

Graph based parsing

GBP

Graph based Parsing

- Les structures à prédire dans le cadre de l'analyse en dépendance sont des graphes (arbres de dépendances).
- Peut-on prédire directement le graphe correspondant à une phrase?
- Au cœur de GBP, la **fonction de score** d'un arbre de dépendance $T = (V, A) \in \mathcal{T}(S)$:

$$\lambda(T) = \lambda(V, A) \in \mathbb{R}$$

- Etant donné une phrase S , on cherche l'arbre $\hat{T}$ de score maximal

$$\hat{T} = \arg \max_{T \in \mathcal{T}(S)} \lambda(T)$$

Différences clefs avec Transition based Parsing

- On prédit directement la structure finale et pas les actions qui permettront de construire le graphe.
 - Pas besoin de décomposer un arbre en séquence de configurations et transitions à l'aide d'un oracle.
- Méthode exacte : on produit l'arbre qui maximise la fonction score
 - Considérer l'ensemble $\mathcal{T}(S)$ de tous les arbres possibles d'une phrase S sans énumérer les éléments de l'ensemble.

Schéma général

- 1 Définir une fonction de factorisation d'un arbre T ($\Psi(T)$)
- 2 Définir une fonction de score $\lambda(\psi)$ pour un facteur ψ
- 3 Définir une fonction de score $\lambda(T)$ pour un arbre T
- 4 Choisir un algorithme d'analyse

$$\hat{T} = \arg \max_{T \in \mathcal{T}(S)} \lambda(T)$$

Notations

- $S = w_0 w_1 \dots w_n$ une phrase
- $T = (V, A)$ un arbre de dépendances
- $\mathcal{T}(S)$ l'ensemble des arbres possibles pour la phrase S
- $\Psi(T)$ ensemble des facteurs d'un arbre T
- $\Psi(S)$ ensemble des facteurs potentiels d'une phrase S
- $\mathcal{L} = \{l_1 \dots l_m\}$ ensemble des étiquettes des relations syntaxique

Décomposition en facteurs

- On ne peut estimer directement le score d'un arbre à partir des données car la probabilité d'occurrence d'un arbre particulier est, en général, nulle.
- On décompose un arbre en **facteurs** à l'aide d'une fonction de factorisation.


$$\Psi(T) = \{\psi_1, \dots, \psi_q\}$$

- Le score d'un arbre est une fonction du score de ses facteurs

Fonction de factorisation

- Cas le plus simple : modèles d'ordre 1 ($\Psi_1(T)$)
 - un facteur correspond à une dépendance.
 - un arbre comportant n nœuds comporte $n - 1$ dépendances donc $n - 1$ facteurs ($O(n)$)
- modèles d'ordre 2 ($\Psi_2(T)$) :
 - les facteurs sont composés de deux dépendances
 - plusieurs manières de combiner deux dépendances au sein d'un facteur
 - Grand parents : $A \rightarrow B \rightarrow C$
 - Frères : $A \leftarrow B \rightarrow C$

Exemple



Facteurs d'une phrase

- Les facteurs d'une phrase $\Psi(S)$ est l'ensemble de tous les facteurs de tous les arbres possibles de S

$$\Psi(S) = \bigcup_{T \in \mathcal{T}(S)} \Psi(T)$$

- On a en général

$$|\Psi(S)| \ll |\mathcal{T}(S)|$$

- Etant donné une phrase S de longueur n :
 - $|\Psi_1(S)|$ est une fonction quadratique de n
 - $|\Psi_2(S)|$ est une fonction cubique de n
- On se limitera ici aux modèles d'ordre 1.

Facteurs d'une phrase

- Les facteurs d'ordre 1 de la phrase S peuvent être stockés dans une table $\lambda_1[g][d][l]$
- avec :
 - $1 \leq g \leq n$ l'indice du gouverneur
 - $1 \leq d \leq n$ l'indice du dépendant
 - $1 \leq l \leq |\mathcal{L}|$ une étiquette de dépendance
- Le remplissage de λ_1 est réalisé en $O(n^2)$

Score des facteurs d'ordre 1

- Le score des facteurs est calculé à l'aide d'un classifieur.
- Ce dernier prend en entrée un couple (paire ordonnée) de mots (g, d) et calcule une distribution de probabilités sur l'ensemble des étiquettes.
- La probabilité p_l associée à l'étiquette l est interprétée comme le score $\lambda((g, l, d))$ de la dépendance (g, l, d) .

Fonction de décomposition (Feature function)

- Une feature représente un aspect d'un couple de mots (g, d) qui semble intéressant pour prédire l'existence d'une dépendance entre g et d .
- Exemples
 - la forme de g ou de d
 - la partie de discours de g ou de d
 - la distance entre g et d dans la phrase
 - ...
- La fonction de décomposition représente une couple de mots (g, d) sous la forme d'un vecteur de features.

$$f_D : V_S \times V_S \rightarrow \mathcal{X}$$

- Le vecteur de features constitue l'entrée du classifieur.

Score d'un arbre

- le score d'un arbre est une fonction des scores de ses facteurs

$$\lambda(T) = f(\lambda(\psi_1), \dots, \lambda(\psi_q)) \quad \forall \psi_i \in \Psi(T)$$

- f peut prendre n'importe quelle forme, on utilisera ici une simple somme :

$$\lambda(T) = \sum_{\psi \in \Psi(T)} \lambda(\psi)$$

Recherche de $\hat{T}$


Deux familles de méthodes :

- Analyse par recherche de l'arbre couvrant maximal (Maximum Spanning Tree)
 - Algorithme de Chu-Liu-Edmonds
- Programmation dynamique
 - Algorithme CYK
 - variante de Eisner


Arbre couvrant maximal

- Etant donné :
 - un graphe orienté $G = (V, A)$
 - une fonction λ associant un poids à chaque arc de A
- Un arbre couvrant de G est un sous-graphe $G' = (V', A')$ tel que
 - $V' = V$
 - G' est un arbre orienté
- Un arbre couvrant maximal de G est
 - un arbre couvrant de G de poids maximal
 - où le poids d'un sous-graphe est la somme des poids de ses arcs
- En général, la recherche d'un arbre couvrant maximal ne peut être faite de manière triviale en énumérant les arbres couvrants de G car ils sont trop nombreux!


Exemple




Exemple



Exemple




Exemple



SCORE = 22

Exemple




SCORE = 23

Algorithme de Chu-Liu-Edmonds : Idée générale

Tout nœud qui n'est pas la racine r doit avoir exactement un arc entrant


- Choisir pour chaque sommet (sauf r) l'arc entrant de poids maximal
- Si la structure produite est un arbre, on s'arrête
- Sinon, elle contient un cycle C
- Choisir un arc entrant pour C
- le choix de l'arc entrant de C élimine un arc de C

Algorithme de Chu-Liu-Edmonds




On choisit pour chaque sommet
l'arc entrant de poids maximal

Algorithme de Chu-Liu-Edmonds




On choisit pour chaque sommet
l'arc entrant de poids maximal

Algorithme de Chu-Liu-Edmonds




On a de la chance, le résultat est un arbre

Algorithme de Chu-Liu-Edmonds



On modifie le poids de l'arête $b \rightarrow c$, qui valait 12 et qui vaut maintenant 16.

Algorithme de Chu-Liu-Edmonds





Pas de chance, il y a maintenant un cycle!

Elimination d'un cycle

- Pour casser le cycle, on enlève un arc de ce dernier et on rattache un des sommets du cycle à l'extérieur.
- Deux possibilités :
 - On rattache c à l'extérieur.
 - On a le choix de le rattacher à r ou à a
 - On le rattache à r car $r \xrightarrow{14} c$ alors que $a \xrightarrow{10} c$
 - $r \xrightarrow{14} c \xrightarrow{20} b$
 - le choix de $r \rightarrow c$ élimine $b \rightarrow c$
 - le score vaut alors 34
 - On rattache b à l'extérieur.
 - On a le choix de le rattacher à r ou à a
 - On le rattache à r car $r \xrightarrow{8} b$ alors que $a \xrightarrow{4} b$
 - $r \xrightarrow{8} b \xrightarrow{16} c$
 - le choix de $r \rightarrow b$ élimine $c \rightarrow b$
 - le score vaut alors 24

Deux solutions




- On choisit celle de gauche qui vaut 50 alors que celle de droite vaut 40
- Pour comparer les solutions, on compare :
poids de l'arc ajouté - poids de l'arc éliminé
- Ici : $14 - 16 > 8 - 16$
- Mais : l'élimination d'un cycle peut en créer un nouveau !

CLE : initialisation

- On part d'un graphe orienté pondéré
- Chaque sommet possède un arc entrant à partir de tous les autres sommets
- Sauf le sommet racine (r) qui ne possède pas d'arc entrant
- Le tableau MAE (Meilleur Arc Entrant) stocke, pour chaque sommet, l'arc entrant de meilleur poids
- Le tableau ELIMINE indique, pour chaque arc entrant d'un sommet d'un cycle, l'arc du cycle avec lequel il est incompatible


- Pour tout sommet $v \neq r$, $MAE[v]$ = arc entrant de meilleur poids.
- Si un cycle C a été créé :
 - **contracter** les sommets de C sous la forme d'un nouveau sommet v_C
 - les arcs sortants des sommets de C sortent maintenant de v_C
 - les arcs entrants des sommets de C entrent maintenant en v_C
 - pour tout sommet u de C et pour chaque arc a entrant en u depuis l'extérieur de C :
 - $ELIMINE[a] = MAE[u]$
 - $score[a] = score[a] - score[ELIMINE[a]]$
- répéter jusqu'à ce que tout sommet (sauf la racine) possède un arc entrant et qu'aucun cycle n'est créé.

Exemple




MAE		élimine	
v_1		a	
v_2		b	
v_3		c	
		d	
		e	
		f	
		g	
		h	
		i	

On traite v_1



MAE		élimine	
v_1	g	a	
v_2		b	
v_3		c	
		d	
		e	
		f	
		g	
		h	
		i	


On traite v_2



■ Création d'un cycle

MAE		élimine	
v_1	g	a	
v_2	d	b	
v_3		c	
		d	
		e	
		f	
		g	
		h	
		i	


Contraction $\{v_1, v_2\}$



MAE		élimine	
v_1	g	a	g
v_2	d	b	
v_3		c	
		d	
		e	
		f	
		g	
		h	g
		i	

- Traitement des arcs entrant en v_1 de l'extérieur du cycle
- Mise à jour des poids des arcs


Contraction $\{v_1, v_2\}$



MAE		élimine	
v_1	g	a	g
v_2	d	b	d
v_3		c	
		d	
		e	
		f	
		g	
		h	g
		i	d


- Traitement des arcs entrant en v_2
- Mise à jour des poids des arcs

Contraction $\{v_1, v_2\}$




MAE		élimine	
v_1	g	a	g
v_2	d	b	d
v_3		c	
v_4		d	
		e	
		f	
		g	
		h	g
		i	d

On traite v_3



MAE		élimine	
v_1	g	a	g
v_2	d	b	d
v_3	f	c	
v_4		d	
		e	
		f	
		g	
		h	g
		i	d


On traite v_4



■ création d'un cycle

MAE		élimine	
v_1	g	a	g
v_2	d	b	d
v_3	f	c	
v_4	h	d	
		e	
		f	
		g	
		h	g
		i	d


Contraction $\{v_3, v_4\}$



■ création d'un cycle


MAE		élimine		
v_1	g	a	g	h
v_2	d	b	d	h
v_3	f	c		f
v_4	h	d		
v_5		e		
		f		
		g		
		h	g	
		i	d	

Contraction $\{v_3, v_4\}$




MAE		élimine		
v_1	g	a	g	h
v_2	d	b	d	h
v_3	f	c		f
v_4	h	d		
v_5		e		
		f		
		g		
		h	g	
		i	d	

On traite v_5



MAE		élimine		
v_1	g	a	g	h
v_2	d	b	d	h
v_3	f	c		f
v_4	h	d		
v_5	a	e		
		f		
		g		
		h	g	
		i	d	

Fin de la contraction




MAE		élimine		
v_1	g	a	g	h
v_2	d	b	d	h
v_3	f	c		f
v_4	h	d		
v_5	a	e		
		f		
		g		
		h	g	
		i	d	

Expansion

- A l'issue de la contraction, tout sommet s possède un meilleur arc entrant $e = MAE(s)$
- Le choix de e élimine un arc au sein d'un cycle, permettant de le casser
- Parcourir les arcs de MAE dans l'ordre inverse de leur ajout : (a, h, f, d, g)
- Pour tout arc e parcouru, choisir e et éliminer les arcs incompatibles avec e


On traite v_5 (l'arc a)



MAE		élimine		
v_1	$\mathbf{a}(g)$	a	g	h
v_2	d	b	d	h
v_3	f	c		f
v_4	$\mathbf{a}(h)$	d		
v_5	a	e		
		f		
		g		
		h	g	
		i	d	


- On élimine g et h , qui sont incompatibles avec a
- On fait l'expansion de v_5

Expansion de v_5




MAE		élimine		
v_1	$\mathbf{a}(g)$	a	g	h
v_2	d	b	d	h
v_3	f	c		f
v_4	$\mathbf{a}(h)$	d		
v_5	a	e		
		f		
		g		
		h	g	
		i	d	

On traite v_4



MAE		élimine		
v_1	$\mathbf{a}(g)$	a	g	h
v_2	d	b	d	h
v_3	f	c		f
v_4	$\mathbf{a}(h)$	d		
v_5	a	e		
		f		
		g		
		h	g	
		i	d	

Expansion de v_4



MAE		élimine		
v_1	$\mathbf{a}(g)$	a	g	h
v_2	d	b	d	h
v_3	f	c		f
v_4	$\mathbf{a}(h)$	d		
v_5	a	e		
		f		
		g		
		h	g	
		i	d	

Application de l'algorithme CLE au problème de l'analyse

Etant donné une phrase S :

- 1 On construit le multigraphe de dépendance $G(S)$
- 2 On réduit le multigraphe de dépendance à un graphe de dépendance $G'(S)$
- 3 On exécute l'algorithme CLE sur $G'(S)$

Graphe d'une phrase

- Etant donné :
 - une phrase $S = w_0 \dots w_n$,
 - un ensemble d'étiquettes syntaxiques $\mathcal{L} = \{l_1, \dots, l_m\}$
- on définit le *graphe de dépendance* de S , noté $G(S)$, le graphe orienté étiqueté (V_S, A_S) , de la manière suivante :
 - $V_S = \{w_0, \dots, w_n\}$
 - $A_S = \{(w_i, l, w_j) \mid \forall w_i, w_j \in V_S \text{ et } l \in \mathcal{L}, \text{ avec } i \neq j \text{ et } j \neq 0\}$
- les poids des arcs sont définis de la façon suivante :
$$\lambda(w_i, l, w_j) = \lambda_1[w_i][w_j][l]$$
- Notes :
 - $G(S)$ est un multigraphe : il existe entre deux sommets autant de dépendances qu'il existe d'étiquettes syntaxiques.
 - $G(S)$ est un graphe complet pour l'ensemble de sommets $V_S - \{w_0\}$
 - il existe un arc depuis w_0 vers tous les autres sommets.

Réduction d'un multigraphe à un graphe

- L'algorithme CLE est défini sur un graphe orienté
- Or le graphe $G(S)$ est un *multigraphe* : il existe entre deux sommets autant de dépendances qu'il existe d'étiquettes syntaxiques.
- Il est possible de réduire le multigraphe en un graphe orienté $G'(S) = (V'_S, A'_S)$ de la manière suivante
 - $V'_S = V_S$
 - $A'_S = \{(w_i, w_j) \mid \forall w_i, w_j \in V_S, \text{ avec } i \neq j \text{ et } j \neq 0\}$
- $G'(S)$ est aussi un graphe complet, mais avec un seul arc entre deux sommets
- On définit les poids des arcs de A'_S de la façon suivante :

$$\lambda(w_i, w_j) = \max_{l \in \mathcal{L}} \lambda(w_i, l, w_j)$$

Exercice

On souhaite analyser le groupe prépositionnel *sur la route* avec l'algorithme de Chu-Liu-Edmonds. Les poids des dépendances sont représentés dans la matrice ci-dessous, où les lignes correspondent aux gouverneurs et les colonnes aux dépendants (la dépendance (ROOT, sur), par exemple, vaut -2).

	ROOT	sur	la	route
ROOT	0	-2	0	1
sur	0	0	0	2
la	0	0	0	0
route	0	2	1	0

- 1 Dessinez le graphe complet sur lequel se fera la recherche de l'arbre couvrant.
- 2 Dessinez tous les arbres couvrants et calculez leur poids.
- 3 Retrouvez l'arbre optimal à l'aide de l'algorithme CLE.