

# Certification des garanties de sécurité d'un contrôleur en boucle fermée avec du machine learning

Pierre HOUDOUIN, Manuel RUIZ

Affiliation

{pierre.houdouin, manuel.ruiz}@rte-france.com

**Mots-clés :** *Machine learning, proxys, optimisation, certification*

## 1 Introduction

Intégrer les énergies renouvelables (EnR) à grande échelle entraîne des congestions de lignes imprévisibles dans le réseau. Face à ce problème, le Gestionnaire du Réseau de Transport d'Electricité (RTE) a choisi de déployer des contrôleurs zonaux pour gérer les contraintes : les Nouveaux Automates de Zone Adaptatifs (NAZA) [1]. Ces contrôleurs en boucle fermée pilotent en temps réel les batteries, l'écrêtement de la production éolienne et peuvent modifier la topologie du réseau à l'intérieur de la zone. Ils effectuent des actions à l'échelle locale pour assurer le respect des contraintes de sécurité locales du réseau.

Le déploiement massif de ces nouveaux automates dans un système aussi critique que le réseau électrique impose de certifier leur bon fonctionnement, et plus particulièrement celui du MPC, la brique d'aide à la décision du contrôleur. Dans ce travail, étant donné un scénario de production EnR, on souhaite calculer la probabilité  $p_{\text{sécurité}}$  que les actions de l'optimiseur assurent le bon respect des contraintes de sécurité. Les contraintes de sécurité imposent que le flux des lignes ne dépasse pas le seuil maximum autorisé, propre à chaque ligne. Si le flux dépasse le seuil, la ligne est dite congestionnée et la sécurité des équipements n'est plus assurée.

L'estimation de  $p_{\text{sécurité}}$  repose sur la loi des grands nombres. L'approche la plus simple est l'approche brute-force : on tire aléatoirement des scénarios, qu'on simule, jusqu'à atteindre une estimation de  $p_{\text{sécurité}}$  suffisamment précise. La convergence de cette approche est assurée par le Théorème Central Limite et plus on effectue d'itérations, plus l'estimation de la probabilité sera précise. Bien que fonctionnant en théorie, cette approche est malheureusement inenvisageable en pratique :

- Seul des scénarios assez extrêmes, tirés par conséquent rarement, sont susceptibles de menacer la sécurité des équipements.
- Un grand nombre de scénarios doit donc être tiré pour observer suffisamment de situations menaçantes et estimer précisément  $p_{\text{sécurité}}$
- Les simulations de réseaux électriques coûtent très cher en temps de calcul

Néanmoins, il n'est peut-être pas nécessaire de simuler tous les scénarios pour obtenir une bonne approximation de  $p_{\text{sécurité}}$ . Par exemple, dans un scénario sans vent, la production éolienne ne congestionnera jamais les lignes. L'issue de certains scénarios peut par conséquent être déterminé avec une grande confiance sans effectuer de simulations. Éviter toutes ces simulations inutiles permettrait de simuler seulement les scénarios qui ont réellement une chance de menacer la sécurité du réseau et bénéficier d'un gain de temps considérable. C'est l'objectif de notre nouvelle méthode de certification : apprendre avec du machine learning une approximation du simulateur de réseau, un *proxy*, pour prédire l'issue de certains scénarios, éviter certaines simulations et certifier plus rapidement la brique d'optimisation.

## 2 Méthode de certification avec proxy

Pour certifier le MPC, on s'intéresse au calcul de la probabilité  $p_{\text{sécurité}}$  d'observer une menace de sécurité. Pour calculer cette probabilité plus rapidement qu'avec la méthode brute-force, on apprend un proxy du simulateur réel pour éviter des simulation :

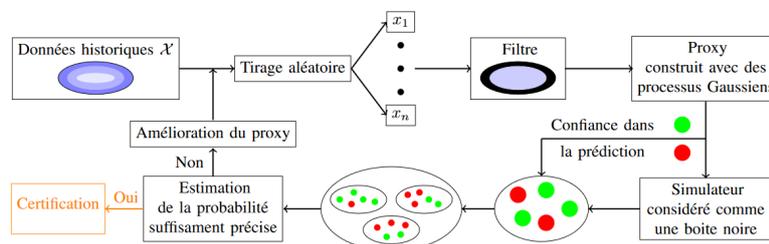


FIG. 1 – Certification avec proxy

### Génération d'un scénario

Des données historiques sont utilisées pour générer aléatoirement des scénarios de production EnR. Les scénarios générés sont ensuite filtrés pour éliminer ceux jugés irréalistes.

### Prédiction de l'issue

Le proxy prédit pour chaque scénario la probabilité d'observer des congestions. Si la prédiction est suffisamment fiable, elle est conservée et une simulation est évitée. Le proxy doit satisfaire deux exigences fondamentales :

- Apprendre la dynamique complexe d'une boîte noire qu'est le simulateur réel
- Evaluer en permanence la qualité de ses prédictions pour juger leur fiabilité

Les processus gaussiens [2] répondent à ces deux exigences et sont parfaitement adaptés à notre problème. Ils permettent d'apprendre précisément la réponse d'une fonction inconnue et fournissent des intervalles de confiance exacts autour des prédictions.

### Simulation d'un scénario

On utilise un simulateur du réseau électrique pour déterminer le flux maximum observé sur chaque ligne. Le simulateur est traité comme une boîte noire inconnue et coûteuse à évaluer.

### Estimation de $p_{\text{sécurité}}$

On utilise le Théorème Central Limite pour obtenir un intervalle de confiance autour de la probabilité  $p_{\text{sécurité}}$  qu'on souhaite estimer.

### Amélioration du proxy

Lorsque la prédiction du proxy n'est pas satisfaisante, le scénario est simulé. Les résultats de chaque simulation sont ensuite utilisés pour entraîner le proxy. Le proxy s'améliore donc au cours des itérations et de plus en plus de simulations sont évitées.

### Enjeux

La réussite de l'approche machine learning dépend de la capacité du proxy à approximer suffisamment précisément et rapidement le simulateur.

## Références

- [1] Hoang, Duc-Trung and Olaru, Sorin and Iovine, Alessio and Maeght, Jean and Panciatici, Patrick and Ruiz, Manuel, *Power Congestion Management of a sub-Transmission Area Power Network using Partial Renewable Power Curtailment via MPC*, 2021 60th IEEE Conference on Decision and Control (CDC)
- [2] Rasmussen, Bousquet, O., von Luxburg, U., Rätsch, G, *Gaussian Processes in Machine Learning*, Advanced Lectures on Machine Learning. ML 2003. Lecture Notes in Computer Science, vol 3176. Springer, Berlin, Heidelberg