



APPRENTISSAGE DE GRAMMAIRES CATEGORIELLES DE MODULES

Travail de recherche fait par:

Camilo Thorne

Sous la direction de:

M. D. BECHET (LIPN)

Villetaneuse, le 1er octobre 2004.



Structure de la présentation

- Notions générales.
- Grammaires de modules étiquetées.
- Résultats: apprentissage de grammaires de modules étiquetées.



Définition – grammaires catégorielles

➤ Une grammaire catégorielle est un triplet

$$\mathbf{G} = \langle \Sigma, \delta, \mathbf{S} \rangle \text{ avec :}$$

- Σ un alphabet fini (ou lexique).
- $\delta : \Sigma \rightarrow \mathbf{P}_f(\mathbf{T})$ une fonction finie.
- \mathbf{S} le type des phrases bien formées.



Caractères généraux

- Leur système de types, **LC** (ou **MINCLL**), relève de la logique linéaire.
 - C'est un formalisme faiblement équivalent à celui des grammaires hors-contexte (Kanazawa, 1998).
- L'analyse syntaxique se fait via un arbre ou réseau de preuve pour **MINCLL**.

Le langage engendré par une grammaire catégorielle

$$s = m_1 \dots m_n \in \mathbf{L}(G)$$

\Leftrightarrow_{df}

- ils existent n types A_1, \dots, A_n assignés par δ tels que le séquent $A_1, \dots, A_n \vdash S$ est démontrable dans **MINCLL**



Apprentissage – conditions suffisantes

Densité finie bornée

⇒ (1)

Élasticité finie

⇒ (2)

Apprenabilité

(1) Shinohara, 1990.

(2) Kanazawa, 1998.

Densité finie bornée

- C'est une propriété des systèmes grammaticaux $\mathbf{GS} = \langle \mathbf{S}^*, \mathbf{GK}, \mathbf{L} \rangle$ associés à une classe \mathbf{GK} de grammaires.
- Elle implique, pour chaque $n \in \mathbb{N}$, que la classe $\{\mathbf{L}(\mathbf{G}) \mid \mathbf{G} \in \mathbf{GK}, t(\mathbf{G}) \leq n \text{ et } \mathbf{G} \text{ est réduite par rapport à } X \subseteq \mathbf{S}^* \text{ fini}\}$ a une élasticité finie.

Élasticité finie

- C'est une propriété d'une classe L de langages sur un alphabet Σ .
- Quand on fait le lien avec une classe GK de grammaires, elle implique l'existence d'un algorithme d'apprentissage φ_{GK} pour GK .



Apprenabilité

Une classe GK est apprenable lorsqu'il existe un algorithme φ_{GK} d'apprentissage pour cette classe.

Grammaires de modules étiquetées


- Ce sont des grammaires ayant un alphabet « enrichi » avec des informations syntaxiques: des modules. Leur alphabet est donc une partie de $\Sigma \times \mathbf{M}$.
- Si on prend pour alphabet $\Sigma_{\text{mod}} = \Sigma \times \mathbf{M}$ on a affaire à \mathbf{GC}_{mod} , aux grammaires étiquetées d'alphabet infini.
- Si on prend comme alphabet $\Sigma_{\text{modf}} \subset \Sigma \times \mathbf{M}$ finie on a affaire à $\mathbf{GC}_{\text{modf}}$, aux grammaires étiquetées d'alphabet fini.

Un exemple

- Voici une grammaire étiquetée d'alphabet fini (défini implicitement par δ):
- Soit G_0 la grammaire de modules avec δ définie par:


$N \cdot \bullet$
chat \mapsto $N \cdot \bullet$

Un exemple



le

|→



(SN o- N)⁻

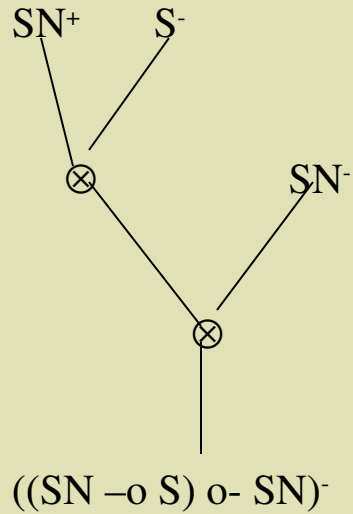
N⁻•

escalier

|→


N⁻•

Un exemple



monte


\mapsto



- On peut montrer que « Le chat monte l'escalier » $\in \mathbf{L}(G_0)$.

- On obtient un réseau de preuve planaire:

Un exemple



Résultats

- $L(\mathbf{GC}_{\text{modf}})$ a une élasticité finie. Donc $\mathbf{GC}_{\text{modf}}$ est apprenable.
- Ils existent des sous-classes apprenables de \mathbf{GC}_{mod} , car le système \mathbf{GS}_{mod} a une densité finie bornée.
 - $L(\mathbf{GC}_{\text{mod}})$ a une élasticité infinie.



Quelques références

- Kanzawa. Learnable classes of Categorical Grammars. 1998.
- Béchet. Incremental Parsing of Lambek Calculus Using Proof-Net Interphases. 2002.
- Shinohara. Inductive Inference from Positive Data is Powerful. 1990.
- Lambek. The Mathematics of Sentence Structure. 1958.
- Tiede. Deductive Systems and Grammars. Proofs as Grammatical Structures. 1999.

Théorèmes cités

- **THEO**. Soit **GK** une classe de grammaires. Si $L(\mathbf{GK})$ a une élasticité finie, alors **GK** est apprenable. (Kanazawa, 1998).
- **THEO**. Soit **GS** un système grammatical. Si **GS** a une épaisseur finie bornée, alors la classe $\{\mathbf{L}(\mathbf{G}) \mid \mathbf{G} \in \mathbf{GK}, t(\mathbf{G}) \leq n \text{ et } \mathbf{G} \text{ est réduite par rapport à } X\}$ a une élasticité finie. (Shinohara, 1990).
- **THEO**. Un séquent $\Gamma \vdash A$ est démontrable en **MINCLL** avec contexte vide éventuellement vide \Leftrightarrow il existe un réseaux de preuve planaire pour $\vdash \Gamma^-, A^+$. (Retoré, 1996).



Annexe 1: apprentissage

Définition – apprentissage

- Une classe **GK** de grammaires est apprenable à partir d'exemples positifs

\Leftrightarrow_{df}

Il existe un algorithme d'apprentissage φ_{GK} , i.e. un algorithme qui converge à terme vers une certaine grammaire $G \in GK$ en ayant comme entrée l'énumération d'un $L \in L(GK)$ quelconque.

Définition - algorithme d'apprentissage

➤ Soit **GK** une classe de grammaires. On dit que l'algorithme φ_{GK} apprend **GK**

$\Leftrightarrow_{\text{df}}$

$$\bullet \varphi_{\text{GK}} : \cup_{i \in \mathbb{N}} (S^*)^i \rightarrow \text{GK}$$

- pour toute grammaire **G** avec $L(\mathbf{G}) = \langle s_i \rangle_{i \in \mathbb{N}}$, il existent une grammaire **G'** et un entier n_0 tel que pour tout $n > n_0$,
 $\varphi_{\text{GK}}(\langle s_0, \dots, s_{n_0} \rangle) = \mathbf{G}'$ et $L(\mathbf{G}) = L(\mathbf{G}')$

Définition – élasticité finie

- Une classe L de langages sur un alphabet Σ a une élasticité finie

\Leftrightarrow_{df}

il n'existe pas de suites $\langle L_i \rangle_{i \in \mathbb{N}}$, $\langle s_i \rangle_{i \in \mathbb{N}}$ de langages et de chaînes sur Σ telles que, pour tout $i \in \mathbb{N}$:

- $s_i \notin L_i$
- $\{s_0, \dots, s_i\} \subseteq L_{i+1}$

Définition - systèmes grammaticaux

➤ Un système grammatical est un triplet

$\mathbf{GS} = \langle \mathbf{S}^*, \mathbf{GK}, \mathbf{L} \rangle$ avec:

- $\mathbf{S}^* \subseteq \Sigma^*$ un ensemble récursif de suites sur un alphabet Σ .
- \mathbf{GK} une classe de grammaires.
- $\mathbf{L} : \mathbf{GK} \rightarrow \mathbf{P}(\mathbf{S}^*)$ telle que, pour toute $\mathbf{G} \in \mathbf{GK}$,
 $\mathbf{L}(\mathbf{GK}) \subseteq \mathbf{S}^*$.

Définition – grammaire réduite par rapport à X

➤ Soit \mathbf{GS} un système grammatical. $\mathbf{G} \in \mathbf{GK}$ et $X \subseteq \mathbf{S}^*$ fini. \mathbf{G} est réduite par rapport à X

$\Leftrightarrow_{\text{df}}$

- $X \subseteq \mathbf{L}(\mathbf{G})$
- pour toute $\mathbf{G}' \in \mathbf{GK}$, si $\mathbf{G}' R \mathbf{G}$ et $\mathbf{G}' \neq \mathbf{G}$, alors
 $\neg[X \subseteq \mathbf{L}(\mathbf{G}')]$

Définition – densité finie bornée

➤ Un système grammatical **GS** a une densité finie bornée

\Leftrightarrow_{df}

- pour tout $i, j \in \mathbb{N}$, $G_i R G_j \Rightarrow L(G_i) \subseteq L(G_j)$ (L est croissante, R est l'ordre des grammaires)
- pour tout $n \in \mathbb{N}$, la classe $\{L(G) \mid G \in \mathbf{GK}, t(G) \leq n \text{ et } G \text{ est réduite par rapport à } X \subseteq S^* \text{ fini}\}$ est une classe finie.



Annexe 2: types

Grammaires de modules

➤ Ce sont des grammaires où l'on remplace l'ensemble **T** des types par **M** celui des modules de la logique linéaire. En effet, il se trouve que:

Existence d'un arbre d'analyse

$\Leftrightarrow (*)$

Existence d'un réseau de preuve planaire

(*) Retoré, 1996.

Le système de types

- L'ensemble des types est défini par la grammaire :

$$T ::= At \mid T \multimap T \mid T \circlearrowleft T \mid T \otimes T.$$

- Comme système de types on a un calcul de séquents, la logique linéaire multiplicative non commutative bilatère sans constantes ni opérateur \wp . **MINCLL**, pour abrégé.