

COLLÈGE
DE FRANCE
— 1530 —

Algorithmes : conclusion

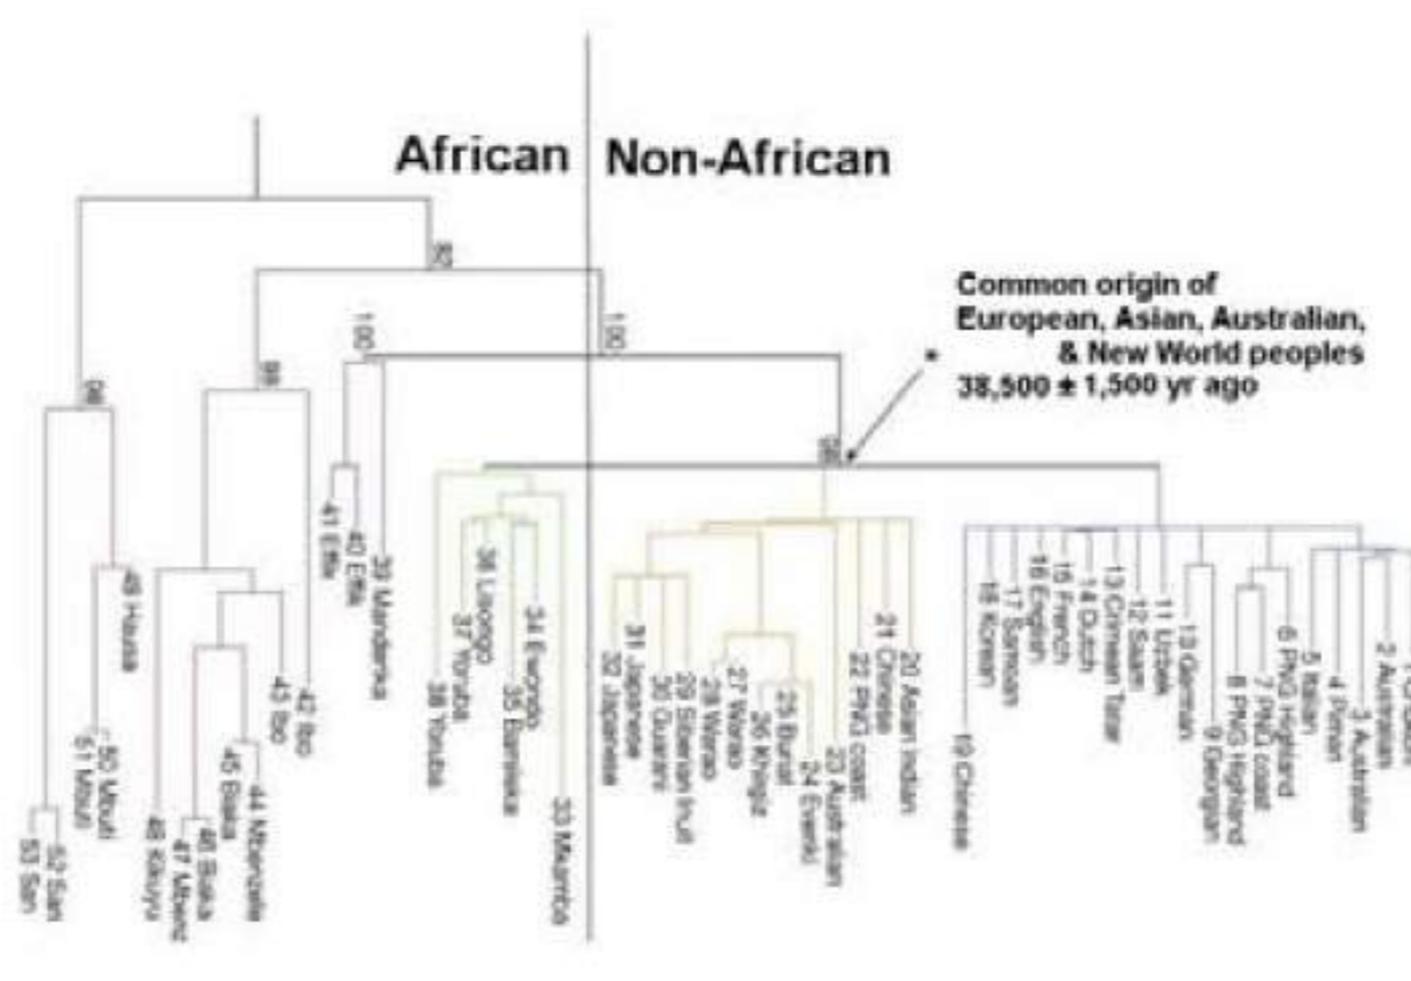
Claire Mathieu



Reconstruction d'arbre à partir d'ADN
Arbre de Steiner et méthode primale-dual
Conclusion

Reconstruction d'arbre à partir d'ADN

Arbre phylogénétique



**Reconstruction basée sur l'ADN :
l'ancêtre commun à tous les hommes modernes
a vécu en Afrique il y a environ 200 000 ans**

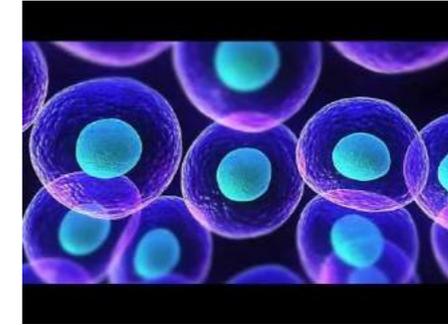
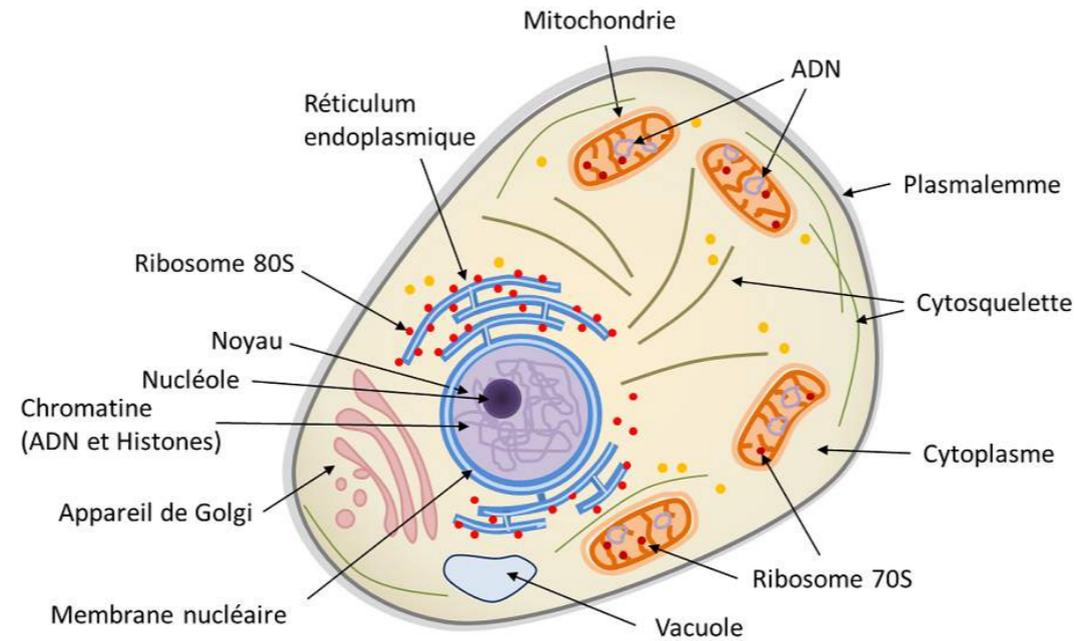


**L'homme vivant dont l'ADN est probablement
le plus ancien de l'humanité**

L'ADN pour reconstruire l'évolution



Personne



Cellules

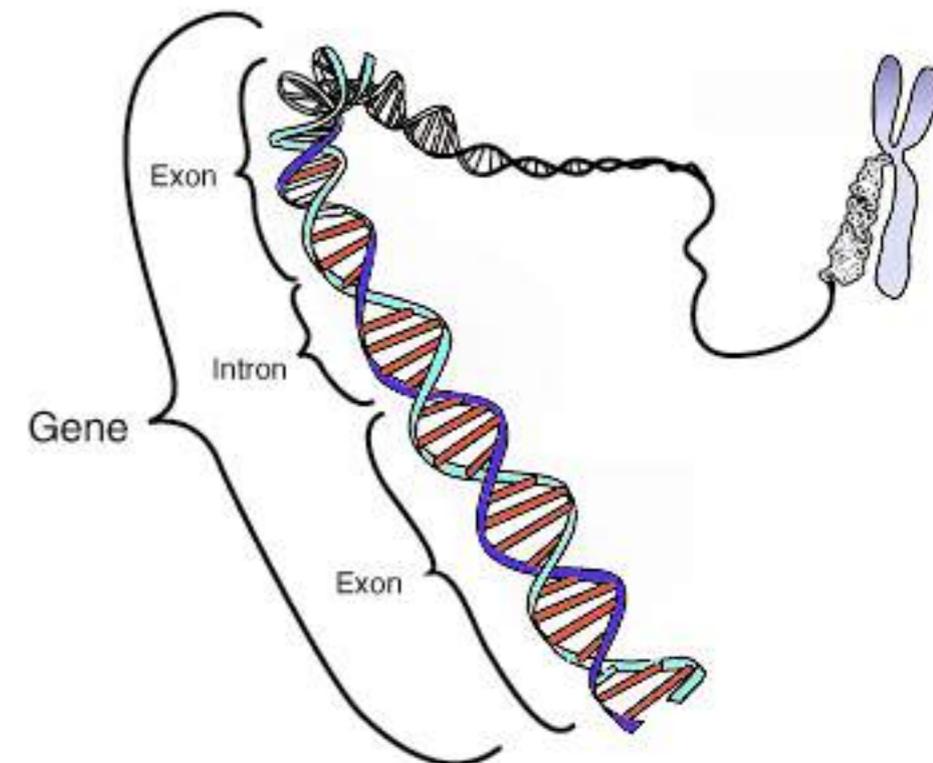
noyau

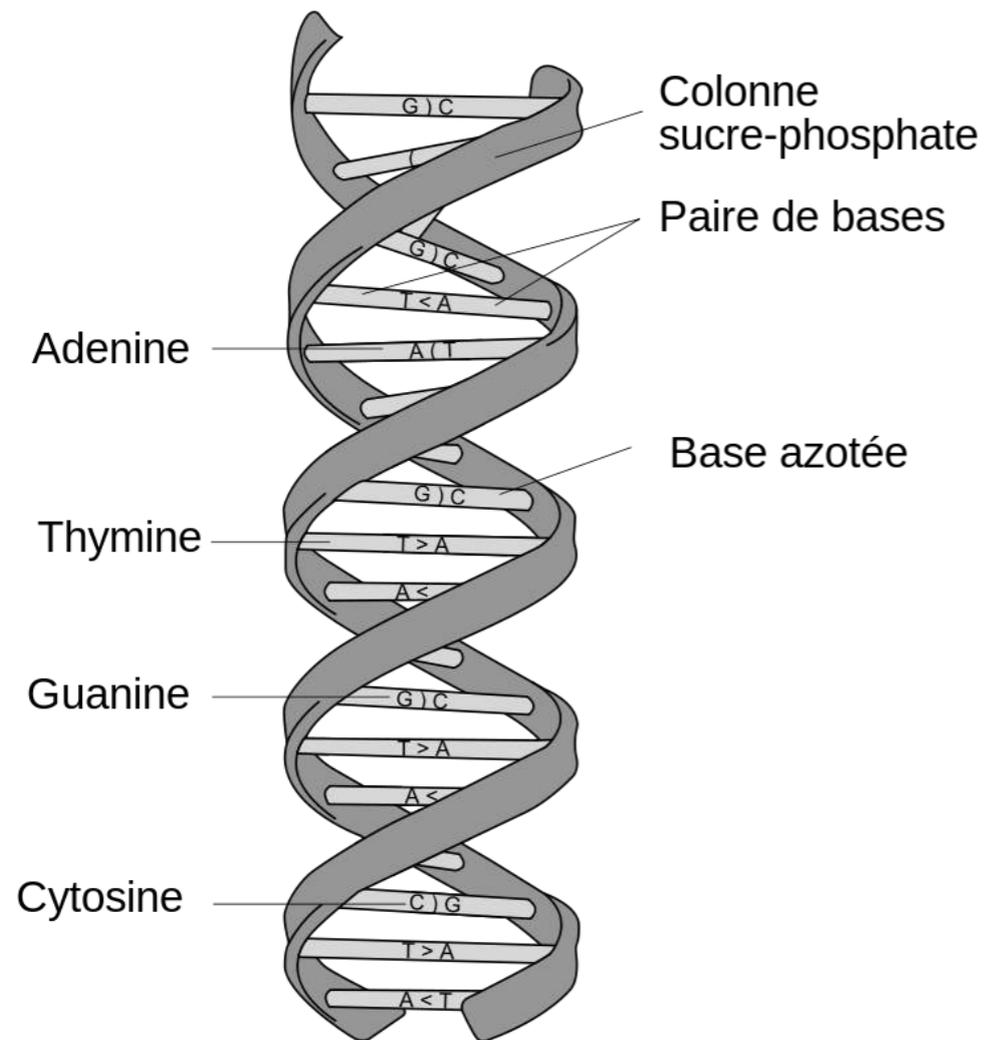
mitochondries
ADN

22 paires de
chromosomes autosomes
ADN

1 paire de chromosomes
XY (homme) ou XX (femme)
ADN

Le chromosome a 2 brins d'ADN.
La mitochondrie aussi.
Gènes : fragments d'ADN

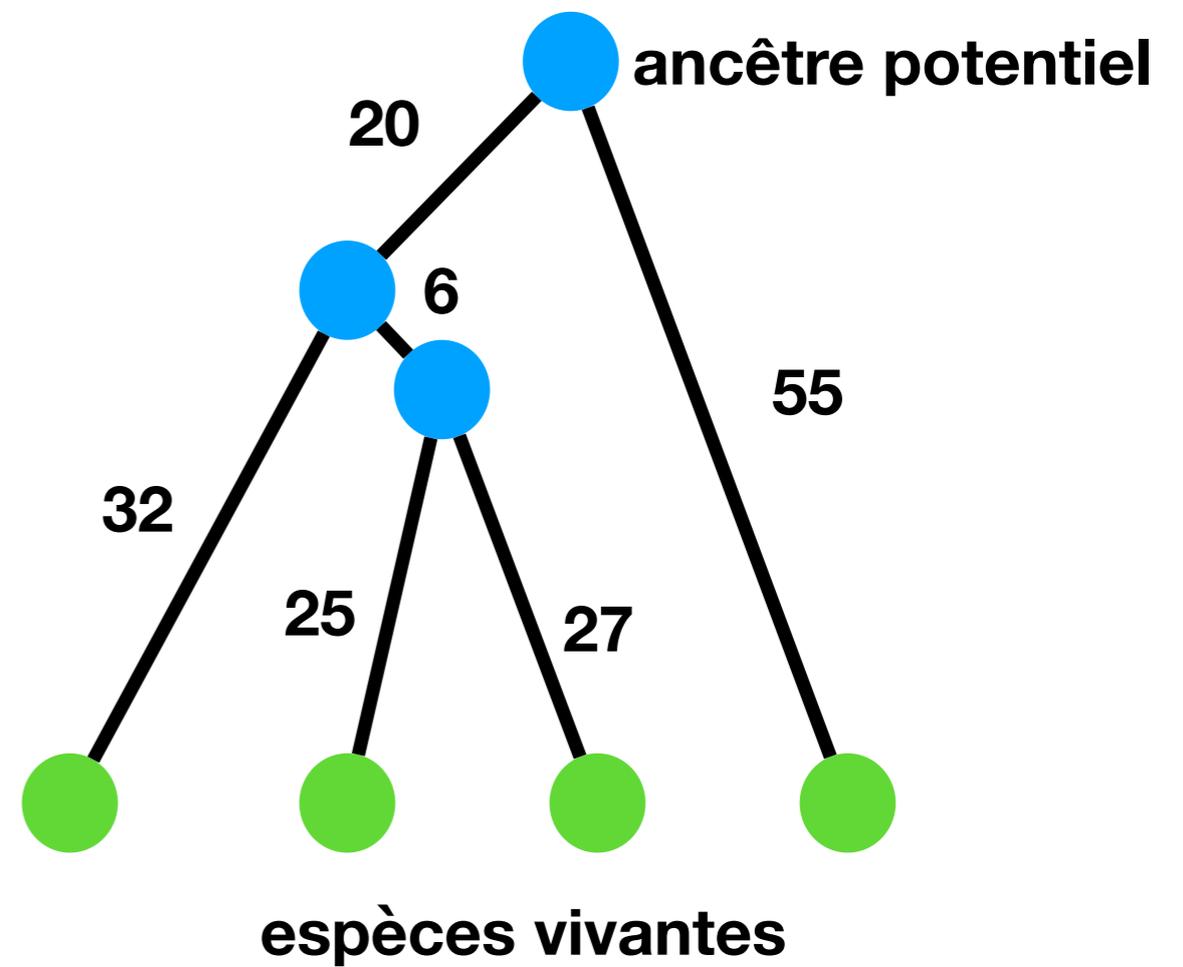
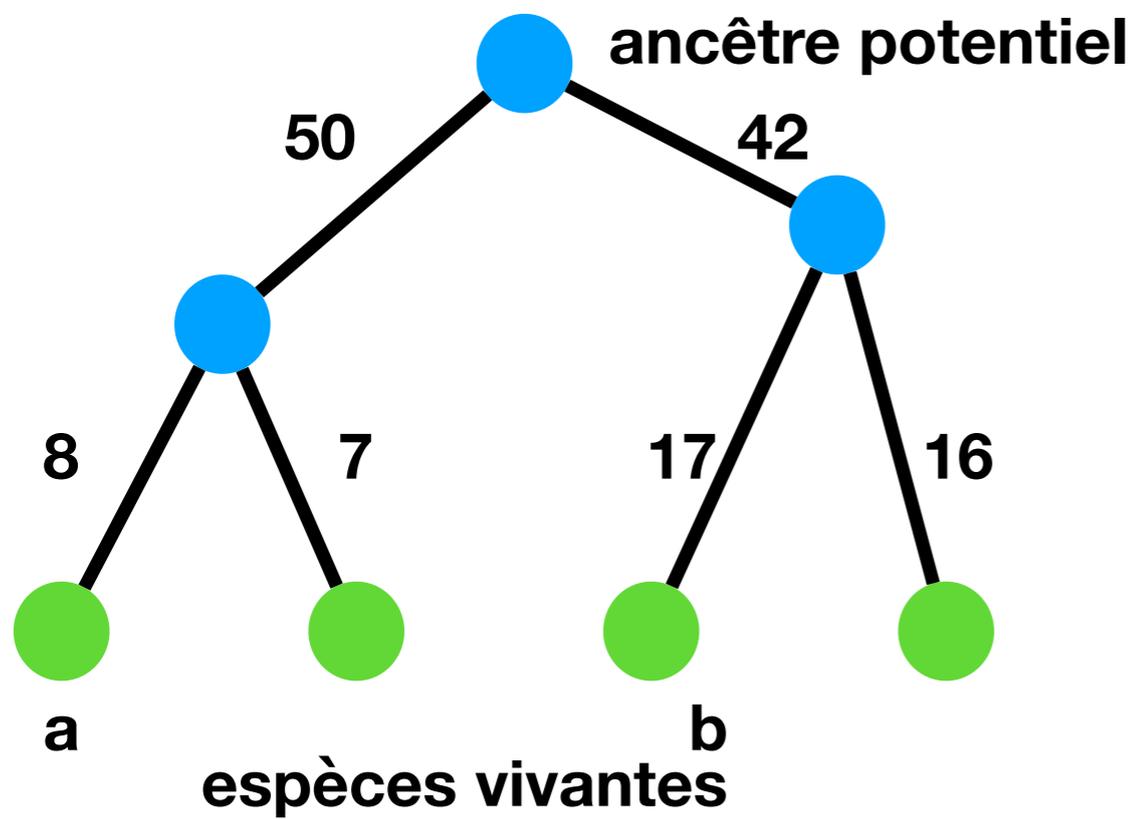




**Mot écrit avec les lettres A,C,G,T
(lettre = base azotée du nucléotide)**

**Évolution : mutations
Modifications du mot**

**$D(i,j)$: distance entre le mot de l'individu i et le mot de l'individu j
nombre de mutations
temps écoulé depuis différenciation de leur ancêtre commun le plus récent**



$D(a,b)=8+50+42+17=117$

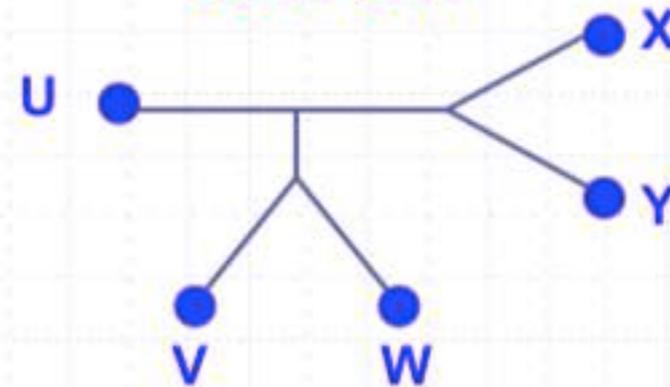
Étant donné les distances,
reconstruire l'arbre.

INPUT:

U	AGGGCAT
V	TAGCCCA
W	TAGACTT
X	TGCACAA
Y	TGCGCTT



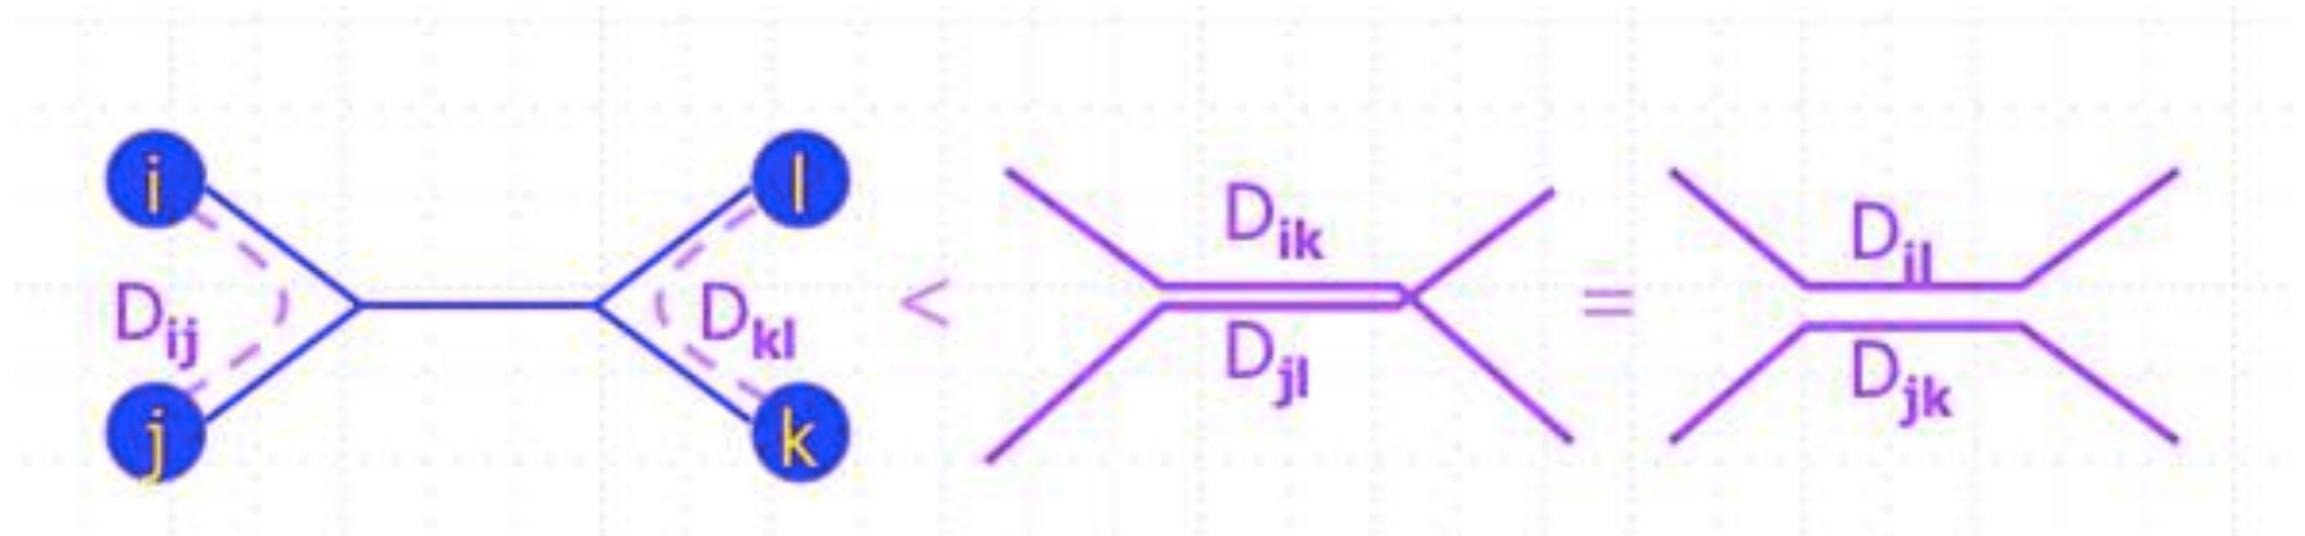
OUTPUT:



Définition

Une matrice **D** est additive si
pour tout quadruplet i, j, k, l :

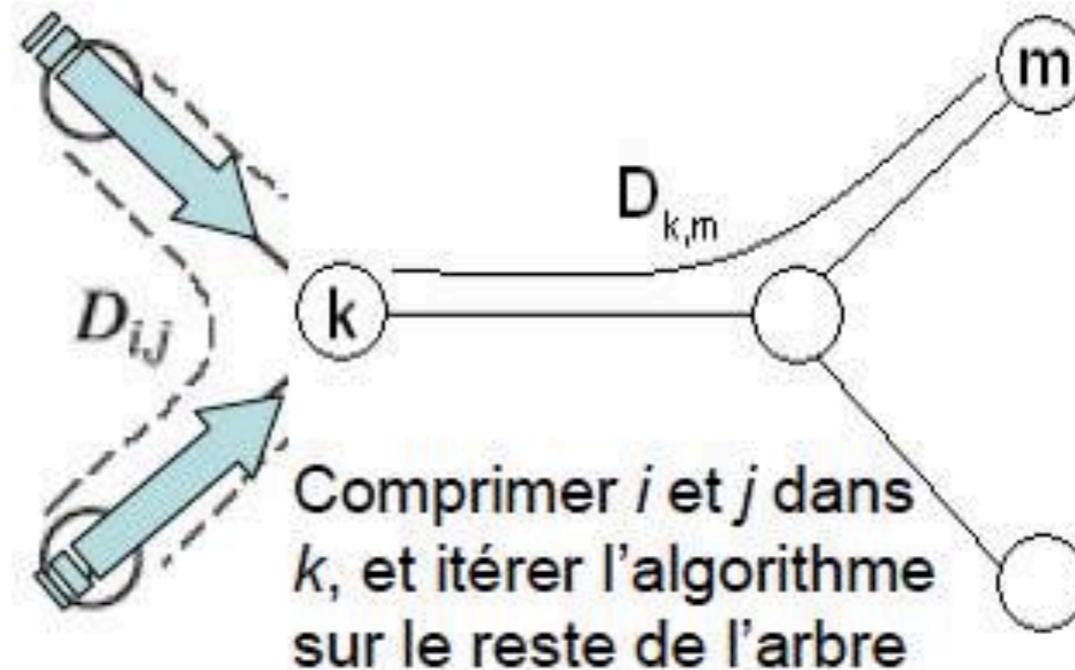
$$D_{ij} + D_{kl} \leq D_{ik} + D_{jl} = D_{il} + D_{jk}$$



Algorithme pour distances additives

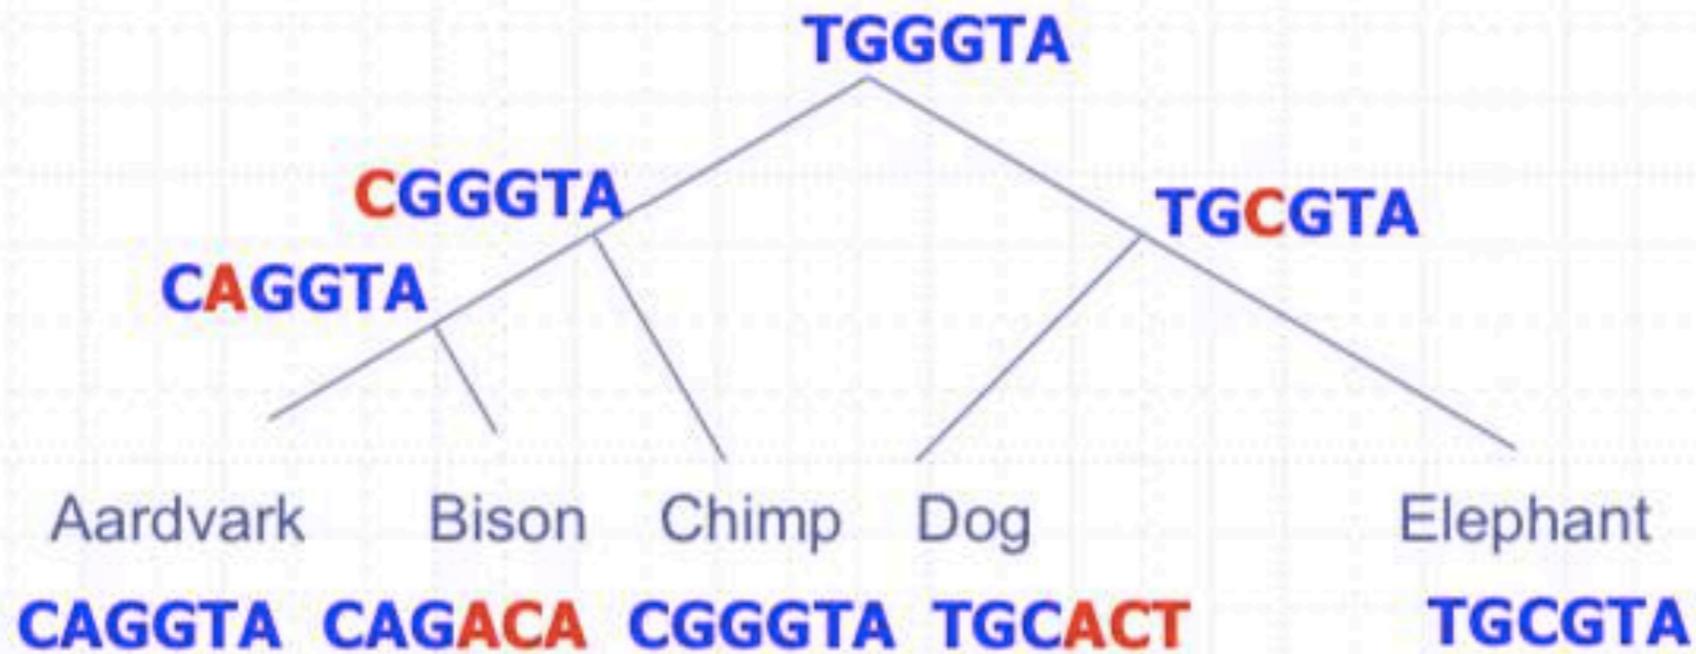
- Trouver des feuilles « voisines » i et j avec père k
- Effacer lignes et colonnes de i et j de la matrice
- Ajouter une nouvelle ligne et colonne correspondant a k , ou la distance entre k et toute autre feuille m peut être calculée comme suit :

$$D_{km} = (D_{im} + D_{jm} - D_{ij})/2$$



Trouver les mots qui “expliquent” au mieux le présent

Aardvark: CAGGTA
Bison: CAGACA
Chimp: CGGGTA
Dog: TGCACT
Elephant: TGC GTA



- **Au niveau des espèces : arbre d'évolution**
- **Au niveau des populations : ancêtre commun**
- **Au niveau des langages : évolution des langues indo-européennes**
- **Au niveau des individus : arbres généalogiques ?**

Marqueur : Segment d'ADN DYS 393.

Tous les hommes, quelle que soit leur origine, ont la même séquence AGAT sur ce même marqueur. Ils ne diffèrent que par le nombre de répétitions. Celles ci peuvent aller de 9 à 17 pour ce marqueur.

Plus le nombre de marqueurs identiques est élevé, plus la parenté entre 2 hommes est proche. Les résultats des différents marqueurs donne notre identité génétique appelée HAPLOTYPE. C'est avec cet haplotype que l'on peut rechercher ses cousins dans une base de données.

	Locus	1	2	3	4	5	6	7	8	9	10
	DYS	393	390	19	391	385a	385b	426	388	439	389
	Allèles	13	24	14	11	11	14	12	12	13	13

Table 1

Y-STR profile for the putative Louis XVI sample, independently replicated in the Bologna and Barcelona laboratories.

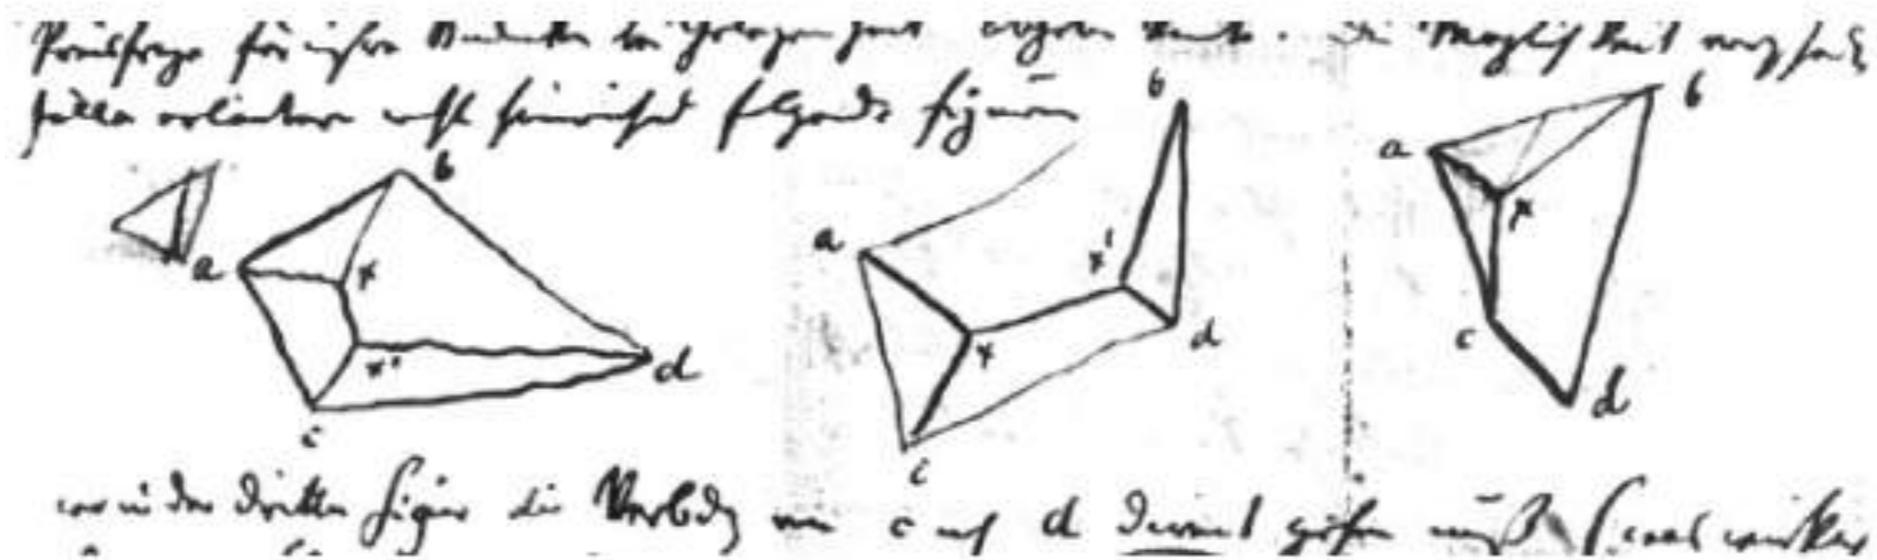
Marker	Alleles (Bologna)	Alleles (Barcelona)
DYS389I	12	12
DYS389II	30	30
DYS390	22	22
DYS456	15	15
DYS19	15	15
DYS385	13, 18	13, 18
DYS458	21	21
DYS437	15	15
DYS438	10	10
DYS448	21	21
YGATAH4	12	12
DYS391	10	10
DYS392	11	11
DYS393	14	14
DYS439	12	12
DYS635	21	21

L'anonymat du don d'ADN est un leurre...

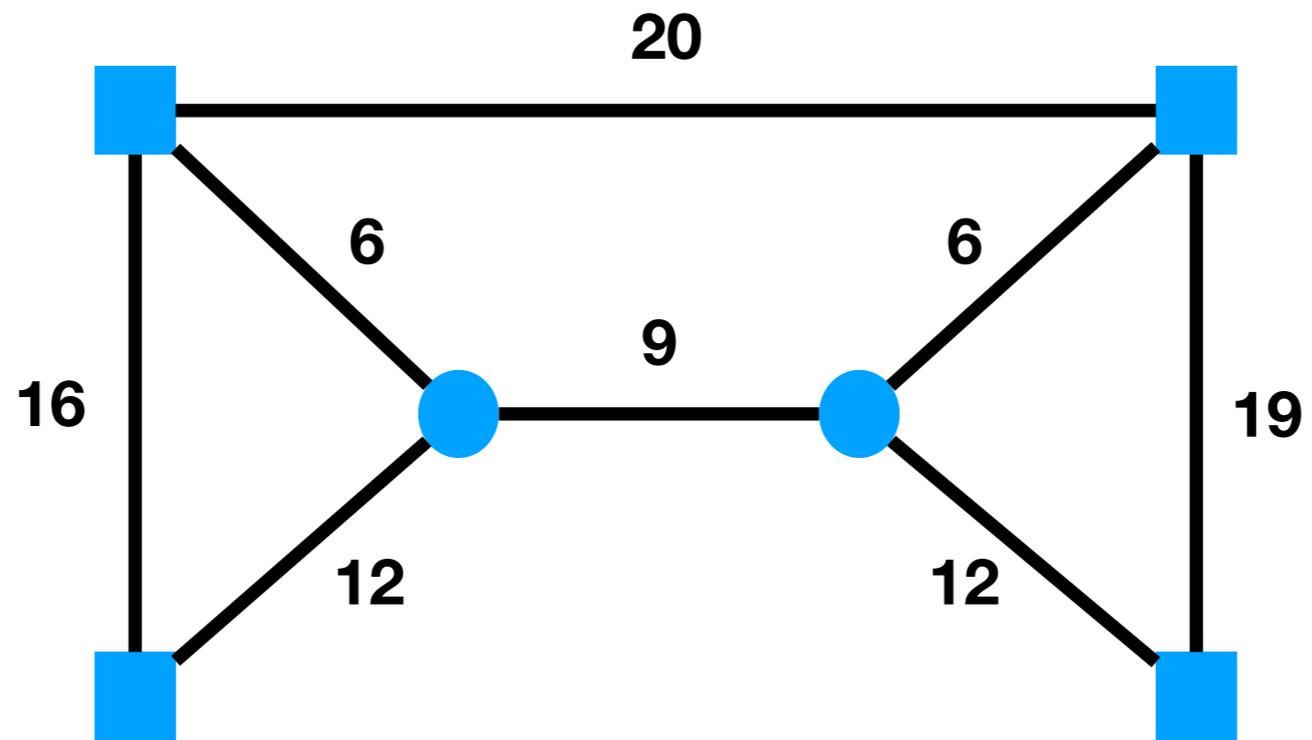
Arbre de Steiner et méthode primal-dual

arbre de Steiner

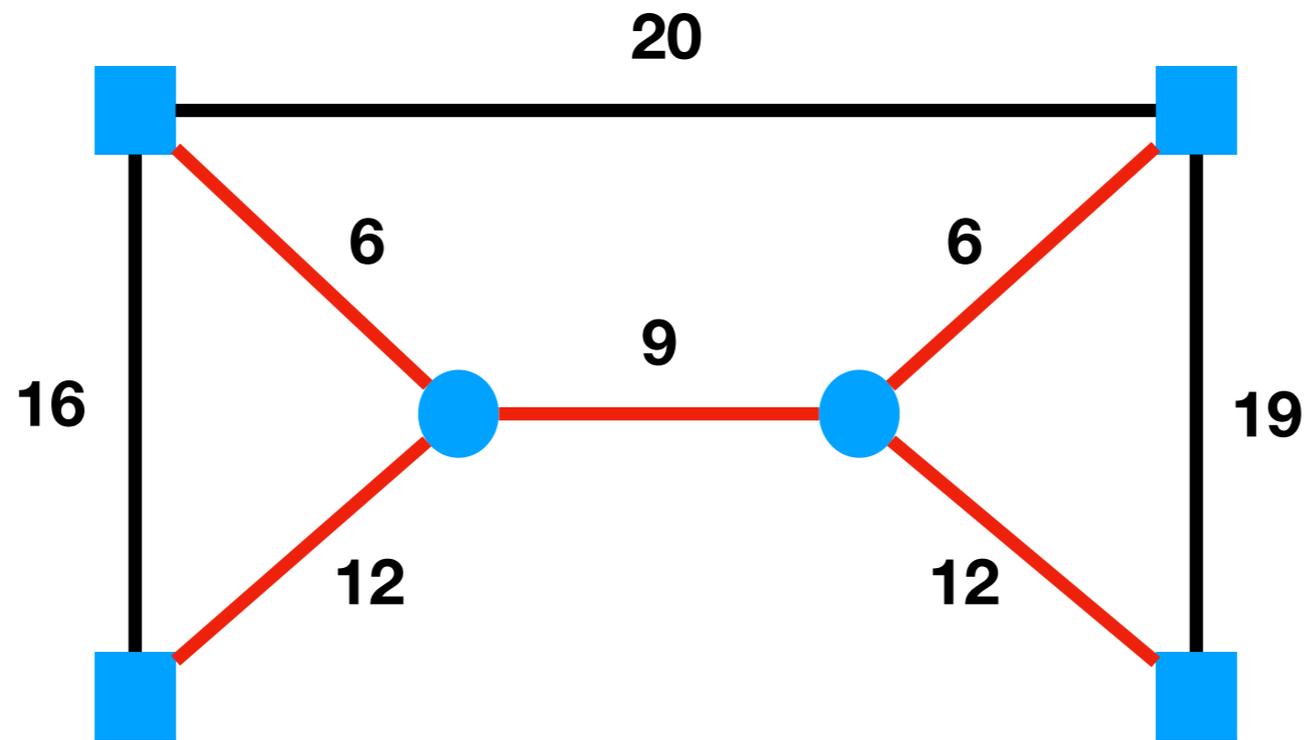
Quelle est la façon la plus courte de connecter quatre points a,b,c,d ?



Mentionné en 1836 dans une lettre de Gauss à Schumacher



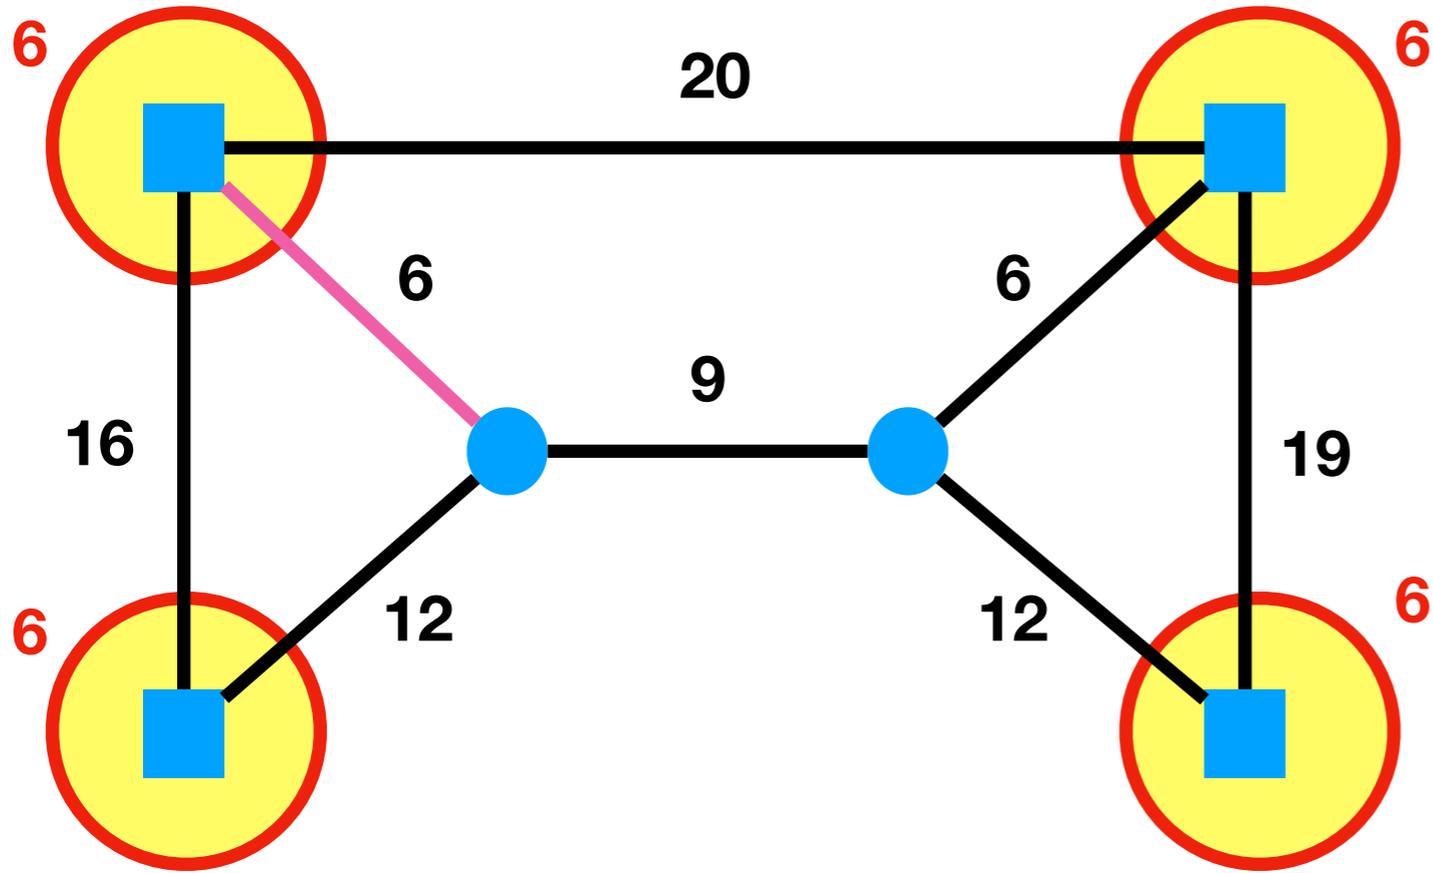
Graphes avec
terminaux à
connecter



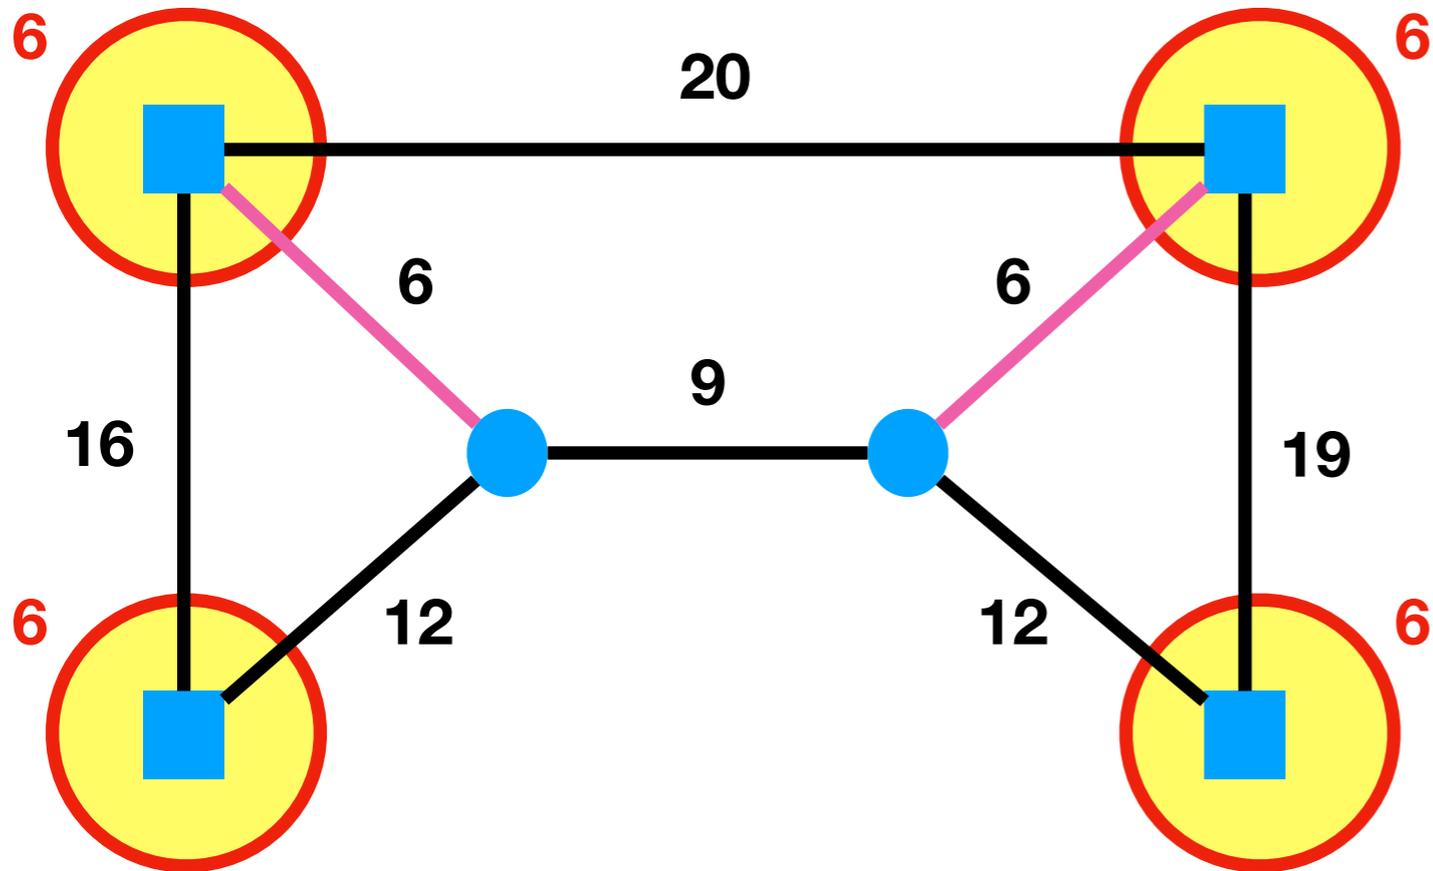
OPT

$$6+12+9+6+12=45$$

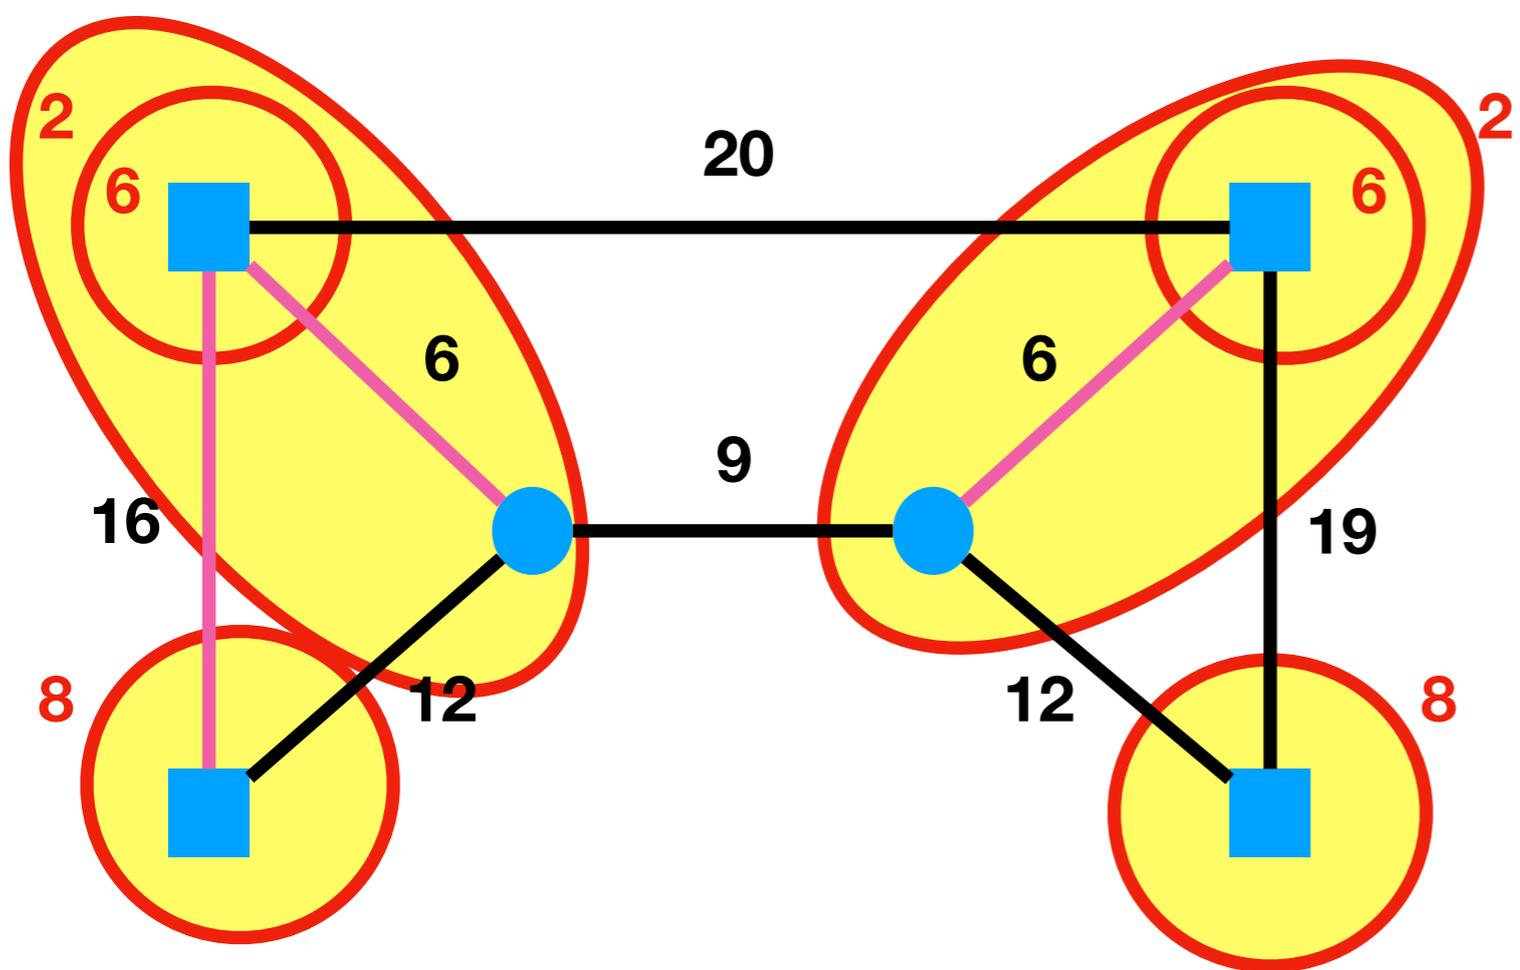
Algorithme



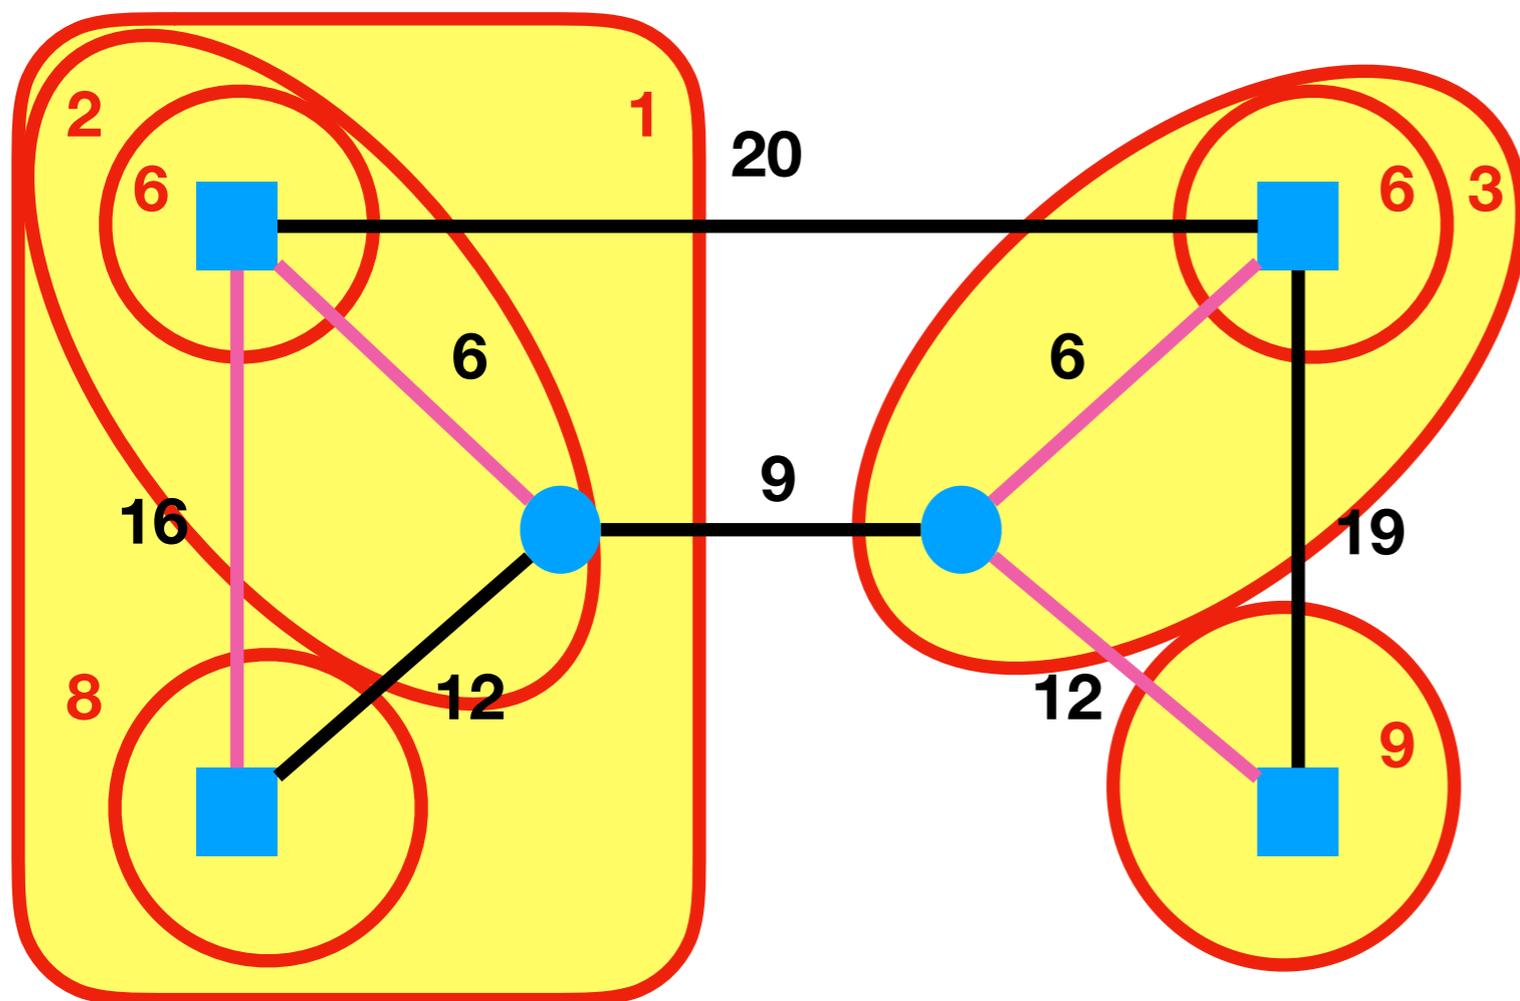
t=6



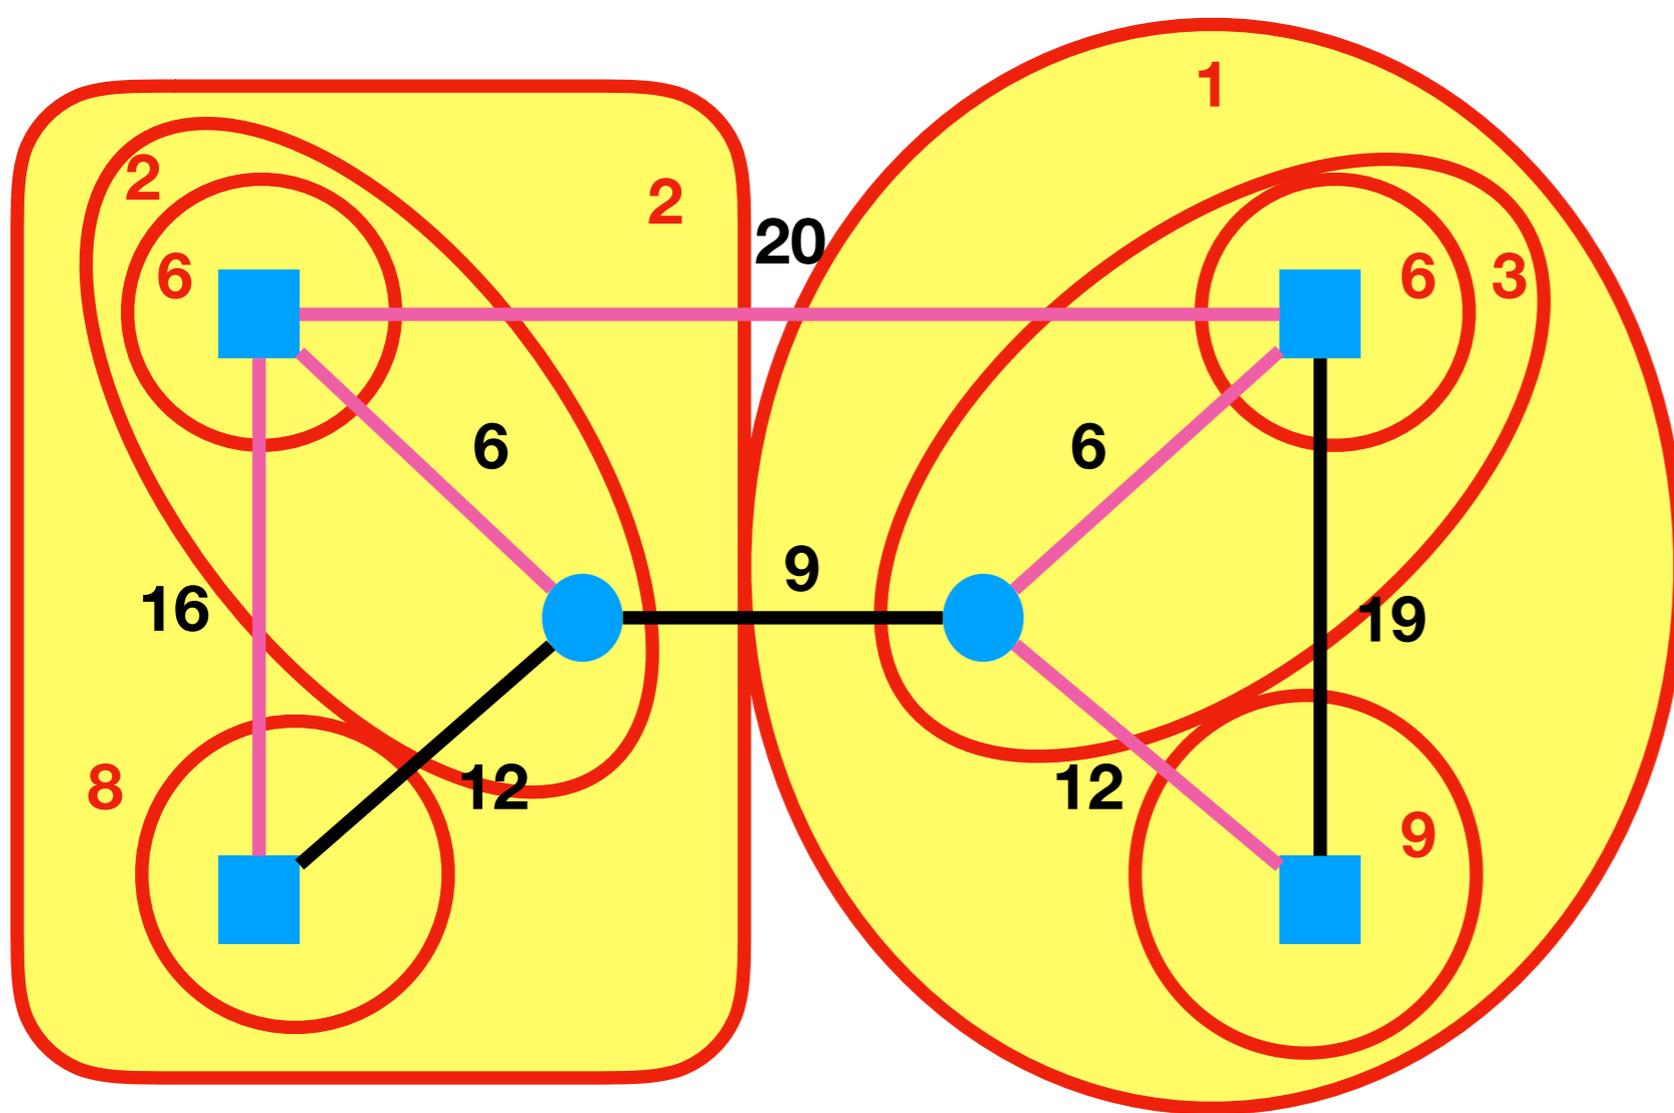
t=6



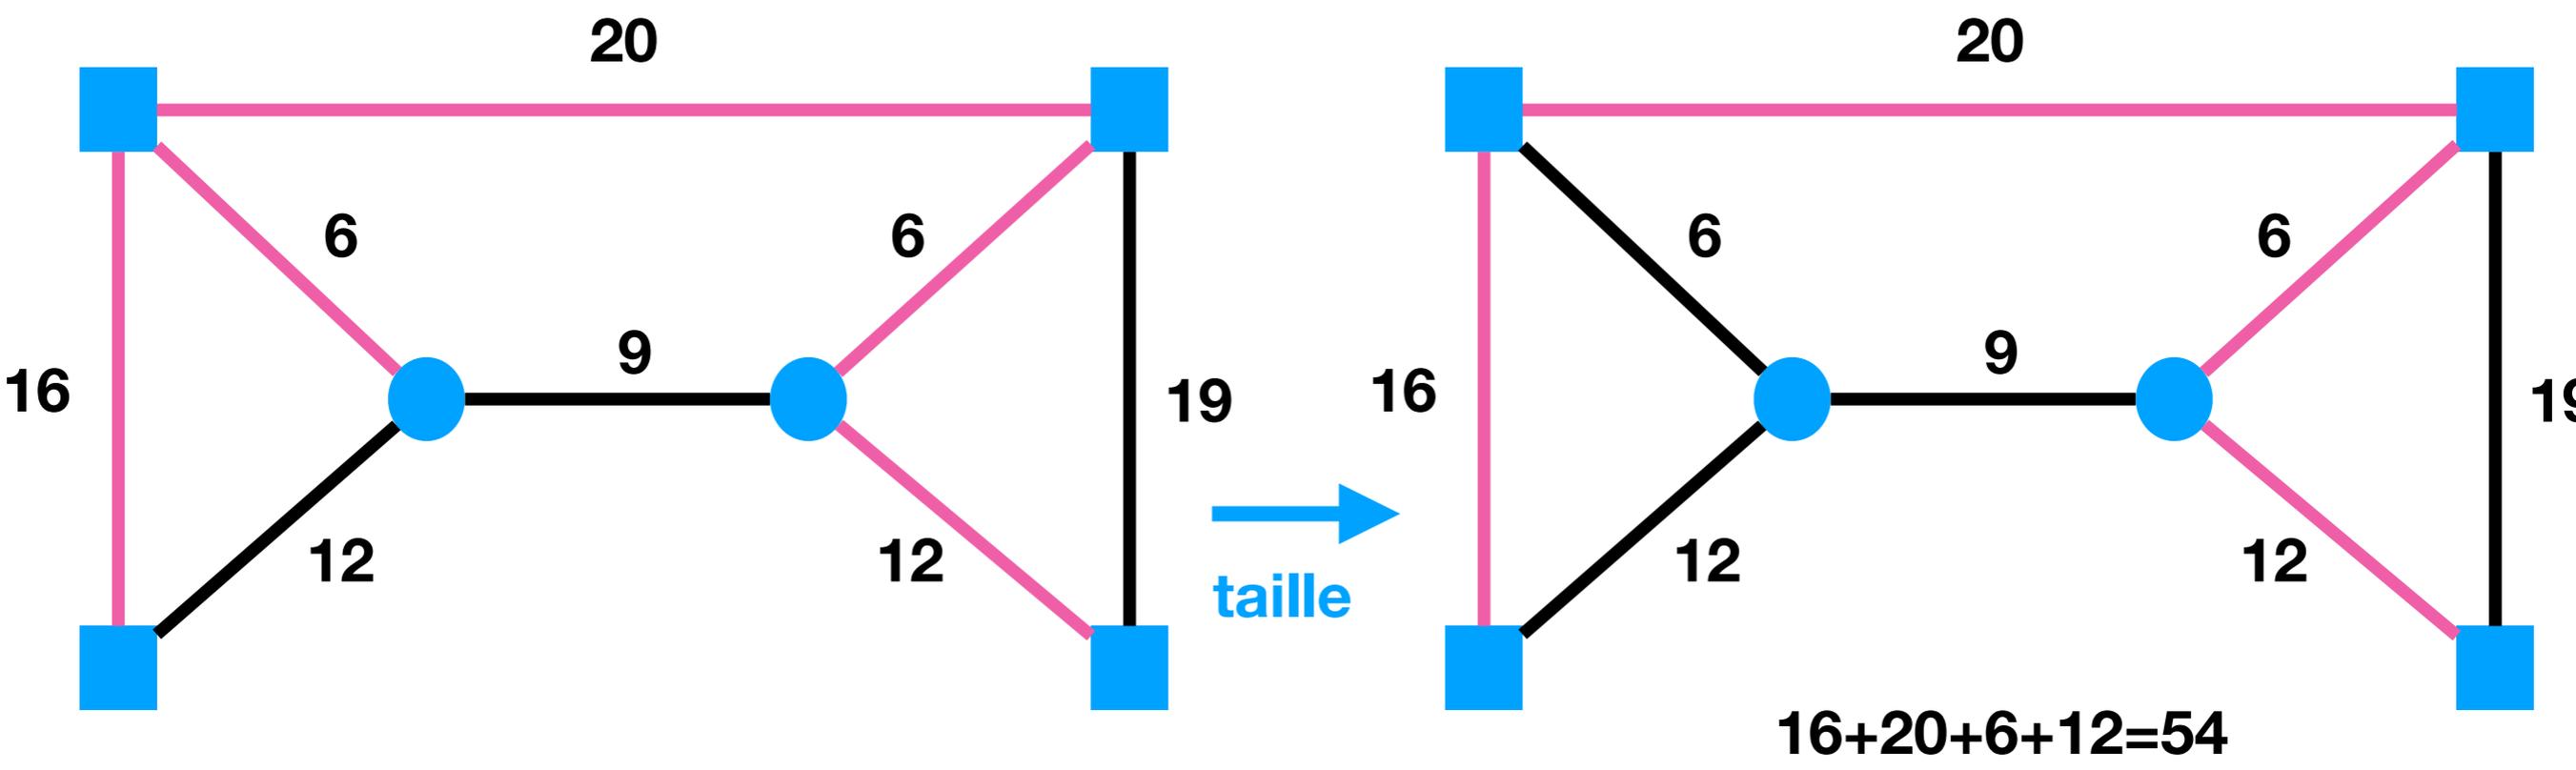
$t=8$



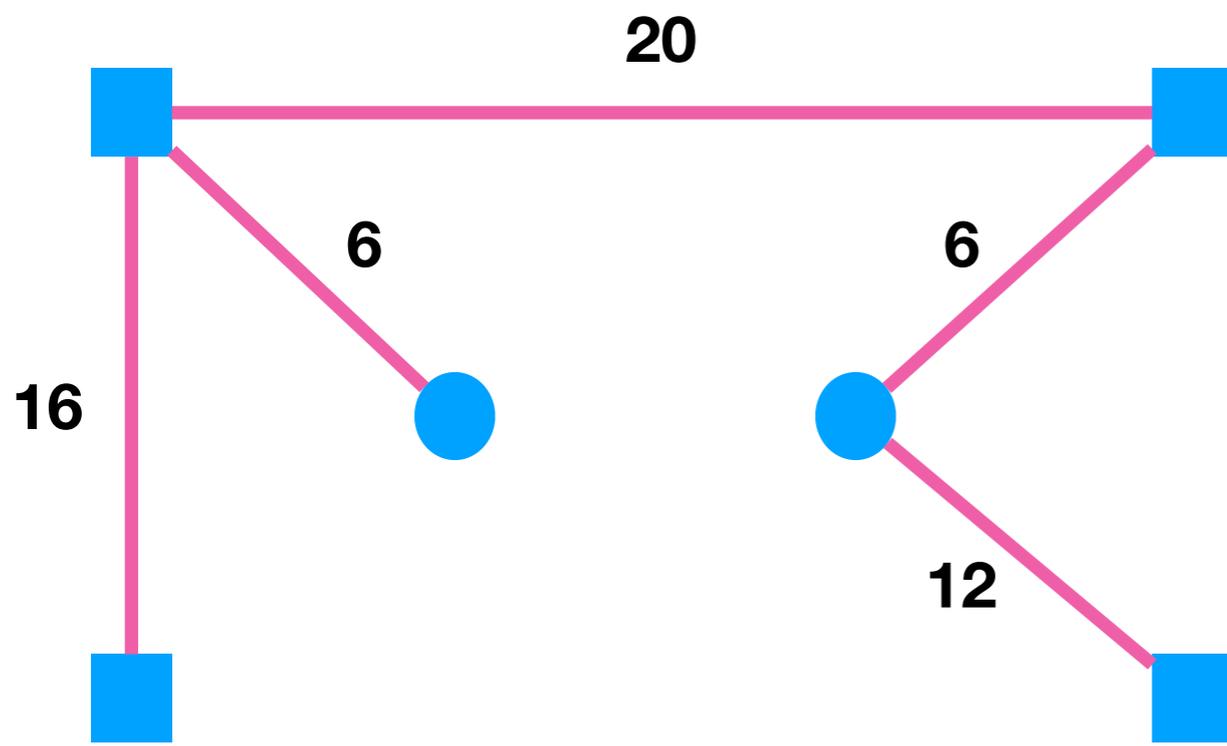
$t=9$



t=10

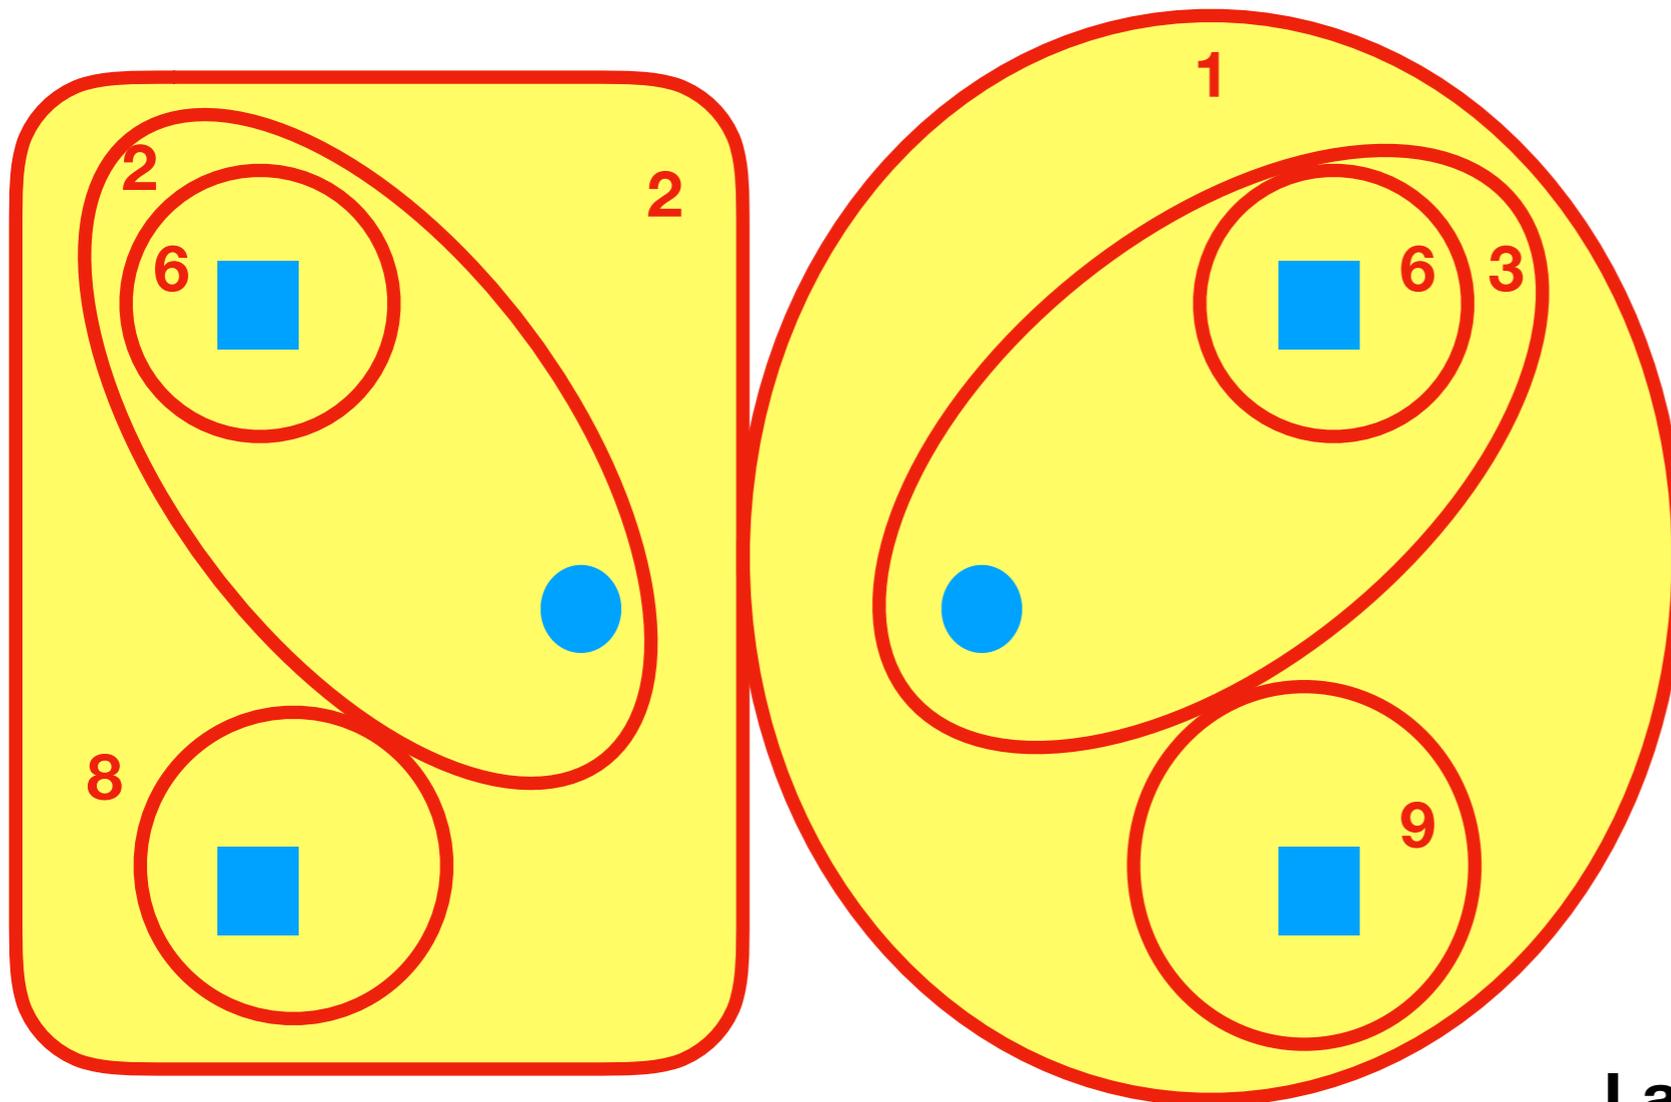


**Ce que l'algorithme fait :
deux structures construites en simultan **



**Un arbre
connectant les terminaux
(structure primale)**

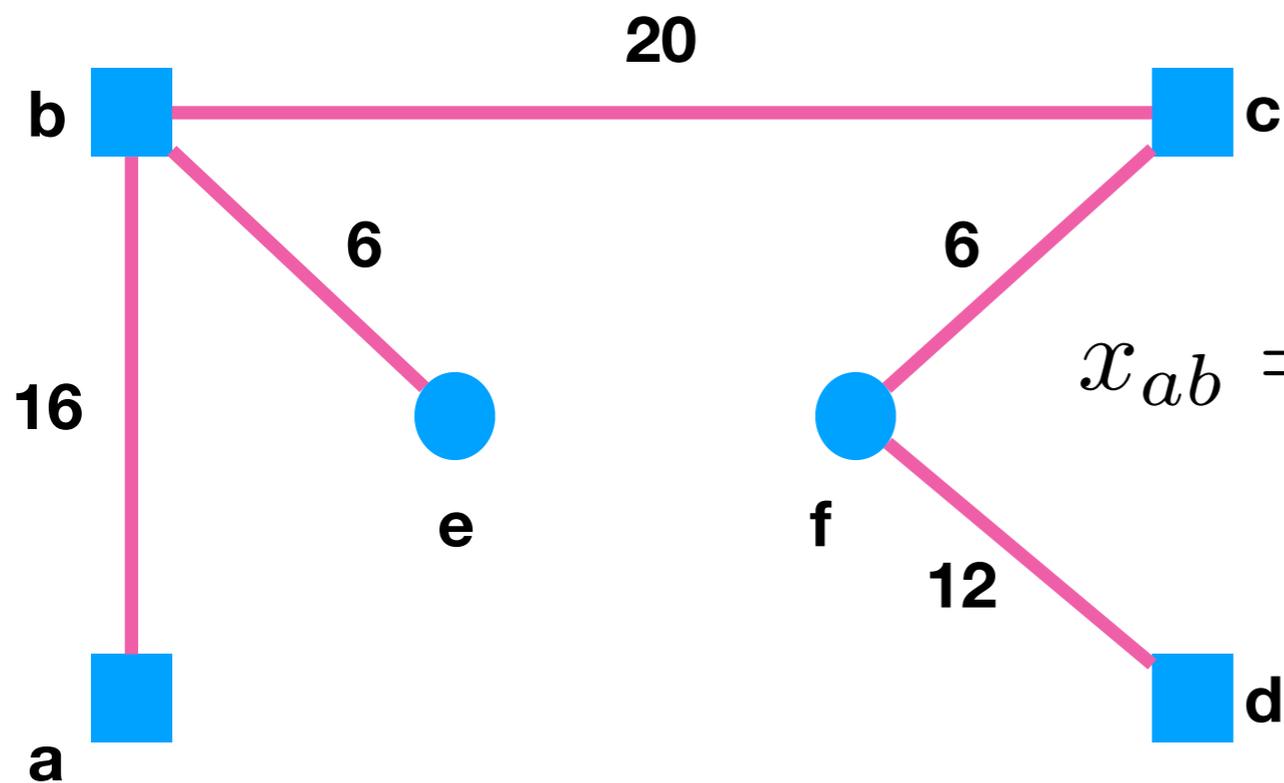
**La structure d finie par
le probl me**



**Un ensemble de
coupes imbriqu es
(structure duale)**

**Une structure "cach e"
r v l e par l'analyse
du probl me**

La 2e structure guide l'algorithme

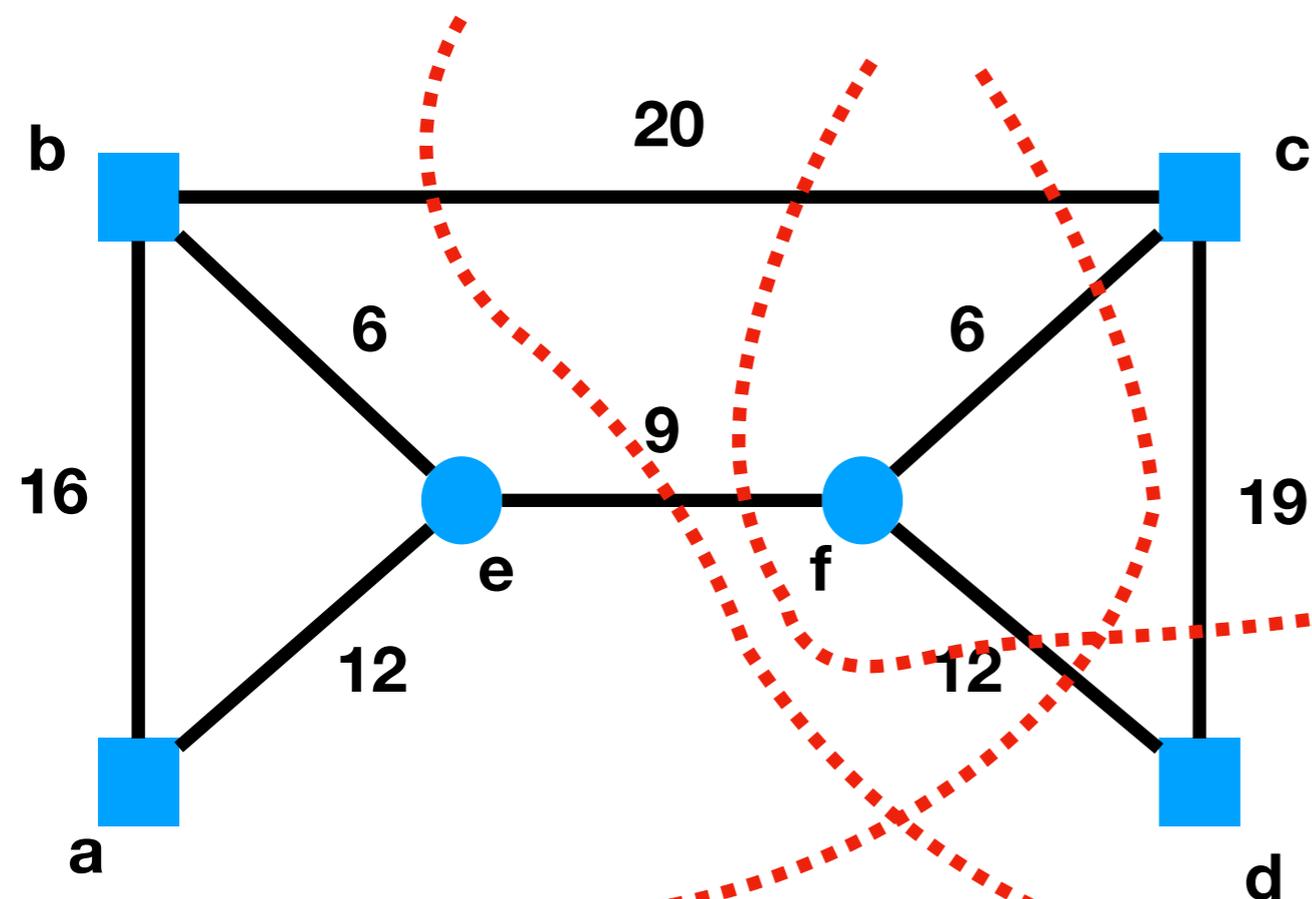


Un arbre connectant les terminaux (structure primale)

$$x_{ab} = x_{be} = x_{bc} = x_{cf} = x_{fd} = 1$$

$$x_{ae} = x_{ef} = x_{ad} = x_{cd} = 0$$

$$\min 16x_{ab} + 6x_{be} + 12x_{ae} + 20x_{bc} + 9x_{ef} + 6x_{fc} + 12x_{fd} + 19x_{cd}$$



$$0 \leq x_e \leq 1$$

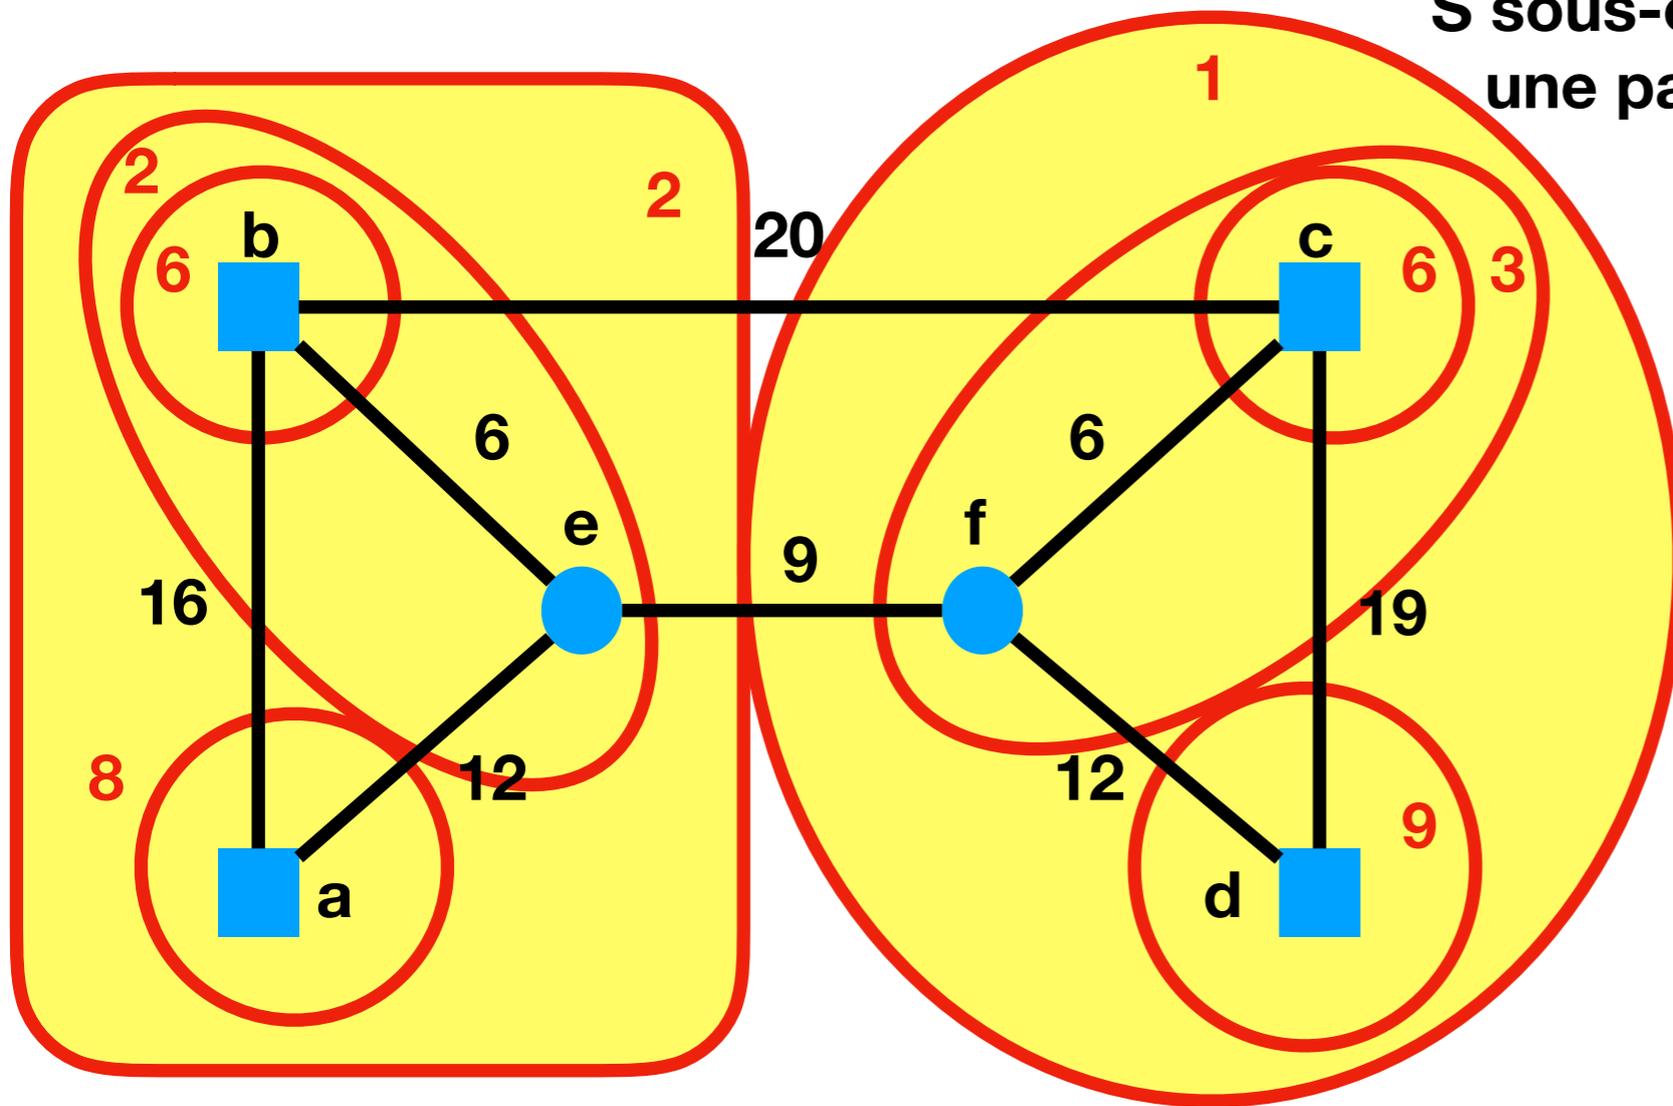
Toute coupe S séparant les terminaux doit être traversée par au moins une arête de l'arbre

$$x_{bc} + x_{cf} + x_{fd} \geq 1$$

$$x_{bc} + x_{cf} + x_{fd} \geq 1$$

$$x_{bc} + x_{ef} \geq 1$$

S sous-ensemble des sommets contenant une partie non-triviale des terminaux = coupe séparant les terminaux



$$0 \leq y_S \leq 1$$

$$y_b + y_{be} + y_{bea} + y_{cfd} + y_{cf} + y_c + \dots \leq 20$$

$$y_b + y_{be} + y_a + \dots \leq 16$$

$$\sum_{S:e \in S \times (V \setminus S)} y_S \leq (\text{poids de } e)$$

$$\max y_{bea} + y_{be} + y_b + y_e + y_a + y_{fcd} + y_{fc} + y_f + y_c + y_d + \dots$$

Toute coupe S séparant les terminaux doit être traversée par au moins une arête e de l'arbre

Variables $x(e)$

Minimiser le poids total des arêtes sélectionnées

Toute arête e doit être coupée par au plus poids(e) coupes S séparant les terminaux

Variables $y(S)$

Maximiser le nombre total de coupes sélectionnées

Dualité

$$\left\{ \begin{array}{l} \min \sum_e w(e)x_e : \\ \sum_{e \text{ coupé par } S} x_e \geq 1 \quad (\forall S) \\ 0 \leq x_e \leq 1 \quad (\forall e) \end{array} \right\} \longleftrightarrow \left\{ \begin{array}{l} \max \sum_S y_S : \\ \sum_{S \text{ coupant } e} y_S \leq w_e \quad (\forall e) \\ 0 \leq y_S \leq 1 \quad (\forall S) \end{array} \right\}$$

Théorème

$$\sum_e x_e^* = \min \sum_e w(e)x_e = \max \sum_S y_S = \sum_S y_S^*$$

On peut montrer que

l'analyse construit (x_e) et (y_S) tels que $\sum_e x_e \leq 2 \sum_S y_S$

Donc poids de l'arbre résultat

$$= \sum_e x_e \leq 2 \sum_S y_S \leq 2 \sum_S y_S^* = 2 \sum_e x_e^* \leq 2 OPT$$



Comprendre la dualité (1/4)

$$\begin{cases} \max 6x_1 + 14x_2 + 13x_3 : \\ x_1 + 4x_2 + 2x_3 \leq 48 \\ x_1 + 2x_2 + 4x_3 \leq 60 \\ 0 \leq x_1, x_2, x_3 \end{cases}$$

Est-il possible que la valeur optimale vaille 10000?

$$6x_1 + 14x_2 + 13x_3 = 10000?$$

Non, car

$$6x_1 + 14x_2 + 13x_3 \leq 6.5(x_1 + 4x_2 + 2x_3) \leq 312$$

Comprendre la dualité (2/4)

$$\begin{cases} \max 6x_1 + 14x_2 + 13x_3 : \\ x_1 + 4x_2 + 2x_3 \leq 48 \\ x_1 + 2x_2 + 4x_3 \leq 60 \\ 0 \leq x_1, x_2, x_3 \end{cases}$$

Est-il possible que la valeur optimale vaille 312?

$$6x_1 + 14x_2 + 13x_3 = 312?$$

Non, car

$$6x_1 + 14x_2 + 13x_3 \leq 5(x_1 + 4x_2 + 2x_3) + (x_1 + 2x_2 + 4x_3) \leq 300$$

Comprendre la dualité (3/4)

$$\begin{cases} \max 6x_1 + 14x_2 + 13x_3 : \\ x_1 + 4x_2 + 2x_3 \leq 48 \\ x_1 + 2x_2 + 4x_3 \leq 60 \\ 0 \leq x_1, x_2, x_3 \end{cases}$$

Quelle est la meilleure borne qu'on puisse obtenir ainsi ?

On multiplie la première inégalité par un coefficient positif y_1

On multiplie la deuxième inégalité par un coefficient positif y_2

tels que

$$6 \leq y_1 + y_2$$

$$14 \leq 4y_1 + 2y_2$$

$$13 \leq 2y_1 + 4y_2$$

Alors on a la borne $6x_1 + 14x_2 + 13x_3 \leq 48y_1 + 60y_2$

Donc la meilleure borne qu'on puisse obtenir ainsi est :

$$\min(48y_1 + 60y_2)$$

En résumé (4/4)

Primal

$$\left\{ \begin{array}{l} \max 6x_1 + 14x_2 + 13x_3 : \\ x_1 + 4x_2 + 2x_3 \leq 48 \\ x_1 + 2x_2 + 4x_3 \leq 60 \\ 0 \leq x_1, x_2, x_3 \end{array} \right.$$

Dual

$$\left\{ \begin{array}{l} \min 48y_1 + 60y_2 : \\ y_1 + y_2 \geq 6 \\ 4y_1 + 2y_2 \geq 14 \\ 2y_1 + 4y_2 \geq 13 \\ 0 \leq y_1, y_2 \end{array} \right.$$

On a argumenté que :

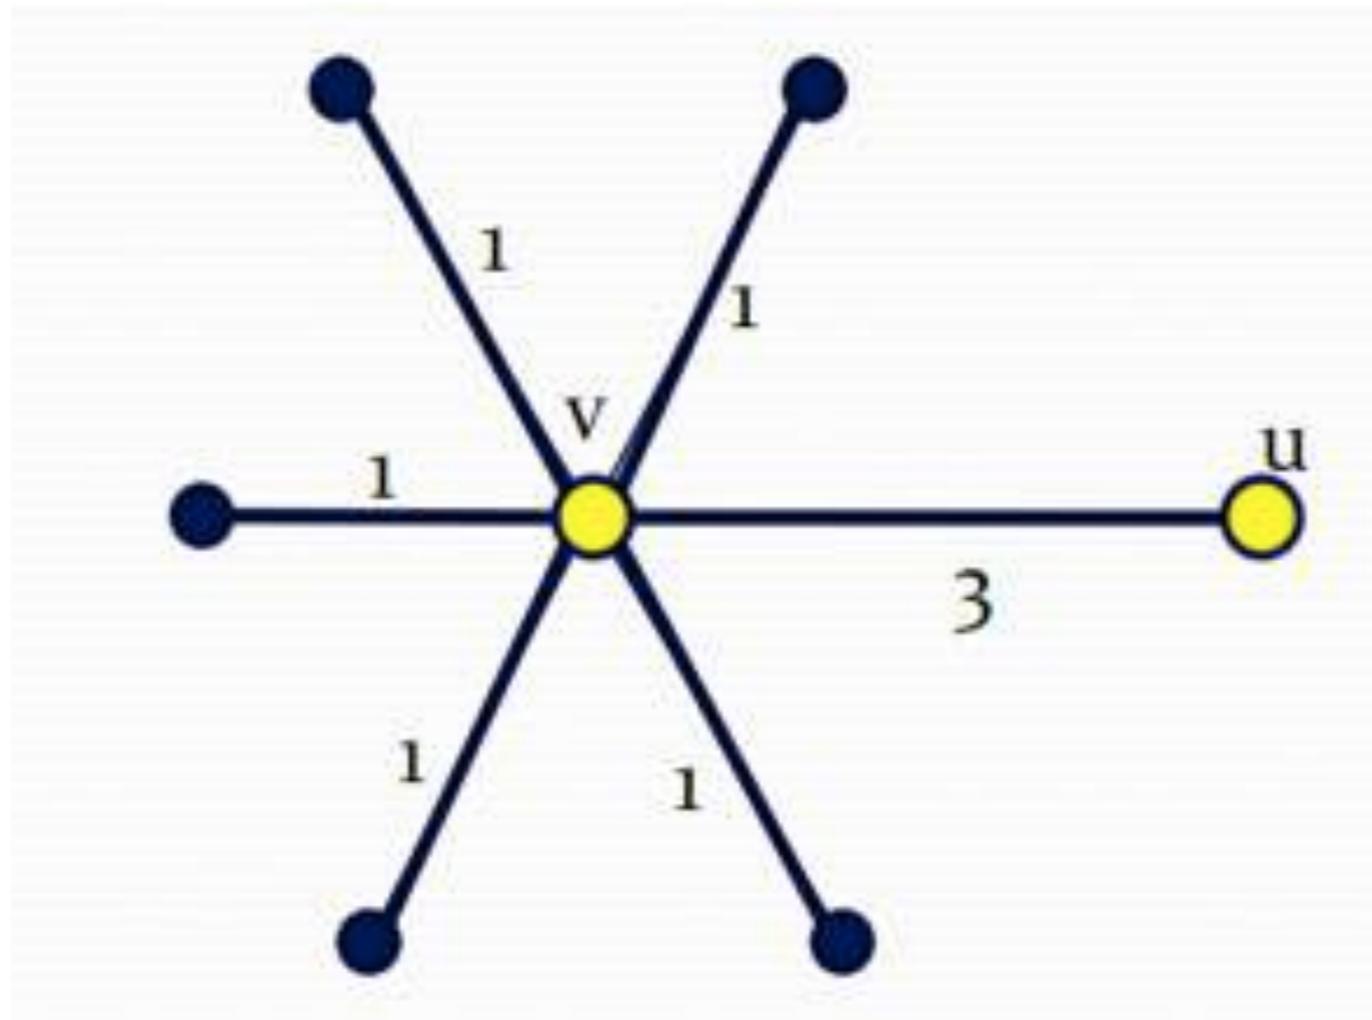
$$\max 6x_1 + 14x_2 + 13x_3 \leq \min 48y_1 + 60y_2$$

Théorème

$$\sum_e x_e^* = \min \sum_e w(e)x_e = \max \sum_S y_S = \sum_S y_S^*$$




Remarque : utilité de la taille finale



Application : sidérurgie



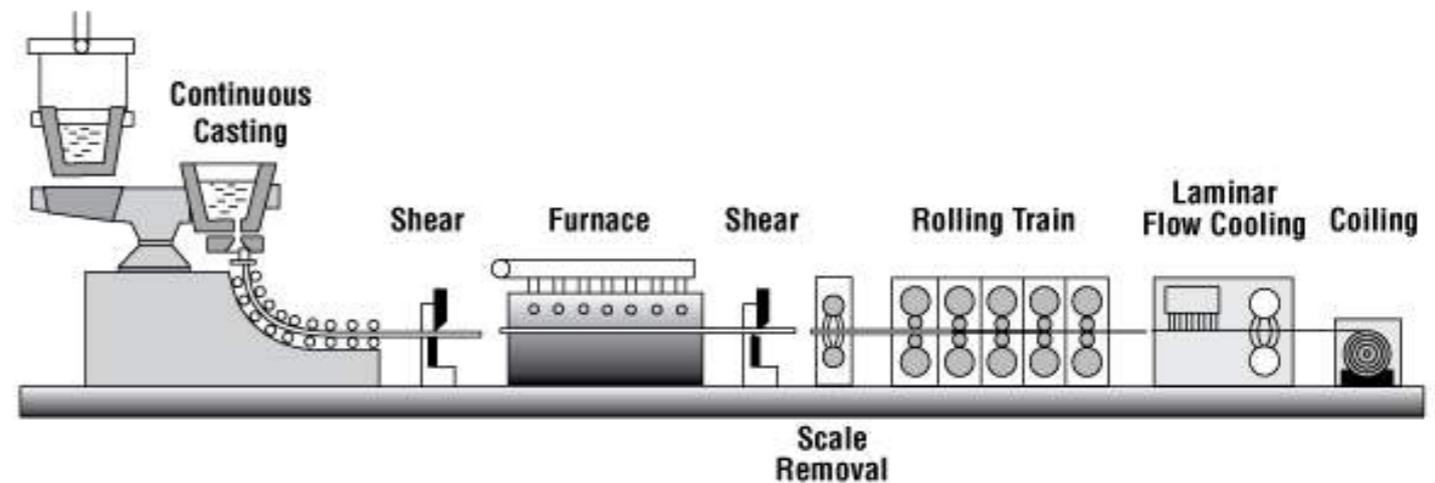
Usine de laminage d'acier



Brames d'acier



Une commande : rouleau d'acier de largeur, longueur, épaisseurs fixées

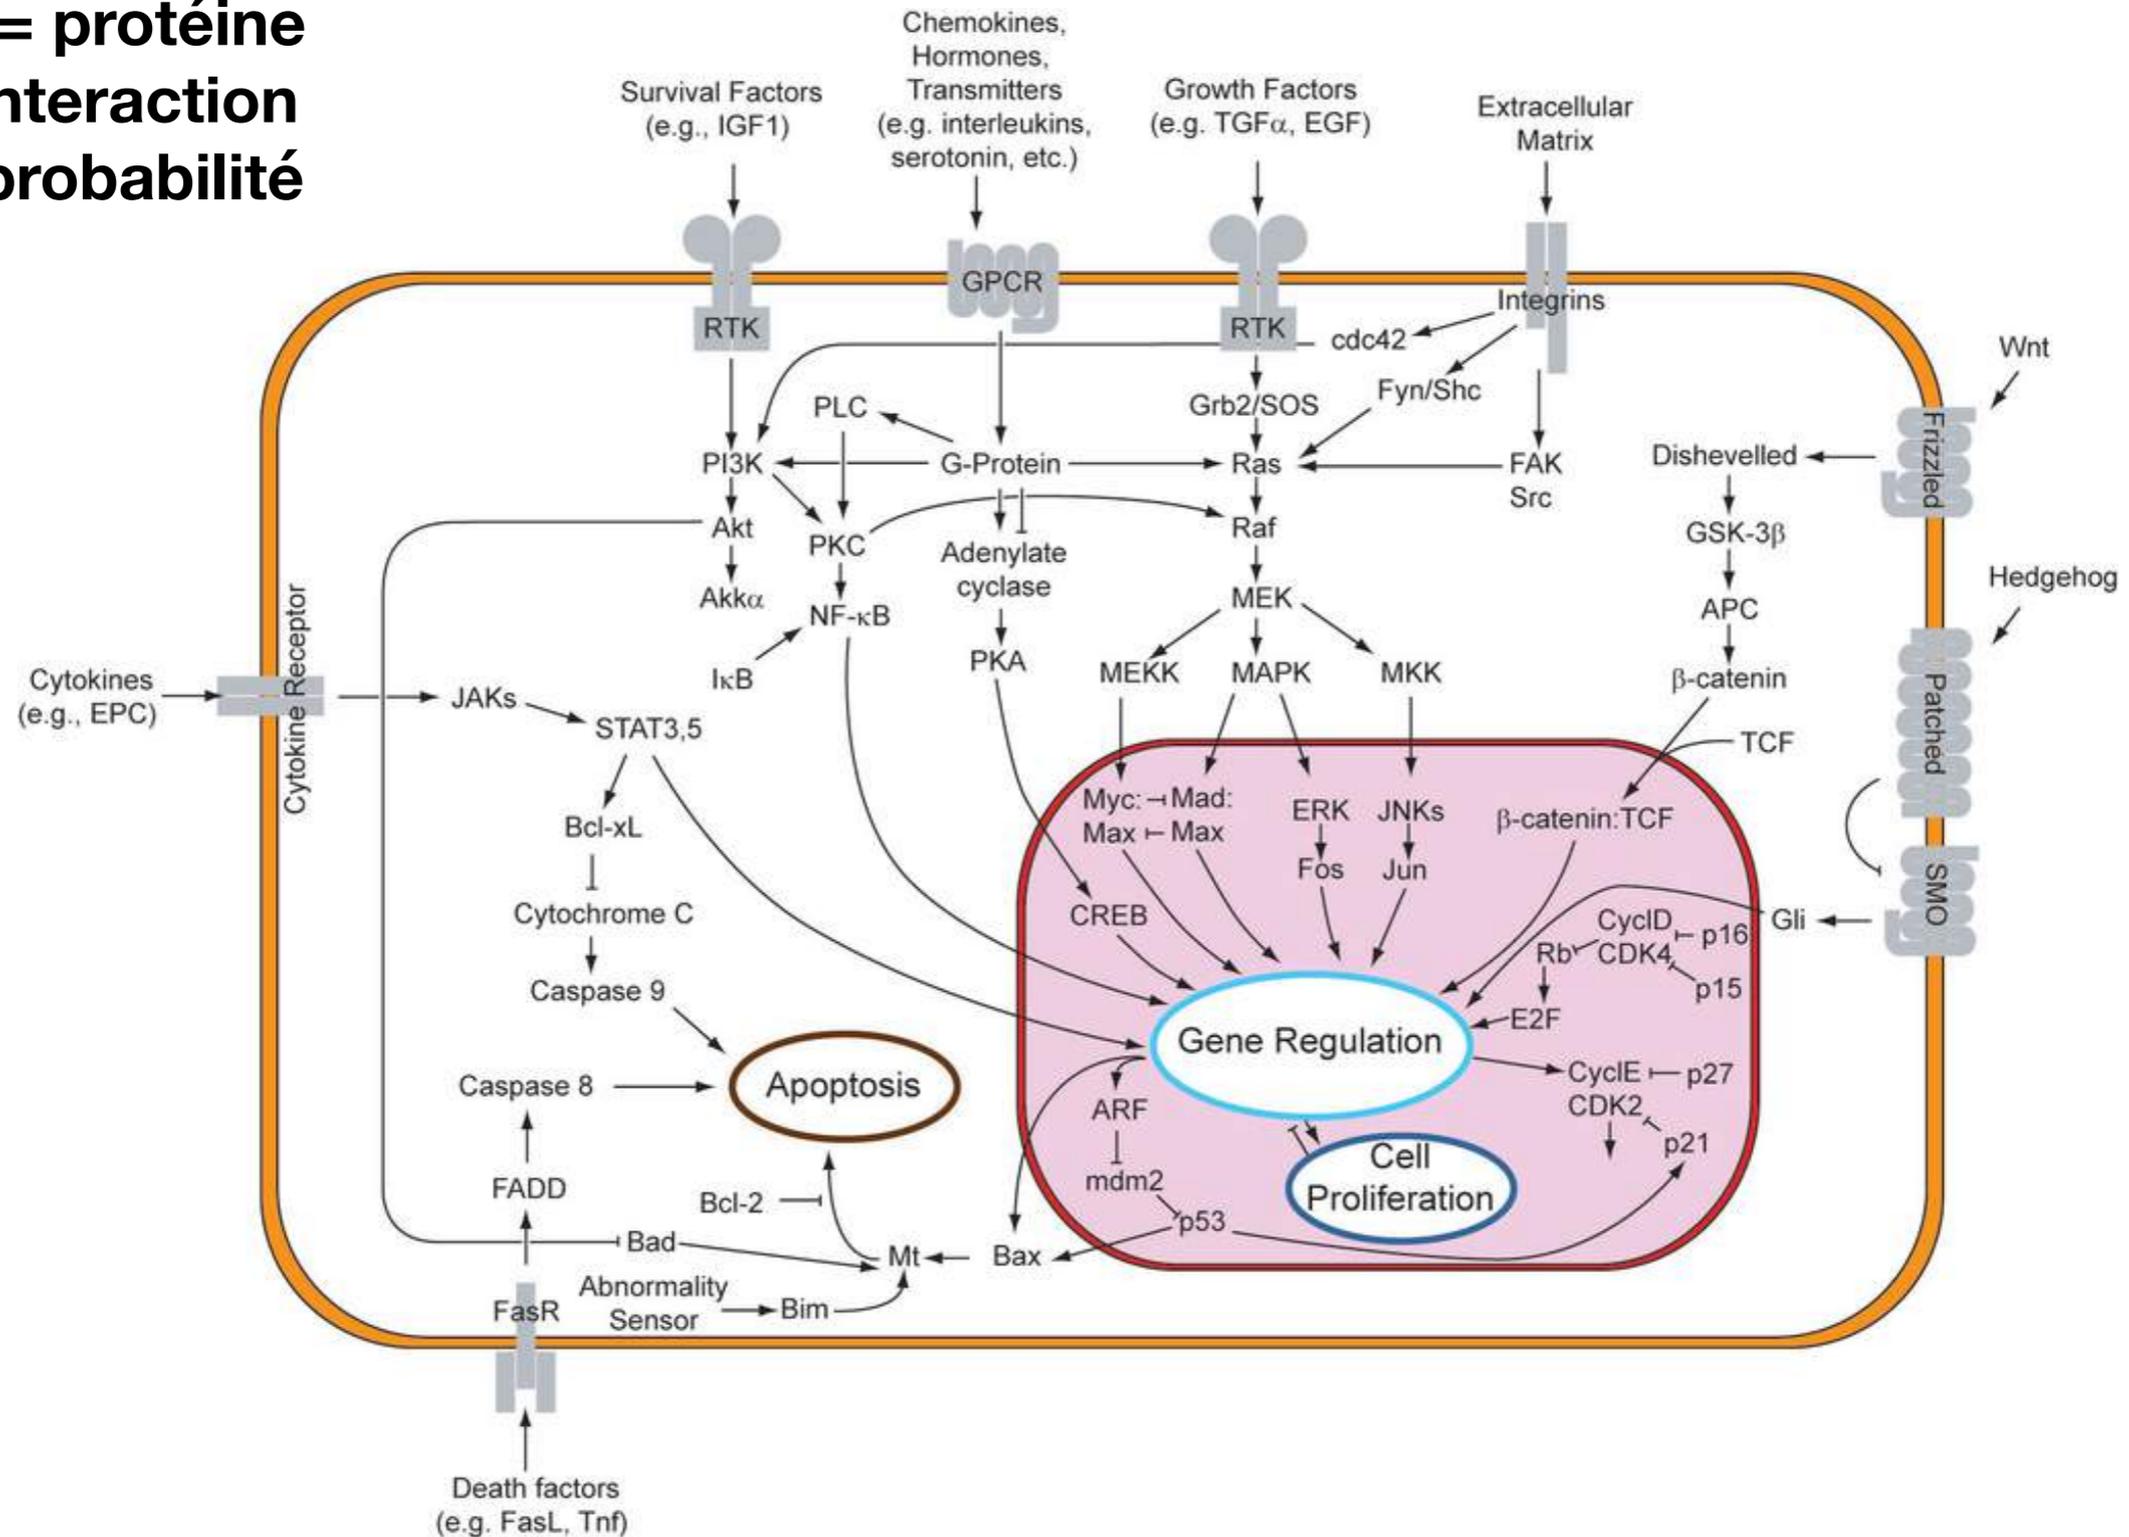


**Coût de transition
d'une commande à une autre**

Voyageur de commerce avec récompenses

Application : médecine

Réseau biologique
 sommet = protéine
 arête = interaction
 poids = probabilité



Flux d'information par interactions entre protéines
 Identification de voies de signalisation cellulaire

Arbre de Steiner
 avec récompenses

"We identify the role of the COS8 protein, a member of a gene family of previously unknown function,"

De l'utilité de l'étude théorique des algorithmes

- Méthode **générale**
- Algorithmes **simples**
- **Quasi-impossibles à trouver sans connaître la dualité**

Conclusion

Problèmes, algorithmes, analyse

Flux de données

Modèles

Questions

Graphes dynamiques

Modélisation et réseaux sociaux

Distribué

Théorie des jeux

Aléa

Techniques

Marches aléatoires

Schémas d'approximation

Programmation dynamique

Applications

Programmation linéaire

Biologie

Primal-dual

Réseaux

Médecine

Allocation de ressources dans la société

Usines

Problèmes ouverts