Chapitre 2

Recherche des modèles fréquents et associations

Les motifs fréquents sont des motifs ou patterns (tel que les ensembles d'items, les sous séquences, ou les sous structures) qui apparaissent fréquemment dans un ensemble de données. Par exemple, un ensemble d'items tel que le lait et le pain qui apparaissent souvent dans une base de transactions dans un supermarché, est un ensemble d'items fréquent. Une sous séquence telle que acheter premièrement un PC puis une caméra numérique ensuite une carte mémoire qui se produit souvent dans la base historique des achats, est une séquence d'items fréquente. Les sous structures peuvent être des sous-graphes ou des sous-arbres qui peuvent être combinés avec des ensembles ou des séquences d'items. Trouver de tels motifs fréquents joue un rôle essentiel dans la fouille des associations et des corrélations, et représente une tâche importante en data mining et constitue toujours un thème qui attire beaucoup de recherches.

L'analyse des motifs fréquents trouve son application dans plusieurs domaines :

- L'analyse du panier du marché, pour comprendre les habitudes des clients afin de mieux organiser les rayons d'articles, organiser les promotions, ...etc.
- L'analyse d'ADN en biologie afin de comprendre les propriétés génétiques des espèces.
- L'analyse du climat en météorologie afin de mieux orienter l'agriculture ou choisir l'orientation des pistes des aérodromes.
- ...

2.1 Concepts de base

2.1.1 Base de données formelle

La version de base de l'extraction de motifs fréquents permet de faire la fouille dans une table d'une base de données relationnelle dont les valeurs sont des booléens indiquant la présence ou l'absence d'une propriété. Une telle base est appelée base de données formelle.

Une base de données formelle est définie par un triplet (O, P, R) où :

- O est un ensemble fini d'objets.
- P est un ensemble fini de propriétés.
- R est une relation sur $O \times P$ qui permet d'indiquer si un objet x a une propriété p (noté xRp) ou non.

Par exemple dans le cas d'analyse du panier dans un supermarché, O est l'ensemble des transactions d'achat, P est l'ensemble d'articles et R est la relation indiquant si un article a est acheté dans la transaction t.

Considérons par exemple la base de données formelle suivante :

Tr	a	b	c	d	e
x_1	1	0	1	1	0
x_2	0	1	1	0	1
x_3	1	1	1	0	1
x_4	0	1	0	0	1
x_5	1	1	1	0	1
x_6	0	1	1	0	1

- $O = \{x_1, x_2, x_3, x_4, x_5, x_6\}$.
- $P = \{a, b, c, d, e\}$.
- xRp si et seulement si la ligne de x et la colonne de p se croisent sur un 1 (et pas sur un 0), par exemple :x_1Ra, x_1Rc et x_1Rd.

2.1.2 Motif

Un motif d'une base de données formelle (O, P, R) est un sous-ensemble de P. L'ensemble de tous les motifs d'une base est donc l'ensemble des parties de P, noté 2^P. On dira qu'un objet $x \in O$ possède un motif m si $\forall\ p \in m,\ xRp$. Pour la base de données en exemple, on a donc :

- Motif de taille 0 = $\emptyset$ ($C_5^0 = 1$ motif).
- Motifs de taille 1 = $\{a\}, \{b\}, \{c\}, \{d\}$ et $\{e\}$, qu'on notera, pour simplifier, $\underline{a}, \underline{b}, \underline{c}, \underline{d}$ et $\underline{e}$. ($C_5^1 = 5$ motifs).
- Motifs de taille 2 = $\underline{ab}, \underline{ac}, \underline{ad}, \underline{ae}, \underline{bc}, \underline{bd}, \underline{be}, \underline{cd}, \underline{ce}, \underline{de}$ ($C_5^2 = 10$ motifs)
- Motifs de taille 3 = $\underline{abc}, \underline{abd}, \underline{abe}, \underline{acd}, \underline{ace}, \underline{ade}, \underline{bcd}, \underline{bce}, \underline{bde}, \underline{cde}$ ($C_5^3 = 10$ motifs).
- Motifs de taille 4 = $\underline{abcd}, \underline{abce}, \underline{abde}, \underline{acde}, \underline{bcde}$ ($C_5^4 = 5$ motifs).
- Motifs de taille 5 = $\underline{abcde}$ ($C_5^5 = 1$ motifs).

Dans la base formelle précédente, x_1 possède les motifs :$\emptyset, \underline{a}, \underline{c}, \underline{d}, \underline{ac}, \underline{ad}, \underline{cd}$ et $\underline{acd}$. Parmi l'ensemble global de 2^p motifs, on va chercher ceux qui apparaissent fréquemment. Pour cela, on introduira les notions de connexion de Galois et de support d'un motif.

2.1.3 Connexion de Galois

La connexion de Galois associée à une base de données formelle (O, P, R) est le couple de fonctions (f, g) définies par :

$$\begin{cases} f: & 2^p \to 2^o \\ & m \to f(m) = \{x \in O/\ x\ possède\ m\} \\ g: & 2^o \to 2^p \\ & X \to g(X) = \{p \in P/\ \forall x \in X\ xRp\} \end{cases}$$

g est dite duale de f et f duale de g. On dit parfois que $f(m)$ est l'image du motif m.

Exemples :

$$\begin{array}{ll} f(\underline{bc}) = \{x_2, x_3, x_5, x_6\} & g(x_2, x_3, x_5, x_6) = \{b, c, e\} \\ f(\underline{acd}) = \phi & g(x_1) = \{a, c, d\} \\ f(\underline{a}) = \{x_1, x_3, x_5\} & g(x_1, x_3, x_5) = \{a, c\} \end{array}$$

2.1.4 Support d'un motif

Soit $m \in 2^P$, un motif. Le support de m est la proportion d'objets dans O qui possèdent le motif :

$$\begin{array}{rl} Support: & 2^p \to [0, 1] \\ & m \to Support(m) = \frac{|f(m)|}{|O|} \end{array}$$

Par exemple dans la base précédente, on a :

$$Support(\underline{a}) = \frac{3}{6},$$

$$Support(\underline{b}) = \frac{5}{6},$$
$$Support(\underline{ab}) = \frac{2}{6},$$
$$Support(\emptyset) = 1,$$
$$Support(P) = 0.$$

Propriété fondamentale : Le support est décroissant de $(2^p, \subseteq)$ dans $([0,1], \leq)$. Autrement dit, si m est un sous-motif de m' ($m \subseteq m'$) alors $Support(m) \geq Support(m')$. Le support mesure la fréquence d'un motif : plus il est élevé, plus le motif est fréquent. On distinguera les motifs fréquents des motifs non fréquents à l'aide d'un seuil σ_s.

2.1.5 Motif fréquent

Soit $\sigma_s \in [0,1]$. Un motif m est fréquent (sous-entendu, relativement au seuil σ_s) si $Support(m) \geq \sigma_s$. Sinon, il est dit non fréquent.

2.2 Méthodes efficaces pour la recherche des modèles fréquents

Une approche naïve pour l'extraction des motifs fréquents consiste à parcourir l'ensemble de tous les motifs, à calculer leurs nombres d'occurrences (support) et à ne garder que les plus fréquents. Malheureusement, cette approche est trop consommatrice en temps et en ressources. En effet, le nombre de motifs est 2^p (p est le nombre de propriétés), et en pratique, on veut manipuler des bases ayant un grand nombre d'attributs.

2.2.1 Algorithme Apriori

L'algorithme Apriori proposé par Agrawal et ses co-auteurs en 1994 est un algorithme de base qui permet d'extraire des motifs fréquents dans une base ayant plusieurs milliers d'attributs et plusieurs millions d'enregistrements. L'idée est d'effectuer une extraction par niveaux selon le principe suivant :

- On commence par chercher les motifs fréquents de longueur 1 ;
- On combine ces motifs pour obtenir des motifs de longueur 2 et on ne garde que les fréquents parmi eux ;
- On combine ces motifs pour obtenir des motifs de longueur 3 et on ne garde que les fréquents parmi eux ;
- ... continuer jusqu'à la longueur maximale.

Cette approche s'appuie sur les deux principes fondamentaux suivants (qui reposent sur la décroissance du support) :

1. Tout sous-motif d'un motif fréquent est fréquent.
2. Tout sur-motif d'un motif non fréquent est non fréquent.

L'algorithme de référence basé sur cette approche est l'algorithme Apriori. Le pseudo-code suivant décrit l'extraction de motifs fréquents selon ce principe :

Algorithme 1 Apriori

Entrées: Base de données de transactions D, Seuil de support minimum σ

Sorties: Ensemble des items fréquents

$i \leftarrow 1$

$C_1 \leftarrow$ ensemble des motifs de taille 1 (un seul item)

tantque $C_i \neq \phi$ **faire**

Calculer le Support de chaque motif $m \in C_i$ dans la base

$F_i \leftarrow \{m \in C_i | support(m) \geq \sigma\}$

$C_{i+1} \leftarrow$ toutes les combinaisons possibles des motifs de F_i de taille $i+1$

$i \leftarrow i+1$

fin tantque

retourner $\cup_{(i \geq 1)} F_i$

Exemple :

L'application de l'algorithme sur la base donnée en exemple avec $\sigma = 0.25$ se passe comme suit :

1. Génération de candidats de taille 1 :
   - $C_1 = \{a, b, c, d, e\}$
   - Supports : $\frac{3}{6}, \frac{5}{6}, \frac{5}{6}, \frac{1}{6}, \frac{5}{6}$

   D'où $F_1 = \{a, b, c, e\}$ (aucun motif fréquent ne contiendra d).
2. Génération de candidats de taille 2 : Combiner 2 à 2 les candidats de taille 1 de F_1 :
   - $C_2 = \{ab, ac, ae, bc, be, ce\}$
   - Supports : $\frac{2}{6}, \frac{3}{6}, \frac{2}{6}, \frac{4}{6}, \frac{5}{6}, \frac{4}{6}$

   $F_2 = C_2$: tous les motifs de C_2 sont fréquents.
3. Génération de candidats de taille 3 : Combiner 2 à 2 les candidats de taille 2 de F_2 (et ne considérer que ceux qui donnent des motifs de taille 3) :
   - $C3 = \{abc, abe, ace, bce\}$

– Supports : $\frac{2}{6}, \frac{2}{6}, \frac{2}{6}, \frac{4}{6}$

$F_3 = C_3$: tous les motifs de C3 sont fréquents.

4. Génération de candidats de taille 4 :
   – $C4 = \{abce\}$
   – Supports : $\frac{2}{6}$
5. Génération de candidats de taille 5 : $C_5 = \emptyset$. Donc, $F_5 = \emptyset$
6. L'algorithme retourne alors l'ensemble des motifs fréquents : $F_1 \cup F_2 \cup F_3 \cup F_4$

Remarque 1 : On peut voir cet algorithme comme le parcours du treillis des parties de P ordonné pour l'inclusion.

Supposons par exemple que $P = \{a, b, c\}$. Le treillis des parties de P est :

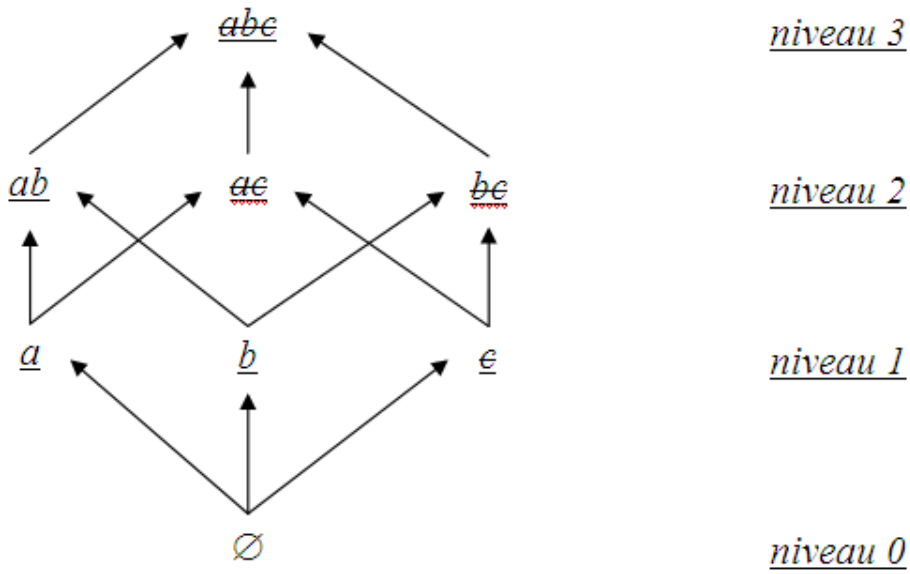

Il est parcouru par niveau croissant à partir du niveau $i = 1$. Quand un motif n'est pas fréquent, tous ses sur-motifs sont non fréquents. Dans notre exemple c n'est pas fréquent (il a été barré) et, par conséquent, aucun de ses sur-motifs n'est considéré. On a ainsi élagué le parcours du treillis.

Remarque 2 : Un des objectifs des optimisations de cet algorithme est de diminuer le nombre d'accès à la base de données.

Remarque 3 : Le seuil σ est fixé par l'analyste. Celui-ci peut suivre une approche itérative en fixant un seuil au départ et, en fonction du résultat, changera la valeur du seuil : Si trop de motifs fréquents ont été trouvés, il augmentera le seuil ; dans le cas inverse, il le diminuera. Par ailleurs, on peut constater que le temps de calcul de l'algorithme Apriori

décroit avec le seuil. Par conséquent, si l'analyste fixe une valeur de seuil trop grande, cela gaspillera moins de temps que s'il en fixe un trop petit.

2.2.2 Optimisations

2.2.2.1 L'algorithme AprioriTlD

L'algorithme Apriori nécessite N passes sur la base, N étant la taille du plus grand ensemble susceptible d'être fréquent. Une optimisation possible consiste à générer en mémoire, pendant la première passe, les identifiants (TID) des transactions pour chaque 1-itemset (ensemble de motifs de taille 1) fréquent. Dans la suite, les listes de TID correspondant à chaque k-itemset sont gardées. Le calcul d'un k-itemset se fait toujours à partir des deux (k-1)-itemsets contenant un élément de moins, mais le comptage se fait simplement par intersection des deux listes de TID des deux (k-1)-itemsets source. Nous construisons la liste des TID après avoir déterminé les 1-itemsets fréquents, ce qui est plus efficace en taille mémoire mais nécessite deux passes. La première passe permet d'éliminer les produits non fréquents et réduit donc les listes de TID en mémoire construites dans une deuxième passe. Générer les listes de TID en mémoire en parallèle dès la première passe est plus efficace. Cependant, il n'est possible d'éliminer des listes qu'après le comptage total de la base, lorsqu'on sait qu'un 1-itemset ne sera pas fréquent. L'algorithme nécessite alors une taille mémoire de N*P TID, N étant le nombre de transactions et P le nombre de produits. Il devient très inefficace si les listes ne tiennent pas en mémoire.

2.2.2.2 L'algorithme apriori partitionné

L'algorithme proposé par Savasere permet de résoudre le problème de place mémoire de l'algorithme précédent. L'idée est simplement de diviser la base en Q partitions, de sorte que chaque partition tienne en mémoire. Chaque partition est traitée indépendamment et les ensembles fréquents sont découverts pour chaque partition. La validité de l'algorithme est basée sur le lemme suivant : pour être globalement fréquent, un ensemble doit être fréquent dans au moins une partition. Ayant obtenu les ensembles fréquents sur chaque partition, il suffit dans une passe finale d'explorer l'union des ensembles fréquents sur la base. L'opération se fait par un comptage simple sur la base. Les ensembles non globalement fréquents, mais localement fréquents dans une partition, sont ainsi éliminés. L'avantage de cet algorithme est qu'il nécessite deux passes au plus. Il est aussi facilement parallélisable, les partitions pouvant être traitées indépendamment. Dans ce cas, il faut

cependant beaucoup de mémoire pour tenir les partitions et listes de TID en mémoire.

2.2.2.3 Algorithme de comptage dynamique

L'algorithme DIC a été proposé par Brin et al. Pour réduire le nombre de parcours de la base de données. DIC partitionne la base de données en blocs de M transactions. Durant le calcul des supports des k-itemsets, après le parcours d'une partition de taille M de D, on vérifie les k-itemsets candidats qui ont déjà atteint le support minimum, DIC les utilise alors pour générer des candidats de taille (k+1), et commence à compter leurs supports. Ainsi les supports de candidats de tailles différentes sont calculés durant les mêmes parcours de D. En contrepartie de la diminution du nombre de balayages de la base de données, DIC considère des itemsets candidats de tailles différentes simultanément. Ceci pose le problème de stockage des itemsets candidats traités simultanément et du coût de calcul des supports des candidats qui est plus important que pour Apriori.

2.2.3 Algorithme FP-growth

A l'opposé d'Apriori qui génère des itemsets candidats et qui les teste pour ne conserver que les itemsets fréquents, FP-Growth (Han et al. (2000)) construit les itemsets fréquents sans génération de candidats. En fait, il utilise la stratégie "diviser et dominer" (divide-and-conquer). Tout d'abord, il compresse les itemsets fréquents représentés dans la base de données à l'aide d'un FP-Tree (frequent-pattern tree) dont les branches contiennent les associations possibles des items.

Chaque association peut être divisée en fragments (pattern fragment) qui constituent les itemsets fréquents. La méthode FP-Growth transforme le problème de la recherche de l'itemset fréquent le plus long par la recherche du plus petit et sa concaténation avec le suffixe correspondant (le dernier itemset fréquent de la branche aboutissant à l'item considéré). Ceci permet de réduire le coût de la recherche.

Pour expliquer le principe de FP-Growth, on choisit la base précédente :

Tr	a	b	c	d	e	Itemset
x_1	1	0	1	1	0	a,c,d
x_2	0	1	1	0	1	b,c,e
x_3	1	1	1	0	1	a,b,c,e
x_4	0	1	0	0	1	b,e
x_5	1	1	1	0	1	a,b,c,e
x_6	0	1	1	0	1	b,c,e

– Premièrement, FP-Growth parcourt la base de donnée et lit tout les items existant en calculant leur support et les compare avec le seuil de support préfixé. Ainsi, il n'accepte que les items ayant un support supérieur ou égal au seuil appelés items fréquents. On choisit ici un seuil de support minimum égal à 2. FP-Growth enregistre les items fréquents dans une liste L où ils figurent par ordre décroissant de support. Dans notre exemple, la liste correspondante est :

Item	Fréquence
a	3
b	5
c	5
d	1
e	5

Table des fréquences

Item	Fréquence
b	5
c	5
e	5
a	3

Table triée des items fréquents

– Deuxièmement, un FP-Tree est construit par la création d'une racine vide et un second parcours de la base de données où chaque transaction est décrite dans l'ordre des items donné par la liste triée des fréquences suivante :

Transaction	items
x_1	c,a
x_2	b,c,e
x_3	b,c,e,a
x_4	b,e
x_5	b,c,e,a
x_6	b,c,e

La transaction x_1 va construire la première branche du FP-Tree avec é noeuds (c :1) et (a :1). La seconde transaction x_2, contenant dans l'ordre : b,c,e construit une branche où le noeud b est lié à la racine, le noeud c lié à b et le noeud a lié à c. La troisième transaction va construire une branche b,c,e,a qui partage les noeuds bce avec la deuxièmes branche, ainsi les noeuds b,c et e seront incrémentés de 1. On aura alors (b :2),(c :2),(e :2)et (a :1) et ainsi de suite.

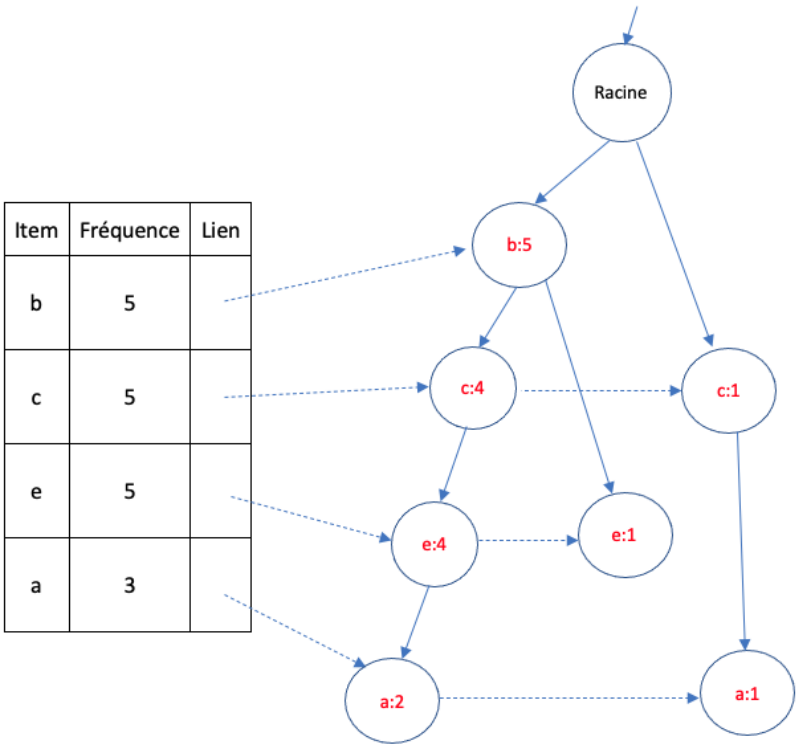

– En dernier lieu, le FP-Tree est fouillé par la création des (sub-)fragment conditionnels de base. En fait, pour trouver ces fragments, on extrait pour chaque fragment de longueur 1 (suffix pattern) l'ensemble des préfixes existant dans le chemin du FP-Tree (conditional pattern base). L'itemset fréquent est obtenu par la concaténation du suffixe avec les fragments fréquents extraits des FP-Tree conditionnels.

Items	Base des motifs conditionnels	FP-tree conditionnel	Motifs fréquents générés
a	{b,c,e :2}, {c :1}	{b :2,c :3,e :2}	{b,a :2}, {c,a :3}, {e,a :2}, {b,c,a :2}, {b,e,a :2}, {c,e,a :2}, {b,c,e,a :2}
e	{b,c :4 }, {b :1}	{b :5},{c :4}	{b,e :5},{c,e :4},{b,c,e :4}
c	{b :4}	{b :4}	{b,c :4}
b	-		

2.3 Types de motifs fréquents

Le nombre de motifs présents dans une base de données est généralement très grand, il est courant d'en obtenir plusieurs millions. Leur utilisation repose classiquement sur une démarche de sélection par la fréquence à fin de ne conserver que les plus représentatifs, mais aussi parce que c'est une façon pragmatique efficace d'élaguer l'espace de recherche. Néanmoins cette approche s'avère insuffisante dans de nombreux cas pratiques et montre ses limites lorsque l'espace de recherche est important ou la base très dense et corrélée.

Les représentations condensées de motifs fournissent une solution au problème de l'extraction de motifs fréquents en proposant un résumé des motifs fréquents, tout en assurant de pouvoir reconstruire l'ensemble des motifs fréquents si nécessaire. En général, on en trouve deux types :

2.3.1 Motif fréquent fermé

Un motif fréquent est dit fermé s'il ne possède aucun sur-motif qui a le même support.

2.3.2 Motif fréquent maximal

Un motif fréquent est dit Maximal si aucun de ses sur-motifs immédiats n'est fréquent.

Exemple

Le schéma suivant illustre la relation entre le motifs fréquents, fréquents fermés et fréquents maximaux :

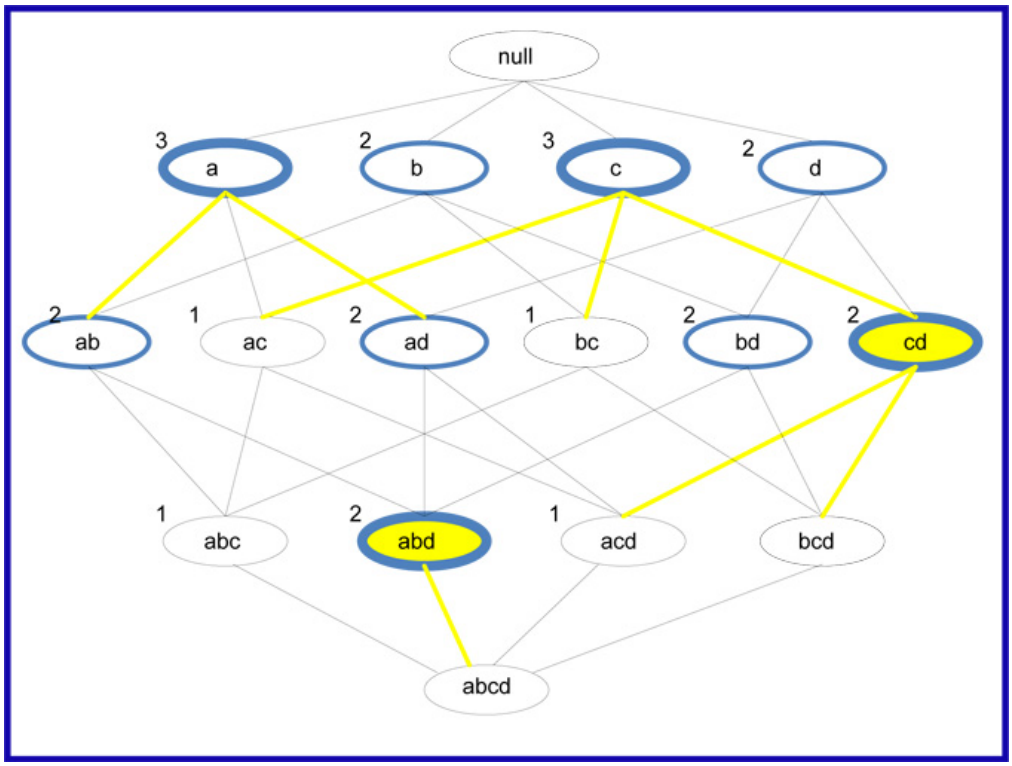

– Les motifs encerclés par les lignes minces ne sont pas fréquents, les autres le sont.

– Les motifs encerclés par des lignes plus épais sont fermés.

– Les motifs colorés sont maximaux.

Il est clair que :

$$\text{Les motifs maximaux} \subset \text{Les motifs fermés} \subset \text{Les motifs fréquents}$$

2.4 Passage aux règles d'association

La phase qui suit la phase de recherche des motifs fréquents est la phase de découverte des règles d'association basées sur tous les items fréquents trouvés. Cette phase est relativement simple, elle consiste à trouver toutes les règles qui existent entre les items fréquents. Par exemple pour une règle telle que $\{x_1, x_2, x_3\} \Rightarrow x_4$, il faut premièrement que $\{x_1, x_2, x_3\}$ et x_4 soient fréquents. Ensuite, il faut que la confidence de la règle dépasse un certain seuil. La confidence est calculée comme suit :

$$\begin{aligned} Confidence(\{x_1, x_2, x_3\} \Rightarrow x_4) &= P(x_4 / \{x_1, x_2, x_3\}) \\ &= \frac{Support(\{x_1, x_2, x_3\} \cup x_4)}{Support(\{x_1, x_2, x_3\})} \end{aligned}$$

Où le $Support(x)$ est le nombre d'enregistrements où apparait l'item x,
et le $Support(\{x_1, x_2, x_3\})$ est le nombre d'enregistrement où apparaissent les items x_1, x_2, x_3 ensemble.
L'ensemble des règles d'association peut être trouvé en calculant la confidence de toutes les combinaisons possibles des items fréquents puis prendre celles dont la confidence est importante. Cette opération peut être accélérée en enregistrant la liste des items fréquents avec leurs fréquences dans une table qui peut être accédée rapidement.

Définition d'une règle d'association

Soit m_1 et m_2 deux motifs. Une règle d'association est une implication de la forme :

$$m_1 \Rightarrow m_2$$
$$\text{Où} \quad m_1, m_2 \in 2^P, \quad et \quad m_1 \cap m_2 = \emptyset$$

2.4.0.1 Support d'une règle

La règle $m_1 \Rightarrow m_2$ est vérifiée dans la base de donnée D avec un support s, où s est le pourcentage d'objets dans D contenant $m_1 \cup m_2$:

$$Support(m_1 \Rightarrow m_2) = \frac{Nombre\ de\ transactions\ contenant(m_1 \cup m_2)}{Nombre\ total\ de\ transactions}$$

2.4.0.2 Qualité d'une règle

La qualité de la règle représente une mesure de la cooexistance des deux paries (gauche et droite) de la règle. Plusieurs métriques sont utilisées :

- **Confidence :** La confidence de la règle $m_1 \Rightarrow m_2$ est définie par le pourcentage de transactions qui contiennent $m_1 \cup m_2$ dans les transaction contenant m_1.

  $$Conf(m_1 \Rightarrow m_2) = \frac{Support(m_1 \cup m_2)}{Support(m_1)} = \frac{Nombre\ de\ transactions\ contenant(m_1 \cup m_2)}{Nombre\ de\ transactions\ contenant\ m_1}$$

- **Lift :** c'est l'amélioration

  $$Lift(m_1 \Rightarrow m_2) = \frac{Support(m_1 \cup m_2)}{Support(m_1) \times Support(m_1)}$$

  C'est le rapport entre le support observé et celui attendu si m_1 et m_2 étaient indépendants.

Si le Lift d'une règle est égal à 1, cela signifie que les occurrences de ses deux parties sont totalement indépendantes. Si par contre le lift est supérieur à 1, il nous informe du degré de dépendance des deux parties et leur candidature pour les futures prédictions.

Le lift considère à la fois la confidence de la règle et la base toute entière.

- **Leverage :** Il représente la différence entre la fréquence observée d'apparition des deux parties ensembles et leur apparition ensemble attendues s'il étaient indépendants.

$$Leverage(m_1 \Rightarrow m_2) = Support(m_1 \cup m_2) - Support(m_1) \times Support(m_2)$$

- **Conviction :**

  La conviction est calculé par la formule :

$$Conv(m_1 \Rightarrow m_2) = \frac{1 - Support(m_2)}{1 - Conf(m_1 \Rightarrow m_2)}$$

  Elle représente le rapport entre la fréquence d'apparition de X sans Y (taux d'erreur de la règle), et le taux des prédictions erronés.

Les règles qui dépassent un minimum de support et un minimum de qualité sont appelées règles **solides**.

Une fois les items fréquents dans une base de donnée sont extraits, il devient simple de générer les règles d'association qui vérifient un minimum de support et un minimum de confidence, comme suit :

- Pour chaque motif fréquent l, générer tous les sous ensembles non vides de l ,
- Pour chaque sous-ensemble non vide s de l, enregistrer la règle (s ⇒ l-s) si :

$$Confidence(s \Rightarrow l - s) \geq Min\_Conf$$

  Où Min_Conf est un seuil minimum de confidence.

Puisque les règles sont générées des motifs fréquents, chacune vérifie automatiquement le support minimum.

2.5 Motifs rares

Les motifs rares représentent les motifs qui apparaissent rarement dans un ensemble de données tel que les symptômes non usuels ou les effets indésirables exceptionnels qui peuvent se déclarer chez un patient pour une pathologie ou un traitement donné.

De même que pour les motifs fréquents, certains phénomènes rares dans les bases de données peuvent également véhiculer des connaissances.

La découverte des motifs rares peut se révéler très intéressante, en particulier en médecine et en biologie. Prenons d'abord un exemple simulé d'une base de données médicale où nous nous intéressons à l'identification de la cause des maladies cardio-vasculaires (MCV). Une règle d'association fréquente telle que "niveau élevé de cholestérol → MCV" peut valider l'hypothèse que les individus qui ont un fort taux de cholestérol ont un risque élevé de MCV. A l'opposé, si notre base de données contient un grand nombre de végétariens, une règle d'association rare "végétarien → MCV" peut valider l'hypothèse que les végétariens ont un risque faible de contracter une MCV. Dans ce cas, les motifs végétarien et MCV sont tous deux fréquents, mais le motif végétarien, MCV est rare. Un autre exemple est en rapport avec la pharmacovigilance, qui est une partie de la pharmacologie dédiée à la détection et l'étude des effets indésirables des médicaments. L'utilisation de l'extraction des motifs rares dans une base de données des effets indésirables des médicaments pourrait contribuer à un suivi plus efficace des effets indésirables graves et ensuite à prévenir les accidents fatals qui aboutissent au retrait de certains médicaments.

2.5.1 Définitions

Un motif est dit rare ou infréquent si son support est inférieur ou égal à un support maximum (noté max_supp).

Généralement, on considère que $max\_supp = min\_supp - 1$, c'est-à-dire qu'un motif est rare s'il n'est pas fréquent. Cela implique l'existence d'une seule frontière entre motifs rares et fréquents.

2.5.2 Recherche des motifs rares

Une première approche pour la recherche des motifs rares est celle de treillis. Prenons l'exemple de la base suivante :

	A	B	C	D	E
1	X		X	X	
2		X	X		X
3	X	X	X		X
4	X				X
5	X	X	X		X

En fixant min_supp à 3 ($max\_supp = 2$), On obtient le treillis suivant :

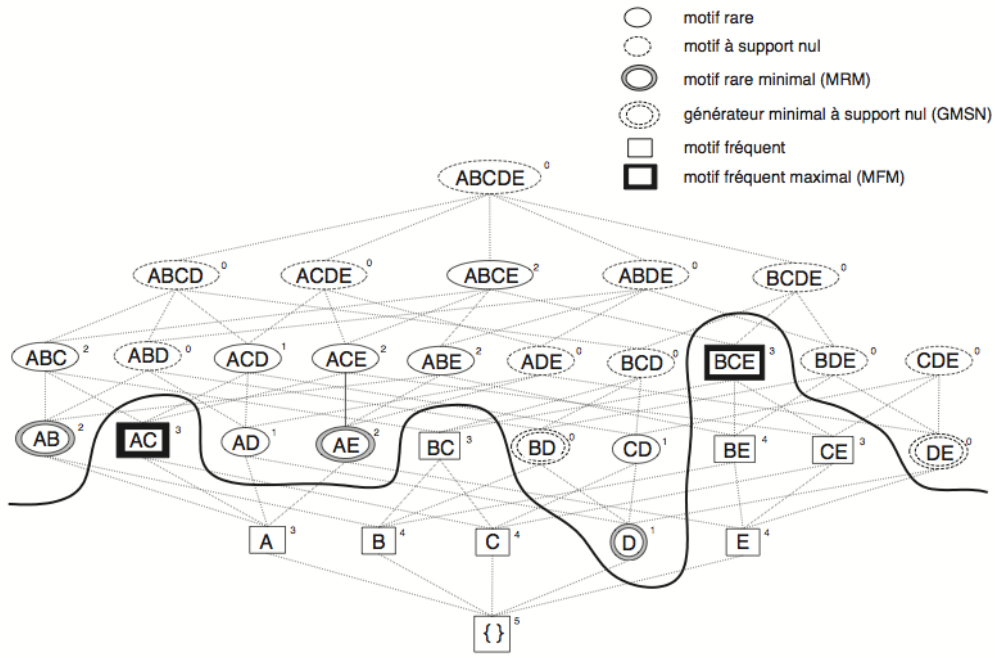

Les motifs peuvent être séparés en deux ensembles formant une partition : les motifs rares et les motifs fréquents. Une frontière peut être dessinée entre ces deux ensembles. L'ensemble des motifs rares et l'ensemble des motifs fréquents ont tous deux un sous-ensemble minimal générateur. Dans le cas des motifs fréquents, ce sous-ensemble est appelé ensemble des motifs fréquents maximaux (MFM).

Ces motifs sont dits maximaux, parce qu'ils n'ont pas de sur-motifs fréquents. Du point de vue du nombre de ces motifs ils sont minimaux, c'est-à-dire qu'ils forment un ensemble générateur minimal à partir duquel tous les motifs fréquents peuvent être retrouvés.

Les motifs rares minimaux (MRM) sont définies en tant que complémentaires des MFMs. Un motif est un MRM s'il est rare (et ainsi tous ses sur-motifs sont rares) et si tous ses sous-motifs ne sont pas rares. Ces motifs forment un ensemble générateur minimal à partir duquel tous les motifs rares peuvent être retrouvés.

Ces motifs forment un ensemble générateur minimal à partir duquel on peut retrouver les motifs rares. Nous devons d'abord générer tous les sur-motifs possibles des motifs rares minimaux, puis calculer le support des motifs rares grâce à un passage sur la base de données.

2.5.3 Apriori-Rare

De manière surprenante, les motifs rares minimaux peuvent être trouvés simplement à l'aide de l'algorithme bien connu Apriori. Il est conçu pour trouver les motifs fréquents, mais, puisque nous sommes dans le cas où non fréquent signifie rare, cela a pour "effet collatéral" d'explorer également les motifs rares minimaux. Quand Apriori trouve un motif rare, il ne générera plus tard aucun de ses sur-motifs car ils sont de manière sûre rares. Puisque Apriori explore le treillis des motifs niveau par niveau du bas vers le haut, il comptera le support des motifs rares minimaux. Ces motifs seront élagués et plus tard l'algorithme peut remarquer qu'un candidat a un sous-motif rare. En fait Apriori vérifie si tous les (k-1)-sous-motifs d'un k-candidat sont fréquents. Si l'un d'entre eux n'est pas fréquent, alors le candidat est rare. Autrement dit, cela signifie que le candidat a un sous-motif rare minimal. Grâce à cette technique d'élagage, Apriori peut réduire significativement l'espace de recherche dans le treillis des motifs. Une légère modification d'Apriori suffit pour conserver les MRM. Si le support d'un candidat est inférieur au support minimum, alors à la place de l'effacer nous l'enregistrons dans l'ensemble des motifs rares minimaux

Tous les motifs rares sont retrouvés à partir des motifs rares minimaux. Pour cela nous avons besoin de générer tous les sur-motifs possibles des MRM.