

Vers une approche floue pour le design de plan expérimental



CNIA La Rochelle - 3 juillet 2024

Olivier Rousselle, Jean-Philippe Poli, Nadia Ben Abdallah



Objectifs

Développement d'une méthode basée sur la logique floue pour le design de plan expérimental, sous contraintes et avec peu de données.

- Apprentissage de règles (régression) et connaissances expertes
- Suggestion de la prochaine expérimentation à faire
- Diminution du nombre d'expérimentations pour atteindre une performance cible
- Explicabilité / interprétabilité




Vue d'ensemble de l'approche

Connaissances



Points échantillonnés



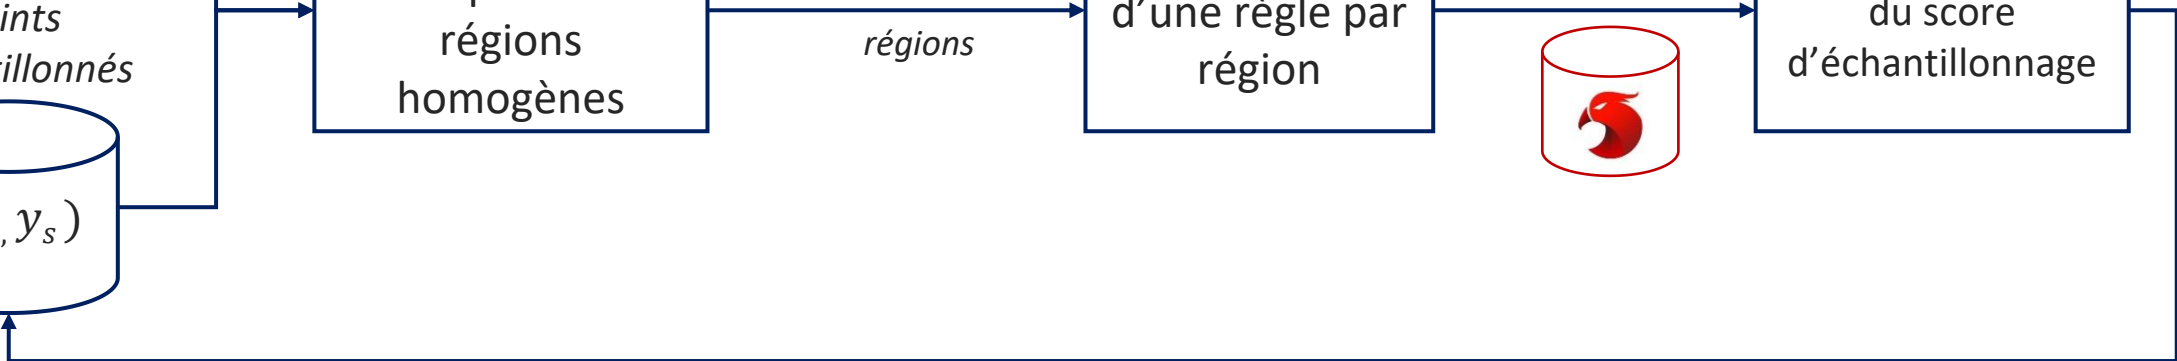
Découpage de l'espace en régions homogènes

régions

Apprentissage d'une règle par région



Maximisation du score d'échantillonnage





■ Etapes de l'algorithme


Clustering

- Clustering flou
 - Un point peut appartenir à plusieurs clusters à différents degrés
 - Somme des degrés pour un même point vaut 1

- Fonctions d'appartenance obtenues en minimisant:

$$\sum_{x_s} \sum_{m_c} \mu_c(x_s) \|x_s - m_c\|^2$$

- Prise en compte de toutes les dimensions + sorties



Degrés d'appartenance - étude de cas avec 3 variables de composition et 3 clusters.

Apprentissage de règles

- 1 règle par cluster. Règle de Sugeno de la forme :

$$\text{Si } \mathbf{x} \in C \text{ alors } \hat{y}_c = \alpha_c \cdot \mathbf{x} + \beta_c$$

- Système d'inférence flou de Sugeno :


$$\hat{y} = \sum_c \mu_c(\mathbf{x}) \hat{y}_c(\mathbf{x}) = \sum_c \mu_c(\mathbf{x}) (\alpha_c \cdot \mathbf{x} + \beta_c)$$

- Optimisation des coefficients de régression :

$$L(\alpha, \beta) = \sum_{x_s} (\hat{y}(x_s) - y(x_s))^2 = \sum_{x_s} \left(\sum_c \mu_c(x_s) (\alpha_c \cdot x + \beta_c) - y(x_s) \right)^2$$

Apprentissage de règles plus interprétables

- Afin d'obtenir un modèle plus interprétable, projection des clusters sur les axes
- Retour à des règles floues classiques avec des propositions floues




Choix de la prochaine expérimentation

- On définit le score d'échantillonnage par: $S(\mathbf{x}) = \hat{y}(\mathbf{x}) + \lambda d(\mathbf{x})$
- Compromis exploration / exploitation
- Ex. de prochain point à tester: $\{x_1 = 0.35, x_2 = 0.5, x_3 = 0.15\}$




■ Expérimentations

Fonction objectif connue à 3 entrées




$$f(\mathbf{x}) = \left| \prod_{k=1}^3 \sin(k\pi x_k) \right|$$

- 100 valeurs sur chaque axe
→ 5151 expérimentations à faire
- La méthode dépend du choix des points initiaux
 - On choisit 5 points initiaux non pertinents
 - On atteint 80% de la valeur maximale de Y en 20±12 itérations





Score d'échantillonnage




Fonction objectif :

$$f(x) = \left| \prod_{i=1}^3 \sin(\pi i x_i) \right|$$



Fonction objectif connue à N entrées

→ Comparer le nombre d'itérations nécessaires entre notre approche et l'optimisation bayésienne



Données réelles: concrete dataset

- Déterminer la performance de la régression
 - Notre méthode: $RMSE = 8,7 \pm 2,9$
 - Optimisation Bayésienne : $RMSE = 15,1 \pm 3,6$
- Déterminer le nombre d'expérimentations nécessaires
 - Même protocole que précédemment
 - Nombre d'expérimentations: $9 \pm 6,7$



■ Conclusion

Conclusion

Critères	Algorithme flou	Optimisation bayésienne
Echantillonnage adaptatif	+	+
Interprétabilité	~	-
Connaissances expertes	+	-
Régions	+	-
Déterminisme	+	-
Grande dimension	+	+
Rapidité calcul	~/+	+

Merci de votre attention !

