques considérés comme sensibles et non publiés dans la littérature.

La figure 2.10 donne un aperçu des flux d'énergie, à la fois *électrique* et *thermique*, du modèle. Cette représentation permet de visualiser comment l'énergie est transformée, stockée et en partie perdue dans la batterie NaS. Comme expliqué plus loin, la prise en compte de la température est particulièrement importante avec cette technologie (batterie chaude).

Parce que ce modèle a été réalisé avant le modèle générique présenté précédemment (partie Lithium-ion 2.1.2), certaines notations sont différentes. En particulier, le "vocabulaire NaS" utilise la profondeur de décharge (Depth of Discharge DoD) d'une cellule au lieu de la charge Q_{cell} . La DoD au sens NGK est homogène à une charge (Ah), vaut zéro lorsque la cellule est pleine, et s'incrémente à mesure que la cellule se décharge : la DoD est le complémentaire de Q_{cell} . Par ailleurs, la tension à vide V_0 d'une cellule est notée e_{cell} .

Structure du modèle Une batterie NaS est composée de N modules, représentés figure 2.8. Chaque module NGK (350 kWh/50kW) est composé d'un arrangement série-parallèle de $n_s \times n_p = 32 \times 12 = 384$ cellules NaS. Nous ne détaillerons pas la structure interne d'une cellule, mais nous avons reproduit un schéma figure 2.9. On trouvera chez Oshima *et al.* [77] plus de détails, en particulier sur l'électrolyte solide en β -alumine qui est un savoir-faire clé de NGK.

Notre modèle s'appuie sur la structure modulaire des batteries NaS et fonctionne en interne à l'échelle d'un module (tout comme notre modèle Lithium-ion fonctionne à l'échelle d'une cellule).




FIGURE 2.8 – Assemblage de cellules et modèle électrique de la batterie NaS

En supposant un parfait équilibrage entre les modules, nous divisons le flux d'énergie à stocker ($P_{mod} = P_{sto}/N$) pour réaliser le changement d'échelle de la batterie complète vers un module.

Dès lors, le dimensionnement de notre modèle (capacité E_{rated}) est parfaitement ajustable, en changeant simplement en interne le nombre⁹ de modules N . Remarquons que la puissance et l'énergie nominales varient proportionnellement : le rapport "E/P" est fixé à 7 heures de par le dimensionnement (géométrique) des cellules NGK.

Par ailleurs, la modélisation électrique (tension à vide e_{cell} et résistance R_{cell}) est spécifiée pour une cellule, et non pour un module. Nous avons donc des relations de passage pour les variables électriques, en supposant une répartition équilibrée des courants ($I_{cell} = I_{mod}/n_p$) et des tensions ($e_{cell} = e_{mod}/n_s$). Enfin, $R_{mod} = R_{cell} n_s/n_p$.

Synthétiquement, notre modèle est un modèle d'état basé sur 3 variables d'état :

- DoD (en Ah), la profondeur de décharge d'une cellule NaS
- T (en °C), la température d'un module NaS
- N_{cycles} , le nombre de "cycles pleins équivalents" qui représente le vieillissement en cyclage

Modèle électrique d'une cellule NaS Comme Hussien *et al.*, nous modélisons la cellule NaS par une source de tension e_{cell} et une résistance interne R_{cell} qui modélise la chute de tension ΔV (voir figure 2.8). Par rapport au modèle Lithium-ion, il y a donc l'hypothèse que la chute de tension est proportionnelle au courant. Par contre, la complexité de modèle est plus grande, car ce modèle de tension dépend non seulement de la charge (DoD), mais aussi de la température et du vieillissement.

La figure 2.9 illustre la dépendance fortement non linéaire de la résistance avec la DoD et la température. Par ailleurs, la résistance augmente avec le vieillissement en cyclage, proportionnellement à $\sqrt{N_{cycles}}$ [58, fig. 4]. La tension à vide est elle constante à 2.075 V lorsque la cellule est chargée, puis décroît linéairement avec la DoD [58, fig. 5].

La dynamique de la DoD est une équation de comptage de charge analogue à (2.6) :

$$DoD(k+1) = DoD(k) - I_{cell}(k) \cdot \Delta t \quad (2.13)$$

où nous notons que, comme pour nos autres modèles de batterie, la convention récepteur est utilisée : le courant est positif lorsque la batterie se charge.

9. Comme pour le modèle Lithium-ion, le nombre de modules N n'est pas considéré comme forcément entier. Cette approximation est raisonnable lorsque $N \gg 1$ et c'est le cas à La Réunion avec $N = 20$.

2 Modélisations




FIGURE 2.9 – En haut : résistance interne d’une cellule NaS, fonction de la profondeur de décharge, température de module et du sens du courant. En bas : tension à vide d’une cellule. À droite : schéma structurel d’une cellule NaS, reproduit de Bito [12].

La dynamique des “cycles pleins équivalents”, qui modélise le vieillissement en cyclage, est présentée ici par souci de cohérence, mais ce comptage du type “Ah throughput” [11, §4] sera expliqué plus précisément dans la partie 2.2 consacrée au vieillissement. L’incrémentation se fait avec le transit de charge $I\Delta_t$, compté en valeur absolue :

$$N_{cycles}(k+1) = N_{cycles}(k) + \frac{|I_{cell}(k)|\Delta_t}{2C_{cell}} \quad (2.14)$$

où C_{cell} est la capacité utilisable de la cellule NaS (~600 Ah). Cette équation modélise le vieillissement dû au cyclage (effet d’un courant non nul), par contre le vieillissement calendaire (dû au temps, en l’absence de courant) n’est pas pris en compte dans cette équation. Le fabricant NGK garantit la batterie pour 5000 cycles, avec une durée de vie calendaire de 15 ans.

Modèle thermique d’un module NaS Par rapport à notre modèle Lithium-ion, le changement clé pour la NaS est l’ajout d’une modélisation thermique.

La modélisation thermique est particulièrement importante car la température fait fortement varier la résistance interne, et donc le rendement (figure 2.9). La modélisation des flux thermiques (figure 2.10) s’effectue à l’échelle d’un *module*, car il contient ses 384 cellules dans une enveloppe thermiquement isolée par du vide [12, fig. 2]. Rempli de sable entre les cellules, un module pèse environ 3 tonnes. En utilisant la valeur typique de 1 kJ/K/kg pour la chaleur massique, nous arrivons à une capacité thermique de $C_{th} = 3$ MJ/K pour le module, en concordance avec d’autres observations. La dynamique de la température fait intervenir 4 flux thermiques :

$$C_{th} \frac{dT}{dt} = R_{mod} I_{mod}^2 - V_l I_{mod} - P_0 \frac{T - T_{out}}{T_0 - T_{out}} + P_{heat} \quad (2.15)$$




FIGURE 2.10 – Flux d'énergie (électrique et thermique) du modèle de batterie NaS, représentés pendant la charge

Tout d'abord, les pertes Joule génèrent une puissance $R_{mod}I_{mod}^2$. Ensuite, un flux réversible de chaleur latente est créé par la réaction de charge-décharge. Ce flux sortant $V_l I_{mod}$ est proportionnel au courant (\propto vitesse de réaction) et le terme entropique [62] V_l est positif : la charge d'une NaS ($I_{mod} > 0$) est une réaction endothermique alors que la décharge ($I_{mod} < 0$) est exothermique. Numériquement, $V_l \approx 50 \text{ mV} \times n_s$ pour une cellule pleinement chargée et monte à 100 mV lorsqu'elle est déchargée [62, fig. 4]. Enfin, une partie de la chaleur fuit vers l'extérieur, selon un modèle linéaire $\propto (T - T_{out})$ et un chauffage électrique embarqué de quelques kW permet de maintenir la température en injectant une puissance $P_{heat} > 0$ ajustable. Le détail de la régulation thermique relève du savoir-faire du fabricant.

Conversion puissance \leftrightarrow courant Comme pour le modèle générique de batterie (§2.1.2), il est nécessaire de disposer de la relation de conversion puissance \mapsto courant. Alors que dans le cas générique il faut résoudre une équation non linéaire (2.11), le cas de la NaS est soluble analytiquement. En effet, la relation courant \mapsto puissance (2.8) prend une forme particulière (quadratique) :

$$P_{mod} = \underbrace{e_{mod} I_{mod}}_{\text{puissance stockée}} + \underbrace{R_{mod} I_{mod}^2}_{\text{puissance dissipée}} \quad (2.16)$$

où le premier terme, la puissance stockée chimiquement, est noté P_{sto}^{emf} sur la figure 2.10, et le deuxième terme P_{sto}^{Joule} . L'équation (2.16) s'inverse pour obtenir une relation puissance \mapsto courant analytique :

$$I_{mod}(P_{mod}) = \frac{P_{mod}}{e_{mod}} \frac{2}{1 + \sqrt{1 + 4R_{mod}P_{mod}/e_{mod}^2}} \quad (2.17)$$

dans laquelle on peut noter l'approximation $I_{mod} \approx P_{mod}/e_{mod}$ lorsque la puissance est faible devant $e_{mod}^2/4R_{mod}$, (puissance maximale extractible).

Pertes de l'onduleur Le système de stockage NaS est fourni clé en main avec un onduleur pour convertir le courant continu (côté batterie) en courant alternatif (50 Hz côté réseau). Nous prenons en compte les pertes de l'onduleur, représentées en haut du diagramme des flux (2.10). A priori, les pertes dépendent de façon complexe du point de fonctionnement : pertes constantes dues aux auxiliaires, pertes dues aux commutations, pertes de conduction (termes linéaire et quadratique par rapport au courant). Cependant, en l'absence de données constructeur sur les pertes de l'onduleur, nous avons utilisé des pertes simplifiées à 5 % du flux $|P_{sto}^{DC}|$, ce qui revient à fixer (assez arbitrairement) le rendement de l'onduleur à 95 % environ.

2.2 Modélisation du vieillissement

Les systèmes de stockage, et en particulier les batteries électrochimiques, ont une durée de vie limitée, car ils s'usent par le passage du temps et par leur utilisation. Cette usure est bien connue pour les appareils électroniques portables, mais touche aussi les batteries stationnaires. Comme le vieillissement peut entraîner de coûteux remplacements, la prévision de la durée de vie est particulièrement importante pour l'optimisation économique du dimensionnement, objectif de nos travaux. Notons, comme Sauer *et al.* [91], qu'il faut distinguer :

- la prévision de durée de vie *en ligne*, qui a pour but de diagnostiquer la durée vie restante d'une batterie individuelle, au fur et à mesure de son utilisation.
- la prévision de durée de vie *a priori*, qui a pour but le dimensionnement et la planification du système. Elle prédit la tendance de vieillissement pour une batterie moyenne.

C'est ce dernier type de prévision qui concerne nos travaux. Après un tour d'horizon succinct du vieillissement des batteries, nous nous concentrons sur notre contribution : la formalisation du comptage de cycles sous forme de modèles dynamiques (travail réalisé pendant le stage de Samy Biyadi [13] que nous avons co-encadré).

2.2.1 Tour d'horizon

Effets du vieillissement Le vieillissement d'une batterie s'observe par une modification de ses caractéristiques et ces modifications vont généralement dans le sens d'une *baisse de performance*. Deux grandeurs importantes sont particulièrement surveillées : la *capacité*¹⁰, qui a tendance à diminuer et la *résistance interne*, qui a tendance à augmenter.

Il existe ainsi une *définition conventionnelle*, assez fréquemment utilisée, pour la fin de vie d'une batterie : diminution de 20% de la capacité ou augmentation de 100% de la résistance. Lorsqu'une de ces deux conditions est remplie, la batterie est considérée comme "bonne à changer". Notons que cette définition a émergé du contexte des véhicules électriques : la capacité conditionne l'autonomie alors que la résistance limite la puissance maximale que la batterie peut fournir. Dans un contexte stationnaire, cette définition n'est donc pas forcément adaptée, créant le

10. capacité énergétique ou coulombienne selon les points de vue

terreau des études de “seconde vie des batterie”, c’est-à-dire la réutilisation sur le réseau de batteries de véhicule usées [24].

Catégorisation Comme pour beaucoup de modèles, nous pouvons distinguer deux types de modèles de vieillissement :

- les modèles *de connaissance* (“boîte blanche”), basés sur la connaissance du fonctionnement interne physico-chimique du système, et d’autre part
- les modèles *de comportement* (“boîte noire”), basés sur une observation extérieure du comportement du système.

C’est cette dernière approche que nous choisissons, car les processus physico-chimiques à l’œuvre dans la dégradation d’une batterie sont compliqués. On pourra se référer à Broussely *et al.* [23], Vetter *et al.* [99] pour une description des phénomènes qui touchent chacun des composants (anode, cathode, électrolyte, ...) d’une cellule Lithium-ion. En outre, un modèle physico-chimique nécessite forcément un *grand nombre de paramètres liés à la structure interne* de la cellule, paramètres que quasiment seul le fabricant connaît. En conséquence, un modèle boîte blanche est, en pratique, inapplicable pour le non-spécialiste. Nous choisissons donc l’approche comportementale, s’appuyant exclusivement sur des données de test “facilement” disponibles, en particulier des courbes de tenue en cyclage (exemple figure 2.11).

Rappelons ensuite que le vieillissement est usuellement séparé en deux composantes ¹¹ :

- usure calendaire : dégradation du stockage en l’absence de sollicitation (au repos, $P_{sto} = 0$), par le simple “passage du temps”.
- usure en cyclage : dégradation supplémentaire du stockage lorsqu’il est sollicité ($P_{sto} \neq 0$).

Vieillessement calendaire L’usure calendaire dépend des conditions du repos, en particulier de la température et de l’état d’énergie (influence de la tension). Si ces conditions sont fixes, il est possible de s’appuyer sur un abaque. Par contre, si les conditions de repos varient, il peut être nécessaire de calculer dynamiquement le vieillissement calendaire. Cette approche dynamique est couramment utilisée pour le vieillissement des super-condensateurs [15, 66].

Concernant les batteries Lithium-ion, les données à notre disposition sur le vieillissement calendaire [69, fig. 5] montrent une forte influence de la température et de l’état d’énergie. La température est éliminée par le choix de climatiser les batteries (cf. modélisation partie 2.1.2). Pour l’état d’énergie, il faut par contre un modèle de vieillissement calendaire dynamique tel que celui de Kovaltchouk *et al.* [66]. Il est également possible de supposer que le SoE moyen est assez faible ¹² pour pouvoir négliger le vieillissement calendaire devant le cyclage et c’est ce que nous avons fait. Un modèle plus précis, validé par des données de test permettrait d’aller loin.

Pour la batterie NaS NGK, le fabricant garantit une durée de vie fixée à 15 ans (usure progressive irréversible due à la corrosion). Dans ce cas de figure, il n’y a pas de modèle de vieillissement calendaire à formaliser, juste un coût de remplacement à prendre en compte pour tout projet sur une durée supérieure à 15 ans.

11. Cette séparation usuelle pourrait faire oublier qu’en réalité les différents phénomènes physiques *interagissent*. Nous n’entrerons pas dans cette question complexe, mais relevons par exemple chez Ecker *et al.* [32, §7] que le cyclage pourrait *ralentir* le vieillissement calendaire : “[...] resistance increases much faster during storage, than under operation. In future work the relation between calendar and cycle life has to be investigated in more detail to account for this effect.” (technologie Li-ion NMC).

12. ce qui est souvent le cas dans une application EnR où l’on souhaite lisser ou garantir la production (à la différence des véhicules électriques qui sont souvent à pleine charge)

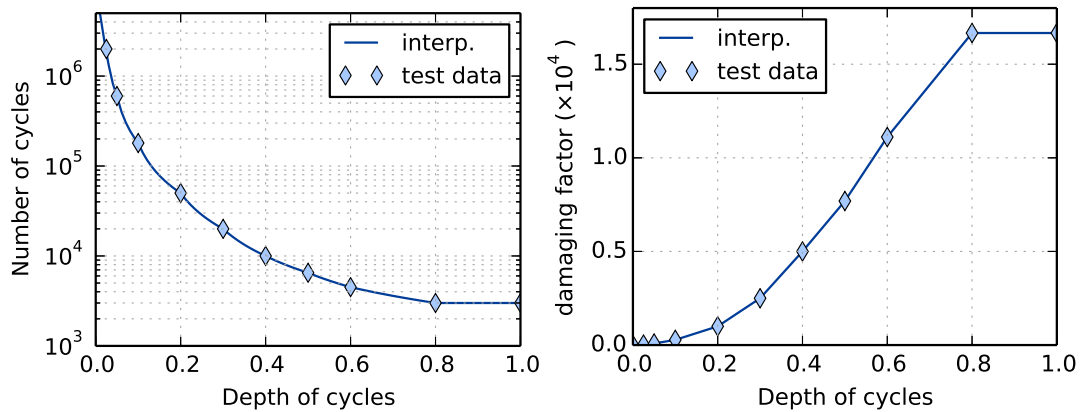


FIGURE 2.11 – Durée de vie en cyclage d’une batterie Lithium-ion, fonction de la profondeur des cycles (données constructeur [69, fig. 6]). À gauche : nombre de cycles N . À droite : facteur d’endommagement $dam = 1/2N$

Vieillessement en cyclage Côté vieillissement en cyclage, le terme de *cyclage* sous-entend un type spécifique de sollicitations : des successions de charges et de décharges formant des cycles *périodiques*. Ces sollicitations périodiques sont en effet souvent utilisées par les constructeurs pour leurs tests de vieillissement.

La figure 2.11 montre un exemple de courbe de “tenue en cyclage” où l’on constate que le nombre de cycles avant fin de vie (cf. plus haut pour la définition conventionnelle) dépend fortement de la profondeur de ces cycles. Le constat qu’il est possible de faire plus de petits cycles que de grands cycles est assez général (batteries au plomb, batterie Lithium-ion).

Si ces tests en cyclage périodique peuvent bien convenir à certaines applications, cette caractérisation s’adapte mal aux sollicitations *stochastiques* que nous rencontrons dans le contexte éolien-stockage. En conséquence, notre travail sur le vieillissement a consisté essentiellement à chercher à reformuler des modèles existants pour les adapter à notre contexte.

Nous nous concentrons à présent sur deux formalismes couramment utilisés pour le vieillissement en cyclage. Nous montrons comment ces modèles, en apparence distincts, peuvent être unifiés dans certains cas. Nous présentons également les failles de l’approche “comptage de cycles simple”.

2.2.2 Formalisation du vieillissement en cyclage

Nous introduisons A , une variable d’état de vieillissement (State of Aging, SoA) qui doit résumer l’information sur l’état de santé de la batterie. Le SoA part de 0 lorsque la batterie est neuve, en “pleine santé” puis croît progressivement pour atteindre 1 en fin de vie. Remarquons qu’on trouve également dans la littérature la variable état de santé (State of Health, SoH) qui est la grandeur complémentaire ($SoH = 1 - A$).

Pour faire évoluer le SoA au fil des sollicitations, deux méthodes sont couramment utilisées. Elles ont été décrites principalement dans le contexte des batteries au plomb, mais le formalisme est nettement plus général. Nos sources principales sont un rapport du Risø de Bindner *et al.* [11]¹³ et un article comparatif de Sauer *et al.* [91].

13. Le §2.2 “Lifetime models” donne un aperçu des méthodes. Nous avons éliminé la méthode physique “Performance degradation”, car elle est totalement spécifique à la technologie plomb-acide.

- le comptage de l'énergie échangée¹⁴, qui comptabilise le vieillissement de façon *continue*, *progressive*.
- le comptage de cycles¹⁵ qui comptabilise le vieillissement de façon *discontinue*, à chaque fois que se termine un cycle de charge ou de décharge. Relevons qu'il existe plusieurs façons de compter les cycles. Ce comptage se fait souvent à la fin d'une simulation (post-traitement)

Notre contribution consiste à montrer comment le *comptage de cycles peut se faire de manière continue*, sous certaines conditions. En corolaire, nous montrons que ce comptage continu contient en fait le comptage d'énergie échangée comme cas particulier. Ainsi ces deux approches sont en partie unifiées.

Pourquoi un modèle de vieillissement continu ? Notre objectif est d'obtenir un modèle de vieillissement continu ou "instantané", par opposition au calcul en post-traitement. Plus précisément, nous souhaitons un modèle qui s'écrive sous forme de modèle dynamique (en représentation d'état) :

$$\begin{aligned} \text{en temps continu} \quad \dot{x} &= f(x, P_{sto}) \\ \text{en temps discret} \quad x_{k+1} &= f(x_k, P_{sto}) \end{aligned}$$

avec x le vecteur d'état du processus de vieillissement, contenant l'état de vieillissement A avec d'éventuelles variables auxiliaires. Ce type de modèle a plusieurs avantages :

1. facilité d'accouplement avec le modèle de stockage, car il est déjà du type système dynamique (e.g. équation (2.1))
2. ce couplage avec le modèle du stockage permet, si besoin, de facilement faire varier les paramètres du stockage avec le vieillissement. C'est le cas pour la batterie NaS (la résistance R_{cell} augmente avec N_{cycles}). Cette idée se retrouve aussi dans "Performance degradation model" de Bindner *et al.* [11, §2.2.2].
3. la structure "système dynamique" est absolument essentielle pour mettre en œuvre une optimisation dynamique de la gestion du stockage qui prenne en compte le vieillissement. En effet, pour optimiser la gestion, il faut pouvoir évaluer à chaque instant le coût de chaque "décision de stocker".

Le principe des comptages discontinus La plupart des méthodes de comptages sont malheureusement discontinues. Elles s'inspirent des méthodes de prévision de la *rupture par fatigue* des structures mécaniques : la charge-décharge d'une batterie (variation du SoE) est vue comme l'analogie du chargement cyclique d'une poutre (variation de la contrainte ou de la déformation).

Cette approche "fatigue" considère que le système peut subir un nombre N_{max} d'événements avant rupture. Par conséquent, on attribue à chaque événement un poids $1/N_{max}$. L'état de vieillissement est alors la somme des poids de chaque événement i :

$$A = \sum_i \frac{1}{N_{max}^{(i)}} \quad (2.18)$$

14. nommé, selon les variations, "(weighted) Ah ageing" [91] et "Ah throughput model" [11, §4]. "Ah" signifie que c'est la charge échangée qui est comptée, mais on peut tout aussi bien compter l'énergie échangée.

15. Sauer *et al.* [91] utilisent, de façon un peu plus générale, le terme de "event-oriented ageing".




FIGURE 2.12 – Comparaison de deux algorithmes de comptage de cycles [4]

et, partant de 0, A atteint bien 1 au bout de N_{max} événements.

Dans le contexte des batteries, l'évènement typiquement considéré dans les tests est un *cycle de décharge*. Il s'agit d'une décharge suivie d'une charge pour retrouver l'état d'énergie initial (ex. figure 2.13). Nous désignons par DoD l'amplitude $SoE_{max} - SoE_{min}$ ¹⁶ d'un tel cycle (on trouve aussi les notations de ΔSoC ou ΔDoD). Par extension de langage, nous utilisons parfois le terme "cycle" pour désigner la moitié d'un cycle (un "demi-cycle"), c'est-à-dire une phase de (dé)charge seule, sans retour à l'état d'énergie initial.

L'addition des dommages (2.18) se généralise au cas où les évènements ne sont pas tous identiques, en particulier avec des amplitudes de chargement différentes qui font varier N_{max} . Pour les structures mécaniques, il existe les courbes de Wöhler (Stress-life data, ou "S-N curves"), et pour les batteries il s'agit des courbes de tenue en cyclage $N_{max}(DoD)$ dont la figure 2.11 est un exemple. On attribue alors à chaque évènement i d'amplitude $DoD^{(i)}$ une contribution de $1/N_{max}(DoD^{(i)})$ à l'usure. L'hypothèse clé du comptage ("règle de Miner") suppose que tous les dommages élémentaires se combinent par simple addition, ce qui aboutit à :

$$A = \sum_i \frac{1}{N_{max}(DoD^{(i)})} \quad (2.19)$$

Cette hypothèse de linéarité a un caractère arbitraire, mais a le mérite d'être parfaitement cohérente avec les données de tests effectués à une DoD donnée. C'est au cas par cas que des tests spécifiques peuvent valider ou invalider la règle de Miner. En l'absence de données d'expérience, elle apparaît comme une "hypothèse raisonnable".

Comptages de cycles La loi de Miner (2.19) indique comment sommer les contributions de différents cycles. Par contre, elle n'indique pas comment définir et donc détecter les cycles. Alors que dans un cas simple (cycles de la figure 2.13) il n'y a pas d'ambiguïté, cela devient vite nettement plus compliqué avec un profil $SoE(t)$ réel.

Il existe plusieurs algorithmes usuels pour le comptage de cycles. Ceux-ci ont été bien normalisés par l'ASTM [4]¹⁷ (toujours dans le contexte de la fatigue mécanique) et nous utilisons donc la dénomination de cette norme E1049. La figure 2.12 montre les cycles vus par les 2 algorithmes les plus typiques : "simple range counting" et "Rainflow counting". Pour montrer leurs différences, nous avons créé un profil $SoE(t)$ avec un grand cycle qui est interrompu par un micro-

16. la terminologie DoD fait souvent référence à des variations d'état de charge (SoC) plutôt que d'état d'énergie (SoE). Nous procédons donc à une "récupération" de cette variable pour en faire une profondeur *énergétique* de cycle.

17. ASTM International, connu jusqu'en 2001 comme the American Society for Testing and Materials (ASTM)

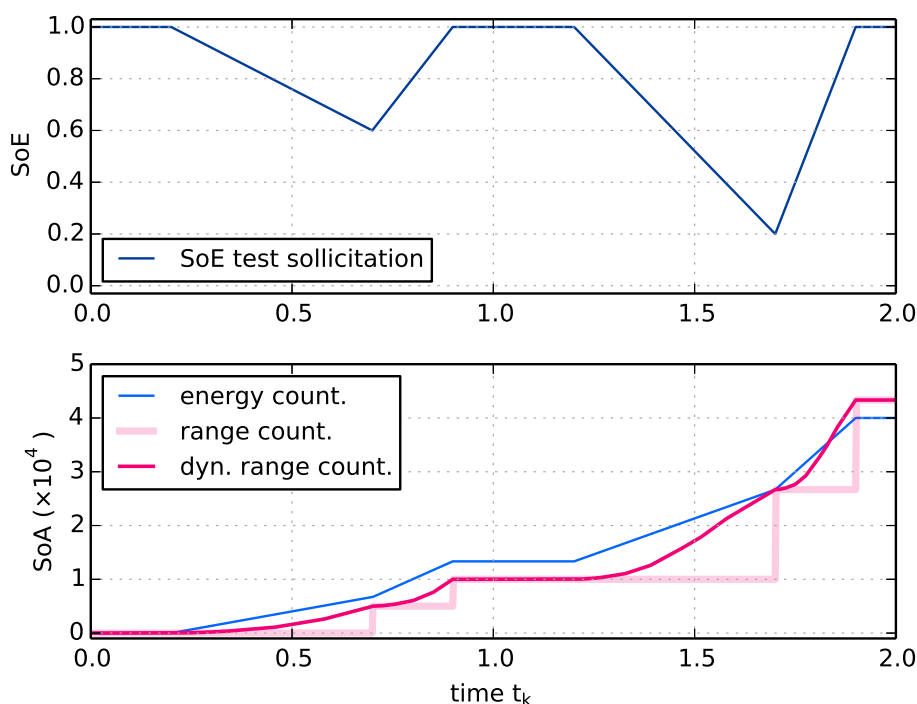


FIGURE 2.13 – Comparaison de trois méthodes de comptage du vieillissement en cyclage

cycle, ce qui est le prototype d'une sollicitation complexe. L'observation de la figure permet de comparer les deux algorithmes :

- Le “simple range counting”, ou “comptage d'amplitude simple” se contente de découper la sollicitation $SoE(t)$ à chaque extrémum, c'est-à-dire à chaque changement de signe de P_{sto} . Il compte ce qu'on nomme parfois des *demi-cycles*. De ce fait, le grand cycle est pour partie *masqué* par le micro-cycle : la grande décharge est découpée en 2 demi-cycles plus petits.
- Le comptage Rainflow travaille également sur la série des extrémums de la sollicitation $SoE(t)$, mais avec une vision plus globale qu'un simple découpage. Il est ainsi capable de distinguer la *superposition* du grand cycle et du micro-cycle. Nous ne détaillons pas son fonctionnement, mais on trouvera chez Downing *et al.* [31] une explication pédagogique (basée sur l'idée de fermeture de cycles d'hystérésis) de l'algorithme normalisé par l'ASTM.

Grâce à un algorithme de comptage, il devient possible de mettre en œuvre la loi de Miner (2.19) sur un profil de SoE quelconque. Cela permet de pondérer arbitrairement l'effet de la profondeur de cycle, mais aussi de prendre en compte tout autre paramètre si besoin : la durée du cycle, le SoE moyen du cycle.

Problème, les algorithmes de comptage sont décrits [4] comme des *post-traitements* du profil de SoE (ou plus précisément à la série des extrémums de $SoE(t)$) et non comme des systèmes dynamiques. La figure 2.13 (courbe rouge clair) montre l'évolution du SoA lorsque le comptage (2.19) est mis à jour à chaque détection de fin de demi-cycle (approche comptage d'amplitude simple). Bien que mis à jour périodiquement, ce comptage n'est pas du type “système dynamique” et le caractère discontinu du comptage crée des discontinuités sur l'état de vieillissement.

Nous montrons à présent que deux cas particuliers permettent d'obtenir un comptage continu : le comptage de l'énergie (connu) et le comptage d'amplitude simple (notre contribution).

2.2.3 Modélisation dynamique du cyclage

Comptage de l'énergie échangée Il s'agit sans doute du plus simple des modèles dynamiques pour prédire la durée de vie en cyclage. Il est utilisé en particulier dans le logiciel HOMER créé au National Renewable Energy Laboratory (NREL) pour la simulation de réseaux isolés avec EnR, diesel et stockage.

Cet algorithme a été popularisé pour les batteries au plomb à partir d'un constat sur les courbes de tenue en cyclage : le produit du nombre de cycles N_{max} par la profondeur de ces cycles est à peu près constant [44, p. 104]. Autrement dit, la courbe $N_{max}(DoD)$ prend la forme particulière d'une hyperbole :

$$N_{max}(DoD) = N_{life} \frac{1}{DoD} \quad (2.20)$$

où N_{life} est le nombre de cycles pleins ($DoD = 1$)¹⁸ réalisables sur la vie de la batterie. Sur la figure 2.11, on observe que $N_{life} = 3000$. Cependant, pour cette batterie Lithium-ion, la relation (2.20) n'est pas vérifiée : si la batterie peut assurer 3000 cycles à $DoD=1$, elle assure, à $DoD=1/10$, non pas 30 000, mais 200 000 cycles. Par contre cette relation est valable pour beaucoup de technologies de batteries au plomb (ex. figure 7 du rapport de Bindner *et al.* [11, §4]).

Avec l'hypothèse (2.20), un cycle de profondeur DoD contribue au vieillissement à hauteur de $1/N_{max} = DoD/N_{life}$. Cette contribution est exactement *proportionnelle* à la profondeur du cycle, et donc de l'énergie échangée pendant le cycle. En effet, un cycle de profondeur DoD échange une énergie :

$$E_{cycle}(DoD) = \int_{\text{cycle}} |P_{sto}| dt = 2DoD.E_{rated} \quad (2.21)$$

Ainsi le comptage du vieillissement (2.19), dans ce cas particulier, se réécrit :

$$A = \sum_i \frac{DoD^{(i)}}{N_{life}} = \sum_i E_{cycle}^{(i)} \frac{1}{2N_{life}E_{rated}} = \int |P_{sto}| dt \frac{1}{2N_{life}E_{rated}} \quad (2.22)$$

et le vieillissement est donc simplement le rapport entre l'énergie échangée par le stockage et l'énergie échangeable sur sa vie :

$$A(t) = E_{exch}(t)/E_{life} \quad \text{avec} \quad (2.23)$$

$$E_{exch}(t) = \int_0^t |P_{sto}| dt \quad \text{et} \quad E_{life} = 2N_{life}E_{rated}$$

Avec cette écriture, il n'y a pas besoin de savoir comment décompter les cycles, car le comptage des charges/décharge disparaît au profit du comptage de l'énergie. On arrive très simplement à une écriture dynamique :

$$\frac{dA}{dt} = |P_{sto}|(t)/E_{life} \quad (2.24)$$

qui peut encore s'écrire :

$$dA = \frac{1}{E_{life}} |dE_{sto}| = \frac{1}{2N_{life}} |dSoE| \quad (2.25)$$

18. Le comptage d'énergie est d'ailleurs appelé également "comptage des cycles pleins équivalents".

Ces dernières formes, en écriture infinitésimale, se transposent naturellement en temps discret. Par exemple, partie 2.1.3, le comptage des cycles de la batterie NaS (2.14) est l'écriture en temps discret de l'équation (2.25). Seule différence, le nombre de cycles N_{cycles} utilisé dans le vocabulaire NaS se traduit en SoA par $N_{cycles} = A \times N_{life}$. Avec quelques variations, c'est également ce comptage qui est utilisé par Riffonneau *et al.* [88] dans un contexte PV-stockage Pb-acide.

Nous présentons figure 2.13 (courbe bleue) l'évolution du SoA sur un cycle simple. L'augmentation de A se fait proportionnellement aux variations du SoE, comme exprimé dans l'écriture (2.25).

Le modèle de vieillissement par comptage de l'énergie échangée est donc très satisfaisant sur deux aspects : il est très simple et il s'exprime bien sous la forme continue que nous souhaitons. Il souffre par contre d'un problème : pour les batteries Lithium-ion¹⁹, l'hypothèse $N_{cycles}(DoD) \propto N_{life}/DoD$ n'est pas vérifiée comme observé figure 2.11. Ainsi, le comptage de l'énergie est soupçonné de surestimer le vieillissement dû aux petits cycles. Ceci est d'autant plus gênant que dans notre application éolien-stockage, la sollicitation stochastique amène beaucoup de petits cycles. Le comptage d'amplitude simple permet de lever cette limitation puisqu'il est possible d'utiliser une courbe de tenue en cyclage de forme arbitraire.

Modélisation dynamique du comptage simple Dans le cadre du stage de Master 1 de Samy Biyadi [13], nous avons montré que l'addition des dommages par la loi de Miner (2.19) combinée au comptage de cycles simple peut se mettre sous forme d'un système dynamique. Nous introduisons pour cela la notion de *facteur d'endommagement*, inversement proportionnel au nombre de cycles avant rupture :

$$dam(DoD) = \frac{1}{2N_{max}(DoD)} \quad (2.26)$$

Cette fonction est représentée sur la partie droite de la figure 2.11. Elle permet d'écrire la somme des dommages (2.19) sous la forme :

$$A = \sum_i dam(DoD^{(i)}) \quad (2.27)$$

où les événements i comptés sont des *demi-cycles* (une décharge ou une charge) d'amplitude $DoD^{(i)}$. C'est le fait de compter des demi-cycles qui explique le facteur 1/2 dans la définition de $dam(DoD)$.

Pour rendre le comptage (2.27) progressif, nous avons altéré le statut de la variable DoD : au lieu d'être l'amplitude d'un cycle terminé, elle devient l'**amplitude instantanée** du cycle en cours. Voici son évolution en temps continu :

$$dDoD = dSoE \quad (2.28)$$

$$\text{reset : } DoD(t^+) = 0 \quad \text{if } DoD(t) \cdot dSoE < 0 \quad (2.29)$$

La DoD évolue donc parallèlement au SoE²⁰ (2.28) mais avec une remise à zéro²¹ à chaque changement de cycle. Le changement de cycle (passage de charge à décharge ou l'inverse) cor-

19. et même pour certaines batteries plomb telles que les cellules PowerCell™ de Xtreme Power. La courbe de garantie constructeur a une forme exponentielle $N_{max}(DoD) = N_{life} \cdot a^{1-DoD}$, avec $N_{life} = 1000$ et $a = 500$. (cf. <http://xtremepower.com/xp-technology/powercells.php>, enregistré le 17 déc 2012, inaccessible aujourd'hui)

20. rappelons que nous utilisons une définition énergétique de la profondeur de cycle (variations du SoE), et non pas coulombienne (variations du SoC).

21. la remise à zéro de l'équation (2.28) classe ce modèle parmi les "systèmes hybrides" ou "automates hybrides".




FIGURE 2.14 – Effets des micro-cycles sur le comptage : à un cycle de décharge de profondeur 0.50 sont superposés 10 micro-cycles de profondeur 0, 0.04, 0.06 et 0.10. EN HAUT : pour les profondeurs < 0.05 , le grand cycle n'est pas interrompu et donc la valeur finale du vieillissement est inchangée. EN BAS : pour les profondeurs > 0.05 , le grand cycle est interrompu, ce qui le masque aux yeux de l'algorithme Range Counting. Le vieillissement final est alors diminué ! À l'inverse, le comptage d'énergie est cohérent : les micro-cycles augmentent le vieillissement.

respond à un changement de signe de ΔSoE , c'est-à-dire de la puissance P_{sto} . Remarquons que nous utilisons le signe de DoD pour porter l'information du signe passé de P_{sto} : $DoD(t) > 0$ en charge, $DoD(t) < 0$ en décharge.

Grâce à cette amplitude instantanée, il devient possible de faire augmenter progressivement le vieillissement avec le principe d'interpolation suivant : "le vieillissement $A(t)$ à l'instant t est la valeur du vieillissement *si le cycle en cours devait s'interrompre* à l'instant d'après t^+ ". Cela se traduit mathématiquement par :

$$\text{en temps continu} \quad dA = \frac{\partial dam}{\partial DoD}(|DoD|(t)) \cdot |dSoE| \quad (2.30)$$

$$\text{en temps discret} \quad A_{k+1} = A_k + dam(|DoD_{k+1}|) - dam(|DoD_k|) \quad (2.31)$$

Sur la figure 2.13, on peut comparer la méthode discontinue (trait rouge clair) à notre modèle dynamique (trait rouge sombre) et constater que :

- le comptage dynamique fait augmenter le vieillissement progressivement, comme le comptage de l'énergie échangée, mais en suivant la forme particulière de la fonction d'endommagement de la figure 2.11.
- les valeurs du vieillissement par comptage dynamique coïncident exactement à la fin de chaque cycle avec le comptage discontinu : notre modèle est bien cohérent par construction.

Il est intéressant de comparer notre modèle avec le comptage d'énergie. En comparant les équations d'évolution (2.30) et (2.25), on observe la similarité de structure : l'âge augmente proportionnellement à $|dSoE|$, mais avec une pondération différente. Le comptage d'énergie peut être vu comme un cas particulier où le facteur d'endommagement est linéaire ($dam(DoD) = DoD/2N_{life}$) et donc la pondération $\frac{\partial dam}{\partial DoD}$ se réduit à la constante $1/2N_{life}$. À l'inverse, notre comptage continu permet une pondération arbitraire par la profondeur instantanée du cycle.

Algorithme du comptage dynamique Nous proposons une implémentation à temps discret des équations dynamiques (2.28) et (2.30). La fonction a pour signature :

$$\text{dyn_range_counting} : (DoD, A, \Delta SoE)_k \mapsto (DoD, A)_{k+1}$$

où (DoD, A) sont les variables d'état et ΔSoE est la sollicitation (égale à $P_{sto}\Delta t/E_{rated}$). Notre implémentation séquentielle est donnée dans la syntaxe Python :

```
def dyn_range_counting(DoD, age, delta_SoE):
    '''dynamical range counting'''
    # New cycle detection:
    # true when consecutive SoE variations have opposite signs
    new_cycle = (delta_SoE * DoD) < 0
    if new_cycle: # Reset of DoD
        DoD = 0

    # DoD accumulation for current cycle
    DoD_next = DoD + delta_SoE
    # Evolution of the Aging
    delta_age = damage(abs(DoD_next)) - damage(abs(DoD))
```



```
age_next = age + delta_age  
  
return DoD_next, age_next
```

Le problème des micro-cycles Nous avons relevé sur la figure 2.12 que le comptage de cycles simple n'est pas capable de reconnaître un grand cycle lorsque celui-ci est masqué par des micro-cycles qui l'interrompent. Comme notre algorithme dynamique est la version continue de ce comptage, il souffre du même défaut. Nous avons donc mis en évidence avec Samy Biyadi la "faille des micro-cycles" de notre algorithme, illustrée figure 2.14. Le facteur d'endommagement en cyclage utilisé est toujours celui de la figure 2.11.

Pour des faibles micro-cycles ($DoD < 0,05$, pour lesquels il n'y pas d'inversion du signe de la sollicitation), l'algorithme n'est pas perturbé et, comparant $DoD = 0$ et $DoD = 0,04$, le vieillissement final est inchangé, quel que soit l'algorithme. Les micro-cycles font seulement varier la trajectoire du vieillissement instantané, comme attendu.

À l'inverse, pour des micro-cycles plus grand ($DoD > 0,05$, pour lesquels il a des inversions du signe de la sollicitation), l'algorithme prédit un vieillissement moindre avec qu'en l'absence de micro-cycles. Nous n'avons pas de données pour décider si cette prévision est juste ou fausse, mais ce résultat ne semble pas "cohérent avec le bon sens". Par comparaison, le comptage d'énergie est plus cohérent : les micro-cycles augmentent le vieillissement.

Perspectives pour le comptage Rainflow Pour pallier la faille de l'algorithme de comptage d'amplitude simple, il nous semble raisonnable d'utiliser l'algorithme Rainflow [31], car il est plus "intelligent".

Ce comptage est déjà utilisé pour le vieillissement calendaire du modèle de batterie Plomb-acide "Kinetic Battery Model" [11, §6] créé à UMass (University of Massachusetts Amherst) dans le cadre du programme informatique "Hybrid2" [71] (simulation des micro-réseaux électriques hybrides continus-alternatifs).

Point positif, cet algorithme est capable de reconnaître des superpositions arbitraires de cycles, mais cet atout a une contrepartie négative : le Rainflow ne peut pas être mis sous forme d'un modèle d'état de dimension fixée²². En faire un modèle dynamique comme le comptage simple semble donc malheureusement impossible. Il reste peut-être la possibilité de réaliser une version approchée du Rainflow qui compterait les cycles avec un nombre d'imbrications de cycles limité. Une étude supplémentaire est nécessaire pour valider cette possibilité.

Utilisation des modèles de vieillissement Au final, les modèles que nous venons de présenter nous servent pour :

- l'évaluation du vieillissement lors d'une simulation. Pour cet usage, la modélisation dynamique est utile mais non nécessaire, car une évaluation a posteriori (e.g. par un comptage Rainflow) peut suffire.
- l'optimisation de la gestion de l'énergie, prenant en compte le vieillissement. C'est pour ce second usage que nous avons mis l'accent sur la modélisation dynamique, seule à même de fournir une image instantanée du vieillissement, ainsi que de l'effet de chaque décision de stocker. Différentes actions peuvent alors être comparées pour choisir la meilleure.

Nous revenons sur la gestion du vieillissement dans notre partie "Prolongements" 5.2.

22. Nous n'avons pas étudié l'algorithme Rainflow avec suffisamment de détails pour démontrer cette proposition, mais nous pensons qu'elle est très probablement vraie.

2.3 Modélisation stochastique de l'erreur de prévision

Nous avons vu en introduction (§1.2.2) que la garantie d'une production éolienne sur la base d'un engagement J+1 fait intervenir deux signaux : la production $P_{prod}(t)$ et l'engagement J+1 $P_{grid}^*(t)$ supposé égal à la prévision $P_{pre}(t)$ (§1.2.3).

Par ailleurs, nous avons montré comment l'écart à l'engagement $P_{dev} = P_{grid} - P_{grid}^*$ peut se réécrire (1.8) comme la différence entre l'écart production-engagement $P_{mis} = P_{prod} - P_{grid}^*$ et la puissance P_{sto} absorbée par le stockage :

$$P_{dev}(t) = P_{mis}(t) - P_{sto}(t) \quad (\text{rappel 1.8})$$

Du point de vue du système de stockage, c'est donc ce signal d'écart P_{mis} qui constitue la principale entrée incertaine (perturbation stochastique) de notre problème, plus que les signaux P_{prod} et P_{grid}^* pris séparément. Nous réduisons donc la dimension des entrées en nous focalisant sur le signal différence P_{mis} , qui est aussi l'erreur de prévision de production J+1. Comme annoncé partie 1.3.2, l'étude de la différence est également motivée empiriquement par l'idée d'une annulation partielle de la complexité respective des deux processus de production et de prévision.

Les données utilisées pour notre analyse proviennent de l'opérateur éolien Quadran (ex-Aérowatt) qui nous a gracieusement fourni les données de production et de prévision J+1 de plusieurs fermes d'outre-mer. Nous utilisons ici les données de la ferme de Grand Maison en Guadeloupe (cf. annexe A.1). Un extrait de 50 jours est présenté figure 2.15, sur les 327 jours disponibles, avec la production, la prévision J+1 et l'erreur de prévision.

Pourquoi une modélisation stochastique ? On pourrait croire que modéliser les données d'entrée, en particulier les erreurs de prévision, n'est pas nécessaire. En effet, les historiques de données peuvent être directement utilisés pour alimenter une simulation "data-based" du système éolien-stockage. La simulation permet alors un calcul direct des paramètres d'intérêt, par exemple, l'écart à l'engagement *moyen*. Pourtant, cette approche peut être dangereuse, car le "chiffre" obtenu n'est pas forcément celui qu'on croit. En effet, la sortie de la simulation dépend directement du jeu de données d'entrée et deux caractéristiques de ces données doivent être prises en compte :

- **variabilité des données** : lorsque l'entrée présente un caractère stochastique, la sortie de la simulation est elle-même stochastique. Le résultat obtenu, malgré le déterminisme de la simulation, est donc *entaché d'erreurs*. Cette erreur doit être estimée pour vérifier que le rapport signal sur bruit est suffisamment grand.
- **représentativité des données** : le jeu de données d'entrée est souvent un extrait temporel court par rapport à la durée de fonctionnement réelle du système (une vingtaine d'années pour une ferme éolienne). L'extrait peut alors ne pas être représentatif de toutes les caractéristiques globales, par exemple s'il y a des effets saisonniers.

Pour améliorer la représentativité et le rapport signal sur bruit, il faut des séries temporelles suffisamment longues. Dans notre contexte de stockage, avec des constantes de temps de plusieurs heures, quelques années de données *complètes* (sans trous) seraient bien appropriées, mais c'est nettement plus que ce que nous (et beaucoup d'autres chercheurs) avons (327 jours avec des trous). Heureusement, de plus en plus de jeux de données deviennent librement accessibles (ex. des données BPA, annexe A.3).

Nous proposons donc une analyse et une modélisation des données d'erreur de prévision dans un premier but de construire un *générateur stochastique* de séries temporelles. Les séries

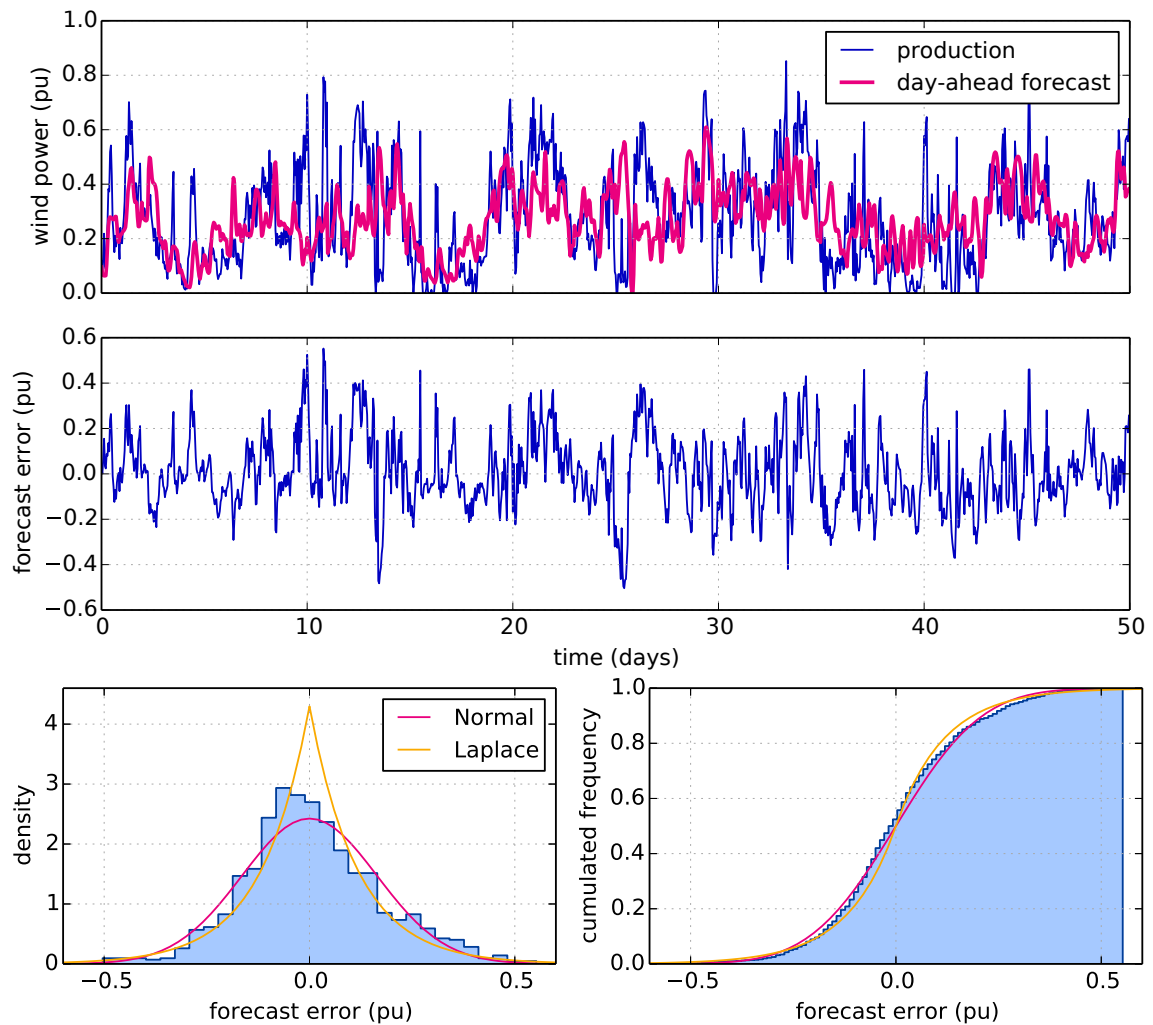


FIGURE 2.15 – EN HAUT : 50 jours de prévision J+1 à pas d'une heure pour la ferme de Grand Maison, Guadeloupe (juin-juillet 2010). EN BAS : histogramme de l'erreur de prévision, comparé aux distributions normale et laplacienne de même écart-type (0,16 pu).

synthétiques d'erreurs de prévision, générées par des tirages aléatoires, permettent de répéter nos simulations avec différentes entrées : c'est l'approche Monte-Carlo. Cette approche permet de bien maîtriser l'aspect variabilité et d'estimer des intervalles de confiance sur les statistiques estimées.

Le risque de la simulation basée sur un modèle, c'est que celui-ci ne prenne pas en compte certaines caractéristiques des données qui impactent fortement les grandeurs d'intérêt. C'est par exemple le cas de la structure temporelle (abordée partie 2.3.2) qui, si négligée, amène à sous-estimer une capacité de stockage d'un ordre de grandeur !

Pour finir, la modélisation statistique de l'erreur de prévision de production a une deuxième finalité : elle est absolument indispensable pour mettre en œuvre l'optimisation de la gestion de stockage avec la *programmation dynamique* (abordée chapitre 3).

2.3.1 Modélisation statique

Nous analysons ici l'erreur de prévision d'un point de vue statique, c'est-à-dire sans son aspect temporel qui est abordé juste après.

Nous avons tracé figure 2.15 l'histogramme des erreurs de prévision correspondant à l'extrait de 50 jours représenté au-dessus. L'erreur de prévision a un écart-type $\sigma_P = 220$ kW, soit 16% de la puissance nominale du parc. L'histogramme nous renseigne sur la distribution *marginale* de l'erreur. Nous observons qu'elle est approximativement gaussienne pour cet extrait, mais ça n'est pas une généralité. Avec d'autres données, la répartition est plutôt laplacienne (aussi appelée double exponentielle), avec à la fois plus de valeurs proches de zéro et plus de valeurs extrêmes. Ces deux distributions théoriques sont tracées pour comparaison (courbes rouge et orange).

Lange [67] montre par exemple que le caractère non linéaire de la conversion de puissance d'une éolienne (courbe $P(v)$) transforme la répartition des erreurs de vitesse de vent (m/s) plutôt gaussienne en erreurs de puissance (kW) nettement non gaussiennes. Il obtient une répartition avec un net pic en zéro, comme une distribution Laplace, quoiqu'un peu asymétrique [67, fig. 13].

Dépendance à la puissance prévue Cette analyse de la distribution marginale, c'est-à-dire moyennée au fil du temps, ne doit pas faire oublier que la répartition de l'erreur dépend du niveau de puissance prévue : les erreurs sont "conditionnellement hétéroscédastiques" (variance non constante). On trouvera par exemple chez Bludszuweit *et al.* [14] une modélisation paramétrique (par des distributions bêta²³) de l'erreur de prévision en fonction de la puissance prévue.

Nous n'avons au final pas utilisé ce type de résultat pour notre travail de dimensionnement, mais cette dépendance pourrait se révéler importante dans certains prolongements de nos travaux. Nous rappelons donc certains résultats observés pendant notre stage²⁴ de Master 2 [49] où nous avons modélisé la relation production-prévision par un modèle de régression. La figure 2.16 permet d'observer le nuage de point (P_{pre}, P_{prod}) et l'on y constate clairement que la variance de l'erreur de prévision augmente avec la puissance prévue.

Nous avons montré que cette hétéroscédasticité s'estompe [49, fig. 22] lorsqu'on transforme le nuage de points en appliquant une transformation "gamma" $x \mapsto x^{1/\gamma}$ à chaque variable, pour un choix d'exposant γ entre 2 et 3. Il y a une intuition physique derrière cette transformation : comme la courbe de conversion $P(v)$ d'une éolienne est approximativement cubique ($P(v) \propto v^3$,

23. Famille de lois de probabilité applicable à une variable réelle $X \in [0,1]$. Gouvernée par deux paramètres de forme α et β positifs, elle a pour densité $f(x; \alpha, \beta) \propto x^{\alpha-1}(1-x)^{\beta-1}$.

On en trouvera des tracés sur http://fr.wikipedia.org/wiki/Loi_bêta

24. encadré par Pascal Bondon, Directeur de Recherche au Laboratoire des Signaux et Systèmes (LSS) de Supélec.




FIGURE 2.16 – Relation entre production (moyenne 1h) et prévision J+1 d’une ferme en Guadeloupe. EN BLEU : l’ensemble des 293 jours de données disponibles. EN TURQUOISE : données de l’extrait de 50 jours de la figure 2.15. EN ROUGE : intervalle de confiance de la prévision calculé par régression de quantile sur les données transformées $x \mapsto x^{1/\gamma}$, avec $\gamma = 2.5$

hors zone d'écrêtage), la transformation gamma permet, plus ou moins, de passer de l'espace des puissances à l'espace des vitesses de vent.

Dans l'espace transformé $(P_{pre}^{1/\gamma}, P_{prod}^{1/\gamma})$, nous avons ainsi appliqué une régression linéaire de quantiles [63] pour obtenir les intervalles de confiance tracés figures 2.16. Les intervalles de confiance, qui sont des droites dans l'espace transformé, acquièrent une forme fuselée après transformation inverse. Ainsi, nous modélisons bien l'augmentation de l'erreur de prévision avec la puissance moyenne.

Remarque : il est souvent mentionné que la variance de l'erreur de prévision *diminue* pour les forts niveaux de puissance (ex. Bludszuweit *et al.* [14, fig. 5]), à cause de l'écrêtage de puissance des éoliennes. Comme les données des fermes Aérowatt ne comportent pas de points à fonctionnement écrêté (cf. figure 2.16 : pas de production supérieure à 0,9 pu), notre régression ne peut pas modéliser ce phénomène.

L'étude statique de l'erreur de prévision, en termes de distribution marginale, est suffisante pour le dimensionnement *en puissance* d'un système de stockage. C'est par exemple l'utilisation que font Bludszuweit *et al.* [14] de leur modélisation. Par contre, la structure temporelle de l'erreur de prévision est primordiale pour le dimensionnement en énergie.

2.3.2 Modélisation temporelle

Comme le système de stockage a vocation à "absorber" les erreurs de prévision, son énergie évolue avec l'*accumulation* des erreurs successives. La modélisation de la dépendance entre ces erreurs successives est alors très importante.

Certains articles traitant de systèmes éolien-stockage modélisent des erreurs de prévision *sans* structure temporelle. Concrètement, les erreurs sont synthétisées par un générateur aléatoire de distribution donnée. Cette approche revient, implicitement, à supposer que les séquences d'erreurs $(P_{err}(0), P_{err}(1), \dots)$ sont *indépendantes*. En réalité, les erreurs de prévision $J+1$ ne sont *pas indépendantes*, mais au contraire fortement *corrélées positivement*. De plus, nous avons montré dans un article [52] que la non-prise en compte de cette corrélation entraîne une forte *sous-évaluation* du besoin en capacité de stockage. La dépendance temporelle des erreurs impacte en fait tous les processus dynamiques du réseau (i.e. les processus qui ont une mémoire). En plus du stockage, cela inclut par exemple les générateurs thermiques conventionnels (à cause des contraintes temporelles de démarrage et de fonctionnement).

Qualitativement, la corrélation positive des erreurs de prévision $J+1$ s'explique facilement : si un modèle de prévision se trompe à une heure donnée, c'est sans doute parce que l'état météorologique est mal prévu pour une bonne partie de la journée. Il est donc normal que les erreurs persistent pendant plusieurs heures. Ce phénomène concerne probablement aussi les erreurs d'autres prévisions d'énergie (e.g. photovoltaïque et consommation).

Notons que le constat de la corrélation de ces erreurs n'est pas nouveau. Il apparaît déjà dans un rapport précurseur de Lennart Söder qui travaillait dès 1994 sur l'intégration de l'énergie éolienne sur le réseau [92, p. 43-131]. Son modèle autorégressif (voir plus bas) inclut aussi les corrélations des productions de plusieurs fermes. Ce travail a été poursuivi dans le cadre du projet d'intégration de l'éolien WILMAR [93, 16] avec un modèle permettant de générer des scénarios de production (en particulier des arbres de scénarios) qui sont très utiles pour certains algorithmes d'optimisation du dispatching. Nous retrouvons l'approche autorégressive dans d'autres études d'intégration de l'éolien aux Pays-Bas [97] ou en Californie [29].




FIGURE 2.17 – Autocorrélation estimée de l’erreur de prévision éolienne (données de la figure 2.15), comparée à l’autocorrélation théorique d’un modèle AR(1), pour 3 valeurs du coefficient ϕ

Nous présentons à présent le modèle de dépendance qui sous-tend notre publication sur l’effet de la corrélation sur le dimensionnement d’un stockage [52] et le texte qui suit reprend pour l’essentiel la partie 3 “Stochastic Modeling of Forecast Errors” de cet article.

Une large partie de cette étude de séries temporelles a été réalisée avec le logiciel de statistiques R [87] (logiciel libre, licence GPL).

Autocorrélation des erreurs de prévision Une façon simple d’analyser la dépendance temporelle d’un processus stationnaire $\{X(k)\}$ est de regarder la fonction d’autocorrélation, qui est l’autocovariance²⁵ normalisée par la variance de la série temporelle :

$$\rho_X(h) = \frac{\text{Cov}(X(k), X(k+h))}{\text{Var}(X(k))}, \quad h \in \mathbb{Z} \quad (2.32)$$

Nous avons tracé figure 2.17 l’autocorrélation estimée (fonction acf dans R) des erreurs de prévision P_{mis} représentées figure 2.15. Nous observons que la corrélation des erreurs entre deux heures consécutives est de presque 80%, puis décroît exponentiellement. Elle reste significativement positive pendant une douzaine d’heures avant d’entrer dans l’intervalle de confiance autour de zéro (lignes grises pointillées).

Nous choisissons de modéliser cette structure de corrélation par un processus de la famille “classique” des processus autorégressifs à moyenne mobile (ARMA) [21]. Les ARMA sont des modèles linéaires paramétriques dont on peut facilement ajuster les paramètres aux données (fonction arima dans R).

Modélisation ARMA Un processus stochastique $\{X(k)\}$ est appelé processus ARMA(p,q) s’il satisfait à l’équation aux différences

$$\begin{aligned} X(k) - \phi_1 X(k-1) - \dots - \phi_p X(k-p) = \\ \varepsilon(k) + \theta_1 \varepsilon(k-1) + \dots + \theta_q \varepsilon(k-q), \end{aligned} \quad (2.33)$$

25. Pour deux variables aléatoires X et Y , on définit $\text{Cov}(X,Y) = \mathbb{E}[(X - \mathbb{E}[X])(Y - \mathbb{E}[Y])]$. La covariance évalue les variations communes de deux variables aléatoires.

où $\{\varepsilon(k)\}$ est un “bruit blanc” : séquence de variables aléatoires d'espérance nulle, indépendantes et identiquement distribuées (IID). Les polynômes $\phi(z) = 1 - \phi_1 z - \dots - \phi_p z^p$ et $\theta(z) = 1 + \theta_1 z + \dots + \theta_q z^q$ à coefficients réels n'ont pas de racines communes et ni $\phi(z)$ ni $\theta(z)$ n'ont de racines sur le disque unité fermé $\{z \in \mathbb{C} : |z| \leq 1\}$. Il y a alors une unique solution stationnaire $\{X(k)\}$ à l'équation (2.33). Dans un vocabulaire plus électronique, un processus ARMA correspond au filtrage d'un bruit blanc par un filtre numérique à réponse impulsionnelle infinie (IIR filter), voire finie (FIR filter) si l'on ne garde que la partie MA(q).

L'ajustement d'un modèle ARMA à une série temporelle donnée consiste à sélectionner des ordres (p, q) appropriés et à estimer les paramètres. Le choix des ordres est un problème de sélection de modèles statistiques qui peut s'effectuer grâce à des critères d'informations tels que AIC ou BIC [21][section 9.3]. Pour nos données $P_{mis}(k)$, ces critères aboutissent aux ordres (0,1) ce qui correspond à un modèle AR(1) d'expression simple :

$$P_{mis}(k) = \phi P_{mis}(k-1) + \varepsilon(k) \quad (2.34)$$

et la valeur estimée de ϕ est $\hat{\phi} = 0,78$, avec un intervalle de confiance à 95 % de $[0,75 - 0,82]$. Cet intervalle peut se réduire en utilisant un jeu de données plus long que les 50 jours considérés ici. L'estimation (avec la routine `arima` dans R) est basée sur la méthode du maximum de vraisemblance. La procédure d'ajustement estime aussi l'écart-type σ_ε du bruit, mais cette valeur importe moins que l'écart-type du processus, sachant que les deux sont liés : $\sigma_\varepsilon = \sigma_P \sqrt{1 - \phi^2}$. L'écart-type estimé $\hat{\sigma}_P$ est 220 kW soit 0,16 pu (cf. partie précédente). L'analyse des résidus²⁶ montre qu'ils sont décorrélés, comme attendu.

L'autocorrélation théorique du processus AR(1) (2.34) prend une forme particulière et simple :

$$\rho_{P_{mis}}(h) = \phi^{|h|}, \quad h \in \mathbb{Z} \quad (2.35)$$

et le paramètre ϕ est donc le coefficient de corrélation de $P_{mis}(k)$ entre deux instants successifs (i.e. 2 heures successives). Nous observons que l'autocorrélation estimée sur les données (figure 2.17) présente bien la décroissance exponentielle de l'équation (2.35)

Pour illustrer qualitativement l'effet du coefficient ϕ sur des trajectoires temporelles, nous présentons figure 2.18 un extrait d'une semaine d'erreur de prévision (en haut) en regard de deux simulations stochastiques AR(1) (milieu et bas), avec respectivement $\phi = 0,78$ (égal à l'estimation faite sur les données) et $\phi = 0$ (bruit blanc : l'autocorrélation (2.35) est nulle pour $h \neq 0$). Nous y observons que ϕ influe sur la “rugosité” des trajectoires. Les données de terrain et la simulation avec $\phi = 0,78$ partagent une même rugosité alors qu'avec $\phi = 0$, la trajectoire est plus “chahutée”.

Par ailleurs, la corrélation positive fait aussi augmenter la durée des séquences de mêmes signes consécutifs (erreurs successivement positives ou erreurs successivement négatives). Cette caractéristique est très importante dans un contexte de stockage, puisqu'une erreur de même signe implique pour un stockage une plus forte excursion énergétique que si les erreurs successives se compensent par des signes différents. Ce constat permet de comprendre qualitativement pourquoi la corrélation impacte aussi fortement le besoin en capacité de stockage [52].

Validation du modèle, limites et perspectives Comme détaillé dans notre article [52, §3.4], nous avons analysé d'autres jeux de données pour tester notre approche de modélisation. En particulier la BPA (cf. annexe A.3) fournit librement des données de production et de prévision éoliennes. Ces données complémentaires sont d'échelle *régionale* (et agrègent donc toutes les fermes d'un réseau) à la différence des données locales de Grand Maison. Les erreurs de prévision

26. Estimation de la séquence de bruit d'entrée $\hat{\varepsilon}(k) = P_{mis}(k) - \hat{\phi}P_{mis}(k-1)$

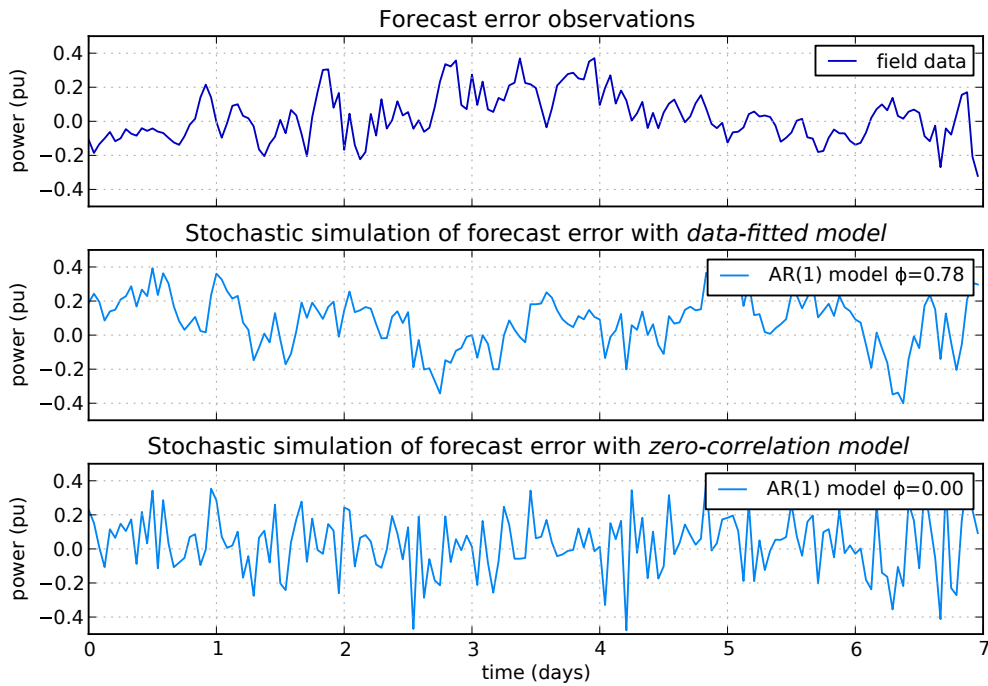


FIGURE 2.18 – Comparaison de l’erreur de prévision observée sur le terrain avec deux simulations stochastiques : modèle AR(1) avec $\sigma_P = 0.16$ dans les deux cas, mais avec $\phi = 0,78$ (au milieu) et $\phi = 0,0$ (en bas)

sont alors plus faibles (amélioration de la qualité des prévisions avec l’étendue spatiale [45]). En termes de structure temporelle, nous observons que :

- les erreurs de prévisions $J+1$ successives (à pas horaire) sont *toujours positivement corrélées*.
- l’autocorrélation décroît à peu près exponentiellement (comme le modèle AR(1)).
- en ajustant un modèle AR(1), nous obtenons un coefficient ϕ dans l’intervalle $[0,8 - 0,9]$, par exemple 0,85 pour les données BPA.

Ces observations permettent de généraliser en bonne partie les résultats obtenus sur les données de la ferme de Grand Maison. Cependant, l’analyse fine des résultats, avec certaines séries de données plus longues, met en lumière certaines limites du modèle AR(1). Ces limites sont en fait celles de la famille ARMA en général (conséquence : la solution ne passe pas par un choix d’ordres (p,q) plus élevés).

Premièrement, un modèle ARMA stationnaire ne peut prendre en compte de motif périodique journalier, présent par exemple dans les données BPA. L’existence de ces motifs témoigne de la façon dont sont générées les prévisions : non pas heure par heure, mais par *blocs de 24 heures*. Une solution possible serait alors de simuler des blocs d’erreur comme dans le projet WILMAR [16]. Cette approche permet d’obtenir une *remise à zéro* de l’erreur de prévision au début de chaque nouvelle journée. Cependant, les prévisions $J+1$ sont généralement utilisées dans un contexte où elles doivent être livrées une dizaine d’heures à l’avance (ex : appel d’offres éolien-stockage de la CRE [28], marché day-ahead). Par conséquent, l’erreur moyenne de prévision à la 1^{ère} heure de chaque jour n’est pas nulle.

Deuxièmement, nous avons vu (cf. modélisation statique §2.3.2) que le niveau d’erreur de prévision augmente avec la puissance. Comme la production éolienne présente des alternances

de périodes de faible et de forte production, cela crée des alternances de faible et forte erreur de prévision : des “bouffées de variabilité”. Un modèle ARMA ne peut pas modéliser un tel comportement, mais il est possible de lui adjoindre la notion de “régime de temps” en faisant dépendre le modèle de quelques “états cachés” dont les transitions sont régies par une chaîne de Markov.

Il s’agit alors d’un processus autorégressif à changement de régime, du type Markov-switching autoregressive model (MSAR). Ce type de processus a été utilisé pour modéliser des séries temporelles de vent, en particulier par Ailliot *et al.* [1], depuis au moins 2004, mais aussi la variabilité court terme de puissance éolienne [82]. Nous pensons qu’il est donc aussi adapté à la modélisation de l’erreur de prévision.

Enfin, la distribution marginale d’un processus ARMA est gaussienne²⁷ alors que les erreurs de prévision ne le sont généralement pas (cf. § 2.3.2). Il existe certes des modèles de processus Laplace-AR(1), c’est-à-dire de distribution marginale laplacienne et dont l’autocorrélation suit la forme (2.35), mais, à la différence des AR gaussiens, il n’existe pas de modèle Laplace-AR unique²⁸. Nous mentionnons Dewald *et al.* [30] pour une introduction aux modèles dits “LAR(1)” et “NLAR(1)”, et plus généralement Grunwald *et al.* [48] pour les processus AR(1) non gaussiens. Sans prétendre à l’exhaustivité, nos quelques expériences numériques avec ces modèles n’ont pas permis d’en trouver de satisfaisants, car les distributions jointes $(X(k), X(k + 1))$ prennent souvent des formes très “artificielles”.

En conclusion, nous pensons que les processus AR à changement de régime MSAR sont particulièrement prometteurs, car ils permettent à la fois de modéliser les bouffées de variabilité, mais aussi d’obtenir des densités marginales non gaussiennes, comme le montrent bien Ailliot *et al.* [1].

Autre application de modèle AR Dans un autre contexte, nous avons également utilisé un modèle AR (d’ordre 2) pour modéliser les fluctuations de production d’un houlogénérateur (récupération d’énergie de la houle marine). La modélisation de cette fluctuation est essentielle pour conduire l’*optimisation dynamique* du lissage de production (basé sur un stockage par supercondensateurs). La méthode d’ajustement du modèle AR, un peu moins “classique”, est décrite dans notre article [50, §2 Stochastic Model of a Wave Energy Production].

2.3.3 Génération de scénarios stochastiques de production

Nos travaux nous ont conduits à nous concentrer sur la modélisation du “signal différence” qu’est l’erreur de prévision de production, car il est, du point de vue du stockage, plus important que les signaux de production et de prévision pris séparément. Si ce signal d’erreur suffit pour beaucoup de stratégies de gestion de stockage, il existe cependant des cas où les signaux de production et prévision doivent être disponibles. Dans le contexte éolien-stockage, c’est le cas par exemple lorsqu’on souhaite *délester* la production ou lorsque les pénalités d’écart à l’engagement dépendent non seulement de l’écart mais aussi du niveau de production (cf. cahier des charges de l’appel d’offres [28] : la pénalisation de l’écart se fait par décote du tarif d’achat de la production). Dès lors, il devient intéressant de disposer non plus d’un générateur d’erreur de prévision, mais d’un générateur de *scénarios de production*.

Une approche simpliste serait d’ajouter à la série de puissance prévue $P_{pre}(k)$ (par un service de prévision externe) un scénario d’erreur $P_{mis}(k)$, issu par exemple du modèle AR(1) de

27. si le bruit d’entrée ε est gaussien. Si ça n’est pas le cas, le processus ARMA est souvent quasi gaussien malgré tout (pour ε de variance finie) à cause du caractère attracteur de la distribution gaussienne (cf. notion de “loi stable”).

28. car un processus non gaussien n’est pas entièrement défini par ses seules caractéristiques d’ordre 2 (i.e. moyenne et autocovariance)




FIGURE 2.19 – Exemple de génération stochastique de production éolienne J+1, par “bruitage” de la prévision J+1.

la partie précédente. Malheureusement, cette approche se heurte à deux problèmes : la somme $P_{pre} + P_{mis}$ peut devenir négative, mais surtout cela ne tient pas compte du lien entre variabilité de l’erreur et niveau de puissance prévue (cf. §2.3.2).

Pour cet aspect génération de scénarios de production, nous n’avons pas dépassé le stade de la réflexion, mais nous recommandons un article de Pinson *et al.* [83] comme à la fois une introduction aux enjeux des scénarios de production éolienne et une proposition de méthode de génération. Les scénarios sont construits sur un modèle de prévision probabiliste existant (prévision de quantiles) auquel est adjointe une estimation adaptative de la covariance sur 48h.

À titre illustratif, nous avons tracé figure 2.19 des scénarios de production J+1 sur une semaine. Ces scénarios ont été générés en additionnant un bruit corrélé (modèle AR(1) de la partie 2.3.2) aux prévisions transformées (cf. $x \mapsto x^{1/\gamma}$ §2.3.1). La prévision bruitée subit ensuite la transformation inverse pour obtenir une erreur conditionnellement hétéroscédastique. Cette approche n’est qu’illustrative, car ces scénarios ne sont pas véritablement calibrés. En particulier, la transformation non linéaire de la prévision bruitée donne un résultat biaisé (production sur-estimée en moyenne).

2.4 Modélisation des variations rapides de puissance éolienne

Comme annoncé partie 1.3.2, nous souhaitons modéliser les variations de production d’une ferme éolienne. Modéliser une production éolienne peut prendre de nombreuses formes selon l’objectif de la modélisation. Notre objectif est le *lissage de ces variations* par un système de stockage, et en particulier le dimensionnement et la gestion de ce stockage (abordée partie 3.4.2). Cela explique que nous nous intéressions spécifiquement aux *variations* de la production.

L’objectif de cette modélisation est double : tenter de *comprendre* la structure des variations et obtenir un modèle permettant la *gestion par Programmation Dynamique*.

2.4.1 Analyse de la variabilité d’une ferme

Pour cette analyse, nous utilisons des données collectées par EDF sur la ferme de La Perrière à La Réunion (détails annexe A.2). La production de cette ferme de 10,2 MW est mesurée de façon continue dans le cadre du projet Pégase. Cette mesure présente l’intérêt d’être à haute fréquence : pas de 5 secondes. Nous disposons de données sur la période juin–décembre 2012 (~3 Mpts).




FIGURE 2.20 – Dix extraits de 6 heures de production d’une ferme éolienne (données moyennées à pas d’une minute). À DROITE : histogramme de l’ensemble de la production.

Dans l’objectif de lissage des fluctuations nous devons choisir une échelle de temps et nous nous sommes fixés sur un pas $\Delta_t = 1$ minute. Dans cette partie, le signal discret $P_{prod}(k)$ désigne donc la puissance produite à pas d’une minute, moyennée sur une minute. Certains résultats sont donc bien sûr dépendants de ce choix de pas de temps.

Nous présentons figure 2.20 une série d’extraits de 6 heures de production (tirage aléatoire d’extraits) pour donner une idée de la variabilité de la production d’une ferme. Les trajectoires diffèrent à la fois par leur moyenne sur les 6 heures, mais aussi par leur variabilité rapide, c’est-à-dire leur structure de dépendance temporelle.

Définition de la variabilité Il n’existe pas de définition unique de la variabilité de la production éolienne. Le terme de variabilité recouvre différentes notions selon les études, car la définition est dépendante de la problématique de chaque étude.

La notion de *rampe* de puissance, et en particulier de “ramp rates” (taux d’accroissement) est souvent utilisée. Dans leur rapport sur la variabilité de fermes éoliennes, Sørensen *et al.* [94] définissent ce taux comme la variation de puissance *moyenne* entre deux fenêtres de moyennage consécutives. Cette définition laisse ouvert le choix de la longueur de fenêtre, qui peut par exemple être 10 minutes [94, fig. 6].

Cependant, il existe d’autres métriques. Par exemple, dans une étude sur le lissage des fluctuations avec une batterie, Yoshimoto *et al.* [105] mesurent l’écart entre les puissances instantanées maximale et minimale sur une fenêtre de longueur donnée. Ils nomment cette mesure “Maximum Fluctuation” et considèrent des fenêtres de 1 à 60 minutes. Dans un travail sur la variabilité intra horaire, Boutsika *et al.* [20] utilisent la notion de “conditional range metric”, où “range” (l’amplitude) désigne le couple $(\min P_{prod}(k), \max P_{prod}(k))$ sur une fenêtre. Cette étude va un cran plus loin en étudiant la distribution de cette amplitude, non seulement fonction de la longueur de fenêtre, mais aussi fonction de la puissance moyenne sur la fenêtre (d’où le terme de *conditional range*). En particulier, Boutsika *et al.* observent que l’amplitude est plus petite lorsque la production est proche de 0 ou 100 % et plus grande pour les puissances intermédiaires [20, fig. 3].

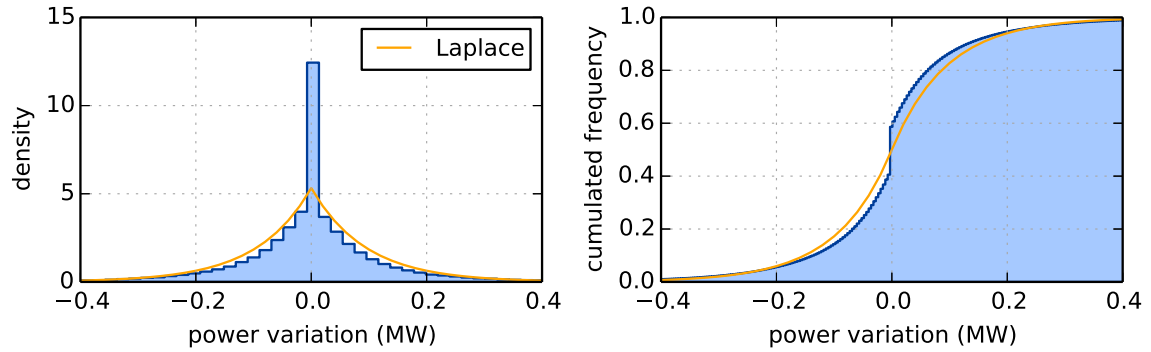


FIGURE 2.21 – Répartition des variations de production à pas d’une minute. Une répartition laplacienne de même écart-type est tracée pour comparaison.

Enfin, il y a également un intérêt spécifique pour les rampes de puissance extrêmes, en particulier dans le cadre du projet européen SafeWind. La question de la définition de ces rampes est intimement liée à la question de leur détection et in fine de leur prévision [19]. On trouvera plus de détails sur ces questions de détection dans les travaux de thèse d’Arthur Bossavy à Mines ParisTech [18].

Incréments de production Pour notre part, nous étudions, comme *Sørensen et al.*, la variabilité sous l’angle des variations entre deux instants consécutifs :

$$\Delta P(k) = P_{prod}(k) - P_{prod}(k - 1) \quad (2.36)$$

et nous rappelons que le pas de temps d’étude est pour nous 1 minute. Figure 2.21, nous représentons la répartition de ces écarts. L’écart-type des variations inter minutes est de 0,13 MW, à comparer aux 10 MW de puissance nominale de la ferme et à l’écart-type global de la production qui est de 1,5 MW. Ainsi, la variabilité sur 1 minute, mesurée en écart-type, vaut presque 9 % de la variabilité globale.

Au niveau de la forme de la distribution, elle est plus laplacienne que gaussienne, mais avec une forte proportion (15 %) de variations exactement nulle (cf. fig. 2.21 la discontinuité en zéro de la répartition cumulée). Ces variations nulles apparaissent essentiellement lors des phases de production nulle (vent faible ou arrêt des machines). Plus généralement, il faut garder à l’esprit que la répartition de la figure 2.21 est une vision marginale d’une répartition qui dépend en fait du niveau de production [20], comme c’est le cas aussi pour l’erreur de prévision (cf. § 2.3.1).

2.4.2 Modélisation simpliste

Dans l’objectif d’obtenir un modèle de la production pour l’optimisation du lissage des variations, nous supposons un modèle simple pour la série $\{\Delta P(k)\}$ des incréments de production : $\{\Delta P(k)\}$ est supposée une suite de variables aléatoires indépendantes et identiquement distribuées (iid). Nous notons $\sigma_{\Delta P}$ l’écart-type de ces incréments, qui vaut 0,13 MW pour les données de La Perrière.

Cette hypothèse d’indépendance (e.g. de décorrélation) fait de la production P_{prod} une *marche aléatoire*. Cela correspond bien à la forte persistance observée sur les données (fig. 2.19), mais relevons aussi que cette modélisation présente un important défaut physique. En effet, une marche




FIGURE 2.22 – Évolution de l'écart-type observé des variations de production à pas h (croissance qui sature), comparée au modèle de marche aléatoire (croissance en \sqrt{h} qui diverge).

aléatoire a un caractère *diffusif* (sa variance augmente linéairement au cours du temps), alors que la production est bien sûr bornée ($0 \leq P_{prod} \leq P_{nom}$).

Nous détaillons donc plus précisément cette question de la diffusion en s'intéressant figure 2.22 à une statistique qui mesure effectivement le caractère diffusif de la production. Nous analysons les variations de la production entre des instants éloignés d'un temps h :

$$\Delta_h P(k) = P_{prod}(k) - P_{prod}(k - h) \quad (2.37)$$

et nous représentons figure 2.22 l'écart-type de cette variation à pas h . Nous observons que cet écart-type est d'autant plus grand que l'écart temporel h est grand. Cependant, l'écart-type sature lorsque les instants sont suffisamment éloignés ($h > 200$ heures environ). Cela montre que les valeurs de la production éloignées de plus d'une semaine sont décorréélées. La variance de $\Delta_h P$ vaut alors le double²⁹ de la variance de la production σ_P^2 . Figure 2.22, cette saturation est représentée en termes d'écart-type par l'asymptote $\sqrt{2}\sigma_P$.

Par comparaison, nous représentons l'écart-type théorique du modèle marche aléatoire. Avec ce modèle, la variation à pas h de l'équation (2.37) devient la somme de h incréments indépendants de variance $\sigma_{\Delta P}^2$. La variance de $\Delta_h P$ vaut alors $\sigma_{\Delta P}^2 \times h$. Figure 2.22, ce modèle est représenté en termes d'écart-type par la courbe $\sigma_{\Delta P} \sqrt{h}$ qui diverge lorsque $h \rightarrow \infty$, contrairement à l'écart-type observé qui sature.

Nous observons une bonne adéquation des données au modèle $\sigma_{\Delta P} \sqrt{h}$ pour un horizon moyen (h entre 1 et 15 minutes), avec une erreur relative inférieure à 15%. Au-delà de 15 minutes, le modèle marche aléatoire surestime la variance à cause de sa divergence.

Malgré sa validité limitée, ce modèle a l'avantage d'être un modèle extrêmement simple, puisqu'il n'y a aucune mémoire pour les incréments ΔP . Du point de vue de la production $P_{prod}(k)$, il s'agit d'un modèle markovien d'ordre 1, ce qui est très avantageux pour l'utilisation dans un algorithme de Programmation Dynamique.

29. Les variances de 2 variables aléatoires indépendantes s'additionnent. Ainsi, pour $h > 200$ heures, on a : $\text{Var}[\Delta_h P] = \text{Var}[P_{prod}(k)] + \text{Var}[P_{prod}(k - h)] = 2 \text{Var}[P_{prod}] = 2\sigma_P^2$




FIGURE 2.23 – Autocorrélation des variations de production à pas d’une minute (estimation sur les données). Le trait pointillés marque l’intervalle de confiance autour de zéro.

Néanmoins, l’hypothèse d’indépendance des incréments ΔP reste une approximation. Nous avons tracé leur autocorrélation figure 2.23 où nous observons une *légère mais significative corrélation négative* pour toute une plage d’écart temporels jusqu’à 30 minutes. Nous avons souhaité comprendre comment cette structure temporelle pouvait être modélisée, ce qui nous amène à faire le lien avec le spectre de la production et la notion de bruit fractionnaire.

2.4.3 Analyse spectrale et bruit fractionnaire

Plusieurs travaux ont été publiés sur l’analyse spectrale des séries temporelles de production éolienne. Avant de les présenter, nous rappelons, de façon simplifiée, la définition théorique de la densité spectrale de puissance ou PSD en abrégé (Power Spectral Density). Le lecteur se rapportera à Brockwell *et al.* [21, §4.3] pour plus de détails et de rigueur.

Analyse spectrale – définitions La densité spectrale, que nous notons $S(\lambda)$, est définie pour une série temporelle *stationnaire* $\{X(k)\}$ comme la transformée de Fourier de sa fonction d’auto-covariance γ :

$$S(\lambda) = \frac{1}{2\pi} \sum_{k \in \mathbb{Z}} \gamma(k) e^{-ik\lambda} \quad \text{pour } \lambda \in [-\pi, \pi] \quad (2.38)$$

où la variable λ est une pulsation normalisée (en rad/sample). La conversion en fréquence (en Hz) se fait par la relation $\lambda = 2\pi f/F_s$ (avec $f \in [-F_s/2, F_s/2]$) où F_s est la fréquence d’échantillonnage. Pour exprimer le spectre en Hz, il y a donc un facteur d’échelle $\tilde{S}(f) = 2\pi/F_s S(\lambda)$. En termes d’unités, nos données s’exprimant en MW, le spectre $\tilde{S}(f)$ est en MW^2/Hz . La densité spectrale est positive et symétrique ($S(-\lambda) = S(\lambda)$) pour des données réelles ce qui explique qu’elle n’est généralement représentée que pour les fréquences positives.

La transformation de Fourier inverse permet retrouver l’autocovariance à partir de la densité spectrale :

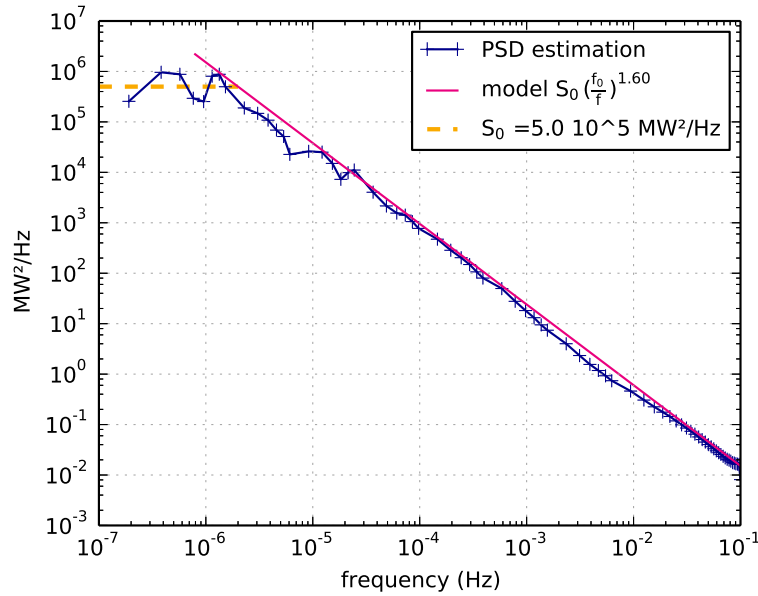


FIGURE 2.24 – Densité spectrale (PSD) estimée de la production éolienne (à pas de 5 s, donc $F_s/2 = 0,1$ Hz). Comparaison à un modèle de décroissance en $1/f^\alpha$, avec $\alpha = 1,6$.

$$\gamma(k) = \int_{-\pi}^{+\pi} S(\lambda) e^{ik\lambda} d\lambda = \int_{-F_s/2}^{+F_s/2} \tilde{S}(f) e^{2i\pi kf/F_s} df \quad \text{pour } k \in \mathbb{Z} \quad (2.39)$$

Dans cette équation, on note la relation particulière pour $k = 0$ qui donne la variance par la sommation du spectre : $\text{Var } X = \gamma(0) = \int S(\lambda) d\lambda$. Ainsi, la densité spectrale représente bien la *répartition de la variance* du processus le long de l'axe des fréquences.

D'un point de vue pratique, la définition (2.38) n'est pas utilisable pour estimer le spectre à partir d'un extrait de série temporel. Différentes méthodes d'estimation existent, dont beaucoup sont basées sur le lissage du périodogramme [21, chap. 10].

Remarquons avec la définition (2.38) que le spectre d'un processus stochastique ne caractérise que les *statistiques d'ordre 2* (la covariance) du processus. Il y a donc une grande différence avec la transformée de Fourier d'un signal déterministe qui, elle, définit entièrement le signal.

Analyse spectrale de données de production La densité spectrale de la *vitesse du vent* est assez largement étudiée et fait même l'objet de normes [94, §6.1.1]. Partant de la densité spectrale du vent, il existe d'ailleurs des générateurs de séries temporelles, comme celui de Nichita *et al.* [75]. Par contre, l'analyse spectrale des données de *production éolienne* est moins courante. Nous relevons en particulier le travail de Apt [3]. Celui-ci fait le lien entre ses observations de spectres et la théorie des fluides turbulents de Kolmogorov [65] (1941) qui prédit une décroissance du spectre en $1/f^{5/3}$. Le travail d'Apt a également été rediscuté dans la thèse de Bossavy [18, fig. 2.2, p 30]. Pour référence, notons que l'analyse d'Apt a été prolongée par Katzenstein *et al.* [59] qui analyse, toujours dans le domaine spectral, l'effet du foisonnement entre plusieurs fermes.

Pour notre part, nous avons réalisé l'analyse spectrale des données de La Perrière, et comme Apt nous obtenons un spectre qui décroît effectivement en $1/f^\alpha$ (donc linéairement en échelle log-log) sur 5 décades (10^{-6} à 10^{-1} Hz). Comme représenté sur la figure 2.24, le spectre décroît avec une pente $\alpha = -1,6$, proche de la valeur de la théorie de Kolmogorov ($-5/3 \approx 1,67$).

Par ailleurs, nous esquissons le lien entre cette décroissance avec une puissance non entière et la théorie des *bruits fractionnaires* ou plus généralement des processus dits à *longue mémoire*.

Processus à longue mémoire, bruit fractionnaire Nous ne souhaitons pas entrer dans la théorie des processus à longue mémoire avec qui nous avons peu d'expérience. Nous dirigeons donc le lecteur vers Brockwell *et al.* [21, § 13.2 Long memory processes] pour la définition d'un processus ARIMA(p,d,q). Ce modèle a été introduit par Hosking [57] pour modéliser la persistance dans des données hydrologiques, en particulier le débit du Nil. Nous souhaitons simplement souligner le lien entre ces modèles de série temporelle et l'analyse spectrale qui révèle une décroissance du spectre en $1/f^\alpha$.

Partant d'un bruit blanc $\{\varepsilon(k)\}$, on crée un processus stochastique $\{X(k)\}$ appelé bruit fractionnaire par la relation :

$$X(k) = (1 - B)^{-d} \varepsilon(k) \quad \text{avec } d \in \mathbb{R} \quad (2.40)$$

où B est l'opérateur retard³⁰. De cette relation, analysons trois cas particuliers où d est entier :

- pour $d = +1$, $X(k)$ est un bruit intégré, défini par $X(k) = X(k-1) + \varepsilon(k)$
- pour $d = 0$, $X(k)$ est le bruit blanc d'entrée inchangé, $X(k) = \varepsilon(k)$
- pour $d = -1$, $X(k)$ est un bruit différencié, défini par $X(k) = \varepsilon(k) - \varepsilon(k-1)$

Le coefficient d est donc le *degré d'intégration* fractionnaire. Dans le cas où d n'est pas entier, la relation (2.40) doit être prise dans un sens formel : $X(k)$ est un processus MA(∞)³¹ dont les coefficients (i.e. la réponse impulsionnelle) proviennent du développement en série de Taylor de la fonction $z \mapsto (1 - z)^{-d}$. Précisons que pour avoir une variance finie, il faut imposer $d < 1/2$. Le terme long mémoire vient de la décroissance lente de la fonction d'autocovariance³².

Ce modèle de bruit fractionnaire, qui peut être combiné avec un processus ARMA pour former un ARIMA(p,d,q) [57], présente l'intérêt d'avoir un spectre dont *l'asymptote est une puissance fractionnaire* de la fréquence :

$$S(\lambda) = C |1 - e^{-i\lambda}|^{-2d} \underset{0}{\sim} C \lambda^{-2d} \quad \text{avec } C = \sigma_\varepsilon / 2\pi \quad (2.41)$$

Ainsi, la pente $\alpha = -1,6$ du spectre de la figure 2.24 correspond à un degré d'intégration fractionnaire $d = 1,6/2 = 0,8$. Nous observons donc que nous sommes assez proches du modèle de marche aléatoire (i.e. un bruit intégré, $d = 1$) présenté plus haut. Lorsqu'on différencie la production pour s'intéresser aux incréments $\Delta P(k)$, cela revient à faire chuter d'une unité le degré d'intégration pour arriver à $d = -0,2$ (i.e. un bruit légèrement différencié), ce qui est assez en accord avec l'observation de l'autocorrélation des incréments (fig. 2.23).

L'outil des bruits fractionnaires permet donc de créer un modèle *temporel* qui est en bon accord avec les observations dans le domaine spectral. Par ailleurs, ce type de modèle permet également de *synthétiser* des séries temporelles (e.g. grâce au paquet `fracdiff` dans R), ce qui peut être bien utile pour une simulation.

Par contre, dans une perspective d'optimiser la gestion (par la Programmation Dynamique), cette modélisation à longue mémoire souffre d'un problème qui nous semble insoluble : l'ordre d'un tel modèle est infini alors même que la Programmation Dynamique exige des modèles de faible dimension ($\dim < 4$).

30. B pour opérateur "backshift" qui décale une série $\{X(k)\}$ en $\{X(k-1)\}$.

31. $X(k) = \sum_{i=0}^{\infty} h_i \varepsilon(k-i)$, avec pour réponse impulsionnelle $h_i = \prod_{j=1}^i \frac{j-1+d}{j}$.

32. $\gamma(h)$ décroît en $1/h^{1-2d}$ alors que la décroissance est exponentielle pour un ARMA.

Sans avoir étudié la question en détail, nous relevons qu'il est possible d'approximer un bruit fractionnaire (longue mémoire) par un processus ARMA (courte mémoire), en particulier avec un ARMA(1,1). Cette approximation ARMA, discutée par Basak *et al.* [7], repose sur une quasi-compensation entre les pôles du polynôme AR et les zéros du polynôme MA. Malheureusement, il est plus avantageux, pour la Programmation Dynamique, d'utiliser un modèle purement AR (pour avoir une observation parfaite de l'état). L'approximation par une somme d'AR(1) de Mandelbrot [70] pose le même problème d'observation.

Pistes d'amélioration du modèle Au-delà de la question de la longue mémoire, qui nous semble difficile à mettre en œuvre avec la programmation dynamique, nous proposons deux pistes pour améliorer le modèle simple de marche aléatoire présenté partie 2.4.2. Ces deux pistes ont l'avantage de ne pas trop augmenter la dimension du modèle :

- prendre en compte la *dépendance* entre la distribution des variations de puissance $\Delta P(k)$ et le niveau de puissance produite $P_{prod}(k)$, comme souligné par Boutsika *et al.* [20]. Cela aboutit à un modèle markovien d'ordre 1 de la production $P_{prod}(k)$. Ce type de modèle a par exemple été décrit par Papaefthymiou *et al.* [78] (avec discrétisation de P_{prod} pour obtenir une chaîne de Markov avec quelques dizaines d'états discrets).
- utiliser un modèle AR avec une chaîne Markov cachée pour modéliser des types de temps. Déjà mentionné partie 2.3.2 pour la modélisation des erreurs de prévisions, un tel modèle permettrait de modéliser des changements de régime (présence de “bouffées de variabilité” par exemple).

Pour conclure cette discussion sur la modélisation de la variabilité de production, signalons que nous avons mis en œuvre à la partie 3.4.2 le modèle de marche aléatoire pour la gestion optimale du lissage de rampe. Cet étude est malheureusement trop esquissée pour en déduire quelles améliorations sur la modélisation méritent le plus d'attention.

2.5 Intégration logicielle des modèles : StorageSim

La plupart des modèles présentés dans ce chapitre ont vocation à alimenter des simulations temporelles servant au dimensionnement d'un système de stockage d'énergie. Au fur et à mesure de nos travaux, nous avons donc écrit différents codes de simulation temporelle utilisés en particulier dans deux communications [52, 53]. Au fil de l'enrichissement de notre bibliothèque de modèles, nous avons souhaité *consolider* les différentes briques éparses dans un cadre unifié mais modulaire.

Nous avons donc créé un petit module Python³³ baptisé StorageSim qui permet de réaliser des simulations temporelles de stockage, et en particulier des simulations Monte-Carlo (sollicitations stochastiques). Ce module implémente un système de puissance simple représenté figure 2.25. Ce système générique comporte :

- une sollicitation d'**entrée** (puissance P_{in}) qui peut par exemple être un modèle stochastique de production éolienne, de productible éolien, ou bien d'erreur de prévision (cf. modèle AR(1) détaillé partie 2.3.2)

33. Langage de programmation créé dans les années 1990 par Guido van Rossum (<http://python.org/>). Populaire pour le développement d'applications web, il est aussi utilisé en science, par exemple en astronomie et en bio-informatique. Il se popularise aussi pour l'analyse de données (en compétition avec R bien implanté en statistiques). Son utilisation en ingénierie est moindre (prédominance de Matlab/Simulink).




FIGURE 2.25 – Flux de puissance d’une simulation StorageSim. Un ou des systèmes de stockage* absorbent des puissances $P_{sto}(i)$ qui permettent de régler la puissance en sortie P_{out} , face à une entrée P_{in} incontrôlée. (*) La notion de “stockage” est légèrement élargie pour inclure aussi l’absorption *irréversible* d’énergie, en particulier le délestage, lorsque P_{in} représente non pas une production mais un productible éolien.

- un ou des **systèmes de stockage** (puissance $P_{sto}^{(i)}$), ou plus généralement des “absorbeurs d’énergie” ce qui permet aussi d’inclure du délestage.
- une **sortie** (puissance P_{out}) qui reçoit tout ce qui a été injecté mais non stocké. Si par exemple l’entrée est une production éolienne brute, alors la sortie représente une production lissée par le stockage.

La puissance de sortie est liée algébriquement aux autres puissances :

$$P_{out} = P_{in} - \sum_i P_{sto}^{(i)} \quad (2.42)$$

et dans cette équation, P_{in} est une entrée incontrôlée alors que la ou les puissances $P_{sto}^{(i)}$ sont les variables de contrôle qui permettent d’influer sur la sortie (par exemple réaliser un lissage de production). Chaque stockage bénéficie d’une *loi de contrôle* qui fixe P_{sto} en fonction de la sollicitation d’entrée P_{in} ainsi que de toute variable d’état du stockage, en particulier son énergie E_{sto} .

La structure générique de l’équation de flux (2.42) permet de représenter des contextes bien différents. Dans notre contexte éolien-stockage (§1.2.2) elle reproduit l’équation de l’écart à l’engagement (1.8), avec P_{out} dans le rôle de P_{dev} et P_{in} dans le rôle de l’erreur de prévision P_{mis} . Dans le contexte d’un véhicule hybride, P_{in} peut jouer le rôle de la puissance demandée à la chaîne de traction du véhicule (“profil de mission”) et P_{out} est alors la puissance demandée au moteur thermique. C’est en ce sens que nous qualifions la structure de la figure 2.25 de générique.

Structure Le module StorageSim s’organise en différents sous-modules :

- inputgen contient les modèles des données d’entrée en particulier pour la génération stochastique d’erreur de prévision (modèle AR(1) détaillé partie 2.3.2).
- consumer contient les modèles des systèmes qui absorbent l’énergie du signal d’entrée, c’est-à-dire en particulier les modèles de systèmes de stockage (modèle idéal §2.1.1 et Lithium-ion §2.1.2).
- electrochem permet la création d’un modèle de batterie électrochimique à partir de la modélisation générique de la tension $V(I_{cell}, Q_{cell})$ détaillée partie 2.1.2. Le modèle Lithium-ion de SAFT est donc une dérivation particulière de ce modèle.

- simulation contient le code de simulation temporelle proprement dit, qui orchestre le dialogue entre les différents composants. Un mécanisme intégré dans la boucle de simulation permet le calcul automatique de statistiques à chaque simulation (statistiques définies librement par l'utilisateur).

Au niveau de l'architecture, le code utilise une approche orientée objet, mais privilégie la composition des classes³⁴ à l'héritage (i.e. classes dérivées). Le calcul numérique est effectué avec des tableaux numpy [98] (<http://www.numpy.org/>), module classique pour le calcul numérique en Python.

Au niveau de la maintenance, le code est versionné avec git (<http://git-scm.com/>), est documenté avec sphinx (<http://sphinx-doc.org>) et utilise le framework de tests unitaires nose (<https://nose.readthedocs.org>).

Utilisation et disponibilité Grâce à la nature dynamique du langage Python, les simulations peuvent être effectuées interactivement (comme avec Matlab). Un exemple de session d'utilisation avec le Notebook IPython [81] est proposé en annexe B.1.

Ce logiciel est disponible librement (licence BSD) sur Internet. Pour des raisons de confidentialité, le modèle de batterie Sodium-Soufre (§2.1.3) ne fait pas partie de ce logiciel.

Dans ce chapitre, nous avons présenté les modélisations nécessaires à l'étude du dimensionnement et de la gestion d'un stockage d'énergie. Ces modèles sont de nature variée puisqu'ils concernent à la fois des *composants* (systèmes de stockage d'énergie), des *phénomènes* (vieillessement en cyclage des batteries) et des *entrées du système* (production éolienne, erreur de prévision de production).

Nous poursuivons à présent le fil de notre problématique pour aborder au chapitre 3 la question de la *gestion* de l'énergie d'un système de stockage.

34. cf. discussion "Prefer composition over inheritance?" <http://stackoverflow.com/questions/49002/>

Chapitre 3

Gestion optimale de l'énergie stockée

Sommaire

3.1	Présentation de la Programmation Dynamique Stochastique	73
3.2	Discussion sur l'applicabilité, critique et comparaison	85
3.3	Gestion optimale pour la garantie d'engagement J+1	91
3.4	Autres applications de gestion optimale de stockage	104

Nous avons identifié au chapitre introductif que l'optimisation de la gestion de l'énergie d'un système de stockage, à dimensionnement fixé, est l'une des deux questions principales de nos travaux (cf. partie 1.2.3, l'autre question étant le dimensionnement). Nous abordons l'optimisation de la gestion avant celle du dimensionnement, car nous avons vu partie 1.3.3 que, pour un traitement couplé de ces deux problèmes, l'optimisation de gestion peut se faire à *dimensionnement fixé*, à l'intérieur d'une boucle externe d'optimisation du dimensionnement (co-optimisation imbriquée [42]).

Par ailleurs, nous avons identifié (§1.3.3) que le problème d'optimisation de la gestion est de nature *dynamique* (présence de variables d'état, à commencer par l'état d'énergie) et *stochastique* (présence d'incertitude sur les erreurs de prévision). Ce diagnostic nous a conduits à sélectionner la méthode de la programmation dynamique de Bellman [8] (abrégée DP en anglais), dans sa déclinaison stochastique (SDP).

Nous commençons donc partie 3.1 par présenter la SDP, avec ses concepts et ses notations. Nous illustrons cette présentation avec l'exemple concret qu'est notre problème principal : la gestion de stockage pour la garantie d'un engagement J+1. Partie 3.2, nous discutons de l'application de la méthode d'un point de vue général et nous comparons la SDP à d'autres méthodes de gestion d'énergie. Ensuite, nous détaillons partie 3.3 l'exploitation des résultats d'optimisation sur notre problème spécifique. En particulier, nous discutons l'effet du choix de différentes fonctions coûts pour pénaliser l'écart à l'engagement. Enfin, nous proposons partie 3.4 des résultats de l'application de la SDP sur des problèmes complémentaires de stockage.

3.1 Présentation de la Programmation Dynamique Stochastique

Avant de détailler la méthode, nous présentons un rapide état des lieux de son utilisation pour la gestion d'un stock d'énergie.

3.1.1 Utilisation de la (S)DP pour la gestion d'énergie

La programmation dynamique a été créée par Bellman [8] dans les années 1950 pour étudier et résoudre les problèmes d'optimisation dynamique tels que les allocations successives de ressources (multi-stage allocation). L'intérêt de cette méthode pour la gestion du stock d'énergie d'une batterie vient du parallèle évident avec la gestion du stock d'eau d'un barrage hydroélectrique.

L'utilisation de la (S)DP pour résoudre des problèmes de ressources en eau, et en particulier la gestion de réservoirs est presque concomitante à la méthode elle-même (voir par exemple le panorama de Yakowitz [103] en 1982). La gestion du stock d'eau de barrages hydroélectriques fait donc appel à cette méthode depuis longtemps et a fait l'objet de nombreux développements dont le plus connu est peut-être la méthode SDP duale (SDDP) de Pereira *et al.* [80]¹. La recherche se poursuit encore actuellement, par exemple pour inclure des contraintes en probabilité sur le stock [2] (exemple : garantir qu'un lac de barrage soit suffisamment rempli certains mois d'été pour satisfaire les besoins du tourisme nautique).

De façon générale, la programmation dynamique a été utilisée pour différents problèmes de gestion d'énergie *avec incertitude*. Nous relevons en particulier le travail de Lin *et al.* [68] (University of Michigan) sur un véhicule hybride et celui de Bilbao *et al.* [10] (EPFL, Suisse) sur un ascenseur avec stockage. Pour ces deux applications, la clé de l'optimisation se situe dans la modélisation des systèmes, et en particulier de la dynamique des incertitudes. Dans chaque cas, la SDP permet d'obtenir une *loi de gestion* optimale. Costa [27][chap. 5] a également étudié la prise en compte d'incertitudes dans la planification d'un micro-réseau.

La programmation dynamique a aussi été utilisée dans un contexte de gestion d'énergie *déterministe*, c'est-à-dire la planification à l'avance, *hors-ligne*, du partage optimal des flux de puissance (i.e. calcul de trajectoire optimale). Nous relevons le travail de Riffonneau *et al.* [88] (Grenoble) sur un système photovoltaïque-batteries et de Caux *et al.* [25] (Toulouse) sur un véhicule hybride. Cependant, cette utilisation de la programmation dynamique dans un contexte déterministe ne doit *pas être confondue* avec l'utilisation dans un contexte stochastique, car les objectifs sont nettement différents. Comme nous allons le voir dans la prochaine partie, l'optimisation stochastique a pour objectif d'obtenir une *loi de gestion* optimale, par opposition à l'optimisation déterministe qui recherche une *trajectoire* optimale. Nous précisons donc en particulier cette notion de "loi de gestion".

Pour l'essentiel, nos connaissances sur la programmation dynamique proviennent du livre de Dimitri Bertsekas [9]². En particulier, nous pensons que son premier chapitre présente de façon concise et claire 80 % des concepts utilisés dans nos travaux. Nous avons également trouvé quelques compléments utiles chez Whittle [100].

Relevons que l'optimisation dynamique est l'objet d'un partenariat industrie-université persistant entre EDF R&D et l'équipe d'optimisation de Michel De Lara, au CERMICS (laboratoire de l'École des Ponts ParisTech). Nous avons bénéficié de cette expérience en participant à l'école "Stochastic Control for the Management of Renewable Energies" (STOCORE) organisée en avril 2013 au CIRM³ par Pierre Carpentier, Jean-Philippe Chancelier et Michel De Lara.

1. Cette méthode a fait l'objet d'un développement commercial réussi avec logiciel SDDP développé par PSR (<http://www.psr-inc.com.br>) pour l'optimisation du dispatch d'une production hydraulique et thermique (société brésilienne, dans un pays où 3/4 de la production est hydroélectrique).

2. les supports visuels de son cours au MIT sont librement disponibles (<http://ocw.mit.edu>, course nb. 6.231).

3. Centre International de Rencontres Mathématiques, à Marseille

3.1.2 Mise en œuvre de la méthode SDP

Les ingrédients de la méthode La programmation dynamique s'intéresse à l'optimisation d'un système au fil du temps (nous considérons des instants discrets k). Plus précisément, elle s'intéresse au cas où les décisions ne peuvent être prises séparément à cause d'un *couplage temporel* représenté par une équation dynamique :

$$x_{k+1} = f(x_k, u_k, w_k) \quad (3.1)$$

où interviennent trois variables (scalaires ou vectorielles) :

- l'état du système x , qui joue le rôle de "mémoire" ou d'"inertie",
- la commande u , que l'on souhaite choisir à chaque instant k pour minimiser un coût,
- la perturbation aléatoire w , qui rend l'état futur x_{k+1} partiellement incertain (perturbation absente dans le cas d'un problème déterministe),

et la fonction f est appelée "dynamique du système". Nous la supposons ici invariante, c'est-à-dire indépendante de l'instant k .

L'objectif à minimiser est une *fonction coût additive*, c'est-à-dire la somme cumulée du coût, noté $c(x_k, u_k, w_k)$, que subit le système à chaque instant :

$$\sum_{k=0}^{K-1} c(x_k, u_k, w_k)$$

or la présence de perturbations stochastiques w_k fait de cette somme une *variable aléatoire* pour laquelle la minimisation n'a pas de sens. Nous considérons alors que l'objectif est de minimiser l'*espérance* (la moyenne par rapport aux perturbations) de cette somme :

$$J = \mathbb{E} \left\{ \sum_{k=0}^{K-1} c(x_k, u_k, w_k) \right\} \quad (3.2)$$

et K représente le nombre d'instant considérés pour l'optimisation, appelé *horizon* du problème. Le coût (3.2) est un problème à horizon *fini*, sachant que nous abordons plus bas la question de l'horizon infini (pour minimiser un *coût moyen*).

Application au problème de garantie d'engagement Nous rappelons figure 3.1 (reproduction de la figure 1.3) la structure de notre problème : gestion d'un stockage pour garantir un engagement $J+1$. P_{mis} est l'erreur de prévision, ou plus généralement l'écart entre le productible et un engagement $J+1$. L'objectif de la gestion est de *répartir optimalement* ce flux d'énergie, à chaque instant k , entre un stockage (P_{sto}) et le réseau (P_{dev}), l'écart à l'engagement qui est pénalisé). Pour la présente illustration, nous ne considérons pas l'écrêtage du productible ($P_{cur} = 0$).

La première étape de la mise en œuvre de la programmation dynamique consiste à modéliser le problème, ce que nous avons fait au chapitre 2. En particulier, il faut faire l'inventaire des variables d'états, celles qui apparaissent dans une équation dynamique du type (3.1). Pour notre problème, nous avons une première variable d'état évidente : l'énergie E_{sto} contenue dans le système de stockage. Cette énergie est régie par une équation du type :

$$E_{sto}(k+1) = E_{sto}(k) + P_{sto}(k)\Delta_t \quad (\text{rappel 2.1})$$

où $P_{sto}(k)$ joue le rôle d'une variable de commande u_k .




FIGURE 3.1 – Structure simplifiée du système “éolien-stockage avec engagement” pour la gestion d’énergie

Pour le coût, nous allons prendre l’exemple simple d’une pénalisation quadratique de l’écart à l’engagement :

$$c = P_{dev}^2(k) = (P_{mis}(k) - P_{sto}(k))^2 \quad (\text{cf. 1.8})$$

qui fait intervenir P_{mis} , l’écart entre productible et engagement. Nous avons vu que cet écart (qui est, avec quelques hypothèses, l’erreur de prévision $J+1$) a un comportement stochastique. On pourrait croire qu’il suffit de prendre l’écart P_{mis} comme variable de perturbation w , mais cela n’est pas possible. En effet, la SDP impose que la série des perturbations $\{w_k\}$ soient *indépendantes entre elles*, or nous avons vu partie 2.3.2 que les erreurs de prévision $J+1$ sont fortement corrélées et nous en avons proposé un modèle AR(1) (2.34). Cette corrélation “promeut” la perturbation P_{mis} au rang de variable d’état. Ainsi, notre modèle de dynamique fait intervenir deux variables d’état $x = (E_{sto}, P_{mis})$, régies par l’équation :

$$\begin{aligned} E_{sto}(k+1) &= E_{sto}(k) + P_{sto}(k)\Delta_t \\ P_{mis}(k+1) &= \phi P_{mis}(k) + w(k) \end{aligned} \quad (3.3)$$

où P_{sto} est la variable de commande et w la perturbation indépendante et identiquement distribuée (iid). Le pas de temps Δ_t vaut 1 heure, en lien avec le modèle AR(1) et nous prenons $\phi = 0,8$ pour la corrélation des erreurs entre 2 heures consécutives.

Pour terminer la modélisation, nous devons considérer des *contraintes* sur la commande. Elles peuvent dépendre de l’état et sont notées génériquement $u \in U(x)$. Pour notre exemple, ce sont les limites du stockage qui contraignent la puissance absorbable :

- les limites d’énergie : $0 \leq E_{sto} + P_{sto}\Delta_t \leq E_{rated}$ (i.e. (2.2))
- les limites de puissance : $|P_{sto}| \leq P_{rated}$

Pour toute la partie 3.1, nous fixons numériquement l’échelle du système de stockage avec une capacité $E_{rated} = 10$ MWh et pour l’écart-type des erreurs de prévision $\sigma_p = 1$ MW. Cela correspondrait à une erreur RMS de 10 % pour une ferme éolienne de 10 MW. Pour cette partie nous ne souhaitons pas limiter la puissance, mais l’hypothèse gaussienne du modèle AR(1) rend improbable toute erreur $P_{mis} > 4\sigma_p$. Nous prenons donc $P_{rated} = 4$ MW.

Résolution du problème d’optimisation A priori, la fonction coût (3.2) semble dépendre de $3K$ variables : les triplets (x_k, u_k, w_k) pour $k = 0, \dots, K-1$. Cependant, l’effet des perturbations w_k est moyenné avec l’opérateur espérance. De plus, l’évolution des variables d’état est complètement définie par la dynamique (3.1), une fois que l’on connaît les contrôles et l’état initial.

Ainsi, le problème d'optimisation consiste-t-il à trouver, en agissant sur la série des contrôles (u_0, \dots, u_{K-1}) , le coût minimal J^* , qui dépend uniquement de l'état initial x_0 :

$$J^*(x_0) = \min_{u_0, \dots, u_{K-1}} J(x_0, u_0, \dots, u_{K-1}) \quad (3.4)$$

La résolution se fait grâce au “principe d'optimalité” de Bellman [9, §1.3]. Il s'agit de découper temporellement la fonction coût pour faire une optimisation itérative, instant par instant, *en partant de la fin* du problème. À chaque pas, on calcule $J_k^*(x_k)$ qui est le coût optimal du sous-problème d'optimisation sur les instants $k, \dots, K - 1$:

$$J_k^*(x_k) = \min_{u_k, \dots, u_{K-1}} \mathbb{E} \left\{ \sum_{n=k}^{K-1} c(x_n, u_n, w_n) \right\} \quad (3.5)$$

1. La récursion démarre au dernier instant ($k = K$) dont le coût est nul⁴ :

$$J_K^*(x_K) = 0 \quad (3.6)$$

2. Puis, la récursion à rebours se poursuit avec “l'équation de la programmation dynamique” :

$$J_k^*(x) = \min_{u \in U(x)} \mathbb{E}_w \left\{ \underbrace{c(x, u, w)}_{\text{coût instantané}} + \underbrace{J_{k+1}^*(f(x, u, w))}_{\text{coût du futur}} \right\} \quad (3.7)$$

aussi appelée “équation de Bellman”.

L'équation de Bellman permet de calculer J_k^* à partir de la connaissance de J_{k+1}^* , c'est-à-dire qu'on résout l'optimisation sur les instants $k, \dots, K - 1$ grâce à la connaissance préalable de l'optimum sur les instants $k + 1, \dots, K - 1$. Au final, par récursion pour $k = K - 1, K - 2, \dots, 0$, on arrive à $J_0^*(x)$ qui est le coût minimal total $J^*(x_0)$ défini par (3.4).

En terme de vocabulaire, on parle de coût du futur (“cost-to-go” en anglais) pour parler de la pénalisation J_{k+1}^* des instants futurs. Dans les contextes où l'on cherche non pas à minimiser un coût mais à maximiser un revenu, on parle plutôt de fonction valeur ou de “valeur de Bellman”. Par exemple pour les barrages hydroélectriques, on parle de la “valeur de l'eau”. Le coût du futur dépend de l'état futur x_{k+1} , mais cette variable est éliminée grâce à la dynamique (3.1).

La résolution, à chaque itération, de la minimisation (3.7) présente un point remarquable :

L'optimisation ne fournit pas la *valeur ponctuelle* d'une commande optimale u_k^* mais une commande qui dépend de l'état, c'est-à-dire une *loi de gestion* optimale :

$$u_k^* = \mu_k^*(x_k) \quad (3.8)$$

Ainsi, la méthode de la programmation dynamique fournit deux résultats :

- résultat *structurel* : le coût minimum d'un problème d'optimisation dynamique stochastique est atteint par un fonctionnement en *boucle fermée*. La commande optimale est une fonction des variables d'état, fonction appelée “loi de gestion”⁵.

4. dans une formulation plus générale, il est possible d'ajouter au coût (3.2) une pénalisation $g_K(x_K)$ de l'état final x_K et dans ce cas $J_K^* = g_K$.

5. les termes pour désigner une loi de gestion varient selon les contextes : loi de contrôle, politique (policy en anglais), ou stratégie. Parfois certains les différencient, par exemple en appelant stratégie la séquence des lois de gestion à appliquer à chaque instant : $\pi = \{\mu_0, \dots, \mu_{K-1}\}$

- résultat *numérique* : l'équation de Bellman (3.7) permet de calculer, parmi toutes les lois de gestion possibles $\mu : x_k \mapsto u_k$, celle qui est optimale : μ_k^* . Cette loi optimale dépend de l'instant k , même pour un système avec une dynamique f invariante (3.1).

La notion de contrôle en boucle fermée s'oppose au contrôle en *boucle ouverte*, c'est-à-dire le précalcul, à l'instant $k = 0$, des commandes u_0, \dots, u_{K-1} . La performance supérieure de la boucle fermée s'explique par la présence des perturbations stochastiques qui ne sont pas connues au départ, mais qui sont *révélées au fur et à mesure*. En prenant une décision $u_k = \mu_k(x_k)$, on bénéficie, au travers des variables d'état, de la connaissance des perturbations passées w_0, \dots, w_{k-1} .

Appliquée à notre problème, la programmation dynamique nous apprend, du point de vue structurel, que la puissance optimale à stocker est une fonction (à déterminer) des variables d'état $E_{sto}(k)$ et $P_{mis}(k)$ à chaque instant. La décision optimale ne dépend pas de valeurs plus anciennes ou bien d'autres variables supplémentaires. La décision optimale n'est pas non plus une suite de valeurs $P_{sto}(0), P_{sto}(1), \dots$ qu'on précalculerait, par exemple au début de chaque journée.

Remarquons qu'avec un problème déterministe, c'est-à-dire en l'absence de perturbations, la boucle fermée perd son avantage sur la boucle ouverte du point de vue de la performance. C'est ainsi que l'optimisation dynamique déterministe, souvent appelée "contrôle optimal" cherche généralement à calculer une *trajectoire optimale* (i.e. la série de nombres (x_1^*, \dots, x_K^*)) plutôt que des lois de gestions (i.e. la série de fonctions $(\mu_0^*, \dots, \mu_{K-1}^*)$). Ce calcul direct des trajectoires peut souvent être plus efficace, mais, en présence d'incertitudes, cette optimisation en boucle ouverte n'est malheureusement plus optimale.

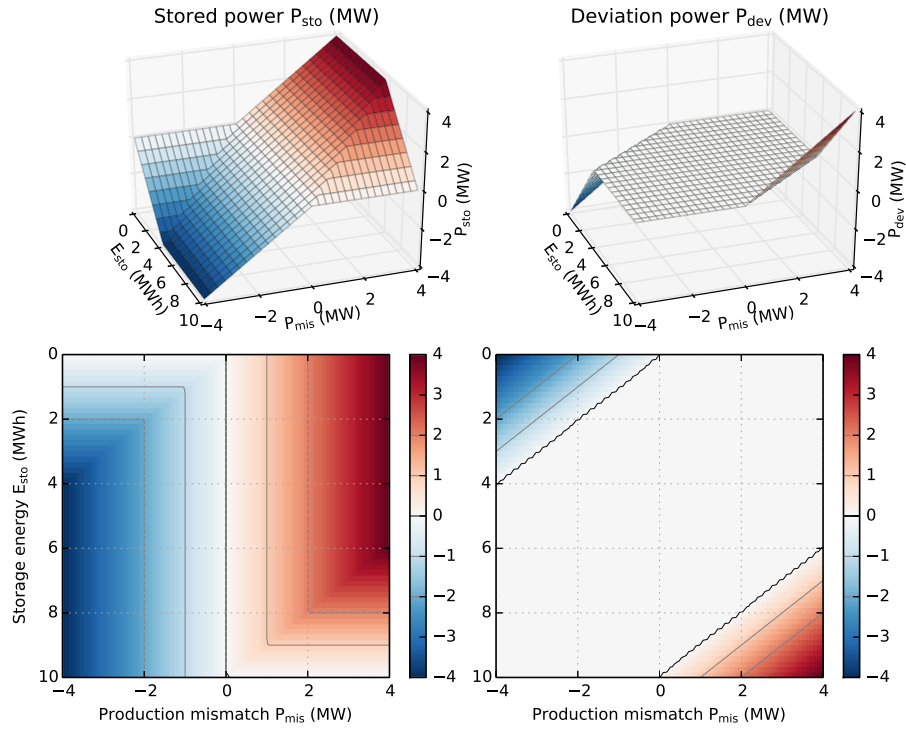
Interprétation de l'algorithme : stratégie myope vs proactive Interprétons la résolution récursive (3.7) sur notre problème pour mettre en évidence la notion de stratégie *myope*, par opposition à stratégie *proactive*.

La récursion commence avec $J_K^*(x_K) = 0$, c'est-à-dire un coût du futur nul, car il s'agit du dernier instant du problème. Par conséquent, la première itération (3.7) aboutit à une loi de gestion μ_{K-1}^* qui minimise seulement le coût instantané du dernier instant. Cette stratégie est bien optimale pour le dernier instant, car il n'y a pas d'instant futur à prendre en compte, mais elle n'est généralement pas optimale pour les instants précédents car elle est *myope*.


Pour notre problème, le coût d'un instant est P_{dev}^2 qui est minimal si l'on choisit $P_{sto} = P_{mis}$ (car alors $P_{dev} = 0$), sous réserve que les limites du stockage ne soient pas atteintes⁶. Cette loi de gestion est représentée sur la figure 3.2a.

6. rappelons que l'optimalité de cette décision est conditionnée à nos hypothèses de modélisation : pas de prise en compte des pertes ou de l'usure du stockage.

3.1 Présentation de la Programmation Dynamique Stochastique



(a) loi de gestion *myope* qui minimise l'écart P_{dev}^2 de façon instantanée



(b) loi gestion *proactive* qui ne compense qu'une partie de l'erreur instantanée pour mieux absorber les écarts futurs

FIGURE 3.2 – Comparaison de deux lois de gestion pour minimiser un coût quadratique $\sum_k P_{dev}^2(k)$.

Lecture des graphiques de loi de gestion

La figure 3.2 présente deux lois de gestions (3.2a et 3.2b), chacune représentée par 4 graphiques complémentaires. Cette représentation qui vise à apporter le maximum d'information est reprise plusieurs fois dans ce chapitre.

Tout d'abord, la loi de gestion est représentée avec le double point de vue des variables P_{sto} (puissance absorbée par le stockage, à gauche) et P_{dev} (écart à l'engagement, à droite). Ces deux variables contiennent certes la même information (car elles sont liées par $P_{dev} = P_{mis} - P_{sto}$), mais présente deux points de vue complémentaires : celui du système de stockage (P_{sto}) et celui du réseau électrique (P_{dev} qui subit la pénalisation).

Les lois de gestion sont des fonctions des deux variables d'état E_{sto} (entre 0 et 10 MWh) et P_{mis} (entre -4 et 4 MW). Pour en améliorer la visualisation, nous représentons chaque fonction à la fois par une surface 2D dans un espace 3D (en haut) par une carte de couleur (en bas). La représentation 3D permet de voir la *forme globale* (planéités, ruptures de pentes) alors que la carte de couleur permet de mieux voir les *courbes de niveaux*. Le code couleur indique la valeur de la puissance pour P_{sto} et P_{dev} respectivement (rouge sombre : 4 MW, blanc : 0 MW, bleu sombre : -4 MW). Les lignes de niveau -2, -1, +1, +2 MW sont marquées en gris et la ligne 0 MW en noir. En particulier, on observe figure 3.2a que la ligne $P_{sto} = 0$ est verticale ce qui correspond à $P_{mis} = 0$: la batterie n'absorbe aucune puissance lorsque l'erreur de prévision est nulle.

La ligne de niveau 0 MW pour P_{dev} bénéficie d'un traitement spécial : nous traçons en fait 2 lignes correspondant à deux niveaux très proches 0^- et 0^+ . Cela permet de mettre en évidence que, pour certaines loi de gestion, P_{dev} est strictement nulle sur une large plage. C'est le cas pour la gestion myope figure 3.2a mais pas pour la gestion proactive figure 3.2b.

Sur toutes les lois de gestion, on observera que la puissance absorbée P_{sto} est nulle ou négative lorsque la batterie est pleine, c'est-à-dire sur la ligne horizontale $E_{sto} = 10$ MWh. À l'opposé (ligne $E_{sto} = 0$ MWh), P_{sto} est toujours nulle ou positive lorsque la batterie est vide.

La loi de gestion de la figure 3.2a se réduit essentiellement à un *plan* : $P_{sto} = P_{mis}$ du point de vue du stockage, $P_{dev} = 0$ du point de vue du réseau. Ces plans sont cependant interrompus à cause de la saturation énergétique du stockage : l'écart à l'engagement P_{dev} devient positif [ou négatif] lorsque la batterie est quasi pleine [ou vide] et que l'erreur de prévision est positive [ou négative]. Plus précisément, cette saturation est elle-même linéaire (plans des coins haut-gauche et bas-droite) et on remarquera que $P_{sto}(k)$ en zone saturée prend une valeur telle que l'état d'énergie suivant $E_{sto}(k+1)$ est exactement plein ou vide (10 ou 0 MWh). Par exemple, $P_{sto}|_{E_{sto}=9, P_{mis}=3} = 1$ MW donc $E_{sto}(k+1) = 9+1 = 10$ (et en parallèle, $P_{dev} = 3-1 = 2$ MW).

Pourquoi cette stratégie $P_{sto} = P_{mis}$ est-elle myope ? Prenons le cas où l'erreur de prévision est positive (surproduction) : la stratégie $P_{sto} = P_{mis}$ invite à stocker la surproduction en totalité. Cependant, cela fait monter l'état d'énergie de la batterie, ce qui conduit aux instants suivants à se retrouver avec une batterie pleine, incapable d'absorber davantage d'énergie. Ainsi, compenser fortement l'erreur de prévision à un instant donné peut causer de fortes déviations aux instants futurs. Une stratégie plus proactive serait peut-être de n'absorber qu'une partie de la surproduction (ex : $P_{sto} = 0,6 P_{mis}$) pour se réserver plus de marges d'absorption pour le futur.

L'équation (3.7) exprime donc le *compromis* optimal entre la satisfaction des intérêts immédiats et la prise en compte des besoins futurs. L'information sur les intérêts futurs est portée par $J_{k+1}^*(x_{k+1})$ qui donne le coût du futur déjà optimisé à la précédente itération. Au fur et à mesure

des itérations, la stratégie optimale tient compte de plus en plus d'instants futurs (à l'itération k , l'équation de Bellman optimise un sous-problème à horizon $K - k$) et devient donc *proactive*⁷. Nous représentons figure 3.2 (en bas) la gestion optimale pour un horizon de 20 heures qui, pour minimiser l'écart quadratique moyen, accepte effectivement de ne pas annuler totalement P_{dev} .

Il s'avère d'ailleurs que pour un problème *stationnaire* (la dynamique f et le coût instantané c ne dépendent pas de l'instant) la stratégie μ_k^* se stabilise lorsque l'horizon $K - k$ devient "assez grand". Ce phénomène nous pousse à traiter l'optimisation à horizon infini pour trouver directement cette *stratégie stationnaire optimale*.

3.1.3 Optimisation d'un coût moyen (horizon infini)

Nous venons de présenter le problème d'optimisation à horizon fini, où le coût (3.2) est une somme de K instants. Dans le cas de l'optimisation d'un système éolien-stockage, l'horizon devrait être la durée de vie du système (20 ans environ) soit presque 200 000 instants ($\Delta_t = 1$ h). Cela représente beaucoup d'itérations, d'autant plus que la résolution numérique de l'équation de Bellman (3.7) montre que, passées les premières itérations, la loi de gestion μ_k devient stationnaire (ne dépend plus de k). Pour notre problème de gestion avec une batterie de 10 MWh, cette convergence intervient en une vingtaine de pas, soit $20\Delta_t = 20$ heures pour le système. Empiriquement, nous constatons que la constante de temps de convergence est de l'ordre de la constante de temps du stockage ($E_{rated}/\sigma_P = 10$ h).

Autre observation importante, la fonction coût augmente quasi linéairement avec le nombre d'instants considérés et donc la somme (3.2) diverge. Il devient alors naturel de considérer le coût moyen :

$$J = \frac{1}{K} \mathbb{E} \left\{ \sum_{k=0}^{K-1} c(x_k, u_k, w_k) \right\} \quad \text{with } K \rightarrow \infty \quad (3.9)$$

dont il faut noter que c'est un nombre et non plus une fonction de l'état initial, puisqu'avec $K \rightarrow \infty$ on considère un *état d'équilibre stationnaire* où l'état initial n'a plus d'influence.

L'optimisation de ce problème dit de "coût moyen à horizon infini" pose nettement plus de problèmes techniques (du point de vue mathématique) que les problèmes à horizon fini. Notre exposé les passe sous silence, mais ils sont abordés pour partie par Bertsekas [9, vol. 1, §7.4] qui y consacre également tout le chapitre 4 du second volume.

La résolution du problème s'exprime par une équation de Bellman modifiée. D'équation réursive, elle devient une équation d'équilibre stationnaire :

$$J^* + \tilde{J}(x) = \min_{u \in U(x)} \mathbb{E}_w \left\{ \underbrace{c(x, u, w)}_{\text{coût instantané}} + \underbrace{\tilde{J}(f(x, u, w))}_{\text{coût relatif du futur}} \right\} \quad (3.10)$$

où J^* est le coût moyen optimal et \tilde{J} le coût *relatif* optimal, fonction de l'état. Cette fonction n'est définie qu'à une constante près, donc il faut se donner un état de référence x_{ref} pour lequel nous fixons $\tilde{J}(x_{ref}) = 0$. L'argument de la minimisation fournit la loi gestion optimale $\mu^* : x \mapsto u$ qui est stationnaire. Le coût relatif $\tilde{J}(x)$ est aussi qualifié de *transitoire*, car il représente le coût transitoire que subit le système en allant à l'état x plutôt qu'à l'état de référence x_{ref} . Ce coût relatif joue donc le même rôle de pénalisation de l'état futur que la fonction coût-du-futur $J_{k+1}(x_{x+1})$ dans l'équation de Bellman à horizon fini (3.7).

7. attention, *proactif* ne doit pas être confondu avec *anticipatif* : la stratégie optimale proactive prépare l'avenir mais ne prétend pas le connaître. L'optimisation stochastique doit respecter la contrainte de *non-anticipativité*.

3 Gestion optimale de l'énergie stockée

Pour résoudre l'équation (3.10) du problème à horizon infini, il existe deux algorithmes classiques, tous deux itératifs :

- “Value Iteration” : calcul itératif de la fonction valeur $\tilde{J}(x)$
- “Policy Iteration” : calcul itératif de la loi de gestion $\mu(x)$

Value Iteration La fonction valeur (le coût du futur) est calculée de façon incrémentale, avec la même méthode que dans l'équation de Bellman classique (3.7) : augmentation incrémentale de l'horizon temporel du problème.

L'algorithme commence par une approximation triviale du coût relatif $\tilde{J}_0(x) = 0$ puis améliore successivement cette approximation en appliquant une étape de l'équation de Bellman :

$$J_{k+1} + \tilde{J}_{k+1}(x) = \min_{u \in U(x)} \mathbb{E}_w \left\{ \underbrace{c(x, u, w)}_{\text{coût instantané}} + \underbrace{\tilde{J}_k(f(x, u, w))}_{\text{coût relatif du futur}} \right\} \quad (3.11)$$

et cette équation est itérée jusqu'à ce que J_k converge vers J^* . En parallèle, la loi de gestion μ_k , qui est obtenue à chaque étape comme argument de la minimisation⁸, converge vers la gestion optimale μ^* .

Cet algorithme est simplement la reprise de l'équation originelle de la programmation dynamique, mais où l'on doit retirer à chaque pas la valeur du coût à l'état de référence pour aboutir à la décomposition $J_k + \tilde{J}_k(x)$ telle que $\tilde{J}_k(x_{ref}) = 0$ (on parle de “relative value iteration”)

Interprétation de l'algorithme : la stratégie optimale est calculée itérativement en partant d'une vision myope (initialement le futur est gratuit), puis l'horizon est augmenté incrémentalement pour s'approcher d'un horizon infini. Cette approche présente un défaut potentiel : elle force à résoudre des minimisations qui ne nous intéressent pas. En effet, les premières itérations correspondent à l'optimisation d'un problème à courte vue qui ne sert que de base pour l'optimisation à longue vue. Le nombre de pas nécessaire à la convergence est donc lié aux constantes de temps de la dynamique du problème. Pour notre problème exemple, une vingtaine de pas (équivalents à 20 h avec $\Delta_t = 1$ h, pour un stockage de constante de temps $E_{rated}/\sigma_P = 10$ h) suffisent, donc cet algorithme est acceptable.

Cependant, notre travail sur le houlogénérateur SEAREV (§3.4.1 et [50]) est un cas bien différent puisqu'il faut environ 1000 pas (équivalents à 100 s avec $\Delta_t = 0,1$ s) pour avoir un horizon suffisant. Pour ce type de cas, il existe un algorithme plus efficace.

Policy Iteration Cet algorithme se propose d'éviter les calculs intermédiaires d'optimisation à courte vue. Pour cela, l'algorithme démarre avec une loi de gestion initiale μ_0 qui va être améliorée incrémentalement par une procédure en deux étapes illustrée figure 3.3 :

1. *évaluation* : pour chaque nouvelle loi de gestion μ_k , évaluation de sa performance à horizon infini, c'est-à-dire calcul de son coût moyen J_{μ_k} et de son coût relatif \tilde{J}_{μ_k} .
2. *amélioration* de la loi de gestion grâce à une étape de Value Iteration, en utilisant le coût relatif à l'infini \tilde{J}_{μ_k} de la loi de gestion précédente.

L'évaluation d'une stratégie μ consiste à calculer son coût moyen J_μ (3.9) ainsi que son coût relatif $\tilde{J}_\mu(x)$. Ces deux coûts (un nombre et une fonction) sont solution d'une équation d'équilibre analogue à (3.10), mais où la minimisation est remplacée par une gestion fixe $u = \mu(x)$:

8. La mise en œuvre numérique de la minimisation est discutée au § *Discrétisation de la commande*, page 88.

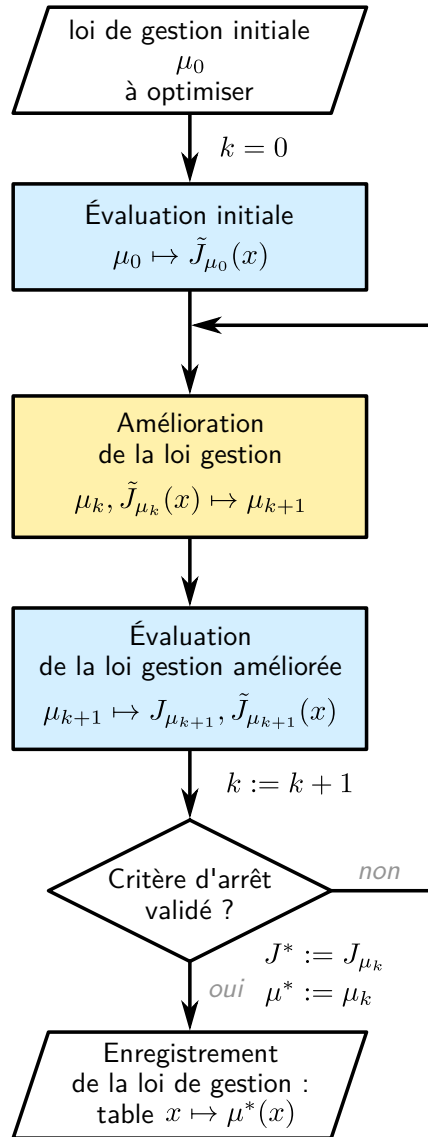


FIGURE 3.3 – Principe de l’algorithme de policy iteration. L’amélioration itérative d’une loi de gestion (policy) se fait par la répétition de deux étapes : *évaluation* sur un horizon infini (le coût d’une stratégie est solution de (3.12)), puis *amélioration* par une étape de value iteration (3.13) qui s’appuie sur le coût relatif de la loi de gestion de la précédente itération.

$$J_\mu + \tilde{J}_\mu(x) = \mathbb{E}_w \left\{ \underbrace{c(x, \mu(x), w)}_{\text{coût instantané}} + \underbrace{\tilde{J}_\mu(f(x, \mu(x), w))}_{\text{coût relatif du futur}} \right\} \quad (3.12)$$

Ensuite, une fois qu'une stratégie μ_k est évaluée, deux cas de figure se présentent : soit le coût moyen J_{μ_k} n'a pas diminué (ou n'a pas assez diminué vis-à-vis d'un critère d'arrêt) et l'on considère que le minimum a été atteint, soit il y a encore une marge de progression et la stratégie μ_k est *améliorée* avec une étape de value iteration :

$$\mu_{k+1}(x) = \arg \min_{u \in U(x)} \mathbb{E}_w \left\{ \underbrace{c(x, u, w)}_{\text{coût instantané}} + \underbrace{\tilde{J}_{\mu_k}(f(x, u, w))}_{\text{coût relatif du futur}} \right\} \quad (3.13)$$

dont le résultat est une stratégie μ_{k+1} qui est améliorée au sens où il est garanti que son coût moyen $J_{\mu_{k+1}}$ est inférieur ou égal au coût de la stratégie précédente ($J_{\mu_{k+1}} \leq J_{\mu_k}$, cf. Bertsekas [9, Proposition 7.4.2]).

La phase d'évaluation peut être conduite de plusieurs façons, selon la manière dont est modélisé le système. Comme nous considérons le cas où le système admet une modélisation dynamique (3.1) a priori simple, nous nous tournons vers l'évaluation *itérative*⁹. Il s'agit de calculer le coût par la même méthode itérative que pour l'algorithme de value iteration (3.11), mais en remplaçant la minimisation par une gestion fixe $u = \mu(x)$. Chaque pas est donc nettement moins gourmand en calcul. Pour l'exemple de la gestion du stockage du SEAREV, avec les paramètres utilisés dans l'article [50], une étape d'évaluation (qui se fait avec 1000 itérations) dure 10 s alors qu'une étape d'amélioration dure 20 s. Ainsi, une étape globale de policy iteration prend 30 secondes.

L'intérêt de l'algorithme policy iteration vient de sa *vitesse de convergence rapide*. En effet, le nombre d'itérations sur la stratégie n'est pas dicté par les constantes de temps de la dynamique du système comme c'est le cas pour l'algorithme value iteration. Avec notre exemple du SEAREV, seules 5 itérations sont nécessaires, soit un temps de calcul total de 3 minutes. À l'inverse, l'algorithme value iteration nécessiterait 1000 itérations de 20 secondes, soit plus de 5 heures.

Nous avons trouvé chez Whittle [100, ch3, §5] une explication structurelle de cette convergence rapide. En résumé, dans l'équation d'optimalité (3.10), la fonction \tilde{J} recherchée est un point fixe : $\tilde{J} = \mathcal{L}(\tilde{J})$, où l'opérateur \mathcal{L} correspond au membre de droite de (3.10). L'algorithme value iteration correspond à une itération sur le point fixe $\mathcal{L}(\mathcal{L}(\dots \mathcal{L}(0)))$ dont la convergence est linéaire. À l'inverse, policy iteration est équivalent à la méthode de Newton-Raphson (cf. théorème 3.5.2 [100, p. 57]) dont la convergence est *quadratique*¹⁰.

3.1.4 Implémentation logicielle : StoDynProg

Nous avons structuré notre implémentation des algorithmes de la programmation dynamique dans un petit module Python baptisé StoDynProg. Il a été présenté à la conférence EuroSciPy [50], avec le lissage de production d'un houlogénérateur pour exemple d'application (cf. §3.4.1).

Ce programme fournit une interface de programmation (API) permettant à un utilisateur de décrire, en langage Python, un problème d'optimisation dynamique : fonction dynamique f , pénalité instantanée c , et contraintes sur les variables de commande. Il permet ensuite de régler les paramètres de résolution (e.g. discrétisation de l'espace d'état, abordée §3.2.2), puis de trouver

9. autres méthodes d'évaluation de la loi de gestion : 1) simulation de trajectoires (fonction coût approchée par régression) et 2) résolution d'un système d'équations linéaires (réservée aux systèmes dont la dynamique est une chaîne de Markov dont on connaît explicitement la matrice de transition).

10. une convergence quadratique signifie que la précision (en nombre de chiffres corrects) *double à chaque itération*.

la loi de gestion optimale avec l'algorithme Policy Iteration. Le code source de ce programme est disponible librement (licence BSD) sur <https://github.com/pierre-haessig/stodynprog>.

Pour compléter cette présentation, nous proposons en annexe B.2 un exemple d'utilisation pour résoudre notre problème exemple : gestion optimale d'un stockage avec entrée AR(1).

3.2 Discussion sur l'applicabilité, critique et comparaison

3.2.1 Démarche générale de mise en œuvre

Nous venons de présenter les algorithmes (e.g. policy iteration) de la programmation dynamique qui permettent d'optimiser la gestion d'un système de stockage avec des entrées incertaines. Cependant, l'application des algorithmes n'est qu'une des étapes nécessaires à la mise en œuvre de la gestion optimale. Nous récapitulons donc à présent l'ensemble de la démarche :

1. *modélisation* du problème, en particulier la dynamique des entrées incertaines,
2. *optimisation* de loi de gestion, par exemple avec l'algorithme policy iteration,
3. *validation* de la performance de la loi de gestion sur des données réelles.

Cette démarche est par exemple appliquée dans notre article sur le lissage de la production du houlogénérateur SEAREV [50], dont nous reprenons certains résultats partie 3.4.1. À la lumière de nos quelques expériences de gestion de stockage, nous commentons ces trois étapes du point de vue de la mise en pratique dans un contexte EnR-stockage.

La modélisation du problème couvre en fait trois tâches.

a) D'une part, il faut modéliser la dynamique de la partie déterministe du système. Par chance, dans le cas d'un système de stockage idéal (§2.1.1), l'équation dynamique est très simple (2.1). Plus généralement, la dynamique n'a *pas besoin d'être linéaire*, mais par contre le modèle doit être *de faible dimension* (cf. "Curse of dimensionality" partie suivante 3.2.2). Dans tous les cas, cette modélisation doit inclure les contraintes sur la commande.

b) Ensuite, il faut modéliser la dynamique des entrées incertaines, car la perturbation w de la dynamique (3.1) est forcément iid. Le processus AR(1) que nous avons utilisé pour modéliser l'erreur de prévision de production P_{mis} (§2.3.2) est couramment choisi, à cause de sa simplicité. Dans tous les cas, il faut privilégier un modèle de dimension faible (Curse of dimensionality). Nous proposons au tableau 3.1 une classification synthétique des différents types de variables que l'on peut rencontrer, avec l'exemple d'une variable de température extérieure.

c) Enfin, il faut définir une fonction coût qui soit bien représentative du comportement que l'on souhaite obtenir du système. Nous avons présenté en exemple une pénalisation quadratique, mais nous montrons partie 3.3.1 que d'autres sont possibles et que la loi de gestion obtenue est très différente. En effet, une loi de gestion n'est jamais *optimale que par rapport à une fonction coût donnée!*

L'optimisation a été abordée dans la partie précédente. Nous soulignons juste que l'algorithme policy iteration nécessite qu'on lui fournisse une stratégie de gestion initiale (notée μ_0 sur la figure 3.3). Nous n'avons pas étudié extensivement la sensibilité de l'algorithme à ce choix. Il semble possible de démarrer avec une stratégie non réfléchie (ex : $\mu_0 \equiv 0$), mais il est facile de trouver une stratégie initiale plus éclairée. Par exemple, la stratégie myope $P_{sto} = P_{mis}$ est un bon choix de stratégie initiale, car sa performance est assez proche de l'optimum.

	Déterministe	Aléatoire
Indépendante	Constante → $T = 20^\circ\text{C}$	Indépendante et identiquement distribuée (iid) → $T \sim \text{Uniforme}(15^\circ\text{C}, 25^\circ\text{C})$
Dépendante du temps	Fonction déterministe du temps → $T = 20 - 5 \cos(2\pi t/24)$	Indépendante, mais distribution dépendant du temps. → $T \sim \text{Unif}(20^\circ\text{C}, 25^\circ\text{C})$ le jour, et $T \sim \text{Unif}(10^\circ\text{C}, 15^\circ\text{C})$ la nuit.
Dépendante d'elle-même	Équation différentielle (ce qui revient à une fonction du temps)	Processus autorégressif. → AR(1), chaîne de Markov

(on peut combiner autorégression et dépendance au temps dans un processus non stationnaire, par exemple un AR(1) dont les paramètres dépendent du mois de l'année [1])

TABLE 3.1 – Une classification possible des variables d'entrée d'un système, avec l'exemple d'une variable de température extérieure T . Notons que si une variable dépend du temps, la dynamique (3.1) devient *non stationnaire*, cas que nous n'avons pas présenté partie 3.1.

La validation pourrait sembler superflue. En effet, l'optimisation dynamique fournit en sortie la valeur du coût moyen optimal J^* . Pourtant, cette valeur n'est pas satisfaisante pour plusieurs raisons. Tout d'abord, nous allons voir ci-après (§3.2.2 discrétisation de l'état) que le nombre obtenu peut être *biaisé* à cause d'une discrétisation trop grossière de l'état. Nous déconseillons donc d'utiliser ce nombre pour rapporter la performance de la loi de gestion obtenue. Nous jugeons plus fiable d'utiliser une simulation temporelle (de type Monte-Carlo à cause des entrées stochastiques). En plus de garantir la bonne évaluation de la performance, la simulation permet aussi d'observer le comportement temporel de la loi de gestion obtenue. L'observation temporelle permet de juger visuellement et quantitativement de la pertinence d'une loi de gestion selon d'autres critères que la seule fonction coût.

Il est aussi intéressant de comparer la gestion optimale à une loi de gestion *empirique* dont on disposerait déjà (comme figure 3.12) pour voir ce que le long calcul d'optimisation a réellement apporté comme gain.

Enfin, il faut, si possible, réaliser une simulation temporelle qui utilise de véritables *historiques de données d'entrée* à la place des modèles stochastiques. En effet, les modèles du type AR sont généralement une approximation du comportement réel des entrées (hypothèse linéaire, hypothèse gaussienne). Le lissage de la production du SEAREV (partie 3.4.1) illustre bien les conséquences du caractère approximatif du modèle des entrées. En particulier, il faut vérifier que la loi de gestion optimale ne présente pas de contreperformance, car la quête de l'optimalité se fait souvent au détriment de la robustesse.

3.2.2 Discrétisation de l'état, Curse of dimensionality

Les différentes équations de la programmation dynamique présentées partie 3.1 sont toutes des *équations fonctionnelles* : leur solution n'est pas un nombre mais une fonction. Les fonctions manipulées sont la fonction coût ($x \mapsto J(x)$ ou $x \mapsto \tilde{J}(x)$) et la loi de gestion ($x \mapsto \mu(x)$), toutes deux fonctions de l'état x . Comme ces fonctions n'ont pas a priori de forme analytique simple, leur manipulation *numérique* nécessite une base permettant de les manipuler comme des vecteurs. Nous avons choisi une approche simple, à savoir calculer \tilde{J} et μ sur une *grille rectangulaire* régulière.

Pour ce faire, chaque variable d'état doit être bornée à un intervalle. Pour l'énergie d'un stockage, l'intervalle est naturel ($E_{sto} \in [0, E_{rated}]$) et pour l'erreur de prévision P_{mis} , nous utilisons un intervalle de valeurs plausibles, tel que $[-4\sigma_P, 4\sigma_P]$, où σ_P est l'écart-type de cette erreur. Ensuite, il faut se donner un nombre de points de discrétisation pour chaque variable d'état : N_{x_1}, N_{x_2}, \dots , soit $N_{E_{sto}}, N_{P_{mis}}$ pour notre problème. Pour chaque variable d'état $x_i \in [x_i^b, x_i^{\#}]$, la grille $[x_i^{(n)}]_{1 \leq n \leq N_{x_i}}$ s'obtient donc par un `linspace(x_i^b, x_i^{\#}, N_{x_i})`¹¹. Sur la figure 3.2, la pixellisation des images représentant la loi de gestion correspond à la discrétisation sous-jacente de l'état (grille de $N_{E_{sto}} \times N_{P_{mis}} = 61 \times 51$ points).

Interpolation Le fait de ne calculer \tilde{J} et μ qu'en des points discrets x_i appartenant à une grille oblige à se doter d'un mécanisme d'interpolation. Elle est nécessaire pour deux tâches :

- évaluer le coût du futur J_{k+1} au point $x_{k+1} = f(x_k, u_k, w_k)$ (nécessaire dans (3.7) ou (3.13)), car même si x_k est sur la grille, x_{k+1} ne l'est généralement pas.
- utiliser la loi de gestion μ pour une simulation temporelle, où l'état x peut prendre n'importe quelle valeur.

Le cahier des charges du mécanisme d'interpolation satisfaisant inclut la rapidité et le support des dimensions multiples ($x \in \mathbb{R}^n$ avec n entre 1 et 5). Nous avons ainsi utilisé la routine d'interpolation *multilinéaire* sur grille rectangulaire régulière écrite par Pablo Winant (PSE-École d'Économie de Paris) dans le cadre de son projet Do1o [101] qui sert à la modélisation de dynamiques macroéconomiques (code source sur <https://github.com/albop/dolo>).

Choix de la finesse de discrétisation Nous n'avons pas de règles précises pour le choix de la finesse de discrétisation. Pour nos différents problèmes de stockage, nous avons observé qu'une discrétisation avec quelques dizaines de points par variables donne des résultats satisfaisants (pour une discrétisation *régulière*, et avec une interpolation linéaire des fonctions). Nous retenons deux critères pour guider ce choix :

- la finesse doit être suffisante pour que les variations des fonctions \tilde{J} et μ soient bien représentées (inspection visuelle de la régularité sur des graphiques du type de la figure 3.2).
- la finesse impacte aussi la valeur du coût moyen. Nos observations sur différents exemples montrent que le coût moyen d'une stratégie obtenue par évaluation (3.12) est biaisé lorsque la discrétisation est trop grossière. Ainsi, il est possible de juger numériquement la pertinence de la discrétisation en testant plusieurs pas de discrétisation et en observant à partir de quelle finesse l'évaluation de coût donne une valeur stabilisée.

Figure 3.4, nous cartographions le coût moyen ($c = P_{dev}^2$) de la loi de gestion empirique ($P_{sto} = P_{mis}$), pour plusieurs choix des nombres de points de discrétisation $N_{E_{sto}}, N_{P_{mis}}$. Ce coût est calculé en résolvant itérativement l'équation d'équilibre (3.12) sur une grille de taille $N_{E_{sto}} \times N_{P_{mis}}$ (la plus petite : 10×25 , la plus grande : 100×150). La "vraie valeur" du coût ($0,553 \pm 0,001$) est calculée par une simulation temporelle stochastique qui utilise 10^7 échantillons (cf. programme StorageSim §2.5). Nous pouvons observer que, pour notre exemple, il est intéressant de discrétiser plus finement la variable P_{mis} que E_{sto} .

Curse of Dimensionality Le principal défaut de la programmation dynamique vient de sa mauvaise adaptation à des problèmes de grande dimension, en termes de vecteur d'état. Le terme

11. fonction `linspace` de Matlab ou `numpy`




FIGURE 3.4 – Effet de la finesse de discrétisation sur l'évaluation du coût d'une loi de gestion. L'augmentation du nombre de points de discrétisation $N_{E_{sto}}, N_{P_{mis}}$ fait effectivement converger le calcul (3.12) vers la "vraie valeur", calculée par simulation temporelle (avec 10^7 échantillons). Les lignes rouges représentent l'intervalle de confiance à 95 % de cette vraie valeur : $0,553 \pm 0,001$.

anglais de "Curse of dimensionality" est ainsi attaché à la méthode depuis sa création. Cette "malédiction" s'illustre bien par la question de la discrétisation. En supposant que l'on choisisse 10 points pour chacune des n variables d'état, il faut manipuler $N_{x_1} \times \dots \times N_{x_n} = 10^n$ points pour représenter chaque fonction \tilde{J} et μ . Ainsi, le besoin en mémoire et en calcul augmente exponentiellement avec la dimension du vecteur d'état et il est généralement dit qu'il faut se restreindre aux dimensions inférieures à 4 ou 5.

Seules des structures particulières de problèmes permettent de franchir cette barrière. Par exemple, avec la méthode de programmation dynamique duale SDDP [80] qui permet de gérer des systèmes hydroélectriques avec plusieurs barrages nécessite un *coût convexe* et une dynamique linéaire. En l'absence de structure particulière, il faut accepter de faire des approximations, sur le modèle, ou bien se tourner vers d'autres méthodes de gestion (§3.2.3).

Discrétisation de la commande Pour réaliser l'étape de minimisation de l'équation (3.13) il est possible de faire appel à une routine d'optimisation. Cette optimisation est relativement simple, car il suffit de trouver la *valeur* de la commande optimale, mais ce calcul doit être répété en chaque point de la grille des variables d'état. Il doit donc être rapide et fiable.

Notre exigence d'obtenir un résultat garanti (minimum global, et pas d'erreur de convergence) ainsi que la facilité d'implémentation (calcul vectorisé) nous ont conduit à préférer travailler par *énumération*. Nous générons ainsi une grille de commande possible, par exemple P_{sto} entre $-P_{rated}$ et $+P_{rated}$, avec un pas de 0,001 MW, et nous calculons le coût associé à chaque choix pour trouver l'optimum. Il faut donc choisir le pas de discrétisation de la commande Δ_u . Sachant que les variables de commande de notre problème (P_{sto}, P_{cur}) sont des puissances de l'ordre du MW, un pas de 0,001 MW donne entière satisfaction. Cette approche garantit que la loi de gestion obtenue est précise à un niveau $\pm\Delta_u$ totalement maîtrisé.

En contrepartie, cette approche par énumération aggrave la malédiction de la dimension pour peu que le problème traité ait beaucoup de variables de décision continues (ce qui n'est pas notre cas).

3.2.3 Comparaison aux autres méthodes

Nous terminons notre discussion sur l'applicabilité de la programmation dynamique par une rapide comparaison à des méthodes alternatives. Il s'agit d'une comparaison générale et de principe, et non de l'analyse numérique comparative qu'on pourrait réaliser sur un problème exemple.

D'un point de vue structurel, seule la programmation dynamique stochastique (SDP) permet, à notre connaissance, le "véritable" contrôle optimal d'un système non linéaire avec des entrées incertaines. Cependant, deux questions viennent nuancer cette affirmation :

- La gestion optimale est-elle vraiment *souhaitable* ? En effet, la gestion optimale se fait par rapport à un critère de coût particulier. Ce critère ne couvre pas forcément tous les besoins (parfois non explicités) que doit satisfaire une loi de gestion. Par ailleurs, le coût (3.9) est défini comme une espérance, c'est-à-dire un coût moyenné vis-à-vis de l'incertain, ce qui masque la variabilité (notion de *risque* implicitement masquée).
- La gestion optimale est-elle vraiment *optimale* ? En effet, la mise en œuvre de la SDP nécessite souvent des simplifications dans la modélisation du système, en particulier la réduction de la dimension. En conséquence, la SDP fournit une loi de gestion certes optimale pour le problème simplifié, mais pas forcément optimale pour le problème originel (d'où la nécessité de tester la performance sur de vraies données §3.2.1). À cause de ces simplifications, des approches a priori sous-optimales pourraient, dans certains cas, se révéler plus performantes sur le système réel que la gestion obtenue par SDP.

Ces deux réserves sur la SDP, qui s'ajoutent au problème de "Curse of dimensionality", poussent à s'intéresser aux méthodes alternatives pour la gestion d'énergie d'un stockage.

Approches alternatives Nous proposons de classer ces approches en trois catégories :

- Gestion non optimale : loi de gestion empirique
 - Gestion non optimale "optimisée" : loi de gestion paramétrique dont les paramètres sont optimisés, programmation dynamique approximée (ADP)
 - Optimisation dynamique déterministe (boucle ouverte), répétée régulièrement pour "refermer la boucle", aussi appelée Model Predictive Control (MPC).
- **Gestion empirique** La gestion par une loi empirique, c'est-à-dire guidée par l'intuition et l'expérience de son créateur, est couramment utilisée. Le terme anglais de "rule-based control" est souvent présent lorsqu'une telle loi fait intervenir des conditions "if-then-else". Leur avantage : pas de lourd calcul pour les obtenir, et structure *intelligible* (il est possible de comprendre le processus de décision). Leur performance n'est pas forcément mauvaise, car la gestion empirique peut tomber "par hasard" sur la gestion optimale (gestions empirique et optimale sont de *même nature* : contrôle en boucle fermée). Bien sûr, la performance qui dépend de la pertinence de l'intuition n'est pas garantie.

Pour sa simplicité, nous utilisons pour partie la gestion empirique ($P_{sto} = P_{mis}$) au chapitre 4 sur le dimensionnement. Nous avons vu (§3.1.2) que cette stratégie est optimale si l'on considère la pénalisation de l'écart P_{dev} sur un seul instant. Ainsi, une optimisation myope est une façon simple d'obtenir une gestion empirique.

– **Gestion empirique “optimisée”** La gestion “optimisée” est une autre approche courante dans la littérature, mais le mot “optimisé” (optimized en anglais) prête souvent à confusion. Il s’agit en fait d’une approche empirique, donc sous-optimale, mais où *certaines paramètres de réglage sont ajustés* par une procédure d’optimisation. Par exemple, on peut imposer une loi de gestion linéaire $\mu(x) = Kx$ et chercher la matrice des gains K qui donne la meilleure performance. Autre exemple, Caux *et al.* [25] utilisent une structure de contrôleur flou dont les fonctions d’appartenance sont ajustées par optimisation (algorithme génétique). Ces lois paramétriques peuvent génériquement se noter $x \mapsto \mu_\theta(x)$ où θ est le vecteur des paramètres ajustables. Si la structure heuristique est une famille de fonctions suffisamment bien pensée pour contenir la loi de gestion optimale, la performance peut tout à fait atteindre l’optimal. Malheureusement, comme la loi de gestion optimale est généralement inconnue (sinon on l’utiliserait !), il est impossible de connaître a priori la bonne structure paramétrique.

Il existe cependant certaines façons d’obtenir une structure optimale ou quasi optimale. Tout d’abord, quelques problèmes d’optimisation admettent une *solution analytique* dont on peut réutiliser la structure. Par exemple, les problèmes à dynamique linéaire et coût quadratique (contrôle LQ) ont une loi de gestion optimale linéaire $\mu(x) = Kx$. Certains problèmes de gestion d’inventaire avec coûts linéaires admettent une loi de gestion par seuils (stratégies dites “(s,S) policies” [9, §4.2]).

En l’absence de solution analytique, il est aussi possible de faire tourner un algorithme SDP et analyser la loi de gestion obtenue. C’est ainsi que Kim *et al.* [61] créent une structure paramétrique de loi de gestion (pour un véhicule à hydrogène + super-condensateurs) qui leur permet ensuite de conduire efficacement un travail de dimensionnement optimal du système. Pour la gestion de stockage avec une tolérance d’erreur, partie 3.3.3, nous essayons la même démarche.

L’optimisation des paramètres de gestion peut se faire sur des *simulations temporelles*, par exemple en rejouant des scénarios historiques. Il faut alors bien prendre garde au problème du *surapprentissage* (overfitting en anglais), c’est-à-dire que la loi de gestion n’améliore la performance que du scénario particulier sur lequel elle est optimisée, mais la détériore sur d’autres scénarios statistiquement similaires. Dans un contexte véhiculaire où l’entrée est un profil de mission, on parle aussi de “cycle beating”. Les précautions classiques de l’apprentissage automatique (machine learning) sont alors à appliquer, en particulier séparer les données d’entrée en trois ensembles : apprentissage, validation et test.

Pour terminer notre discussion sur la gestion sous-optimale, nous devons mentionner la famille de méthodes de la programmation dynamique approximée (ADP). Il s’agit de contrer la malédiction de la dimension (§3.2.2) grâce à différents procédés d’approximation, par exemple en utilisant une base de fonctions plutôt qu’une grille pour représenter la fonction coût $J(x)$. N’ayant pas suffisamment approfondi ce trop vaste sujet, nous proposons le chapitre 6 (vol. 1) du livre de Bertsekas [9] pour une vision de plusieurs méthodes. Powell [86] dresse également un panorama large du sujet. Il présente l’intérêt de croiser les points de vue des différentes disciplines qui s’intéressent à l’ADP (e.g. sous le nom de “reinforcement learning”). L’optimisation déterministe que nous présentons maintenant peut d’ailleurs être vue comme une forme d’ADP.

– **Optimisation déterministe** L’optimisation dynamique déterministe, aussi appelée Model Predictive Control (MPC) est également une approche très populaire. Elle consiste à calculer une trajectoire de contrôles optimaux (u_0^*, \dots, u_K^*) qui minimise le coût sur un horizon donné, en supposant toutes les entrées connues¹². De la séquence de contrôle (boucle ouverte), seule la première commande u_0^* (ou les quelques premières) est appliquée et l’optimisation est recommen-

12. Les entrées incertaines sont ainsi remplacées par des valeurs typiques (ex : $P_{mis} = 0$)

cée au pas suivant pour prendre en compte les éventuels changements imprévus (typiquement les erreurs de prévisions). Cette répétition de l'optimisation à chaque pas permet de "refermer la boucle de contrôle". Dans un contexte PV-stockage, le travail de Riffonneau *et al.* [88] entre dans cette catégorie (optimisation des flux d'énergie sur une journée au pas de 10 minutes, avec production PV et consommation supposées connues à l'avance grâce à des prévisions).

Bien qu'étant basée sur des algorithmes d'optimisation parfois complexes¹³, l'approche MPC n'en reste pas moins *a priori sous-optimale*. En effet, elle ne prend pas en compte de manière *intrinsèque* les entrées incertaines. Ainsi, le terme "optimal" souvent attaché à cette méthode prête à confusion, même si la méthode reste tout à fait utile dans beaucoup de contextes. Dans un contexte EnR-stockage où l'incertitude sur les entrées est grande, nous avons l'impression que l'utilisation de loi de gestion en boucle fermée, même heuristique, est plus appropriée. Bien sûr, seule une comparaison côte à côte des performances respectives de chaque méthode permettrait d'affirmer cela solidement.

Dans tous les cas, une loi de gestion boucle fermée précalculée (par SDP ou heuristique) présente l'avantage, comparativement au MPC, de demander moins de calcul *en-ligne*.

3.3 Gestion optimale pour la garantie d'engagement J+1

Nous entrons à présent dans une discussion plus détaillée de l'optimisation de la gestion pour la garantie d'un engagement J+1, problème précédemment schématisé figure 1.3. Nous récapitulons synthétiquement la formalisation du problème (i.e. la phase "1. modélisation" de la démarche décrite partie 3.2.1) nécessaire à l'application de la programmation dynamique :

- Variables : état (E_{sto}, P_{mis}) , commande (P_{sto}, P_{cur}) , et perturbation w
- Dynamique du système $f : (E_{sto}, P_{mis}, P_{sto}, P_{cur}, w)_k \mapsto (E_{sto}, P_{mis})_{k+1}$
 - énergie stockée : $E_{sto}(k+1) = E_{sto}(k) + P_{sto}(k)\Delta_t$
 - erreur de prévision du productible : $P_{mis}(k+1) = \phi P_{mis}(k) + w(k)$
- Coût de chaque instant $c(E_{sto}, P_{mis}, P_{sto}, P_{cur}, w)$, à choisir
- Contraintes sur la commande $(P_{sto}, P_{cur}) \in U(E_{sto}, P_{mis})$
 - limites d'énergie : $P_{sto}(k)\Delta_t \in [-E_{sto}(k), E_{rated} - E_{sto}(k)]$
 - limites de puissance : $P_{sto}(k) \in [-P_{rated}, +P_{rated}]$
 - limites d'écrêtage : $P_{cur}(k) \in [0, P_{mis}(k)]$

Cette liste est la reprise directe des équations présentées partie 3.1.2, mais avec l'ajout de la variable d'écrêtage P_{cur} qui correspond à la décision de perdre volontairement du productible jugé superflu, plutôt que de le stocker ou de l'envoyer sur le réseau en acceptant un écart à l'engagement positif (cf. schéma de la figure 1.3).

Remarque : en principe, la contrainte supérieure sur l'écrêtage " $P_{cur} \leq P_{mis}$ " devrait être " $P_{cur} \leq P_{prod}$ " (i.e. "on ne peut pas délester plus de puissance que le productible P_{prod} "). Cependant, avec notre modélisation qui utilise uniquement les signaux d'écart (erreur de prévision P_{mis} , écart à l'engagement P_{dev}), la variable P_{prod} n'est pas présente. Par conséquent, nous utilisons la relation $P_{mis} = P_{prod} - P_{grid}^*$: comme l'engagement P_{grid}^* est forcément positif, on sait que $P_{mis} \leq P_{prod}$. Ainsi, la contrainte $P_{cur} \leq P_{mis}$ permet bien de garantir que l'on n'écrête pas plus que le productible. Par ailleurs, même si cette contrainte est plus conservative, elle semble

13. les problèmes sont souvent exprimés sous forme *linéaire mixte* avec variables entières (MILP), car des algorithmes éprouvés existent pour les résoudre, même avec un grand nombre de variables (>1000).

raisonnable. En effet, quelle raison pousserait à vouloir délester plus de puissance que l'écart productible-engagement P_{mis} ?

Le problème étant modélisé, nous appliquons la programmation dynamique stochastique pour trouver la loi de gestion optimale qui minimise le coût (3.9), à savoir la *moyenne* du coût c_k subi par le système à chaque instant (optimisation "à horizon infini"). Cela nous permet d'étudier la loi de gestion obtenue pour différents choix de paramètres, en particulier la forme du coût c_k (§3.3.1), mais aussi la capacité E_{rated} et le coefficient ϕ (§3.3.2).

Pour finir, cette étude de l'effet de différents paramètres nous permet d'ouvrir la possibilité de *paramétriser* certaines lois de gestion optimale (§3.3.3). Cette paramétrisation est importante dans la perspective de la *co-optimisation* de la gestion avec le dimensionnement du système de stockage.

3.3.1 Effet de la forme du coût

Nous discutons tout d'abord du choix de la fonction $c(x,u,w)$ qui pénalise chaque instant. Ce choix est fondamental, car l'optimisation vise à trouver une loi de gestion qui minimise la valeur moyenne de $c(x,u,w)$ au cours du temps. Nous allons voir que la loi de gestion obtenue est extrêmement sensible à ce choix. Nous proposons l'étude de plusieurs formes de pénalisation, mais qui ont toutes pour point commun de pénaliser l'écart à l'engagement :

$$P_{dev} = P_{mis} - P_{cur} - P_{sto} \quad (\text{rappel 1.8})$$

dont on vérifie qu'il s'exprime bien en fonction de l'état et de la commande. Notons que nous nous intéressons ici à la *forme plus qu'à la valeur* de la pénalisation. L'expression précise d'un coût exprimé avec des paramètres économiques vient au chapitre 4.




FIGURE 3.5 – Différentes formes de pénalisation de l'écart à l'engagement : linéaire (valeur absolue), quadratique, seuil de tolérance (fonction "puits") et seuil-quadratique.

Parmi la très grande variété des choix possibles, nous présentons figure 3.5 quatre formes particulières de pénalisation, à appliquer à la variable d'écart P_{dev} . Il s'agit ici de pénalisations *symétriques*, sachant qu'il serait possible de pénaliser asymétriquement les écarts positifs et négatifs (ex : les écarts négatifs, qui correspondent à une sous-production, pourraient être plus fortement pénalisés). Toutes ces fonctions pénalisent les "grands écarts", mais avec plusieurs différences :

- la fonction **linéaire** pénalise l'écart proportionnellement à sa valeur absolue. Si la pente est unitaire, le coût moyen J s'interprète alors comme un "écart moyen en valeur absolue" (MAE en anglais) qui a même unité que l'écart (en MW dans notre cas).
- la fonction **quadratique**, par rapport à la linéaire, pénalise plus fortement les "grands écarts" que les petits. Le coût moyen J correspond à la variance de P_{dev} , en MW^2 qui est

une unité peu lisible. Par contre la grandeur \sqrt{J} est intéressante, car elle correspond à l'écart-type de P_{dev} (en MW).

- la fonction **seuil de tolérance** ne pénalise pas les écarts plus petits qu'une certaine valeur P_{tol} . Au-delà de cette tolérance, la pénalisation est fixe (une "amende forfaitaire"). Cette forme est importante, car elle se rapproche du mécanisme de pénalité utilisé dans l'appel d'offres éolien-stockage de la CRE [28], même si ce dernier est plus compliqué, car il est calculé comme une décote de la rémunération de la production.
- la fonction **seuil-quadratique** présente la même propriété de ne pas pénaliser les écarts inférieurs à P_{tol} . Par contre, la pénalisation au-delà est progressive, et de plus en plus sévère pour les grands écarts. Nous allons voir son intérêt par rapport au seuil "simple".

À noter que pour simplifier notre propos, nous fixons la commande d'écrêtage P_{cur} à zéro (i.e. pas d'écrêtage). Ainsi, la puissance P_{sto} est la seule variable de décision.

Analyse de trajectoires Figure 3.6 nous présentons les quatre trajectoires temporelles obtenues en appliquant la gestion optimale vis-à-vis de chacune des quatre fonctions coûts, sur un *même problème*, ce qui signifie ici :

- non seulement les *mêmes paramètres* : capacité de stockage $E_{rated} = 5$ MWh, sollicitation P_{mis} AR(1), avec pour écart-type $\sigma_P = 1$ MW et coefficient de corrélation inter-heures $\phi = 0,8$,
- mais aussi *même trajectoire de sollicitation* $P_{mis}(k)$ (i.e. même tirage aléatoire), pour permettre la comparaison côte à côte des signaux entre les quatre cas.

Pour chaque cas, le 1^{er} graphique montre l'évolution de l'état d'énergie SoE , le 2^{ème} montre la sollicitation d'entrée P_{mis} ainsi que la puissance absorbée par le stockage P_{sto} (choisie par la loi de gestion). Le 3^{ème} montre l'écart à l'engagement P_{dev} (variable pénalisée). On pourra observer que le SoE croît lorsque $P_{sto} > 0$. Lorsque le stockage est plein ($SoE = 1$), la puissance absorbée P_{sto} est contrainte à être négative ou nulle. En comparant les différents cas, nous pouvons faire les observations suivantes :

- avec la pénalisation *linéaire* (fig. 3.6a), le système de stockage présente 2 régimes de fonctionnement : tant que la batterie n'est pas saturée (pleine ou vide) l'écart P_{dev} est fixé à zéro, mais lorsque la batterie est saturée il n'y a plus aucune atténuation de l'écart d'entrée ($P_{dev} = P_{mis}$), car elle ne peut plus fournir ou absorber de puissance ($P_{sto} = 0$). En fait, cette gestion correspond à la gestion "myope" présentée figure 3.2a. Nous sommes donc dans un cas particulier où une gestion empirique s'avère en fait optimale.
- avec la pénalisation *quadratique* (fig. 3.6b), la gestion cherche à réduire le nombre de "grands écarts" et cherche donc à éviter de se retrouver avec un SoE saturé. Pour ce faire, cette gestion fait le compromis de ne pas totalement compenser l'écart P_{mis} , au prix d'un écart instantané P_{dev} non nul. Ainsi, la puissance absorbée n'est qu'une fraction de P_{mis} , fraction d'autant plus forte que le SoE est proche de la saturation. (La loi de gestion est tracée figure 3.10a, de même qu'en 3.2b, mais pour une capacité deux fois plus grande.)
- avec les pénalisations *avec tolérance* (fig. 3.6c et 3.6d), les trajectoires sont très différentes des cas sans tolérance. Pour un seuil choisi à 1 MW, il y a peu de valeurs de l'écart P_{dev} hors tolérance. Il y a pourtant quelques dépassements lorsque le SoE approche de la saturation (vers $t = 0,5$ et 4,5 jours). C'est lors de ces dépassements que la différence entre la pénalisation à seuil simple et seuil-quadratique apparaît :

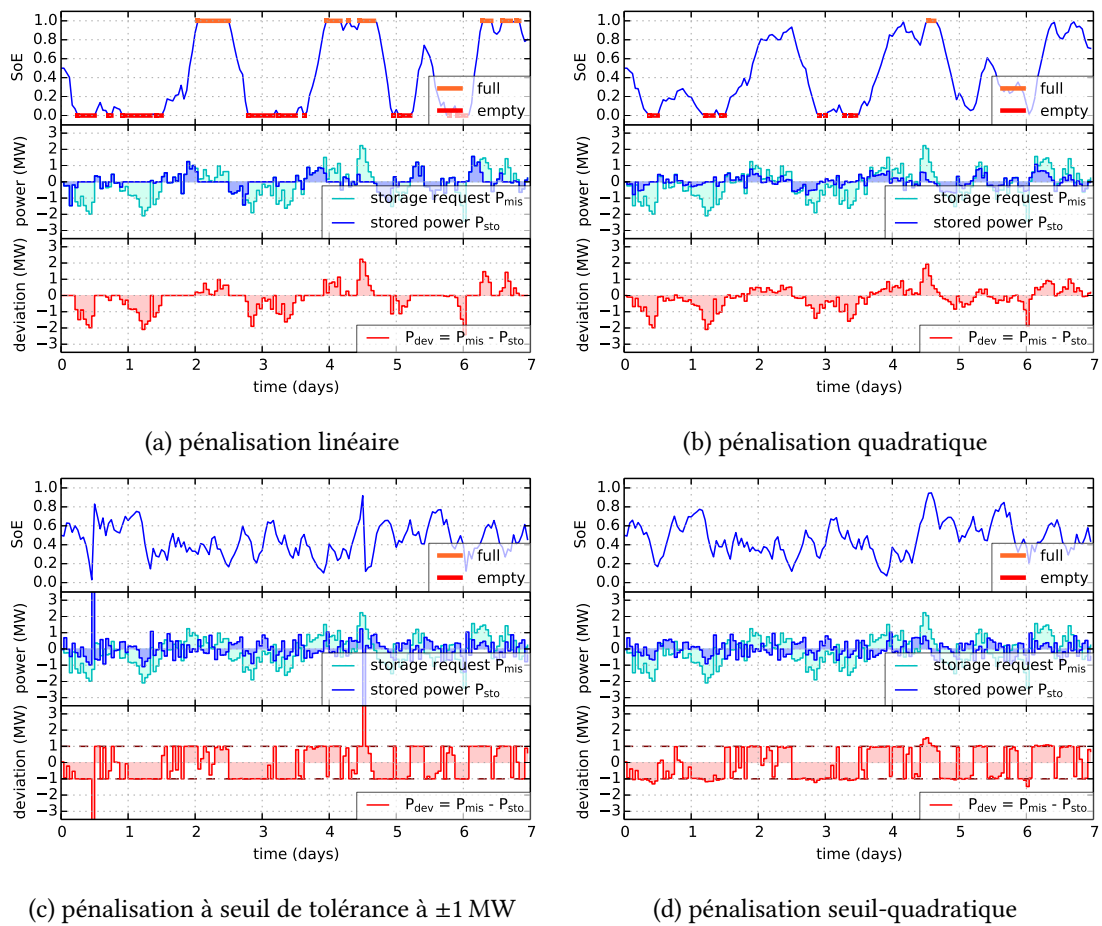


FIGURE 3.6 – Trajectoires optimales vis-à-vis de 4 formes différentes de pénalisation de l'écart à l'engagement P_{dev} . Capacité de stockage $E_{rated} = 5$ MWh.

- avec le seuil simple (fig. 3.6c), une fois que le seuil est franchi, tout écart supplémentaire est *marginalelement gratuit* (la dérivée de $c(P_{dev})$ est nulle). La gestion optimale en profite totalement, pour ne pas dire abusivement (“effet d’aubaine”). En effet, lorsque le stock est quasi vide ($t = 0,5$ j) et que l’erreur de prévision P_{mis} est négative (sous-production par rapport à l’engagement), la gestion fait le choix d’absorber une puissance positive pour se recharger, ce qui aggrave fortement l’écart négatif à l’engagement ($P_{dev} < -4$ MW). Comme la limite de puissance du stockage est large ($P_{rated} = 4$ MW), cela permet en un pas (1 h) de quasiment remplir le stockage .
- avec la pénalisation seuil-quadratique (fig. 3.6d), les écarts à l’engagement ne sont pas marginalement gratuits au-delà du seuil. Au contraire, ils coûtent de plus en plus cher (la dérivée de $c(P_{dev})$ est positive et croissante pour $P_{dev} \geq P_{tol}$). Cela se traduit sur la trajectoire par des écarts *faibles et répartis* sur plusieurs instants. La batterie ne se recharge plus brusquement à $t = 0,5$ j. Globalement, la gestion est beaucoup plus “douce” qu’avec le seuil simple.

Analyse des lois de gestions avec tolérance Pour bien saisir les différences entre les lois de gestion obtenues vis-à-vis de deux pénalisations avec tolérance, nous avons représenté ces lois figure 3.7 (même type de représentation que sur la figure 3.2, mais nous avons ajouté deux lignes de niveau rouges à $\pm P_{tol}$ pour marquer la portion de l’espace d’état où la tolérance est strictement respectée).


Pour les deux gestions, on observe, du point de vue du réseau (variable P_{dev} , à droite), deux *larges plages d’écart quasi constant* : $P_{dev} \approx -P_{tol}$ (zone bleu clair) lorsque l’erreur de prévision P_{mis} est négative et la batterie plutôt vide, et inversement $P_{dev} \approx +P_{tol}$ (zone rouge clair) lorsque l’erreur de prévision P_{mis} est positive et la batterie plutôt pleine. Entre ces deux zones, la ligne de partage $P_{dev} = 0$ est une droite qui coupe le plan (E_{sto}, P_{mis}) de façon inclinée. Cela signifie que les deux variables interviennent dans la décision. Nous identifions que l’équation de cette droite est $(E_{sto} - E_{rated}/2) + \tau P_{mis} = 0$, avec un coefficient $\tau = 4$ h environ. Nous reportons à la partie 3.3.2 la discussion sur cette droite et son orientation (e.g. l’interprétation de la valeur de τ).

Deux différences existent pourtant entre ces deux lois avec tolérance. Tout d’abord, avec le seuil simple (fig. 3.7a), les zones d’écart quasi constant sont parfaitement horizontales, avec un écart à l’engagement constant, placé exactement en limite de tolérance ($|P_{dev}| = P_{tol}$). À l’inverse, la pénalisation seuil-quadratique (fig. 3.7b) engendre un dépassement qui augmente progressivement, à mesure que la batterie approche de la saturation ¹⁴.


En zone de saturation, le comportement est aussi très différent, comme nous l’avons déjà relevé sur les trajectoires de la figure 3.6. Dans le cas de la pénalisation avec seuil simple, figure 3.7a, le passage en saturation amène à une *soudaine inversion de signe* de la puissance absorbée P_{sto} . Par exemple, lorsque la batterie est vide et l’erreur de prévision négative (coin haut-gauche), la gestion choisit d’absorber fortement de la puissance ($P_{sto} = 4$ MW), en aggravant ainsi l’écart à l’engagement ($P_{dev} = -8$ MW, hors échelle). À l’inverse figure 3.7b, dans la même situation, la gestion de la pénalisation seuil-quadratique se contente de mettre le stockage “en pause” ($P_{sto} = 0$) ce qui entraîne un écart à l’engagement fort mais moins grave ($P_{dev} = P_{mis} = -4$ MW). Ainsi, un “regard moral” qualifierait la gestion “seuil simple” d’opportuniste et peu soucieuse du réseau, alors que la seconde fait de son mieux (“best effort”) pour aider le réseau.

14. avec le coût seuil quadratique, la gestion est naturellement amenée à faire de légers dépassements hors de la tolérance. Pour obtenir, comme figure 3.7b, que la tolérance soit tout de même strictement respectée, au moins sur une certaine plage, nous avons en fait pénalisé l’écart avec seuil légèrement plus strict que P_{tol} (0,95 MW).

3 Gestion optimale de l'énergie stockée



(a) pénalisation avec seuil de tolérance simple (correspond à la trajectoire fig. 3.6c)



(b) pénalisation seuil-quadratique (correspond à la trajectoire fig. 3.6d)

FIGURE 3.7 – Comparaison des lois de gestion optimales obtenues pour deux formes de pénalisation avec tolérance ($P_{tol} = 1$ MW) de l'écart à l'engagement P_{dev} . Trajectoires correspondantes sur les figures 3.6c et 3.6d.

Importance de la forme de la pénalisation Les exemples que nous venons de traiter illustrent l'importance qu'a la *forme* de la pénalisation sur la loi de gestion, et donc au final sur les trajectoires.

D'un point de vue théorique, nous soupçonnons que la *non-convexité* de la fonction de pénalisation (cas de la pénalisation à seuil simple) *explique la discontinuité* de la loi de gestion (fig. 3.7a), même si seule une étude théorique plus poussée pourrait le démontrer. Une pénalisation convexe¹⁵ semble donc préférable pour obtenir une loi de gestion "raisonnable", c'est-à-dire sans discontinuités et sans effets d'aubaine.

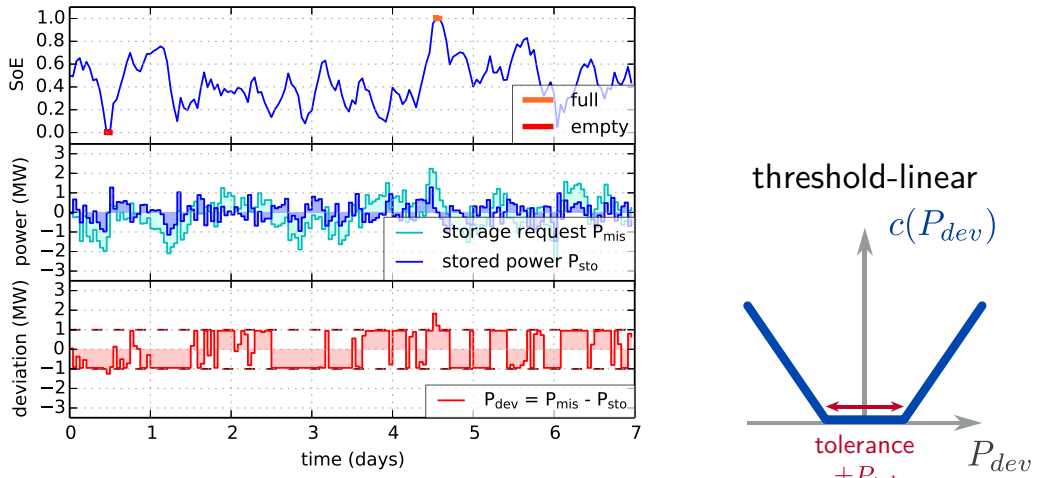
D'un point de vue pratique, notre analyse, certes basée sur des hypothèses simplificatrices, montre que la fonction de pénalisation doit être *choisie avec soin* par l'acteur qui fixe les règles de pénalisation (opérateur réseau ou régulateur du marché selon les situations). Malheureusement, les pénalisations qui sont le plus facilement exprimables dans la langue juridique d'un texte réglementaire (typiquement : les pénalisations à seuil) ne sont pas celles qui donnent les trajectoires les plus douces (typiquement : les pénalisations avec des termes quadratiques).

De ce point de vue, une pénalisation linéaire par morceaux (et convexe) semble un bon compromis. À titre illustratif, nous proposons figure 3.8 une forme *seuil-linéaire* qui donne un comportement intermédiaire entre ceux obtenus pour la pénalisation à seuil simple et la pénalisation seuil-quadratique. L'opérateur réseau MAVIR en Hongrie (pays à production très peu flexible) applique une pénalité de ce type à tous les parc éoliens depuis 2007 : 17 €/MWh pour toute énergie produite en dehors d'un engagement J+1, avec une tolérance de $\pm 50\%$ [54].

Pour l'opérateur d'un parc éolien-stockage, cette analyse montre aussi que l'outil de l'optimisation dynamique ne doit pas être utilisé de façon aveugle. En effet, la pénalisation à seuil simple, qui est structurellement la plus proche de la pénalisation de l'appel d'offres éolien-stockage, donne une loi de gestion soi-disant optimale, mais en fait inacceptable du point de vue de nombreux critères. Par exemple, nous n'avons pas pris en compte les limites sur les variations de la puissance imposées par les règles de l'appel d'offres. Cette règle qui limite les variations brusques rend donc la loi de gestion de la figure 3.7a inapplicable. Ce défaut illustre un trait négatif caractéristique de l'optimisation (optimisation dynamique ou optimisation en général) : pour rendre le problème soluble ("tractable" en anglais) il faut souvent le simplifier fortement et la solution optimale obtenue peut s'avérer finalement inacceptable pour le problème complet (ex : violation de contraintes non explicites).

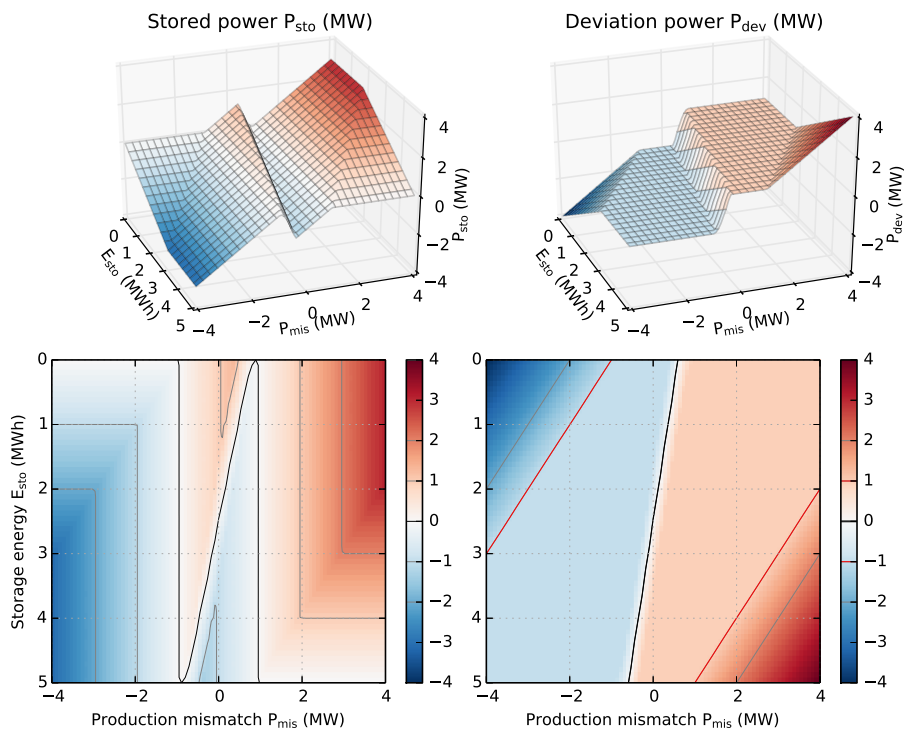
Par conséquent, il peut être intéressant de conduire l'optimisation dynamique non pas avec la fonction coût "exacte" (i.e. tirée directement d'un règlement ou d'une analyse économique), mais au contraire de procéder, comme souvent en statistiques, à une *régularisation* de la fonction coût, c'est-à-dire de pénaliser, plus ou moins empiriquement, certaines variables. Là encore, la forme seuil-linéaire de la figure 3.8 est un bon exemple de régularisation : la pénalisation par seuil simple est remplacée par une fonction convexe (fig. 3.8b) qui donne une loi de gestion parfaitement identique dans la zone non saturée (fig. 3.8c) mais sans les décisions inacceptables (e.g. les charges et décharges opportunistes qui aggravent l'écart à l'engagement).

15. si la fonction $c(P_{dev})$ est deux fois dérivable, la condition de convexité est simplement $c''(P_{dev}) \geq 0$.



(a) trajectoire optimale (à comparer à la figure 3.6)

(b) forme de la pénalisation seuil-linéaire



(c) loi de gestion optimale, à comparer aux figures 3.7a et 3.7b

FIGURE 3.8 – Effet d'une pénalisation par une forme seuil-linéaire. Le comportement obtenu, nettement plus acceptable que celui de la pénalisation à seuil simple (fig. 3.6c), est proche de celui de la pénalisation seuil-quadratique (fig. 3.6d), tout en gardant une forme de pénalisation d'expression simple (e.g. transposable dans un texte réglementaire).

3.3.2 Effet de la capacité et de la corrélation des erreurs

Nous avons discuté dans la partie précédente de l'effet de la *forme* de la fonction de pénalisation et nous avons vu qu'elle peut radicalement altérer la forme de la loi de gestion optimale.

Nous nous intéressons à présent à l'effet des paramètres numériques, en particulier de la capacité du stockage E_{rated} et du coefficient ϕ qui représente la corrélation des erreurs de prévision entre deux heures consécutives. Nous allons voir que la variation de ces paramètres ne change pas radicalement la loi de gestion mais la *transforme* (étirements et rotations).

Effet de la capacité de stockage En premier lieu, la variation de la capacité de stockage a un effet sur le coût : le coût moyen J^* , c'est-à-dire l'écart à l'engagement mesuré par la fonction de pénalisation choisie, est d'autant plus faible que la capacité est grande (constat valable pour toutes les formes de pénalisation que nous avons étudiées). Cependant, l'étude de cette variation de la performance du système est réservée pour le chapitre 4 consacré au dimensionnement. Nous nous concentrons donc sur l'effet sur la loi de gestion. Il s'avère qu'il dépend en fait de la forme de la pénalisation de l'écart à l'engagement P_{dev} .

Si la pénalisation est *linéaire*, nous avons vu que la loi de gestion se réduit à la stratégie myope " $P_{sto} = P_{mis}$ " (représentée figure 3.2a). Dans ce cas, la forme de la loi ne change pas, si ce n'est les zones de saturation du stockage. En effet, ces zones sont définies dans l'espace d'état par les inégalités :

$$E_{sto} + P_{mis}\Delta_t \geq E_{rated} \quad \text{zone "stockage bientôt plein"} \quad (3.14a)$$

$$E_{sto} + P_{mis}\Delta_t \leq 0 \quad \text{zone "stockage bientôt vide"} \quad (3.14b)$$

qui dépendent de la capacité. Nous les avons représentées schématiquement figure 3.9. Les zones de saturation délimitées par les inégalités (3.14) sont bien visibles sur les cartes de niveau des lois de gestion des figures 3.8c, 3.7a et 3.2a.




FIGURE 3.9 – Zones de saturation énergétique du stockage, représentées dans l'espace d'état.

Lorsque la pénalisation de l'écart à l'engagement est *quadratique*, un autre effet intéressant est observable : moins la capacité est grande, moins le stockage va être utilisé. Nous voulons dire par là que, à même état d'énergie ($SoE = E_{sto}/E_{rated}$) et à même erreur de prévision P_{mis} , la puissance absorbée P_{sto} est plus faible. Cet effet est visible figure 3.10. La réduction de la puissance absorbée se traduit directement par un plus grand écart à l'engagement. Par exemple, à l'état (0 MWh, 4 MW), on a $P_{dev} \approx 1,8$ MW avec la capacité de 5 MWh (fig. 3.10a, coin haut-droit) contre $P_{dev} \approx 0,4$ MW avec la capacité de 20 MWh (fig. 3.10b).

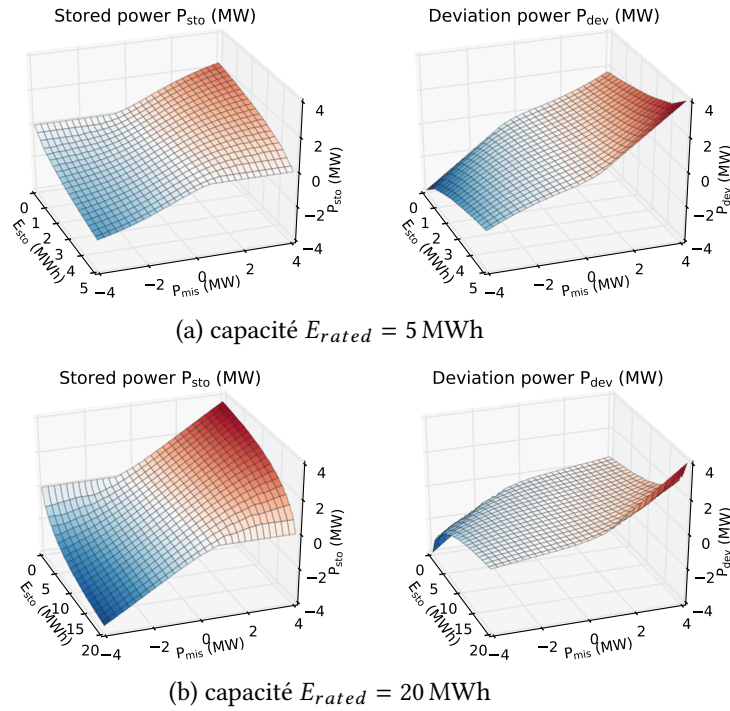


FIGURE 3.10 – Effet de la capacité sur la gestion optimale pour une pénalité quadratique (coefficient de corrélation ϕ fixé à 0,8)

Interprétation : nous avons vu à la partie 3.1.2 que le fait de n’absorber qu’une partie de l’erreur de prévision (i.e. $P_{sto} = \alpha P_{mis}$ avec $0 < \alpha < 1$) correspond à une stratégie proactive qui ménage de l’espace de stockage pour les futures erreurs. Dans le cas d’une “petite” batterie, la faible capacité oblige à réduire assez agressivement la puissance stockée. Inversement, le besoin d’anticiper est plus faible pour une large capacité.

Effet de la corrélation des erreurs de prévision Le coefficient ϕ qui règle l’autocorrélation des erreurs de prévision a un impact important, au même titre que la capacité de stockage. Tout d’abord, nous montrons au chapitre sur le dimensionnement (§4.2) que plus ϕ est élevé (proche de 1), plus la performance, en termes de critère d’écart à l’engagement, est dégradée. Cela se traduit par l’augmentation du besoin en capacité de stockage pour garder un niveau de performance donné.

Pour la loi de gestion, dans le cas où la pénalité est quadratique, nous constatons un effet d’étirement similaire à ce que nous venons de décrire pour la variation de la capacité du stockage (fig. 3.10). Nous ne nous y attardons donc pas.

Un autre effet, qui ressemble à une rotation, peut être mis en évidence lorsque la pénalité comporte un seuil de tolérance. Nous avons tracé figure 3.11 la loi de gestion optimale face une pénalisation seuil-quadratique pour deux valeurs du coefficient ($\phi = 0$ et $\phi = 0,6$). En comparant les deux figures, on peut observer que les deux zones d’écart quasi constant ($P_{dev} \approx -P_{tol}$ et $P_{dev} \approx +P_{tol}$) se répartissent toujours de part et d’autre d’une ligne $P_{dev} = 0$ toujours droite, mais dont l’orientation varie. Ce constat nous pousse à caractériser cette ligne $P_{dev} = 0$, et en particulier l’influence de ϕ .

3.3 Gestion optimale pour la garantie d'engagement J+1

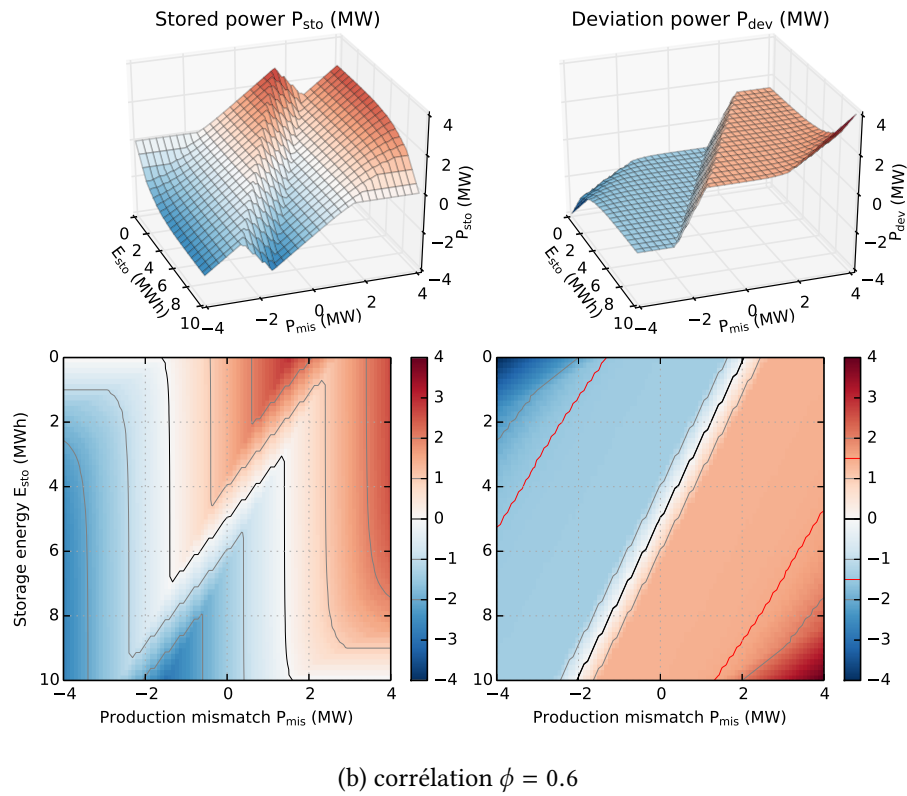
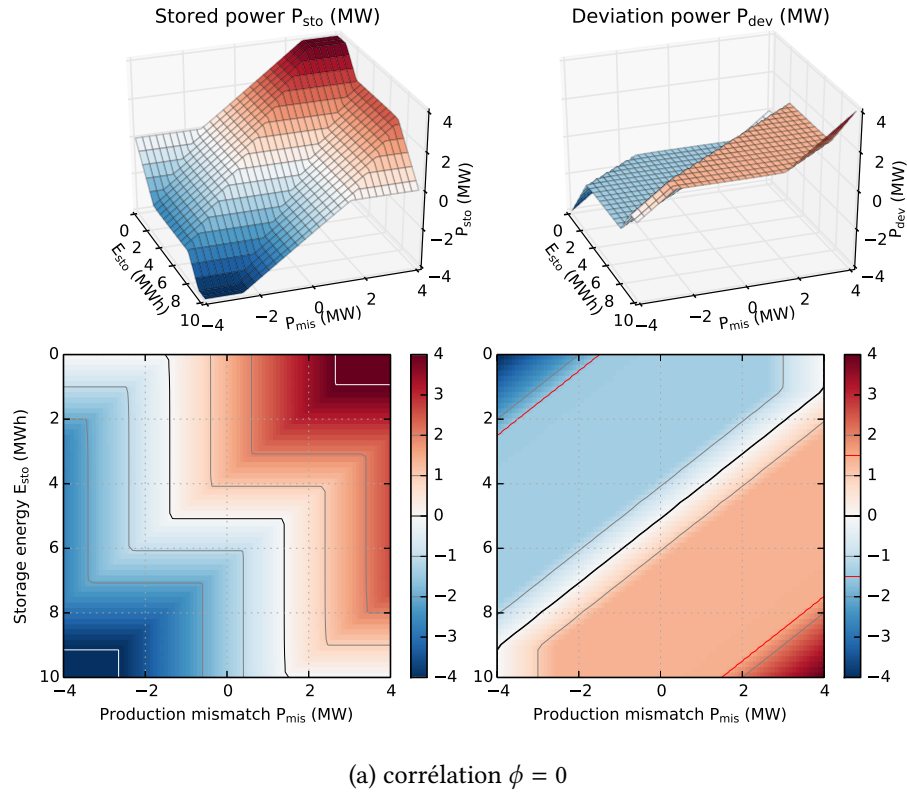


FIGURE 3.11 – Effet de la corrélation des erreurs de prévision sur la gestion optimale pour une pénalité seuil-quadratique (capacité E_{rated} fixée à 10 MWh)

Caractérisation de la ligne de décision “écart nul” Pour deux cas présentés figure 3.11 ainsi qu’avec celui de la figure 3.7b ($\phi = 0,8$), nous constatons que la ligne $P_{dev} = 0$ est une droite d’équation :

$$(E_{sto} - E_{rated}/2) + \tau P_{mis} = 0 \quad (3.15)$$

où le paramètre τ agit sur l’orientation de cette droite. Observons que τ varie avec ϕ :

- sur la figure 3.11a ($\phi = 0$), nous observons que $\tau \approx 1$ h,
- sur la figure 3.11b ($\phi = 0,6$), nous observons que $\tau \approx 2,5$ h,
- sur la figure 3.7b ($\phi = 0,8$), nous observons que $\tau \approx 5$ h.

Pour modéliser les variations de ce paramètre τ , nous proposons un modèle basé sur des arguments théoriques qui est en bonne adéquation avec ces observations. Malheureusement, la démonstration qui suit est incomplète, car elle fait appel à une hypothèse empirique basée sur une “intuition énergétique”, mais ceci peut constituer une piste de réflexion.

Nous supposons empiriquement que la gestion du stockage a pour objectif d’annuler le “déséquilibre énergétique” du système. Du côté de l’énergie stockée, le déséquilibre correspond à l’écart $E_{sto} - E_{rated}/2$. En effet, le système a intérêt à ramener l’énergie du stockage à l’état de mi-énergie $E_{sto} = E_{rated}/2$, car c’est l’état qui offre le plus marge à la hausse et à la baisse¹⁶. Pour atteindre cet état, la gestion devrait chercher à absorber :

$$P_{sto}^{\oplus} = -\frac{1}{\Delta_t}(E_{sto} - E_{rated}/2) \quad (3.16)$$

où le signe \oplus dénote juste que c’est une valeur cible qui n’est pas forcément atteignable ou souhaitable (pour respecter la tolérance). L’équation (3.16) implique du point de vue de l’écart à l’engagement ($P_{dev} = P_{mis} - P_{sto}$) :

$$P_{dev}^{\oplus} = P_{mis} + \frac{1}{\Delta_t}(E_{sto} - E_{rated}/2) \quad (3.17)$$

Point remarquable, si l’on prend l’équation (3.17) pour $P_{dev}^{\oplus} = 0$, elle est strictement équivalente à (3.15) pour $\tau = 1$ h, c’est-à-dire la ligne de partage observée en l’absence de corrélation ($\phi = 0$) sur la figure 3.11a.

Pour prendre en compte la corrélation qui fait croître τ , il faut ajouter au “déséquilibre énergétique” la contribution des erreurs de prévision futures ($P_{mis}(k+h)$ pour $h > 0$). Pour quantifier ces erreurs futures, nous devons énoncer la formule de prévision d’un processus AR(1). Connaissant à un instant k la valeur courante $P_{mis}(k)$, les valeurs futures $P_{mis}(k+h)$ sont égales, *en espérance*, à :

$$\mathbb{E}[P_{mis}(k+h)|P_{mis}(k)] = \phi^h P_{mis}(k), \quad \text{pour } h = 1, 2, \dots \quad (3.18)$$

et en sommant ces puissances futures, nous obtenons l’énergie moyenne attendue pour les instants $k+1$ et suivants :

$$E_{mis} = \mathbb{E}\left[\sum_{h=1}^{\infty} P_{mis}(k+h)\Delta_t | P_{mis}(k)\right] = \sum_{h=1}^{\infty} \phi^h \Delta_t P_{mis}(k) \quad (3.19)$$

16. l’intérêt d’avoir une marge à la hausse *et* à la baisse vient de la *symétrie* de la pénalisation des écarts. Si, par exemple, seuls les écarts négatifs (sous-production) étaient pénalisés, il y aurait plus intérêt à avoir une batterie toujours chargée.

Il est alors possible d'ajouter cette énergie moyenne attendue au terme $E_{sto} - E_{rated}/2$ dans l'équation (3.17). Après simplifications¹⁷, nous obtenons une nouvelle valeur cible de l'écart à l'engagement qui tient compte de l'erreur de prévision :

$$P_{dev}^{\oplus} = \frac{1}{\Delta_t} (E_{sto} - E_{rated}/2 + \frac{\Delta_t}{1-\phi} P_{mis}) \quad (3.20)$$

En prenant cette équation en $P_{dev}^{\oplus} = 0$, nous pouvons la comparer à (3.15) pour identifier le paramètre τ :

$$\tau = \frac{\Delta_t}{1-\phi} \quad (3.21)$$

et cette formule est en très bon accord avec les observations (ex : pour $\phi = 0,6$, on a $1/(1-\phi) = 2,5$). Cette bonne adéquation justifie empiriquement notre hypothèse d'une loi de gestion basée sur la notion de déséquilibre énergétique. Le coefficient τ s'interprète comme un "horizon temporel énergétique". Si par exemple, l'erreur de prévision à un instant k est de +1 MW, le coefficient τ indique qu'il faut s'attendre, en moyenne, à subir une surproduction de $\tau \times P_{mis} = 5$ MWh pour les instants k et suivants (pour $\phi = 0,8$).

Pour finir, si nous ajoutons à l'équation (3.20) une saturation pour les valeurs hors de l'intervalle $\pm P_{tol}$, nous obtenons une fonction paramétrique des deux variables d'état qui suit fidèlement la forme des lois de gestion optimale (tant que l'état n'est pas en zone de saturation énergétique telle que définie figure 3.9). Cette observation nous amène au sujet de la paramétrisation d'une loi de gestion.

3.3.3 Paramétrisation de la gestion avec tolérance

L'étude précédente sur l'effet des coefficients du problème a mis en évidence que la loi de gestion face à un coût avec seuil de tolérance peut être écrite de façon paramétrique :

$$P_{dev}^{\oplus} = f_{sat}^{P_{tol}} \left(\frac{1}{\Delta_t} (E_{sto} - E_{rated}/2 + \tau P_{mis}) \right) \quad (3.22)$$

où $f_{sat}^{P_{tol}}(\dots)$ note la fonction identité qui sature à $\pm P_{tol}$:

$$f_{sat}^{P_{tol}}(p) = \begin{cases} -P_{tol} & \text{si } p < -P_{tol} \\ p & \text{si } -P_{tol} \leq p \leq P_{tol} \\ +P_{tol} & \text{si } p > +P_{tol} \end{cases} \quad (3.23)$$

Seule restriction, la valeur cible (3.22) de l'écart à l'engagement n'est applicable qu'en dehors de la zone de saturation énergétique délimitée par les inégalités (3.14) (cf. fig. 3.9). Pour obtenir une loi de gestion applicable sur tout l'espace d'état, il suffit d'appliquer les saturations appropriées à la variable $P_{sto}^{\oplus} = P_{mis} - P_{dev}^{\oplus}$ pour que la puissance absorbée respecte les contraintes du stockage en terme d'énergie et de puissance (rappelées au début de la partie 3.3).

La loi de gestion (3.22) a deux paramètres : P_{tol} , qui découle directement du cahier des charges, et le coefficient τ dont on a vu qu'il peut être réglé d'après la valeur de ϕ (3.21). Cependant, il est tout à fait possible de choisir τ par optimisation d'un critère calculé sur des simulations temporelles. Cela permet de se passer de l'optimisation dynamique.

17. en particulier, en utilisant la somme d'une suite géométrique $\sum_{h=0}^{\infty} \phi^h = 1/(1-\phi)$

Intérêt de la représentation paramétrique Partie 1.3.3, nous avons expliqué que les optimisations du dimensionnement et de la gestion sont *couplées*. Pour être certain d'atteindre la meilleure performance, ces optimisations doivent être conduites de façon soit *simultanée* soit *imbriquée*. Dans cette perspective, disposer d'une description paramétrique de la loi de gestion est extrêmement avantageux, car l'optimisation simultanée peut être conduite en utilisant un seul vecteur de paramètres qui agrège les paramètres du dimensionnement (ex : E_{rated}) et ceux de la loi de gestion paramétrique.

Le travail de Kim *et al.* [61], sur un véhicule hybride hydrogène + batterie, est un exemple d'application de cette méthode. Dans un premier temps, la SDP permet d'obtenir une loi de gestion optimale. Le résultat obtenu est simplifié "visuellement" en une loi à quelques paramètres. La loi de contrôle obtenue est appelée "pseudo SDP controller". Cette loi, dont les paramètres peuvent être optimisés pour chaque dimensionnement, permet d'obtenir le dimensionnement optimal de la chaîne de traction.

Deuxième avantage important, l'expression paramétrique simple d'une loi de gestion peut faciliter l'implémentation sur un système de *contrôle embarqué* (microcontrôleur ou automate). En effet, la programmation dynamique fournit une loi de gestion sous forme de table ($\mu^*(x^{(n)})$), c'est-à-dire la valeur de la commande optimale aux points $x^{(n)}$ appartenant à la grille de l'état, cf. §3.2.2). L'utilisation de cette table nécessite donc son stockage (besoin en mémoire proportionnel au nombre de points de grille) ainsi que l'utilisation d'un algorithme d'interpolation (calcul : additions et produits). Par comparaison, l'expression paramétrique nécessite beaucoup moins de mémoire pour un besoin en calcul similaire.

Effet du pas de temps Lorsque le pas de temps $\Delta_t \rightarrow 0$, c'est-à-dire lorsque le contrôle à temps discret devient un contrôle à *temps continu*, la loi de gestion (3.22) peut être écrite plus simplement. En effet, la transition linéaire entre les deux zones de saturation à $\pm P_{tol}$ devient un seuil dur :

$$P_{dev}^{\oplus} = P_{tol} \cdot \text{sgn}(E_{sto} - E_{rated}/2 + \tau P_{mis}) \quad (3.24)$$

où la *sgn* représente la fonction signe, avec la convention $\text{sgn}(x) = \pm 1$ selon le signe de x . Cette écriture est encore plus simple à implanter sur un contrôleur embarqué.

3.4 Autres applications de gestion optimale de stockage

3.4.1 Lissage de la production d'un houlogénérateur (SEAREV)

Dans le cadre du développement de notre code de programmation dynamique, nous avons souhaité appliquer l'algorithme à un problème de gestion de stockage différent, surtout du point de vue du modèle stochastique de production. Nous nous sommes intéressés au lissage de la production du houlogénérateur direct¹⁸ SEAREV, déjà étudié par nos collègues [6]. Cette étude a servi de support à l'article [50] qui présente notre code.

Il n'y a pas de différence structurelle dans l'architecture du système de stockage (fig. 1.2), par contre la forme de la production est très différente, car elle pulse au rythme des vagues. Ce caractère fondamentalement oscillant oblige à choisir un modèle d'ordre 2 pour la production, ce qui porte la dimension du vecteur d'état à 3 (2+1 pour l'état d'énergie).

18. récupérateur électrique de l'énergie des vagues, direct au sens où l'énergie mécanique que le système extrait de la houle est directement transformé en énergie électrique, sans conversion intermédiaire (e.g. hydraulique). Cela conduit à une production électrique qui pulse au rythme des vagues.

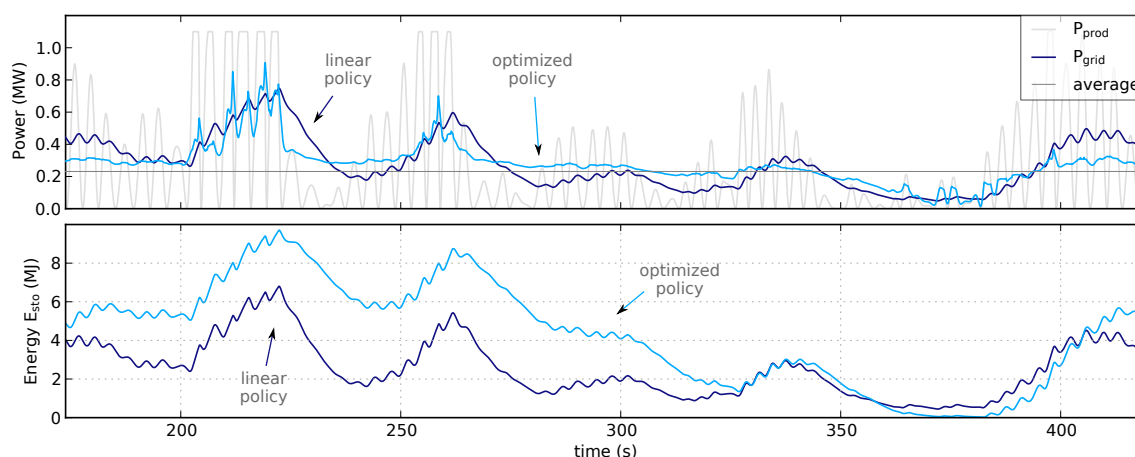


FIGURE 3.12 – Comparaison entre le lissage de puissance d’un SEAREV de 1,1 MW avec un stockage de 10 MJ contrôlé par différentes lois de gestion. BLEU SOMBRE : loi de gestion choisie empiriquement (loi linéaire) BLEU CLAIR : loi optimisée par Programmation dynamique [50].

Ce travail a permis de valider *dans une certaine mesure* l’efficacité de l’approche SDP. En effet, nous avons observé une diminution de l’écart-type de la puissance de sortie P_{grid} de 20 % (le critère à minimiser étant ici la moyenne de P_{grid}^2). Généralement, la gestion optimisée diminue les fluctuations de la sortie comme on peut le voir figure 3.12, par exemple sur la période 270–370 s. Par contre, il y a également des périodes (200–225 s) où la sortie est localement plus fluctuante. Cela s’explique par le caractère approximatif du modèle de production. Ainsi, cette étude permet de mettre en lumière la faible *robustesse* de l’approche SDP à un défaut de modélisation.

Autre point notable, le cas SEAREV illustre la question du choix de la fonction coût. En effet, un des critères que l’on peut objectivement souhaiter améliorer est le *flicker*, car il faut respecter un seuil maximal de flicker pour pouvoir se connecter au réseau électrique. Cependant, ce critère qui pénalise les fluctuations de la tension au point de raccordement est d’expression compliquée par rapport à ce qu’accepte la programmation dynamique. Ainsi, le coût quadratique P_{grid}^2 peut être vu comme une pénalisation *mandataire* (“proxy”). Dans ce cas, on peut se demander si ce choix est adapté ou si d’autres sont plus adéquats, comme par exemple la pénalisation de la variation $\Delta G(k) = P_{grid}(k) - P_{grid}(k - 1)$. Ce travail comparatif reste à faire, sachant qu’utiliser une pénalisation de la variation entre 2 instants a le défaut (du point de vue de la programmation dynamique) d’augmenter le vecteur d’état d’une variable. En effet, l’expression de $\Delta G(k)$ fait intervenir une valeur de l’instant passé $k - 1$. Comme nous allons le voir dans la partie qui suit (lissage de rampe), cela crée un couplage entre les valeurs successives du contrôle P_{sto} .

3.4.2 Lissage des rampes de production éolienne

Intérêt possible du lissage de rampe Nos travaux sur le système éolien-stockage portent essentiellement sur la conduite de ce système pour garantir un engagement de production $J+1$. Ce cahier des charges a pour but de permettre à EDF SEI d’intégrer un tel système dans l’optimisation $J+1$ de l’ensemble de la production d’une île (cf. §1.2.2).

Malheureusement, la production éolienne n’est que moyennement prévisible un jour à l’avance (10 à 15 % d’erreur RMS, cf. §2.3). Par conséquent le besoin en capacité énergétique de stockage est important (cf. chapitre 4) et on peut se demander si ce cahier des charges permet, pour une capacité donnée, de fournir le meilleur service au réseau. Pour prendre un exemple caricatural,

si une journée est globalement moins venteuse que prévue, y a-t-il vraiment un intérêt à utiliser une batterie électrochimique pour compenser 24 heures de production trop faible, alors qu'une unité de "production de base" (i.e. peu flexible, comme une centrale à charbon) pourrait faire le travail. Le but d'un système de stockage, qui est une unité extrêmement flexible, ne serait-il pas plutôt de réguler les variations rapides de la production ?

Ainsi, suite à nos échanges avec EDF SEI, nous avons souhaité étudier un cahier des charges sans notion de prévision ni d'engagement de production¹⁹, mais centré sur la réduction de la variabilité. En particulier, inspiré par l'exemple de certaines îles d'Hawaï, nous nous sommes intéressés à la limitation des rampes de puissance (aussi appelée lissage ou contrôle de rampe). Ce type de contrôle a été expérimenté de façon opérationnelle dans le cadre d'un partenariat entre le développeur éolien FirstWind et le fabricant de systèmes de stockage Xtreme Power²⁰ [102]. Le premier projet pilote, datant de 2009, associe un stockage de 1,5 MW/1 MWh à la ferme "Kaheawa wind I" de 30 MW (île de Maui).

Description des systèmes existants Mis à part un brevet déposé par Xtreme Power sur la gestion de rampe [26], nous n'avons pas trouvé de publication sur les résultats du projet Kaheawa, si ce n'est un diaporama de promotion de la technologie [102]. En revanche, on trouvera chez Matsuura [73] une vision générale de l'intégration de l'éolien sur le système électrique de Hawaï, géré par Hawaiian Electric (HECO). Par ailleurs, nous avons trouvé sur le site d'HECO un cahier des charges d'appel d'offres EnR [55] qui contient des exigences chiffrées en termes de rampe. En particulier, les unités de 5 à 25 MW doivent respecter une limite de 2MW/min. Au delà de 100 MW, cette limite est de 5% P_{nom} /min.

Relevons également le travail de Yoshimoto *et al.* [105] sur le lissage de la production de la ferme "Tomamae Wind Villa" (31 MW) au Japon, avec un système de stockage vanadium redox-flow de 6MW/6MWh. La loi de gestion utilisée est conçue dans le domaine fréquentiel à l'aide de filtres passe-bas [104]. Il ne s'agit donc pas d'un contrôle de rampe au sens strict, même si en pratique cela réduit effectivement l'amplitude des variations.

Formalisme Avant toute optimisation proprement dite, la première étape (cf. méthodologie §3.2.1) consiste à formaliser le problème, si possible d'une manière adaptée à la mise en œuvre de la programmation dynamique.

En introduisant le problème de gestion de stockage pour garantir un engagement (§1.2.2), nous avons mentionné que la sollicitation d'entrée P_{mis} peut être vue comme une "consigne idéale de stockage", car si le stockage est capable de réaliser cette consigne ($P_{sto} = P_{mis}$), alors l'écart à l'engagement est nul ($P_{dev} = 0$). Nous montrons à présent qu'il est possible de faire émerger cette *même notion de "consigne idéale" pour le lissage de rampe*. Rappelons tout d'abord notre notation des variations de production :

$$\Delta P(k) = P_{prod}(k) - P_{prod}(k - 1) \quad (\text{rappel 2.36})$$

19. même en l'absence d'engagement contractuel des producteurs EnR, rien n'empêche l'opérateur du réseau insulaire d'utiliser en interne des prévisions de production J+1 pour optimiser le plan de production.

20. Xtreme Power, entreprise texane, a développé plusieurs projets éolien-stockage à Hawaï avec une technologie de stockage Pb-acide "de puissance" (ratio E/P annoncé entre 15 et 60 minutes), en concurrence directe avec certaines technologies Lithium-ion. Une technologie de cellule à faible résistance interne (baptisée PowerCell™) est associée à convertisseur à électronique de puissance pour former un système de stockage baptisé Dynamique Power Resource™. Malheureusement, "Kahuku wind farm" (île d'Oahu), l'un des plus importants projets avec 15 MW/10 MWh associé à 30 MW d'éolien, a brûlé en août 2012. La ferme n'a redémarré qu'en février 2014. Indépendamment ou pas, Xtreme Power s'est déclarée en faillite ("chapter 11 bankruptcy") en janvier 2014 et a été rachetée par Younicos, un concurrent allemand.

Grâce à la présence d'un stockage, il est possible de moduler la puissance fournie au réseau ($P_{grid} = P_{prod} - P_{sto}$), et donc ses variations :

$$\Delta G(k) = P_{grid}(k) - P_{grid}(k-1) \quad (3.25)$$

L'objet du lissage de rampe est de gérer la puissance P_{sto} absorbée par le stockage pour maîtriser les variations ΔG de la puissance injectée sur le réseau. Dans une démarche de contrôle optimal, c'est donc cette variable ΔG qui doit être pénalisée dans la fonction coût J . Le coût d'un instant est donc supposé de la forme $c_k = c(\Delta G(k))$.

Nous réécrivons cette grandeur qui est pénalisée sans faire intervenir la puissance P_{grid} :

$$\Delta G(k) = \Delta P(k) - P_{sto}(k) + P_{sto}(k-1)$$

et cette écriture nous amène à définir la variable P_{req} dite "consigne idéale de stockage" :

$$P_{req}(k) = P_{sto}(k-1) + \Delta P(k) \quad (3.26)$$

avec laquelle nous obtenons finalement une écriture de ΔG intéressante, car analogue à (1.8) (" $P_{dev} = P_{mis} - P_{sto}$ ") :

$$\Delta G(k) = P_{req}(k) - P_{sto}(k) \quad (3.27)$$

Ainsi, la variable pénalisée ΔG est l'analogue de P_{dev} tandis que P_{req} remplace P_{mis} . P_{req} est bien la "consigne idéale" au sens où, si elle est respectée ($P_{sto} = P_{req}$), alors la variation ΔG est nulle. À présent, nous avons tous les éléments pour écrire une équation dynamique du système, avec deux variables d'état (E_{sto}, P_{req}) :

$$\begin{aligned} E_{sto}(k+1) &= E_{sto}(k) + P_{sto}(k)\Delta_t \\ P_{req}(k+1) &= P_{sto}(k) + \Delta P(k+1) \end{aligned} \quad (3.28)$$

La première équation ("stockage idéal") est familière car elle a déjà été utilisée dans ce chapitre et dans le précédent. La deuxième, qui remplace le processus AR(1) modélisant P_{mis} , est par contre très différente, puisque la variable de commande P_{sto} y intervient (alors que P_{mis} est un processus incontrôlé).

Pour que l'équation (3.28) constitue véritablement une équation dynamique utilisable en programmation dynamique, il faut néanmoins respecter une condition : les variations de production ΔP , qui constituent la perturbation stochastique du problème, doivent être indépendantes (séquence iid). C'est dans ce sens que, partie 2.4.2, nous avons modélisé les fluctuations de production par des incréments ΔP indépendants. Rappelons que ce modèle, qui équivaut à modéliser $P_{prod}(k)$ par une marche aléatoire, n'est qu'une approximation du comportement réel (complexe) de la production éolienne²¹. À ce titre, il est donc très important de vérifier la performance de la loi de gestion sur des données réelles (cf. étape 3 de la méthodologie §3.2.1).

Limitation de rampe Comme sur les îles d'Hawaï, nous supposons un cahier des charges visant non pas à annuler les variations de production (objectif illusoire d'obtenir une production constante), mais à les limiter. Nous notons r la rampe maximale souhaitée (en MW/h, MW/min

21. Il est tout à fait possible d'enrichir l'équation (3.28) pour modéliser la production éolienne de façon plus complexe qu'une marche aléatoire. Par exemple, l'ajout de P_{prod} dans le vecteur d'état permet de modéliser une production markovienne, comme le font Papaefthymiou *et al.* [78].

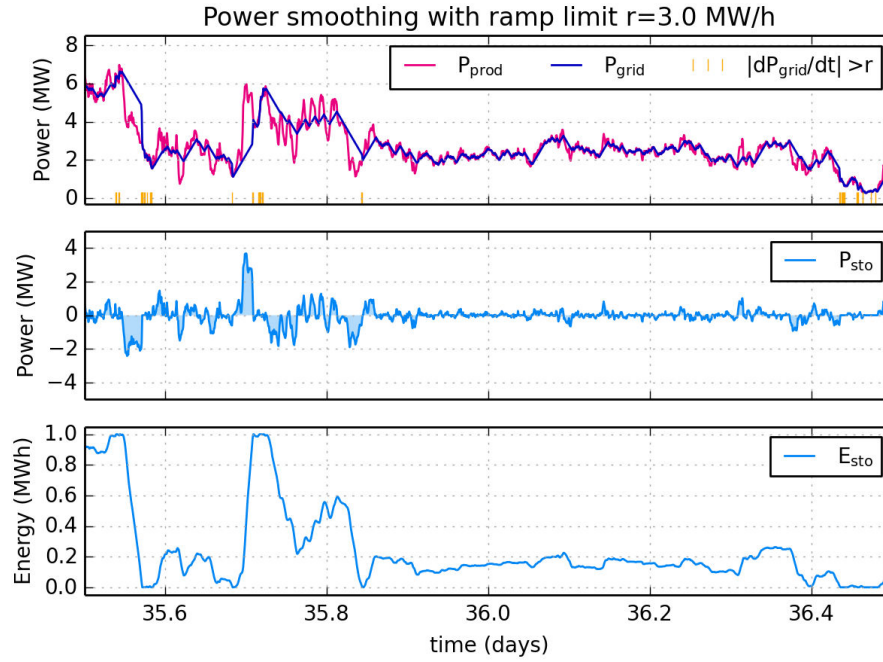


FIGURE 3.13 – Lissage de rampe simulé sur 24 heures de données Pégase (ferme 10 MW de La Perrière, avec $E_{rated} = 1$ MWh), avec la gestion empirique (3.30)

ou autre unité de même dimension). L'objectif est donc de contrôler le stockage pour garantir le respect de cette rampe maximale :

$$|\Delta G(k)| \leq r\Delta t, \quad \text{à tout instant } k \quad (3.29)$$

Dans un premier temps, pour respecter cette contrainte, nous utilisons la variable de consigne idéal P_{req} pour construire une loi de gestion empirique. Une première possibilité simple est la stratégie " $P_{sto} = P_{req}$, tant que le stockage n'est pas saturé", ce qui permet d'assurer une injection constante sur le réseau ($\Delta G = 0$). Cependant, il semble raisonnable de ne pas viser un objectif aussi strict. Ainsi, nous pouvons plutôt viser de laisser passer toutes les variations, sauf celles qui sont hors tolérance. Cela s'exprime par :

$$P_{sto}(k) = P_{req} - f_{sat}^{r\Delta t}(P_{req}) \quad (3.30)$$

où f_{sat} est la même fonction de saturation qu'utilisée pour la paramétrisation de la gestion d'engagement (3.23). En particulier, si $|P_{req}| \leq r\Delta t$, le stockage est mis au repos ($P_{sto} = 0$).

Nous avons appliqué la loi de gestion empirique (3.30) sur les données de production de la ferme de La Perrière (10 MW, cf. §2.4). Un tracé temporel de cette simulation est présenté figure 3.13. Pour cette simulation, la capacité de stockage est fixée à 1 MWh (avec une puissance illimitée), et la vitesse de rampe à 3 MW/h (soit 0,05 MW/min). L'extrait de 24 heures choisi présente un profil de production intéressant : le premier quart présente d'importantes fluctuations (chute rapide de 6 à 2 MW, puis remontée à 6 MW) alors que le reste de la journée est relativement stable autour de 3 MW.

Les marques oranges pointent les instants où la contrainte de rampe (3.29) n'est pas respectée. Nous observons que ces non-respects se produisent lorsque le stockage est saturé, lors des grandes




FIGURE 3.14 – Lissage de rampe simulé sur 24 heures de données Pégase, avec loi de gestion optimisée (pénalisation seuil-linéaire)

fluctuations de P_{prod} . Lorsque la production reste autour de 3 MW (35,9–36,4 j), il n’y a plus de dépassements.

Mises à part les saturations du stockage, un problème apparaît figure 3.13 : la loi empirique (3.30) gère mal l’état d’énergie. En effet, sur toute la période 35,9–36,4 j, l’état d’énergie est bloqué sans raison à un niveau bas (entre 15 et 25 %, sachant qu’à d’autres moments, ce même phénomène de blocage apparaît à d’autres niveaux). Ainsi, il manque clairement une *régulation de l’état d’énergie*, et pour en ajouter une, nous voyons trois solutions :

1. ajouter explicitement un retour d’état sur le SoE , par exemple dans la fonction de saturation (suivant l’exemple de (3.22))
2. ajouter implicitement un retour en ajustant la rampe maximale en fonction du SoE
3. trouver une loi de gestion par optimisation dynamique

La première approche correspond à la recherche d’une loi de gestion “empirique optimisée” (cf. notre nomenclature des méthodes alternatives partie 3.2.3). La deuxième approche est utilisée par Xtreme Power à Hawaï et nous la décrivons au paragraphe suivant.

Pour notre part, nous avons essayé directement l’optimisation dynamique. Pour sa mise en œuvre, le respect de la contrainte de rampe (3.29) doit être traduit en une fonction de pénalisation $c(\Delta G(k))$. Parmi toute la palette des formes de pénalisation possible (ex : figure 3.5), le respect de l’inégalité (3.29) fait préférer une forme *avec tolérance* de $\pm r\Delta_t$. Pour respecter la contrainte le maximum de temps, il faut minimiser la proportion de temps où $|\Delta G(k)| > r\Delta_t$. Cela nous ferait choisir une pénalisation avec seuil de tolérance “simple” (fonction en puits), mais nous avons vu partie 3.3.1 que le résultat obtenu avec cette forme non convexe peut être totalement inacceptable. Nous choisissons donc une forme *seuil-linéaire* :

$$c(\Delta G(k)) = \begin{cases} 0 & \text{si } |\Delta G(k)| \leq r\Delta_t \\ |\Delta G(k)| - r\Delta_t & \text{si } |\Delta G(k)| > r\Delta_t \end{cases} \quad (3.31)$$

La trajectoire obtenue avec la loi de gestion optimale vis à vis de cette pénalisation est présentée figure 3.14. On y observe que l'état d'énergie est bien régulé (autour de 50 %). Ainsi, les dépassements de rampe visibles figure 3.13 sur la période 36,4–36,5 j ont disparu. Autre point légèrement visible vers $t=35,6$: lorsqu'il y a des dépassements de rampes, ils sont moins brutaux qu'avec la gestion empirique. Par exemple, il y a, sur l'ensemble des 208 jours de données, 52 dépassements "extrêmes" (au sens $|\Delta G| > 1 \text{ MW/min}$). Avec la gestion empirique, il en reste encore 48²² alors qu'il n'y en a plus que 4 avec la gestion optimisée.

Nous ne détaillerons pas plus cette optimisation dynamique de la gestion de rampe, car il s'agit de résultats prélimaires. Des études complémentaires sont nécessaires pour en valider la performance et bien comprendre l'influence de certains paramètres, en particulier la forme de la pénalisation et la rampe maximale tolérée (i.e. la valeur de r).

Rampe adaptative Pour compléter notre étude de la gestion de rampe, nous avons analysé la stratégie de gestion utilisée par Xtreme Power pour la ferme de Kaheawa à Hawaï. Nos seules sources sont une série temporelle de 3 heures [102, diapos 18-19] et leur brevet [26]. Il en ressort que la limitation de rampe est non pas constante, mais adaptative, fonction de l'état d'énergie.

L'idée est tout d'abord de transformer la contrainte (3.29) en séparant la limite de rampe unique r en une limite positive r^+ et une limite négative r^- . Ensuite, ces deux rampes limites sont elles-mêmes ajustées en fonction de l'état d'énergie. Au final, la contrainte à respecter dépend de l'état d'énergie de l'instant courant, d'où la notion de "rampe adaptative" :

$$r^-(SoE(k))\Delta_t \leq \Delta G(k) \leq r^+(SoE(k))\Delta_t \quad (3.32)$$

Nous avons représenté figure 3.15 un exemple d'adaptation des pente maximales r^+ et r^- en fonction de l'état d'énergie :

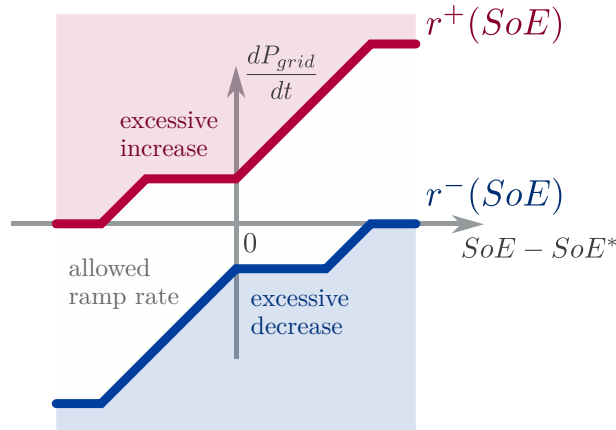


FIGURE 3.15 – Exemple de limitation de rampe adaptative, d'après le brevet d'Xtreme Power [26, fig. 5]

Illustrons cette méthode à l'aide des valeurs annoncées pour la ferme de Kaheawa :

22. et avec la gestion empirique pour une rampe r plus stricte que 3 MW/h, le nombre de variations extrêmes est aggravé !

3.4 Autres applications de gestion optimale de stockage

- lorsque le SoE est proche d'une valeur cible SoE^* , par exemple 50 %²³, les rampes sont limitées à 0,1 MW/min ($r^+ = +0,1$ et $r^- = -0,1$).
- lorsque le SoE est plus élevé ($SoE - SoE^* > 0$), les limites de pentes sont décalées positivement ($r^+ = +1$ et $r^- = 0$) ce qui dégrade la performance (rampe maximale à 1 MW/min), mais augmente les chances de décharger la batterie.
- lorsque le SoE est plus bas ($SoE - SoE^* < 0$), les limites de pentes sont décalées négativement ($r^+ = 0$ et $r^- = -1$). Là encore, la pente maximale est dégradée à 1 MW/min (en valeur absolue), mais cela augmente les chances d'absorber de la puissance pour se recharger.

Point positif, cette stratégie permet de bien gérer l'état d'énergie du stockage. Par contre, elle crée une ambiguïté sur la notion de rampe maximale : est-ce 0,1 ou 1 MW/min ? Si c'est la plus grande valeur qui compte, quel est l'intérêt d'essayer de faire mieux "de temps en temps" ? Cette interrogation se propage au gestionnaire du réseau : sur quelle valeur doit-il se baser pour régler son système (e.g. réserves primaire et secondaire) ?

Dans ce chapitre, nous avons formalisé le problème d'optimisation de la gestion d'énergie du système éolien-stockage, puis présenté la méthode pour le résoudre : la programmation dynamique stochastique (SDP). Nous l'avons ensuite appliquée à notre problème de gestion d'énergie pour garantir un engagement de production avec diverses variations des paramètres pour acquérir de l'expérience sur les différentes lois de gestion possibles et sur les comportements induits sur le système de stockage. Pour finir, nous avons appliqué cette démarche d'optimisation à d'autres problèmes de gestion d'énergie pour en vérifier la *flexibilité* : lissage de rampes de production éolienne et houlogénération.

À présent, nous poursuivons le fil de la problématique de ces travaux pour aborder, au chapitre 4, la dernière question : celle du *dimensionnement* d'un système de stockage pour atténuer les erreurs d'engagement de production.

23. pour Xtreme Power, le SoC cible est de 30 %, pour des raisons qu'on imagine liées à leur technologie Plomb-acide

Chapitre 4

Dimensionnement d'un stockage d'énergie

Sommaire

4.1	Méthode	113
4.2	Garantie d'un engagement de production J+1	115
4.3	Interaction dimensionnement – gestion	133

Nous abordons dans ce dernier chapitre la question du dimensionnement d'un système de stockage d'énergie. Nous entendons par dimensionnement du système le choix de sa capacité énergétique utile E_{rated} ainsi que sa puissance nominale P_{rated} .

Nous abordons également dans ce chapitre la question du choix de certains paramètres du cahier des charges. Pour le problème de l'engagement J+1, il s'agit de la valeur d'écart tolérée P_{tol} .

4.1 Méthode

Critères de dimensionnement Le dimensionnement du stockage vise à trouver une valeur des paramètres E_{rated} et éventuellement P_{rated} qui soit "satisfaisante". Pour objectiver la notion de "satisfaction", il faut la *quantifier* dans un ou des critères numériques de satisfaction. La valeur de ces critères, qui dépendent a priori des paramètres de dimensionnement, guide la décision de dimensionnement. Pour procéder à la décision, les critères peuvent être utilisés de deux manières :

1. la valeur du critère doit être *optimisée* (minimisée ou maximisée selon les cas), ou bien
2. la valeur du critère doit *respecter une contrainte*.

À titre illustratif, le coût sur cycle de vie du système de stockage est un exemple de critère que l'on peut souhaiter minimiser. La moyenne quadratique de l'écart à l'engagement en est un autre. Cependant, ce critère d'écart moyen peut aussi être traité par une contrainte en se donnant une valeur maximale à ne pas dépasser.

Lorsque plusieurs objectifs doivent être optimisés, certains peuvent être *contradictoires*. Par exemple, minimiser l'écart à l'engagement est généralement contradictoire avec la minimisation de la capacité de stockage. Plusieurs méthodes permettent de traiter les objectifs contradictoires :

4 Dimensionnement d'un stockage d'énergie

- ne garder qu'un seul objectif à optimiser, en traitant les autres comme des contraintes.
Exemple : minimiser la capacité de stockage, sous contrainte que l'écart à l'engagement ne soit pas plus grand qu'une valeur donnée.
- agréger les objectifs en un seul, par exemple avec une somme pondérée.
Exemple : pondérer les critères grâce à des paramètres économiques (coût du stockage, coût des pénalités d'écart) pour se ramener à la minimisation d'un coût économique global.
- traiter explicitement le problème par une optimisation multiobjectif. Le résultat n'est alors plus un jeu unique de paramètres optimaux, mais un ensemble de solutions (dit "front de Pareto") dont aucune ne domine¹ l'autre. Le choix final des paramètres de dimensionnement, parmi ces solutions dites *non dominées*, est laissé à l'appréciation d'un expert.

Pour notre part, nous avons essentiellement utilisé les deux premières approches. La première permet de répondre à une question qui touche à la structure du problème : "quelle capacité de stockage est nécessaire pour atteindre un niveau de performance donné ?" Cette question peut être étudiée en dehors de toute considération économique et c'est par exemple le cas de l'étude paramétrique ci-après (§4.2.1).

La deuxième approche est complémentaire, car elle donne une vision économique au problème. Un des paramètres cruciaux de ce type d'étude est le coût unitaire attribué à un système stockage (coût "par kW" ou "par kWh").

Prérequis du calcul Pour le calcul des critères de dimensionnement, il faut tout d'abord disposer d'une modélisation de l'ensemble du problème. Cela inclut les différents composants présentés au chapitre 2, avec la modélisation énergétique du stockage, de son vieillissement ainsi que la modélisation des entrées incertaines, en particulier la production et la prévision de production éolienne.

Il faut ensuite une loi de gestion du stockage, soit empirique, soit qui minimise un critère de pénalisation (gestion optimale, présentée chapitre 3). Cette loi de gestion dépend elle-même, a priori, du dimensionnement.

Si la loi de gestion est optimisée sur la base d'un critère de pénalisation, il faut bien sûr choisir ce critère *en adéquation* avec l'objectif de dimensionnement. Par exemple, le dimensionnement d'un système pour garantir un engagement de production $J+1$ avec une certaine tolérance devrait faire intervenir une loi de gestion optimisée vis-à-vis d'une pénalisation avec tolérance. Il n'est cependant pas nécessaire d'utiliser *exactement les mêmes* fonctions pour la pénalisation d'une loi de gestion et pour le dimensionnement. Plusieurs raisons peuvent, en effet, pousser à les différencier :

- il est inutile d'optimiser la loi de gestion avec des termes de pénalisation qui sont indépendants de la commande. Exemple : le coût de la capacité de stockage.
- certains critères de dimensionnement donnent une loi de gestion insatisfaisante. Exemple : le critère "proportion du temps où la tolérance d'écart n'est pas respectée" correspond à la pénalité "à seuil simple" étudiée partie 3.3.1 dont nous avons vu qu'elle amène de grands à-coups de puissance.

À l'aide de tous ces modèles, le problème est bien spécifié et nous pouvons réaliser des simulations numériques. Elles sont réalisées pour l'essentiel avec notre programme modulaire StorageSim (cf. présentation §2.5). Comme annoncé partie 1.3.3, la présence d'entrées incertaines

1. la dominance au sens de Pareto utilise la relation d'ordre dite "ordre produit" : pour deux paires de réels (x,y) et (x',y') , on dit que $(x,y) \leq (x',y')$ ssi $x \leq x'$ et $y \leq y'$. Par exemple $(1,1) \leq (2,2)$. Cette relation d'ordre n'est pas totale, c'est-à-dire que certains éléments sont incomparables, par exemple $(1,2)$ et $(2,1)$.

donne à ces simulations un caractère stochastique : ce sont des *simulations Monte-Carlo*. Conséquence pratique, le calcul d'un critère à partir de ces simulations stochastiques fait apparaître des problèmes d'*estimation statistique*, car les résultats sont "bruités". Nous détaillons sur un exemple ci-après la méthode utilisée pour obtenir des résultats avec suffisamment de précision.

Notons qu'un autre point méthodologique fondamental, celui de l'interaction entre le dimensionnement et la gestion, est traité à la fin de ce chapitre (§4.3).

4.2 Garantie d'un engagement de production J+1

Pour traiter ce problème, nous utilisons le modèle présenté dans la partie 3.3. Rappelons que, comme expliqué en introduction (§1.2.2), il s'appuie sur l'hypothèse sous-jacente que l'engagement de production est choisi égal à la prévision.

4.2.1 Effet de la corrélation des erreurs de prévision

Avant de traiter l'optimisation économique du dimensionnement, nous présentons un premier résultat qui démontre l'importance de prendre en compte la corrélation des erreurs de prévision. L'étude s'appuie sur la modélisation AR(1) de l'erreur de prévision présentée partie 2.3.2. Ces résultats ont été publiés dans la revue *Wind Energy* [52] et nous reprenons ici le fil de la partie 4 de cet article. Les paramètres de la modélisation sont :

- la capacité du stockage E_{rated} ,
- l'amplitude (écart-type) de l'erreur de prévision σ_P et
- le coefficient ϕ qui règle l'autocorrélation de ces erreurs.

Enfin, la loi de gestion employée pour le stockage est la stratégie " $P_{sto} = P_{mis}$, tant que possible". Cette stratégie, que nous avons aussi appelée "myope" et "empirique", est en fait optimale pour une pénalisation linéaire de l'écart P_{dev} (§3.3.1).

Analyse visuelle qualitative Pour percevoir qualitativement l'effet de l'autocorrélation de l'erreur de prévision sur la performance du système, nous avons représenté, figure 4.1, deux simulations du système sur une semaine. Dans les deux cas, la capacité est fixée à 15 MWh et l'écart-type des erreurs de prévision à 1 MW (ratio $E_{rated}/\sigma_P = 15$ h). Cette normalisation de la capacité, détaillée plus bas, illustre que notre étude peut s'adapter à toute amplitude de l'entrée, par simple mise à l'échelle des grandeurs. Sur la figure de gauche (fig. 4.1a), l'erreur de prévision n'est pas autocorrélée ($\phi = 0,0$), alors qu'à droite (fig. 4.1b), ϕ est fixé à 0,8, valeur typiquement observée sur les données de terrain (§2.3.2).

L'effet de cette loi de gestion est bien visible : tant que le stockage n'est pas saturé (ni vide, ni plein : $0 < SoE < 1$), l'écart à l'engagement P_{dev} est strictement nul. Par contre, lorsque le stockage est saturé, il n'absorbe plus rien ($P_{sto} = 0$) tant que l'erreur de prévision ne change pas de signe, ainsi cette erreur de prévision est intégralement reportée sur le réseau ($P_{dev} = P_{mis}$).

En comparant les deux simulations, on peut clairement observer que l'écart à l'engagement P_{dev} est en moyenne *beaucoup plus grand lorsque la sollicitation P_{mis} est corrélée positivement* (cas $\phi = 0,8$) que lorsque cette séquence est indépendante (cas $\phi = 0,0$). En effet, la corrélation positive implique que l'erreur de prévision peut rester du même signe pendant plusieurs instants consécutifs. Il y a donc moins de compensations rapides entre les erreurs positives et négatives et le stockage est plus souvent saturé. Fort de cette observation, nous passons à présent à l'étude quantitative, pour laquelle il nous faut *spécifier un critère* d'écart à l'engagement.

4 Dimensionnement d'un stockage d'énergie




FIGURE 4.1 – Simulation stochastique d'un système de stockage pour deux valeurs différentes du coefficient ϕ qui fixe la structure d'autocorrélation de l'erreur de prévision P_{mis} (autres paramètres : $E_{rated} = 15$ MWh et $\sigma_P = 1$ MW)

Analyse quantitative Notre outil de simulation numérique de stockage (§2.5) permet de calculer des séries d'écart à l'engagement $\{P_{dev}(k)\}$. Comme l'entrée P_{mis} est un processus aléatoire, l'écart P_{dev} l'est aussi et la quantification de "l'amplitude" de cet écart doit donc se faire de manière *statistique*. Nous choisissons d'utiliser le critère de la moyenne en valeur absolue (dite aussi norme 1) que nous abrégeons MAD (Mean Absolute Deviation) :

$$\|P_{dev}\|_1 = \mathbb{E}[|P_{dev}(k)|] \quad (4.1)$$

Ce critère peut avoir une interprétation économique directe : il est proportionnel aux pénalités financières, dans un cadre où le producteur éolien serait pénalisé pour chaque MWh hors engagement (énergie en plus ou en moins, comptée sans tolérance). Bien sûr, d'autres choix de critère sont possibles, comme la moyenne quadratique (norme 2 : $\|P_{dev}\|_2 = \mathbb{E}[|P_{dev}(k)|^2]^{1/2}$) qui donne plus de poids aux grands écarts, ou bien encore des quantiles.

Notons qu'avec notre approche Monte-Carlo, l'estimation d'une espérance $\mathbb{E}[\cdot]$ revient à calculer une moyenne sur un grand nombre de réalisations. Avec une série $\{P_{dev}(n)\}$ de N échantillons obtenus par simulation, le critère MAD est estimé par :

$$\|\hat{P}_{dev}\|_1 = \frac{1}{N} \sum_{n=1}^N |P_{dev}(n)| \quad (4.2)$$

Plutôt que de présenter ce critère d'écart tel quel, nous préférons rendre plus lisible le rôle améliorateur du stockage en normalisant $\|P_{dev}\|_1$ par $\|P_{dev}\|_1^0$, sa valeur en l'absence de stockage. Ce facteur se calcule facilement, car en l'absence de stockage, l'écart P_{dev} est égal à l'erreur de prévision P_{mis} qui est un processus gaussien :

$$\|P_{dev}\|_1^0 = \mathbb{E}[|P_{mis}|] = \sqrt{\frac{2}{\pi}} \sigma_P \approx 0.80 \sigma_P \quad (4.3)$$

où le facteur $\sqrt{\frac{2}{\pi}}$ est le rapport naturel entre la norme 1 et l'écart-type (i.e. norme 2) d'une variable aléatoire gaussienne. Ainsi, le critère d'écart normalisé $\|P_{dev}\|_1^{\text{norm}}$ est défini par :

$$\|P_{dev}\|_1^{\text{norm}} = \frac{\|P_{dev}\|_1}{\sqrt{2/\pi} \sigma_P} \quad (4.4)$$




FIGURE 4.2 – Évaluation statistique de la performance par simulation temporelle : convergence vers un état stationnaire (oubli de l'état initial) et effet du nombre de trajectoires.
 GRAPHES 1 ET 2 : 100 réalisations aléatoires indépendantes, partant du même $SoE(0) = 0,5$. Une trajectoire est surlignée, la même que celle de la figure 4.1a.
 GRAPHES 3 : Évolution du critère MAD avec la durée de la simulation. L'estimation est d'autant plus précise qu'un grand nombre N de trajectoires est utilisé.

de sorte que, par exemple, une valeur $\|P_{dev}\|_1^{norm} = 0.5$ signifie que le stockage a permis de réduire l'effet de l'erreur de prévision d'un facteur 2.

Méthode d'estimation statistique Le calcul d'un critère de performance sur des échantillons générés par simulation stochastique demande quelques précautions que nous souhaitons préciser. Pour illustrer cette discussion, nous nous servons de la figure 4.2. Nous y avons tracé la même simulation temporelle qu'à la figure 4.1a ($E_{rated} = 15$ MWh, $\sigma_P = 1$ MW, $\phi = 0$), mais en la rejouant 100 fois avec un tirage aléatoire différent de l'entrée P_{mis} . Cela permet d'observer le comportement global des trajectoires. Le dernier graphe montre la valeur du critère d'écart moyen (4.2) calculé en faisant une moyenne sur l'ensemble des N trajectoires. Cette moyenne est calculée à chaque pas de la simulation, créant ainsi cette courbe temporelle. Par ailleurs, nous représentons cette moyenne pour plusieurs valeurs de N .

Première observation : l'estimation du critère est *bruitée*. Les fluctuations aléatoires du critère sont très visibles lorsque $N = 10^3$ trajectoires sont utilisées, moins pour $N = 10^4$ et presque plus pour $N = 10^6$. C'est la *loi des grands nombres* qui permet cette réduction de la variance du critère estimé lorsque N augmente. Il est important d'avoir une variance faible, surtout pour les grandes capacités de stockage pour lesquelles l'écart $\|P_{dev}\|_1^{norm}$ est petit (problème de rapport signal sur

bruit). Ainsi, N doit être choisi "assez grand" et dans les études qui suivent nous utilisons un nombre de trajectoires N entre 10^5 et 10^7 .

Point important, pour que la loi des grands nombres s'applique efficacement, il faut que les N échantillons $P_{dev}(n)$ à moyenner (4.2) soient *statistiquement indépendants*. Cela signifie qu'il n'est pas bon de prendre N observations successives sur une trajectoire $P_{dev}(k)$, car elles ne sont clairement pas indépendantes. C'est pour cette raison que nous choisissons la simulation vectorisée pour calculer N trajectoires indépendantes en parallèle. Comme les tirages aléatoires qui génèrent ces trajectoires sont indépendants², les N échantillons $P_{dev}(n)$ sont bien indépendants entre eux.

Deuxième observation : l'effet de l'état initial. Toutes les simulations partent d'un état d'énergie $SoE(0)$ égal $1/2$ et l'on peut observer qu'il faut *un certain temps* avant que cet état initial soit "oublié", c'est-à-dire qu'il n'ait plus d'influence sur toutes les statistiques que l'on peut vouloir calculer. Dans le vocabulaire des simulations Monte-Carlo Markov Chains (MCMC), on parle de *convergence* de la simulation lorsque l'état stationnaire est atteint. Notons que connaître le nombre de pas de temps nécessaire pour arriver à un état stationnaire est un sujet d'étude en soi [22].

Pour nos simulations de stockage, il faut noter que ce temps de convergence est d'autant plus grand que la capacité de stockage est grande (pour une amplitude d'entrée σ_P donnée) et il est donc souhaitable d'avoir une règle pour ajuster automatiquement la longueur K d'une simulation. À cet effet, nous avons utilisé une règle empirique qui s'inspire des propriétés de diffusion des marches aléatoires. En effet, l'énergie stockée $E_{sto}(k)$ se comporte, en l'absence de saturation, comme une marche aléatoire dont les incréments ont une variance égale à $(\sigma_P \Delta_t)^2$. L'écart-type de cette marche aléatoire après K instants est donc $\sigma_P \Delta_t \sqrt{K}$ et nous prenons K suffisamment grand pour que cet écart-type de l'énergie stockée atteigne la valeur de la capacité E_{rated} .

C'est ainsi que nous choisissons K égal à la partie entière de $(E_{rated}/(\sigma_P \Delta_t))^2$, valeur qui augmente, malheureusement, *quadratiquement* avec la capacité. Dans le cas de la figure 4.2, avec $E_{rated} = 15\sigma_P \Delta_t$, on a donc $K = 225$ (soit 9 jours en temps simulé, car $\Delta_t = 1$ h) qui apparaît bien comme suffisant, car on observe clairement que la statistique d'écart se stabilise au bout de 4 jours environ. Pour les simulations qui sont l'objet de cette section (cf. figure 4.3 et explications ci-après), la plus grande capacité est $300\sigma_P \Delta_t$, ce qui nécessite $300^2 \approx 10^5$ pas de temps. Par ailleurs, nos études empiriques montrent que cette règle de choix de K permet bien d'atteindre un état stationnaire.

Étude paramétrique Nous avons calculé le critère d'écart $\|P_{dev}\|_1^{\text{norm}}$ sur une large plage de capacité de stockage E_{rated} pour faire le lien entre le dimensionnement et la performance du système. Nous avons également fait varier le coefficient d'autocorrélation ϕ pour mettre en évidence son effet sur le besoin en capacité de stockage.

Pour le choix de l'amplitude de l'erreur de prévision σ_P , il faut remarquer qu'elle n'est finalement qu'un facteur d'échelle : seule compte la valeur *relative* de la capacité E_{rated} par rapport à σ_P . Ainsi, nous exprimons nos résultats en terme de *capacité normalisée* de stockage, qui est la grandeur adimensionnelle suivante :

$$E_{rated}^{\text{norm}} = \frac{E_{rated}}{\sigma_P \cdot \Delta_t} \quad (4.5)$$

et donc, sans perte de généralité, nous pouvons prendre σ_P égal à 1 MW.

2. En fait, les tirages sont issus d'un générateur de nombres *pseudo*-aléatoires, qui est, dans numpy (idem Matlab), le "Mersenne Twister"[72], très largement utilisé pour les simulations Monte-Carlo.




FIGURE 4.3 – Abaque pour déterminer la capacité de stockage en fonction de l'écart à l'engagement souhaité (en moyenne valeur absolue), pour plusieurs valeurs du coefficient d'autocorrélation ϕ [52]. Exemple d'application surligné.

Pour finir, nous avons choisi l'espace paramétrique suivant :

- 30 points pour E_{rated}^{norm} , espacés logarithmiquement entre 1 et 300,
- 10 points entre 0,0 et 0,9 pour le coefficient ϕ

et pour chacune des 30×10 paires de paramètres (E_{rated}^{norm}, ϕ) , nous avons estimé le critère d'écart $\|P_{dev}\|_1^{norm}$ en suivant la méthode décrite au paragraphe précédent (avec $N = 10^5$ trajectoires). Pour la plus grande capacité de stockage, chaque estimation nécessite la simulation de $N \times K_{max} \approx 10^{10}$ instants, ce qui dure 10 minutes environ. Cependant, le calcul sur l'ensemble des 300 points de la grille des paramètres ne dure que quelques heures (au lieu de $300 \times 10' = 50$ h) grâce à la parallélisation³ et l'ajustement automatique de la longueur de simulation K .

Les résultats de nos simulations sont présentés figure 4.3. La statistique d'écart est représentées par un ensemble de courbes, une pour chaque valeur du paramètre ϕ . Le deuxième paramètre, E_{rated}^{norm} , est placé sur l'axe vertical alors que le résultat du calcul, l'estimation de $\|P_{dev}\|_1^{norm}$, est placée en abscisse. Cette disposition non usuelle permet de lire les courbes comme un *abaque de pré-dimensionnement* (détaillé au prochain paragraphe) qui répond à la question : pour un niveau de performance souhaité, quelle capacité est nécessaire ?

L'observation du réseau de courbes montre à quel point l'augmentation de l'autocorrélation fait augmenter le besoin en capacité de stockage (échelle log pour E_{rated}^{norm}). La courbe pour $\phi = 0,80$ est surlignée en rouge, car elle correspond à la valeur estimée sur des données de terrain (ferme de Grand Maison §2.3.2).

Outil de pré-dimensionnement Nous illustrons la lecture de la figure 4.3 comme outil de dimensionnement préliminaire avec l'exemple de la ferme de Grand Maison (cf. annexe A.1). Par préliminaire, nous voulons signifier que ces résultats ne tiennent pas compte de plusieurs aspects

3. parallélisation avec la méthode `Pool.map()` du module `multiprocessing` qui fait partie de la bibliothèque standard de Python. Elle est bien adaptée pour calculer la valeur d'une fonction sur une grille de paramètres.

importants du problème, dont les pertes, le vieillissement et qu'il n'y a pas d'optimisation de la stratégie d'engagement de production de la veille pour le lendemain.

Pour la ferme de Grand Maison, l'erreur de prévision en moyenne valeur absolue est de 12,7 % de la puissance nominale du parc ($\sigma_P = 0,16P_{nom}$, cf. 2.3.1). Imaginons alors qu'un règlement novateur impose d'abaisser cette valeur à 5 %, à l'aide d'un stockage. Il s'agit d'une réduction de 39 % de l'erreur de prévision, c'est-à-dire un objectif de $\|P_{dev}\|_1^{norm} = 0,39$. En lisant, sur la figure 4.3, la courbe $\phi = 0,8$, cette amélioration de la performance nécessite une capacité normalisée de 15. Ainsi, on obtient $E_{rated} = 15\sigma_P\Delta_t = 3,3$ MWh.

C'est une capacité importante pour une ferme 1,4 MW. Si cependant, l'autocorrélation des erreurs de prévision n'avait pas été prise en compte, revenant à supposer, à tort, que $\phi = 0$, la capacité nécessaire n'aurait été que $E_{rated} = 2\sigma_P\Delta_t = 0,44$ MWh, une sous-estimation d'un facteur 7 ! Pour finir, la courbe $\phi = 0,8$ permet de voir qu'avec un tel sous-dimensionnement, la performance obtenue est nettement moins bonne que souhaité, avec $\|P_{dev}\|_1^{norm} = 0,78$, (deux fois plus que l'objectif initial).

Cet exemple illustre donc bien l'importance de la prise en compte de l'autocorrélation des erreurs de prévision de production pour le dimensionnement (et nous avons vu partie 3.3.2 qu'elle peut aussi influencer sur la loi de gestion).

Pour finir, notons que dans l'article [52], nous discutons de la validation de ces résultats vis-à-vis de données de terrains grâce à la méthode du bootstrap paramétrique de Tsay [96]. De ce travail de validation ressortent deux faits. Tout d'abord, la simulation stochastique avec un modèle AR(1) et la simulation avec des données de terrains donnent bien des résultats statistiquement compatibles. Par contre, cela met aussi en évidence qu'il faut de longues séries temporelles pour obtenir une estimation suffisamment précise. Il est donc souhaitable d'utiliser *plusieurs années* de données de production-prévision.

4.2.2 Dimensionnement économique, sans tolérance d'écart


La partie précédente a traité du dimensionnement avec l'approche "contrainte sur un critère de performance". À présent, nous nous intéressons à l'optimisation économique. Pour ce faire, nous devons attribuer un coût aux différents aspects du problème :

- la capacité de stockage initialement installée,
- les éventuels remplacements du stockage à cause du vieillissement,
- les pertes énergétiques, qui entraînent un manque à gagner sur la vente d'électricité, et
- les écarts à l'engagement de production $J+1$, qui sont pénalisés.


Observons que plusieurs de ces phénomènes, en particulier les pertes, ainsi que les paramètres de prix (détaillés après), *dépendent fortement de la technologie* de stockage choisie. Par conséquent, nous nous concentrons à présent sur une technologie, la batterie Sodium-Soufre NGK dont le modèle a été présenté partie 2.1.3. Les résultats qui suivent ont été présentés à la conférence PowerTech 2013 [53]. Point important, rappelons que le dimensionnement de cette technologie se fait par le seul choix de la capacité énergétique E_{rated} . En effet, la puissance nominale lui est proportionnelle : $P_{rated} = E_{rated}/7,2$ h.

Avant de calculer les coûts proprement dits, il est nécessaire de calculer les différents critères qui interviennent dans la fonction coût. Nous procédons donc à des simulations comme dans la partie précédente, mais en utilisant cette fois le modèle de batterie NaS. La loi de gestion de l'énergie est, comme précédemment, la compensation totale des erreurs de prévision : " $P_{sto} = P_{mis}$, tant que possible".

4.2 Garantie d'un engagement de production J+1



(a) $E_{rated} = 5 \text{ MWh}$



(b) $E_{rated} = 15 \text{ MWh}$

FIGURE 4.4 – Simulation stochastique avec le modèle de batterie NaS, la sollicitation d'entrée AR(1) d'écart-type $\sigma_P = 1 \text{ MW}$ et $\phi = 0,8$ et loi de gestion empirique " $P_{sto} = P_{mis}$ " [53].

Analyse qualitative des simulations Suivant la même structure qu'à la partie 4.2.1, nous commençons par analyser qualitativement des trajectoires de simulation. Figure 4.4, une simulation d'une semaine a été conduite pour deux capacités différentes, 5 et 15 MWh. La sollicitation d'entrée P_{mis} (notée P_{sto}^* sur la figure) est un modèle AR(1) d'écart-type $\sigma_P = 1$ MW et $\phi = 0,8$. Nous utilisons la même présentation des trajectoires en 3 panneaux qu'à la figure 4.1b, sauf qu'un 4^{ème} graphe présente les pertes (absentes du modèle de stockage idéal). Ces pertes sont représentées par 2 termes :

- P_{heat} compte la puissance électrique consommée pour le chauffage des modules NaS pour les maintenir à température (cf. équation thermique (2.15)).
- P_{losses} regroupe les pertes du système de stockage proprement dit, à savoir celles de l'onduleur ainsi que les pertes Joule représentées par la résistance interne.

Observons que les pertes du stockage P_{losses} sont corrélées positivement à la puissance absorbée P_{sto} (en valeur absolue), alors que les pertes de chauffage sont corrélées négativement. En effet, comme les pertes Joule contribuent au chauffage de la batterie, P_{heat} est faible lorsque P_{losses} est grand, et inversement. Enfin, observons, en comparant la figure 4.4b à la 4.4a, que la consommation de chauffage est nettement plus grande avec la batterie de 15 MWh qu'avec la plus petite de 5.

Avec la plus grande batterie, les écarts à l'engagement sont, comme attendu, moins grands. La raison est pour partie la plus grande capacité énergétique, mais aussi la plus grande puissance maximale. Par exemple figure 4.4a, sur la plage $t=0,5-1,5$ j, la limitation de P_{sto} à 0,6 MW est particulièrement visible.

Analyse quantitative Pour le calcul du coût économique, nous calculons plusieurs critères de performance à l'aide de simulations stochastiques. Comme pour la partie 4.2.1, il s'agit de calculer des moyennes sur des trajectoires. Pour alléger les équations qui suivent nous utilisons la notation \bar{X} au lieu de $\mathbb{E}[X]$ pour symboliser l'espérance d'une variable aléatoire X .

Figure 4.5, nous représentons les critères de performance pour 100 valeurs de capacité réparties entre 1 et 50 MWh. Pour chaque capacité, nous avons simulé $N = 10^3$ trajectoires indépendantes d'une durée de 30 jours. Nous utilisons moins de trajectoires qu'à la partie précédente ($N = 10^5$), car nous exploitons tous les points de la trajectoire. Sur ces trajectoires, nous calculons les critères suivants :

- l'écart à l'engagement en moyenne valeur absolue (MAD) $\overline{|P_{dev}|}$, graphe 1 en rouge
- les pertes électriques moyennes \bar{P}_{losses} et la consommation moyenne du chauffage \bar{P}_{heat} , graphe 2.
- le vieillissement en cyclage moyen, compté en nombre de cycles pleins équivalents, graphe 3.

Nous avons estimé les espérances en deux temps : chaque variable est d'abord moyennée sur l'axe temporel, pour chacune des N trajectoires séparément, puis ces N moyennes temporelles de trajectoire sont moyennées entre elles. Ces moyennes globales sont représentées par des lignes sur la figure 4.5. Les intervalles colorés représentent l'écart-type entre les moyennes temporelles de chaque trajectoire. Comme nous avons utilisé des trajectoires de 30 jours, ces intervalles représentent donc la *variabilité inter mensuelle*. Cette variabilité est assez grande pour le critère d'écart MAD, et plus basse pour les pertes.

Pour commencer, la figure 4.5 confirme que plus la capacité de stockage est grande, plus l'écart à l'engagement moyen (MAD) est faible. Néanmoins, cette décroissance diminue avec les grandes capacités⁴. Lorsque la capacité de stockage augmente, nous observons également que

4. comme avec la "loi des rendements décroissants" en économie

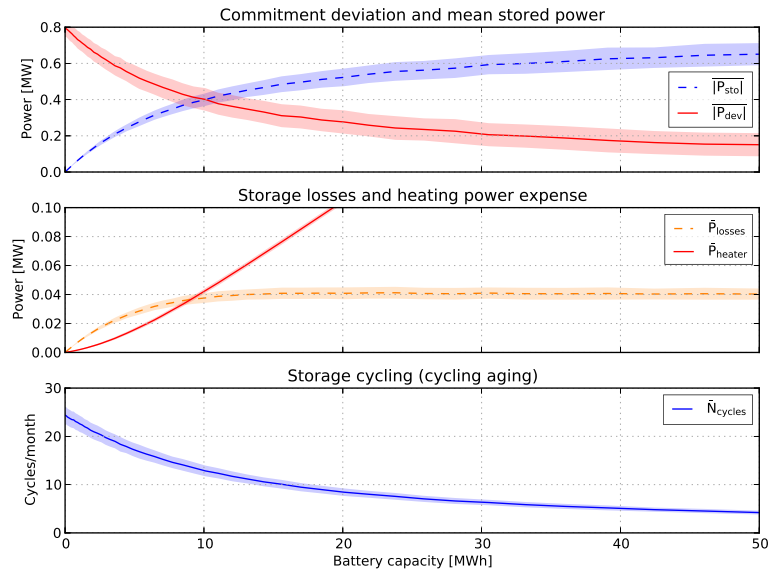


FIGURE 4.5 – Analyse paramétrique de la performance du système de stockage NaS, fonction de sa capacité (rapport $E/P = 7,2$ h) [53]. Sollicitation d'entrée AR(1) d'écart-type $\sigma_P = 1$ MW et $\phi = 0,8$.

les pertes du système de stockage plafonnent, sans doute à cause du modèle à rendement fixe de l'onduleur. Par contre, les pertes de chauffage augmentent linéairement (sauf entre 0 et 5 MWh où les pertes Joule aident significativement au chauffage) et deviennent vite prépondérantes au-delà de 10 MWh. Pour finir, le vieillissement en cyclage (compté en nombre de cycles pleins sur 30 jours, vu la longueur des simulations) diminue avec la capacité. Dans tous les cas, ce cyclage par mois est inférieur à la limite autorisée par la technologie NaS : le constructeur garantit en effet 5000 cycles sur les 15 ans de durée de vie du système, soit $5000/(15 \times 12) = 27,8$ cycles/mois.

Dans une perspective de dimensionnement, la figure 4.5 montre qu'il faut bien sûr une batterie suffisamment grande pour réduire les écarts à l'engagement, mais pas *trop grande*, à cause de l'augmentation des pertes de chauffage. Pour procéder au dimensionnement basé sur un optimum économique, nous procédons à présent à la pondération monétaire des différents critères que nous venons de calculer.

Modélisation et optimisation du coût Pour donner un poids économique aux différents critères “physiques” calculés, nous utilisons plusieurs paramètres, 2 pour quantifier le vieillissement, et 3 paramètres de prix :

- durée de vie calendaire : $t_{life} = 15$ ans (garantie du constructeur NGK)
- durée de vie en cyclage : $N_{life} = 5000$ cycles pleins équivalents (garantie du constructeur NGK)
- prix unitaire énergétique d'une batterie NaS : $c_{batt} = 280$ k€/MWh⁵ (fourchette large pour les technologies électrochimiques : 150–1500 k€/MWh)
- prix de vente de l'électricité du système éolien-stockage : $c_{elec} = 150$ €/MWh, qui pénalisent les pertes (fourchette de prix économiquement réaliste : 100–200 €/MWh).

5. ce prix unitaire correspond à un prix de 2 M€ pour la batterie NaS de 7,2 MWh installée à La Réunion. En réalité, les complexités réglementaires (installation classée ICPE) et les contraintes de génie civil ont porté ce coût à 3 M€, mais nous supposons ici que l'expérience fera baisser ce coût.

4 Dimensionnement d'un stockage d'énergie

- prix des pénalités des écarts à l'engagement : $c_{dev} = 150 \text{ €/MWh}$, pour un écart à l'engagement compté en moyenne valeur absolue (MAD).

Pour dimensionner le système sur cycle de vie, nous calculons les coûts de façon actualisée, c'est-à-dire répartis sur une durée d'usage⁶. Nous notons C_{sto} le coût total du système de stockage, calculé sur une durée t , où sont additionnés l'investissement et l'usure du stockage ainsi que le coût des pertes :

$$C_{sto}(t) = c_{batt} E_{rated} \left(\frac{\bar{N}_{cycles}(t)}{N_{life}} + \frac{t}{t_{life}} \right) + c_{elec} (\bar{P}_{losses} + \bar{P}_{heat}) t \quad (4.6)$$

Le coût du stockage prend en compte à la fois le coût actualisé du cyclage, grâce au terme $\bar{N}_{cycles}(t)/N_{life}$ (égal à l'état de vieillissement en cyclage), et le coût calendaire, grâce au terme t/t_{life} (qui comprend également l'investissement initial). Le coût stockage ($c_{batt} E_{rated}$) est donc compté au prorata de son usure. Les pertes sont simplement comptées sur la base de l'énergie moyenne perdue sur la durée t .

À ce coût du système de stockage, nous ajoutons C_{dev} , le coût des pénalités :

$$C_{dev}(t) = c_{dev} \overline{|P_{dev}|} t \quad (4.7)$$

pour arriver au coût total à minimiser :

$$C_{tot}(t) = C_{sto}(t) + C_{dev}(t) \quad (4.8)$$

Ces différents coûts, s'exprimant en €, sont calculés sur une durée t arbitraire. Nous souhaitons les rendre plus lisibles en les divisant par la production éolienne attendue sur cette durée, ce qui permet d'obtenir des "€/MWh d'énergie produite" :

$$\tilde{C}_{sto} = \frac{C_{sto}(t)}{\bar{P}_{prod} t}, \quad \tilde{C}_{dev} = \frac{C_{dev}(t)}{\bar{P}_{prod} t}, \quad \tilde{C}_{tot} = \frac{C_{tot}(t)}{\bar{P}_{prod} t} \quad (4.9)$$

sachant qu'en supposant un facteur de charge de 20 % pour notre ferme de 10 MW (i.e. 1750 h/an équivalent pleine puissance), nous obtenons une production moyenne $\bar{P}_{prod} = 2 \text{ MW}$. Finalement, le coût total mis à l'échelle est :

$$\tilde{C}_{tot} = \frac{1}{\bar{P}_{prod}} \left(c_{batt} \left(\frac{\overline{|P_{sto}|}}{2N_{life}} + \frac{E_{rated}}{t_{life}} \right) + c_{elec} (\bar{P}_{losses} + \bar{P}_{heat}) + c_{dev} \overline{|P_{dev}|} \right) \quad (4.10)$$

Les différents termes du coût du stockage (4.6), mis à l'échelle comme (4.9), sont représentés dans la partie haute de la figure 4.6. Tous croissent avec la capacité, mais certains présentent une asymptote horizontale (pertes et vieillissement en cyclage). Nous relevons que sur la plage 0–10 MWh, les deux coûts les plus importants sont l'usure calendaire et en cyclage. Au-delà de 20 MWh, le chauffage dépasse le cyclage. Cela confirme l'importance, pour la technologie NaS, d'une bonne modélisation thermique.

Sur la partie basse de la figure 4.6, nous observons que, pour de faibles capacités, les pénalités d'écarts \tilde{C}_{dev} décroissent plus vite que ne croit le coût du stockage \tilde{C}_{sto} . Par conséquent, le coût total \tilde{C}_{tot} présente un minimum à 51 €/MWh, atteint pour une capacité optimale $E_{rated}^* = 8,5 \text{ MWh}$. Ce coût optimal se répartit en 32 € de pénalité et 19 € de coût de stockage. Avec

6. mais sans prise en compte de l'inflation, de taux d'intérêt d'emprunt ou autres paramètres financiers dont la discussion sort du cadre de nos travaux.




FIGURE 4.6 – Analyse paramétrique des coûts, fonction du dimensionnement. Ligne traitillée : sensibilité du coût total à une variation de $\pm 30\%$ du prix des pénalités [53]. Sollicitation d'entrée AR(1) d'écart-type $\sigma_P = 1$ MW et $\phi = 0,8$.

4 Dimensionnement d'un stockage d'énergie

ce dimensionnement, l'écart moyen à l'engagement $|\overline{P_{dev}}|$ est réduit de près de 50 % par rapport à la situation sans stockage, ce qui est une amélioration significative mais pas extraordinaire.

Pour finir, soulignons que, même avec ces coûts de stockage et de pénalités relativement élevés, l'opérateur du système éolien-stockage garde un revenu important. En effet, le revenu résiduel de la vente d'électricité est $c_{elec} - \tilde{C}_{tot} \approx 100 \text{ €/MWh}$, ce qui est bien de l'ordre de grandeur du tarif éolien sans stockage.

Sensibilité au coût des pénalités Nous avons fait varier le prix des pénalités c_{dev} de $\pm 30 \%$, car en l'absence de règle universellement établie, notre choix de 150 €/MWh est teinté d'arbitraire. Le coût total réévalué avec cette variation est tracé en ligne traitillée figure 4.6. Nous observons que la réduction des pénalités fait fortement baisser la capacité optimale. En allant plus loin dans la variation, nous constatons qu'en dessous de $c_{dev} = 70 \text{ €/MWh}$, la capacité optimale est de 0 MWh : il n'y a plus d'intérêt économique à acheter un stockage, et toute l'erreur de prévision est reportée sur le réseau.

Cette étude de sensibilité permet d'identifier une plage de prix de pénalisation qui mène à une réduction "raisonnable" de l'écart à l'engagement. Dans le cadre de nos hypothèses de modélisation et de prix, cette plage se situe autour de 100 à 200 €/MWh . Il serait intéressant de la comparer aux coûts induits sur le réseau par les erreurs de prévision (coûts de combustible, de démarrage de turbines à combustion, ...), mais ce calcul est difficile (simulation du réseau complet de l'île sur une longue période).

Pistes d'amélioration de l'étude Cette étude par simulation est dépendante de plusieurs hypothèses dont certaines peuvent sans doute influencer les résultats et mériteraient donc d'être explorées.

Une première piste d'amélioration serait de travailler avec des données d'erreur de prévision qui soient non pas simulées (modèle AR(1)), mais issues d'un système de prévision opérationnel. Rappelons que pour obtenir des résultats de bonne précision, il faut des séries temporelles longues (quelques années complètes).

Deuxième point, nos simulations ont été faites au pas de temps d'une heure, ce qui masque l'effet des fluctuations "infra pas de temps", dont nous avons vu qu'elles sont importantes. Nous soupçonnons que la non-prise en compte de ces fluctuations entraîne une sous-estimation à la fois des pertes et du vieillissement. Pour ce type d'étude, des données de production à haute fréquence, telles qu'enregistrées pour le projet Pégase (cf. annexe A.2), sont précieuses.

Par ailleurs, la modélisation des pertes du système pourrait être améliorée par l'utilisation d'un modèle plus fin des pertes du convertisseur électronique de puissance (le fabricant NGK ne fournit que l'information simpliste d'un rendement de 95%). Cela est vrai en particulier pour les grandes capacités de stockage, pour lesquelles les pertes Joule deviennent petites par rapport à celles de l'onduleur.

Pour finir, nous n'avons pas pris en compte dans nos simulations la dégradation des caractéristiques de la batterie avec le vieillissement. Pour des raisons de temps de calcul, nous avons simulé 30 jours puis directement extrapolé les résultats à 15 ans. Pour prendre en compte la dégradation avec un temps de calcul raisonnable, il faudrait peut-être répéter ces simulations à différents états de vieillissement. Il doit être ensuite possible d'interpoler les résultats sur la vie du système en utilisant le taux de vieillissement moyen.

4.2.3 Dimensionnement avec tolérance d'écart

Pour terminer cette partie 4.2 sur le dimensionnement d'un stockage pour la garantie d'un engagement de production J+1, nous abordons la prise en compte d'une *tolérance* P_{tol} sur l'écart à l'engagement P_{dev} . Comme nous allons le voir, la valeur de ce nouveau paramètre va influencer le dimensionnement. Par conséquent, notre étude porte non seulement sur le choix de la capacité de stockage E_{rated} , mais également sur ce *choix de la tolérance d'écart* P_{tol} .

Comme dans les parties précédentes, nous gardons un modèle AR(1) pour la sollicitation d'entrée du système qu'est l'erreur de prévision P_{mis} . Rappelons que le pas de temps est $\Delta_t = 1$ h, l'écart-type $\sigma_P = 1$ MW et la corrélation entre deux instants consécutifs $\phi = 0,8$.

Par contre, à l'inverse des parties précédentes, nous n'utilisons plus la loi de gestion simple " $P_{sto} = P_{mis}$ ". En effet, nous avons vu au chapitre précédent (§3.3) que l'introduction d'une tolérance dans la fonction de pénalisation donne des lois de gestion optimales nettement différentes des cas sans tolérance (§3.3.1). Nous avons vu également une expression paramétrique simple de la loi de gestion avec tolérance, inspirée par les résultats d'optimisation dynamique (§3.3.3). Nous utilisons donc cette gestion paramétrique optimale. Rappelons qu'elle vise à réaliser un écart cible, adapté à la puissance d'écart toléré P_{tol} :

$$P_{dev}^{\oplus} = f_{sat}^{P_{tol}} \left(\frac{1}{\Delta_t} (E_{sto} - E_{rated}/2 + \tau P_{mis}) \right) \quad (\text{rappel 3.22})$$

Rappelons également que le paramètre τ règle "l'horizon temporel énergétique" relatif à la valeur courante de l'erreur de prévision P_{mis} . Notre discussion sur cette gestion paramétrique (§3.3.3) nous amènerait à fixer $\tau = 5$ h, mais des études de performance en simulation semblent indiquer que la plage 3–5 h donne des résultats très proches, et satisfaisants, du point de vue du respect de la tolérance. Le réglage fin du paramètre τ ne semble donc pas nécessaire.

Le critère de performance que nous voulons étudier est le *taux d'écart à l'engagement hors tolérance*. Pour le définir, nous introduisons la variable *indicatrice* de cet écart :

$$I_{tol} = \begin{cases} 1 & \text{si } |P_{dev}| > P_{tol}, \\ 0 & \text{sinon} \end{cases} \quad (4.11)$$

et c'est l'espérance de cette variable, notée \bar{I}_{tol} , qui nous donne le taux d'écart :

$$\bar{I}_{tol} = \mathbb{E}[|P_{dev}| > P_{tol}] \quad (4.12)$$

Effet de la loi de gestion Avant l'étude paramétrique, voici quelques valeurs de ce taux de non-respect, pour un stockage de 10 MWh et une tolérance de 1 MW, dans différents cas :

sans stockage	sans tolérance	non proactive	paramétrique optimale
32 %	17 %	11 %	4 %

TABLE 4.1 – Taux d'écart à l'engagement hors tolérance, selon la loi de gestion utilisée

et pour bien interpréter ces chiffres, voici quelques éléments de comparaison :

- un écart par jour : $1/24 \approx 4,2$ %
- un écart par semaine : $1/24/7 \approx 0,60$ %
- un écart par mois : $1/24/30 \approx 0,14$ %

4 Dimensionnement d'un stockage d'énergie

Dans le tableau 4.1, la première colonne donne, à titre de comparaison, le taux d'écart en l'absence de stockage (ou bien stockage inactif), c'est-à-dire que $P_{sto} = 0$ et donc $P_{dev} = P_{mis}$. Les trois autres colonnes correspondent à l'utilisation du stockage avec différentes lois de gestion :

1. la gestion **sans tolérance** correspond au contrôle simpliste qui vise à réaliser $P_{sto} = P_{mis}$, (i.e. un écart $P_{dev} = 0$) tant que le stockage n'est pas saturé. Cette gestion est certes optimale pour une pénalisation linéaire *sans* tolérance, mais nous constatons ici clairement qu'elle est très mauvaise pour gérer la tolérance.
2. la gestion **non proactive** correspond à un simple écrêtage des écarts hors tolérance : $P_{dev}^{\oplus} = f_{sat}^{P_{tol}}(P_{mis})$. Cette gestion qui profite en effet de la plage d'écart toléré améliore bien la performance par rapport à la gestion sans tolérance. Cependant, elle ne tient pas compte de l'état d'énergie du stockage, d'où la dénomination "non proactive", et la performance est donc nettement sous-optimale.
3. la gestion **paramétrique optimale** correspond à l'équation (3.22), avec un réglage adapté de la saturation et de la constante de temps τ . Le respect de la tolérance est très nettement amélioré.

Au vu des résultats du tableau 4.1, il y a donc un intérêt fort à utiliser une gestion optimisée. Comme la capacité E_{rated} intervient *explicitement* dans l'équation (3.22) qui définit la loi de gestion, il n'y a pas besoin de calculs compliqués pour adapter ce contrôle à chaque dimensionnement. Cette loi de gestion optimale est donc très bien adaptée à une étude de dimensionnement et c'est elle que nous choisissons pour l'étude qui suit.

Étude paramétrique Nous calculons le critère de performance \bar{I}_{tol} sur une large grille de valeurs des deux paramètres du problème :

- capacité de stockage E_{rated} : 31 points entre 1 et 50 MWh (répartition logarithmique)
- tolérance d'écart P_{tol} : 21 points entre 0 et 2 MW (répartition linéaire)

soit un total de 651 points (E_{rated}, P_{tol}). Ces valeurs sont choisies relativement à l'écart-type de la sollicitation d'entrée $\sigma_P = 1$ MW, c'est-à-dire que pour une amplitude d'entrée différente, les résultats qui suivent sont utilisables par simple mise à l'échelle de E_{rated} et P_{tol} .

Comme pour les parties précédentes, l'évaluation du critère de performance se fait par *simulation temporelle* avec le module StorageSim (§2.5) et une entrée stochastique. Pour que la simulation converge vers un état stationnaire, indépendant de l'état de charge initial, nous utilisons 200 pas de temps (i.e. 200 heures). Avec $N = 10^5$ trajectoires, chaque simulation dure environ 2,5 s (sur un PC de 2011, avec processeur Xeon). Avec la parallélisation des calculs, la simulation pour l'ensemble des 651 points de grille dure environ 8 minutes (au lieu de 30) grâce à l'exploitation du processeur multi-cœur (Xeon 6 cœurs).

La figure 4.7 présente la cartographie du critère de performance \bar{I}_{tol} sous forme de lignes de niveau. Nous observons, sans surprise, que la tolérance d'engagement est mieux respectée lorsque la capacité est grande ou lorsque la tolérance est large (coin haut droit). Inversement, une faible capacité, ou bien une tolérance très stricte (coin bas gauche) amènent nécessairement à un moins bon taux de respect.

Ces lignes de niveau permettent aussi d'exprimer le *compromis* qui existe entre les trois grandeurs tolérance, capacité et taux d'écart. Par exemple, pour respecter la tolérance 99 % du temps ⁷

7. Un taux d'écart de 1 % équivaut, à une heure hors tolérance tous les 4 jours, *en moyenne*. Cependant, remarquons bien que ces taux moyens ne disent rien de la *répartition temporelle* de ces écarts : 2 heures successives tous les 8 jours sont comptées identiquement à 1 heure tous les 4 jours.




FIGURE 4.7 – Cartographie de l'écart à l'engagement hors tolérance. Sollicitation d'entrée AR(1) d'écart-type $\sigma_P = 1$ MW et $\phi = 0,8$.

(ligne verte), on peut choisir une tolérance laxiste de 2 MW et un petit stockage d'un peu plus de 1 MWh. Autre possibilité, ce même taux d'écart peut être atteint avec une tolérance plus stricte de 1 MW, mais cela nécessite une capacité nettement plus grande de 20 MWh.

Cette cartographie exprime donc les différents compromis accessibles dans la limite du *physiquement possible* (au sens où c'est une loi de gestion optimale qui est employée). À cette étude purement technique, nous ajoutons à présent une dimension *économique*. Pour cela, nous devons attribuer une pénalité au taux d'écart que nous venons de calculer.

Étude économique Suivant la même démarche qu'à la partie 4.2.2 pour la batterie NaS, nous utilisons une fonction coût qui pénalise à la fois les écarts et la capacité de stockage. Cependant, la fonction coût est ici plus simple, car nous ne nous focalisons pas sur une technologie de stockage particulière. Si le vieillissement en cyclage n'est pas pris en compte, en revanche le coût est calculé sur la durée de vie t_{life} du stockage pour prendre en compte le vieillissement calendaire. Les deux termes de coût sont :

- le coût C_{sto} du stockage, qui est simplement égal à son coût d'investissement $c_{batt} \cdot E_{rated}$
- les pénalités d'écart C_{dev} , pour lesquelles chaque écart hors tolérance est supposé pénalisé *en proportion de la production éolienne moyenne* sur la plage de temps considérée (cf. explication plus bas). Ce coût des écarts, sur la durée de vie, s'exprime donc par :

$$C_{dev} = c_{dev} \bar{P}_{prod} t_{life} \bar{I}_{tol} \quad (4.13)$$

4 Dimensionnement d'un stockage d'énergie

Au total, nous avons pour fonction coût :

$$C_{tot} = C_{sto} + C_{dev} = c_{batt} \cdot E_{rated} + c_{dev} \bar{P}_{prod} \bar{I}_{tol} \quad (4.14)$$

et ce coût est divisé par l'énergie produite sur la vie pour obtenir des "€/MWh" :

$$\tilde{C}_{tot} = \frac{c_{batt} \cdot E_{rated}}{\bar{P}_{prod} \bar{I}_{tol}} + c_{dev} \bar{I}_{tol} \quad (4.15)$$

Cette fonction coût, à comparer à (4.10), mime le critère de pénalisation de l'appel d'offres (AO) éolien-stockage de la CRE [28, §6.2] :

"la production durant la période de 10 minutes pendant laquelle [un] écart survient est rémunérée à 50 % du tarif [de rachat]" (§6.2 Garantie de la production électrique)

De ce règlement, nous déduisons que chaque écart est pénalisé par une amende équivalente à 50 % du prix de vente de l'électricité. Ainsi, la pénalité c_{dev} dans notre fonction (4.13) est égale à la moitié du tarif de rachat c_{elec} . Il y a cependant trois différences entre notre fonction et le véritable critère de l'AO :

- **le pas de temps** : l'AO se base sur des tranches de 10 min alors que nous travaillons avec un pas de temps de 60 min (à cause de notre modèle d'erreur de prévision).
- **la mesure instantanée** : la pénalisation d'une tranche de 10 min intervient si un dépassement *instantané*⁸ est constaté, alors que nous travaillons avec des puissances *moyennes*. Le critère de l'AO est donc a priori plus sévère.
- **le calcul de la moyenne** : le coût moyen des pénalités de l'AO fait intervenir la moyenne du produit $\bar{I}_{tol} \cdot \bar{P}_{prod}$, qui n'est pas égale au produit des moyennes⁹ $\bar{I}_{tol} \cdot \bar{P}_{prod}$ dans (4.13).

Ces différences sont donc dues à des détails techniques de la modélisation. Le coût exprimé par (4.13) est ce qui se rapproche le plus du critère de l'AO par rapport au modèle dont nous disposons. Une nouvelle modélisation ou bien l'utilisation de vraies données de production-prévision permettrait de se rapprocher davantage du calcul des "vraies pénalités".

Les valeurs numériques des paramètres intervenants dans la fonction coût sont, pour l'essentiel, identiques à celles utilisées dans la partie précédente (§4.2.2) :

- $t_{life} = 15$ ans.
- $\bar{P}_{prod} = 2$ MW (hypothèse d'un facteur de charge de 20 %)
- $c_{batt} = 280$ k€/MWh
- $c_{dev} = 100$ €/MWh¹⁰ (sous-entendu 50 % d'un tarif de rachat $c_{elec} = 200$ €/MWh)


La figure 4.8 présente la cartographie des coûts de l'équation (4.15), sur la même grille de paramètres que la cartographie du taux d'écart, figure 4.7. Le coût du stockage seul est présenté figure 4.8a, où les contours sont bien sûr horizontaux, puisque ce terme ne dépend que de la capacité E_{rated} . Le coût des écarts seul est présenté figure 4.8b, avec des contours qui suivent ceux des taux d'écart de la figure 4.7.

Pour donner une image de la *fiabilité* de la garantie d'engagement, nous avons surligné en gris deux courbes particulières de taux d'écart : 1h/jour (4,2 %) et 1h/mois (0,14 %). Ces deux courbes

8. la mesure "instantanée" de puissance signifie en pratique des puissances moyennées sur *quelques secondes*.


9. il y a égalité ssi les deux variables sont *décorrélées*, c'est-à-dire ici que le niveau de la production est *décorrélé* avec le fait d'être en écart, ce qui n'est probablement pas le cas.

10. attention, ce prix de pénalité est en "€/MWh de production éolienne". Il est très différent du prix en "€/MWh d'écart à l'engagement" de l'équation (4.7) (pénalisation de l'écart en valeur absolue, sans tolérance)



(a) coût du stockage (€/MWh)

(b) coût des écarts hors tolérance (€/MWh)



(c) coût total, avec capacité optimale pour chaque valeur de la tolérance

FIGURE 4.8 – Cartographie des coûts du système pour la garantie d'un engagement de production J+1 avec tolérance d'écart, fonction de la capacité de stockage et de la puissance d'écart toléré. Les coûts sont exprimés en "€/MWh d'énergie produite", d'après un calcul sur une durée $t_{life} = 15$ ans, avec hypothèse d'un facteur de charge de 20% ($\bar{P}_{prod} = 2$ MW). Coût du stockage $c_{batt} = 280$ k€/MWh et coût des écarts $c_{dev} = 100$ €/MWh.

délimitent une plage que nous pouvons qualifier de “zone de fiabilité raisonnable” : hors de cette zone, la tolérance est soit *trop peu* respectée (bas gauche), soit respectée plus que nécessaire (haut droite). Le choix précis des valeurs de frontière est bien sûr arbitraire et doit être adapté à chaque cas d'application ¹¹.

Au final, la figure 4.8c présente la cartographie du coût total $\tilde{C}_{tot}(E_{rated}, P_{tol})$. Observons que pour une faible capacité et une tolérance stricte (bas gauche), le coût est dominé par la pénalisation des écarts \tilde{C}_{dev} , alors que c'est le coût du stockage qui domine lorsque la tolérance est laxiste et la capacité grande (haut droit). Le point (10 MWh, 1 MW), au milieu, est un exemple de point de compromis, avec un taux de dépassement raisonnablement faible de 4 % (1 h/jours). Le coût total du système y est de 15 €/MWh, dont 5 pour les pénalités et 10 pour l'investissement dans le stockage. Pour contextualiser ces valeurs, ce coût total de 15 €/MWh doit être comparé au tarif de rachat supposé à 200 €/MWh. Par ailleurs, cette tolérance de 1 MW est égale à 10 % de la puissance nominale du parc hypothétique étudié et est aussi égale à l'écart-type de l'erreur de prévision P_{mis} . L'AO exige, quant à lui, 15 % “seulement”.

La plage grisée sur la figure 4.8c représente le lieu ¹² des valeurs optimales de capacité, c'est-à-dire qui minimisent le coût total :

$$E_{rated}^*(P_{tol}) = \arg \min_{E_{rated}} C_{tot}(E_{rated}, P_{tol}) \quad (4.16)$$

et cette valeur de capacité est *différente pour chaque valeur de la puissance d'écart toléré* P_{tol} . Nous observons que la capacité optimale est plus grande lorsque la tolérance est plus stricte, et inversement lorsque la tolérance est plus souple. La plus grande capacité est obtenue lorsque la tolérance est nulle, avec environ 15 MWh. Observons également que la capacité optimale sort de la “zone de fiabilité raisonnable” dès que la tolérance est inférieure à 1,3 MW pour aller dans la zone de sous-fiabilité. Ainsi, l'optimum économique conduit à choisir un système qui rend un service de *mauvaise qualité*. Pour améliorer la fiabilité du dimensionnement optimal, il y a deux solutions :

- agir sur les coefficients de coûts : baisse du coût unitaire du stockage c_{batt} , et/ou augmentation du prix des pénalités c_{dev} .
- imposer une contrainte de fiabilité, par exemple $\bar{I}_{tol} < 1\%$ (ce qui est, d'une certaine façon, le cas dans l'AO avec la règle des 100 dépassements sur 30 jours).

mais parmi ces solutions, toutes (sauf la baisse de c_{batt} , qui est cependant plutôt subi) font malheureusement augmenter le coût total du système.

Pistes d'amélioration de l'étude Nous avons déjà signalé à la fin de la partie 4.2.2 quelques pistes d'amélioration qui sont toujours valables ici. En particulier, l'utilisation de *vraies données* de production-prévision permettrait plus de réalisme dans la simulation et le calcul des pénalités d'écart. En particulier, il est possible que le caractère gaussien (donc avec peu de valeurs extrêmes) du modèle d'erreur de prévision P_{mis} conduise à *sous-estimer la fréquence des grands écarts* à l'engagement.

11. l'appel d'offres de la CRE précise par exemple : “si sur une période de 30 jours consécutifs, il est constaté plus de 100 événements donnant lieu à pénalité au titre du non-respect [des garanties de production], l'installation pourra être déconnectée [...]” [28, §6.2].

12. Figure 4.8c, nous avons représenté le lieu des optimums par une *bande floue* plutôt qu'une ligne fine pour matérialiser l'incertitude de leur position. En effet, la minimisation de l'équation (4.16) se fait avec une *interpolation* des coûts calculés sur une grille discrète (E_{rated}, P_{tol}) .

Par ailleurs, nous avons utilisé ici le modèle de stockage idéal, sans pertes, sans vieillissement, ni limitation de puissance. L'introduction d'une limite de puissance constituerait un troisième paramètre intéressant à faire varier dans cette étude (ou bien, pour une technologie de stockage donnée comme la NaS, la puissance nominale pourrait être fixée proportionnellement à la capacité). Relevons qu'une étude de l'effet de la puissance nominale devient particulièrement intéressant s'il est possible de *séparer* le coût du stockage en un coût spécifique sa puissance nominale et un coût spécifique à sa capacité (idéalement une combinaison linéaire $C_{batt} = c_E E_{rated} + c_P P_{rated}$).

4.3 Interaction dimensionnement – gestion

Nous terminons ce chapitre, traitant du dimensionnement, par une étude sur l'interaction entre dimensionnement et gestion. Les résultats qui suivent ont été présentés dans une communication pour la conférence SGE 2014 : “Quelle importance du choix de la loi de gestion pour dimensionner un système de stockage d'énergie ?” [51].

4.3.1 Contexte et enjeux

Au chapitre introductif, nous avons souligné le caractère *couplé* des optimisations du dimensionnement et de la gestion (§1.3.3) d'un système de stockage d'énergie. Ce couplage a été analysé d'un point de vue théorique au sein de la communauté de la conception mécatronique par Fathy *et al.* [42], mais ce problème concerne de nombreux domaines et, à notre connaissance, peu de travaux ont été publiés sur cette question, pourtant fondamentale.

Conséquence de ce couplage, il est nécessaire, a priori, de *co-optimiser* le dimensionnement et la gestion pour atteindre la conception et la performance optimales. Malheureusement, le traitement conjoint de ces deux optimisations est généralement lourd et ce sont donc plutôt des approches *séparées* ou bien *séquentielles* (i.e. optimisation du contrôle, puis du dimensionnement, quitte à reboucler) qui sont préférées. D'un point de vue *théorique*, ces approches simplificatrices ne garantissent pas d'arriver à l'optimum [42]. Face à ce constat, nous choisissons d'étudier la question du couplage d'un point de vue *pratique et quantitatif*, adapté à notre problème particulier de stockage.

Nous avons vu au chapitre 3 que, pour un système de stockage dans un contexte d'incertitude, il est nécessaire d'utiliser le contrôle stochastique pour atteindre la performance optimale. Cependant, la mise en œuvre de la programmation dynamique stochastique (SDP) qui permet d'obtenir ce contrôle peut être très lourde. Qui plus est, la loi de gestion optimale doit être, en général, recalculée pour chaque dimensionnement !

Par conséquent, le dimensionnement se fait souvent sur un système contrôlé par une loi de gestion *sous-optimale*. Nous avons présenté partie 3.2.3 plusieurs lois de gestion alternatives couramment utilisées. Nous appelons ici l'ensemble de ces alternatives “lois de gestion empiriques”, même si certaines peuvent inclure des degrés de liberté optimisables qui peuvent permettre de s'approcher très près de l'optimum atteint par un contrôle SDP.

À l'opposé de ces gestions empiriques, il peut également être tentant, dans une phase de dimensionnement, de remplacer la loi de gestion par une *optimisation déterministe*. Dans le contexte d'un véhicule, elle consiste par exemple à supposer connu à l'avance le profil de mission. Par rapport à l'optimisation stochastique, il n'y a pas besoin de modéliser les entrées incertaines. Les flux d'énergie peuvent alors être optimisés *hors-ligne* [43] (avec une programmation dynamique déterministe, ou une autre méthode d'optimisation adaptée), mais ces flux ne peuvent servir de consignes *en-ligne* que si le profil de mission effectif suit rigoureusement le profil prévu, car il

n'y a pas de rétroaction¹³. En conséquence, l'optimisation déterministe *surestime* la performance réelle du système si celui-ci est soumis à de l'aléa au cours de son fonctionnement.

Problématique Nous venons d'identifier 3 familles de lois de gestion :

1. la gestion optimale stochastique (SDP),
2. la gestion empirique qui sous-estime la performance, et
3. l'optimisation déterministe qui la surestime.

Comme la SDP est très gourmande en calcul, nous partons de l'idée qu'il n'est pas toujours possible d'utiliser cette gestion optimale. Par conséquent, nous supposons que *la gestion optimale SDP est remplacée, pendant la phase de dimensionnement, par une gestion empirique ou déterministe*.

À cause du couplage dimensionnement-gestion [42], le dimensionnement obtenu avec cette gestion "de dimensionnement" est *a priori différent* du dimensionnement optimal, sans que cette différence soit quantifiable a priori. C'est pourquoi, sur un exemple particulier de système de stockage, nous nous concentrons donc sur la question suivante :

Quelle est la sensibilité du dimensionnement au choix de la loi de gestion ?

Originalité Bien que le dimensionnement et la gestion soient souvent traités de façon séparée, il existe des travaux de *co-optimisation* (par exemple Kim *et al.* dans un contexte véhiculaire [61], avec une paramétrisation de la loi de gestion SDP). C'est une démarche similaire que nous avons suivie à la partie 4.2.3 pour dimensionner un stockage en prenant en compte une tolérance d'engagement. Le travail de Rigo-Mariani *et al.* [89] est un autre exemple dans un contexte de dimensionnement PV-stockage, mais où la gestion d'énergie est faite par optimisation déterministe (rendue très efficace par l'exploitation d'une structure de programme linéaire (LP)). Au final, nous n'avons pas connaissance d'une *étude de sensibilité quantitative* sur le choix de la loi de gestion pour le dimensionnement.

4.3.2 Démarche de l'étude

Pour étudier la sensibilité du dimensionnement, nous fixons une définition "formelle" de la *procédure de dimensionnement* du système. La procédure que nous considérons nécessite tout d'abord de choisir :

- un critère de performance en fonctionnement, pour quantifier la performance de la loi de gestion du système.
- un critère de dimensionnement. Comme expliqué à la partie Méthode (§4.1), le critère de dimensionnement prend généralement en compte le critère de performance. Cela peut se faire soit par *pondération* (ex. : un coût total qui additionne investissement et fonctionnement (4.15)), ou par *contrainte* (ex. : minimiser la capacité, sous contrainte d'une performance meilleure qu'un seuil donné).
- une loi (ou famille de lois) de gestion *pour le dimensionnement*. Celle-ci n'est pas forcément optimale par rapport au critère de performance du système.

13. L'approche Model Predictive Control (MPC) présentée partie 3.2.3 est une façon d'ajouter de la rétroaction à l'optimisation déterministe en la répétant périodiquement. Le MPC est ainsi une forme particulièrement sophistiquée de gestion empirique.

La problématique de l'étude est justement de questionner l'influence de ce dernier choix, mais nous allons voir que le choix du critère de dimensionnement joue également un rôle important. Une fois ces choix fixés, la procédure de dimensionnement se fait en deux temps :

1. **Dimensionnement du système**, contrôlé par la loi de gestion “de dimensionnement” choisie.
Typiquement, le critère de dimensionnement est évalué sur toute la plage des dimensionnements jugés possibles. Si la famille de lois de gestion choisie comporte des degrés de liberté, ceux-ci sont optimisés pour *chaque* dimensionnement. Enfin, le choix du meilleur dimensionnement se fait avec le critère de dimensionnement choisi.
2. **Optimisation de la performance**, à dimensionnement *fixé*, en remplaçant la loi de gestion choisie pour le dimensionnement par la loi de gestion *optimale* (SDP).

Remarquons que le dernier point est crucial. Il traduit l'idée que “*je néglige en partie la loi de gestion pour dimensionner le système, car je pourrai m’y pencher après*”. Cette procédure est nommée “séquentielle” par Reyer dans sa classification des méthodes de co-optimisation [42]. Le but de cette étude est de questionner numériquement la validité de cette idée empirique.

Cas étudiés La procédure de dimensionnement étant formalisée, nous l'appliquons pour 3 choix de loi de gestion (SDP, empirique et déterministe), vis-à-vis de 2 critères de dimensionnement. En effet, en laissant libre le choix du critère, notre procédure permet d'étudier différentes variantes et de les comparer. Nous comparons les résultats obtenus en termes de :

- dimensionnement : le choix d'une loi de gestion “de dimensionnement” change-t-il fortement le dimensionnement ?
- performance : le choix d'une loi de gestion “de dimensionnement” change-t-il fortement la performance du système (après passage à la loi de gestion optimale) ?

Système étudié Nous considérons un système éolien-stockage prototypique, avec un modèle de stockage idéal comme utilisé à la partie 4.2.1. Nous supposons qu'il est soumis à une sollicitation aléatoire $P_{req}(k)$ (“storage request”) à pas d'1 heure et d'écart-type $\sigma_P = 1$ MW. Dans cette étude, nous supposons que cette sollicitation n'est pas autocorrélée (bruit blanc, correspondant au processus AR(1) avec $\phi = 0$).

L'objectif du stockage est d'absorber au mieux cet écart en stockant une puissance $P_{sto}(k)$ telle que l'écart P_{dev} soit petit *en moyenne quadratique* (RMS). Nous choisissons donc de quantifier la performance en fonctionnement du système avec un critère d'écart quadratique :

$$J = \|P_{dev}\|^2 = \mathbb{E}[P_{dev}^2] = \frac{1}{N} \mathbb{E} \left\{ \sum_{k=0}^{N-1} P_{dev}^2(k) \right\} \quad \text{avec } N \rightarrow \infty \quad (4.17)$$

Résultats de simulation Pour visualiser le comportement du système, la figure 4.9 présente des simulations temporelles d'un système de stockage de 5 MWh sur 1 semaine face à la même sollicitation $P_{req}(k)$, mais géré par 3 lois différentes :

- fig. 4.9a : gestion empirique “ $P_{sto} = P_{req}$ tant que possible”, déjà rencontrée plusieurs fois dans ce chapitre.
- fig. 4.9b : gestion optimale stochastique (SDP) vis-à-vis d'un coût quadratique, présentée partie 3.3.1.

4 Dimensionnement d'un stockage d'énergie

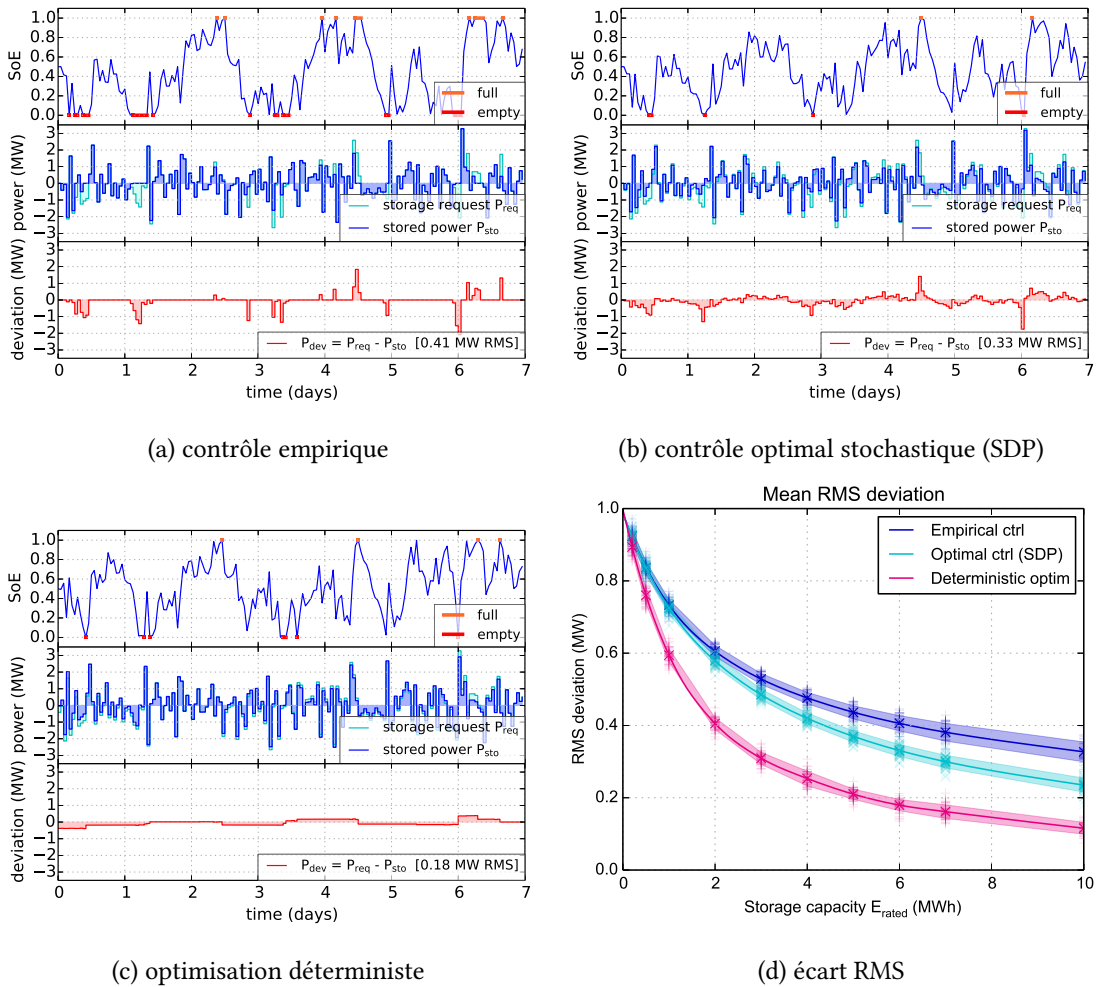


FIGURE 4.9 – Trajectoires d'un système de stockage de 5 MWh pour trois lois de gestion, face à la même sollicitation (perturbation non autocorrélée, à pas d'une heure, d'écart-type $\sigma_P = 1$ MW). BAS DROIT : performance moyenne (en terme d'écart RMS) de chaque loi de gestion, fonction de la capacité de stockage [51].

- fig. 4.9c : optimisation déterministe du profil de puissance stockée $P_{sto}(k)$, *spécifiquement pour ce profil* de sollicitation P_{req} .

En plus de ces trajectoires, le graphique 4.9d synthétise la performance de chaque loi en terme d'écart RMS ($\|P_{dev}\|$) pour des capacités de stockage entre 0 et 10 MWh (les gestions optimales sont recalculées pour chaque dimensionnement).

D'un point de vue qualitatif, les séries temporelles 4.9a et 4.9b permettent de comparer la gestion empirique et la gestion optimale par SDP. La première n'anticipe pas l'évolution de l'état d'énergie, ce qui engendre des saturations brutales (ex. : stockage vide sur la période 1,2 – 1,4 j, entraînant brusquement des écarts P_{dev} négatifs). Inversement, la gestion SDP prend en compte l'état d'énergie pour choisir volontairement des écarts P_{dev} non nuls qui permettent d'avoir moins de saturations du stockage, et donc moins de “grands écarts”.

D'un point de vue quantitatif, nous observons que, toutes lois de gestions confondues, c'est tout d'abord l'augmentation de la capacité E_{rated} qui améliore la performance de fonctionnement : l'écart $\|P_{dev}\|$ qui vaut 1 MW (i.e. σ_P) en l'absence de stockage ($E_{rated} = 0$ MWh) est divisé par deux pour $E_{rated} = 4$ MWh, avec la gestion empirique. La gestion optimale SDP apporte une amélioration supplémentaire de 10 à 20 % grâce à la réduction du nombre de “grands écarts” et ce gain augmente d'ailleurs avec les grandes capacités¹⁴. L'optimisation déterministe, qui utilise la connaissance parfaite des futures sollicitations P_{req} , améliore encore la performance d'un facteur 2. Bien sûr, cette amélioration est artificielle, car lors du véritable fonctionnement en ligne du système, le futur n'est pas connu.

Remarque : les bandes colorées sont une indication de la variabilité de la performance que nous n'exploitons pas dans cette étude. Plus précisément, l'évaluation de la performance a été faite avec $N = 50$ simulations temporelles d'une durée de deux mois, avec une séquence d'entrée $P_{req}(k)$ tirée aléatoirement (approche Monte-Carlo). La bande colorée représente l'écart-type entre les différentes trajectoires. On pourra remarquer que ce nombre N de trajectoires est fortement réduit par rapport aux autres simulations Monte-Carlo de ce chapitre ($N = 10^5$ partie 4.2.1). Cette réduction est due à la gestion du stockage par optimisation déterministe : l'optimisation dépend des *valeurs* de la sollicitation d'entrée¹⁵ et doit donc être répétée pour *chaque trajectoire*, ce qui est très coûteux en calcul.

4.3.3 Résultats de sensibilité

Pour étudier la sensibilité du dimensionnement au choix de la loi de gestion, nous avons considéré deux critères de dimensionnement possibles. Dans les deux cas, la performance du système est l'écart RMS $\|P_{dev}\|$, que la gestion doit minimiser. Cependant, la minimisation de cet écart est *contraire* avec la minimisation de la capacité de stockage E_{rated} . Nous avons vu au début de ce chapitre (§4.1) plusieurs façons de traiter cette contradiction et nous en choisissons deux :

- minimiser la capacité de stockage, en prenant l'écart comme une *contrainte* à respecter, ou
- pondérer cet écart et la capacité pour former un *coût total à minimiser*.

Dimensionnement basé sur une contrainte Le critère de dimensionnement pour cette procédure est une limite sur la moyenne quadratique (RMS) de l'écart P_{dev} . La capacité choisie est

14. explication empirique : “plus le stockage est de grande capacité, plus la gestion optimisée de son énergie porte ses fruits”.

15. par opposition à l'optimisation SDP qui dépend de la *structure* (distribution, autocorrélation, ...) de l'entrée.




FIGURE 4.10 – Dimensionnements basés sur le respect d’une contrainte de performance (écart RMS inférieur à 0.4 MW), avec 3 lois de gestion “de dimensionnement” différentes. [51]

la plus petite vérifiant cette condition :

$$\text{minimiser} \quad E_{rated} \quad (4.18)$$

$$\text{tel que} \quad \|P_{dev}\|(E_{rated}) < \text{seuil} \quad (4.19)$$

La figure 4.10 illustre cette approche pour un seuil fixé à 0.40 MW. Le dimensionnement est donc obtenu par simple intersection des courbes de performance $\|P_{dev}\|(E_{rated})$ avec une horizontale placée au seuil souhaité.

Observations pour le dimensionnement : la capacité obtenue *dépend fortement* de la loi de gestion. Par rapport à un dimensionnement optimal de 4.4 MWh (**A**), la gestion déterministe sous-estime la capacité nécessaire à 2.0 MWh (-53%) (**B₁**) alors que la gestion empirique la surestime à 6.2 MWh (+42%) (**C₁**).

Une fois la capacité choisie, notre procédure d’optimisation séquentielle suppose que l’on réapplique la gestion optimale SDP à dimensionnement fixé. Pour la gestion empirique, cela améliore la performance, mais pour l’optimisation déterministe qui anticipe à tort le futur, la performance est dégradée.

Observations pour la performance : tout comme le dimensionnement, la performance finale du système de stockage est également fortement affectée. Par rapport au seuil visé de 0.40 MW, le dimensionnement basé sur la gestion déterministe aboutit à un écart RMS moyen de 0.57 MW (+44%) (**B₂**) et la contrainte technique fixée au départ n’est pas respectée. La gestion empirique aboutit à un écart de 0.32 MW (-19%) (**C₂**), nettement en dessous de la contrainte grâce au surdimensionnement.

Nous mettons donc en évidence la forte sensibilité du dimensionnement au choix de la loi de gestion lorsque la performance joue comme une contrainte. Dans ce cadre, il semble donc profitable de passer du temps à développer une loi de gestion optimale (SDP) ou quasi optimale (loi paramétrique de forme bien choisie [61], §4.2.3).




FIGURE 4.11 – Dimensionnements par minimisation du coût total du système (somme pondérée des coûts de la capacité et des écarts). Les plages colorées marquent les zones où le coût est inférieur à 105 % du minimum. [51]

Dimensionnement par optimisation d'un coût total Le critère de dimensionnement pour cette procédure considère un coût total où s'additionnent :

- le coût d'investissement du stockage $c_{batt}E_{rated}$. Nous prenons $c_{batt} = 300 \text{ k€}/\text{MWh}$, soit environ le prix d'une batterie Sodium-Soufre, hors surcoûts liés au génie civil et autres contraintes de protection de l'environnement.
- une pénalité proportionnelle à l'écart RMS, calculée sur la vie du système, $c_{dev}\|P_{dev}\|t_{life}$, avec $c_{dev} = 50 \text{ €/MWh}$ et $t_{life} = 15 \text{ ans}$.

Le critère à minimiser est donc :

$$C_{tot}(E_{rated}) = c_{batt}E_{rated} + c_{dev}\|P_{dev}\|(E_{rated})t_{life} \quad (4.20)$$

La figure 4.11 illustre cette approche, avec les trois fonctions coûts pour chacune des trois lois de gestion. Le terme de coût d'investissement, qui est commun au trois, est tracé en ligne tiretée.

Observations pour le dimensionnement : Selon les lois de gestion, les fonctions coûts sont nettement *différentes en valeur*. Cependant, les capacités qui minimisent chaque coût sont *assez proches* : par rapport à un dimensionnement optimal de 4.8 MWh (A), la gestion déterministe donne 4.3 MWh (-11%) (C₁) et la gestion empirique 4.0 MWh (-18%) (B₁).

Observations pour la performance : Lorsque l'on réapplique la gestion optimale aux différents dimensionnements, les coûts obtenus (B₂, C₂) sont *quasi indiscernables* de l'optimum (3.9 M€ sur 15 ans), car tous les dimensionnements se trouvent dans la zone où la dérivée est quasi nulle.

Ainsi, avec cette méthode de dimensionnement basé sur la minimisation d'un coût total, le choix de la loi de gestion semble *peu influencer* le résultat. Se restreindre à la gestion empirique (très simple à mettre en œuvre) se révèle donc un choix très pertinent.

Remarquons pour finir que la position de l'optimum de (4.20) est liée à la *pente* du coût des pénalités ($d\|P_{dev}\|/dE_{rated}$) et qu'il est difficile de dire comment cette pente serait modifiée si les paramètres du problème devaient varier. En conséquence, il nous semble difficile de dire quelle est la généralité de cette observation d'une faible sensibilité au choix de la loi de gestion.

4.3.4 Conclusion et pistes d'amélioration

En considérant un système de stockage simplifié, nous avons étudié la sensibilité du dimensionnement de la capacité énergétique vis-à-vis du choix de la loi de gestion utilisée en phase de dimensionnement

Nous montrons que dans le cas d'un dimensionnement sous contrainte de performance, la loi de gestion utilisée joue un rôle majeur. Inversement, lors d'une minimisation du coût total, nous observons une faible sensibilité du résultat final. La généralisation de cette faible sensibilité à d'autres situations (autre sollicitation d'entrée, par exemple avec autocorrélation non nulle, ou autre critère de pénalisation de l'écart, par exemple avec tolérance, ou encore prise en compte des pertes et du vieillissement...) est malheureusement difficile à évaluer.

De façon générale, l'utilisation d'une optimisation déterministe qui néglige l'aspect stochastique, même si ça n'est que pour le dimensionnement, se révèle dangereuse. En effet, la surestimation de la performance peut mener à un sous-dimensionnement artificiel du stockage qui empêche le système d'atteindre la performance attendue en condition réelle (c'est-à-dire avec des entrées stochastiques imprévisibles).

Inversement, une gestion empirique est plus sûre, car plus conservative. En particulier, nous relevons l'intérêt d'une *gestion paramétrique*, soit de structure empirique, soit inspirée d'un calcul d'optimisation SDP (exemple de la gestion avec tolérance d'écart partie 3.3.3). L'utilisation de paramètres optimisables peut permettre de s'approcher de l'optimum "à moindres frais" (de modélisation et de calculs), ce qui est très intéressant en particulier dans un contexte de dimensionnement. L'exemple de Kim et al. [61] pour la gestion d'énergie d'un véhicule hybride hydrogène-supercondensateurs est à ce titre particulièrement intéressant.

Limites de l'étude Pour nous concentrer sur l'influence du choix de la loi de gestion de dimensionnement, nous avons volontairement choisi un système d'étude extrêmement simplifié. En particulier, il devait être suffisamment simple pour pouvoir calculer, dans un but de comparaison, le dimensionnement optimal basé sur la gestion optimale par programmation dynamique stochastique (SDP). Un dimensionnement basé sur une gestion SDP est rarement possible en général, car l'application répétée de la SDP est très consommatrice de ressources.

Nous avons donc choisi un système de stockage pour lequel nous avons négligé de nombreux phénomènes qui, usuellement, ont une grande influence sur le dimensionnement. En particulier, nous ne prenons en compte ni les pertes de stockage/déstockage ni l'usure.

Par ailleurs, nous avons considéré une entrée aléatoire non autocorrélée, alors que dans le contexte de "garantie d'un engagement de production $J+1$ ", les erreurs de prévision sont autocorrélées positivement (§2.3.2) et nous avons montré que cette autocorrélation a un très grand impact sur le dimensionnement (§4.2.1, [52]).

En conséquence, les résultats numériques des dimensionnements qui précèdent n'ont pas vocation à être représentatifs d'un bon dimensionnement en général. Nous avons néanmoins pris garde à ce que les ordres de grandeur obtenus soient raisonnables pour un système de stockage associé à une ferme éolienne d'une puissance nominale $P_{nom} = 10$ MW, comme dans le reste de ce chapitre.

Dans ce chapitre, nous avons étudié la question du dimensionnement d'un système de stockage pour la garantie d'un engagement de production éolienne. Nous avons à la fois traité d'aspects *physiques* du problème (effet de la corrélation des erreurs de prévision sur le besoin en stockage) et d'aspects *économiques* pour le dimensionnement d'une batterie NaS prenant en compte le coût des pertes et du vieillissement. Nous avons également traité du dimensionnement avec tolérance d'écart à l'engagement, en incluant la question du choix du seuil de tolérance.

Nous avons terminé ce chapitre sur l'interaction entre dimensionnement et gestion, avec une étude de l'influence du choix de la loi gestion utilisée pendant la phase de dimensionnement sur le dimensionnement et la performance du système de stockage obtenu.

Avec le chapitre 2 sur les modélisations et le chapitre 3 sur la gestion d'énergie, nous avons abordé les trois enjeux liés à notre problématique "Comment *dimensionner* et comment *gérer* le système éolien-stockage?". Nous abordons donc maintenant le chapitre de conclusion générale et de perspectives.

Chapitre 5

Conclusion et perspectives

Dans cette thèse de doctorat, nous avons étudié la question du *dimensionnement* et de la *gestion* d'un système éolien-stockage, dans un contexte d'intégration de l'énergie éolienne sur des réseaux électriques insulaires (ex : Guadeloupe, La Réunion), a priori fragiles. Le cahier des charges de notre étude est motivé par un appel d'offres de la CRE [28] pour construire des parcs éoliens avec stockage, permettant de *garantir la production 24 heures à l'avance* (§1.2). La présence d'un stockage est rendue nécessaire par le caractère imparfait des prévisions de production éolienne, basées sur des modèles météorologiques.

5.1 Bilan du travail effectué

Contributions sur la modélisation Après avoir posé le cadre de notre problème de dimensionnement et de gestion d'un système éolien-stockage, nous avons détaillé au chapitre 2 les briques de modélisation du système. Ces modèles sont de nature variée puisqu'ils concernent à la fois des *composants* (systèmes de stockage d'énergie), des *phénomènes* (vieillissement en cyclage des batteries) et des *entrées du système* (production éolienne, erreur de prévision de production).

Concernant les composants, nous avons travaillé sur la modélisation *énergétique* des systèmes de stockage de l'énergie électrique (§2.1). En plus d'un modèle idéal simple, nous avons aussi étudié la modélisation de technologies électrochimiques particulières : Sodium-Soufre (NaS) et Lithium-ion (modélisation de *données expérimentales* sur des modules Li-ion NCA de SAFT). La focalisation sur ces technologies permet de prendre en compte des phénomènes énergétiquement importants mais parfois négligés, comme la thermique (très important pour la NaS). Au-delà des spécificités propres à chaque technologie, nous avons cherché à créer un *cadre unifié* pour la modélisation de batteries électrochimiques. Pour cela nous avons conçu une description basée sur une caractéristique de tension $V(I_{cell}, Q_{cell})$ dont la forme peut être *librement définie* par l'utilisateur (§2.1.2). Nous avons aussi cherché à modéliser les phénomènes de vieillissement en cyclage des batteries sous forme de *modèles dynamiques* (§2.2), dans la perspective de prendre en compte ce vieillissement dans la gestion d'énergie.

Au-delà des composants, nous avons accordé beaucoup d'attention à la modélisation des entrées incertaines, et en particulier sur leur *structure temporelle*, très importante dans un contexte de stockage (§2.3 et 2.4). Nos modèles s'appuient sur l'analyse de *données de terrain* de production et de prévision de production éolienne. Sur ces données, nous avons mis en œuvre des outils statistiques des séries temporelles, en particulier les processus stochastiques autorégressifs. Nous avons également cherché à faire le lien avec des analyses spectrales.

Enfin, nous avons souhaité rendre tous ces modèles facilement opérationnels en créant un module logiciel dit StorageSim (§2.5). Un exemple d'utilisation est présenté en annexe B.1.

Contributions à l'optimisation de la gestion Le chapitre 3 nous a permis de formaliser le problème de la gestion d'énergie du système éolien-stockage sous forme d'un problème d'*optimisation dynamique stochastique*. La méthode de la programmation dynamique stochastique (SDP) permet de résoudre cette classe de problème. La SDP est déjà bien connue dans la gestion d'énergie, par exemple pour les barrages hydroélectriques et nous avons cherché à décrire cette méthode de façon à la fois didactique et adaptée à un problème de stockage (3.1). Nous espérons que cette partie complètera utilement la lecture d'une référence plus généraliste (et sans doute plus rigoureuse) sur le sujet.

Dans l'idée de rendre accessible la mise en œuvre efficace de cette méthode, nous avons également décrit *l'ensemble de la démarche* d'optimisation, depuis la modélisation systémique jusqu'à la validation de la performance de la gestion (§3.2.1). Nous avons aussi discuté quelques détails d'implémentation importants (§3.2.2) et avons présenté des méthodes alternatives à la SDP, mais sous-optimales (§3.2.3). Toujours pour rendre accessible l'outil SDP, nous avons structuré notre implémentation des algorithmes de résolution dans un module logiciel dit StoDynProg qui est indépendant du contexte éolien-stockage (§3.1.4, [50]).

Partie 3.3, nous avons ensuite appliqué l'optimisation dynamique stochastique au problème particulier de garantie d'un engagement de production $J+1$ par un système éolien-stockage. Nous avons étudié l'effet, sur la loi de gestion, de différents paramètres du problème : capacité de stockage, structure temporelle des erreurs (§3.3.2) et surtout *forme de la fonction de pénalisation* des écarts à l'engagement (§3.3.1). Cette résolution de l'optimisation dans plusieurs cas différents nous permet de déduire des observations à caractère général sur la *forme des lois de gestion optimales* pour ce problème. Au final, cela nous permet d'écrire sous forme *paramétrique* la loi de gestion optimale prenant en compte une tolérance d'engagement (§3.3.3).

Pour finir, nous avons souhaité appliquer notre démarche d'optimisation dynamique à d'autres problèmes de gestion d'énergie pour en vérifier la *flexibilité*. Ainsi, toujours dans un contexte de production EnR stochastique, nous avons étudié le lissage de la production d'un houlogénérateur et la limitation des rampes de production en éolien (§3.4).

Contributions à l'optimisation du dimensionnement Le chapitre 4 a été consacré à la question du dimensionnement du système stockage associé à une production éolienne.

En introduction méthodologique (§4.1), nous avons rappelé le caractère généralement contradictoire des deux objectifs principaux que sont la minimisation de la capacité et la maximisation de la performance du système (e.g. réduction de l'écart à l'engagement). Nous avons envisagé deux manières pour résoudre cette contradiction : 1) la *pondération* des deux critères dans une fonction coût et 2) le dimensionnement *sous contrainte de performance*.

Partie 4.2, nous avons traité différents aspects du dimensionnement du stockage pour la garantie d'un engagement $J+1$. Nous avons tout d'abord montré l'effet très important de la structure temporelle (autocorrélation) des erreurs de prévision $J+1$ (§4.2.1). Ce travail s'est fait en réaction à certains travaux de la littérature où cette structure temporelle est malheureusement oubliée, entraînant de forts sous-dimensionnements. En effet, la corrélation positive généralement constatée sur ces erreurs augmente très fortement le besoin en capacité de stockage pour atteindre un niveau de performance donné. Nous avons quantifié l'effet sur le dimensionnement à quasiment un ordre de grandeur supplémentaire.

Partie 4.2.2, le dimensionnement basé sur un coût économique global pour la technologie NaS a fait apparaître l'influence importante de paramètres pas forcément attendus comme le besoin de chauffage. Le prix unitaire du stockage ainsi que le coût de remplacement dû au vieillissement sont bien sûr les facteurs qui influencent très fortement le dimensionnement optimal.

Enfin, nous avons étudié l'effet d'une *tolérance d'écart* à l'engagement pour nous rapprocher du cahier des charges industriel de la CRE (§4.2.3). Nous avons traité de façon symétrique le critère de seuil de tolérance issu du cahier des charges et la capacité de stockage à dimensionner. Cette approche permet de mettre en évidence le *compromis* qui existe entre ces deux paramètres, pour des niveaux de fiabilité donnés. Nous avons également calculé la capacité de stockage optimale. Elle dépend du niveau de tolérance d'écart et est d'autant plus grande que la tolérance est petite.

Nous avons terminé ce chapitre sur une étude plus fondamentale sur l'interaction entre l'optimisation du dimensionnement et de la gestion (§4.3). En effet, ces optimisations sont *couplées*, mais le traitement couplé n'est pas toujours réalisable (complexité calculatoire). Sur un exemple simplifié, nous avons étudié quantitativement l'effet de procédures de dimensionnement-gestion découplées et avons analysé le résultat obtenu, forcément sous-optimal a priori. Nous avons observé que, pour un dimensionnement basé sur une minimisation d'un coût total, le résultat final est peu impacté. Inversement, un dimensionnement basé sur une contrainte de performance s'avère très sensible au choix de la loi de gestion de dimensionnement.

5.2 Prolongements possibles

Au-delà des études présentées dans ce manuscrit, certains aspects de nos travaux sur le système éolien-stockage pourraient être prolongés.

Gestion avec délestage du productible Dans la partie 3.3 consacrée à la gestion de l'énergie pour garantir un engagement de production, nous avons mis en place les outils théoriques et pratiques pour utiliser le délestage de production comme un degré de liberté supplémentaire au stockage. Cependant, nous n'avons pas conduit une étude précise sur *l'intérêt d'utiliser ou non ce délestage*.

Cet intérêt dépend bien sûr du coût relatif de chaque action ("dispatcher, stocker, ou délester", cf. figure 3.1). Ainsi, la pertinence d'une telle étude repose sur la pertinence de la modélisation des différents coûts, sachant que certains facteurs de coût sont difficiles à évaluer. Nous pensons en particulier à l'éventuelle usure prématurée de la turbine éolienne due à une utilisation accentuée de l'écrêtage de puissance.

Validation sur des données de terrains Dans notre description de la démarche d'optimisation de la gestion d'énergie (§3.2.1), nous avons insisté sur l'importance de valider la performance du système sur des données réelles. Cette validation est nécessaire, même lorsque la modélisation s'est faite sur des données de terrains (ex. §2.3.2 modèle AR(1) de l'erreur de prévision). C'est ce que nous avons fait sur l'exemple de la houlogénération (§3.4.1).

Nous pensons que la validation de la performance du système éolien-stockage pour garantir un engagement J+1 pourrait être améliorée par l'utilisation de deux types de données :

- séries de production-prévision sur de *longues durées* (plusieurs années).
- séries à haute résolution temporelle (pas de temps $\Delta_t < 1$ minute)

Les séries longues permettent de valider la performance du système pour des simulations à pas de temps “classique” (10 minutes à 1 heure). La haute résolution temporelle ajoute un aspect important : la fluctuation rapide de production. En effet, on peut penser que les fluctuations rapides (analysées partie 2.4) entraînent pour le stockage : plus de pertes, plus de vieillissement, et peut-être aussi plus d’écart à l’engagement.

La clé d’une bonne validation se situe donc dans la disponibilité de données de terrain, sur de longues durées (plusieurs années), issues de fermes éoliennes, à la fois de production et de prévision. Si les données de production à l’échelle d’une ferme sont rares (hors accord de confidentialité, car données stratégiques pour les opérateurs de parcs), celles de prévisions opérationnelles le sont plus encore (données critiques pour les fournisseurs de prévisions). Idéalement, des jeux de données devraient être librement disponibles pour créer des *benchmarks ouverts* permettant de faire de *comparaisons vérifiables* entre plusieurs méthodes. Dans un domaine connexe, c’est par exemple ce qui a été fait pour la “Global Energy Forecasting Competition 2012” organisée par Hong *et al.* [56].

Prise en compte du vieillissement dans la gestion En modélisant le vieillissement calendaire sous forme de processus dynamique (§2.2), nous avons souhaité créer les bases permettant d’intégrer le vieillissement dans le processus de décision qu’est la gestion d’énergie. Comme le vieillissement des batteries est un aspect important du coût de ces technologies, on trouve dans la littérature quelques contributions à ce sujet. Par exemple, Riffonneau *et al.* [88] utilisent une pénalisation linéaire de la variation de l’état de santé, associé à un comptage de la charge échangée. De façon assez similaire, Borhan *et al.* [17] pondèrent en un critère à minimiser un critère d’écart à l’engagement et un critère d’usure basé sur le “weighted Ah throughput model” de Sauer *et al.* [91]. Autre piste, Koller *et al.* [64] utilisent une pénalisation quadratique sur un modèle de dégradation linéaire par morceaux. Ce formalisme permet de mettre en place une gestion MPC basée une routine d’optimisation “mixed-integer quadratic programming (MIQP)”.

Les différentes approches que nous venons de présenter se basent toutes sur l’idée de *pénaliser à chaque instant* l’usure de la batterie. Nous pensons qu’une alternative intéressante serait de ne pas pénaliser l’usure, mais de fixer une *contrainte d’usure maximum* sur un horizon. En effet, une fois une batterie achetée, il n’est pas fondamentalement mauvais de l’user en s’en servant. Il faut juste ne pas l’user “exagérément”. La contrainte d’usure devrait donc rendre compte du besoin de faire tenir le stockage sur un nombre donné d’années. La pertinence de cette approche est en cours de validation.

Co-optimisation engagement J+1 et gestion Dans le cadre du cahier des charges de l’appel d’offres éolien-stockage [28], l’opérateur éolien doit fournir au gestionnaire réseau un engagement de production J+1 (§1.2.2). Nous avons supposé dans nos travaux que cet engagement de production est choisi égal à la prévision (pas d’optimisation de l’engagement), ou bien que l’éventuelle optimisation de l’engagement J+1 est faite *séparément* de la gestion heure par heure du stockage.

En réalité, les optimisations de l’engagement et de la gestion sont couplées. Empiriquement, lorsque la batterie est vide en fin de journée, l’engagement pourrait être pris plus bas que la prévision pour augmenter les chances de recharger le stock d’énergie. Cependant, nous n’avons pas d’éléments quantitatifs sur cette question et il faudrait donc étudier quel gain de performance peut apporter une co-optimisation.

5.3 Perspectives

Nous proposons quelques pistes de recherches qui nous paraissent intéressantes et qui gravitent autour du cadre de l'éolien-stockage tel que défini par l'appel d'offres éolien-stockage de la CRE [28]

Estimation des coûts du réseau Les pénalités d'écart à l'engagement de l'appel d'offres éolien-stockage [28] ont vocation à être une image des coûts engendrés sur le réseau par l'insertion des EnR intermittentes. Actuellement, la formule de pénalisation se concentre sur l'écart entre production et engagement ($P_{grid} - P_{grid}^*$), mais il est possible que d'autres facteurs tels que les variations de production (dP_{grid}/dt) aient aussi un impact important sur la conduite du réseau. C'est dans cette optique que nous avons d'ailleurs étudié le lissage de rampe §3.4.2. On pourrait aussi imaginer que le mécanisme de pénalisation soit adaptatif, c'est-à-dire fonction des risques spécifiques à chaque journée. Il serait donc intéressant de disposer d'indices quantitatifs pour étayer la formulation des pénalités.

Pour distinguer quelles sont les variables qui interviennent, et surtout estimer le coût à attribuer respectivement à chaque facteur, il est sans doute nécessaire de conduire des simulations de fonctionnement du réseau. Ces simulations devraient inclure à la fois la prévision du dispatch J+1 et la réalisation du dispatch au fil de chaque journée. Ce type de simulation est malheureusement assez lourd, car à réaliser sur de longues périodes (années) pour en déduire des statistiques significatives.

Interaction entre plusieurs fermes L'appel d'offres éolien-stockage vise, par construction, à gérer l'intermittence éolienne à l'échelle de chaque ferme *individuellement*. En présence de plusieurs fermes, il n'y a pas, par exemple, de pénalisations couplées d'écart à l'engagement. Ce choix est motivé par un désir de maintenir une certaine indépendance entre les acteurs économiques.

Il serait intéressant de conduire une étude sur l'interaction de plusieurs fermes éoliennes avec stockage. En particulier, il s'agirait de regarder le comportement de l'écart total à l'engagement ainsi que l'état d'énergie de chacun des systèmes de stockage. En effet, en l'absence de synchronisation entre les fermes, il est possible qu'un stockage se recharge pendant qu'un autre se décharge, menant à une utilisation sous-optimale de l'ensemble des moyens de stockage.

En corolaire d'une telle étude se trouve la comparaison entre l'utilisation de stockages dispersés et gérés indépendamment (cadre de l'appel d'offres) face à une *gestion centralisée* (quitte à ce qu'il y ait plusieurs unités géographiquement dispersées si cela est avantageux).

Autres moyens de flexibilité Autre étude à l'échelle d'un réseau insulaire : comparer un système de stockage à d'autres moyens de flexibilité comme le pilotage dynamique de la consommation (chauffage, climatisations, ...). La comparaison des différentes solutions pourrait se faire sur la base de l'efficacité *technique* (capacité à absorber les fluctuations de production éolienne ou PV), mais aussi *économique* (coûts d'installation et de maintenance), ainsi qu'*environnementale* (besoins en matières premières, énergie grise, émissions de gaz à effet de serre...).

Évaluer la qualité de prévision sous l'angle du stockage Si, pour un parc éolien-stockage, nous imaginons que plusieurs "produits de prévisions" sont disponibles, sur quelle base l'opérateur du parc doit-il faire son choix ? Cette problématique soulève plusieurs questions.

Tout d'abord, la qualité de différentes méthodes de prévision est classiquement évaluée sur la base de critère d'erreurs "généralistes" comme l'erreur en moyenne quadratique (RMSE) ou bien

en valeur absolue (MAE). Est-ce que ces critères sont les mieux adaptés pour choisir la meilleure prévision pour l'application éolien-stockage ?

Par ailleurs, parmi plusieurs prévisions de qualité différente (critère généraliste ou autre), quelle est la *valeur* pour l'application éolien-stockage d'une meilleure prévision ? Cette valeur est-elle en rapport avec les éventuels surcoûts¹ associés à cette meilleure prévision ?

Notre travail de la partie 4.2.1 permet déjà d'établir des liens entre certaines caractéristiques des prévisions (écart-type et corrélation des erreurs) et la performance du système de stockage. Cela nous a d'ailleurs permis de tracer un abaque de pré-dimensionnement (figure 4.3). Pour mieux répondre à ces questions, il faudrait disposer de plusieurs jeux de données de prévision *de la même ferme* pour réaliser des simulations temporelles du système éolien-stockage. Comme il semble difficile d'accéder à de telles données, une étude simplifiée pourrait comparer une prévision commerciale à une prévision simpliste (persistance ou statistiques simples). Le travail de Michiorri *et al.* [74] est un exemple d'étude de l'impact de la prévision, dans le contexte d'un système PV-stockage.

1. exemple de surcoût : utilisation des données de *prévisions d'ensemble* du European Centre for Medium-Range Weather Forecasts (ECMWF)

Annexe A

Sources des données

A.1 Production & prévision éolienne en Guadeloupe (Quadrant)



FIGURE A.1 – Une des 5 turbines Vergnet GEV-MP de la ferme Grand Maison en Guadeloupe.

Nous avons utilisé des données confidentielles générées par Aéro watt (devenue Quadrant en juin 2013). Ces données contiennent la production éolienne ainsi que la prévision J+1 de plusieurs fermes d’Outre-mer, dont Grand Maison en Guadeloupe (commune de Petit Canal).

Cette ferme de 1,375 MW est composée de 5 turbines Vergnet “GEV-MP”, mises en service en 2006. La GEV-MP est une éolienne bipale de 32 m de diamètre spécialement adaptée aux zones tropicales grâce à son mât rabattable qui sert en cas d’alerte au cyclone. La turbine est régulée par calage des pales (pitch control) et contient une génératrice asynchrone à 2 vitesses.

Les prévisions de production J+1 sont réalisées par la société Metnext (actionnaires : CDC Climat et Météo France), prestataire d’Aéro watt, sur la base de *prévisions météorologiques* ainsi que d’une *analyse statistique* des historiques de production des fermes (apprentissage machine avec régression non linéaire du type “réseau de neurones”).

Les données de production (moyennes 10 minutes) et de prévision (à pas d’une heure) ont été homogénéisées par moyennage pour arriver à un pas de temps commun de 1 heure. Nous disposons des données sur la période 2009-09 à 2010-07 soit environ 7848 heures (dont 797 non disponibles).

Visualisation des données : figures 1.5, 2.15 et 2.16.

Source image : Ministère de l’Écologie, du Développement durable et de l’Énergie

<http://www.guadeloupe.developpement-durable.gouv.fr/developper-1-eolien-en-guadeloupe-a464.html>

A.2 Production éolienne à haute fréquence (projet Pégase)

Nous avons utilisé des données de production éolienne à haute fréquence (pas de temps de 5 secondes, contre 10 minutes à 1 heure habituellement). Ces données sont collectées par EDF dans le cadre du projet Pégase qui porte sur la gestion de la variabilité EnR. En particulier, la

production de ferme de La Perrière est mesurée de façon continue. Nous avons utilisé les données de la période juin–décembre 2012 (~3 Mpts).

Cette ferme, située au nord de La Réunion (commune de Sainte Suzanne), appartient à Quadrant, ex-Aérowatt (comme celle de Grand Maison en Guadeloupe). D’une puissance nominale de 10,2 MW, elle est composée de 37 turbines Verget “GEV-MP” de 275 kW. Elle a été mise en service en trois tranches entre 2005 et 2007.

De telles données à haute résolution temporelle permettent de mieux étudier la variabilité de production à l’échelle d’une ferme, incluant un foisonnement significatif. Visualisation des données : figures 2.20 (extraits de 6 h), 2.24 (spectre), 3.13 et 3.14 (simulations de lissage de rampe).

A.3 Bonneville Power Administration (BPA)

La Bonneville Power Administration (BPA) est l’opérateur réseau pour la région Pacific Northwest des États-Unis (en particulier les états d’Idaho, Oregon et Washington). La puissance éolienne de la BPA Balancing Authority était d’environ 4,5 GW en 2013. Notre intérêt pour la BPA vient de ce qu’elle publie librement, entre autres, des données de production éolienne ainsi que des données de prévision particulièrement riches. Les données éoliennes utilisées ont deux sources :

- Wind Generation in the BPA Balancing Authority (<http://transmission.bpa.gov/Business/Operations/Wind/>). Fichiers annuels disponibles à partir de 2007, avec un pas de temps de 5 minutes.
- Wind Power forecasting data (<http://www.bpa.gov/Projects/Initiatives/Wind/Pages/Wind-Power-Forecasting-Data.aspx>). Fichiers mensuels avec un pas de temps de 1 heure, à partir de juin 2012. Les prévisions sont données chaque heure pour les 72 heures suivantes.

Traitement des données Ces deux sources ont été assemblées et agrégées pour obtenir des séries d’erreur de prévision J+1 à pas d’une heure, de juin 2012 à mars 2013. Ces séries de prévision ont été extraites du fichier de prévision global en sélectionnant les blocs de 24 heures générées chaque jour à 17 h et couvrant le jour suivant de 0h00 à 23h00. Ce traitement permet de mimer les contraintes imposées par l’appel d’offre éolien-stockage de la CRE [28] sur le mécanisme d’engagement de production J+1.

Visualisation des données : figure 1.4 (histogramme).

Annexe B

IPython Notebooks

“The IPython Notebook is a web-based interactive computational environment where you can combine code execution, text, mathematics, plots and rich media into a single document.”

<http://ipython.org/notebook.html> [81]

B.1 Simple storage simulation

storage simulation with an input generated by an AR(1) random process

Pierre Haessig - January 2014

```
In [2]: import storagesim as ss
```

Number of vectorized simulations :

```
In [3]: n_sim = 10**4
```

B.1.1 Create the simulation objects

1) Input power model

$$P_{in}(k+1) = \phi P_{in}(k) + \varepsilon(k+1)$$

```
In [4]: p_scale = 1 # MW  
phi = 0.8 # correlation between two successive instants
```

```
ar1 = ss.gen_ar1(0, p_scale, phi, n_sim, seed=0)
```

2) Storage

Energy evolution equation :

$$E_{sto}(k+1) = E_{sto}(k) + E_{sto}(k)\Delta_t$$

rated energy E_{rated}

$$0 \leq E_{sto}(k) \leq E_{rated}$$

B IPython Notebooks

```
In [5]: E_rated = 10 # MWh
        sto = ss.Storage(E_rated, n_sim)
        sto.SoE = 0.5
```

3) Simulation manager FlowSim

```
In [6]: dt = 1 # h
        sim = ss.FlowSim(n_sim, dt, ar1)
        sim.add_consumer(sto)
```

B.1.2 Running a simulation

```
In [7]: sto.SoE = 0.5
        sim.run_sim(24*3)
```

Compute some statistics, like the std along time

```
In [8]: print('input std: {:.3f} MW'.format(sim.p_in[-1].std()))
        print('output std: {:.3f} MW'.format(sim.p_out[-1].std()))

        # Mean absolute error (smaller than std):
        np.mean(np.abs(sim.p_out[-1]))
```

```
input std: 1.002 MW
output std: 0.743 MW
```

```
Out[8]: 0.39141176462112537
```

B.1.3 Plots


```
In [9]: # time vector:
        t = np.arange(sim.p_in.shape[0], dtype=float)*dt # in hours
```

Plot one trajectory, for all variables :

```
In [10]: i_traj = 0 # TODO: animate the plot to change the trajectory

        plt.subplot(211, ylabel='Power (MW)')
        plt.plot(t, sim.p_in[:,i_traj], 'b', label='P_in')
        plt.plot(t, sto.record['p_sto'][:,i_traj], 'g', label='P_sto')
        plt.plot(t, sim.p_out[:,i_traj], 'r', label='P_out')
        plt.ylim(-3*p_scale, 3*p_scale)
        plt.legend(ncol=3)

        plt.subplot(212, ylabel='Energy (MWh)', xlabel='time (h)')
        plt.plot(t, sto.record['E_sto'][:,i_traj], 'g')
        plt.ylim(-.03*E_rated, 1.03*E_rated);
```

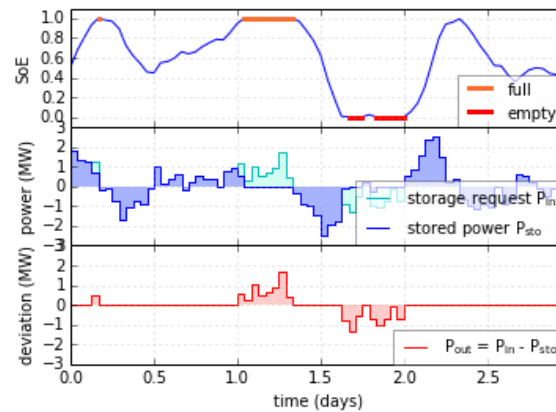


Fancier trajectory plot

```
In [18]: ss.plotting.trajectory_params['p_in'] = '$P_{in}$'
         ss.plotting.trajectory_params['p_out'] = '$P_{out}$'
```

```
In [19]: i_traj = 0
         SoE_traj = sto.record['E_sto'][:, i_traj]/E_rated
         p_sto_traj = sto.record['p_sto'][:, i_traj]
         p_in_traj = sim.p_in[:, i_traj]
```

```
ss.plotting.plot_trajectory(t/24, SoE_traj, p_in_traj, p_sto_traj, p_scale*3);
```




Plot many trajectories

```
In [20]: n_traj=100
```

```
plt.plot(t, sim.p_out[:,0:n_traj], 'b', alpha=0.3)
plt.plot(t, sim.p_out[:,0], 'b', alpha=0.5, lw=7)
```

B IPython Notebooks

```
p_out_std = sim.p_out.std(axis=1)
plt.plot(t, p_out_std, 'r-')
plt.title('P_out: {} trajectories'.format(n_traj));
```




Repartition (histograms)

```
In [21]: hopt = dict(bins=50, cumulative=True, normed=True,
                    histtype='stepfilled', alpha=0.4)
```

```
plt.subplot(111, title='Repartition of the powers', xlabel='power (MW)')
plt.hist(sim.p_in[-1,:], label='P_in', color='b', **hopt)
#plt.hist(sto.record['p_sto'][-1,:], label='P_sto', color='g', **hopt)
plt.hist(sim.p_out[-1,:], label='P_out', color='r', **hopt)
plt.legend(loc='upper left'),
plt.title('Repartition of the power');
```

```
# proportion of P_out = 0 MW
print(np.mean(np.abs(sim.p_out[-1,:]) < 1e-6))
```

0.5945



We can see on this histogram that about 60 % of the time, the output power P_{out} is at 0 MW, thanks to the storage.

B.2 A StoDynProg usage example

This document contains a step-by-step example on :

- how to use the opensource StoDynProg library (<https://github.com/pierre-haessig/stodynprog>),
- in order to solve the *Optimal control of an Energy Storage with an AR(1) input solicitation*.

Pierre Haessig – May 2014

```
In [1]: import numpy as np
import scipy.stats as stats
import matplotlib as mpl
%config InlineBackend.figure_format = 'svg'
```

B.2.1 System description

Problem description overview :

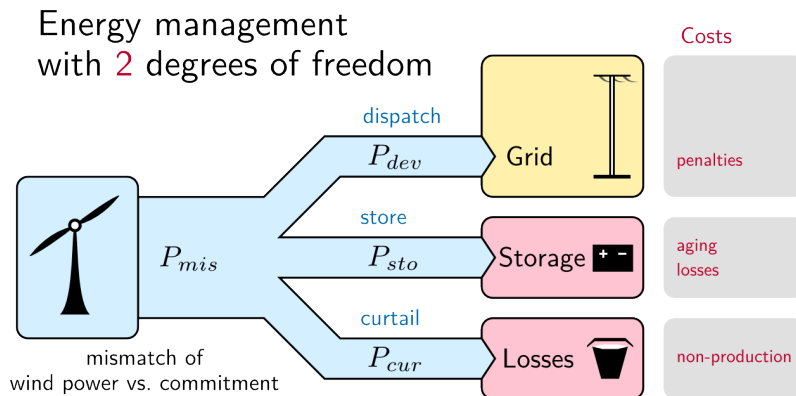


FIGURE B.1 – Storage management problem

Control objective : manage the power flows (e.g. storage power P_{sto}) to minimize system cost (e.g. deviation penalty on P_{dev}) despite the random perturbation P_{mis} .

Power conservation equation :

$$P_{dev} = P_{mis} - P_{sto} - P_{cur}$$

Parameters of the problem

```
In [2]: # time step
dt = 1. # [h]
# AR(1) input : std and correlation
p_scale = 1. # MW
p_corr = 0.8
```

B IPython Notebooks

```
# Storage ratings
E_rated = 10. # MWh
P_rated = 4. # MW
print('Energy storage capacity: {:.1f} MWh'.format(E_rated))
```

Energy storage capacity: 10.0 MWh

Dynamics

Variables of the problem :

- 2 state variables : E_{sto} (stored energy) and P_{mis} (production mismatch)
- 2 control variables : P_{sto} (power absorbed by the storage) and P_{cur} (curtailed power)
- 1 perturbation : w (innovation of the AR(1) process)

$$E_{sto}(k+1) = E_{sto}(k) + P_{sto}(k)\Delta_t$$

$$P_{mis}(k+1) = \phi P_{mis}(k) + w(k)$$

```
In [3]: def dyn_sto(E, P_mis, P_sto, P_cur, innov):
        '''state transition function of a lossless Energy storage

        returns (E(k+1), P_mis(k+1))
        '''
        # 1) Stored energy evolution:
        E_next = E + P_sto*dt
        # 2) Storage request AR(1) model:
        P_mis_next = p_corr*P_mis + innov
        return (E_next, P_mis_next)

# Test:
dyn_sto(5, 2, 1, 0, 0.02)
```

Out[3]: (6.0, 1.62)

Probability law of the innovation $w(k)$

```
In [4]: innov_scale = p_scale * np.sqrt(1- p_corr)
        innov_law = stats.norm(loc=0, scale=innov_scale)
```

Set of admissible controls

Constraints of the Energy Storage are :

1. Energy stock boundaries : $0 \leq E(k+1) \leq E_{rated}$, therefore $-E(k) \leq P_{sto}\Delta_t \leq E_{rated} - E(k)$
2. Power limitation : $-P_{rated} \leq P_{sto} \leq P_{rated}$

Also, the curtailment P_{cur} is constrained between 0 and P_{mis}

```
In [5]: curt_activ = False

def admissible_controls(E, P_mis):
```



```

'''set of admissible control U(x_k) of an Energy storage
The two controls are P_sto and P_cur.

'''
# 1) Constraints on P_sto:
P_neg = np.max((          -E /dt, -P_rated))
P_pos = np.min(( (E_rated - E)/dt, +P_rated))
U1 = (P_neg, P_pos)

# 2) Constraints on the curtailment P_cur
if curt_activ:
    U2 = (0, np.max((P_mis,0)) )
else: # disable curtailment
    U2 = (0,0)
return (U1, U2)

# Test:
admissible_controls(2, 1)

```

Out[5]: ((-2.0, 4.0), (0, 0))

Cost

Instantaneous cost function, which penalized the deviation from the grid commitment P_{dev} . Here we choose a *quadratic* penalization, with a tolerance of $\pm 0.9P_{tol}$

```

In [6]: P_tol = 0.5 #MW
        P_tol_reduced = 0.9 * P_tol

def cost_thres_quad(E, P_mis, P_sto, P_cur, innov):
    '''a threshold-quadratic cost model:
    c_k = (P_dev - P_tol)^2 if P_dev > +P_tol
          (P_dev + P_tol)^2 if P_dev < -P_tol
          0 otherwise
    '''
    P_dev = P_mis - P_cur - P_sto
    # Cost when P_dev is above/in/under the threshold
    c_abov = (P_dev - P_tol_reduced)**2
    c_mid = 0.*P_dev
    c_under = (P_dev + P_tol_reduced)**2
    # Choose the proper cost:
    cost = np.where(P_dev > P_tol_reduced, c_abov, c_mid)
    cost = np.where(P_dev < -P_tol_reduced, c_under, cost)
    return cost

cost_thres_quad(5, 2, 1, 0, 0)

```

Out[6]: array(0.302500000000000005)

Collect all these function in one SysDescription object

```
In [7]: from stodynprog import SysDescription
```

```
sys_desc = SysDescription((2,2,1), name='Storage + AR(1)')
sys_desc.dyn = dyn_sto
sys_desc.control_box = admissible_controls
sys_desc.cost = cost_thres_quad
sys_desc.perturb_laws = [innov_law]

sys_desc.print_summary()
```

```
Dynamical system "Storage + AR(1)" description
* behavioral properties: stationary, stochastic
* functions:
  - dynamics      : __main__.dyn_sto
  - cost          : __main__.cost_thres_quad
  - control box  : __main__.admissible_controls
* variables
  - state        : E, P_mis (dim 2)
  - control      : P_sto, P_cur (dim 2)
  - perturbation : innov (dim 1)
```

B.2.2 Control optimization with SDP

Create a DPSolver object

```
In [8]: from stodynprog import DPSolver
```

```
dpsolv = DPSolver(sys_desc)

# discretize the state space
n_E_sto = 41
n_P_mis = 61
p_mis_max = 4*p_scale
dpsolv.discretize_state(0, E_rated, n_E_sto,
                        -p_mis_max, p_mis_max, n_P_mis)

# discretize the perturbation
perturb_max = 4*innov_scale
n_perturb = 9
dpsolv.discretize_perturb(-perturb_max, perturb_max, n_perturb)

# control discretization step:
p_sto_step = 0.001 # MW
p_cur_step = 0.1 # MW
dpsolv.control_steps=(p_sto_step , p_cur_step)

dpsolv.print_summary()
```

```
SDP solver for system "Storage + AR(1)"
* state space discretized on a 41x61 points grid
  - Delta E = 0.25
  - Delta P_mis = 0.133333
* perturbation discretized on a 9 points grid
  - Delta innov = 0.447214
* control discretization steps:
  - Delta P_sto = 0.001
    yields [4,001 to 8,001] possible values (6,342.5 on average)
  - Delta P_cur = 0.1
    yields 1 possible values
control combinations: [4,001 to 8,001] possible values (6,342.5 on average)
```

Policy optimization with "Policy Iteration" algorithm

Step 1 : Create an empirical control law, to initialize *Policy Iteration* :

```
In [13]: def P_sto_empirical(E, P_mis):
        '''empirical storage policy

        P_sto = P_mis "whenever feasible"
        '''

        # Compute the constraints on P_sto
        P_neg = np.max((          -E /dt, -P_rated))
        P_pos = np.min(( (E_rated - E)/dt, +P_rated))

        # "whenever feasible" control:
        if P_mis < P_neg:
            return P_neg
        elif P_mis > P_pos:
            return P_pos
        else:
            return P_mis
        P_sto_emp_vect = np.vectorize(P_sto_empirical)
        P_sto_emp_vect([0, 5, 9, 10], 2)
```

```
Out[13]: array([2, 2, 1, 0])
```

Evaluate this policy on the state grid :

```
In [14]: state_grid = dpsolv.state_grid_full
        E_sto_grid, P_mis_grid = state_grid

        grid_shape = dpsolv._state_grid_shape
        pol_ini = np.zeros(grid_shape + (2,))
        # P_sto law: (and P_cur = 0 implicetely)
        pol_ini[...,0] = P_sto_emp_vect(*state_grid)
        pol_ini.shape
```


B IPython Notebooks

Out[14]: (41, 61, 2)

Step 2 : Assess the number of value iterations required for the *policy evaluation to converge*

```
In [15]: J, J_ref = dpsolv.eval_policy(pol_ini, 50, rel_dp=True, J_ref_full=True)
plt.plot(J_ref, '-+')
plt.title('Reference cost evolution');
plt.xlabel('number of value iterations');
```

policy evaluation run in 0.06 s



Conclusion : 50 time steps (i.e. 50 hours) is well enough for the cost to converge

Step 3 : Run *Policy Iteration* algorithm

```
In [17]: # Number of policy iterations:
n_pol = 4

# Number of value iterations
#(inner loop used for policy evaluation)
n_val = 50

# run
J, pol = dpsolv.policy_iteration(pol_ini,
                                n_val, n_pol,
                                rel_dp=True)
```

```
policy evaluation run in 0.06 s
ref policy cost: 0.105724
policy iteration 1/4
value iteration run in 6.23 s
policy evaluation run in 0.05 s
ref policy cost: 0.0486519
policy iteration 2/4
value iteration run in 6.25 s
```

```

policy evaluation run in 0.05 s
ref policy cost: 0.0468464
policy iteration 3/4
value iteration run in 6.16 s
policy evaluation run in 0.05 s
ref policy cost: 0.0468268
policy iteration 4/4
value iteration run in 6.16 s
policy evaluation run in 0.05 s
ref policy cost: 0.0468268

```

Conclusion :

- convergence in only 3 step policy improvements
- significant cost improvement : 0.106 \rightarrow 0.047

B.2.3 Plot the energy management policy

Plot the policy from the viewpoing of P_{dev} , the deviation from the grid commitment.
 From the control optimization, we can extract the optimal law $P_{dev}^*(E_{rated}, P_{mis})$ as a 2D array :

```

In [18]: pol_sto = pol[... , 0]
         pol_dev = P_mis_grid - pol_sto
         pol_dev.shape

```

```
Out[18]: (41, 61)
```

Colormap for the plot :

- try to get the nice Cynthia Brewer’s RdBu colormap <http://colorbrewer2.org/?type=diverging&scheme=RdBu&n=11>
- or fallback to Matplotlib coolwarm

```

In [19]: try:
         import brewer2mpl
         cm_blrred = brewer2mpl.get_map('RdBu', 'Diverging', 11, reverse=True).mpl_colormap
     except ImportError:
         print()
         cm_blrred = mpl.cm.coolwarm
     # Test:
     cm_blrred([0, 0.5, 1]) #  $\rightarrow$  blue, white, red

```

```

Out[19]: array([[ 0.01960784,  0.18823529,  0.38039216,  1.          ],
                [ 0.96908881,  0.96647443,  0.96493656,  1.          ],
                [ 0.40392157,  0.          ,  0.12156863,  1.          ]])

```

3D plot of the policy

```

In [20]: from mpl_toolkits.mplot3d import Axes3D
         surf_opts = dict(rstride=3, cstride=3,
                         vmin=-p_mis_max, vmax=p_mis_max,

```

B IPython Notebooks

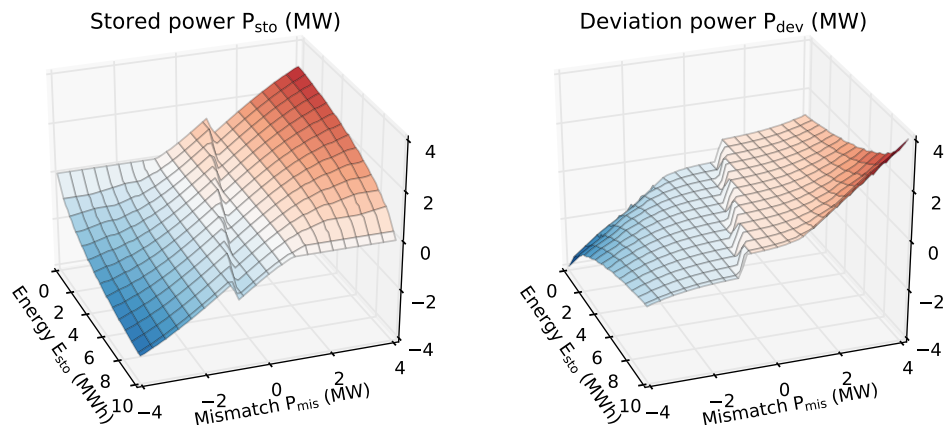
```
cmap=cm_blr, edgecolor=(0,0,0,0.2))

azim = -20
P_mis_label = 'Mismatch  $P_{\text{mis}}$  (MW)'
E_sto_label = 'Energy  $E_{\text{sto}}$  (MWh)'

In [21]: fig = plt.figure(figsize=(8,3.5))
ax1 = fig.add_subplot(121, projection='3d',
                      title='Stored power  $P_{\text{sto}}$  (MW)',
                      xlabel=E_sto_label, ylabel=P_mis_label,
                      )
ax1.plot_surface(E_sto_grid, P_mis_grid, pol_sto, **surf_opts)
ax1.locator_params(nbins=5)
ax1.set_zlim(-p_mis_max, p_mis_max)
ax1.view_init(30, azim)

ax2 = fig.add_subplot(122, projection='3d',
                      title='Deviation power  $P_{\text{dev}}$  (MW)',
                      xlabel=E_sto_label, ylabel=P_mis_label,
                      )
ax2.plot_surface(E_sto_grid, P_mis_grid, pol_dev, **surf_opts)
ax2.locator_params(nbins=5)
ax2.set_zlim(-p_mis_max, p_mis_max)
ax2.view_init(30, azim)

fig.tight_layout()
```



2D plot of the policy

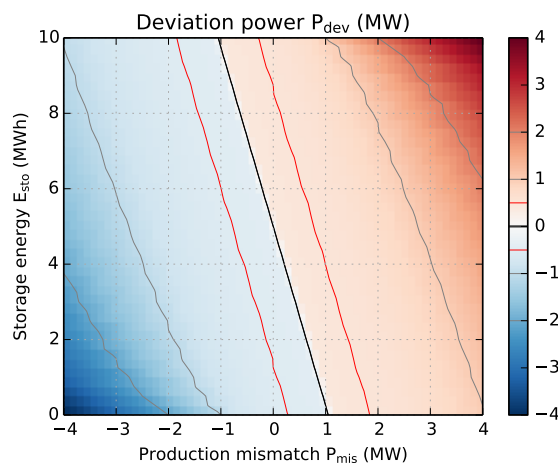
```
In [22]: im_opts = dict(interpolation='nearest', cmap = cm_blr,
                        extent=(-p_mis_max, p_mis_max, 0, E_rated),
                        vmin=-P_rated, vmax=P_rated,
                        origin='lower', aspect='auto')
```

```
P_mis_label = 'Production mismatch $P_{mis}$ (MW)'
E_sto_label = 'Storage energy $E_{sto}$ (MWh)'
```

```
In [23]: fig = plt.figure(figsize=(5,4))
ax = fig.add_subplot(111, title='Deviation power $P_{dev}$ (MW)',
                    xlabel=P_mis_label, ylabel=E_sto_label)
im = ax.imshow(pol_dev, **im_opts)
cbar = fig.colorbar(im, ticks=matplotlib.ticker.MultipleLocator())
# contours
clines = ax.contour(P_mis_grid, E_sto_grid, pol_dev,
                  [-1e-2, 1e-2],
                  colors='k', linestyles='solid', linewidths=.5)
cbar.add_lines(clines)
clines2 = ax.contour(P_mis_grid, E_sto_grid, pol_dev, [-2,-1,1,2],
                    colors='gray', linestyles='solid', linewidths=.5)
cbar.add_lines(clines2, erase=False)

# tolerance power
clines_tol = ax.contour(P_mis_grid, E_sto_grid, pol_dev, [-P_tol, P_tol],
                       colors='r', linestyles='solid', linewidths=.5)
cbar.add_lines(clines_tol, erase=False)

fig.tight_layout()
```



Next steps :

- simulate system trajectories using the optimized control, and
- evaluate the control performance using *real data* (for production mismatch P_{mis})

Bibliographie

- [1] P. AILLIOT, V. MONBET. “Markov-switching autoregressive models for wind time series”. *Environmental Modelling & Software*, 30(0), 92–101. 2012.
- [2] J.-C. ALAIS, M. DE LARA. “Chance-Constrained and Stochastic Viable Management of an Hydroelectric Dam”. In *CLAIO-SBPO, Rio de Janeiro, 24-28 Septembre 2012*. 2012.
- [3] J. APT. “The spectrum of power from wind turbines”. *Journal of Power Sources*, 169(2), 369–374. 2007.
- [4] ASTM. “ASTM E1049 Standard Practices for Cycle Counting in Fatigue Analysis”. 1985.
- [5] J. AUBRY, H. BEN AHMED, B. MULTON. “Sizing Optimization Methodology of a Surface Permanent Magnet Machine-Converter System Over a Torque-Speed Operating Profile : Application to a Wave Energy Converter”. *IEEE Trans. Industrial Electronics*, 59(5), 2116–2125. 2012.
- [6] J. AUBRY, P. BYDLOWSKI, B. MULTON, H. BEN AHMED, B. BORGARINO. “Energy Storage System Sizing for Smoothing Power Generation of Direct Wave Energy Converters”. In *3rd International Conference on Ocean Energy*. 2010.
- [7] G. K. BASAK, N. H. CHAN, W. PALMA. “The approximation of long-memory processes by an ARMA model”. *Journal of Forecasting*, 20(6), 367–389. 2001.
- [8] R. BELLMAN. *Dynamic Programming*. Princeton University Press. 1957.
- [9] D. P. BERTSEKAS. *Dynamic Programming and Optimal Control*. Athena Scientific, 3rd edition. 2005.
- [10] E. BILBAO, P. BARRADE, I. ETXEBERRIA-OTADUI, A. RUFER, S. LURI, I. GIL. “Optimal Energy Management Strategy of an Improved Elevator With Energy Storage Capacity Based on Dynamic Programming”. *IEEE Trans. Industry Applications*, 50(2), 1233–1244. 2014.
- [11] H. BINDNER, T. CRONIN, P. LUNDSAGER, J. F. MANWELL, U. ABDULWAHID, I. BARING-GOULD. “Lifetime Modelling of Lead Acid Batteries”. Technical report, Risø National Laboratory. 2005.
- [12] A. BITO. “Overview of the sodium-sulfur battery for the IEEE Stationary Battery Committee”. In *IEEE Power Engineering Society General Meeting*, volume 2, pp. 1232–1235. 2005.
- [13] S. BIYADI. *Modèle de vieillissement instantané des batteries Li-ion, Rapport de stage de Master 1 Mécatronique*. Master’s thesis, ENS Cachan - antenne de Bretagne. 2012.

- [14] H. BLUDSZUWEIT, J. DOMINGUEZ-NAVARRO, A. LLOMBART. “Statistical Analysis of Wind Power Forecast Error”. *IEEE Trans. Power Syst.*, 23(3), 983–991. 2008.
- [15] O. BOHLEN, J. KOWAL, D. U. SAUER. “Ageing behaviour of electrochemical double layer capacitors : Part II. Lifetime simulation model for dynamic applications”. *Journal of Power Sources*, 173(1), 626–632. 2007.
- [16] A. BOONE. *Simulation of Short-term Wind Speed Forecast Errors using a Multi-variate ARMA(1,1) Time-series Model*. Master’s thesis. 2005.
- [17] H. BORHAN, M. A. ROTEVA, D. VIASSOLO. “Optimization-based power management of a wind farm with battery storage”. *Wind Energy*, 16(8), 1197–1211. 2013.
- [18] A. BOSSAVY. *Caractérisation et prédiction probabiliste des variations brusques et importantes de la production éolienne*. Ph.D. thesis, Mines ParisTech - Centre Énergétique et Procédés. 2012.
- [19] A. BOSSAVY, R. GIRARD, G. KARINIOTAKIS. “Forecasting ramps of wind power production with numerical weather prediction ensembles”. *Wind Energy*, 16(1), 51–63. 2013.
- [20] T. BOUTSIKA, S. SANTOSO. “Quantifying Short-Term Wind Power Variability Using the Conditional Range Metric”. *IEEE Trans. Sustain. Energy*, 3(3), 369–378. 2012.
- [21] P. J. BROCKWELL, R. A. DAVIS. *Time Series : Theory and Methods*. Springer Series in Statistics. Springer New York, second edition edition. 1991.
- [22] S. P. BROOKS, G. O. ROBERTS. “Convergence assessment techniques for Markov chain Monte Carlo”. *Statistics and Computing*, 8(4), 319–335. 1998.
- [23] M. BROUSSELY, P. BIENSAN, F. BONHOMME, P. BLANCHARD, S. HERREYRE, K. NECHEV, R. STANIEWICZ. “Main aging mechanisms in Li ion batteries”. *Journal of Power Sources*, 146(1–2), 90–96. 2005.
- [24] P. CAUMON. “Batteries de véhicule électrique : en route pour une seconde vie stationnaire ?” Technical report, Consulat Général de France à San Francisco, California. 2011.
- [25] S. CAUX, W. HANKACHE, M. FADEL, D. HISSEL. “On-line fuzzy energy management for hybrid fuel cell systems”. *International Journal of Hydrogen Energy*, 35(5), 2134–2143. 2010.
- [26] C. J. COE, A. N. HURST, M. I. HARDIN, M. C. SUCH, R. T. JENNINGS. “Managing Renewable Power Generation”. Patent. 2013. US 7062320.
- [27] L. M. COSTA. *Scheduling of Power System Cells Integrating Stochastic Power Generation*. Ph.D. thesis, Mines ParisTech. 2008.
- [28] CRE. “Cahier des charges de l’appel d’offres n° 332689-2010-FR portant sur des installations éoliennes terrestres de production d’électricité en Corse, Guadeloupe, Guyane, Martinique, à La Réunion, à Saint-Barthélemy et à Saint-Martin”. 2010.
- [29] P. E. DE MELLO, N. LU, Y. MAKAROV. “An optimized autoregressive forecast error generator for wind and load uncertainty study”. *Wind Energy*, 14(8), 967–976. 2011.
- [30] L. S. DEWALD, P. A. W. LEWIS. “A new Laplace second-order autoregressive time-series model–NLAR(2)”. *IEEE Trans. Information Theory*, 31(5), 645–651. 1985.

- [31] S. D. DOWNING, D. F. SOCIE. “Simple rainflow counting algorithms”. *International Journal of Fatigue*, 4(1), 31–40. 1982.
- [32] M. ECKER, J. B. GERSCHLER, J. VOGEL, S. KÄBITZ, F. HUST, P. DECHENT, D. U. SAUER. “Development of a Lifetime Prediction Model for Lithium-Ion Batteries based on Extended Accelerated Aging Test Data”. *Journal of Power Sources*, 215(0), 248 – 257. 2012.
- [33] EDF SEI. “Bilan Prévisionnel de l’Equilibre Offre/Demande d’électricité – Guadeloupe”. Technical report, EDF Direction des Systèmes Energétiques Insulaires. 2013.
- [34] EDF SEI. “Bilan Prévisionnel de l’Equilibre Offre/Demande d’électricité – La Réunion”. Technical report, EDF Direction des Systèmes Energétiques Insulaires. 2013.
- [35] E. ELA, V. GEVORGIAN, P. FLEMING, Y. C. ZHANG, M. SINGH, E. MULJADI, A. SCHOLBROOK, J. AHO, A. BUCKSPAN, *et al.*. “Active Power Controls from Wind Power : Bridging the Gaps”. Technical Report NREL/TP-5D00-60574, National Renewable Energy Laboratory. 2014.
- [36] ENTSOE-E. “ENTSO-E Memo 2012”. Technical report, ENTSOE-E. 2013.
- [37] EPRI. “Handbook of Energy Storage for Transmission or Distribution Applications”. Technical Report 1008703, EPRI. 2002.
- [38] EPRI. “EPRI-DOE Handbook Supplement of Energy Storage for Grid Connected Wind Generation Applications”. Technical Report 1007189, EPRI. 2004.
- [39] EPRI. “Electricity Energy Storage Technology Options : A White Paper Primer on Applications, Costs, and Benefits”. Technical Report 1020676, EPRI. 2010.
- [40] B. T. EWING, J. B. KRUSE, J. L. SCHROEDER. “Time series analysis of wind speed with time-varying turbulence”. *Environmetrics*, 17(2), 119–127. 2006.
- [41] J. EYER, G. COREY. “Energy Storage for the Electricity Grid : Benefits and Market Potential Assessment Guide”. Technical Report SAND2010-0815, Sandia National Laboratories. 2010.
- [42] H. K. FATHY, J. A. REYER, P. Y. PAPALAMBROS, A. ULSOV. “On the coupling between the plant and controller optimization problems”. In *Proceedings of the 2001 American Control Conference, Arlington, VA*, volume 3, pp. 1864–1869. 2001.
- [43] Y. GAOUA, S. CAUX, P. LOPEZ. “Energy Management for an Electric Vehicle Based on Combinatorial Modeling”. In *Proceedings of the International Conference on Industrial Engineering and Systems Management (IESM 2013)*, p. 9. Rabat, Maroc. 2013.
- [44] O. GERGAUD. *Modélisation énergétique et optimisation économique d’un système de production éolien et photovoltaïque couplé au réseau et associé à un accumulateur*. Thèse de doctorat, ENS Cachan. 2002.
- [45] G. GIEBEL, R. BROWNSWORD, G. N. KARINIOTAKIS, M. DENHARD, C. DRAXL. “The state-of-the-art in short-term prediction of wind power : A literature overview”. Technical report, ANEMOS.plus. 2011.
- [46] GOUVERNEMENT. “Arrêté du 17 novembre 2008 fixant les conditions d’achat de l’électricité produite par les installations utilisant l’énergie mécanique du vent”. *Journal Officiel de la République Française*, (290). 2008.

- [47] GOUVERNEMENT. “Arrêté du 8 mars 2013 fixant les conditions d’achat de l’électricité produite par les installations utilisant l’énergie mécanique du vent situées dans des zones particulièrement exposées au risque cyclonique et disposant d’un dispositif de prévision et de lissage de la production”. *Journal Officiel de la République Française*, (78). 2013.
- [48] G. K. GRUNWALD, R. J. HYNDMAN, L. TEDESCO, R. L. TWEEDIE. “Theory & Methods : Non-Gaussian Conditional Linear AR(1) Models”. *Australian & New Zealand Journal of Statistics*, 42(4), 479–495. 2000.
- [49] P. HAESSIG. *Caractérisation de l’incertitude de production éolienne, rapport de stage de Master 2*. Master’s thesis, ENS Cachan - Supélec Laboratoire Signaux et Systèmes. 2011.
- [50] P. HAESSIG, T. KOVALTCHOUK, B. MULTON, H. BEN AHMED, S. LASCAUD. “Computing an Optimal Control Policy for an Energy Storage”. In *6th European Conference on Python in Science (EuroSciPy 2013), Brussels, Belgium*, pp. 51–58. 2013.
- [51] P. HAESSIG, B. MULTON, H. BEN AHMED, S. LASCAUD. “Quelle importance du choix de la loi de gestion pour dimensionner un système de stockage d’énergie ?” In *SGE 2014, Cachan, France*. 2014.
- [52] P. HAESSIG, B. MULTON, H. BEN AHMED, S. LASCAUD, P. BONDON. “Energy storage sizing for wind power : impact of the autocorrelation of day-ahead forecast errors”. *Wind Energy*. 2013. Available online.
- [53] P. HAESSIG, B. MULTON, H. BEN AHMED, S. LASCAUD, L. JAMY. “Aging-aware NaS battery model in a stochastic wind-storage simulation framework”. In *IEEE PowerTech 2013 Conference, Grenoble, France*. 2013.
- [54] B. HARTMANN, A. DÁN. “Cooperation of a Grid-Connected Wind Farm and an Energy Storage Unit – Demonstration of a Simulation Tool”. *IEEE Trans. Sustain. Energy*, 3(1), 49–56. 2012.
- [55] HAWAIIAN ELECTRIC COMPANY . “Invitation for Low Cost Renewable Energy Projects on Oahu Through Request for Waiver from Competitive Bidding. Attachment 1 : Generator Performance Requirements”. 2013.
- [56] T. HONG, P. PINSON, S. FAN. “Global Energy Forecasting Competition 2012”. *International Journal of Forecasting*, 30(2), 357 – 363. 2014.
- [57] J. R. M. HOSKING. “Modeling persistence in hydrological time series using fractional differencing”. *Water Resources Research*, 20(12), 1898–1908. 1984.
- [58] Z. F. HUSSIEN, L. W. CHUNG, M. SIAM, A. ISMAIL. “Modeling of Sodium Sulfur Battery for Power System Applications”. *Elektrika*, 9(2), 66–72. 2007.
- [59] W. KATZENSTEIN, E. FERTIG, J. APT. “The variability of interconnected wind plants”. *Energy Policy*, 38(8), 4400–4410. 2010.
- [60] N. KAWAKAMI, Y. IIJIMA, Y. SAKANAKA, M. FUKUHARA, K. OGAWA, M. BANDO, T. MATSUDA. “Development and field experiences of stabilization system using 34MW NAS batteries for a 51MW wind farm”. In *Industrial Electronics (ISIE), 2010 IEEE International Symposium on*, pp. 2371–2376. 2010.

- [61] M.-J. KIM, H. PENG. “Power management and design optimization of fuel cell/battery hybrid vehicles”. *Journal of Power Sources*, 165(2), 819–832. 2007.
- [62] R. KNÖDLER. “Thermal properties of sodium-sulphur cells”. *Journal of Applied Electrochemistry*, 14(1), 39–46. 1984.
- [63] R. KOENKER, K. HALLOCK. “Quantile Regression”. *The Journal of Economic Perspectives*, 15(4), 143–156. 2001.
- [64] M. KOLLER, T. BORSCHÉ, A. ULBIG, G. ANDERSSON. “Defining a degradation cost function for optimal control of a battery energy storage system”. In *PowerTech (POWERTECH), 2013 IEEE Grenoble*, pp. 1–6. 2013.
- [65] A. N. KOLMOGOROV. “The Local Structure of Turbulence in Incompressible Viscous Fluid for Very Large Reynolds Numbers”. *Proceedings : Mathematical and Physical Sciences*, 434(1890), 9–13. 1941 (1991 reprint).
- [66] T. KOVALTCHOUK, B. MULTON, H. BEN AHMED, J. AUBRY, P. VENET. “Enhanced Aging Model for Supercapacitors taking into account Power Cycling : Application to the Sizing of an Energy Storage System in a Direct Wave Energy Converter”. In *9th Ecological Vehicles and Renewable Energies (EVER) 2014 conference, Monte Carlo, Monaco*. 2014.
- [67] M. LANGE. “On the Uncertainty of Wind Power Predictions—Analysis of the Forecast Accuracy and Statistical Distribution of Errors”. *Journal of Solar Energy Engineering*, 127(2), 177–184. 2005.
- [68] C.-C. LIN, H. PENG, J. GRIZZLE. “A stochastic control strategy for hybrid electric vehicles”. In *Proceedings of the 2004 American Control Conference, Boston, MA*, volume 5, pp. 4710–4715. 2004.
- [69] M. LIPPERT, C. JEUFFRAIN, S. LASCAUD, P. RIOUAL. “Making the Sun Reliable with Li-Ion Energy Storage : Solar PV Energy Management for Large PV Power Plants on Isolated Islands”. In *25th European Photovoltaic Solar Energy Conference and Exhibition*, pp. 3812–3820. 2010.
- [70] B. B. MANDELBROT. “A Fast Fractional Gaussian Noise Generator”. *Water Resources Research*, 7(3), 543–553. 1971.
- [71] J. MANWELL, A. ROGERS, G. HAYMAN, C. AVELAR, J. MCGOWAN, U. ABDULWAHID, K. WU. *Hybrid2 - A Hybrid System Simulation Model : Theory Manual*. Renewable Energy Research Laboratory, Department of Mechanical Engineering. 2006.
- [72] M. MATSUMOTO, T. NISHIMURA. “Mersenne Twister : A 623-dimensionally Equidistributed Uniform Pseudo-random Number Generator”. *ACM Transactions on Modeling and Computer Simulation*, 8(1), 3–30. 1998.
- [73] M. MATSUURA. “Island breezes”. *IEEE Power Energy Mag.*, 7(6), 59–64. 2009.
- [74] A. MICHIORRI, A. BOSSAVY, G. KARINIOTAKIS, R. GIRARD. “Impact of PV forecasts uncertainty in batteries management in microgrids”. In *IEEE PowerTech 2013 Conference, Grenoble, France*, pp. 1–6. 2013.

- [75] C. NICHITA, D. LUCA, B. DAKYO, E. CEANGA. “Large band simulation of the wind speed for real time wind turbine simulators”. *IEEE Trans. Energy Convers.*, 17(4), 523–529. 2002.
- [76] H. A. NIELSEN, H. MADSEN, T. S. NIELSEN. “Using quantile regression to extend an existing wind power forecasting system with probabilistic forecasts”. *Wind Energy*, 9(1-2), 95–108. 2006.
- [77] T. OSHIMA, M. KAJITA, A. OKUNO. “Development of Sodium-Sulfur Batteries”. *International Journal of Applied Ceramic Technology*, 1(3), 269–276. 2004.
- [78] G. PAPAETHYMIU, B. KLOCKL. “MCMC for Wind Power Simulation”. *IEEE Trans. Energy Convers.*, 23(1), 234–240. 2008.
- [79] PARLEMENT EUROPÉEN, CONSEIL DE L’UNION EUROPÉENNE. “Directive 2009/28/CE du Parlement européen et du Conseil du 23 avril 2009 relative à la promotion de l’utilisation de l’énergie produite à partir de sources renouvelables”. *JOL 140 du 5.6.2009*, pp. 16–62. 2009.
- [80] M. PEREIRA, L. PINTO. “Multi-stage stochastic optimization applied to energy planning”. *Mathematical Programming*, 52(1-3), 359–375. 1991.
- [81] F. PÉREZ, B. E. GRANGER. “IPython : a System for Interactive Scientific Computing”. *Computing in Science and Engineering*, 9(3), 21–29. 2007.
- [82] P. PINSON, H. MADSEN. “Adaptive modelling and forecasting of offshore wind power fluctuations with Markov-switching autoregressive models”. *Journal of Forecasting*, 31(4), 281–313. 2012.
- [83] P. PINSON, H. MADSEN, H. A. NIELSEN, G. PAPAETHYMIU, B. KLÖCKL. “From probabilistic forecasts to statistical scenarios of short-term wind power production”. *Wind Energy*, 12(1), 51–62. 2009.
- [84] P. PINSON, G. PAPAETHYMIU, B. KLÖCKL, J. VERBOOMEN. “Dynamic sizing of energy storage for hedging wind power forecast uncertainty”. In *Power Energy Society General Meeting, 2009. PES ’09. IEEE*, pp. 1–8. 2009.
- [85] V. POP, H. J. BERGVELD, J. H. G. OP HET VELD, P. P. L. REGTIEN, D. DANILOV, P. H. L. NOTTEN. “Modeling Battery Behavior for Accurate State-of-Charge Indication”. *Journal of The Electrochemical Society*, 153(11), A2013–A2022. 2006.
- [86] W. B. POWELL. “Perspectives of approximate dynamic programming”. *Annals of Operations Research*, pp. 1–38. 2012.
- [87] R DEVELOPMENT CORE TEAM. *R : A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing, Vienna, Austria. 2009.
- [88] Y. RIFFONNEAU, S. BACHA, F. BARRUEL, S. PLOIX. “Optimal Power Flow Management for Grid Connected PV Systems With Batteries”. *IEEE Trans. Sustain. Energy*, 2(3), 309–320. 2011.
- [89] R. RIGO-MARIANI, B. SARENI, X. ROBOAM. “Optimization methodologies for the energy management and sizing of a microgrid with storage”. In *SGE 2014, Cachan, France*. 2014.
- [90] RTE. “Bilan électrique 2012”. Technical report, RTE. 2013.

- [91] D. U. SAUER, H. WENZL. “Comparison of different approaches for lifetime prediction of electrochemical systems—Using lead-acid batteries as example”. *Journal of Power Sources*, 176(2), 534–546. 2008.
- [92] L. SÖDER. “Integration study of small amounts of wind power in the power system”. Technical report, KTH. 1994.
- [93] L. SÖDER. “Simulation of wind speed forecast errors for operation planning of multi-area power systems”. In *International Conference on Probabilistic Methods Applied to Power Systems, 2004*, pp. 723–728. 2004.
- [94] P. SØRENSEN, P. PINSON, N. CUTULULIS, H. MADSEN, L. JENSEN, J. HJERRILD, M. DONOVAN, J. KRISTOFFERSEN, A. VIGUERAS-RODRIGUEZ. “Power fluctuations from large wind farms - Final report”. Technical Report Risø-R-1711(EN), Risø DTU. 2009.
- [95] Y. THIAUX. *Optimisation des profils de consommation pour minimiser les coûts économique et énergétique sur cycle de vie des systèmes photovoltaïques autonomes et hybrides - Evaluation de la technologie Li-ion*. Thèse de doctorat, ENS Cachan. 2010.
- [96] R. S. TSAY. “Model Checking via Parametric Bootstraps in Time Series Analysis”. *Journal of the Royal Statistical Society. Series C (Applied Statistics)*, 41(1), 1–15. 1992.
- [97] B. UMMELS, M. GIBESCU, E. PELGRUM, W. KLING, A. BRAND. “Impacts of Wind Power on Thermal Generation Unit Commitment and Dispatch”. *IEEE Trans. Energy Convers.*, 22(1), 44–51. 2007.
- [98] S. VAN DER WALT, S. C. COLBERT, G. VAROQUAUX. “The NumPy Array : A Structure for Efficient Numerical Computation”. *Computing in Science and Engineering*, 13(2), 22–30. 2011.
- [99] J. VETTER, P. NOVÁK, M. WAGNER, C. VEIT, K.-C. MÖLLER, J. BESENHARD, M. WINTER, M. WOHLFAHRT-MEHRENS, C. VOGLER, *et al.*. “Ageing mechanisms in lithium-ion batteries”. *Journal of Power Sources*, 147(1–2), 269–281. 2005.
- [100] P. WHITTLE. *Optimal Control. Basics and Beyond*. John Wiley & Sons. 1996.
- [101] P. WINANT. *Dolo, a python library to solve global economic models*. 2010.
- [102] XTREME POWER. “Dynamic Power Resource™ : Core Presentation Fall 2011”. 2011.
- [103] S. YAKOWITZ. “Dynamic programming applications in water resources”. *Water Resources Research*, 18(4), 673–696. 1982.
- [104] K. YOSHIMOTO, T. NANAHARA, G. KOSHIMIZU. “New Control Method for Regulating State-of-Charge of a Battery in Hybrid Wind Power/Battery Energy Storage System”. In *Power Systems Conference and Exposition, 2006. PSCE '06. 2006 IEEE PES*, pp. 1244–1251. 2006.
- [105] K. YOSHIMOTO, T. NANAHARA, G. KOSHIMIZU. “Analysis of data obtained in demonstration test about battery energy storage system to mitigate output fluctuation of wind farm”. In *Integration of Wide-Scale Renewable Resources Into the Power Delivery System, 2009 CIGRE/IEEE PES Joint Symposium*, pp. 1–1. 2009.

Résumé du manuscrit


Le contexte de nos travaux de thèse est l'intégration de l'énergie éolienne sur les réseaux insulaires. Ces travaux sont soutenus par EDF SEI, l'opérateur électrique des îles françaises. Nous étudions un système éolien-stockage où un système de stockage d'énergie doit aider un producteur éolien à tenir, vis-à-vis du réseau, un engagement de production pris un jour à l'avance. Dans ce contexte, nous proposons une démarche pour l'optimisation du dimensionnement et du contrôle du système de stockage (gestion d'énergie). Comme les erreurs de prévision J+1 de production éolienne sont fortement incertaines, la gestion d'énergie du stockage est un problème d'optimisation stochastique (contrôle optimal stochastique).

Pour le résoudre, nous étudions tout d'abord la modélisation des composants du système (modélisation énergétique du stockage par batterie Li-ion ou Sodium-Soufre) ainsi que des entrées (modélisation temporelle stochastique des entrées incertaines). Nous discutons également de la modélisation du vieillissement du stockage, sous une forme adaptée à l'optimisation de la gestion.

Ces modèles nous permettent d'optimiser la gestion de l'énergie par la méthode de la programmation dynamique stochastique (SDP). Nous discutons à la fois de l'algorithme et de ses résultats, en particulier de l'effet de la forme des pénalisations sur la loi de gestion. Nous présentons également l'application de la SDP sur des problèmes complémentaires de gestion d'énergie (lissage de la production d'un houlogénérateur, limitation des rampes de production éolienne).

Cette étude de l'optimisation de la gestion permet d'aborder l'optimisation du dimensionnement (choix de la capacité énergétique). Des simulations temporelles stochastiques mettent en évidence le fort impact de la structure temporelle (autocorrélation) des erreurs de prévision sur le besoin en capacité de stockage pour atteindre un niveau de performance donné. La prise en compte de paramètres de coût permet ensuite l'optimisation du dimensionnement d'un point de vue économique, en considérant les coûts de l'investissement, des pertes ainsi que du vieillissement. Nous étudions également le dimensionnement du stockage lorsque la pénalisation des écarts à l'engagement comporte un seuil de tolérance.

Nous terminons ce manuscrit en abordant la question structurelle de l'interaction entre l'optimisation du dimensionnement et celle du contrôle d'un système de stockage, car ces deux problèmes d'optimisation sont couplés.



Mots-clés : Énergie éolienne, Stockage d'énergie, Garantie de production électrique, Erreurs de prévision météorologique, Dimensionnement de stockage, Gestion d'énergie, Contrôle optimal stochastique, Programmation dynamique.

Keywords: Wind power, Energy storage, Guaranteed electricity production, Weather forecast errors, Storage sizing, Energy management, Stochastic optimal control, Dynamic programming.