

# Génération des multiensembles fréquents de sous-mots partitionnant un mot

Julien David   Lhouari Nourine

LIMOS - Université Blaise Pascal  
ANR DAG (ANR-09-EMER-003-01)

1er avril 2010

# Définition du problème

- **Données** : un alphabet  $\Sigma$ , un mot  $w \in \Sigma^+$ , un entier  $q$ .
- **Problème** : Engendrer toutes les partitions de  $w$  en sous-mots fréquents.

## Exemple

Soit le mot  $w = \text{aaabba}$  et un entier  $q = 2$ .

Les sous-mots  $a$  et  $ab$  permettent de partitionner  $w$  et chaque sous-mot apparait au moins  $q$  fois la partition.

# Motivations

- Algorithmique sur les mots.
- Log mining :
  - Restitution des corrélations dans une base de données,
  - Analyse de systèmes multiprocesseurs.

# Plan

- 1 Produit de mélange, multiensembles de mots
- 2 Graphe des multiensembles
- 3 Algorithme et complexité

# Ordre militaire

L'ordre militaire, ou ordre lexicographique gradué, sur les mots est défini comme suit :

$$\forall v, w \in \Sigma^*, v <_{mil} w \iff \begin{cases} |v| < |w| \\ \text{ou} \\ |v| = |w| \text{ et } v <_{lex} w \end{cases}$$

# Produit de mélange

Le **produit de mélange** de deux mots  $u$  et  $v$  est l'ensemble :

$$u \sqcup v = \{u_1 v_1 \dots u_n v_n \mid u_i, v_i \in \Sigma^* \text{ pour } 1 \leq i \leq n, \\ u = u_1 \dots u_n \text{ et } v = v_1 \dots v_n\}.$$

## Exemple

$$ab \sqcup bc = \{abbc, abcb, babc, bacb, bcab\}$$

# Produit de mélange

Le **produit de mélange** de deux mots  $u$  et  $v$  est l'ensemble :

$$u \sqcup v = \{u_1 v_1 \dots u_n v_n \mid u_i, v_i \in \Sigma^* \text{ pour } 1 \leq i \leq n, \\ u = u_1 \dots u_n \text{ et } v = v_1 \dots v_n\}.$$

Il est possible d'étendre cet opérateur :

$$\sqcup^{k+1} w = (\sqcup^k w) \sqcup w$$

$$\sqcup^0 w = \varepsilon$$

Soit un ensemble de mots  $X = \{w_1, \dots, w_n\}$

$$\bigsqcup X = w_1 \sqcup w_2 \sqcup \dots \sqcup w_n$$

# Sous-mots

Un mot  $v$  est un **sous-mot** d'un mot  $w$  si et seulement si

il existe un mot  $u \in \Sigma^*$  tel que  $w \in v \sqcup u$ .

Un ensemble  $X$  de sous-mots permet de partitionner un mot  $w$  si et seulement si

$$w \in \bigsqcup X$$

# Multiensembles de mots

Un **multiensemble de mots**  $\mathcal{M}$  est un couple  $\langle X, f \rangle$  tel que

- $X \in 2^{\Sigma^+}$  est l'ensemble de mots sous-jacent,
- $f : \Sigma^+ \mapsto \mathbb{N}$  associe à chaque mot sa multiplicité dans  $\mathcal{M}$ .

Soit un multiensemble  $\mathcal{M} = \langle X, f \rangle$ . On étend le produit de mélange aux multiensembles

$$\bigsqcup \mathcal{M} = \bigsqcup_{v \in X} (\bigsqcup^{f(v)} v).$$

# Multiensembles de mots

Un multiensemble  $\mathcal{M}$  de sous-mots permet de partitionner un mot  $w$  si et seulement si

$$w \in \bigsqcup \mathcal{M}$$

## Exemple

Soit le mot  $w = \mathit{bbabccbcab}$  et un entier  $q = 2$ , le multiensemble

$$\{(\mathit{ab}, 2), (\mathit{bc}, 3)\}$$

est une solution. En effet,

$$\mathit{abab} \in \bigsqcup^2 \mathit{ab}$$

$$\mathit{bccbc} \in \bigsqcup^3 \mathit{bc}$$

$$\mathit{bbabccbcab} \in \mathit{abab} \bigsqcup \mathit{bccbc}$$

# Multienssembles candidats

## Definition

Soient  $\mathcal{M} = \langle X, f \rangle$  un multiensemble,  $w \in \Sigma^+$  un mot et  $q \in \mathbb{N}$  un entier. On dit que  $\mathcal{M}$  est un **(w, q)-candidat** si :

- 1  $\forall v \in \Sigma^+$ , soit  $f(v) \geq q$  soit  $f(v) = 0$ ,
- 2 pour tout  $a \in \Sigma$ ,

$$\sum_{v \in X} (f(v) \times \|v\|_a) = \|w\|_a.$$

On note  $\mathfrak{M}_{w,q}$  l'ensemble des (w, q)-candidats.

# Multiensembles valides

## Definition

Un multiensemble  $\mathcal{M} = \langle X, f \rangle$  est **(w, q)-valide** si :

- 1  $\mathcal{M}$  est un  $(w, q)$ -candidat,
- 2 Le mot  $w$  appartient au produit de mélange de  $\mathcal{M}$

$$w \in \bigsqcup \mathcal{M}$$

On note  $\mathcal{M}_{w,q}$  l'ensemble des multiensembles  $(w, q)$ -valides.

On a

$$\mathcal{M}_{w,q} \subseteq \mathfrak{M}_{w,q}.$$

# Génération des solutions

## Méthode

Afin d'engendrer les multiensembles  $(w, q)$ -valides, on utilise la méthode suivante :

- on engendre exhaustivement et sans redondance les  $(w, q)$ -candidats,
- pour chaque candidat, on teste s'il s'agit d'un multiensemble  $(w, q)$ -valide.

On commence par présenter un ensemble d'opérateurs sur les multiensembles.

# Sommes de multiensembles

## Definition

Soient  $\mathcal{M}_1 = \langle X, f \rangle$  et  $\mathcal{M}_2 = \langle Y, g \rangle$  deux multiensembles.

La somme de  $\mathcal{M}_1$  et  $\mathcal{M}_2$ , notée  $\mathcal{M}_1 \oplus \mathcal{M}_2$ , est le multiensemble  $\mathcal{M} = \langle Z, h \rangle$  défini comme suit :

- $Z = X \cup Y$ ,
- pour tout  $z \in Z$ , on a  $h(z) = f(z) + g(z)$ .

## Exemple

$$\{(aa, 1), (ba, 4)\} \oplus \{(aa, 2), (bac, 3)\} = \{(aa, 3), (ba, 4), (bac, 3)\}$$

# Différence de multiensembles

## Definition

Soient  $\mathcal{M}_1 = \langle X, f \rangle$  et  $\mathcal{M}_2 = \langle Y, g \rangle$  deux multiensembles.

La différence de  $\mathcal{M}_1$  et  $\mathcal{M}_2$ , notée  $\mathcal{M}_1 \ominus \mathcal{M}_2$ , est le multiensemble  $\mathcal{M} = \langle Z, h \rangle$  défini comme suit :

- pour tout  $x \in X$ , on a  $h(z) = \max\{f(z) - g(z), 0\}$ .

## Exemple

$$\{(aa, 1), (ba, 4)\} \ominus \{(aa, 2), (ba, 3)\} = \{(ba, 1)\}$$

# Extension de multiensemble

## Definition

Soient un multiensemble  $\mathcal{M} = \langle X, f \rangle$  un multiensemble un mot  $v \in X$ , une lettre  $a \in X \cap \Sigma$  et un entier positif  $i$ . On définit le multiensemble  $\epsilon(\mathcal{M}, v, a, i)$  obtenu en appliquant les opérations suivantes :

$$\epsilon(\mathcal{M}, v, a, i) = \mathcal{M} \oplus \{(va, i)\} \ominus \{(v, i)\} \ominus \{(a, i)\}$$

## Exemple

Soit le multiensemble  $\mathcal{M} = \{(a, 1), (ba, 4)\}$ , on a

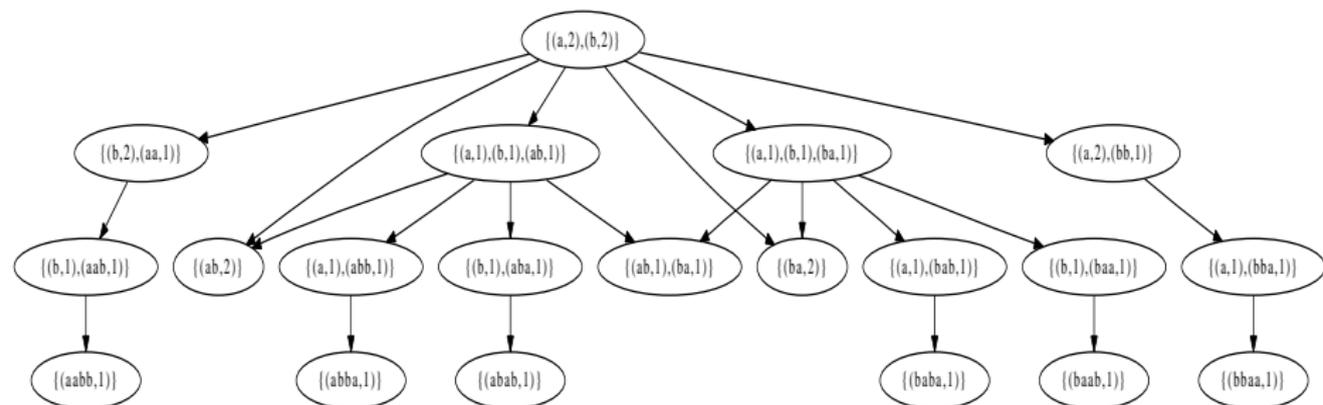
$$\epsilon(\mathcal{M}, ba, a, 1) = \{(ba, 3), (baa, 1)\}$$

# Le graphe de transition

Le **graphe de transition**  $T_{w,q} = (\mathfrak{M}_{w,q}, E_{w,q})$  est un graphe orienté défini comme suit :

- son ensemble de sommets  $\mathfrak{M}_{w,q}$  est l'ensemble des  $(w, q)$ -candidats,
- Il existe une arête  $(\mathcal{M}_1, \mathcal{M}_2) \in E_{w,q}$  **s'il existe un entier  $i$** , un mot  $v$  et une lettre  $a$  tels que  $\mathcal{M}_2 = \epsilon(\mathcal{M}_1, v, a, i)$ .

# Le graphe de transition $T_{abab,1}$



# Propriétés du graphe de transitions

Pour tout graphe  $T_{w,q}$ , les propriétés suivantes sont satisfaites :

- le graphe de transition est acyclique et sa hauteur est bornée par  $|w|$ .
- le graphe de transition admet un arbre couvrant.
- L'ensemble des multiensembles  $(w, q)$ -valides forme un sous-arbre de l'arbre couvrant.

# Graphe acyclique

## Lemma

Le graphe  $T_{w,q}$  est acyclique et sa hauteur est bornée par  $|w|$ .

## Preuve

- Il existe un arc  $(\mathcal{M}_1, \mathcal{M}_2) \in E_{w,q}$  si et seulement si il existe un mot  $v$ , une lettre  $a$  et un entier  $i$  tel que  $\mathcal{M}_2 = \epsilon(\mathcal{M}_1, v, a, i)$ .
- Le nombre d'occurrence de la lettre  $a$  dans  $\mathcal{M}_2$  est strictement inférieur au nombre d'occurrence de  $a$  dans  $\mathcal{M}_1$ .
- S'il existe un chemin entre deux multiensembles dans  $T_{w,q}$ , il existe une lettre  $a \in \Sigma$ , pour laquelle les nombres d'occurrences diffèrent d'un multiensemble à l'autre.
- La somme du nombre d'occurrences de chaque lettre dans un  $(w, q)$ -candidat est au plus égal à  $|w|$ . La longueur de plus long chemin dans  $T_{w,q}$  est donc bornée par  $|w|$ .

# Graphe acyclique

## Lemma

Le graphe  $T_{w,q}$  est acyclique et sa hauteur est bornée par  $|w|$ .

## Preuve

- Il existe un arc  $(\mathcal{M}_1, \mathcal{M}_2) \in E_{w,q}$  si et seulement si il existe un mot  $v$ , une lettre  $a$  et un entier  $i$  tel que  $\mathcal{M}_2 = \epsilon(\mathcal{M}_1, v, a, i)$ .
- Le nombre d'occurrence de la lettre  $a$  dans  $\mathcal{M}_2$  est strictement inférieur au nombre d'occurrence de  $a$  dans  $\mathcal{M}_1$ .
- S'il existe un chemin entre deux multiensembles dans  $T_{w,q}$ , il existe une lettre  $a \in \Sigma$ , pour laquelle les nombres d'occurrences diffèrent d'un multiensemble à l'autre.
- La somme du nombre d'occurrences de chaque lettre dans un  $(w, q)$ -candidat est au plus égal à  $|w|$ . La longueur de plus long chemin dans  $T_{w,q}$  est donc bornée par  $|w|$ .

# Solution Triviale

- On définit le multiensemble  $\mathcal{M}_{w,q}^0$  :
  - Son ensemble de mot sous-jacent est l'alphabet  $\Sigma$  sur lequel  $w$  est défini.
  - Le nombre d'occurrences de chaque lettre  $a$  dans  $\mathcal{M}_{w,q}^0$  est égal à  $\|w\|_a$ .
- Pour tout  $q \leq \min\{\|w\|_a \mid a \in \Sigma\}$ ,  $\mathcal{M}_{w,q}^0$  est  $(w, q)$ -valide car

$$w \in \bigsqcup_{a \in \Sigma} (\bigsqcup^{\|w\|_a} a).$$

- $\mathcal{M}_{w,q}^0$  est l'unique  $(w, q)$ -candidat dont l'ensemble de mots associé ne contient que des lettres.

# L'ensemble des arêtes $E_{w,q}$

Soit un multiensemble  $\mathcal{M} = \langle X, f \rangle$  qui est  $(w, q)$ -candidat, un mot  $v \in X$  et une lettre  $a \in X \cap \Sigma$ .

Pour tout entier  $i \in \mathbb{N}^*$  tel que  $\epsilon(\mathcal{M}, v, a, i) \in \mathfrak{M}_{w,q}$ , on a :

- Si  $v \neq a$ , alors
  - $f(va) + i \geq q$ ,
  - $f(v) - i \geq q$  ou  $f(v) - i = 0$ ,
  - $f(a) - i \geq q$  ou  $f(a) - i = 0$ .
- Si  $v = a$ , alors
  - $f(aa) + i \geq q$ ,
  - $f(a) - 2i \geq q$  ou  $f(a) - 2i = 0$ .

# L'ensemble des arêtes $E_{w,q}$

- On note  $\mathcal{I}(\mathcal{M}, v, a)$  l'ensemble des entiers  $i$  tel que  $\epsilon(\mathcal{M}, v, a, i) \in \mathfrak{M}_{w,q}$ .
- Il est possible de déterminer si  $\mathcal{I}(\mathcal{M}, v, a) = \emptyset$  ou de calculer  $\min(\mathcal{I}(\mathcal{M}, v, a))$  en temps constant.

## Exemple

- Si  $v \neq a$ ,  $f(va) \geq q$ ,  $f(v) > q$ ,  $f(a) > q$ , alors  $\min(\mathcal{I}(\mathcal{M}, v, a)) = 1$ .
- Si  $v \neq a$ ,  $f(va) = 0$ ,  $f(v) \geq 2q$ ,  $f(a) \geq 2q$ , alors  $\min(\mathcal{I}(\mathcal{M}, v, a)) = q$ .
- ...

# Arbre couvrant

L'arbre couvrant est un sous-ensemble d'arêtes  $(\langle X, f \rangle, \langle Y, g \rangle)$  telles qu'il existe un mot  $v \in X$ , une lettre  $a \in X$  et un entier  $i$  tel que :

- $\langle Y, g \rangle = e(X, f, v, a, i)$ ,
- $va = \max_{mil}(Y)$ ,
- $i = \min(\mathcal{I}(X, f, q, v, a))$ .

L'arbre couvrant est enraciné en  $\mathcal{M}_{w,q}^0$  et sa hauteur est borné par  $|w|$ .

# Relation antimonotone

## Lemme

*Pour tous multiensembles  $\mathcal{M}_1, \mathcal{M}_2 \in \mathfrak{M}_{w,q}$  tels que  $(\mathcal{M}_1, \mathcal{M}_2) \in E_{w,q}$ , si  $\mathcal{M}_2$  est  $(w, q)$ -valide alors  $\mathcal{M}_1$  est aussi  $(w, q)$ -valide.*

$\mathcal{M}_1, \mathcal{M}_2$  étant des  $(w, q)$ -candidats, on montre que

$$w \in \bigsqcup \mathcal{M}_2 \implies w \in \bigsqcup \mathcal{M}_1.$$

# Relation antimonotone

Pour tout mot  $v$  et toute lettre  $a$ , on a

$$va \subset v \sqcup a$$

Pour tout multiensemble  $\mathcal{M} = \langle X, f \rangle$ , on a

$$\left( \bigsqcup \mathcal{M} \sqcup va \right) \subset \left( \bigsqcup \mathcal{M} \sqcup v \sqcup a \right).$$

Et par induction,

$$\left( \bigsqcup \mathcal{M} \sqcup^i va \right) \subset \left( \bigsqcup \mathcal{M} \sqcup^i v \sqcup^i a \right),$$

$$\bigsqcup (\mathcal{M} \oplus \{(va, i)\}) \subset \bigsqcup (\mathcal{M} \oplus \{(v, i)\} \oplus \{(a, i)\})$$

Pour tout entier  $i$  tel que  $i \leq f(v)$  et  $i \leq f(a)$  on a bien

$$\left( \bigsqcup \mathcal{M} \oplus \{(va, i)\} \ominus \{(v, i)\} \ominus \{(a, i)\} \right) \subset \bigsqcup \mathcal{M}$$

$$w \in \bigsqcup e(\mathcal{M}, v, a, i) \implies w \in \bigsqcup \mathcal{M}$$

# Relation antimonotone

Pour tout mot  $v$  et toute lettre  $a$ , on a

$$va \subset v \sqcup a$$

Pour tout multiensemble  $\mathcal{M} = \langle X, f \rangle$ , on a

$$\left( \bigsqcup \mathcal{M} \sqcup va \right) \subset \left( \bigsqcup \mathcal{M} \sqcup v \sqcup a \right).$$

Et par induction,

$$\left( \bigsqcup \mathcal{M} \sqcup^i va \right) \subset \left( \bigsqcup \mathcal{M} \sqcup^i v \sqcup^i a \right),$$

$$\bigsqcup (\mathcal{M} \oplus \{(va, i)\}) \subset \bigsqcup (\mathcal{M} \oplus \{(v, i)\} \oplus \{(a, i)\})$$

Pour tout entier  $i$  tel que  $i \leq f(v)$  et  $i \leq f(a)$  on a bien

$$\left( \bigsqcup \mathcal{M} \oplus \{(va, i)\} \ominus \{(v, i)\} \ominus \{(a, i)\} \right) \subset \bigsqcup \mathcal{M}$$

$$w \in \bigsqcup e(\mathcal{M}, v, a, i) \implies w \in \bigsqcup \mathcal{M}$$

# Relation antimonotone

Pour tout mot  $v$  et toute lettre  $a$ , on a

$$va \subset v \sqcup a$$

Pour tout multiensemble  $\mathcal{M} = \langle X, f \rangle$ , on a

$$\left( \bigsqcup \mathcal{M} \sqcup va \right) \subset \left( \bigsqcup \mathcal{M} \sqcup v \sqcup a \right).$$

Et par induction,

$$\left( \bigsqcup \mathcal{M} \sqcup^i va \right) \subset \left( \bigsqcup \mathcal{M} \sqcup^i v \sqcup^i a \right),$$

$$\bigsqcup (\mathcal{M} \oplus \{(va, i)\}) \subset \bigsqcup (\mathcal{M} \oplus \{(v, i)\} \oplus \{(a, i)\})$$

Pour tout entier  $i$  tel que  $i \leq f(v)$  et  $i \leq f(a)$  on a bien

$$\left( \bigsqcup \mathcal{M} \oplus \{(va, i)\} \ominus \{(v, i)\} \ominus \{(a, i)\} \right) \subset \bigsqcup \mathcal{M}$$

$$w \in \bigsqcup e(\mathcal{M}, v, a, i) \implies w \in \bigsqcup \mathcal{M}$$

# Relation antimonotone

Pour tout mot  $v$  et toute lettre  $a$ , on a

$$va \subset v \sqcup a$$

Pour tout multiensemble  $\mathcal{M} = \langle X, f \rangle$ , on a

$$\left( \bigsqcup \mathcal{M} \sqcup va \right) \subset \left( \bigsqcup \mathcal{M} \sqcup v \sqcup a \right).$$

Et par induction,

$$\left( \bigsqcup \mathcal{M} \sqcup^i va \right) \subset \left( \bigsqcup \mathcal{M} \sqcup^i v \sqcup^i a \right),$$

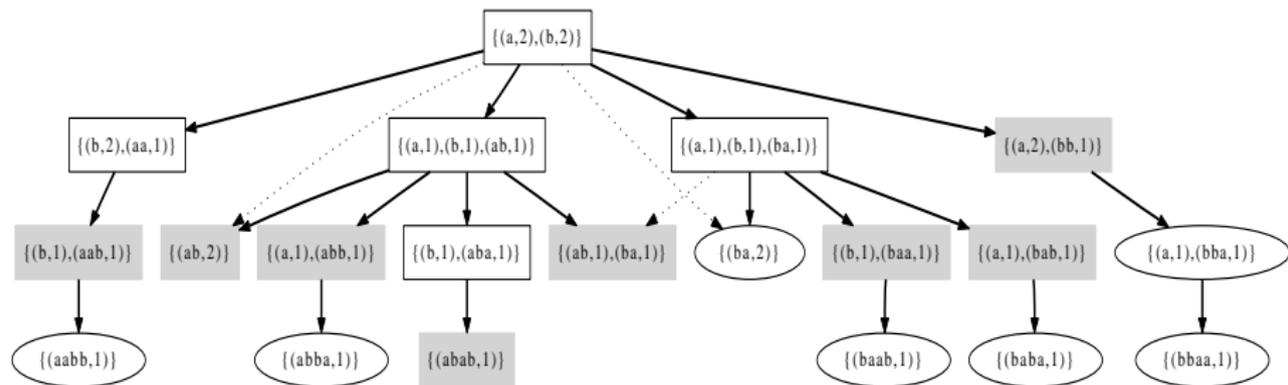
$$\bigsqcup (\mathcal{M} \oplus \{(va, i)\}) \subset \bigsqcup (\mathcal{M} \oplus \{(v, i)\} \oplus \{(a, i)\})$$

Pour tout entier  $i$  tel que  $i \leq f(v)$  et  $i \leq f(a)$  on a bien

$$\left( \bigsqcup \mathcal{M} \oplus \{(va, i)\} \ominus \{(v, i)\} \ominus \{(a, i)\} \right) \subset \bigsqcup \mathcal{M}$$

$$w \in \bigsqcup e(\mathcal{M}, v, a, i) \implies w \in \bigsqcup \mathcal{M}$$

# L'arbre couvrant de $T_{abab,1}$



# Description de l'algorithme

**Algorithm 1:**  $\text{Générateur}(\mathcal{M}, q, w)$

**Données:** Un multiensemble  $\mathcal{M} = \langle X, f \rangle$ , un entier  $q$ , un mot  $w$ .

**début**

**si**  $\mathcal{M}$  est  $(w, q)$ -valide **alors**

Afficher  $\mathcal{M}$

**pour tous les**  $v \in X$  **faire**

**pour tous les**  $a \in X \cap \Sigma$  **faire**

**si**  $va = \max_{\text{mil}}\{X \cup va\}$  **alors**

**si**  $\mathcal{I}(\mathcal{M}, v, a) \neq \emptyset$  **alors**

$i = \min(\mathcal{I}(\mathcal{M}, v, a))$

$\mathcal{M}' = \mathcal{M} \oplus (va, i) \ominus (v, i) \ominus (a, i)$

$\text{Générateur}(\mathcal{M}', q, w)$

**fin**

**fin**

**fin**

**fin**

**fin**

**fin**

# Remarque sur la complexité de l'algorithme

La complexité de l'algorithme *Generateur* dépend de

- Du nombre de multiensembles  $(w, q)$ -valides  
→ on mesure la complexité en fonction de la taille de la sortie.
- De la complexité de l'oracle qui permet de tester si un multiensemble est  $(w, q)$ -valide.

# Problème : *Frequent Partition Generation*

- **Données :**

- un alphabet  $\Sigma$ ,
- un mot  $w \in \Sigma^+$ ,
- un entier  $q$ ,

- **Question :** Quel est l'ensemble des multiensembles  $(w, q)$ -valides ?

# Problème : *Shuffle Product Testing*

- **Données :**

- un alphabet  $\Sigma$ ,
- un mot  $w \in \Sigma^+$ ,
- un entier  $q$ ,
- un multiensemble  $\mathcal{M}$ ,

- **Question :**  $\mathcal{M}$  est-il  $(w, q)$ -valide ?

# Problème : *Shuffle Product Testing*

## Théorème[Warmuth,Haussler]

Soit  $X$  un ensemble de mots et  $w$  un mot. Le problème de décider si  $w \in \bigsqcup X$  est NP-complet.

# Problème : *Incremental Shuffle Product Testing*

- **Données :**

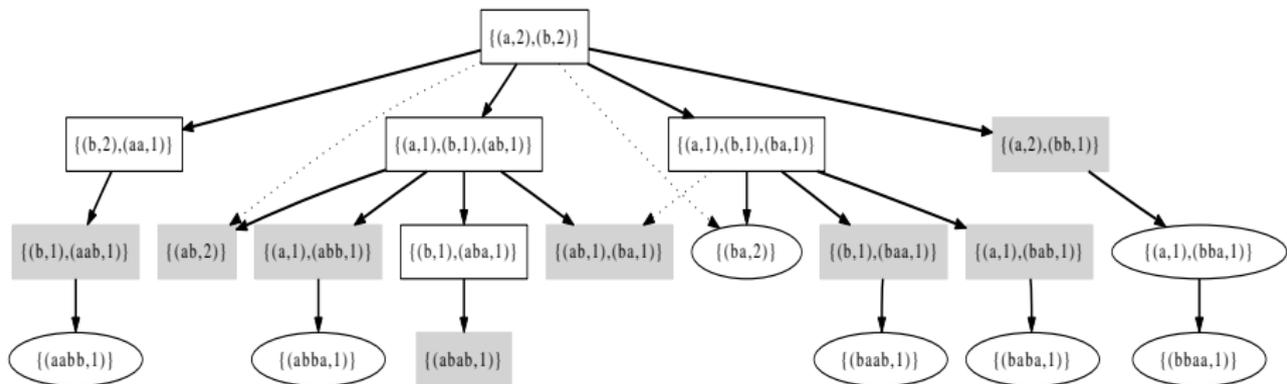
- un alphabet  $\Sigma$ ,
- un mot  $w \in \Sigma^+$ ,
- un entier  $q$ ,
- un multiensemble  $(w, q)$ -valide  $\mathcal{M}$ ,
- un multiensemble  $\mathcal{M}'$  tel que  $\mathcal{M}' = \epsilon(\mathcal{M}, v, a)$ .

- **Question :**  $\mathcal{M}'$  est-il  $(w, q)$ -valide ?

# Problème : *Incremental Shuffle Product Testing*

## Théorème

Sauf si  $P=NP$ , il n'existe pas d'algorithme polynomial pour résoudre *Incremental Shuffle Product Testing*.



# Réduire le temps de calcul

- On fixe un entier  $k$  tel que pour toute solution  $\langle X, f \rangle$ , on ait

$$\sum_{v \in X} f(v) \leq k$$

→ tester si  $w \in \bigsqcup \langle X, f \rangle$  est réalisable en  $\mathcal{O}(|w|^k)$ .

- Ajouter des contraintes supplémentaires

# X-factorisation d'un mot

- soit un mot  $w \in \Sigma^*$ ,
- soit un ensemble  $X$  de facteurs dans  $w$ ,
- existe t'il un algorithme polynomial pour tester si  $X$  partitionne  $w$  ?

# X-factorisation d'un mot

## **Théorème[Rivière, Barth, Cohen, Denise]**

Soit  $X$  un ensemble de mots et  $w$  un mot. Le problème de décider si  $X$  partitionne  $w$  est NP-complet.