

Ampliació d'Algorismia: Aproximation, Parameterization and Streaming

QP 2022-2023: Sheet 3

29. Tenim un flux de dades que conté tots els nombres al conjunt $\{1, \dots, n\}$ menys un. Dissenyeu un algorisme per trobar l'element que falta. El vostre algorisme pot llegir el flux només una vegada i fer servir $O(\log n)$ espai a memòria. L'algorisme ha de proporcionar la resposta correcta després de processar tota l'entrada.

30. Considereu el següent algorisme que processa un graf G amb n nodes i donat per un flux d'arestes.

1. Selecciona una aresta (u, v) amb distribució uniforme sobre les arestes d' E .
 2. Selecciona amb distribució uniforme un vèrtex de $V \setminus \{u, v\}$
 3. Si (u, w) i v, w apareixen després de (u, v) en el flux, la sortida és $m(n - 2)$, si no serà 0.
- (a) Proporcioneu una implementació com algorisme de streaming. El vostre algorisme només pot fer una pasada per el stream i utilitzar $O(n \log n)$ memòria.
- (b) Demostreu que l'algorisme proporciona una estimació del nombre de triangles al graph G .

31. Consider the following graph streaming algorithm

```
1: procedure PARTTREE(int  $n$ , stream  $s$ )
2:    $F = \emptyset$ ,  $x = 1$ 
3:   while not  $s.end()$  do
4:      $(u, v) = s.read()$ 
5:     if  $x$  then
6:       if  $F \cup \{(u, v)\}$  does not contain a cycle then
7:          $F = F \cup \{(u, v)\}$ 
8:       else
9:         if  $F \cup \{(u, v)\}$  contains an odd cycle then
10:           $x = 0$ 
11:        end if
12:      end if
13:    end if
14:   end while
15:   On query, report  $x$ 
16: end procedure
```

- Analyze the performance of PARTTREE.
- Show that the answer to a query is 1 iff and only if the already seen graph is 2-colorable.
- Modify the algorithm so that in addition, when the answer is 1, it provides a valid 2-coloring of G . Justify the efficiency and correctness of your proposal.

32. Considereu el següent algoritme de streaming que intenta resoldre el problema de trobar un matching amb pes màxim a un graf amb pesos a les arestes. Per aquest tipus de grafs l'algorisme té un paràmetre addicional $\gamma > 0$.

Per simplicitat al codi veurem una aresta $e = (u, v)$ com el conjunt $\{u, v\}$. Així podem escriure la condició $e \cap e' \neq \emptyset$ indicant si les arestes e i e' son incidents o no. Cada component del stream té dos valors indicant el primer el conjunt corresponent als vèrtexs de l'aresta i el segon el pes de aquesta aresta.

```

1: procedure GWM(int  $n$ , stream  $s$ , double  $\gamma$ )
2:    $M = \emptyset$ 
3:   while not  $s.end()$  do
4:      $(e, w) = s.read()$ 
5:      $C = \{e' \in M \mid e \cap e' \neq \emptyset\}$ 
6:      $W = \sum_{e \in C} w(e)$ 
7:     if  $w/W \geq (1 + \gamma)$  then
8:        $M = (M \cup \{e\}) \setminus C$ 
9:     end if
10:   end while
11:   On query, report  $M$ 
12: end procedure
```

Per analitzar el rendiment de aquest algorisme diem que un aresta es un *supervivent* si forma part del conjunt M al finalitzar el tractament del stream. Cada supervivent $e \in M$ ha deixat un rastre de arestes mortes, afegides a M en algun moment i després eliminades. Aquest rastre es pot formalitzar com $T_e = C_1 \cup C_2 \cup \dots$, on els C 's es poden definir recursivament. $C_0 = \{e\}$, i

$$C_i = \bigcup_{e' \in C_{i-1}} \{\text{arestes eliminades de } M \text{ en afegir } e'\}.$$

Definim $T(M) = \bigcup_{e \in M} T_e$. Demostreu què:

- (a) $w(T(M)) \leq w(M)/\gamma$
- (b) $\text{opt}(G) \leq (1 + \gamma)(w(T(M)) + 2w(M))$
- (c) Quin és el valor de γ que proporciona el millor rendiment per GWM?

33. Hemos visto como usar reservoir sampling para muestreo de un stream del que no conocemos su longitud. Queremos extender este resultado a la estimación de valores de una función definida sobre el stream.

Tenemos un stream $s = a_1, a_2, \dots, a_m$ formado por valores enteros en $[n] = \{0, \dots, n - 1\}$. Para $i \in [n]$, f_i denota la frecuencia de i en s . Queremos estimar el valor

$$g(s) = \sum_{i \in [n]} g(f_i),$$

donde g es una función con valores reales, con $g(0) = 0$.

El siguiente algoritmo combina la obtención de una muestra con un conteo parcial:

- Obtener x , una muestra (con distribución uniforme) sobre $[m]$
 - $r = |\{i \geq x \mid a_i = a_x\}|$
 - Return $m(g(r) - g(r - 1))$
- a) Demostrad que el algoritmo propuesto proporciona un estimador de la función g .
- b) Proporcionad una implementación del algoritmo propuesto para un stream de datos del que no conocéis su longitud m .