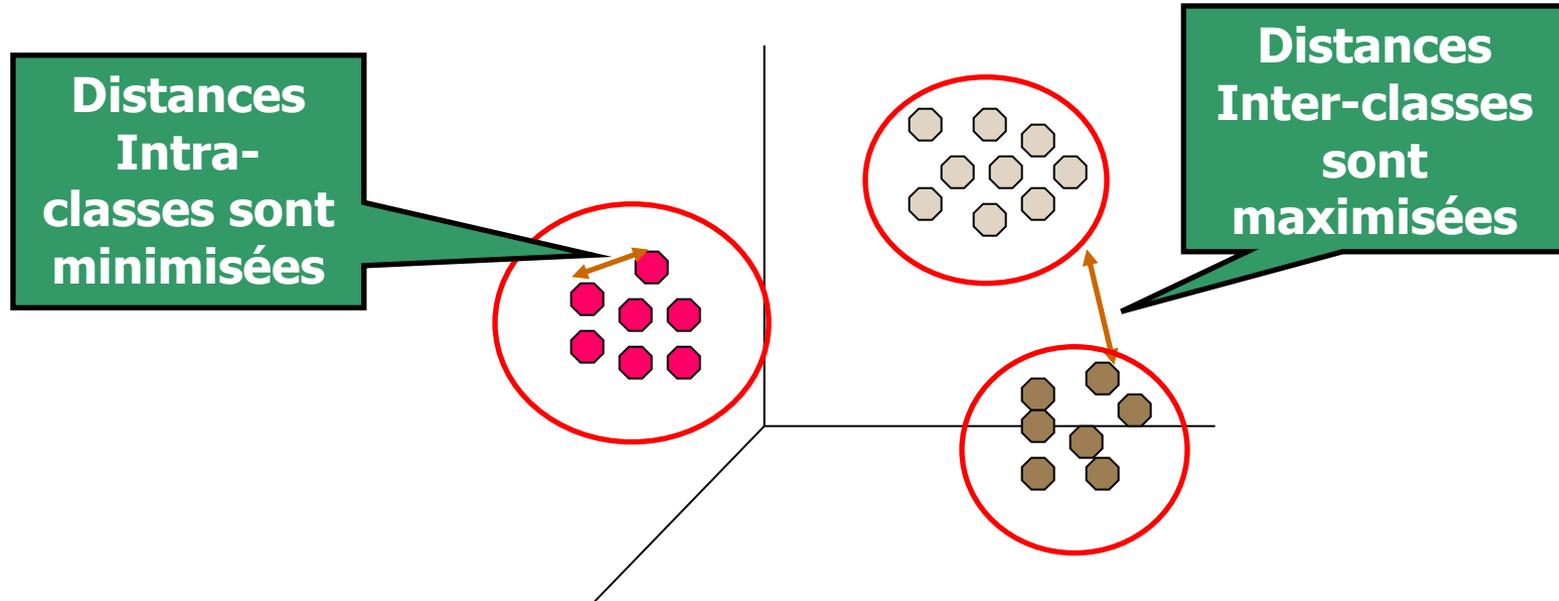


# Clustering

- **La Classification est un apprentissage supervisé. La supervision est faite en nommant les classes des instances d'apprentissage.**
- **Le Clustering est un apprentissage non supervisé. Il n'y a pas une connaissance a priori des classes, ni un ensemble d'apprentissage.**
- **L'algorithme de clustering nécessite une affectation de chaque instance à un groupe ou classe (cluster) de telle façon que tous les objets d'un même groupe sont plus semblables que les autres.**

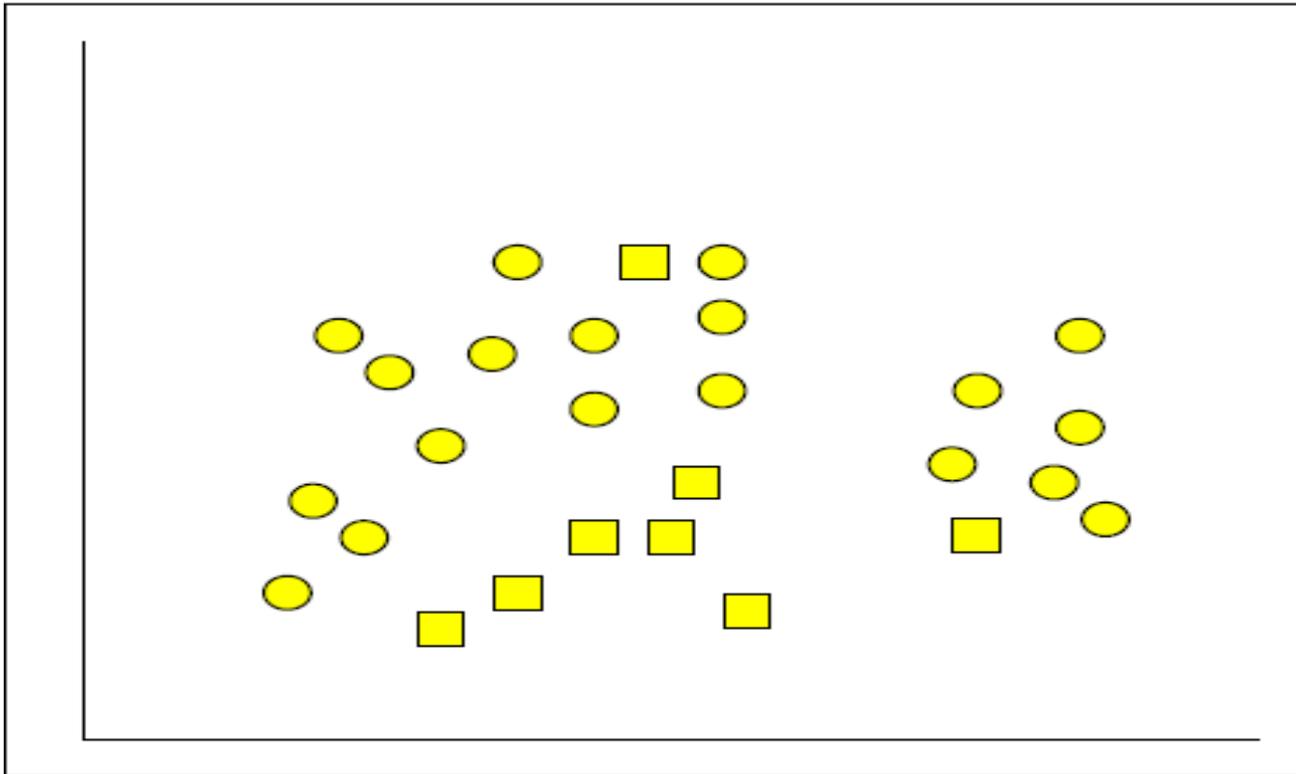
# Clustering

- Trouver des groupes (classes) d'objets tels que chaque objet d'un groupe est similaire qu'un autre objet du même groupe et différent des autres objets des autres groupes
- L'objectif est de trouver un groupement le plus naturel possible des instances.
  - A l'intérieur d'un groupe: Maximiser la similarité entre instances.
  - Entre les groupes: Minimiser la similarité entre les instances.



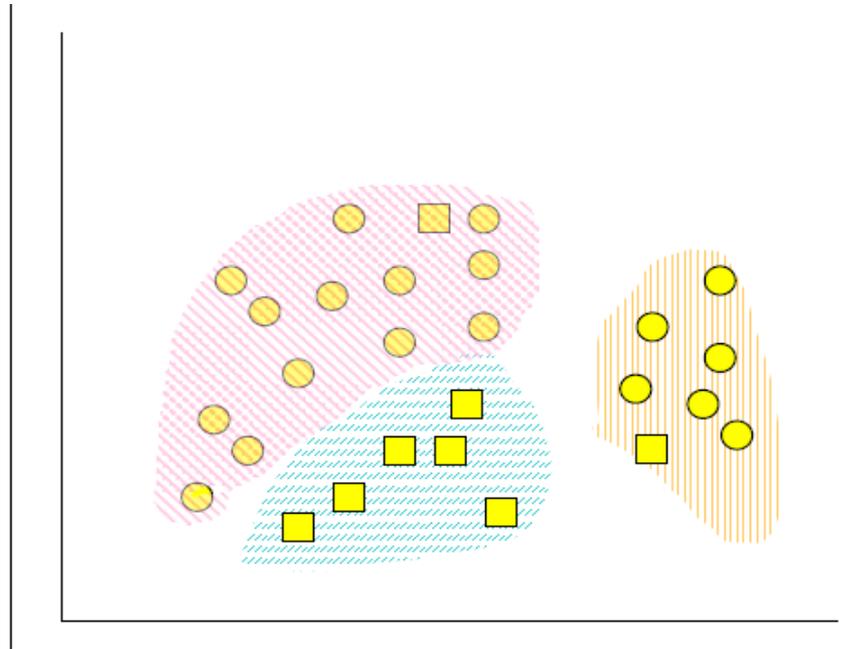
# Clustering

- Par exemple, soit l'ensemble de figures suivant:



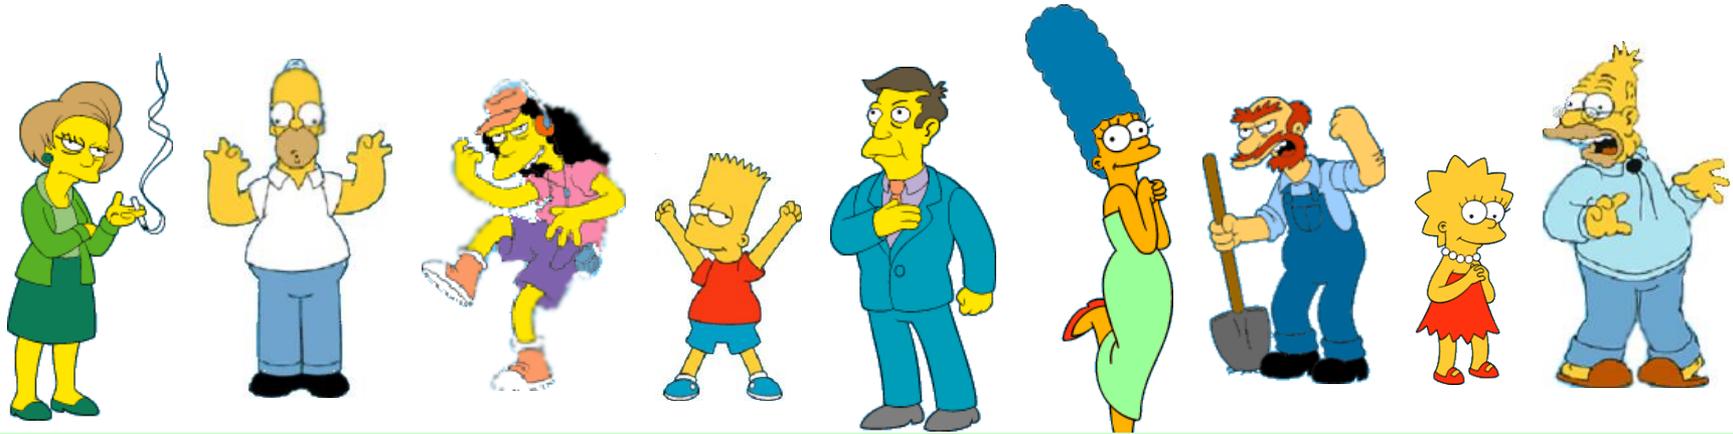
# Clustering

- Un algorithme de clustering peut trouver les clusters suivants:

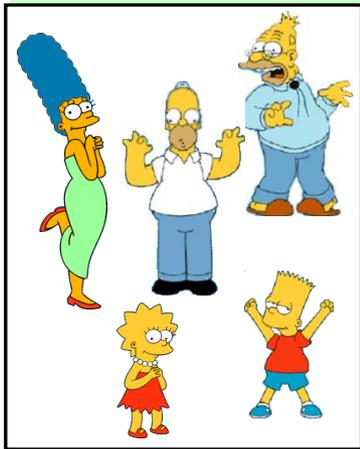


- Bien que certaines figures différentes coexistent dans un cluster.

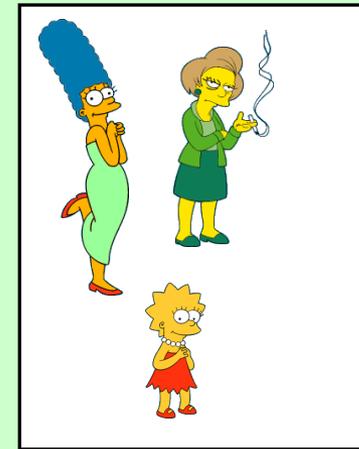
# Quel est le groupement naturel de ces objets?



Les algorithmes de Clustering sont subjectifs



Famille de Tatkare Employés de l'école



Feminins



Masculins

# Le problème du Clustering

- Etant donnée une base de données  $D=\{t_1,t_2,\dots,t_n\}$  de tuples et une valeur entière  $k$ , le *Clustering* est de définir une application  $f:D\rightarrow\{1,\dots,k\}$  où chaque  $t_i$  est affecté à un seul cluster (groupe ou classe)  $K_j$ ,  $1\leq j\leq k$ .
- Un *Cluster*,  $K_j$ , contient exactement les tuples qui lui sont affectés.
- Contrairement au problème de classification, les clusters ne sont pas connus a priori.

# Applications

- **Marketing:**  
Découvrir les groupes de clients basés sur leurs habitudes d'achats



- **Plans de cités:**  
Identifier les groupes de batiments par type, vameur, localisation



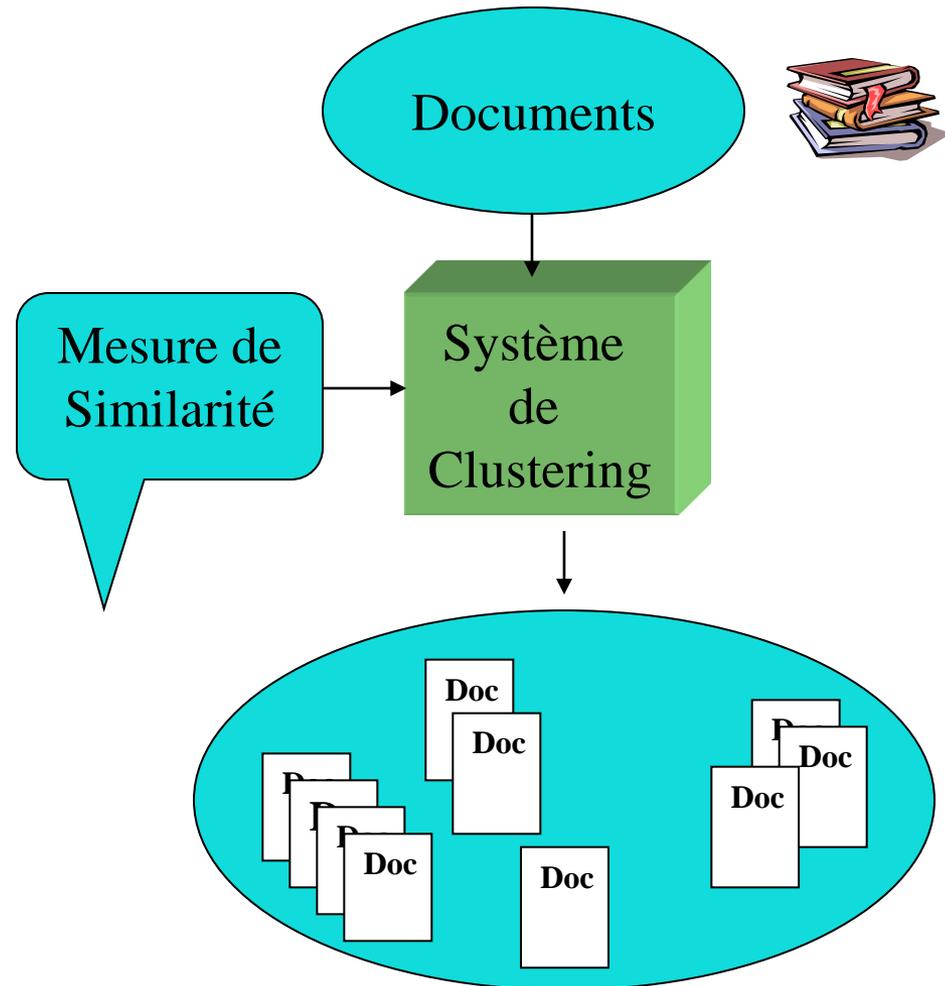
# Applications

- **Traitement d'image:** Identifier les clusters d'images similaires (eg chevaux)
- **Biologie:** Découvrir les groupes de plantes/animaux ayant des propriétés similaires



# Applications

- Etant donnés
  - Un ensemble de documents de texte
  - Une mesure de Similarité
    - e.g., Combien de mots communs dans tous les documents
- Trouver:
  - Les clusters (groupes) de documents pertinents



# Qu'est ce qu'un bon regroupement?

- Une bonne méthode de regroupement permet de garantir
  - Une grande similarité intra-groupe
  - Une faible similarité inter-groupe
- La qualité d'un regroupement dépend donc de la mesure de similarité utilisée par la méthode et de son implémentation



# Mesurer la qualité d'un clustering

- Métrique pour la similarité: La similarité est exprimée par le biais d'une **mesure de distance**
- Une autre fonction est utilisée pour la mesure de la qualité
- Les définitions de distance sont très différentes que **les variables** soient des intervalles (**continues**), **catégories, booléennes ou ordinales**
- En pratique, on utilise souvent une pondération des variables

# Types des variables

- Intervalles:
- Binaires:
- catégories, ordinales, ratio:
- Différents types:

# Intervalle (discrètes)

- Standardiser les données
  - Calculer l'écart absolu moyen:

$$s_f = \frac{1}{n} (|x_{1f} - m_f| + |x_{2f} - m_f| + \dots + |x_{nf} - m_f|)$$

où

$$m_f = \frac{1}{n} (x_{1f} + x_{2f} + \dots + x_{nf}).$$

- Calculer la mesure standardisée (z-score)

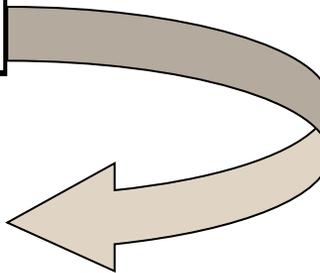
$$z_{if} = \frac{x_{if} - m_f}{s_f}$$

# Exemple

	Age	Salaire
Personne1	50	11000
Personne2	70	11100
Personne3	60	11122
Personne4	60	11074

$$M_{Age} = 60 \quad S_{Age} = 5$$

$$M_{salaire} = 11074 \quad S_{salaire} = 148$$



	Age	Salaire
Personne1	-2	-0,5
Personne2	2	0,175
Personne3	0	0,324
Personne4	0	2

# Similarité entre objets

- Les distances expriment une similarité
- Ex: *la distance de Minkowski* :

$$d(i, j) = \sqrt[q]{(|x_{i_1} - x_{j_1}|^q + |x_{i_2} - x_{j_2}|^q + \dots + |x_{i_p} - x_{j_p}|^q)}$$

où  $i = (x_{i_1}, x_{i_2}, \dots, x_{i_p})$  et  $j = (x_{j_1}, x_{j_2}, \dots, x_{j_p})$  sont deux objets  $p$ -dimensionnels et  $q$  un entier positif

- Si  $q = 1$ ,  $d$  est *la distance de Manhattan*

$$d(i, j) = |x_{i_1} - x_{j_1}| + |x_{i_2} - x_{j_2}| + \dots + |x_{i_p} - x_{j_p}|$$

# Similarité entre objets(I)

- Si  $q = 2$ ,  $d$  est *la distance Euclidienne* :

$$d(i, j) = \sqrt{(|x_{i_1} - x_{j_1}|^2 + |x_{i_2} - x_{j_2}|^2 + \dots + |x_{i_p} - x_{j_p}|^2)}$$

## – Propriétés

- $d(i, j) \geq 0$
- $d(i, i) = 0$
- $d(i, j) = d(j, i)$
- $d(i, j) \leq d(i, k) + d(k, j)$

# Exemple: distance de Manhattan

	Age	Salaire
Personne1	50	11000
Personne2	70	11100
Personne3	60	11122
Personne4	60	11074

→  $d(p1,p2)=120$   
 $d(p1,p3)=132$

Conclusion: p1 ressemble plus à p2 qu'à p3 ☹

	Age	Salaire
Personne1	-2	-0,5
Personne2	2	0,175
Personne3	0	0,324
Personne4	0	0

→  $d(p1,p2)=4,675$   
 $d(p1,p3)=2,824$

Conclusion: p1 ressemble plus à p3 qu'à p2 ☺

# VARIABLES BINAIRES

- Une table de contingence pour données

binaires

		Objet $j$		$sum$
		1	0	
Objet $i$	1	$a$	$b$	$a+b$
	0	$c$	$d$	$c+d$
$sum$		$a+c$	$b+d$	$p$

$a$  = nombre de positions  
où  $i$  a 1 et  $j$  a 1

- Exemple  $o_i = (1, 1, 0, 1, 0)$  et

$$o_j = (1, 0, 0, 0, 1)$$

$$a=1, b=2, c=1, d=1$$

# Mesures de distances

- Coefficient d'appariement (matching) simple (invariant pour variables symétriques):

$$d(i, j) = \frac{b + c}{a + b + c + d}$$

Exemple  $o_i = (1, 1, 0, 1, 0)$  et  $o_j = (1, 0, 0, 0, 1)$

$$d(o_i, o_j) = 3/5$$

- Coefficient de Jaccard  $d(i, j) = \frac{b + c}{a + b + c}$

$$d(o_i, o_j) = 3/4$$

# Variables binaires (I)

- Variable symétrique: Ex. le sexe d'une personne, i.e coder masculin par 1 et féminin par 0 c'est pareil que le codage inverse
- Variable asymétrique: Ex. Test HIV. Le test peut être positif ou négatif (0 ou 1) mais il y a une valeur qui sera plus présente que l'autre. Généralement, on code par 1 la modalité la moins fréquente
  - 2 personnes ayant la valeur 1 pour le test sont *plus similaires* que 2 personnes ayant 0 pour le test

# Variables binaires(II)

- Exemple

Nom	Sexe	Fièvre	Toux	Test-1	Test-2	Test-3	Test-4
Jack	M	Y	N	P	N	N	N
Mary	F	Y	N	P	N	P	N
Jim	M	Y	P	N	N	N	N

- Sexe est un attribut symétrique
- Les autres attributs sont asymétriques
- Y et P  $\equiv$  1, N  $\equiv$  0, la distance n'est mesurée que sur les asymétriques

$$d(\text{jack}, \text{mary}) = \frac{0 + 1}{2 + 0 + 1} = 0.33$$

$$d(\text{jack}, \text{jim}) = \frac{1 + 1}{1 + 1 + 1} = 0.67$$

$$d(\text{jim}, \text{mary}) = \frac{1 + 2}{1 + 1 + 2} = 0.75$$

Les plus similaires sont Jack et Mary  $\Rightarrow$  atteints du même mal

# Variables Nominales

- Une généralisation des variables binaires, ex: rouge, vert et bleu
- Méthode 1: Matching simple
  - $m$ : # d'appariements,  $p$ : # total de variables

$$d(i, j) = \frac{p - m}{p}$$

- Méthode 2: utiliser un grand nombre de variables binaires
  - Créer une variable binaire pour chaque modalité (ex: variable rouge qui prend les valeurs vrai ou faux)

# VARIABLES ORDINALES

- Une variable ordinale peut être discrète ou continue
- L'ordre peut être important, ex: classement
- Peuvent être traitées comme les variables intervalles
  - remplacer  $x_{if}$  par son rang  $r_{if} \in \{1, \dots, M_f\}$
  - Remplacer le rang de chaque variable par une valeur dans  $[0, 1]$  en remplaçant la variable  $f$  dans l'objet  $i$  par

$$z_{if} = \frac{r_{if} - 1}{M_f - 1}$$

- Utiliser une distance pour calculer la similarité

# En Présence de Variables de différents Types

- Pour chaque type de variables utiliser une mesure adéquate. Problèmes: les clusters obtenus peuvent être différents
- On utilise une formule pondérée pour faire la combinaison

$$d(i, j) = \frac{\sum_{f=1}^p \delta_{ij}^{(f)} d_{ij}^{(f)}}{\sum_{f=1}^p \delta_{ij}^{(f)}}$$

- $f$  est binaire ou nominale:

$$d_{ij}^{(f)} = 0 \text{ si } x_{if} = x_{jf}, \text{ sinon } d_{ij}^{(f)} = 1$$

- $f$  est de type intervalle: utiliser une distance normalisée

- $f$  est ordinale

- calculer les rangs  $r_{if}$  et
- Ensuite traiter  $z_{if}$  comme une variable de type intervalle

$$z_{if} = \frac{r_{if} - 1}{M_f - 1}$$