

Nouveaux résultats sur le tri par transpositions

Anthony Labarre¹

23 Janvier 2006

Université Libre de Bruxelles
alabarre@ulb.ac.be

ALPHY/GTGC 2006

¹Subventionné par le “Fonds pour la Formation à la Recherche dans l’Industrie et dans l’Agriculture” (F.R.I.A.).

Contexte et motivation

- ▶ Réarrangements génomiques: mesure de divergence entre les espèces;
- ▶ Nos hypothèses:
 - ▶ ordre des gènes connu;
 - ▶ tous les génomes partagent le même ensemble/nombre de gènes;
 - ▶ un seul type de mutation pris en compte;

Tri par transpositions

- ▶ *Transposition* = échange de deux intervalles adjacents:

$$\begin{array}{c} (2 \ 1 \ \boxed{7 \ 3 \ 5 \ 6} \ \boxed{4 \ 10 \ 9} \ 8) \\ \downarrow \\ (2 \ 1 \ \boxed{4 \ 10 \ 9} \ \boxed{7 \ 3 \ 5 \ 6} \ 8) \end{array}$$

- ▶ *Distance des transpositions* $d(\pi, \sigma)$ = nombre minimal de transpositions transformant π en σ ;
- ▶ *Tri par transpositions*: ramener une permutation à l'identité $\iota = (1 \ 2 \ \cdots \ n)$ par un nombre minimal de transpositions;

Exemple

- ▶ Le tri de $\pi = (3 \ 1 \ 4 \ 2)$ nécessite deux transpositions:

$$\begin{array}{c} \pi = (3 \ \boxed{1} \ \boxed{4} \ 2) \\ \downarrow \\ (\ \boxed{3 \ 4} \ \boxed{1 \ 2} \) \\ \downarrow \\ \iota = (1 \ 2 \ 3 \ 4) \end{array}$$

- ▶ Donc $d(\pi, \iota) = d(\pi) = 2$.

Status du problème

- ▶ Complexité:
 - ▶ du tri: **inconnue**;
 - ▶ du calcul de la distance: **inconnue**;
- ▶ Valeur maximale: **inconnue** (entre $\lfloor \frac{n+1}{2} \rfloor + 1$ et $\lfloor \frac{2n-2}{3} \rfloor$);
- ▶ Meilleur taux d'approximation: $\frac{11}{8}$ [Elias and Hartman, 2005];


Le graphe des cycles [Bafna and Pevzner, 1998]

► Soit $\pi = (4\ 1\ 6\ 2\ 5\ 7\ 3)$;

● ● ● ● ● ● ● ● ●
0 4 1 6 2 5 7 3 8


Le graphe des cycles [Bafna and Pevzner, 1998]

- ▶ Soit $\pi = (4\ 1\ 6\ 2\ 5\ 7\ 3)$;




Le graphe des cycles [Bafna and Pevzner, 1998]

- Soit $\pi = (4\ 1\ 6\ 2\ 5\ 7\ 3)$;



Cycles alternés


- ▶ Décomposition unique en cycles alternés:



- ▶ *Parité* d'un cycle = celle du nombre d'arcs horizontaux qu'il contient; ici, $c(G(\pi)) = 2 = c_{\text{odd}}(G(\pi))$.

Cycles alternés


- ▶ Nombre maximal de cycles alternés pour $(1\ 2\ \dots\ n)$:



- ▶ Donc trier par transpositions revient à créer des cycles alternés impairs “le plus vite possible”;

Une minoration

Au mieux: deux nouveaux cycles impairs en une transposition:



Théorème

[Bafna and Pevzner, 1998] $\forall \pi \in S_n : d(\pi) \geq \frac{n+1-c_{\text{odd}}(G(\pi))}{2}$.

Résultats ([Labarre, 2005] et [Labarre, 2006])

1. Liens entre la théorie “traditionnelle” et une structure plus classique;
2. Caractérisation de classes de permutations dont la distance est calculable en temps polynomial, sans graphe;
3. Nouvelles majorations et, dans certains cas, la distance exacte.

Permutations réduites

- ▶ *Point de rupture* : couple (π_i, π_{i+1}) avec $\pi_{i+1} \neq \pi_i + 1$;
- ▶ $b(\pi)$ = nombre de points de rupture de π ;
- ▶ π est *réduite* si $b(\pi) = n - 1$, $\pi_1 \neq 1$, et $\pi_n \neq n$.

réduite	non réduites
(4 2 1 3)	(<u>1</u> 4 3 2)
	(3 2 1 <u>4</u>)
	(4 <u>2</u> <u>3</u> 1)


Théorème

[Christie, 1998] Toute permutation est “réductible”, et ceci n’affecte pas sa distance.

Le Γ -graphe


- ▶ Toute permutation est le produit de cycles disjoints;
- ▶ Le Γ -*graphe* est le *graphe de la permutation* muni d'un ordre total sur les sommets.

Soit $\pi = (4\ 1\ 6\ 2\ 5\ 7\ 3) = (1, 4, 2)(3, 6, 7)(5)$; alors $\Gamma(\pi)$ est:



Quelques définitions


- ▶ Un k -cycle de $\Gamma(\pi)$ contient k sommets;
- ▶ Un k -cycle est (*im*)pair si k est (*im*)pair;
- ▶ *Monotonicité* d'un cycle:



Les γ -permutations

Définition


Une γ -permutation est une permutation réduite fixant tous les éléments pairs.



Correspondance entre G et Γ

Proposition

Si π est une γ -permutation, alors tout k -cycle de $\Gamma(\pi)$ ($k \geq 2$) apparaît exactement deux fois dans $G(\pi)$.



Minoration sur la distance des γ -permutations

- ▶ Rappel: $d(\pi) \geq \frac{n+1-c_{\text{odd}}(G(\pi))}{2}$ (Théorème 1);
- ▶ Donc, par la proposition précédente:

Lemme

Pour toute γ -permutation π de S_n , on a: $d(\pi) \geq n - c_{\text{odd}}(\Gamma(\pi))$.


- ▶ Stratégie: traiter séparément chaque cycle de $\Gamma(\pi)$;

Cycles monotones

Proposition

Si π est une γ -permutation de S_n ne contenant qu'un seul "grand cycle" monotone C , alors:

$$d(\pi) = n - c_{\text{odd}}(\Gamma(\pi)) = |C| - (|C| \bmod 2).$$



Exemple

$$\begin{aligned} & (3 \boxed{25} \boxed{476981}) \quad 1 \\ & (\boxed{34} \boxed{769812} 5) \quad 2 \\ & (7 \boxed{69} \boxed{812345}) \quad 3 \\ & (\boxed{78} \boxed{123456} 9) \quad 4 \\ & (123456789) \end{aligned}$$

$$\Rightarrow d(\pi) = 4 = 5 - (5 \bmod 2).$$


Cycles non-monotones

Même résultat pour les cycles non-monotones:

Proposition

Si π est une γ -permutation de S_n ne contenant qu'un seul "grand cycle" non-monotone C , alors:

$$d(\pi) = n - c_{\text{odd}}(\Gamma(\pi)) = |C| - (|C| \bmod 2).$$




Distance des γ -permutations

- ▶ Récapitulons; si π est une γ -permutation de S_n , alors:
 - ▶ $d(\pi) \geq n - c_{\text{odd}}(\Gamma(\pi))$;
 - ▶ tout cycle de $\Gamma(\pi)$ peut être traité indépendamment des autres;
 - ▶ la distance de chaque cycle atteint la minoration;
- ▶ Donc:

$$d(\pi) = n - c_{\text{odd}}(\Gamma(\pi)).$$


Une nouvelle majoration

- ▶ Toute permutation (sauf ι) peut être obtenue à partir d'une γ -permutation.




Une nouvelle majoration

- ▶ Toute permutation (sauf ι) peut être obtenue à partir d'une γ -permutation.



Une nouvelle majoration

- ▶ Toute permutation (sauf ι) peut être obtenue à partir d'une γ -permutation.




Théorème

$$\forall \pi \in S_n : d(\pi) \leq n - c_{\text{odd}}(\Gamma(\pi)).$$



Autres instances solubles

- ▶ Que se passe-t'il quand on supprime des 1-cycles dans Γ ?




Autres instances solubles

- ▶ Que se passe-t'il quand on supprime des 1-cycles dans Γ ?





Autres instances solubles

- ▶ Que se passe-t'il quand on supprime des 1-cycles dans Γ ?




Autres instances solubles

- ▶ Que se passe-t'il quand on supprime des 1-cycles dans Γ ?



Autres instances solubles


- ▶ Que se passe-t'il quand on supprime des 1-cycles dans Γ ?



- ▶ k suppressions $\Rightarrow c_{\text{odd}}(G(\pi)) = k$

Autres instances solubles

- ▶ Que se passe-t'il quand on supprime des 1-cycles dans Γ ?



- ▶ k suppressions $\Rightarrow c_{odd}(G(\pi)) = k$
- ▶ dans ce cas:

$$d(\pi) = n - c_{odd}(\Gamma(\pi)) - k + \left(\frac{n + k + 1}{2} \bmod 2 \right).$$

Suppression de points fixes entre deux cycles monotones

- ▶ Si aucun “grand” cycle n’en croise d’autre, alors:
 - ▶ la stratégie utilisée pour les γ -permutations est encore optimale;
 - ▶ la distance de chaque cycle est connue;
- ▶ On a :

$$d(\pi) = n - c_{\text{odd}}(\Gamma(\pi)) - K + \sum_{i=1}^t \left(\frac{n_i + k_i + 1}{2} \bmod 2 \right).$$

- ▶ Autres cas solubles dérivables;

Problèmes ouverts

- ▶ Complexité?
- ▶ Diamètre?
- ▶ Meilleurs résultats:
 - ▶ pour les cycles non-monotones?
 - ▶ pour les cycles se croisant?

Références

-  Bafna, V. and Pevzner, P. A. (1998).
Sorting by transpositions.
SIAM J. Discrete Math., 11(2):224–240 (electronic).
-  Christie, D. A. (1998).
Genome Rearrangement Problems.
PhD thesis, University of Glasgow, Scotland.
-  Elias, I. and Hartman, T. (2005).
A 1.375–Approximation Algorithm for Sorting by Transpositions.
In *Proceedings of WABI*, LNCS 3692, pages 204–215.
-  Labarre, A. (2005).
A new tight upper bound on the transposition distance.
In *Proceedings of WABI*, LNCS 3692, pages 216–227.
-  Labarre, A. (2006).
New bounds and tractable instances for the transposition distance.
Soumis.