

## 5.1 Calcul de $F_2 = \sum_{i=1}^m f_i^2$

**Lemme 5.1.** Pour  $m$  requêtes distinctes :

$$F_2 = m$$

**Lemme 5.2.** Pour  $m - 1$  requêtes distinctes et une requête de multiplicité  $0.1m$  :

$$F_2 = \frac{m^2}{100} + m - 1$$

---

**Algorithm 1** Supposons donnée  $h : [m] \rightarrow \{-1, 1\}$  complètement aléatoire

---

```

 $X \leftarrow 1$ 
while ( $stream \neq \emptyset$ ) do
   $a \leftarrow next$ 
   $X \leftarrow X + h(a)$ 
end while
return  $V = X^2$ 

```

---

**Théorème 5.3.**  $\mathbb{E}(V) = F_2$

**Preuve:** En développant  $X^2$ , par linéarité de l'espérance et indépendance des  $h(i)$  □



L'algorithme prend  $\ln(n)$  bits mais  $h$  prends  $m$  bits de stockage, on veut progresser.

**Théorème 5.4.** Soit  $u \in \{0, 1\}^{\lceil \ln(m) \rceil}$  aléatoire. On définit :

$$h : \begin{array}{l} [m] \rightarrow \{-1, 1\} \\ x \mapsto (-1)^{u \cdot x} \end{array}$$

La fonction  $h$  ainsi construite suffit pour avoir  $\mathbb{E}(V) = F_2$

**Preuve:** Il suffit de prouver que pour  $x \neq x'$  et  $(s, s')$  donnés :

$$\mathbb{P}[h(x) = s \text{ et } h(x') = s'] = \frac{1}{4}$$

Pour cela on pose  $S_{tt'} = \left\{ u \in \{0, 1\}^{\lceil \ln(m) \rceil} \mid u \cdot x = s \text{ et } u \cdot x' = s' \text{ [modulo 2]} \right\}$

On montre ensuite que les 4  $S_{tt'}$  sont en translations les uns par rapport aux autres, et donc en bijection. □

**Algorithm 2** Mémoire  $\ln(n)$ , déterministe

---

```

v ← 0, c ← 0
while (stream ≠ ∅) do
  a ← next
  if a == v then
    c ← c + 1
  else
    if c == 0 then
      v ← a
      c ← 1
    else
      c ← c - 1
    end if
  end if
end while
return v

```

---

## 5.2 Trouver les éléments fréquents

**Théorème 5.5.** Si un élément  $j$  a une fréquence  $f_j > \frac{n}{2}$  l'algorithme 2 le renvoie de manière déterministe.

**Preuve:** Notons  $j$  l'élément dominant,  $m_d$  le nombre de fois que l'on l'a vu après  $d$  tours de boucles, et

$$c' = \begin{cases} c & \text{si } v == j \\ -c & \text{si } v \neq j \end{cases}$$

Il suffit de vérifier  $c' \geq m_d$  à chaque instant pour prouver que  $c' > 0$  à la fin de l'algorithme, et donc  $j$  est renvoyé.  $\square$

**Corollaire 5.6.** En deux passes on peut décider s'il y a un dominant.

**Preuve:** On applique l'algorithme 2 pendant la première passe, il nous donne le seul candidat possible. La seconde passe calcule la fréquence de ce candidat.  $\square$

**Corollaire 5.7.** On peut renvoyer  $k$  éléments distincts tels que  $f_j > \frac{n}{k+1}$ .

**Preuve:** On applique l'algorithme 2 avec  $k$  valeurs et  $k$  compteurs.  $\square$