

Couverture par Ensembles Flous et Maximum d'Influence en Marketing Viral

MARAMI 2015

14-16 octobre 2015

Stefan Janaqi – LGI2P-EMA



Couverture par Ensembles Flous et Maximum d'Influence

Plan

1. Définitions et problème
2. Complexité
3. Influence et couverture par ensembles flous
4. Résultats

Graphe d'Influence

$$G = (V, E, w)$$
$$w: E \rightarrow R$$



Modèle de Diffusion

D = Linear Threshold

$$\text{si } \sum_{u-\text{actif}} w(u, v) \geq t(v)$$

alors v devient actif

$t(v) =$ Seuil d'activation de v .

Couverture par Ensembles Flous et Maximum d'Influence

1. Définitions et problème

Soit $I \subseteq V$ un ensemble initial de sommets **actifs**

$p(v | I) \equiv p(v | I, D, G)$ la probabilité pour v de devenir actif à partir de I , par le modèle de diffusion D , dans le réseau G .

Variables Aléatoires $x(v), v \in V$

v	Inactif	Actif
$x(v)$	0	1
$p(x(v))$	$1 - p(v I)$	$p(v I)$

$$X = \sum_{v \in V} x(v)$$

Cardinalité d'ensemble actif final.
Variable aléatoire.

$$f(I) = E(X) = \sum_{v \in V} E(x(v)) = \sum_{v \in V} p(v | I)$$

Problème. Trouver I maximisant $f(I)$

NP – Difficile
Heuristique Glouton

Couverture par Ensembles Flous et Maximum d'Influence

2. Complexité

EnsembleInitialViralGlouton(G, D, k)

Entrée: G – graphe d'influence ; D – méthode de diffusion
 k – cardinalité d'ensemble initial;

Retourne: I – ensemble viral initial

1. $I \leftarrow \emptyset$

2. tantque $|I| < k$

3. trouver $u^* \leftarrow \operatorname{argmax}_{u \in V \setminus I} (f(I \cup u))$

4. $I \leftarrow I \cup u^*$

5. fintantque

Sous modularité, Monotonie

$$(i) f(\emptyset) = 0$$

$$(ii) A \subseteq B \subseteq V \rightarrow f(A) \leq f(B)$$

$$(iii) A, B \subseteq V, \\ f(A \cup B) + f(A \cap B) \leq f(A) + f(B)$$

Intérêt. [Nem 78] Si $f(I)$ est sous modulaire et monotone alors

$$\left(1 - \frac{1}{e}\right) f(I_{opt}) \leq f(I) \leq f(I_{opt})$$

Linear Threshold [GRA 78, KEM 03] – f est sous modulaire et monotone

RUC [LAG 13a] – f n'est pas sous modulaire.

Couverture par Ensembles Flous et Maximum d'Influence

2. Complexité

1. Calcul de $f(I)$ difficile;
2. Approximation par Monte Carlo
3. Vitesse $1/\sqrt{R}$
4. $N_{LT} \leq R(nm + 2(n + 1)^2 - 1) \sim O(Rnm)$
5. Calcul de I par l'algorithme glouton

$$H \times N_{LT}, H = \sum_{k=0}^{|I|-1} (n - k)$$

$$T_{LT} \sim O(|I| R n^2 m)$$

$$R \approx 10^4, n, m \approx 10^5 \rightarrow T_{LT} \sim O(10^{20}) !!!$$


LinearThresholdDiffusion (G, b, R, S, A)

```
1.  $f(A) \leftarrow 0$ 
2. faire pour  $r \leftarrow 1 \dots R$ 
3.    $t \leftarrow \text{rand}(1, n)$  // seuil aléatoire uniforme de chaque sommet
4.    $A_s \leftarrow A$ 
5.   faire pour  $s \leftarrow 1 \dots S$ 
6.     faire pour  $u \in V \setminus A_s$ 
7.        $\text{infl}(u) \leftarrow \sum_{v \in N^-(u) \cap A_s} w(v, u)$ 
8.     finpour
9.     faire pour  $u \in V \setminus A_s$ 
10.      si  $\text{infl}(u) \geq t(u)$  alors  $A_s \leftarrow A_s \cup u$ 
11.    finpour
12.     $f(A) \leftarrow f(A) + |A_s|/R$ 
13.  finpour
14. finpour
```

Couverture par Ensembles Flous et Maximum d'Influence

3. Influence et couverture par ensembles flous

1. La recherche du premier meilleur sommet nécessite le calcul de $f(u), u \in V$;
2. Soit \mathbf{P} la matrice $n \times n$ avec $\mathbf{P}(v, u) = p(v|\{u\})$;
3. Information d'ordre 1;
4. Calcul de $\mathbf{P} : n \times N_{LT}$ opérations;
5. Recherche d'un « bon » ensemble initial à partir de \mathbf{P} ;
6. Chaque colonne de \mathbf{P} peut être vue comme un degré d'appartenance d'un ensemble flou;




Couverture par Ensembles Flous et Maximum d'Influence


3. Influence et couverture par ensembles flous

Opérations standards avec ensembles flous \mathbf{p}, \mathbf{q} ;


1. $NOT_{frou}(\mathbf{p}) = 1 - \mathbf{p}$; n opérations;
2. $OR_{frou}(\mathbf{p}, \mathbf{q}) = \max(\mathbf{p}, \mathbf{q})$; n opérations;
3. $AND_{frou}(\mathbf{p}, \mathbf{q}) = \min(\mathbf{p}, \mathbf{q})$; n opérations;
4. $CARD_{frou}(\mathbf{p}) = \sum_{v \in V} \mathbf{p}(v)$; n opérations;




2 ensembles flous



NOT flou



OR flou



AND flou

Couverture par Ensembles Flous et Maximum d'Influence

3. Influence et couverture par ensembles flous

Intérêt des ensembles flous.

Propriété 1. Pour tout $I \subseteq V$, $p(v | I) \geq OR_{flou}\{p(v | \{i\}), i \in I\}$;

Propriété 2. Pour tout $I \subseteq V$, $f(I) \geq g(I) = \sum_{v \in V} OR_{flou}\{p(v | \{i\}), i \in I\}$ et cette borne est **exacte**.

Propriété 3. La fonction $g(I)$ est sous modulaire et monotone croissante, **indépendamment** de la méthode de diffusion ayant généré la matrice P .

Conséquence

1. Chercher $I \subseteq V$ maximisant $g(I) \leq f(I)$;
2. NP – Difficile, cas particulier du SET COVER PROBLEM ;
3. Algorithme glouton avec garantie pour $g(I)$;
4. Faible complexité.

Couverture par Ensembles Flous et Maximum d'Influence

3. Influence et couverture par ensembles flous

GloutonCouvertureEnsembleFlou (P, k)

Entrée: P – Colonnes $P_u = p(v | \{u\})$; k – cardinalité d'ensemble initial;

Retourne: I – ensemble viral initial

1. $I \leftarrow \emptyset$; $\mathbf{v} \leftarrow \mathbf{1}_{n \times 1}$; $\mathbf{c} \leftarrow \mathbf{0}_{n \times 1}$
2. **tantque** $|I| < k$
3. **trouver** $u^* \leftarrow \operatorname{argmax} \left(\operatorname{CARD}_{flou} \left(\operatorname{AND}_{flou} (\mathbf{v}, P_u) \right) \right), u \in V \setminus I$;
4. $I \leftarrow I \cup u^*$;
5. $\mathbf{c} \leftarrow \operatorname{OR}_{flou} (\mathbf{c}, P_{u^*})$
6. $\mathbf{v} \leftarrow \operatorname{AND}_{flou} (\mathbf{v}, \operatorname{NOT}_{flou} (\mathbf{c}))$
7. **fantantque**

Gain en complexité

1. Complexité $O(|I|n^2)$
2. Gain $(H - n)N_{LT}$, où, $H - n = \sum_{k=1}^{|I|-1} (n - k) \sim O(|I| n)$ et $N_{LT} \sim O(R m n)$
3. Gain $\sim O(R m)$

Couverture par Ensembles Flous et Maximum d'Influence

4. Résultats, Expérimentations



Graphes Jouets

1. Graphes planaires $G = (V, E, w)$, $G_{a \times b_C_4De_44}$

Grphe de Co Auteurs

1. AUTH_82999 = (V, E, w) , $|V| = 82999$;
2. Pour chaque auteur A la liste $L(A)$ (les indices) de ses publications est fournie (43000 publications au <http://www.ncbi.nlm.nih.gov/pubmed>)
3. l'influence d'un auteur A sur un auteur B

$$w(A, B) = k(A) \frac{|L(A) \cap L(B)|}{|L(B)|}$$



Couverture par Ensembles Flous et Maximum d'Influence

4. Résultats et Expérimentations

Espérance $f(I)$ pour $|I| = 30$ avec le modèle de diffusion LT. I étant choisi par une des 5 méthodes : Random; MaxDeg; MinDist; Glouton f; Glouton g.


$ I = 30$	Random	MaxDeg	MinDist	Glouton $f(I)$	Glouton $g(I)$
G_10x10_C_4_D_44	33	45	38	61	59
G_10x10_C_8_D_44	38	46	37	60	59
G_20x20_C_4_D_44	49	56	43	89	89
G_20x20_C_8_D_44	61	85	45	114	110
AUTH_82999	493	1235*	1224*	1256*	1255*

* - les 30 sommets de I sont sélectionnés parmi une Top_List de 500 sommets prometteurs.

Couverture par Ensembles Flous et Maximum d'Influence

4. Résultats et Expérimentations

Comparaison des espérances $f(I)$ pour $|I| = 1, \dots, 30$



MERCI !
QUESTIONS ?