







Fraude 2: Fraud detection based on Graphs


Contexte : IA et fraudes



Tâches usuelles de ML sur graphes




Node Classification




Prédiction de liens

Node2Vec



But : apprendre cette fonction



Similarité dans le
réseau: $\text{similarité}()$?



f doit préserver la **similarité** des noeuds

Les RW


Quelles stratégies pour RW ?

DeepWalk : non biaisé

Node2Vec : second-ordre biaisé


Rigide

Flexible




- P : retour
- Q : intérieur vs extérieur

Edge2vec?




~~g définie sur $E?$~~
 g définie sur V^2

Operator	Symbol	Definition
Average	$\boxplus$	$[f(u) \boxplus f(v)]_i = \frac{f_i(u) + f_i(v)}{2}$
Hadamard	$\boxdot$	$[f(u) \boxdot f(v)]_i = f_i(u) * f_i(v)$
Weighted-L1	$\ \cdot\ _{\bar{1}}$	$\ f(u) \cdot f(v)\ _{\bar{1}i} = f_i(u) - f_i(v) $
Weighted-L2	$\ \cdot\ _{\bar{2}}$	$\ f(u) \cdot f(v)\ _{\bar{2}i} = f_i(u) - f_i(v) ^2$



Input





Output

Image from: [Perozzi et al.](#). DeepWalk: Online Learning of Social Representations. *KDD 2014*.

Exemple d'encodage du réseau du Karaté Club de Zachary vers un espace 2D

GraphSAGE and DeepLearning on Graph

Généralisation de la notion de convolution :
Neighborhood aggregation





Problème : Structure
des graphes réels plus
complexes
Solution GraphSAGE

Transformer les informations
provenant des voisins et les
combiner :

- $\sum w_i * h_i$
- informations = attributs des
noeuds

GCN




trainable matrices
(i.e., what we learn)

$$\mathbf{h}_v^0 = \mathbf{x}_v$$

$$\mathbf{h}_v^k = \sigma \left(\mathbf{W}_k \sum_{u \in N(v)} \frac{\mathbf{h}_u^{k-1}}{|N(v)|} + \mathbf{B}_k \mathbf{h}_v^{k-1} \right), \forall k \in \{1, \dots, K\}$$


$\mathbf{z}_v = \mathbf{h}_v^K$

Chaque nœud définit
son propre computation
graph




Modélisations du problème


Simple



Bipartite (pondéré)



Bipartite-séquentiel (pondéré)





Visualisation des graphes

- Représentation graphique statique des graphes : GraphViz




GraphViz: Bipartite Weighted





Procédure adoptée?



Difficultés rencontrées et résultats

Premiers résultats non prometteurs:

- Résultats moins bon avec Node2Vec que sans Node2Vec (??)



Retrait des engineered features : le modèle était déjà bien trop performant pour voir l'apport de node2vec (99,9% d'accuracy)

	TN	FP	FN	TP
Sans	83781.8	1.8	1.4	8670.9
Avec	83742.4	3.1	3.3	8707.2

Difficultés rencontrées et résultats(2)

Retrait des features
et nouvel essai



Node2Vec n'apporte
aucune amélioration, ni
détérioration



Remise en question des
données et de la
méthode

Explication



Données générées par
un DT

Peu d'informations de
type graphe?

Features de node2vec
inutiles?

Difficultés rencontrées et résultats(3)

Obtention d'une nouvelle base de données, reflétant mieux des possibles habitudes de consommations



Mais...

	TN	FP	FN	TP
Sans Node2vec	59693.4 [59676.2, 59710.5]	49.7 [47.9, 51.6]	52.2 [50.1, 54.3]	6757.7 [6740.2, 6775.2]
Simple	59724.4 [59679.6, 59769.2]	48.9 [43.0, 54.8]	53.7 [48.3, 59.1]	6726.0 [6678.1, 6773.9]
BP	59651.4 [59605.5, 59697.3]	51.5 [47.4, 55.6]	57.0 [52.6, 61.4]	6793.1 [6748.9, 6837.3]
BP pondéré	59698.7 [59647.3, 59750.1]	54.7 [49.6, 59.8]	53.8 [49.1, 58.5]	6745.8 [6697.9, 6793.7]
BP-seq	59682.0 [59641.6, 59722.4]	52.2 [46.1, 58.3]	54.0 [49.9, 58.1]	6764.8 [6727.0, 6802.6]
BP-seq pondéré	59707.06 [59688.9, 59725.2]	49.54 [47.3, 51.8]	50.76 [48.6, 52.9]	6745.64 [6727.4, 6763.9]

Analyse détaillée de Node2Vec


Essais sur les features générées par node2vec uniquement



Modélisation "Simple" est de loin la plus performante



Donne de "bons" résultats sans les features de la base de données:
Node2vec fonctionne-t-il?




Un calcul de temps d'exécution montre que la classification se fait sans vraiment "regarder" les features générées par node2vec.

	TN	FP	FN	TP
Simple	59385.2	360.7	414.8	6392.3
BP	52845.1	6900.3	5811.2	996.4
BP pondéré	52885.6	6852.2	5813.4	1001.8
BP-seq	53773.4	6001.9	5225.2	1552.5
BP-seq pondéré	53097.8	6633.2	5688.6	1133.4
BP-seq pondéré (p = 2)	53583.3	6157.4	5379.0	1433.3

Simple > BP-seq > BP-seq pondéré > BP

Si node2vec seul fonctionne si bien, peut-on construire un **méta classifieur**?

Méta-classification



Pour modèle simple:
Pour les autres modèles:

1330
5900-600

5497
800-900

55
7000-7100

Méta classification
envisageable



	TN	FP	FN	TP	$G_{FP}(\%)$	$P_{FN}(\%)$	Eff
Sans Node2vec	59693.4 [59676.2, 59710.5]	49.7 [47.9, 51.6]	52.2 [50.1, 54.3]	6757.7 [6740.2, 6775.2]			
Simple	59699.0 [59621.1, 59776.9]	31.4 [28.2, 34.6]	1355.2 [1320.2, 1390.2]	5467.4 [5411.6, 5523.2]	36.8	2500	67.9
BP	59690.7 [59633.5, 59747.9]	8.7 [6.2, 11.2]	5994.1 [5939.1, 6049.1]	859.5 [838.3, 880.7]	82.5	11400	138
BP pondéré	59762.9 [59724.5, 59801.3]	9.1 [6.7, 11.5]	5915.7 [5878.5, 5952.9]	865.3 [854.2, 876.4]	81.7	11200	137
BP-seq	59776.0 [59711.7, 59840.3]	5.9 [4.3, 7.5]	5957.4 [5894.1, 6020.7]	813.7 [795.2, 832.2]	88.1	11300	128
BP-seq pondéré	59765.0 [59716.9, 59813.1]	8.6 [6.8, 10.4]	5923.5 [5874.1, 5972.9]	855.9 [847.5, 864.3]	82.7	11200	135

Est-ce meilleur qu'une sélection aléatoire?
Quel seuil d'efficacité choisir?

$$G_{FP} = \frac{FP - FP_M}{FP}$$

$$P_{FN} = \frac{FN_M - FN}{FN}$$

Conclusion

- ✓ Etude approfondie de 2 algorithmes: **Node2Vec** & **GraphSAGE**
- ✓ **Modélisation** d'un jeu de transactions sous forme de Graphe:
 - ✓ Simple
 - ✓ Bipartite
 - ✓ Bipartite-séquencé
- ✓ **Expérimentation** de Node2Vec sur les modèles de graphe et **amélioration partielle** du processus de classification des transactions
- ✓ **Mesure** de l'augmentation partielle de performance
- ✓ Travail sur la **visualisation** des graphes et de Node2Vec

Pistes pour le futur

Explorer
GraphSAGE

Neo4J pour une
visualisation des
données dynamique

D'autres
méthodes : analyse
spectrale des
graphes