

Rôle des algorithmes du Machine Learning (ML) dans l'analyse de la relation entre la structure chimique et son activité (SAR)

Dans le cadre du projet SCHISM*

Hajar KARINE (née REHIQUI)
hajar.rehioui-karine@unicaen.fr


06/07/2021

* Le projet SCHISM est financé par l'Union européenne dans le cadre du programme opérationnel FEDER/ FSE 2014-2020

Contexte général

Découverte de médicament (Drug Discovery)

Pour découvrir l'impact d'un médicament sur **une cible** (proteïn responsable d'une maladie), un certain nombre de **molécules** sont utilisées (ou testées) comme **inhibiteurs** de ces **cibles**. Si l'interaction entre la molécule est **la cible** se fait, on dit que la molécule est **active** sinon elle est **inactive**




Pharmacophore

Un **Pharmacophore** correspond à un fragment d'une molécule responsable de son **activité biologique** (**active** ou **inactive**).

Les marqueurs pharmacophoriques sont identifiés afin de construire un graphe pharmacophorique

Une **molécule** pourra être décrite par un ensemble de **pharmacophores**





Exemple d'un pharmacophore et de son graphe

Structure Activity Relationship (SAR)

SAR

La relation entre la structure chimique et son activité part du principe que deux **structures chimiques similaires** auront **des activités similaires**



Pourquoi l'utilisation du ML¹?


- la complexité des molécules étudiées
- la grande taille des données


Les aspects du ML

- méthodes supervisées
- méthodes non supervisées
- méthodes semi-supervisées



- prétraitement de la data: feature selection, feature reduction
- régression, classification, regroupement (clustering)
- analyse, interprétation, explication





* perspectives

Prétraitement

Description

- L'objectif est l'étude d'une tyrosine kinase nommée BCR-ABL responsable de la leucémie.
- 1485 molécules qui ont pour cible BCR-ABL, et qui sont décrites par 112048 pharmacophores d'ordres 3 à 7.
- Jeu de données générés par le logiciel Norns¹ à base du Dataset ChEMBL²

Jeu de données	#instances	#attributs	Type de données
Molécules	1485	112048	binaires (0, 1)

Id_Mol	A A A -0	A A A -1	A A A -2	A A A -3
CHEMBL250213	1	0	0	0

1. METIVIER, Jean-Philippe, CUISSART, Bertrand, BUREAU, Ronan, *et al.* The pharmacophore network: a computational method for exploring structure–activity relationships from a large chemical data set. *Journal of medicinal chemistry*, 2018, vol. 61, no 8, p. 3551-3564.

2. GAULTON, Anna, HERSEY, Anne, NOWOTKA, Michał, *et al.* The ChEMBL database in 2017. *Nucleic acids research*, 2017, vol. 45, no D1, p. D945-D954.

Problèmes

- 1) Problèmes de mémoire lors des exécutions
- 2) Données compliquées pour l'analyse clustering

Solutions:

Prétraitement de données:

- 1) Réduire le nombre d'attributs → Classes d'équivalence
- 2) Transformer les données pour obtenir de meilleurs résultats de clustering

Prétraitement : classes d'équivalence

Une classe d'équivalence (CE)

Une **CE** regroupe les **pharmacophores** qui **apparaissent exactement** dans les mêmes **molécules**

Un des **pharmacophores** de chaque **CE** est choisi comme **représentant** de sa classe.

Cette méthode nous a permis de faire une **réduction de 80,25%**

Jeu de données	#instances	#attributs	Type de données
Molécules	1485	22127	binaires (0, 1)


Prétraitement : transformation des vecteurs d'attributs

Transformation supervisée

Cette transformation a pour objectif de regrouper les molécules selon leur activité biologique.

Elle utilise un réseau de neurones ^{*}(NN) qui minimise la fonction d'optimisation "categorical_crossentropy"


Les poids et biais qui ont été utilisés dans la phase d'entraînement sont utilisés pour faire une transformation linéaire



$$x'_{ij} = x_{ij} \times w_{jj} + b_j$$

* Implémentation faite à l'aide des bibliothèques Keras et Tensorflow

Prétraitement : transformation des vecteurs d'attributs




Original



Transformé



Prétraitement : transformation des vecteurs d'attributs



Original



Transformé



Evaluation: NMI

NMI* (Normalized mutual information): est une mesure de qualité qui compare les clusters ou classes résultants avec la vérité terrain. Les résultats varient entre 0 (aucune information mutuelle) et 1 (corrélation parfaite)

* L'évaluation est faite à l'aide de la bibliothèque scikit-learn

Validation du modèle de la transformation (5-fold)

Jeu de données	Original					Transformé				
avant clustering										
après clustering										
NMI	0.088	0.045	0.054	0.024	0.088	0.480	0.395	0.354	0.396	0.427
NMI (5-folds)	0.060					0.410				

Légende: ■ Inactive ■ Active ■ Cluster 0 ■ Cluster 1


	Original		Transformé	
	Cluster 0	Cluster 1	Cluster 0	Cluster 1
Inactive (711)	707 (99.44%)	4 (0.56%)	709 (99.72%)	2 (0.28%)
Active (774)	716 (92.51%)	58 (7.49%)	302 (39.02%)	472 (60.98%)

Clustering

Objectif

Le clustering permet de regrouper les structures similaires et de découvrir les sous-familles d'activités ainsi nous avons la possibilité d'analyser les clusters:

- homogènes → découvrir des structures d'activités similaires → Être apte à expliquer la cause de ce regroupement
- non homogènes → découvrir des activités cliffs → Être apte à expliquer la cause de l'activité cliff



Exemple¹ d'activité cliff

Défis


Comment prédire la sous activité pour une nouvelle donnée ?

Solutions:


Introduire la notion du clustering prédictif

Principe

- 1) Appliquer l'une des méthodes de clustering sur l'ensemble d'apprentissage après sa transformation
- 2) Affecter à chaque cluster construit dans l'étape (1) les données qui lui correspondent (les plus similaires)




Clustering prédictif



Exemple clustering prédictif avec K-means*

* K-means et la prédiction de clusters est faite à l'aide de la bibliothèque scikit-learn

Clustering prédictif

























Exemple clustering prédictif avec K-means

Evaluation: Silhouette

Silhouette* est une mesure calculée en utilisant la distance moyenne intra-cluster et la distance moyenne du cluster le plus proche. La meilleure valeur est 1 et la moins bonne est -1. Les valeurs proches de 0 indiquent que les clusters se chevauchent. Les valeurs négatives indiquent généralement qu'un échantillon a été affecté au mauvais cluster, car un cluster différent est plus similaire.

* L'évaluation est faite à l'aide de la bibliothèque scikit-learn

Clustering prédictif (5-folds)

données	Original					Transformé				
avant clustering										
K-means										
Affinity-Propagation										
NMI K-means	0.252	0.263	0.230	0.283	0.258	0.345	0.288	0.300	0.282	0.278
silhouette K-means	0.130	0.142	0.098	0.225	-0.005	0.472	0.496	0.469	0.489	0.455
NMI Affinity	0.301	0.302	0.175	0.172	0.273	0.345	0.291	0.306	0.280	0.299
silhouette Affinity	0.187	0.075	0.089	0.196	0.193	0.471	0.479	0.483	0.466	0.507

Transformation (Matrice de confusion)


<u>Meilleur fold (5)</u>	Original	Transformé
Inactive (711)	0 0 0 0 3 4 4 128 3	0 1 3 35 0 0 38 27 38
Active (774)	4 63 9 8 0 4 2 63 1	45 8 18 11 29 15 19 7 2

<u>Moins bon fold(2)</u>	Originale	Transformé
Inactive (711)	0 0 0 0 0 0 4 3 135	0 0 0 0 30 4 23 54 31
Active (774)	8 28 4 6 6 3 4 3 93	27 23 32 25 11 4 9 14 10

Analyse d'activité cliffs dans les régions fortement non homogènes

Perspectives
-Explicabilité-

Création d'un modèle parallèle g qui explique le modèle de prédiction f



Le modèle d'explication général se calcule comme suit :

$$f(x) = g(x') = \phi_0 + \sum_{i=1}^M \phi_i x'_i$$

L'idée de base c'est en faisant la somme des contributions de tous les features il faudra avoir la même prédiction (output) que le modèle original $f(x)$.

Feature Importance ¹

$$g(x') = \phi_0 + \sum_{i=1}^M \phi_i x'_i$$

$x' \in \{0,1\}^M$, dite représentation interprétable, est un vecteur binaire indiquant la présence ou l'absence du feature. M est le nombre de features en entrée

ϕ_0 est dite valeur de base. il représente la valeur moyenne des prédictions du modèle f

ϕ_i est une valeur réelle désignant la contribution du feature

Dans le cas de SHAP, la contribution de chaque feature i est calculée comme suit:

$$\phi_i = \frac{1}{N!} \sum_{S \subseteq N \setminus \{i\}} |S|!(|N| - |S| - 1)! [f(S \cup \{i\}) - f(S)]$$




- N : l'ensemble de tous les features
- S : tous les sous ensembles de N moins le feature i
- $f(S \cup \{i\})$: prédiction d'un sous ensemble S en considérant le feature i
- $f(S)$: prédiction d'un sous ensemble S
- $f(S \cup \{i\}) - f(S)$: la contribution marginal du feature i dans chaque sous ensemble S
- $|S|!$: toutes les permutations former par S avant l'ajout de i .
- $(|N| - |S| - 1)!$: toutes les permutations former après l'ajout de i .

1. Rodríguez-Pérez, R.; Bajorath, J. Interpretation of Compound Activity Predictions from Complex Machine Learning Models Using Local Approximations and Shapley Values. *J. Med. Chem.* 2020, 63, 8761–8777.

2. exemple explicatif: <https://towardsdatascience.com/explainable-ai-application-of-shapely-values-in-marketing-analytics-57b716fc9d1f>

Algorithm SHAP in drug Discovery¹


Les résultats sont obtenus en se basant sur le framework SHAP (python) développé par Scott Lundberg²




1. Rodríguez-Pérez, R.; Bajorath, J. Interpretation of Compound Activity Predictions from Complex Machine Learning Models Using Local Approximations and Shapley Values. *J. Med. Chem.* 2020, 63, 8761–8777.

2. <https://github.com/slundberg/shap>

Merci pour votre
attention



Clustering prédictif



Exemple clustering prédictif avec K-means*

* K-means et la prédiction de clusters est faite à l'aide de la bibliothèque scikit-learn