

**Институт проблем передачи информации  
Российской академии наук**

Лаборатория «**Математических  
методов и моделей в биоинформатике**»

сайт лаборатории: <http://lab6.iitp.ru/>

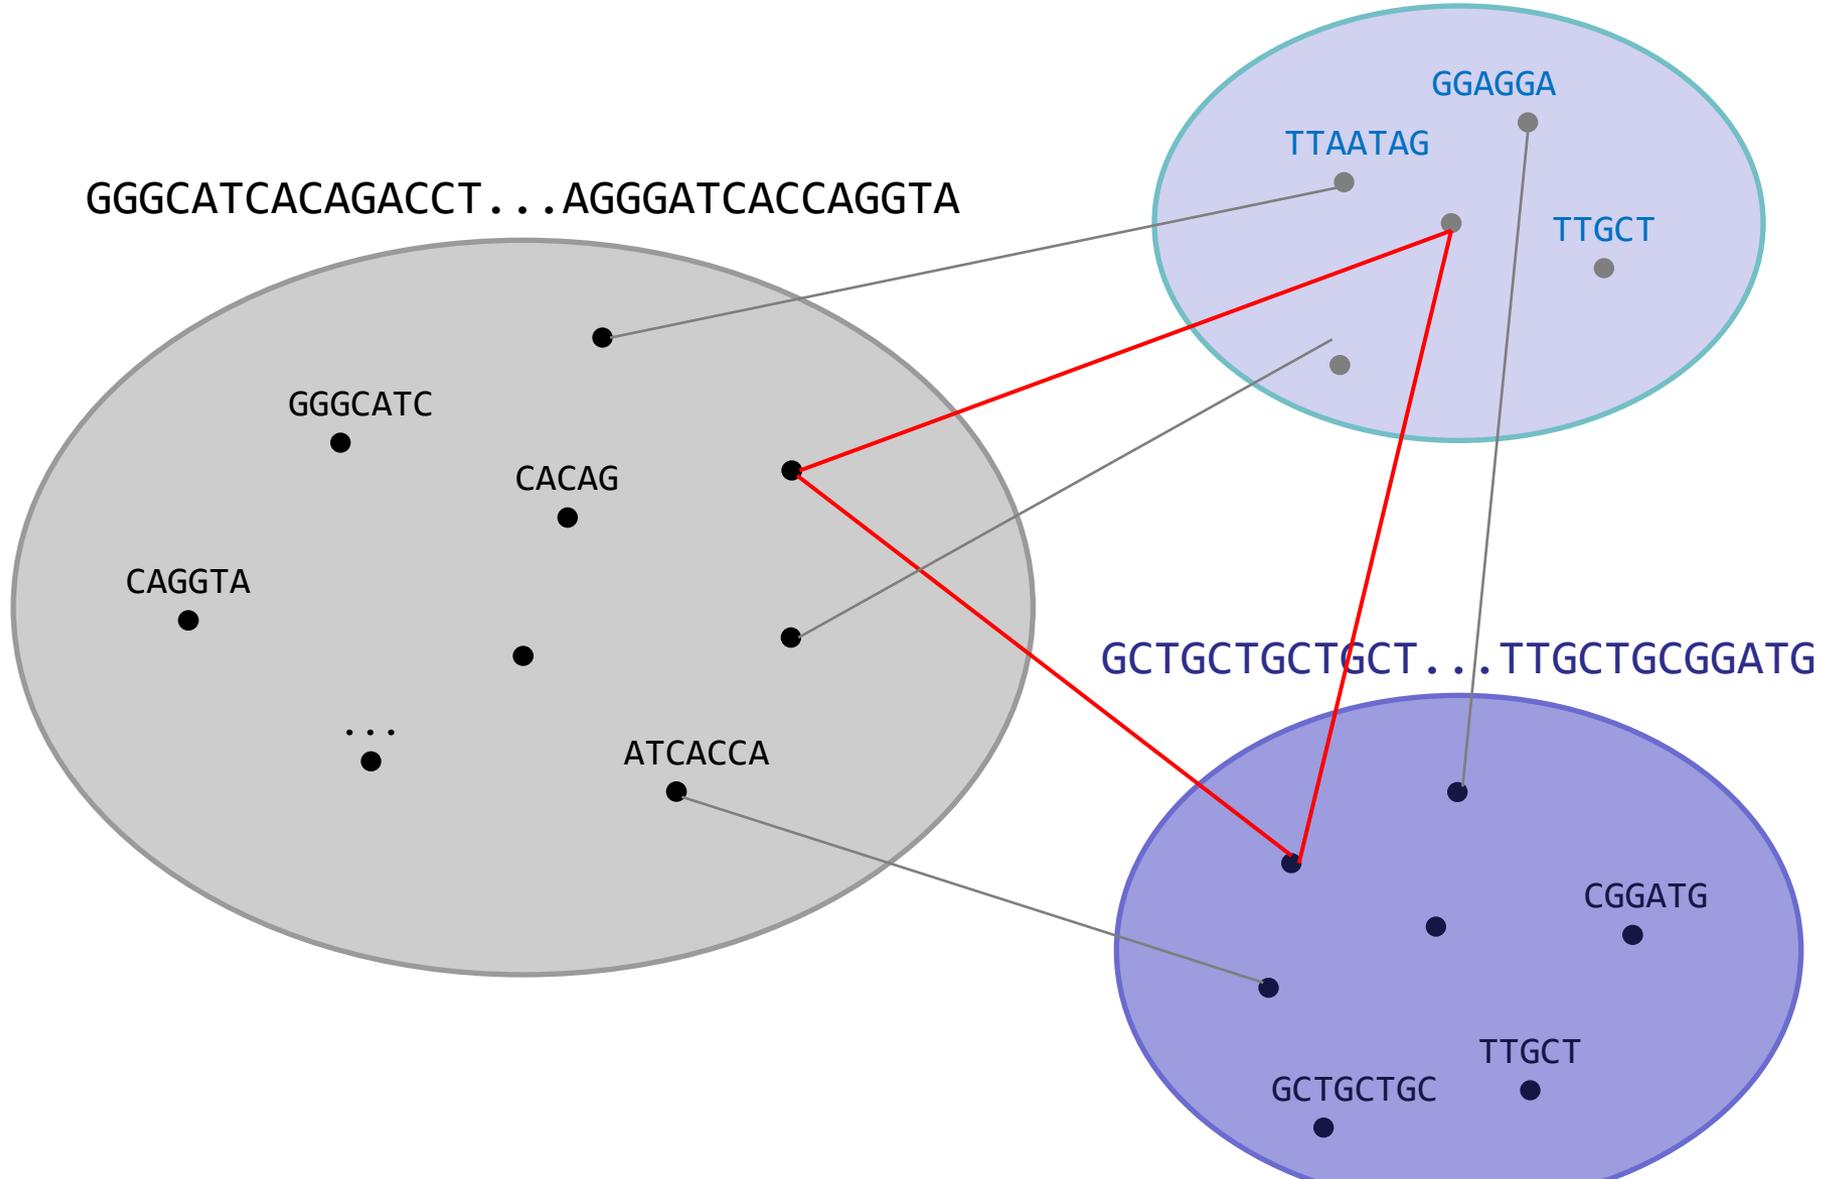
адрес: [lyubetsk@iitp.ru](mailto:lyubetsk@iitp.ru)

**В. Любецкий, К. Горбунов, А. Селиверстов**

**ОПТИМИЗАЦИЯ НА ГРАФАХ**

Типичная задача: дан **многодольный граф**, ребро – близость или иная характеристика пар слов. В нём ищем **клику** или **плотный подграф**:

TTAATAGGAGGA...CCATCTGTTGCT



Какого размера многодольные графы реально возникают в прикладных задачах? **Число долей  $10^5$** , длина последовательности  **$10^9$** , в ней берутся короткие слова, т.е. вершин в доле  $10^9$ : всего **вершин и степень каждой  $10^{14}$** .

*Найти слова, которые встречаются с заданной точностью в  $m=10^5$  последовательностях, с указанием их позиций в ней.*

Точность слов, например, 6 редакционных операций при их длине 150. **Построение графа включается в задачу, так как исходно даны только все последовательности.**

Трудоёмкость свыше  **$10^{28}$** ; **при этом нужна общая память – более терабайтного объёма.**

*Даже при этих скромных оценках нельзя решать задачу с использованием современных суперкомпьютеров.*

**1) Задача кластеризации в многодольном графе**  
состоит в разбиении графа на кластеры: в **кластере**  
**как можно меньше вершин из одной доли**, а как  
**можно больше долей в кластере**.

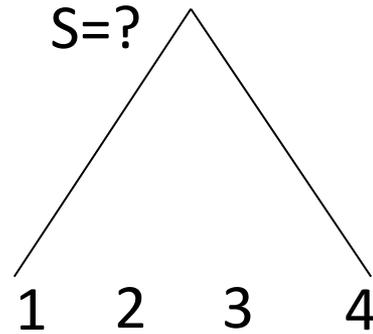
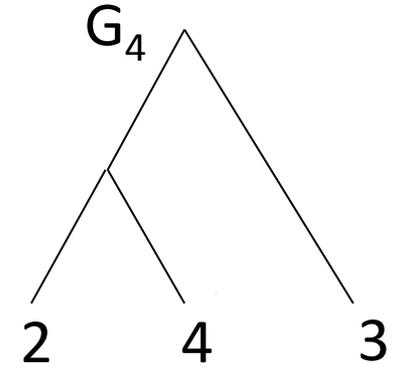
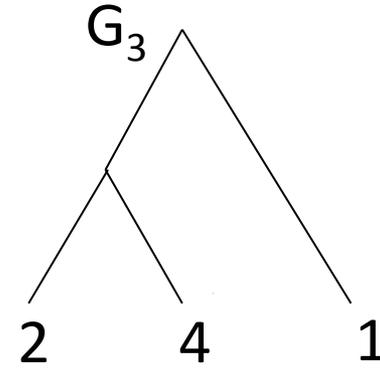
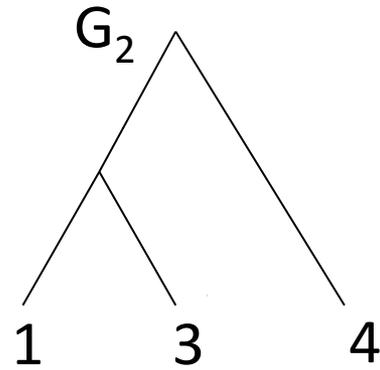
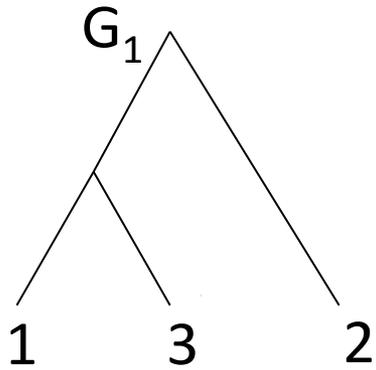
**Новая трудность – задача 2х-параметрическая!**

У нас есть алгоритм, довольно эффективно решающий эту задачу; на основе построения остовного дерева (что проблема). Нужно лучше, это – задача.

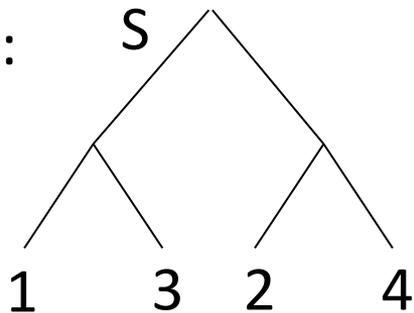
-----

**2) Задача согласования большого числа деревьев-  
ев в единое дерево**

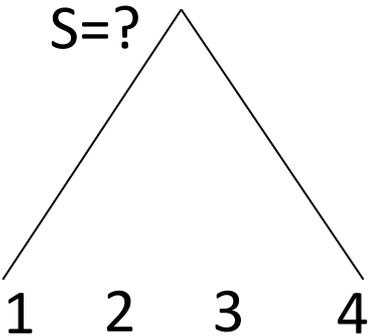
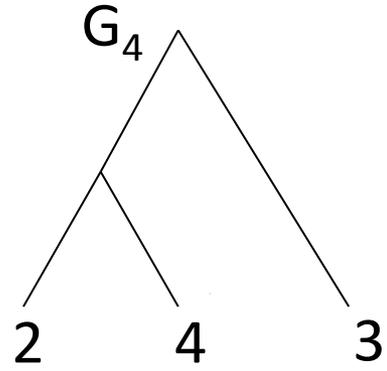
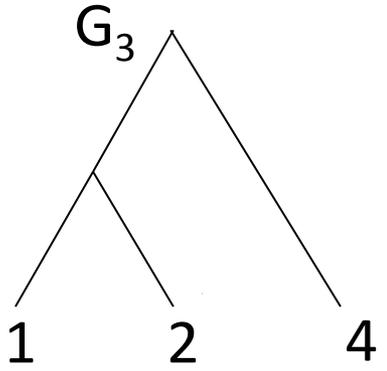
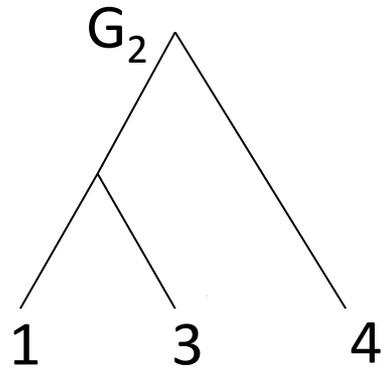
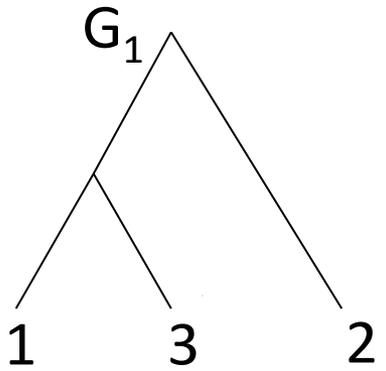
«Среднее» дерево = согласование деревьев. Для хорошо обусловленных данных решение однозначно:



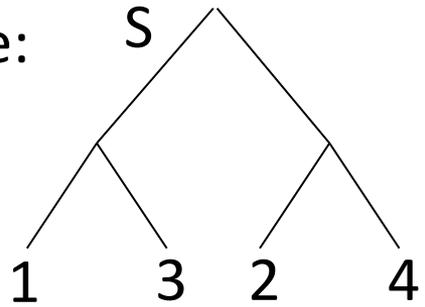
Решение:



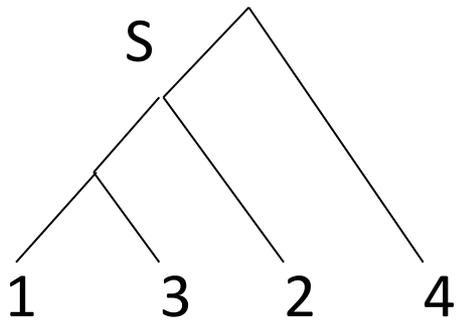
# Согласование деревьев. Для **плохо обусловленных данных** решение неоднозначно:



Решение:

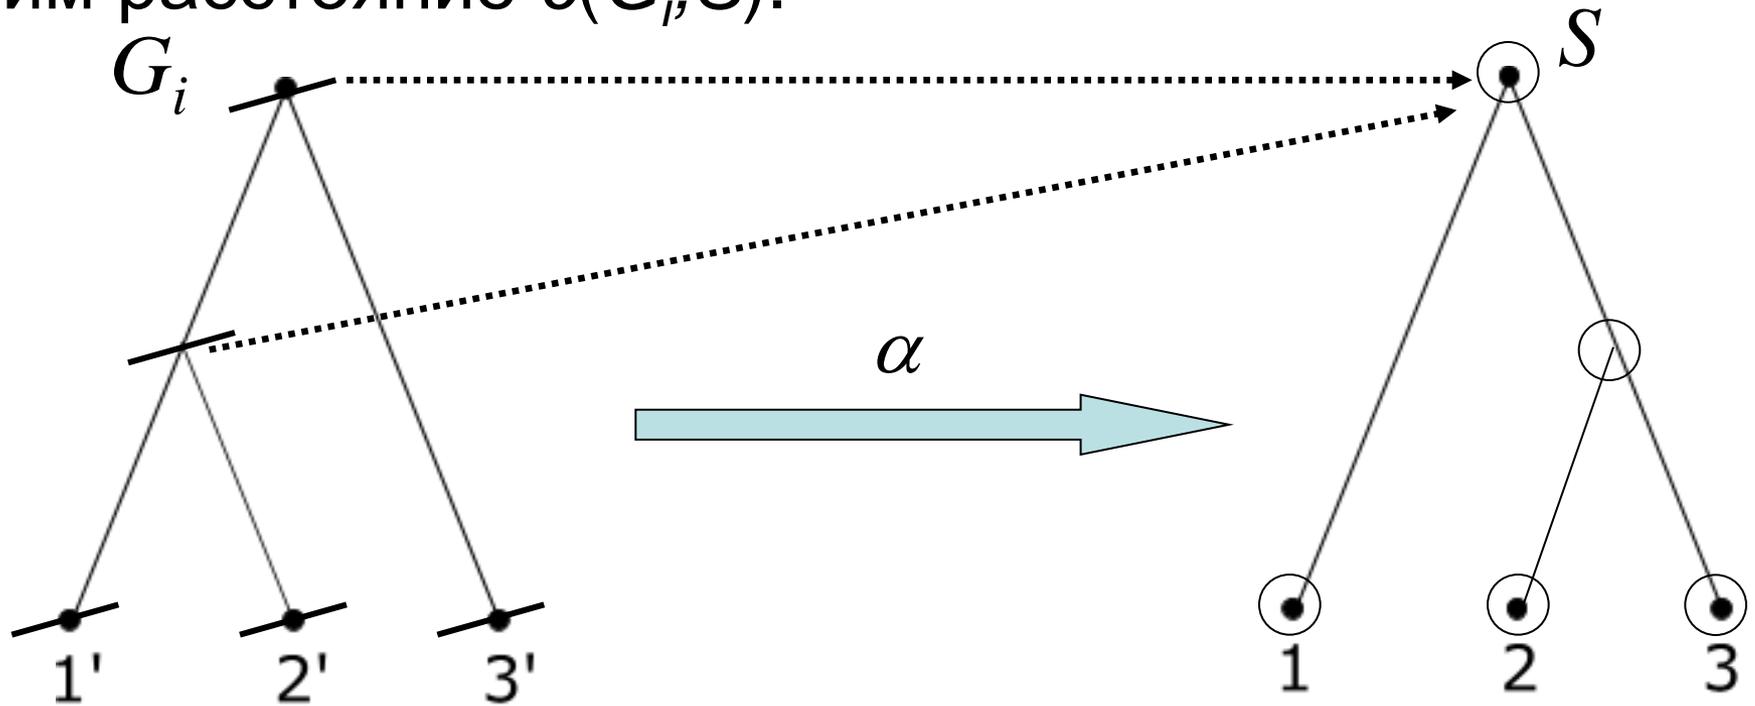


или



Прежде всего, определим **расстояние** от дерева до дерева. Затем **минимизируем**  $\sum_i c(G_i, S)$  **сумму расстояний** в пространстве всех деревьев, которое пробегает искомое  $S$ .

Итак, определим отображение  $\alpha$  и по нему вычислим расстояние  $c(G_i, S)$ .



$$c(G_i, S) = 2$$

Нами получен **кубический** алгоритм, который при некоторых условиях **точно!** находит такой минимум.

### 3) Редакционное **расстояние** между СС-графами.

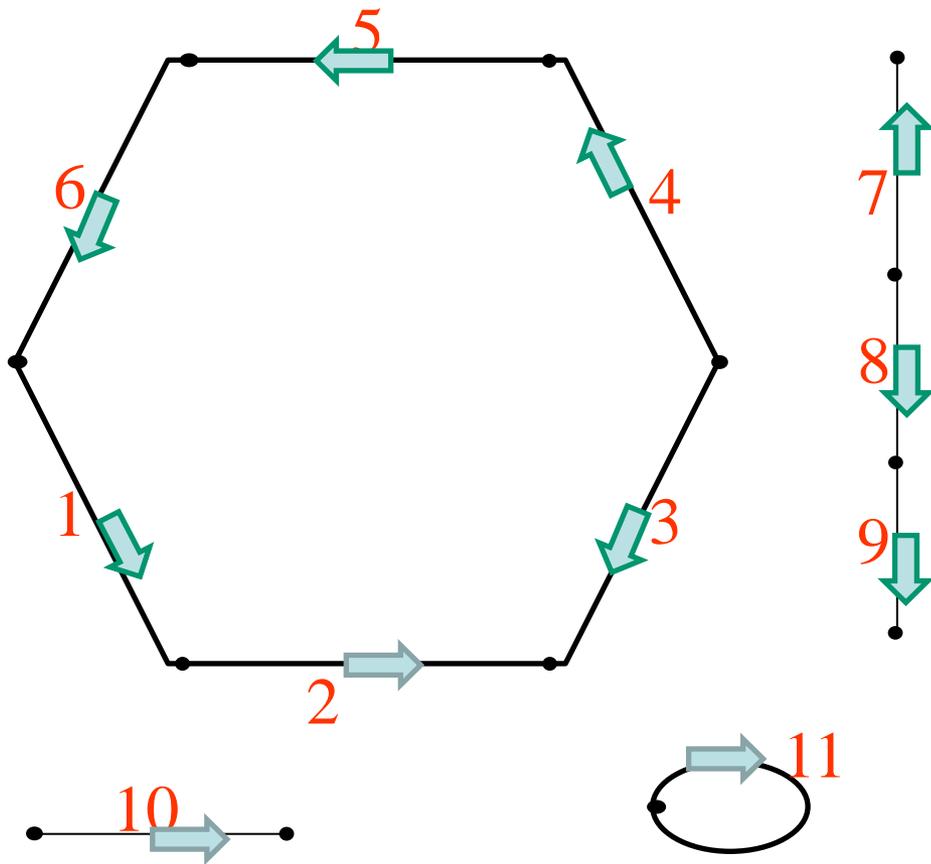
Сначала напомним это **расстояние** для **последовательностей**, оно широко используется.

Типичный пример:

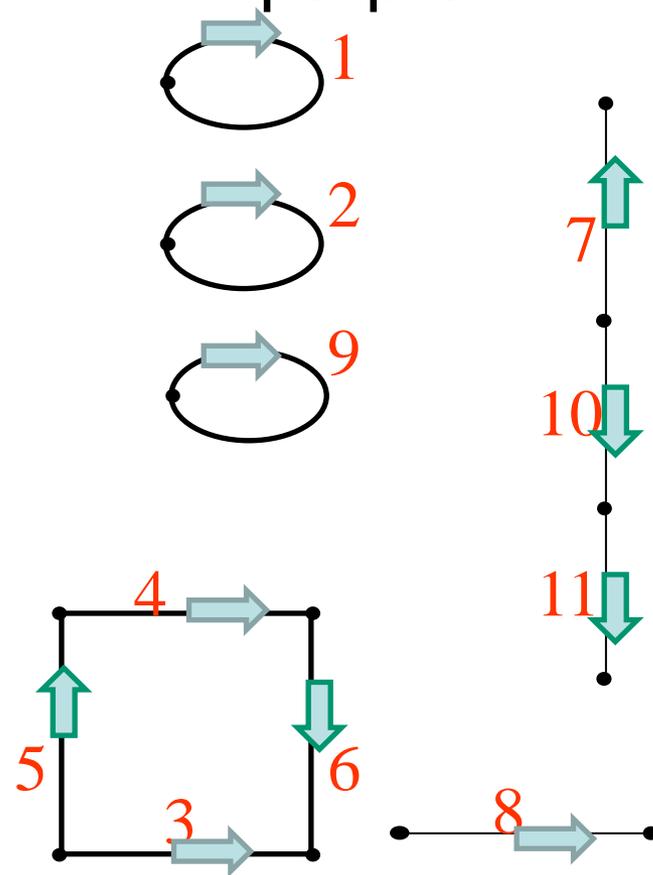
MNFKADN - - - - - IKYSLE EYTRYCKHLVLPQIKLE GQERLKKAKVLFIGA  
MLNPD LNS - - - - - LELTTTEYERYNKHLILPQIQIEGQKRLKMAKVLCIGA  
MKKNYTMNQKTQN LAKCTE IELSTDEYDIYSKQIILEQVGTEGQKKLRCTKVLVIGA

Содержимое понятие расстояния между графами появилось недавно! Фиксирован набор операций, преобразующих один граф в другой. Найти **расстояние – наименьшую длину последовательности операций**, которая преобразует  $a$  в  $b$ , и **саму последовательность этих операций**. // **СС-граф** состоит из произвольного числа **цепей и циклов**, каждое ребро направлено и помечено. Важный частный случай графов!

граф  $a$



граф  $b$

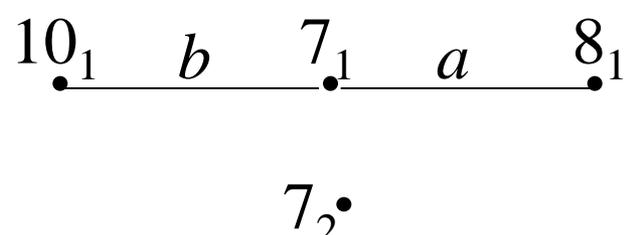
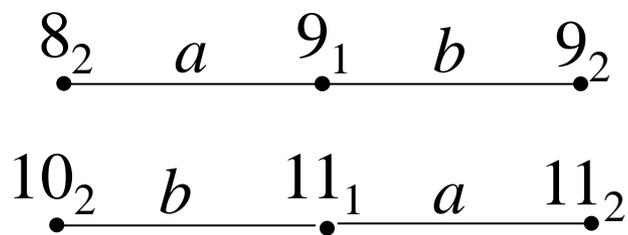
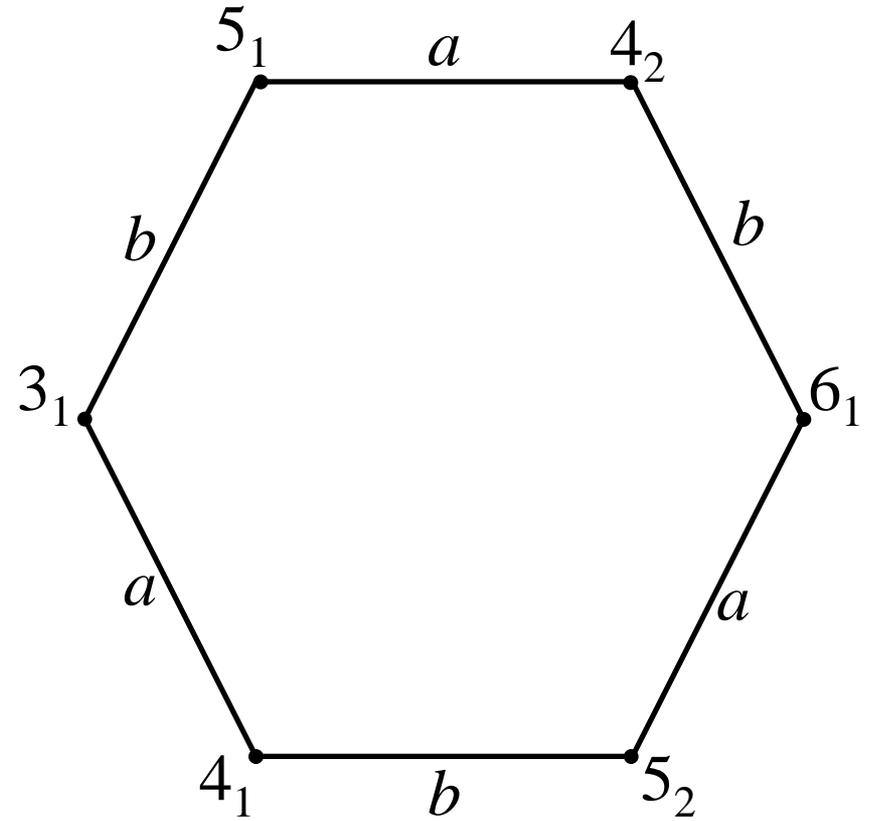
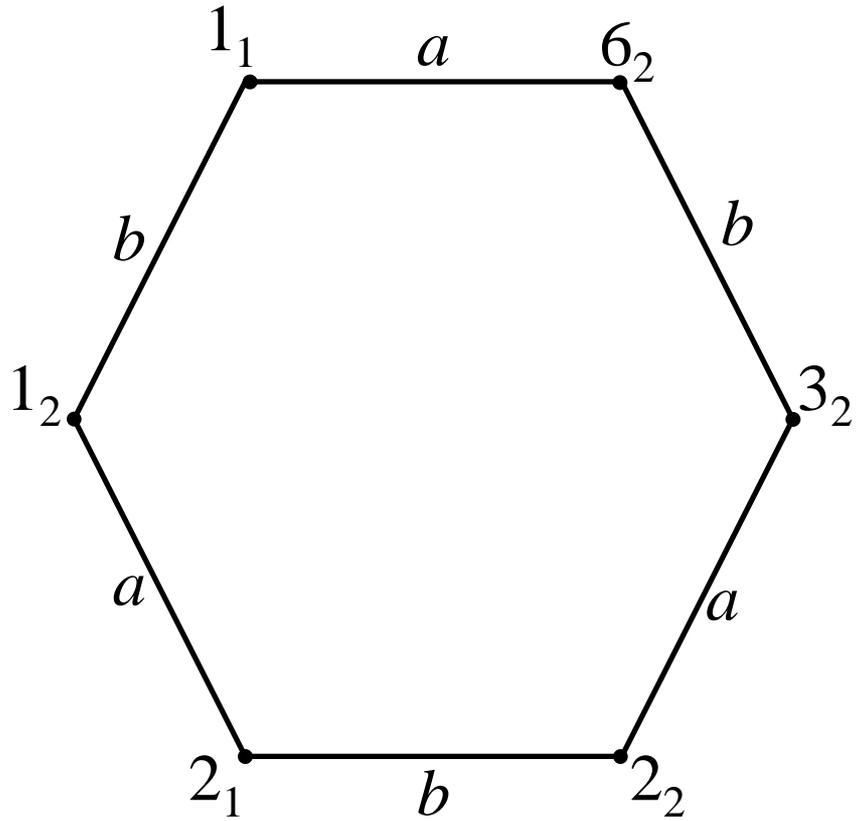


**Вариант Задачи:** каждой операции назначена своя цена, найти цену самой дешёвой последовательности операций которые переводят граф  $a$  в граф  $b$ , и саму эту последовательность. Нами найден **линейный алгоритм** (точно! при некотором условии) решающий эту Задачу для стандартного набора операций:

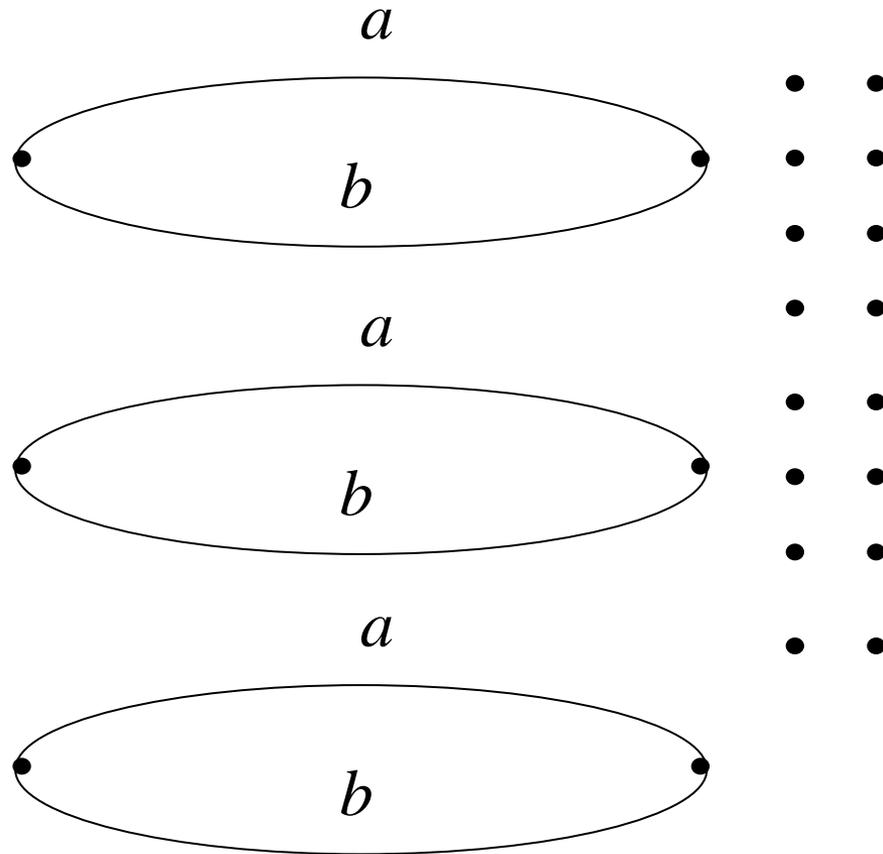
расклейка **двух склеек** в графе и склеивание четырёх освободившихся краёв рёбер по-другому;  
расклейка **одной склейки** и склеивание одного из освободившихся краёв ребра с каким-то свободным краем;  
**расклейка** одной склейки и **склейка** двух свободных краёв;  
**удаление/вставка** связного участка рёбер в графе.

**Исследование этой задачи для других наборов операций представляет также большой интерес.**

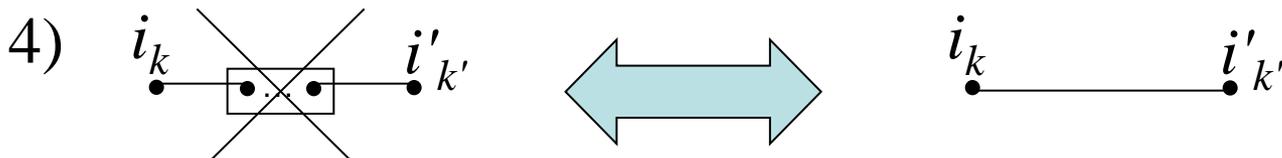
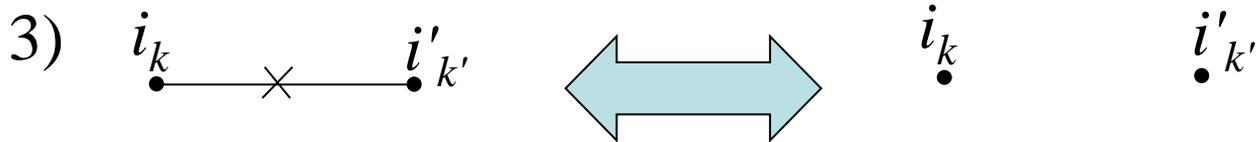
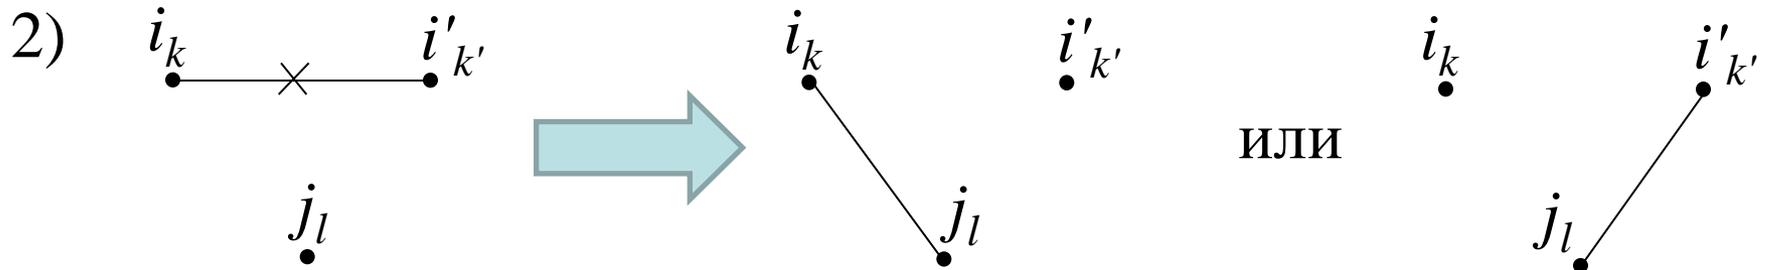
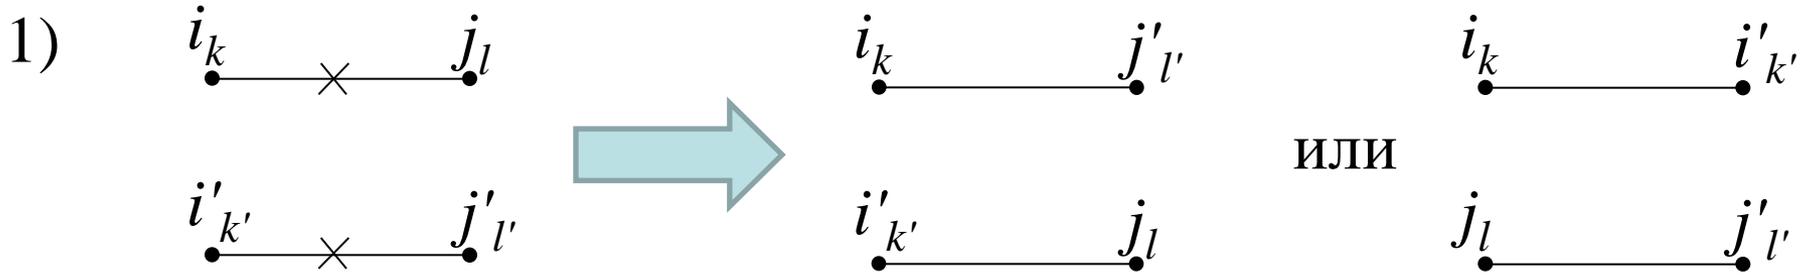
Задачу **удалось решить через показ на новом графе**, какие края рёбер склеены в  $a+b$ . Т.е. теперь единый граф показывает склеенность краёв сразу в двух исходных графах!



Исходная задача эквивалентна **приведению этими операциями графа краёв к следующему виду:**



# Соот-ие операции над «графом краёв» выглядят так:



В случае цен приходится **налагать условия**. Например, такие: сначала обозначим цены разреза  $c_1$ , склейки  $c_1'$ , полуторной переклейки  $c_{1.5}$ , двойной переклейки  $c_2$ .

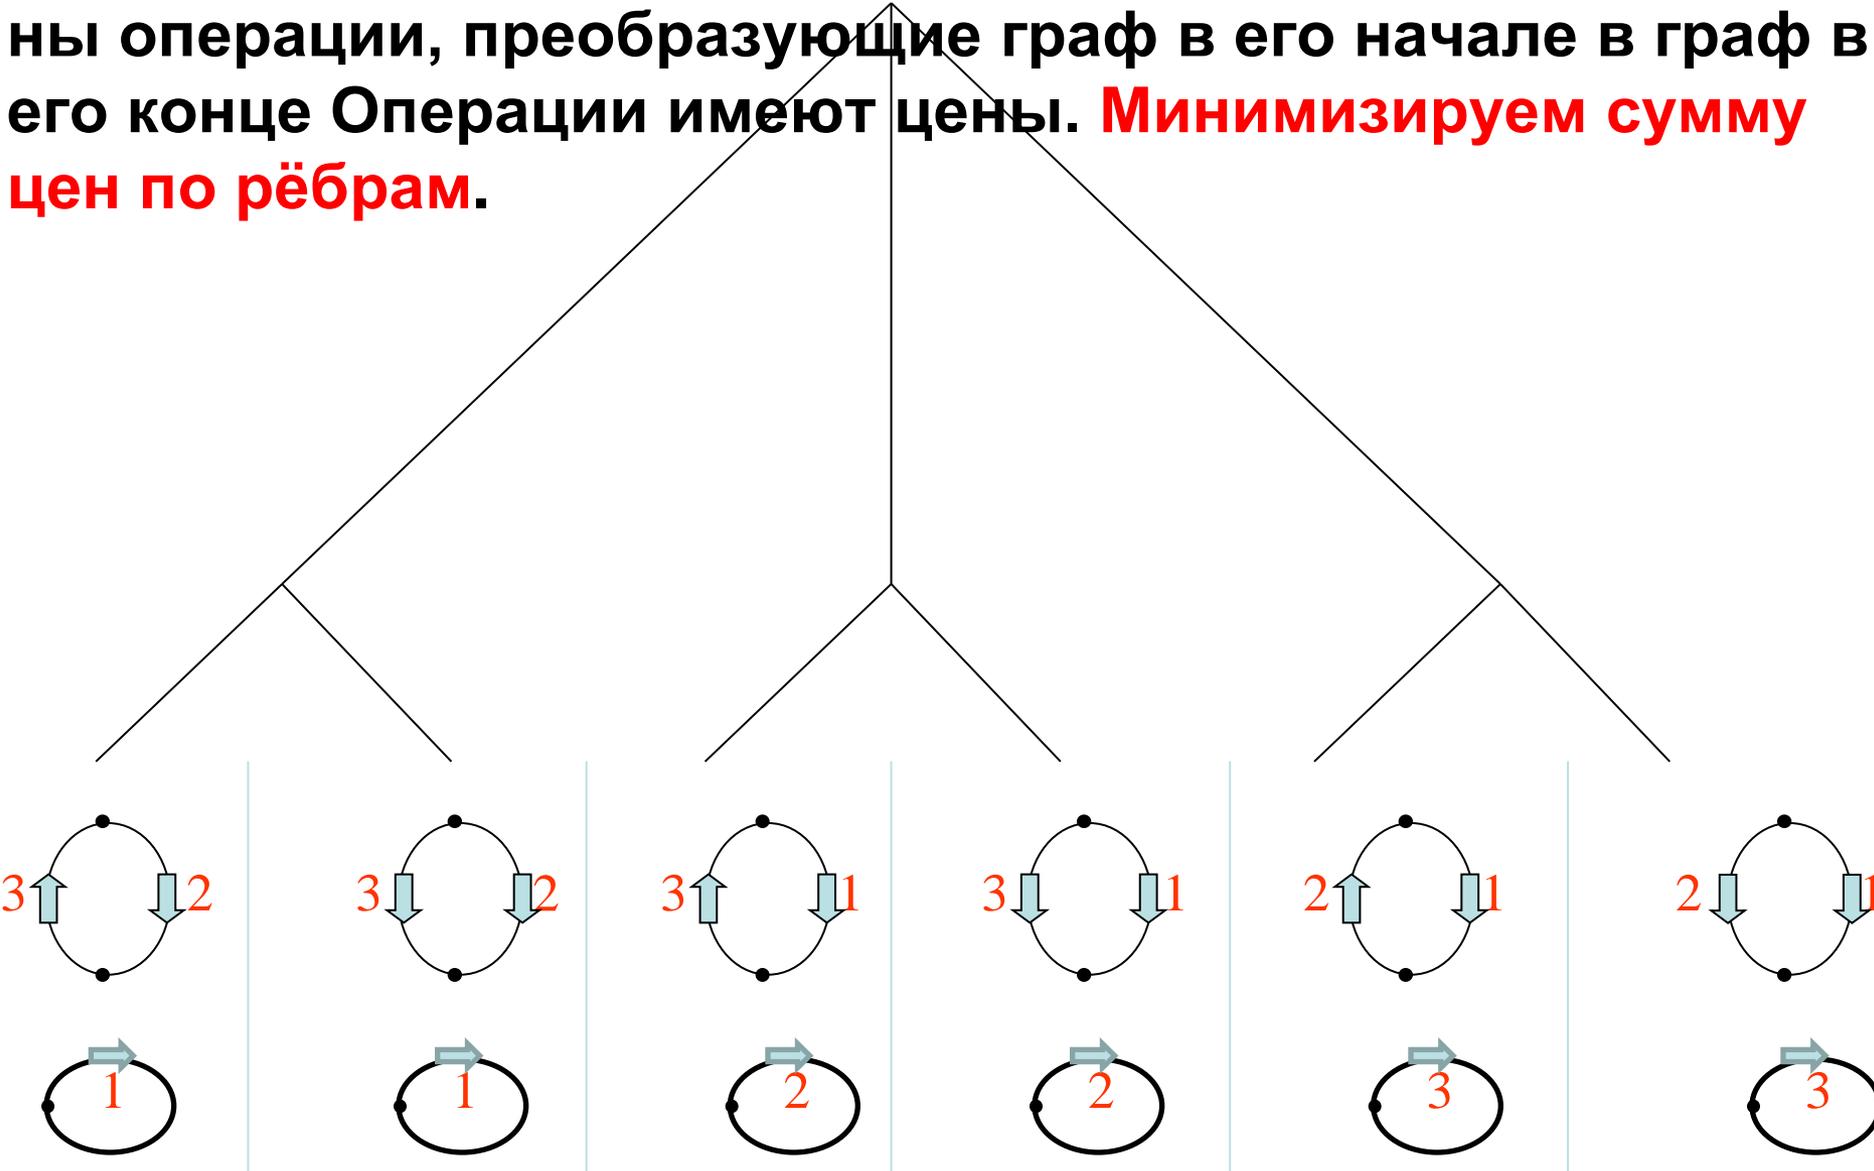
Годятся соотношения цен:  $c_2 \leq c_1 \leq c_1' \leq c_{1.5}$  («циклическое») и  $c_1 \leq c_1' \leq c_{1.5} \leq c_2$  («линейное»).

Нетривиальный эффект этой задачи – **определённые группы цепей (в графе краёв) нужно обязательно преобразовывать вместе**, чтобы достичь минимума!

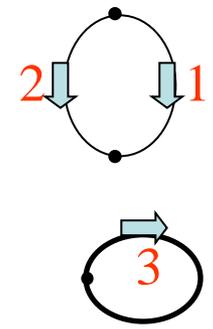
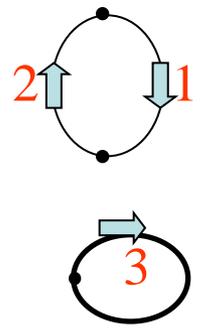
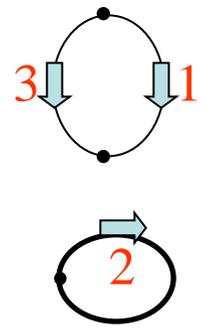
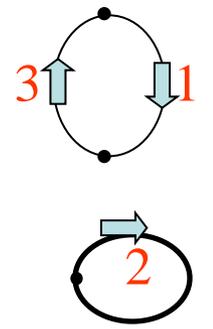
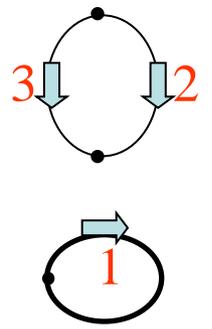
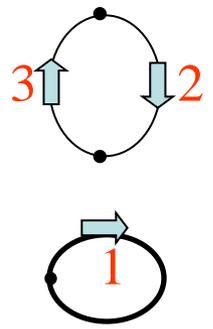
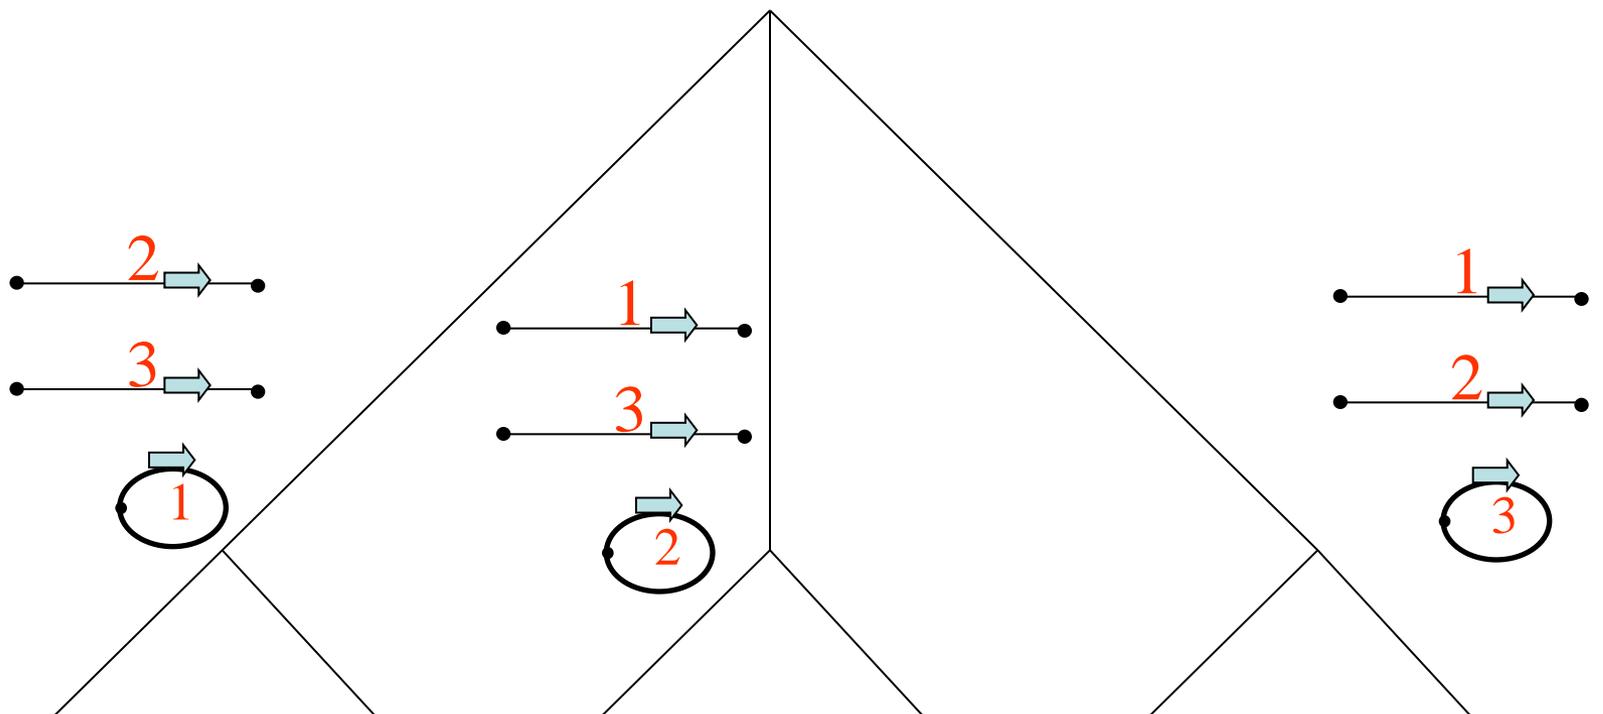
Также важна **задача условной оптимизации**: найти **самую дешёвую последовательность среди самых коротких последовательностей операций**.

Не известно, существует ли полиномиальный по времени алгоритм решения безусловной задачи даже для одного из этих вариантов цен.

4) **Оптимальное продолжение на всё дерево СС-графов, заданных в листьях дерева. Расстановка** – каждой внутренней вершине приписан свой граф. На рёбрах разрешены операции, преобразующие граф в его начале в граф в его конце. **Операции имеют цены. Минимизируем сумму цен по рёбрам.**



# Решение – графы во внутренних вершинах:

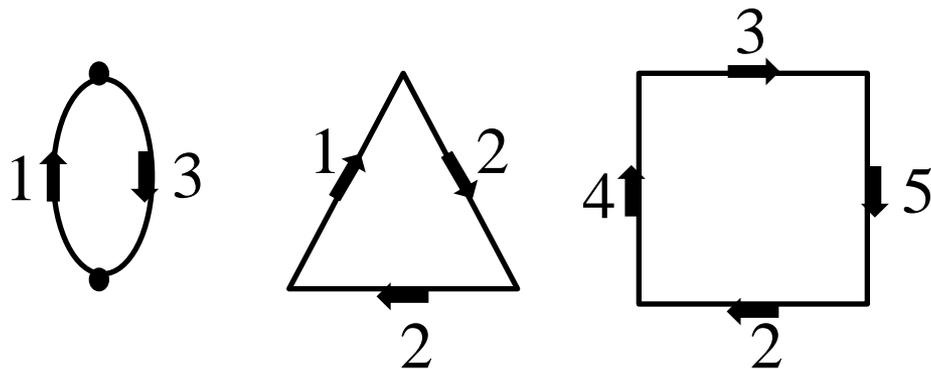


Нами найден кубический от исходных данных алгоритм, точный при некотором условии, который минимизирует цену расстановки.

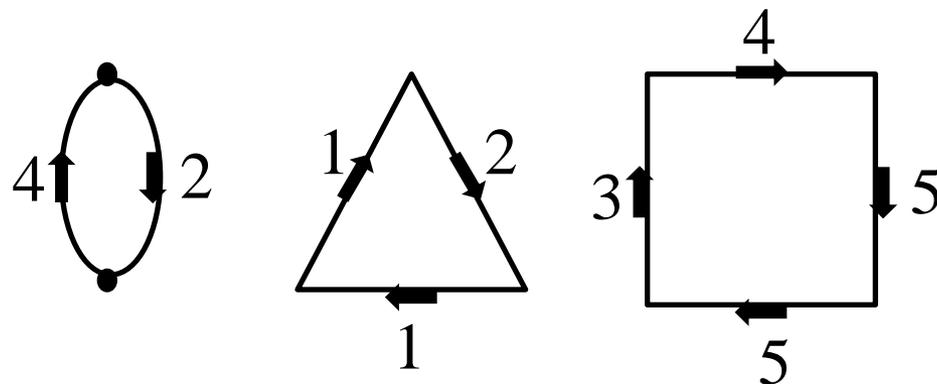
# 5) Сведение задачи вычисления расстояния между СС-графами в случае **ПАРАЛОГОВ** к задаче ЦЛП.

Даны:

Граф *a*



Граф *b*

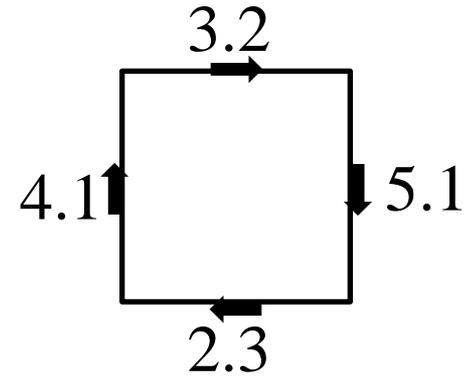
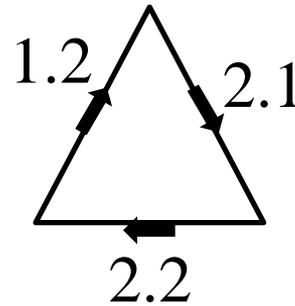
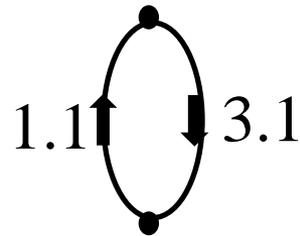


$$F = 0.5 \sum x + \sum y - \sum p$$

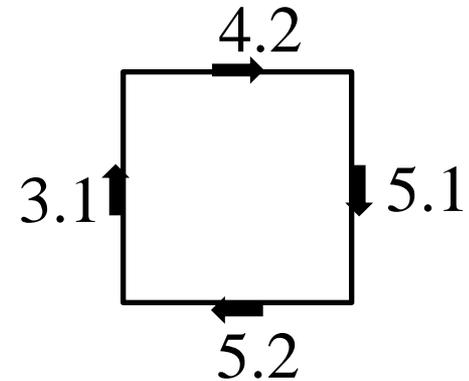
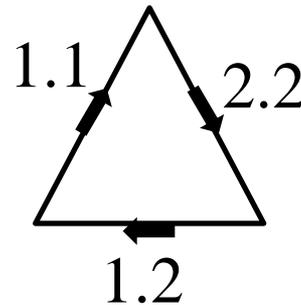
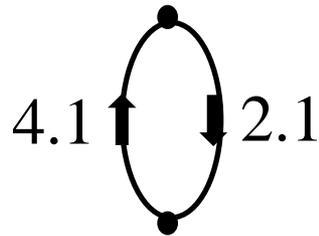
**Нужно:** нумеровать одноимённые в *a* и в *b* рёбра (называемые *общими*), чтобы минимизировать число операций, преобразующих *a* в *b*. Решить – **минимизировать ц.ф. *F*** !  
 Для краткости изложения покажем графы без цепей.

Начнём с нумерации рёбер, чтобы оперировать с ними (первая цифра показывает группу рёбер-паралогов):

Граф *a*

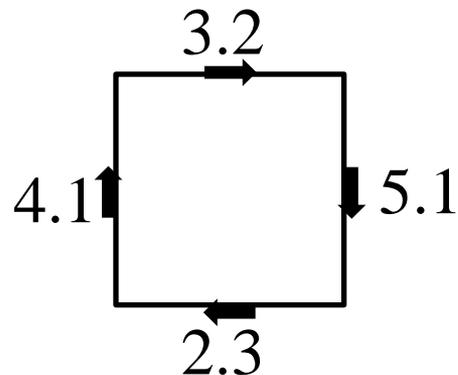
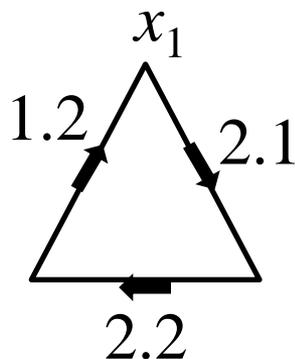
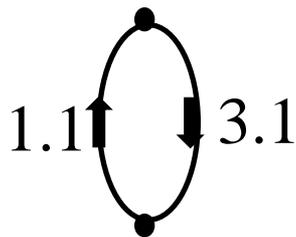


Граф *b*



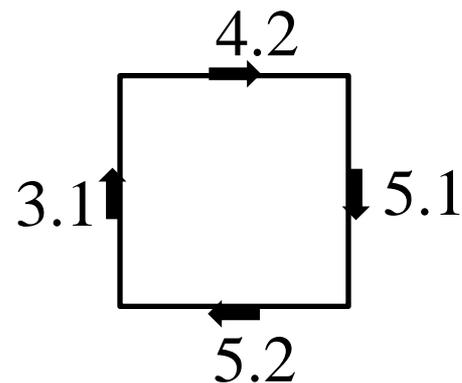
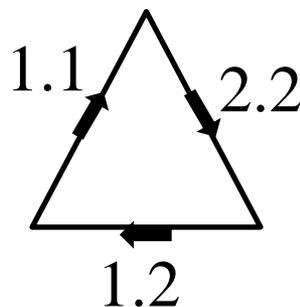
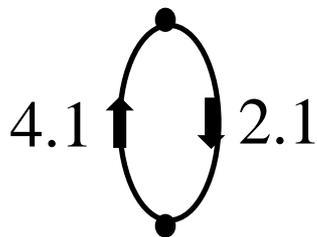
Паре общих рёбер сопоставляется **булева переменная  $z$** , задающая их соответствие. Например,  $z_{231}=1$  означает: ребро 2.3 в *a* соответствует ребру 2.1 в *b*. Ограничение: ребру в одном графе соответствует не более одного ребра в другом.

Граф *a*



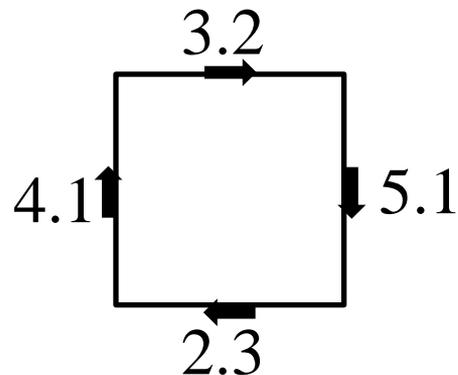
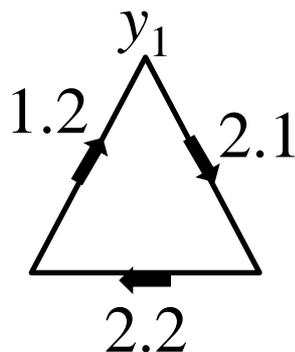
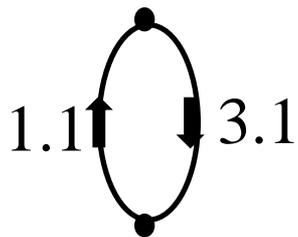
$$x_1 \geq (z_{121} + z_{122}) - (z_{211} + z_{212})$$

Граф *b*



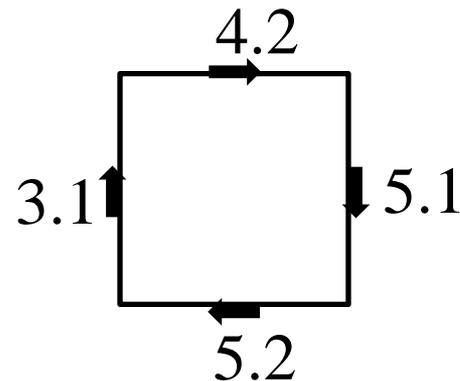
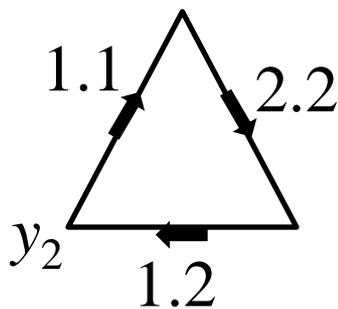
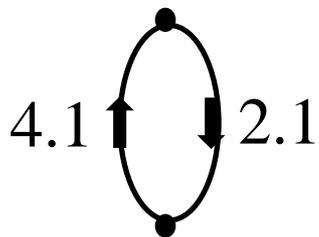
Каждой вершине сопоставляется **булева переменная  $x$** , они указывают, какие вершины в графах соединяют общее ребро с *особым* ребром в соответствии со значениями переменных  $z$ . Приведённое неравенство выражает: если по  $z$ , в *a* ребро 1.2 общее, а 2.1 особое, то  $x_1=1$ ; и т.д.

Граф *a*



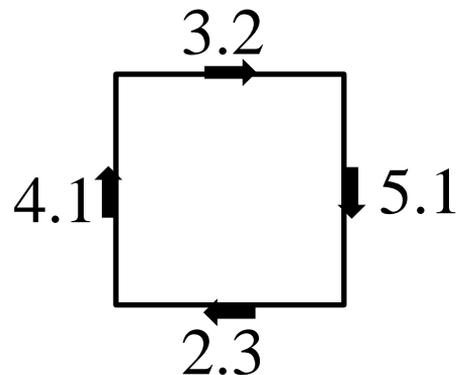
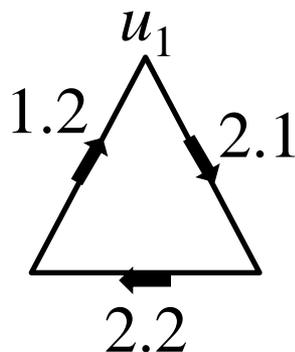
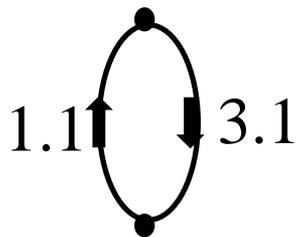
$$y_1 + y_2 \geq z_{122} + (z_{211} + z_{212}) + (z_{111} + z_{121}) - 2$$

Граф *b*



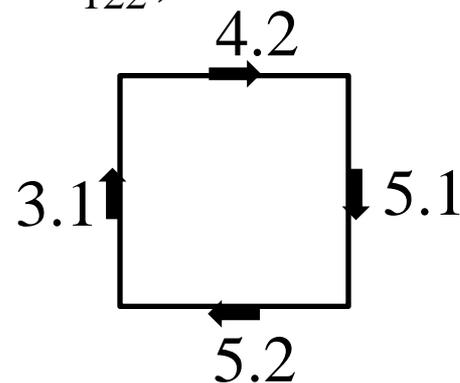
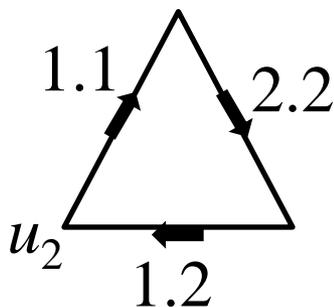
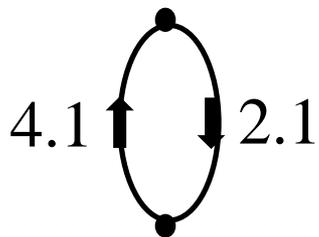
Каждой вершине сопоставляется **булева переменная** *y*, равная 0, если вершина принадлежит особому ребру; на пути из склеек общих рёбер *y* принимает чередующиеся значения, начиная с 0. Например, приведённое ограничение выражает: если рёбра 1.2 в *a* и в *b* соответствуют друг другу, ребро 2.1 в *a* и ребро 1.1 в *b* общие и  $y_1=0$ , то  $y_2=1$ .

Граф *a*



$$u_2 \leq u_1 + m_2(1 - z_{122}), \quad u_1 \leq u_2 + m_1(1 - z_{122})$$

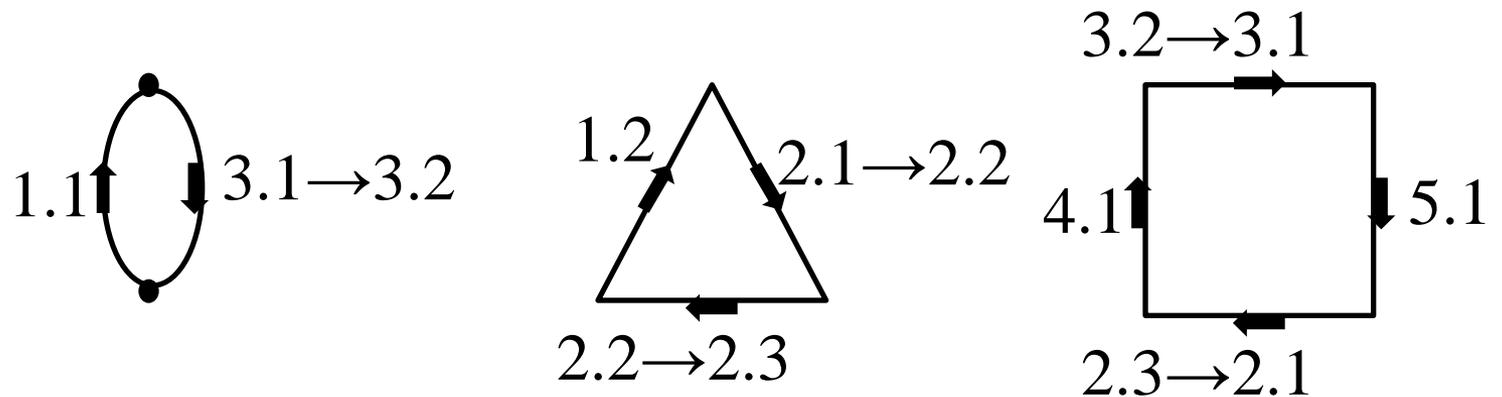
Граф *b*



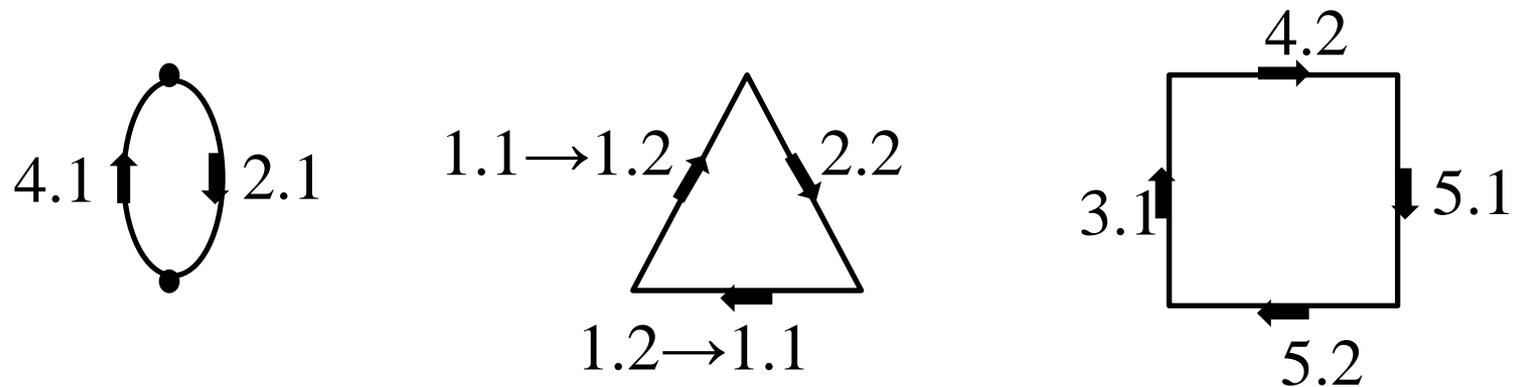
Каждой вершине  $k$  сопоставляется **целочисленная переменная**  $u_k$ , ограниченная сверху положительным числом  $m_k$ , и **булева переменная**  $p_k$ , равная 1, если  $u_k = m_k$ . Приведённые ограничения выражают: если рёбра 1.2 в *a* и в *b* соответствуют друг другу, то  $u_1 = u_2$ .

**Решение для исходной пары графов:**  $z_{112}, z_{121}, z_{212}, z_{231}, z_{321}, z_{411}, z_{511}$  равны 1, остальные значения 0.  
 Нумерация паралогов в исходном графе такова:

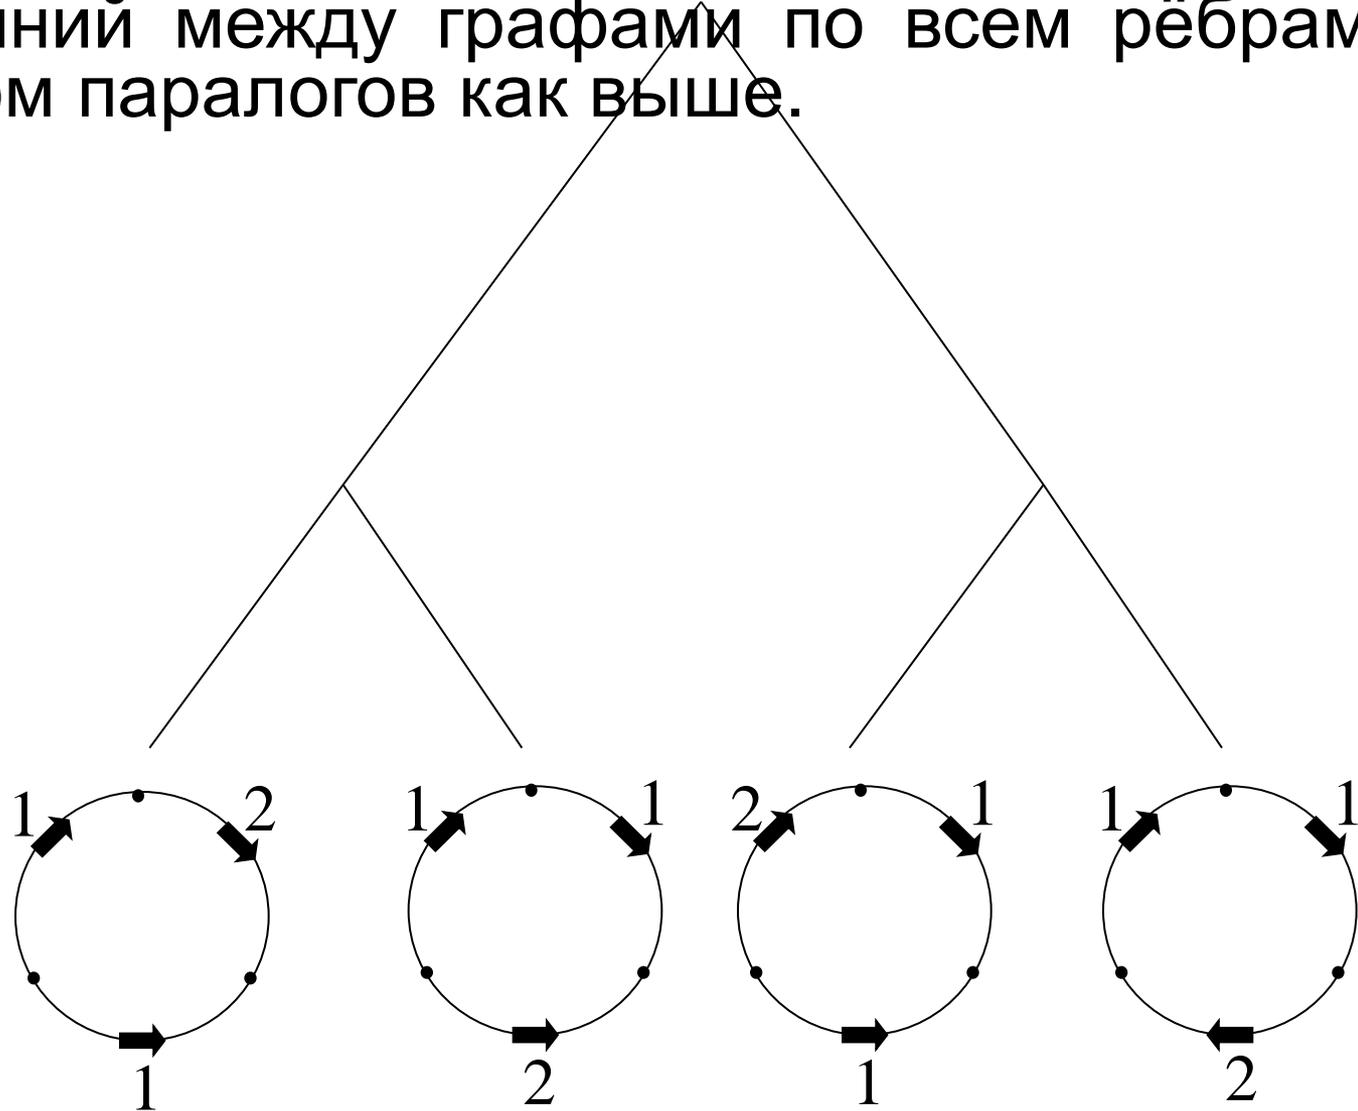
Граф *a*



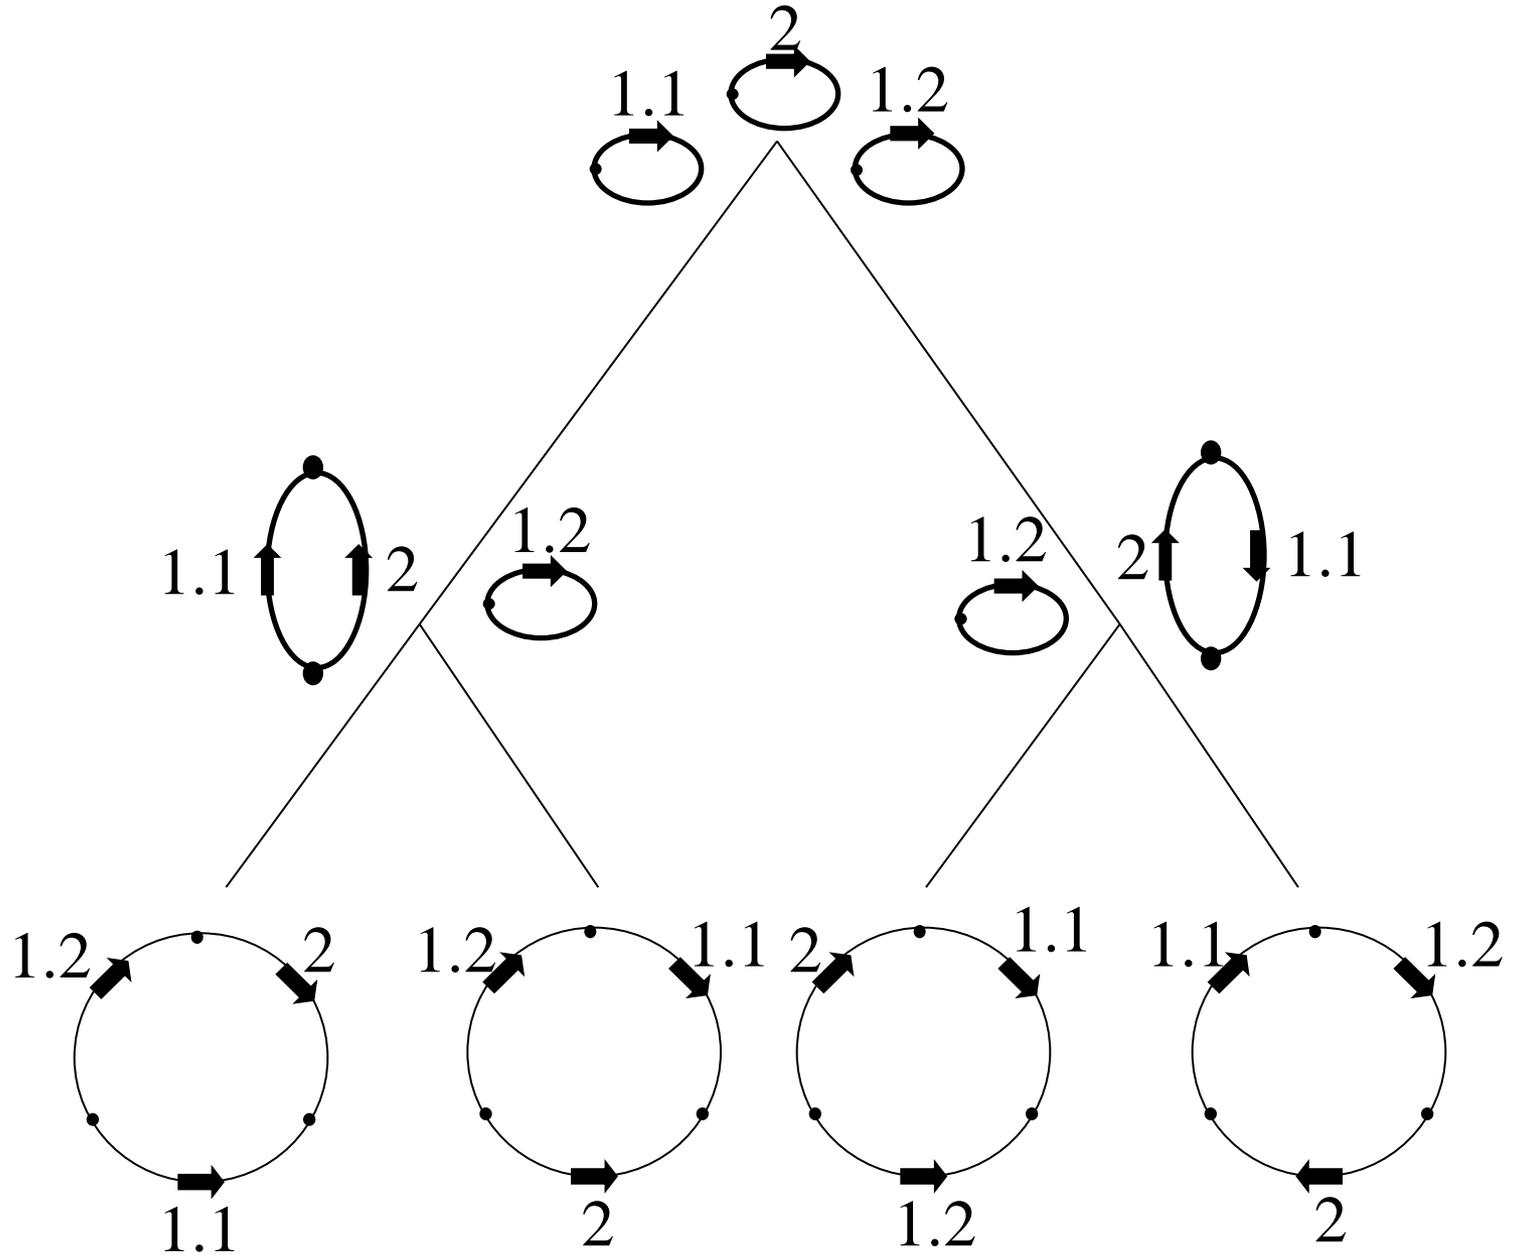
Граф *b*



Аналогично к задаче ЦЛП сводится и задача реконструкции графов на данном дереве. Например, в листьях указаны графы. Найти расстановку графов во внутренних вершинах, которая минимизирует сумму расстояний между графами по всем рёбрам дерева с учётом паралогов как выше.



Показано решение:



**Наши недавние публикации,**  
эти и другие на странице <http://lab6.iitp.ru/> :

V.A. Lyubetsky,  
R.A. Gershgorin, A.V. Seliverstov, K.Yu. Gorbunov,  
Algorithms for Reconstruction of Chromosomal  
Structures,  
BMC Bioinformatics, 2016, 17:40.

O.A. Zverkov, A.V. Seliverstov, V.A. Lyubetsky,  
Regulation of Expression and Evolution of Genes in  
Plastids of Rhodophytic Branch,  
Life, Jan 29 2016, 6:7.

**СПАСИБО за внимание**