

TD : HACHAGE – RUSH HOUR

$$\text{hash}(e) = \sum_{\substack{0 \leq i < M \\ 0 \leq j < M}} d_{i,j} 3^{iM+j}$$

... où pour tout $i, j \in [0, M[:$

$$d_{i,j} = \begin{cases} 0 & \text{si la case } (i,j) \text{ est inoccupée} \\ 1 & \text{si la case } (i,j) \text{ est occupée par un véhicule horizontal} \\ 2 & \text{si la case } (i,j) \text{ est occupée par un véhicule vertical} \end{cases}$$

3. Montrer que si e_1 et e_2 sont deux états accessibles à partir d'un même état initial e et que $\text{hash}(e_1) = \text{hash}(e_2)$, alors $e_1 = e_2$.

Supposons que $\text{hash}(e_1) = \text{hash}(e_2)$:

$$\text{hash}(e_1) = \sum_{\substack{0 \leq i < M \\ 0 \leq j < M}} d_{i,j}^{(1)} 3^{iM+j} \text{ et } \text{hash}(e_2) = \sum_{\substack{0 \leq i < M \\ 0 \leq j < M}} d_{i,j}^{(2)} 3^{iM+j}$$

... avec $d_{i,j}^{(1)}, d_{i,j}^{(2)} \in \{0, 1, 2\}$

Alors on a :

$$\sum_{\substack{0 \leq i < M \\ 0 \leq j < M}} (d_{i,j}^{(1)} - d_{i,j}^{(2)}) 3^{iM+j} = 0$$

Cette somme n'est rien d'autre que l'égalité de deux écritures en base 3 où chaque $d_{i,j}$ est un « chiffre » en base 3 (0, 1 ou 2) dont la position est donnée par l'indice $(i \cdot M + j) \in \{0, 1, 2, \dots, M, M+1, M+2, \dots, (M^2-1)\}$.

Or si un entier a deux écritures en base 3 : $\sum a_p 3^p = \sum b_p 3^p$, alors forcément $a_p = b_p$ pour tout p et donc :

$$\forall i, j, \quad d_{i,j}^{(1)} = d_{i,j}^{(2)}$$

Les deux états e_1 et e_2 ont donc exactement le même motif de cases vides / horizontales / verticales. Les véhicules associés à ces deux états ont donc les mêmes positions, mêmes longueurs, et mêmes directions et donc $e_1 = e_2$.

8. Expliquer en quoi ce serait une mauvaise idée de remplacer le 3^{iM+j} par 4^{iM+j} dans la définition de $\text{hash}(e)$.

Première idée : Notion de débordement :

Si $M=6$, avec la base 3, on a des « chiffres » $d_{i,j} \in \{0, 1, 2\}$, donc on utilise une base 3 sans débordement dans un `int64` car pour $M=6$, on a au plus $1 \cdot 3^0 + 3 \cdot 3^1 + \dots + 3 \cdot 3^{35} < (3^{36} - 1) < 2^{63} - 1$.

Si on remplace 3^{iM+j} par 4^{iM+j} alors pour $M=6$ on monte à $1 \cdot 4^0 + 3 \cdot 4^1 + \dots + 3 \cdot 4^{35} > 3 \cdot 4^{35} > 2^{71}$ ce qui dépasse largement la capacité d'un entier signé 64 bits (environ 2^{63}). On provoquerait donc des débordements arithmétiques et des collisions de hash très nombreuses, ce qui détruirait l'argument d'injectivité.

Deuxième idée : certains termes valent 0 modulo 2^p .

Dans la table de hachage, on ne garde que $h = \text{hash}(e) \bmod 2^p$.

Si on utilise la base 4, on a $4^{iM+j} = 2^{2(iM+j)}$ et $h(e) = \sum_{\substack{0 \leq i < M \\ 0 \leq j < M}} d_{i,j} 2^{2(iM+j)} \bmod 2^p$

Ici, dès que $2 \cdot (iM+j) \geq p$, on a $4^{iM+j} \equiv 0 \pmod{2^p}$. Cela entraîne que toutes les contributions des termes avec $(iM+j) \geq [p/2]$ disparaissent dans le calcul de $\text{hash}(e) \% 2^p$. Autrement dit, le reste modulo 2^p ne dépend plus du tout de ce qui se passe sur « les cases hautes » (celles correspondant aux grands $i \cdot M + j$). Deux états qui diffèrent uniquement sur ces cases-là auront le même indice dans la table de hachage, même si on évitait l'overflow avec des entiers arbitraires.

Exemple : grille 2×2 , base 4, capacité 4

On a $M=2$ et $p = 2$:

$$\text{hash}(e) = d_{0,0} \cdot 4^0 + d_{0,1} \cdot 4^1 + d_{1,0} \cdot 4^2 + d_{1,1} \cdot 4^3$$

$$h(e) = (d_{0,0} \cdot 4^0 + d_{0,1} \cdot 4^1 + d_{1,0} \cdot 4^2 + d_{1,1} \cdot 4^3) \bmod 4$$

$$h(e) = (d_{0,0} \cdot 4^0 \bmod 8 + d_{0,1} \cdot 4^1 \bmod 8 + d_{1,0} \cdot 4^2 \bmod 8 + d_{1,1} \cdot 4^3 \bmod 8) \bmod 4$$

$$h(e) \equiv d_{0,0} \cdot 4^0 + 0 \cdot 4^1 + 0 \cdot 4^2 + 0 \cdot 4^3 \pmod{4}$$

L'indice de la table ne dépend donc que de la case (0,0).