

# Régularisation pour le problème de gestion de production court-terme avec 2 étapes

**Nicolas Lebbe**

EDF – OSIRIS (R36)

22 juin 2015 – 11 septembre 2015

**Tuteurs** : Wim Van Ackooij (**EDF**), Jérôme Malick (**INRIA**)



## Présentation du problème

Objectif

Pénalisation

## Résolution

Méthode actuelle

Régularisation

## Améliorations

« Warm-start »

Nombre de résolutions de sous-problèmes

Récupération primale

Saut de dualité

## Tests

L'ensemble d'incertitude

Nombre d'itérations

Programme final comparé à la demande moyenne

# Présentation du problème

## Objectif – Point de vue général

On cherche à déterminer le « meilleur » programme de production électrique au court-terme (c'est-à-dire pour les deux prochains jours) pour toutes les unités de production.

« Meilleur » :

- ▶ Le moins cher ...
- ▶ Tout en respectant la demande en énergie ...
- ▶ Et les contraintes techniques.

# Objectif – Point de vue mathématique

C'est-à-dire qu'on cherche le programme de production  $x$  optimal du problème :

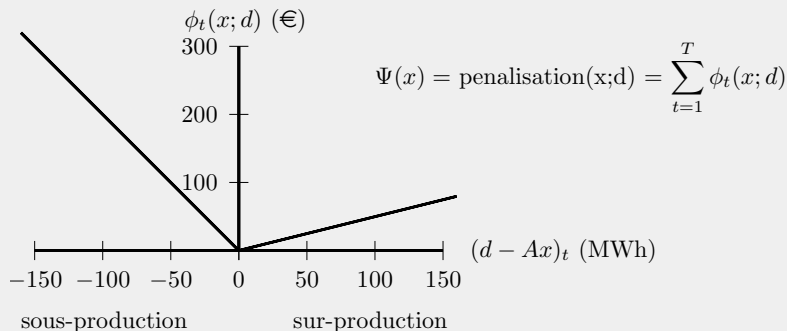
$$\begin{array}{ll} \min & f(x) + \Psi(x) \\ \text{s.c.} & x \in X_1 \end{array} \quad (1)$$

- Avec
- $X_1$  L'ensemble des contraintes techniques.
  - $f(x)$  Le prix de ce programme.
  - $\Psi(x)$  Une pénalisation de l'écart à la demande.

## Comment pénaliser l'écart à la demande ?

Supposons connue la demande en énergie  $d$  à fournir.

On peut alors pénaliser l'écart entre le planning de production choisi  $x$  et la demande  $d$  par une fonction de la forme :



## Demande aléatoire

... Mais la demande n'est pas vraiment connue à l'avance ...

→ On va donc désormais considérer un ensemble  $\mathcal{D}$  contenant plusieurs scénarios de demandes possibles.

**Question :** Comment adapter la fonction de pénalisation



## Demande aléatoire – pénalisation

Choix : **Optimisation robuste.**

→ La pénalisation d'un planning de production  $x$  est donné en considérant le pire des scénarios de  $\mathcal{D}$ .

$$\Psi(x) = \max_{d \in \mathcal{D}} \text{penalisation}(x; d)$$



# Résolution du problème

## Plans sécants + dualisation

$$\begin{array}{ll} \min & f(x) + \Psi(x) \\ \text{s.c.} & x \in X_1 \end{array}$$

Plans sécants  $\longrightarrow$ 

$$\begin{array}{ll} \min & f(x) + \check{\Psi}_k(x) \\ \text{s.c.} & x \in X_1 \end{array}$$

Dualisation  $\downarrow$ 

$$\begin{array}{ll} \max_{\mu \in \mathbb{R}_+^k} & \Theta_k(\mu) \\ \text{s.c.} & \sum_{i=1}^k \mu_i = 1 \end{array}$$

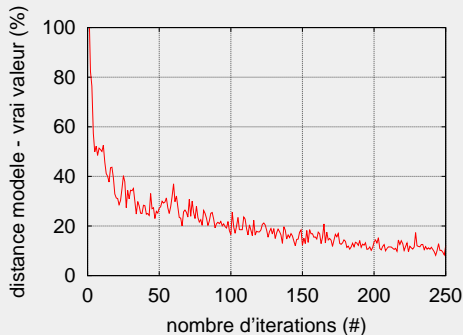
$\Theta_k(\mu)$  obtenu en résolvant  
les  $n$  problèmes :

$$\min_{x_i \in X_i^1} f_i(x_i) + \text{easy-term}(x_i)$$

# Problèmes

Condition d'arrêt : ( $\hat{x}$  minimum du modèle)  
« Distance modèle – vrai fonction en  $\hat{x} < \delta_{\text{stop}}\%$  »

On observe des **oscillations** et une **lenteur de convergence**.



→ il faut régulariser la méthode.

# Méthode de faisceaux


On ajoute un **terme quadratique** d'écart au meilleur itéré qui va contraindre l'algorithme à obtenir à chaque itération :

- ▶ Soit un point éloigné du meilleur déjà trouvé mais beaucoup plus intéressant.
- ▶ Soit un point proche du précédent pas très différent. (permet de raffiner le modèle localement)

Mathématiquement on arrive à la résolution de :

$$\begin{array}{ll} \min & f(x) + \check{\Psi}_k(x) + \frac{1}{2t_k} \|x - \hat{x}_k\|_2^2 \\ \text{s.c.} & x \in X_1 \leftarrow \text{non convexe!} \end{array} \quad (2)$$

## Premier résultat ...



Peut-on faire mieux ?

# Améliorations

## Démarrage à chaud

A chaque itération  $k$  de l'algorithme :

Recherche du minimum du modèle par plans sécants  $\check{\Psi}_k$ .

**Pour cela** : maximisation du dual  $\Theta_k$ .


**Pour cela** : modèle du dual type plans sécants, dualisation etc.

On peut utiliser le modèle de  $\Theta_k$  pour démarrer  $\Theta_{k+1}$  !

La régularisation permet de « prendre de meilleures décisions ».

→ Le Warm-start devrait donc **être plus intéressant pour l'algorithme régularisé.**

# Tests sur données réelles – (#) Résolution sous-problèmes





## Meilleur itéré, pseudo programme, Takriti & Birge ...

Saut de dualité  $\neq 0$  !


Maximisation du dual :  $\max_{\mu} \Theta_k(\mu) = \max_{\mu} \min_{x \in X^1} L(\mu, x)$ .

À  $\mu_{opt}$  maximisant le dual on associe  $x(\mu_{opt})$ .

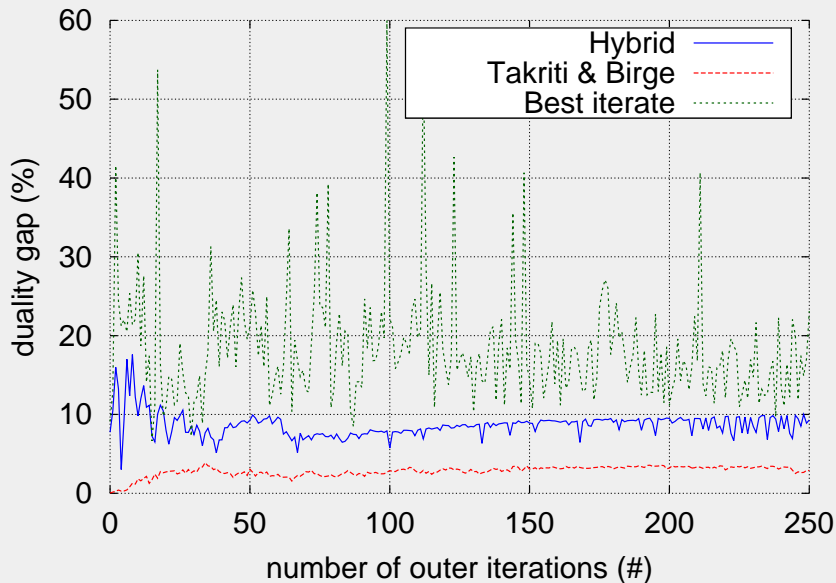
Peut-on obtenir un meilleur programme réalisable que  $x(\mu_{opt})$  ?

→ **Oui**

## Tests sur données réelles – (%) Saut de dualité (simple)



# Tests sur données réelles – (%) Saut de dualité (complet)



# Tests !


## Divers scénarios possibles

**Question** : Quel ensemble  $\mathcal{D}$  choisir ?


- ▶ cardinal **fini** et **petit**. ( $\sim 50$ )  
 $\Psi(x)$  est obtenu en testant tous les scénarios.
- ▶ cardinal **fini** mais **très grand**. (généré selon un graphe de scénarios oscillant autour de la demande moyenne)  
 $\Psi(x)$  est obtenu par programmation dynamique 1D.
- ▶ cardinal **infini** mais « **forme simple** ». (par exemple une bande autour de la demande moyenne)  
Une reformulation de  $\Psi$  donne alors une valeur explicite.

# Tests sur données réelles – (#) Itérations (1/2)


2013.01.14.13.35.18




2013.03.19.13.46.08



2013.05.12.13.54.07




2013.12.09.13.58.33

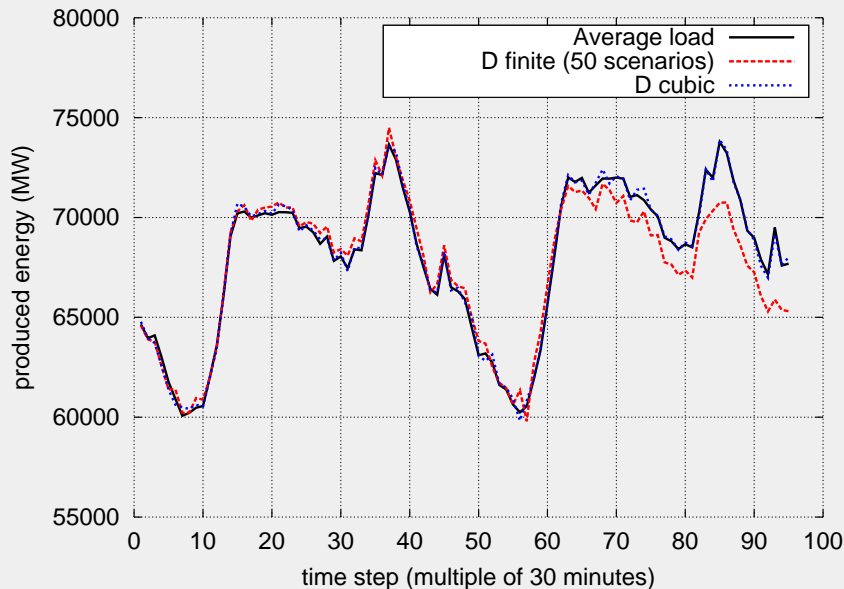


## Tests sur données réelles – (#) Itérations (2/2)

Dans le cas d'un critère d'arrêt très petit (ici  $\delta_{\text{to1}} = 0.1\%$ )



# Tests sur données réelles – Programme obtenu





## Conclusion

- ▶ **Méthode de faisceaux** : stabilisation + réduction du nombre de résolutions de sous-problèmes avec le warm-start.
- ▶ **Heuristique récupération primale** : avec Takriti & Birge  
~ 5.0% de saut de dualité  
... mais à un certain prix (temps de calcul).
- ▶ → Il faut tester sur d'autres ensembles d'incertitude  $\mathcal{D}$  !
- ▶ → La gestion du paramètre  $t_k$  pourrait être amélioré.

**Merci de votre  
attention**

Des questions ?