IA 101

Chapitre 4
Complexité et apprentissage automatique

Apprentissage avec connaissances

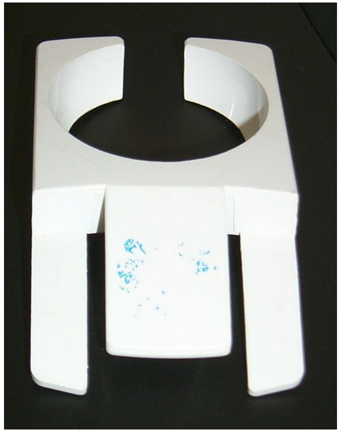

Complexité et apprentissage automatique

- Machine learning is compression
- ML classique : expliquer les données observées grâce à des équations et des paramètres
- → Les équations et les paramètres sont une compression des données

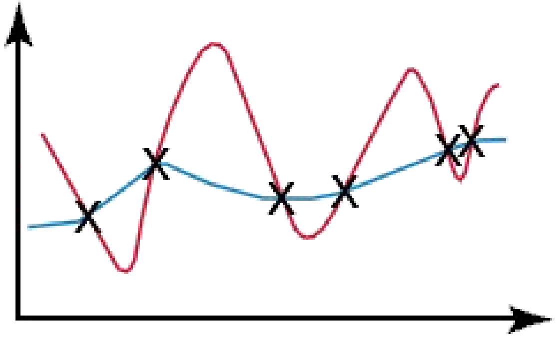

$$y = f(x) = \sum_{i=1}^{k} a_k x^k$$

1223334444...

$$\bigoplus_{m=1}^{n} m^m$$

Contenu

- Analogies
- Clustering
- Longueur de description minimale
- Détection d’anomalies
- Apprentissage avec connaissances

Analogies

g h i → g h j

uu vv ww → uu vv xx
uu vv wx
uu vv jj
uu vv wj

Analogies

a : b :: c : d   a : b :: c : x   x = ?

- king : queen :: man : woman
- rosa : rosam :: vita : vitam   [latin]
- setzen : setzte :: lachen : lachte   [allemand]
- solve : solves :: get : gets   [anglais]
- guru : guru-guru :: pelajar : pelajar-pelajar [indonésien]
- puhua : puhuu :: juhlia : juhlii   [finlandais]
- apte : inapte :: élu : *inélu

Analogies

a : b :: c : d

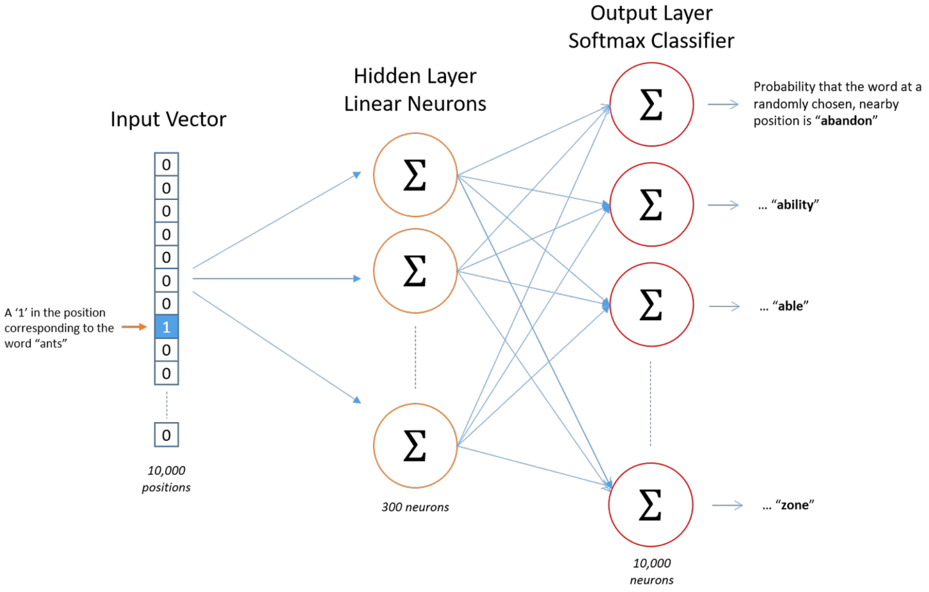

a : b :: c : x   x = ?

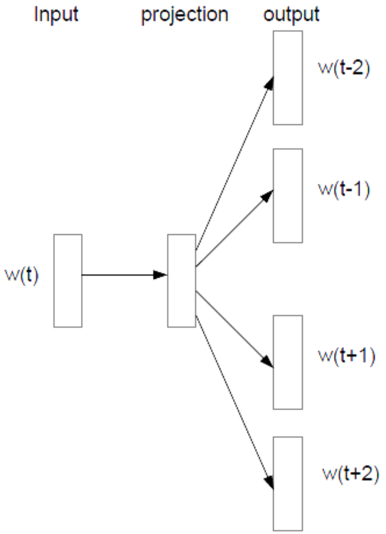

Skip-gram model architecture

"Madrid" - "Spain" + "France" = "Paris"

Mikolov et al, Distributed representations of words and phrases and their compositionality. *NeurIPS 2013*

Analogies

- Des millions de paramètres
- 6 milliards de mots

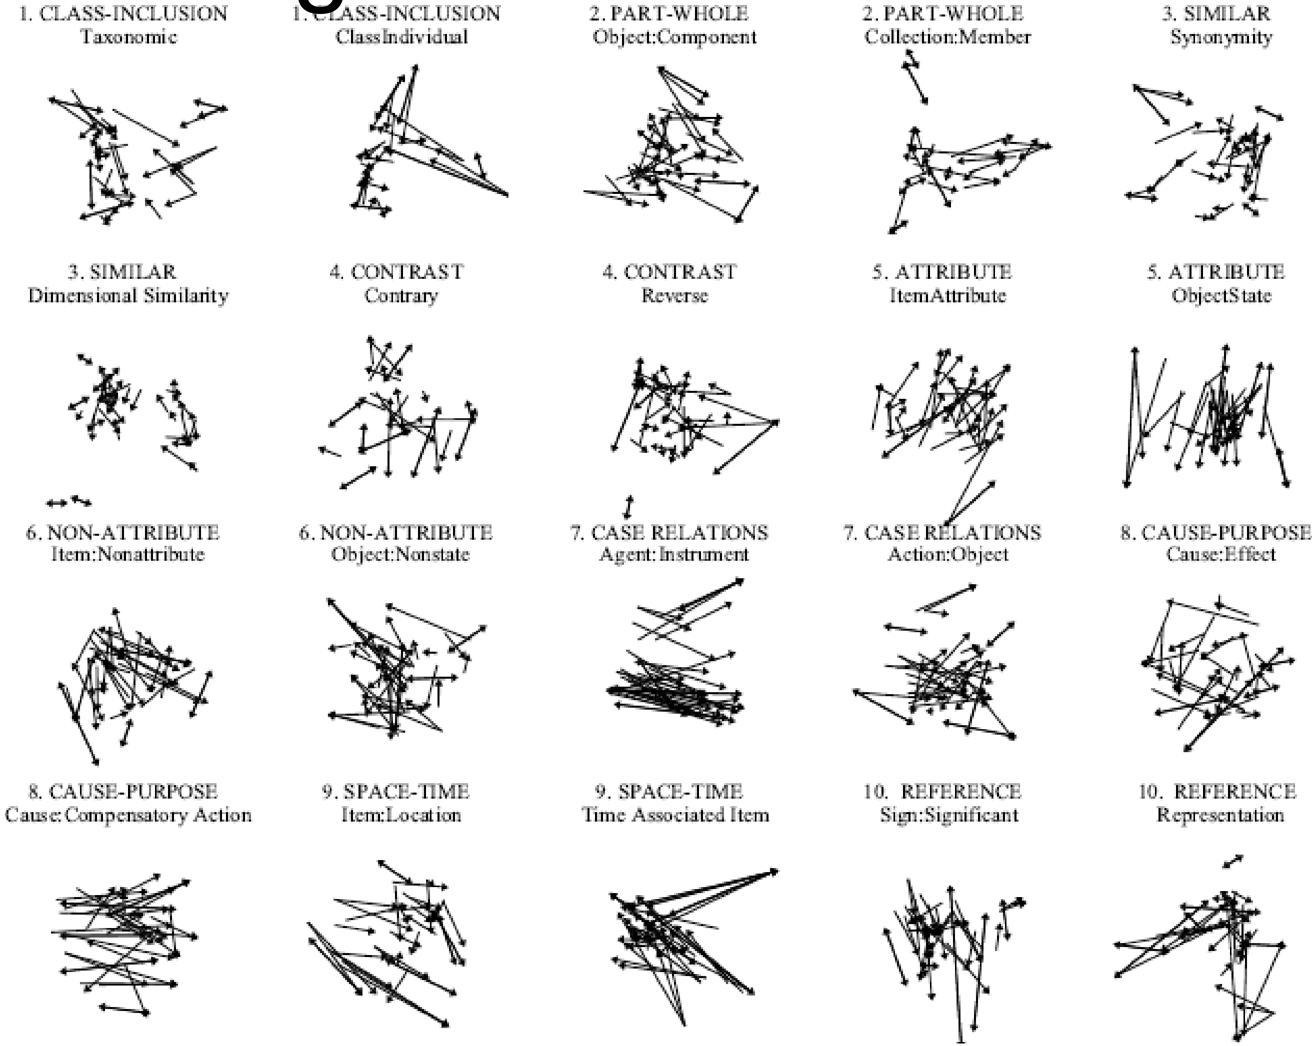

Chen et al, [Evaluating vector-space models of analogy,](#) Cogsci-2017.

Analogies

a : b :: c : x x = ?

$$x = \underset{y}{\operatorname{argmin}}\, K(a, b, c, y)$$

$$a = f(b); x = f(c) \text{ tel que } K(f) \text{ est minimale}$$

$$a \xrightarrow{f} b$$

$$c \xrightarrow{f} x$$

Analogies

`let, 'abc', let` stores the string `abc` in memory.

`mem, 0` retrieves the last item stored in memory (here: `abc`).

`let, ?0, ?1, let` stores an operation (here: concat).

```
$ python
>>> import analogy as A
>>> A.generate_string("abc, ijk")
>>> 'abcijk'
>>> A.generate_string("let, ?0, -, ?0, let, mem, 0, orang")
    'orang-orang'
>>> A.instruction_complexity("let, ?0, -, ?0, let, mem, 0, orang")
    35
```

Analogies

`let, 'abc', let` stores the string `abc` in memory.

`mem, 0` retrieves the last item stored in memory (here: `abc`).

`let, ?0, ?1, let` stores an operation (here: concat).

What is the output of the following program?

`let, ab, ?0, ?1, let, a, mem, 0, a, b`

A. abba
B. aabba
C. abab
D. aabab

Analogies

Language	#analogies	NLG_COMP	NLG_PROP	NLG_ALEA
Arabic	165,113	87.18%	**93.33%**	81.91%
Finnish	313,011	**93.69%**	92.76%	78.75%
Georgian	3,066,273	**99.35%**	97.54%	88.42%
German	730,427	**98.84%**	96.21%	95.42%
Hungarian	2,912,310	**95.71%**	92.61%	86.02%
Maltese	28,365	**96.38%**	84.72%	91.84%
Navajo	321,473	81.21%	**86.87%**	78.95%
Russian	552,423	96.41%	**97.26%**	95.46%
Spanish	845,996	**96.73%**	96.13%	94.42%
Turkish	245,721	**89.45%**	69.97%	70.06%
Total	9,181,112	**96.41%**	94.34%	87.93%

Table 2: Proportion of correct answers when solving analogies from the dataset SIGMORPHON'16 using our method NLG_COMP and two state-of-the-art methods NLG_PROP [Fam and Lepage, 2018] and NLG_ALEA [Langlais *et al.*, 2009].

rosa : rosam :: vita : x

orang : orang-orang :: burung : x

Murena, P.-A., Al-Ghossein, M., Dessalles, J.-L. & Cornuéjols, A. (2020). Solving analogies on words based on minimal complexity transformation. *IJCAI*, 1848-1854.

Longueur de description minimale

Tycho Brahe

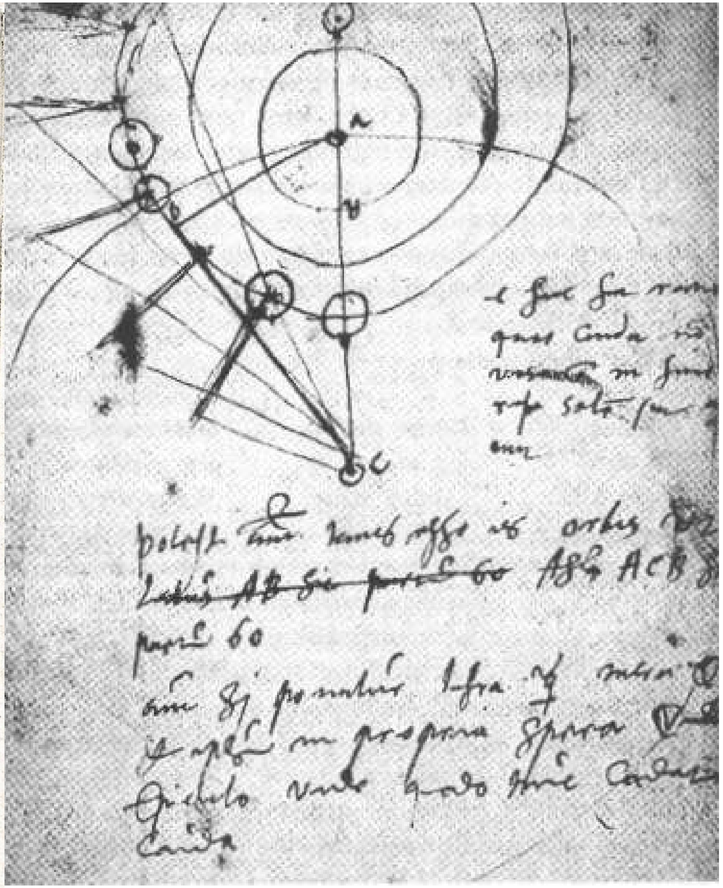

Longueur de description minimale

Johannes Kepler

1) Les planètes du système solaire décrivent des trajectoires elliptiques, dont le Soleil occupe l'un des foyers.

2) Des aires égales sont balayées dans des temps égaux.

3) $$\frac{T^2}{a^3} = \text{constante}$$

Longueur de description minimale

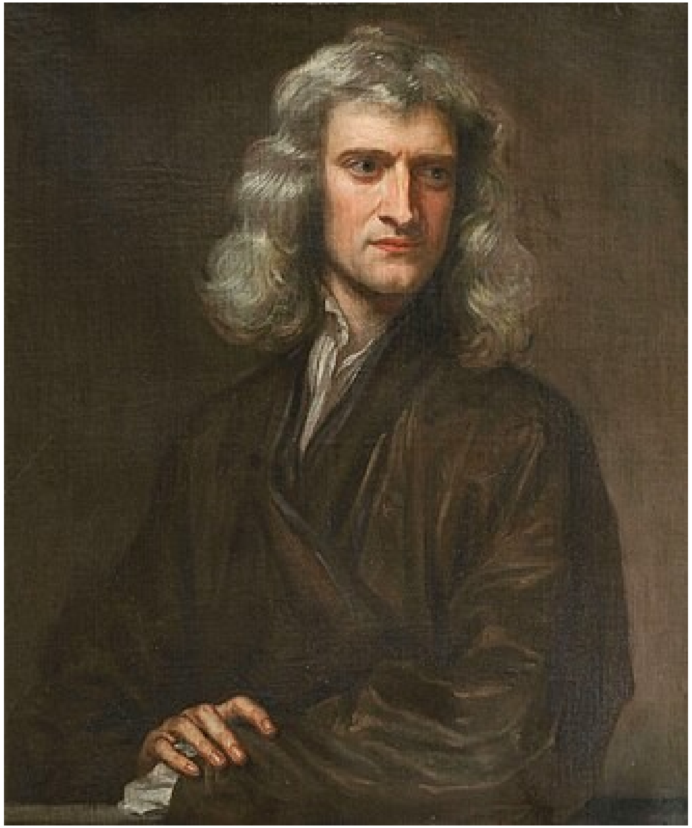

Isaac Newton

1) Tout corps persévère dans l'état de repos ou de mouvement uniforme en ligne droite dans lequel il se trouve, à moins que quelque force n'agisse sur lui, et ne le contraigne à changer d'état.

2) $$\frac{\mathrm{d}\vec{p}}{\mathrm{d}t} = \sum_i \vec{F}_i$$

3) $$\vec{F}_{A\to B} = -\vec{F}_{B\to A}$$

$$\vec{F}_{A\to B} \cdot \vec{AB} = 0$$

Longueur de description minimale

COMPRESSION →

Réalité → Observations → Lois empiriques → Principes

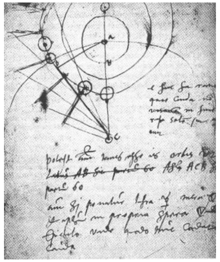

$$\frac{T^2}{a^3} = \text{constante}$$

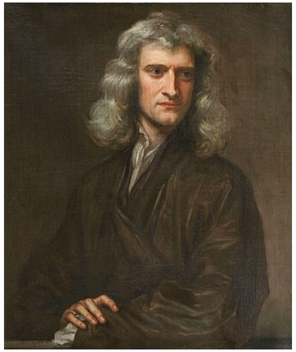

$$\frac{\mathrm{d}\vec{p}}{\mathrm{d}t} = \sum_i \vec{F}_i$$

Longueur de description minimale

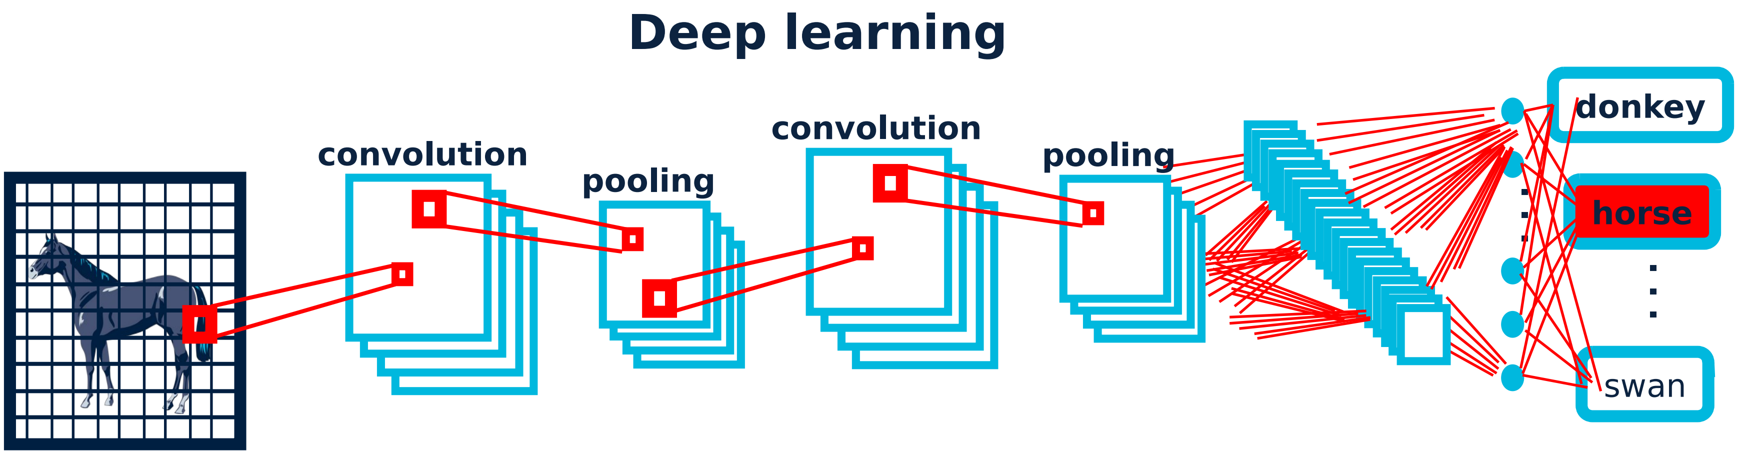

Apprentissage automatique :

- Collecter des observations
- Exprimer les probabilités des observations avec une fonction paramétrique
- Trouver les paramètres qui maximisent la probabilité des observations

Longueur de description minimale

GPT-3 ≈ explication des données trouvées sur internet

ANNALS OF TECHNOLOGY

CHATGPT IS A BLURRY JPEG OF THE WEB

OpenAI's chatbot offers paraphrases, whereas Google offers quotes. Which do we prefer?

By **Ted Chiang**

February 9, 2023

Longueur de description minimale

Quel est le meilleur modèle ?

- Une équation avec 8 paramètres qui prédit 92% des observations
- Un réseau de neurones avec 12M de paramètres entrainé sur 1M d'exemples qui prédit 96% des observations

Longueur de description minimale

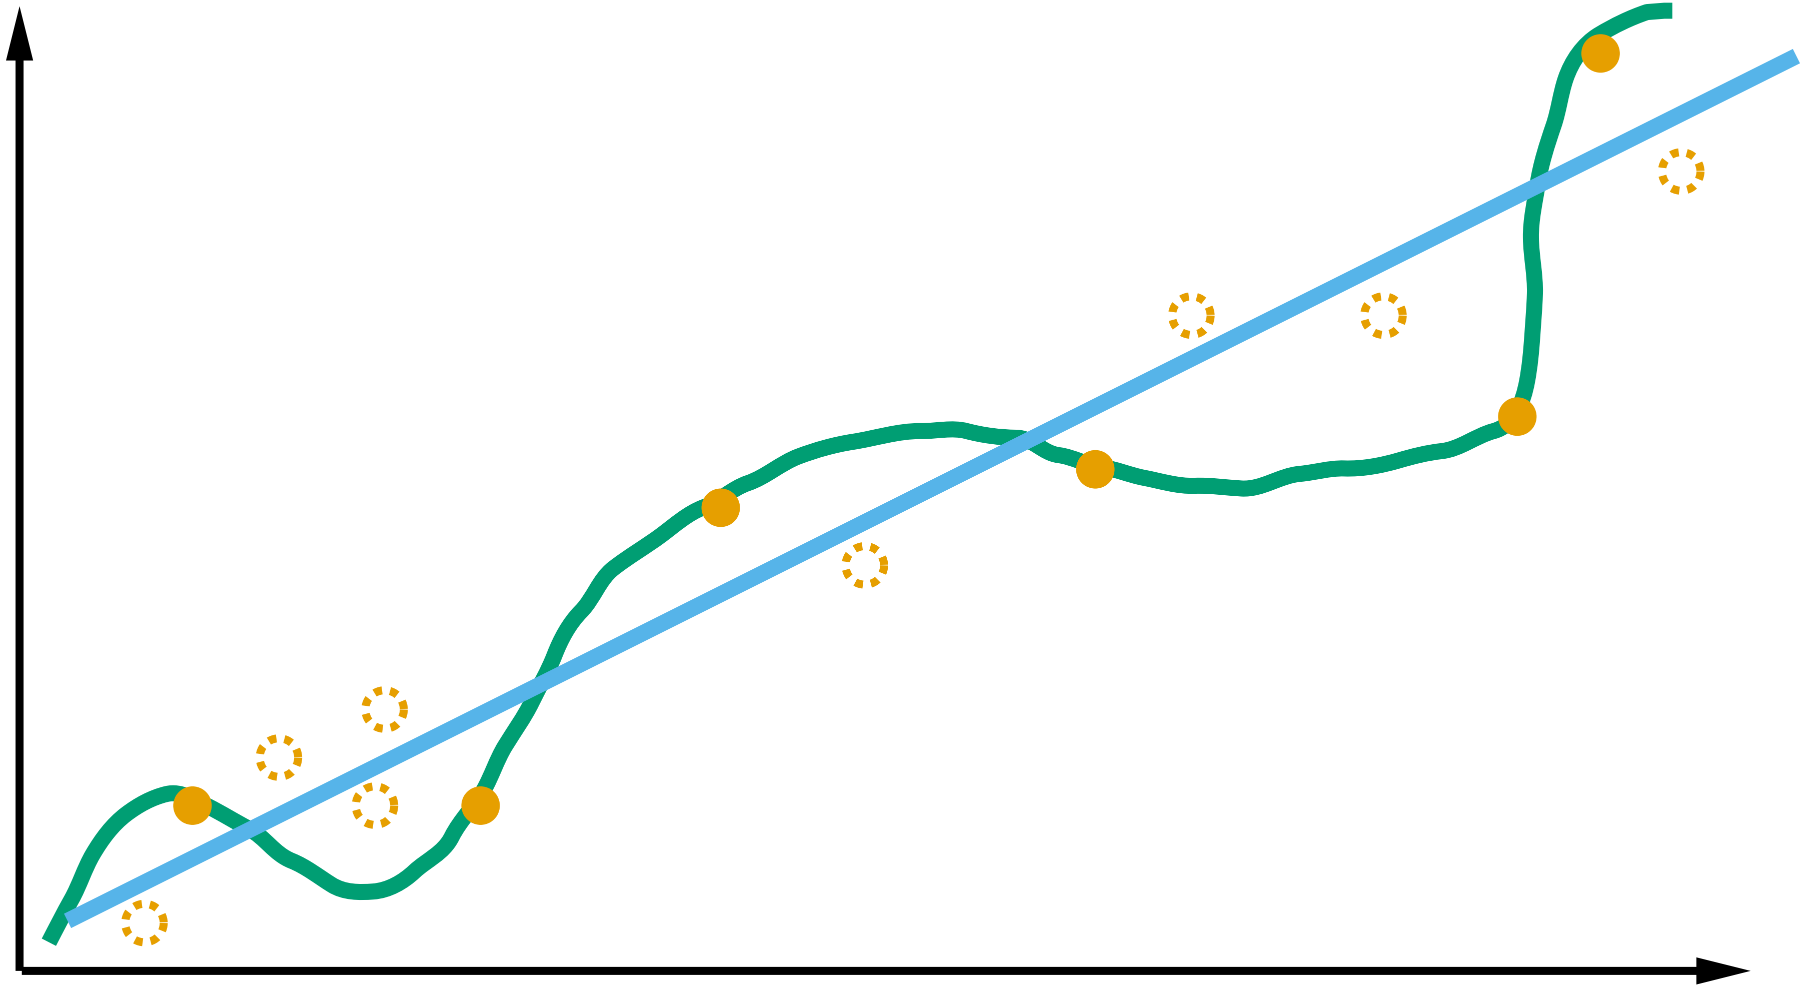

Longueur de description minimale

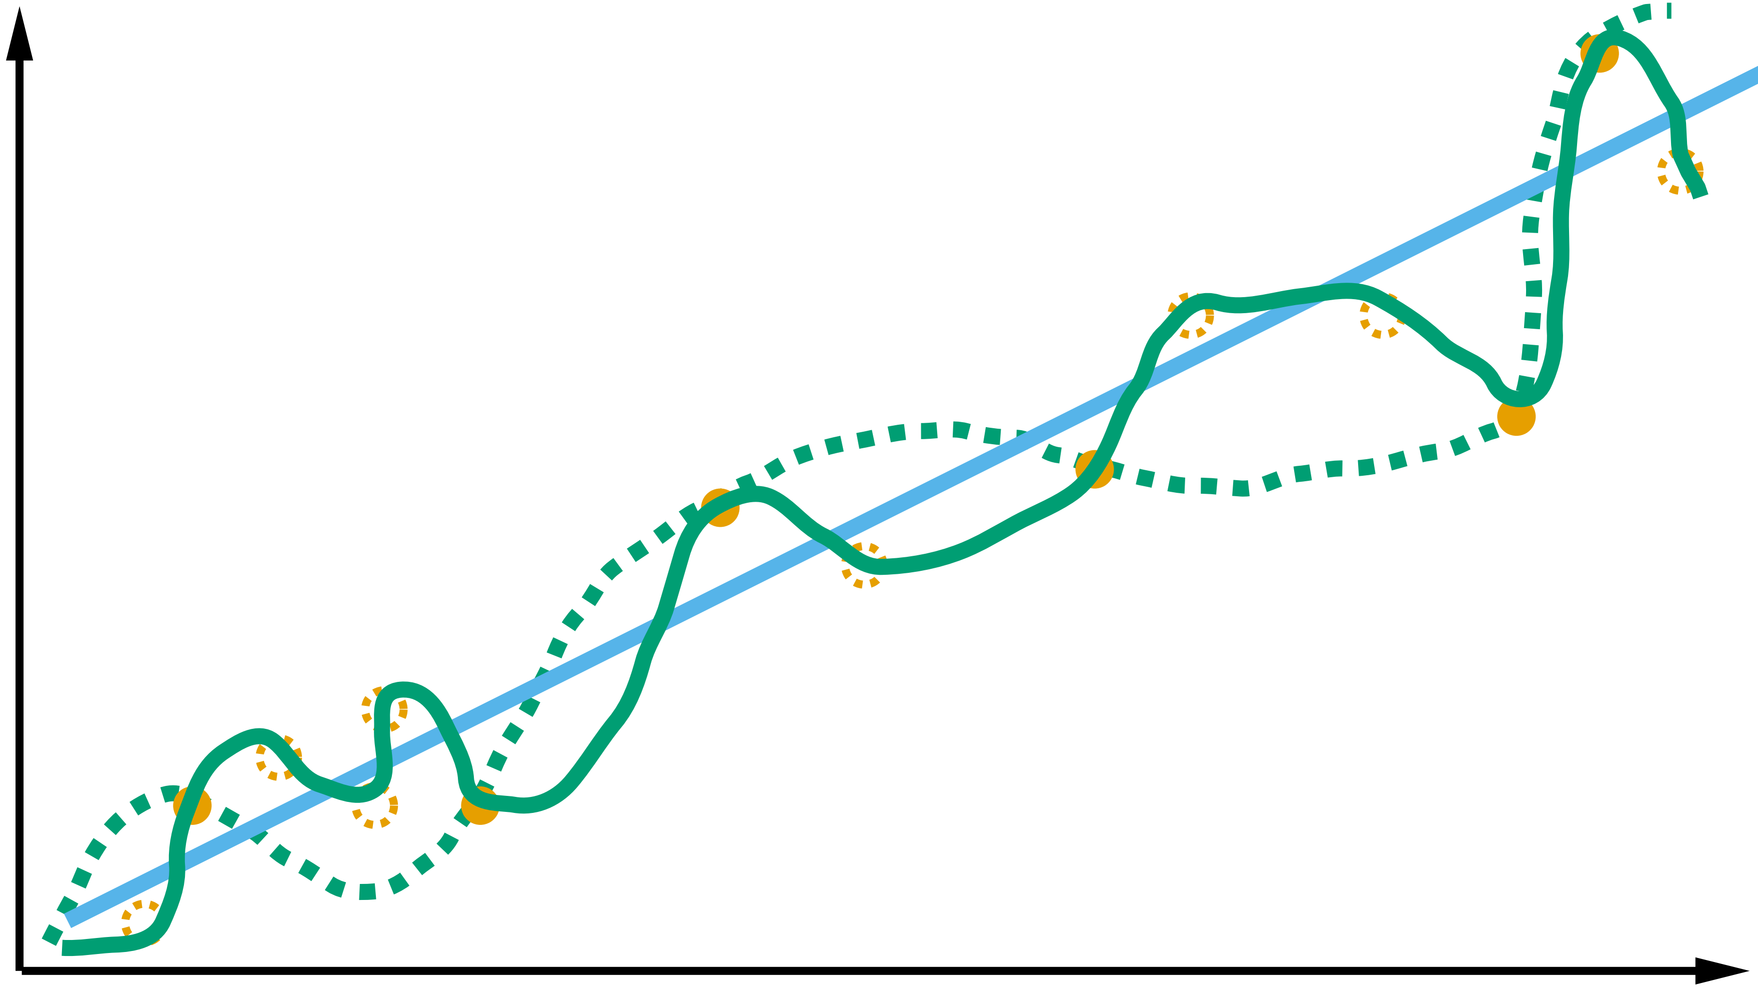

Longueur de description minimale

- Un modèle doit compresser les observations disponibles
- La taille du modèle doit être prise en compte dans la compression

$$K(\text{observations}) \leq K(\text{modele}) + K(\text{observations}|\text{modele})$$

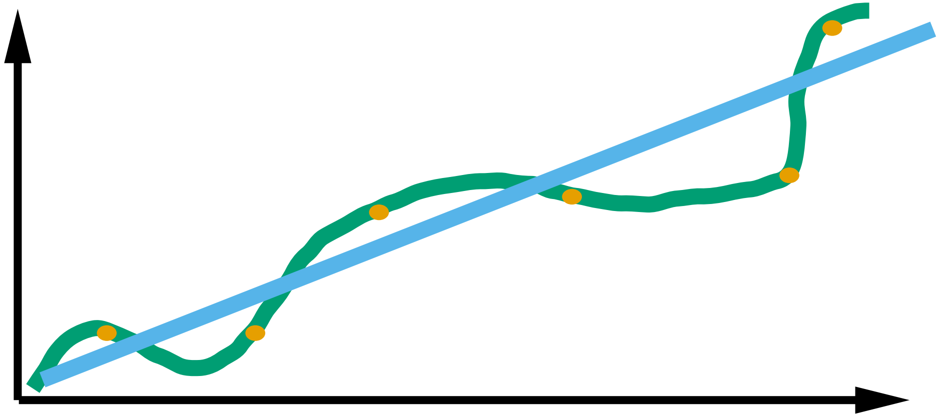

$$y = ax + b \qquad \log(\sum \text{erreurs})$$

$$y = \sum_k a_k x^k \qquad 0$$

Longueur de description minimale

Soit le modèle suivant:

Il y a deux sortes d’individus :

1. Ceux qui se lèvent avant 7h

2. Ceux qui se lèvent après 7h

Ce modèle :

A. Est un premier pas vers la compréhension du role du sommeil

B. Ne sert à rien

Clustering

Clustering

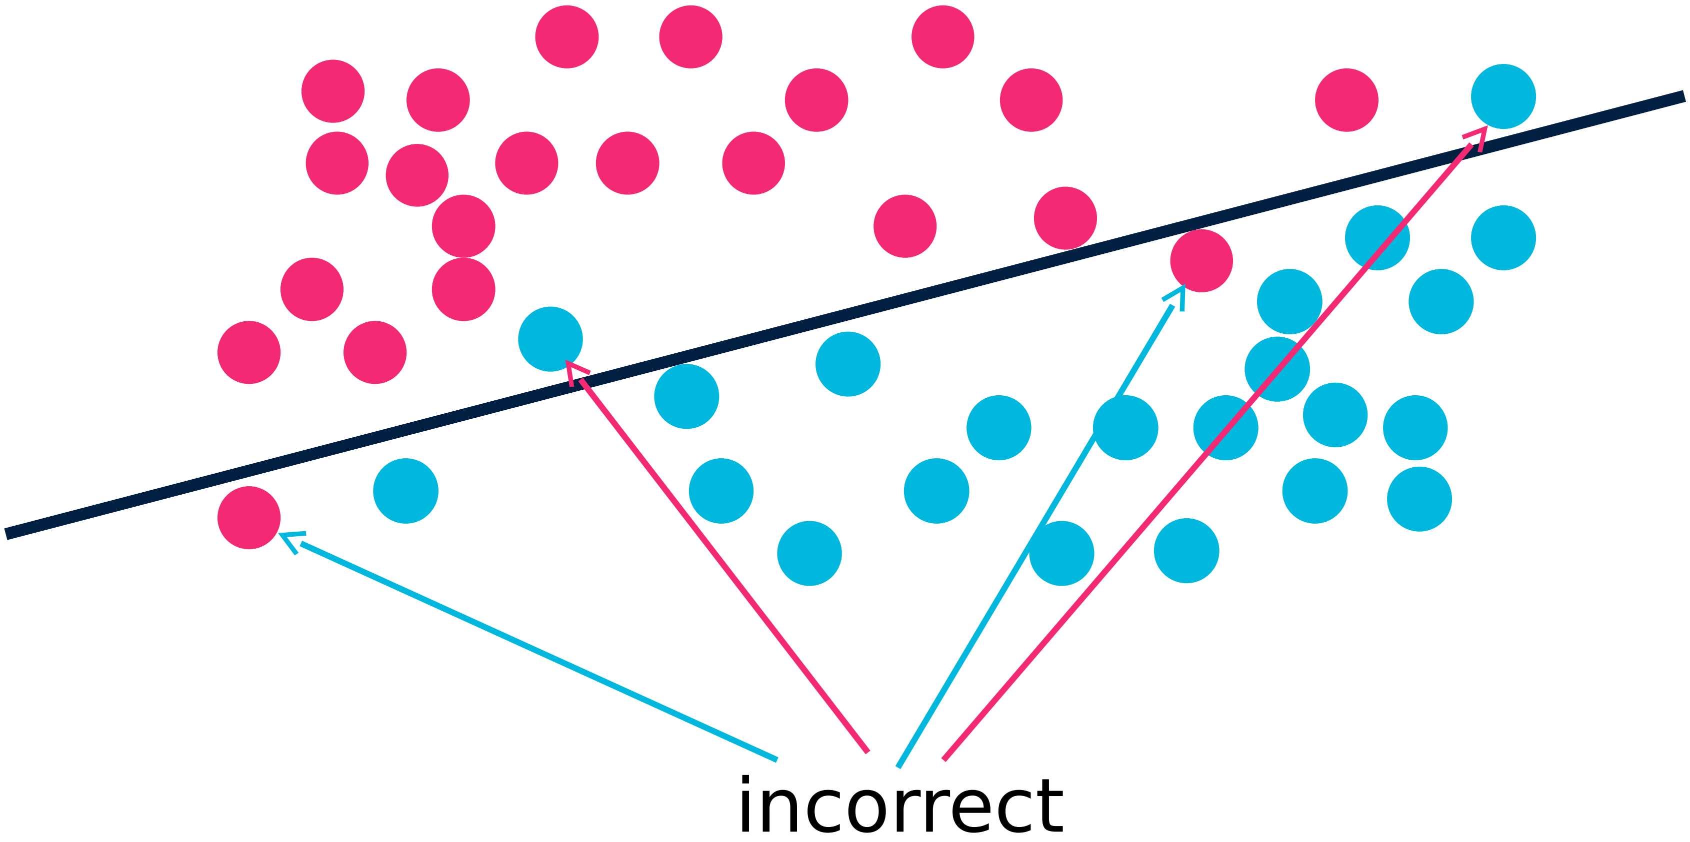

Clustering

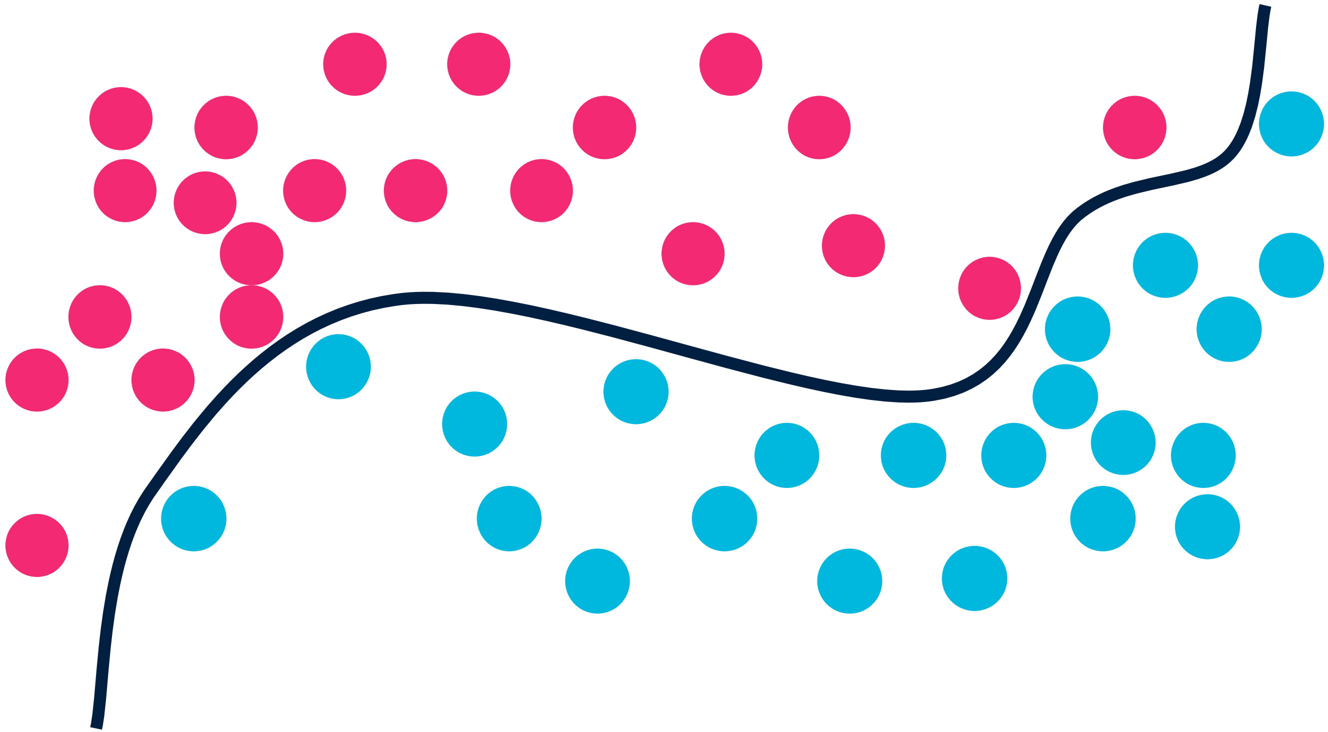

Clustering

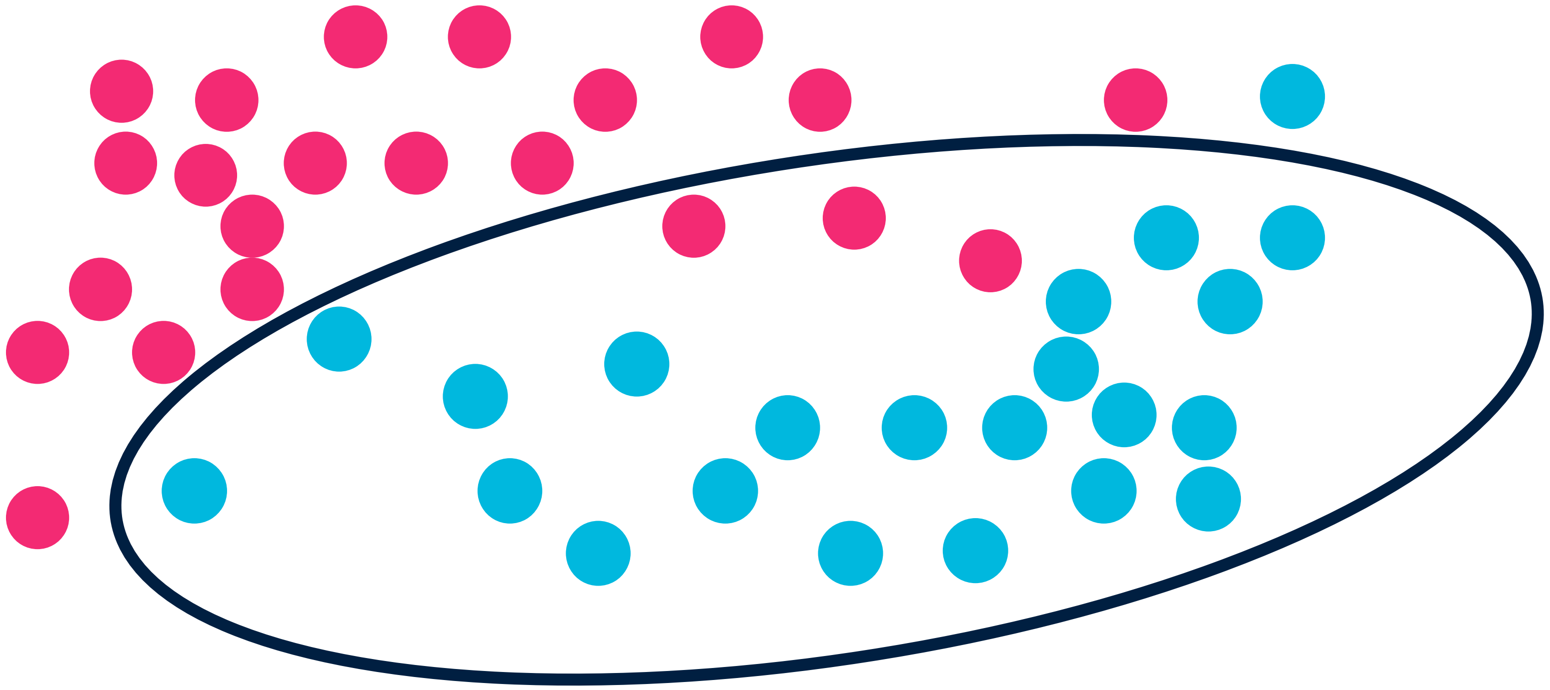

Clustering

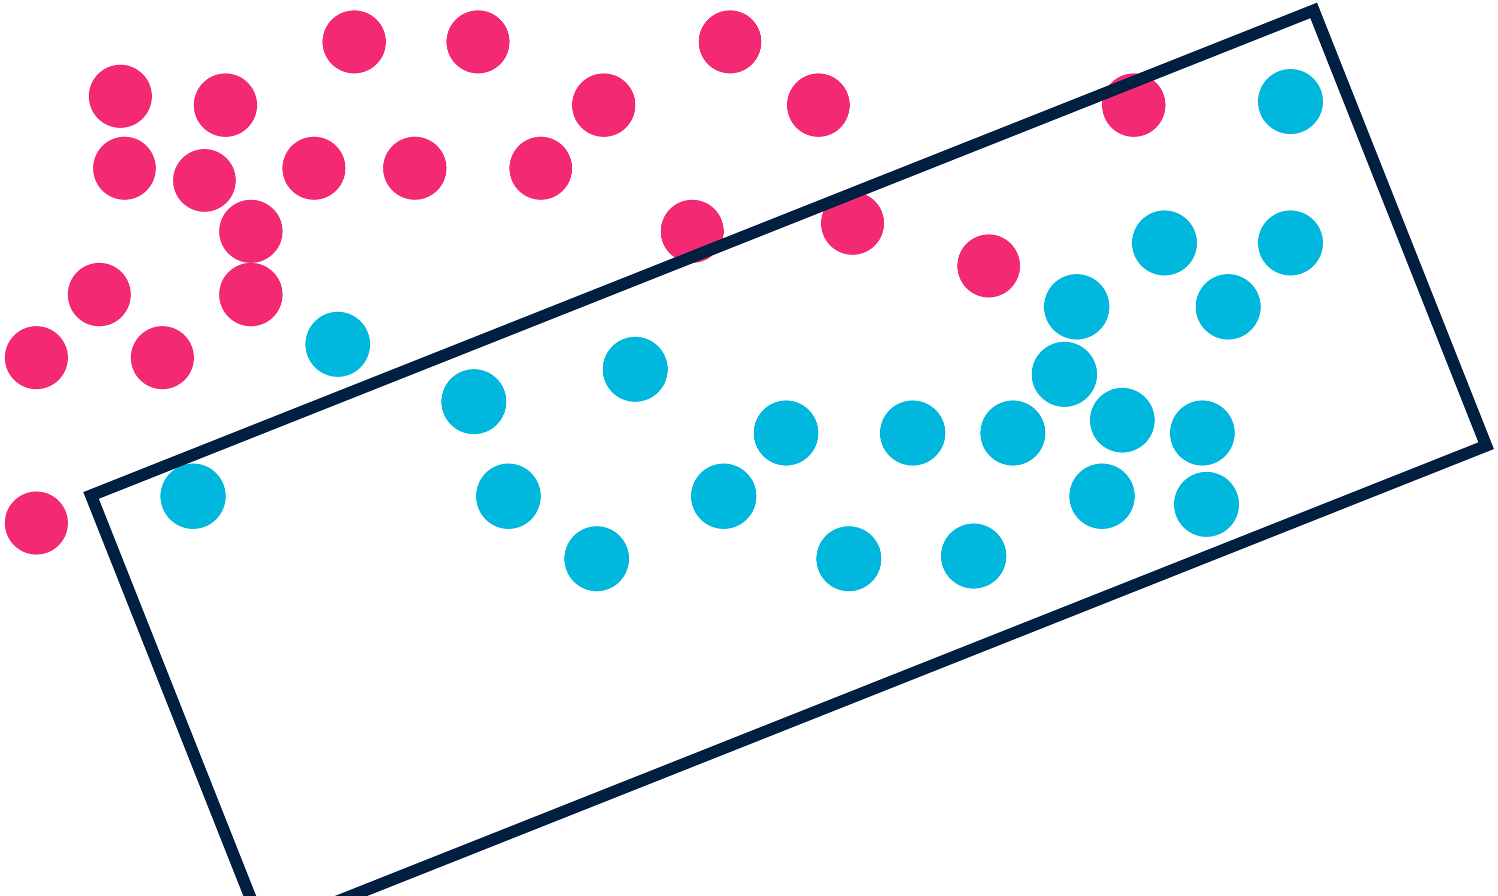

Clustering

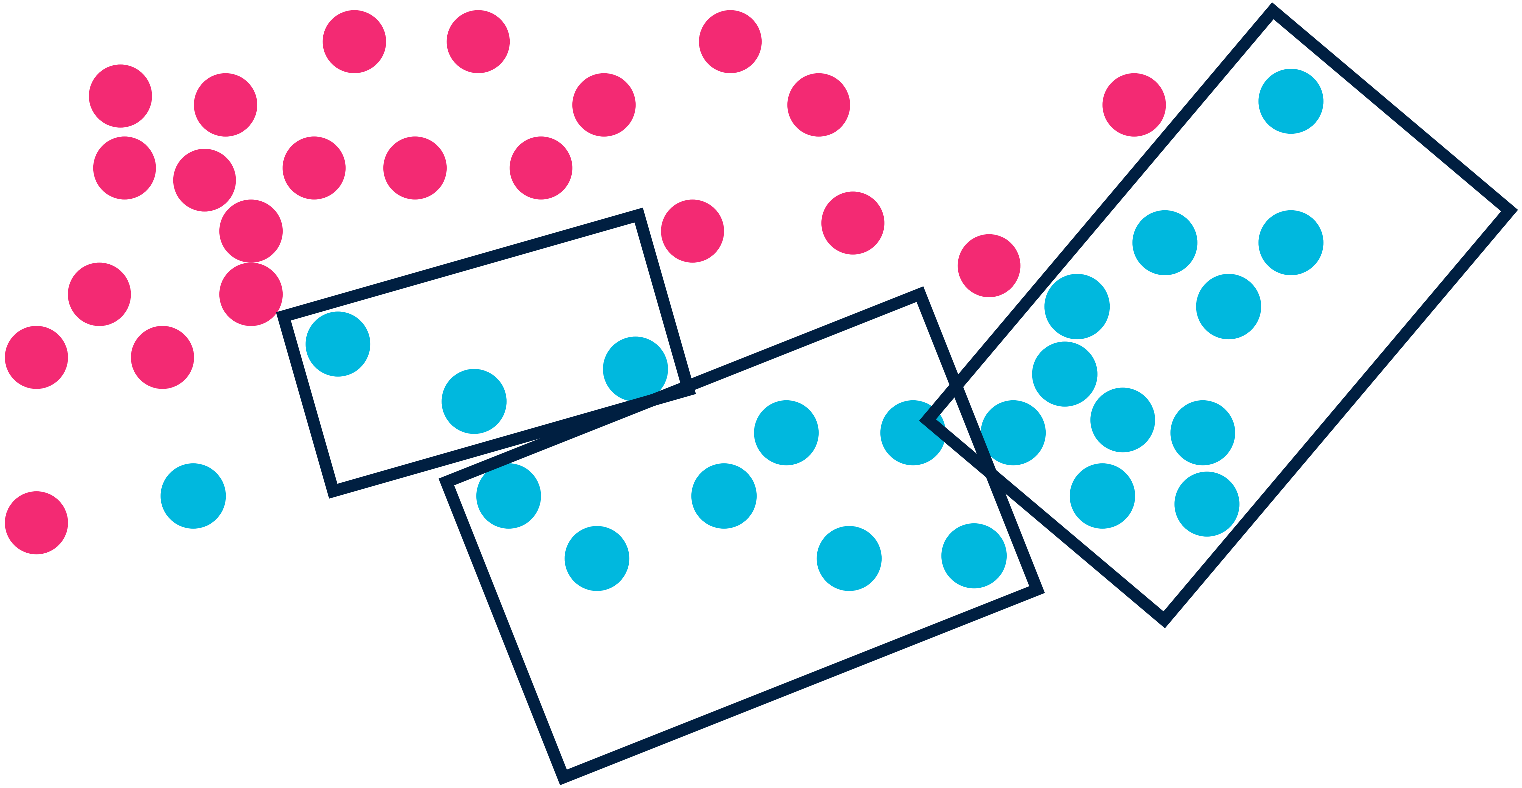

Clustering

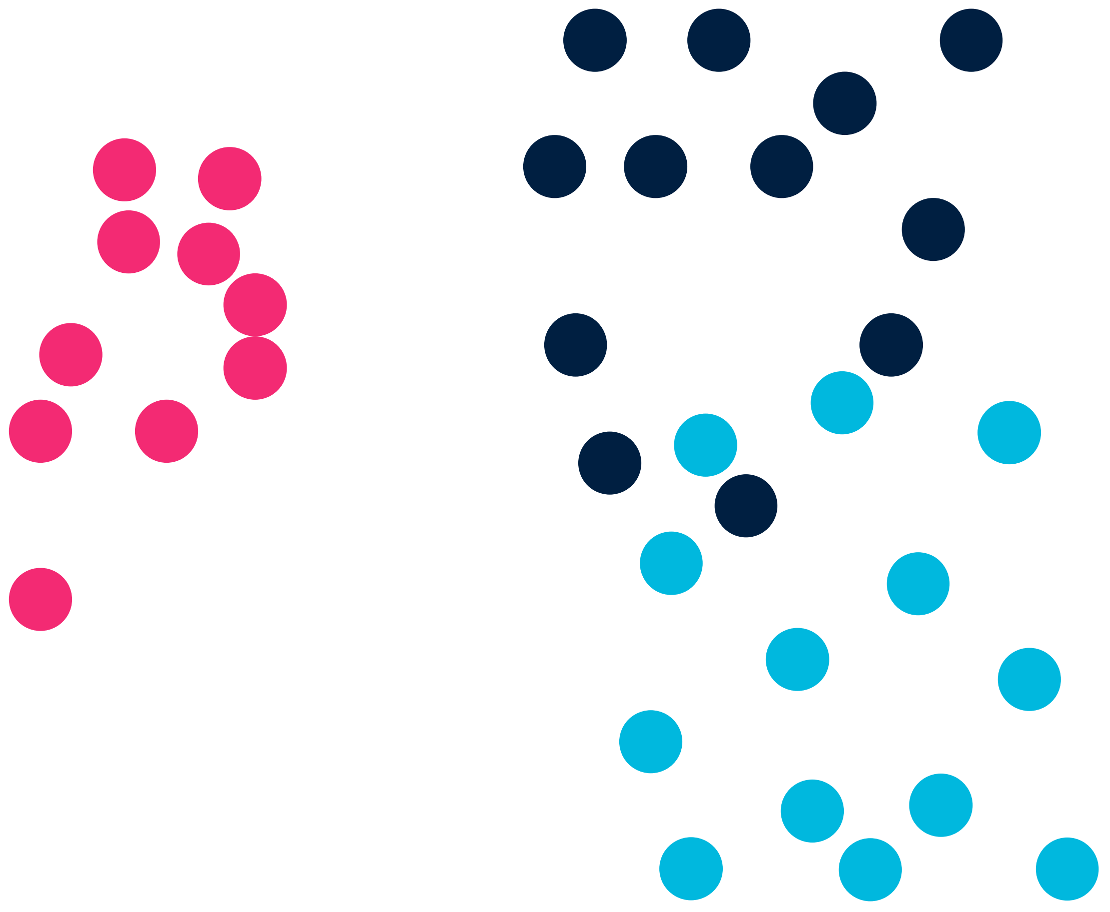

Clustering

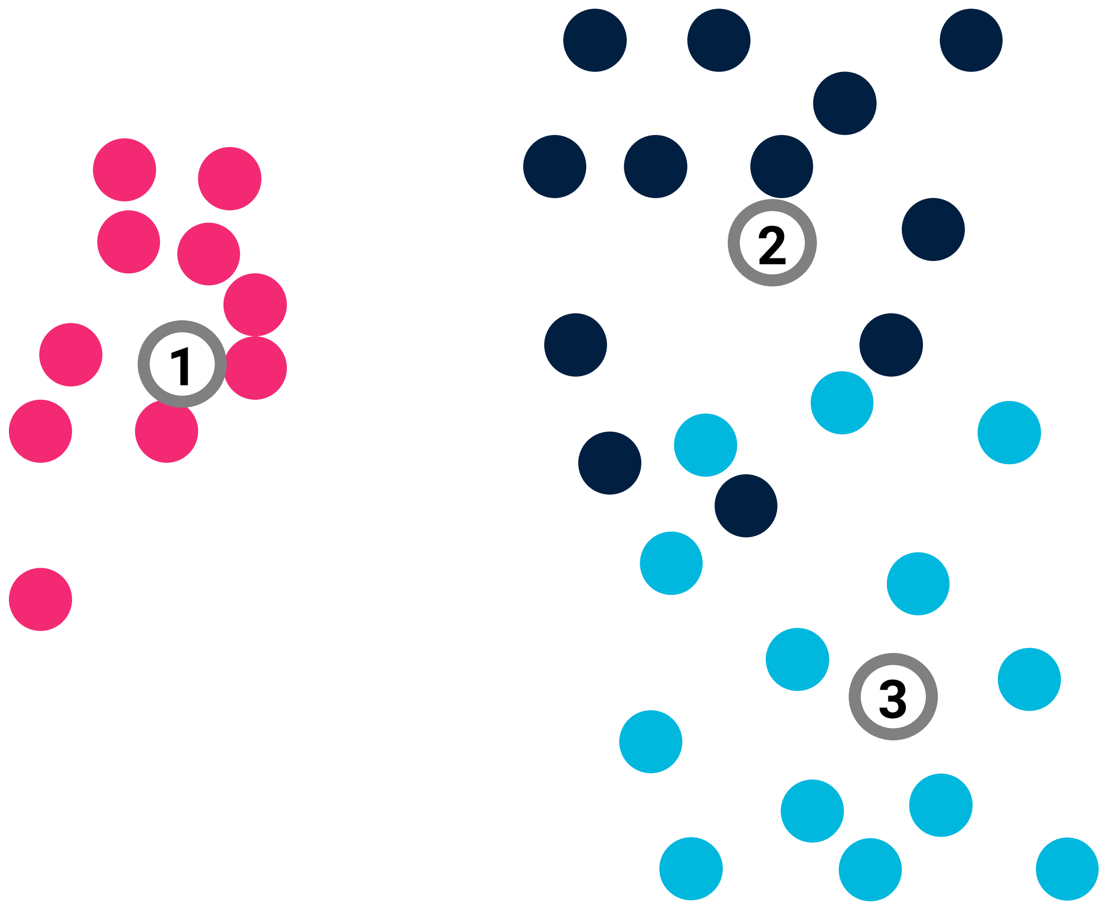

Clustering

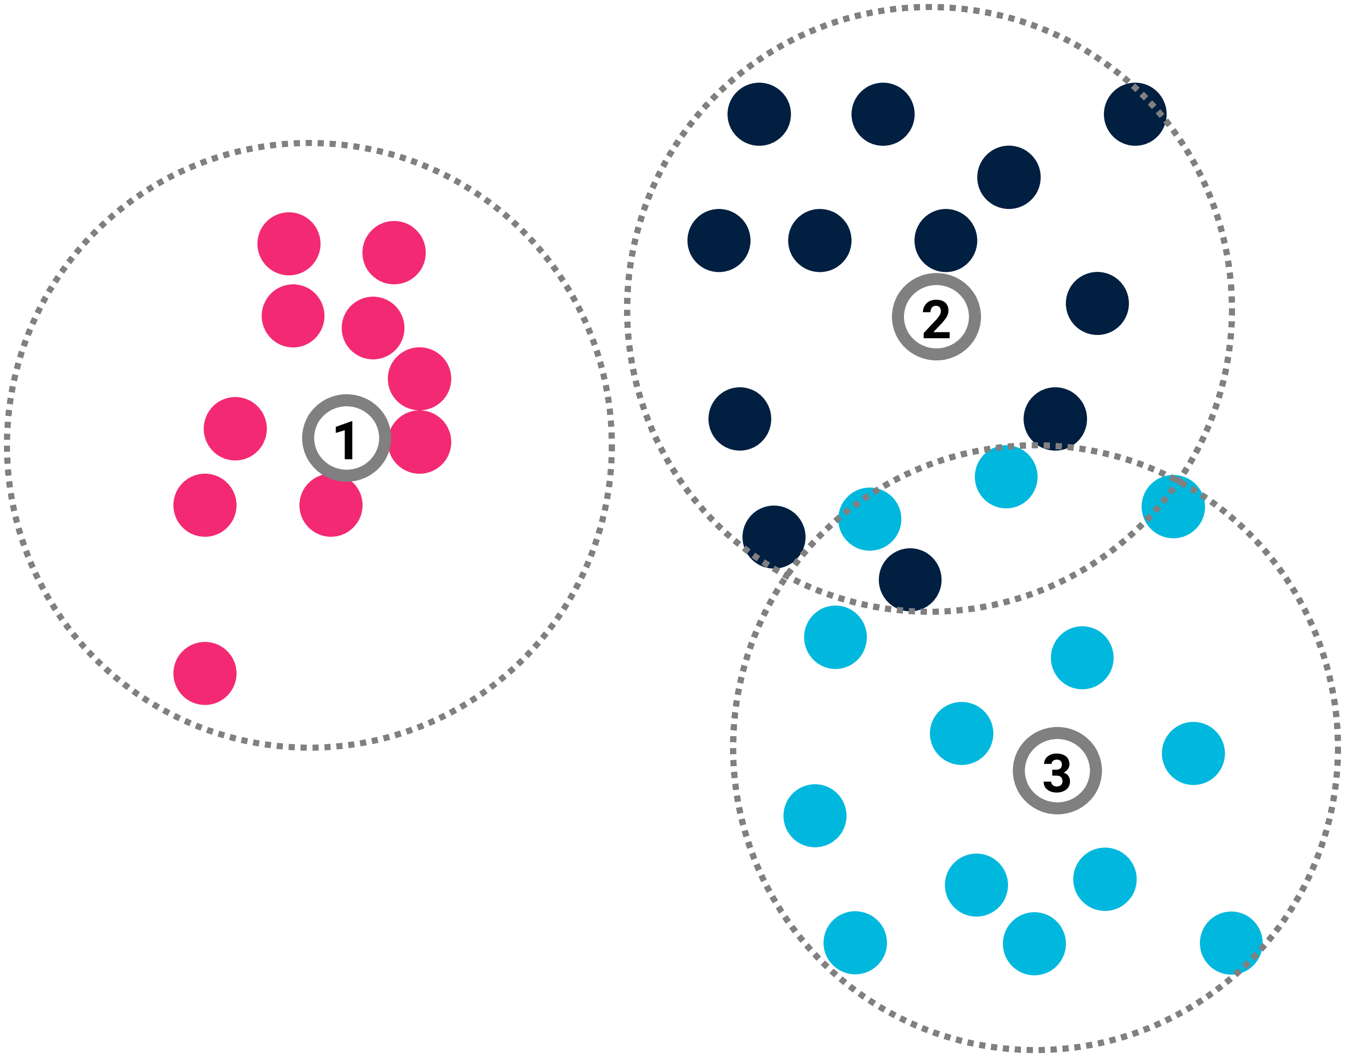

Clustering

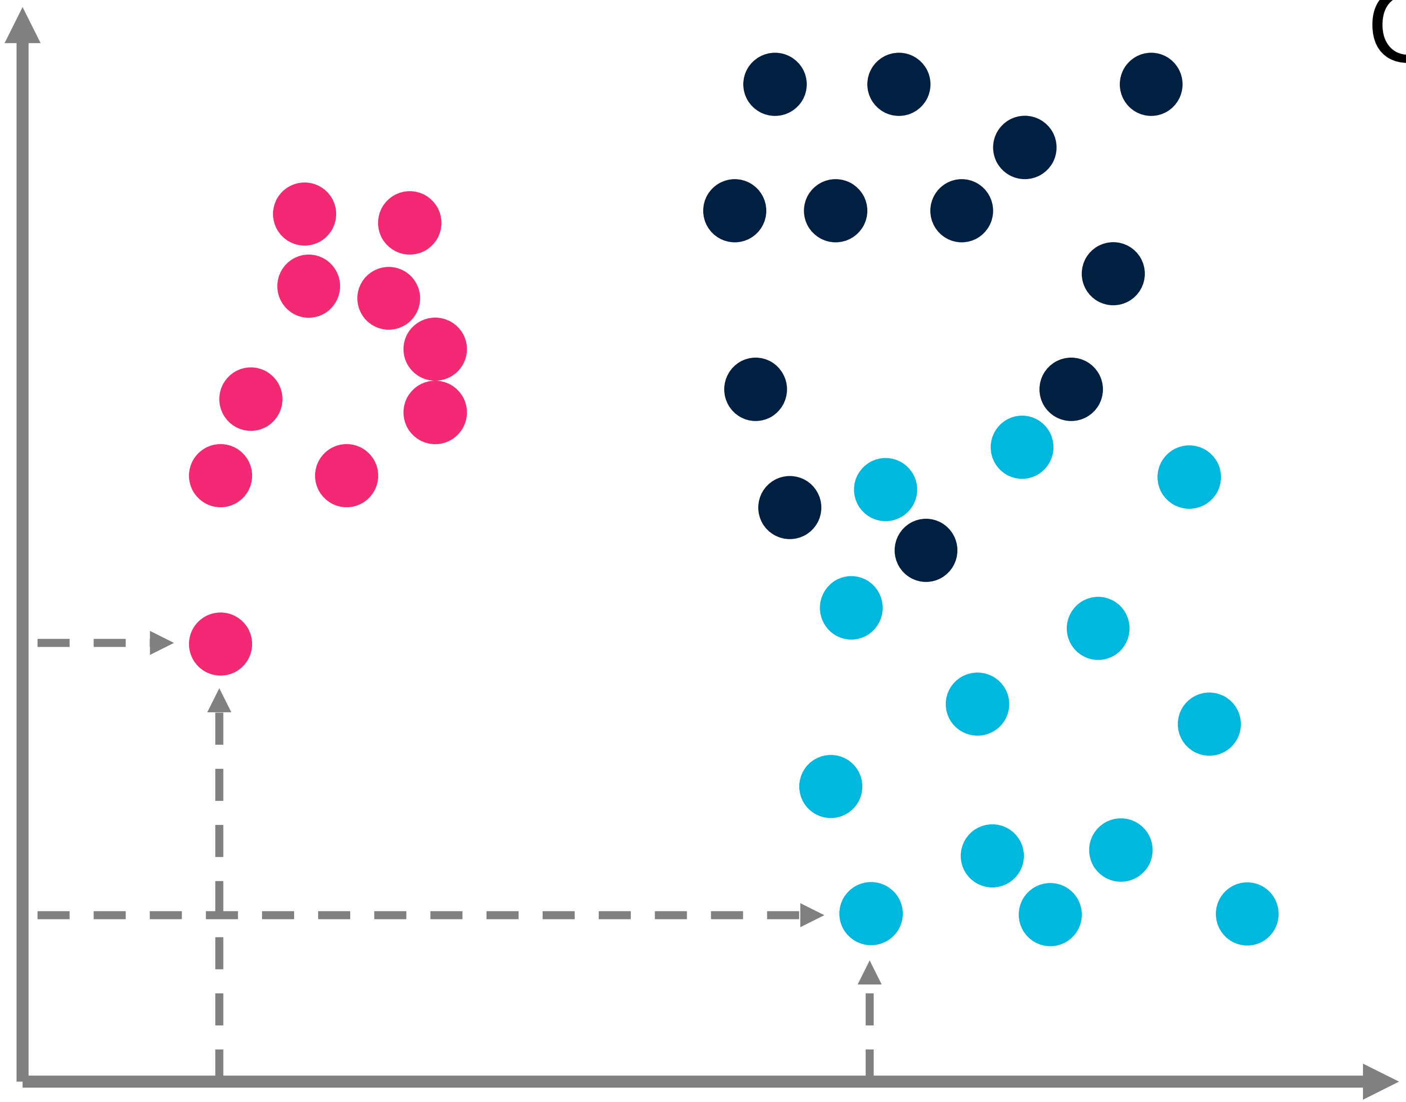

Clustering

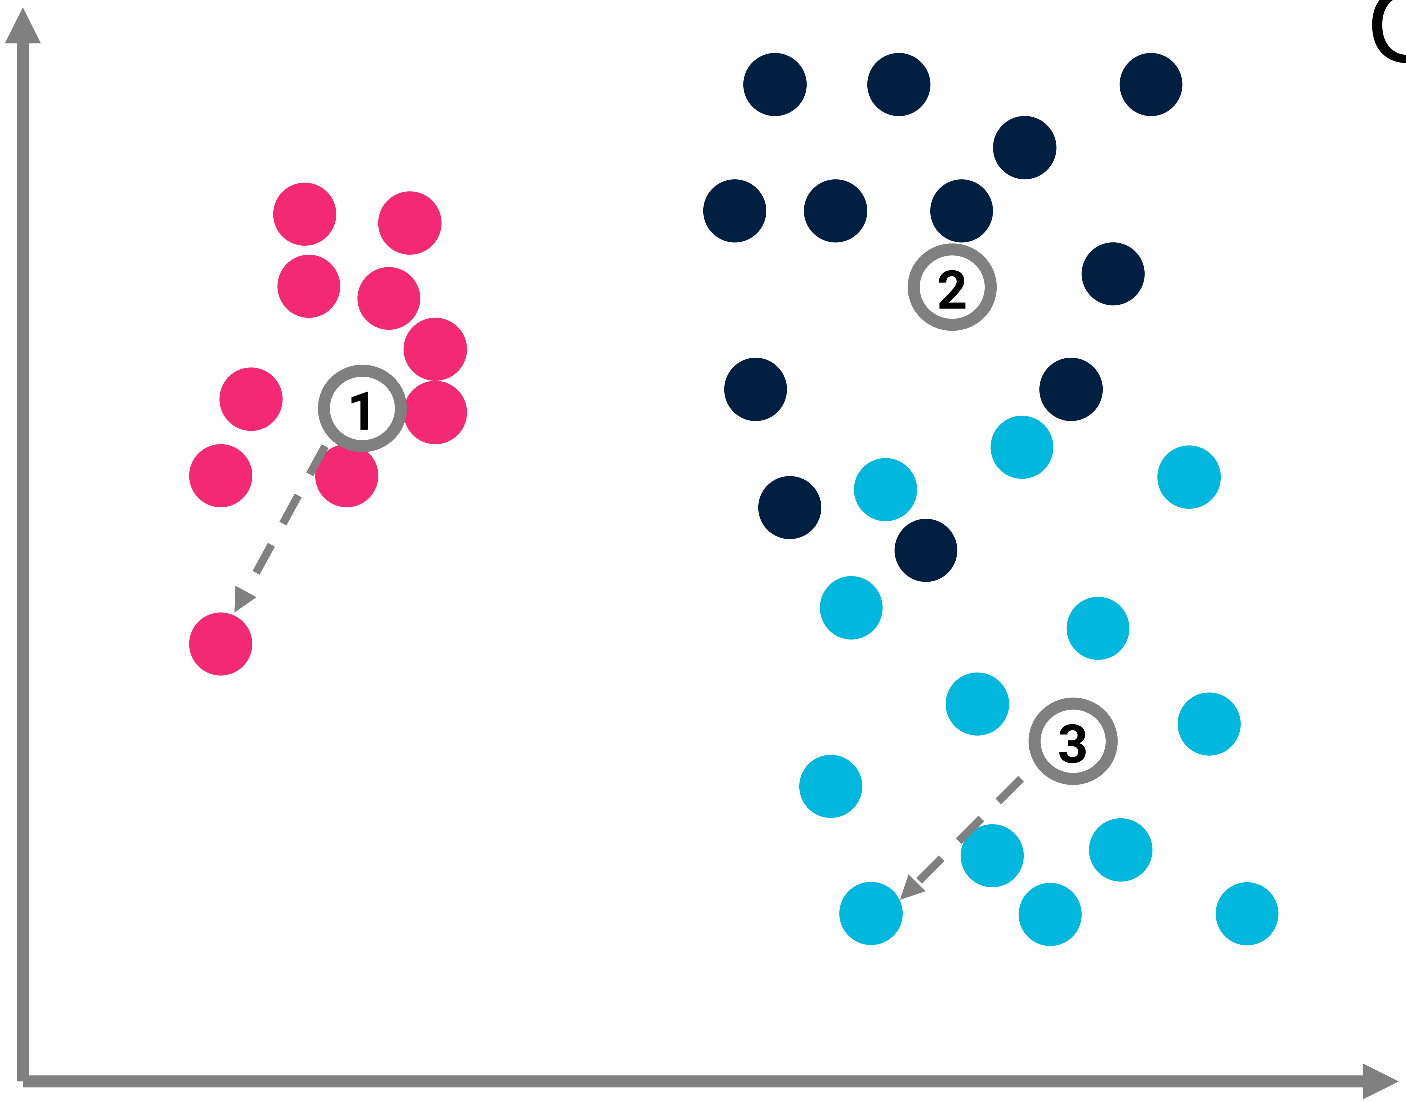

Clustering

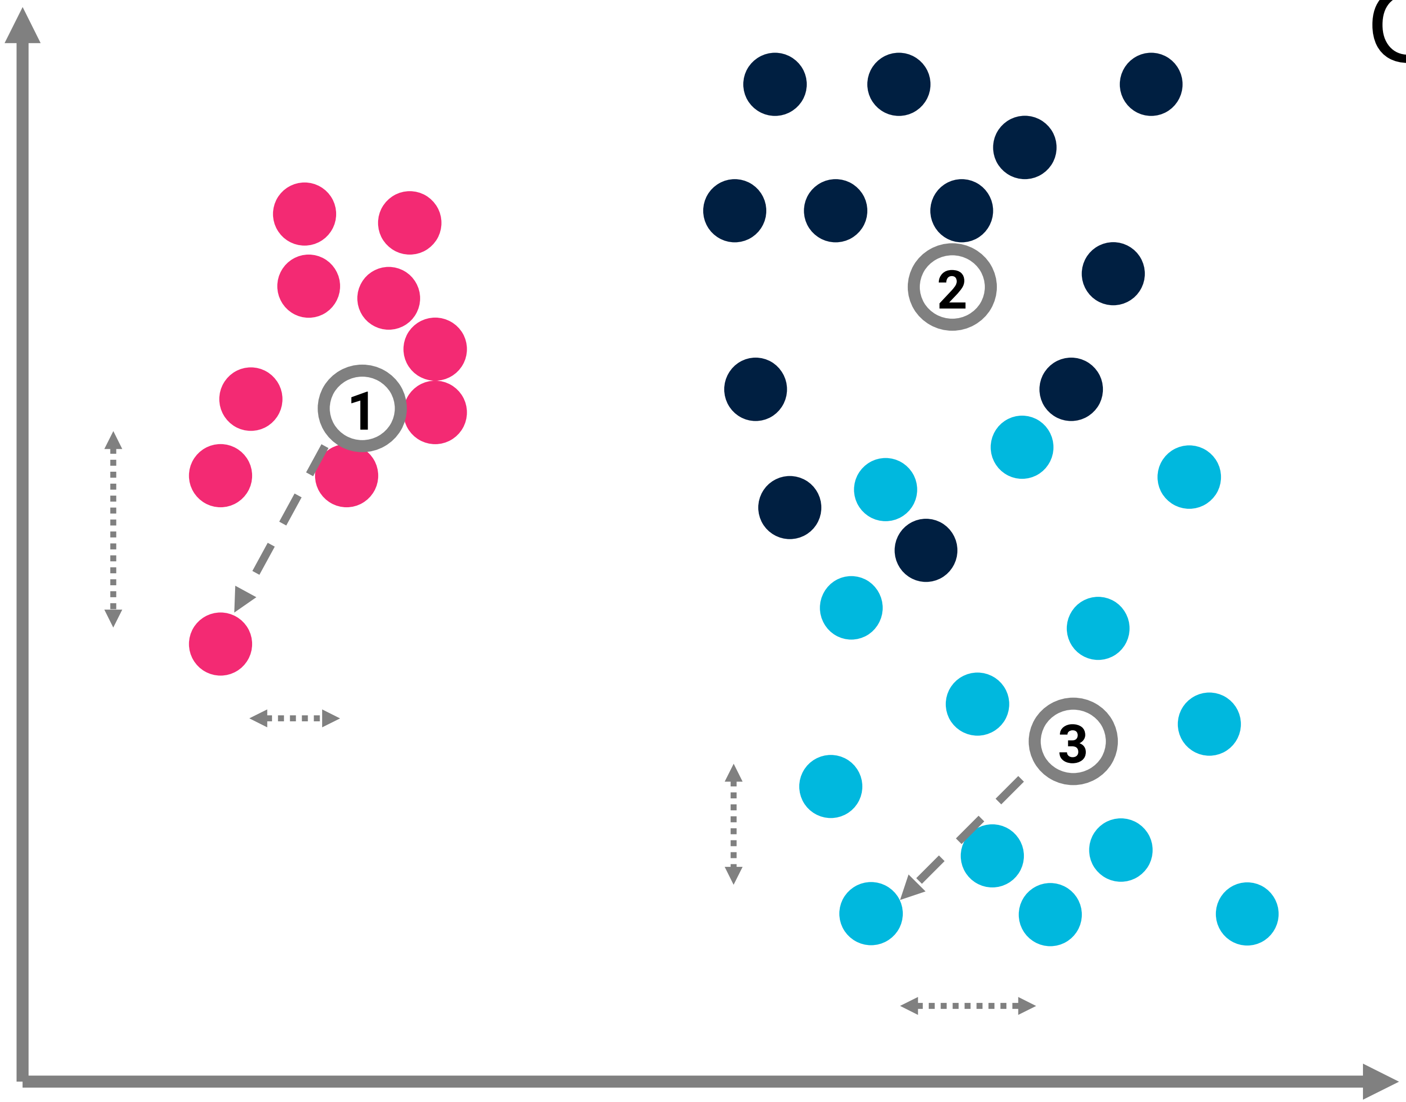

Clustering

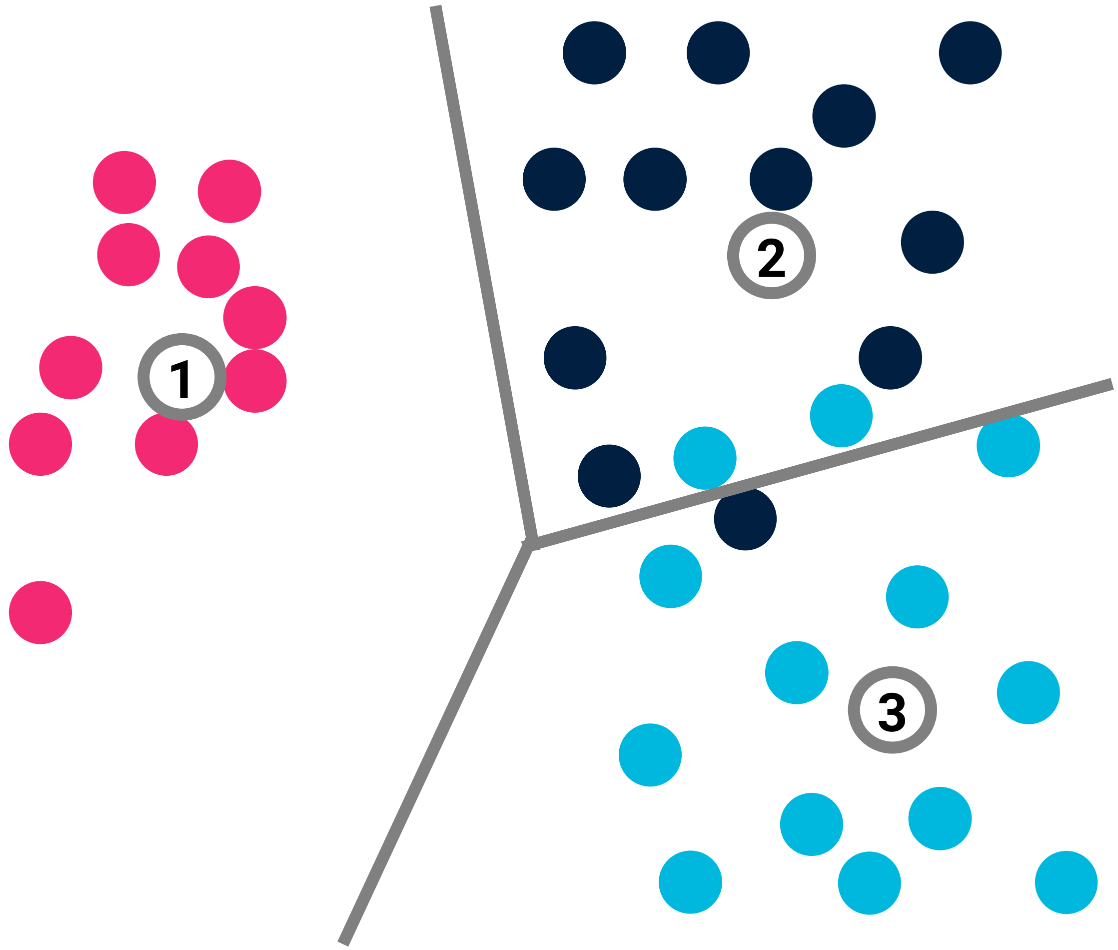

Clustering

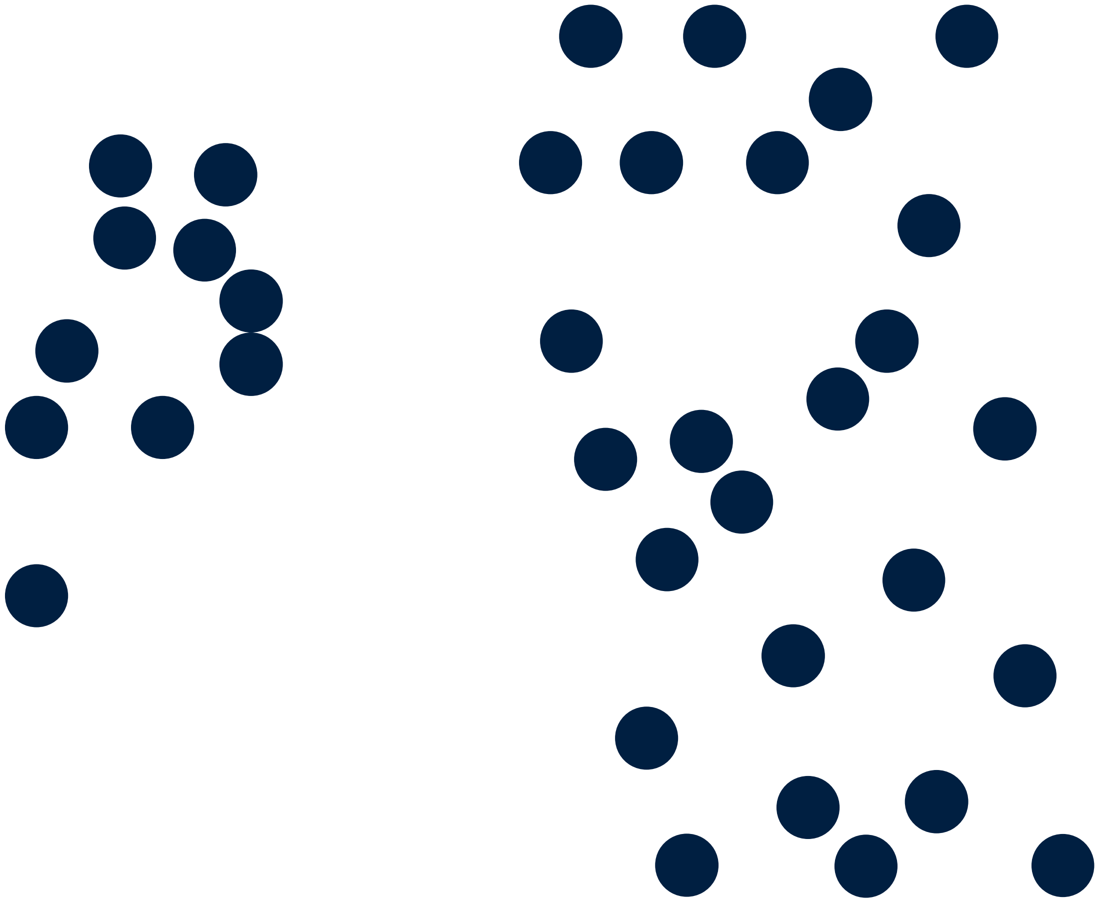

Clustering

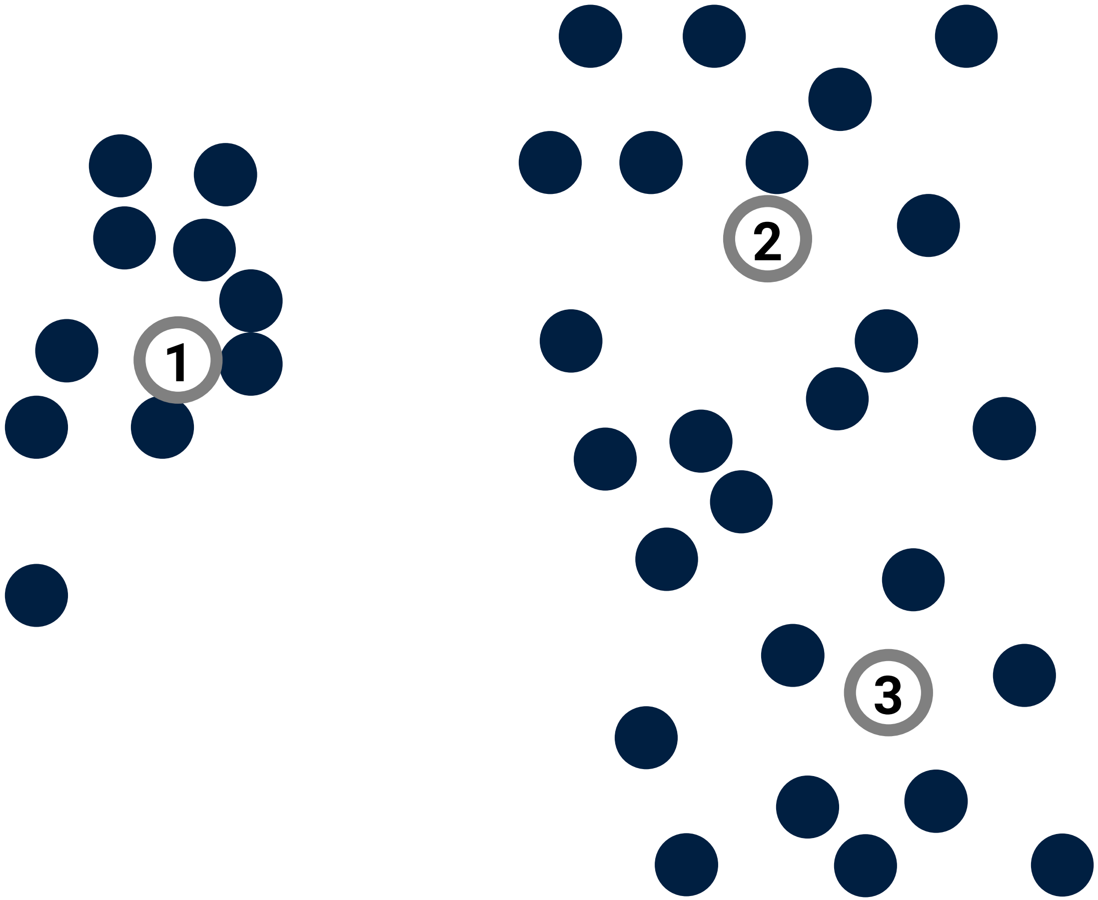

Clustering

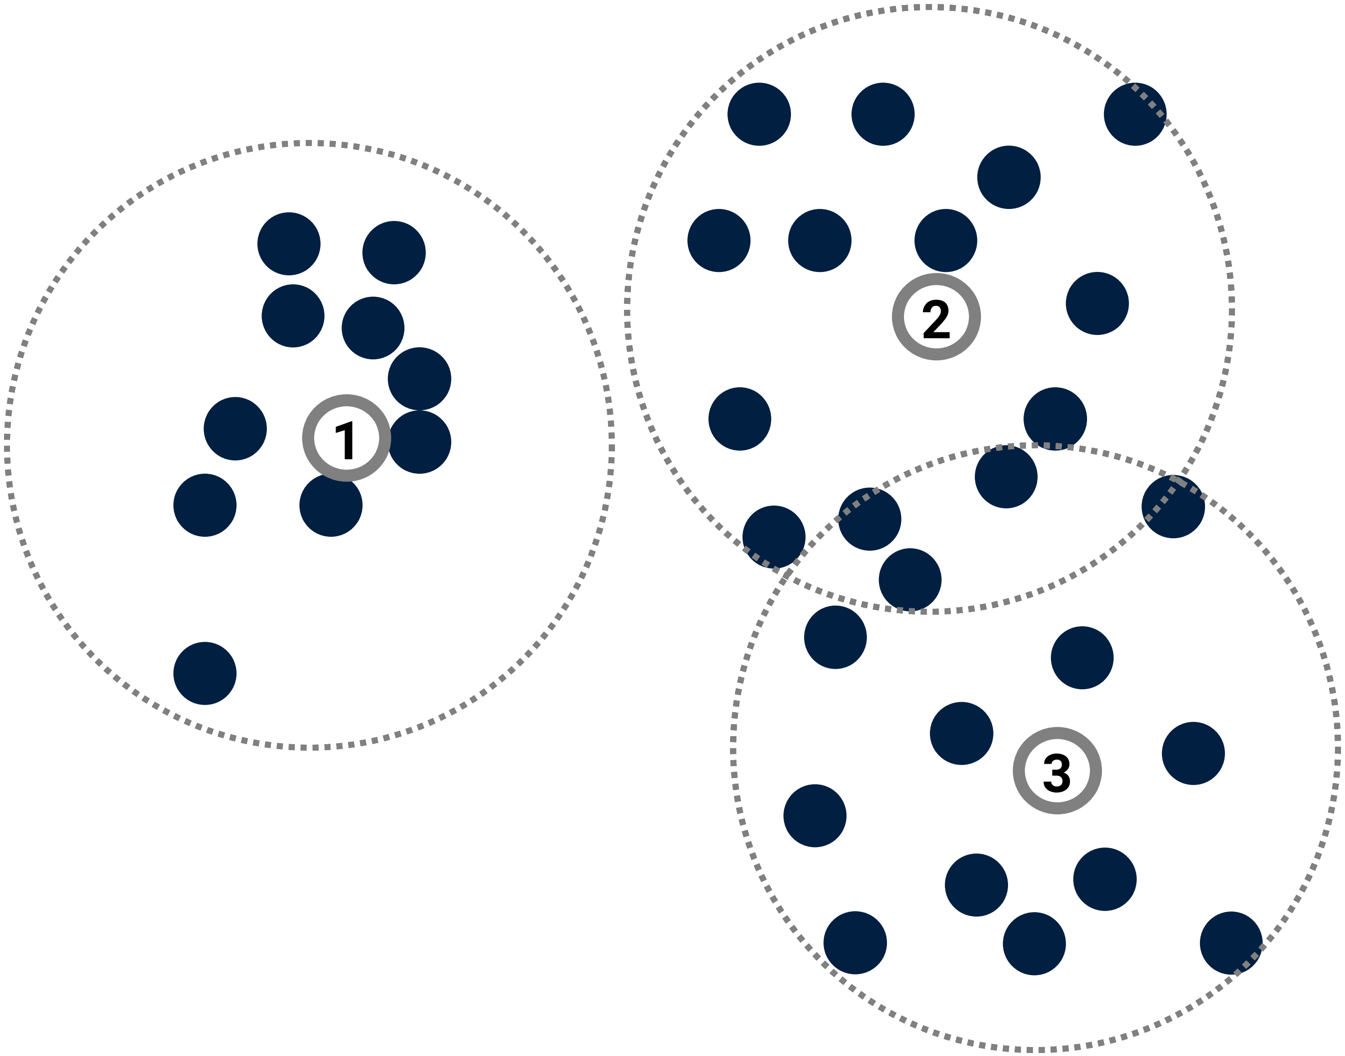

Clustering

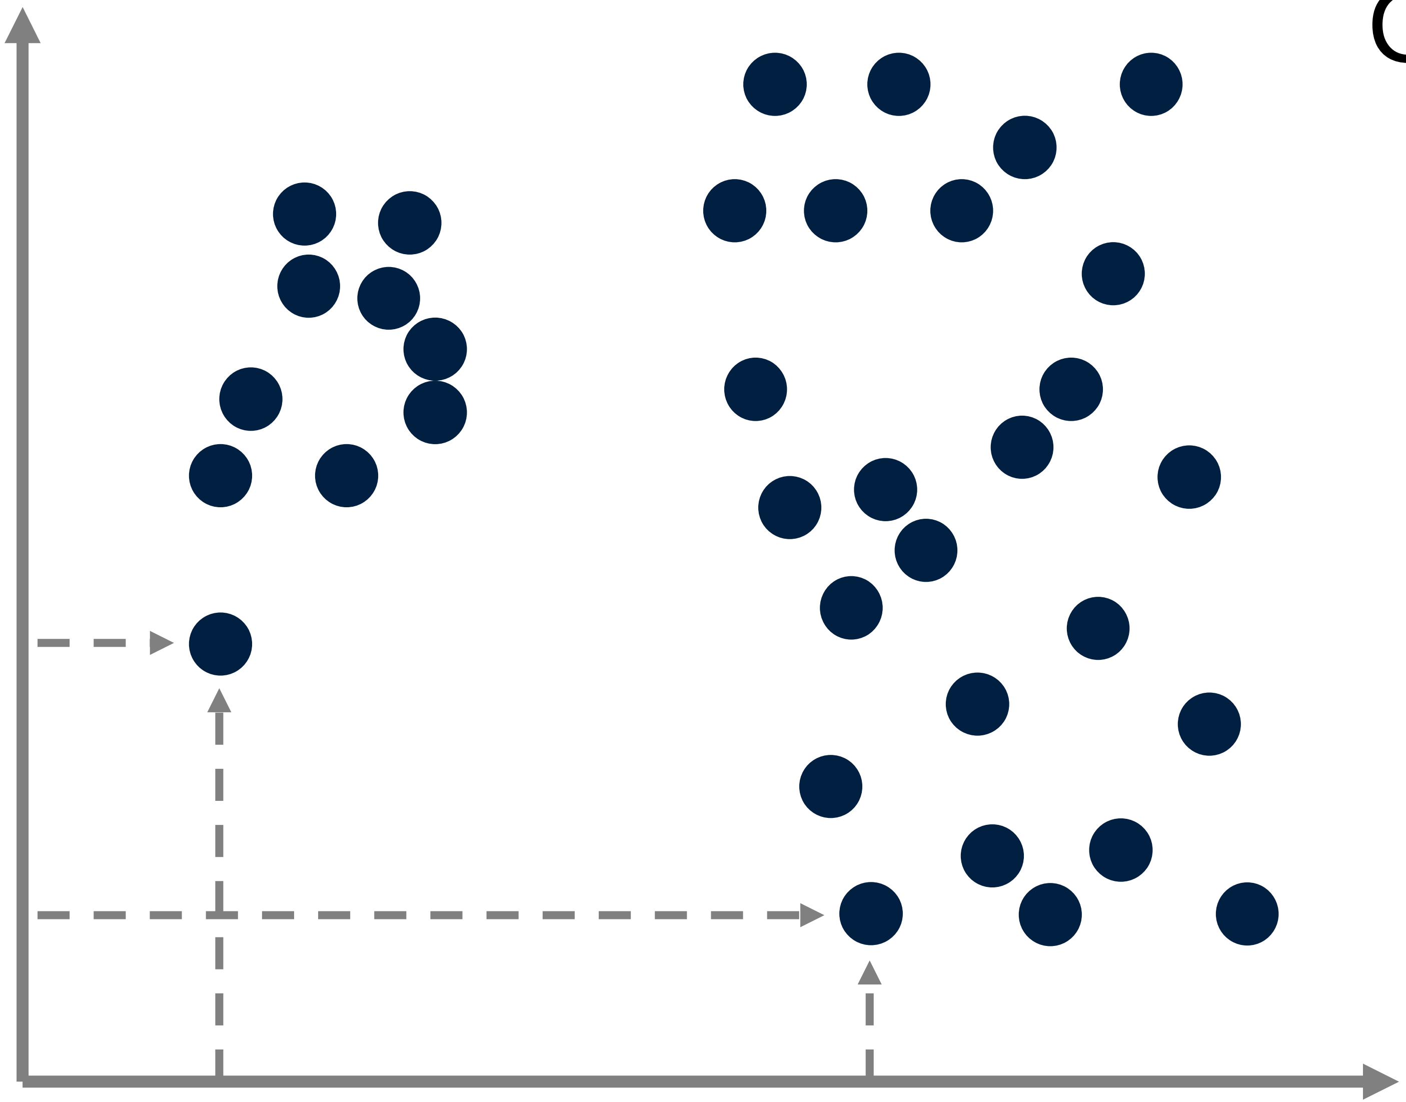

Clustering

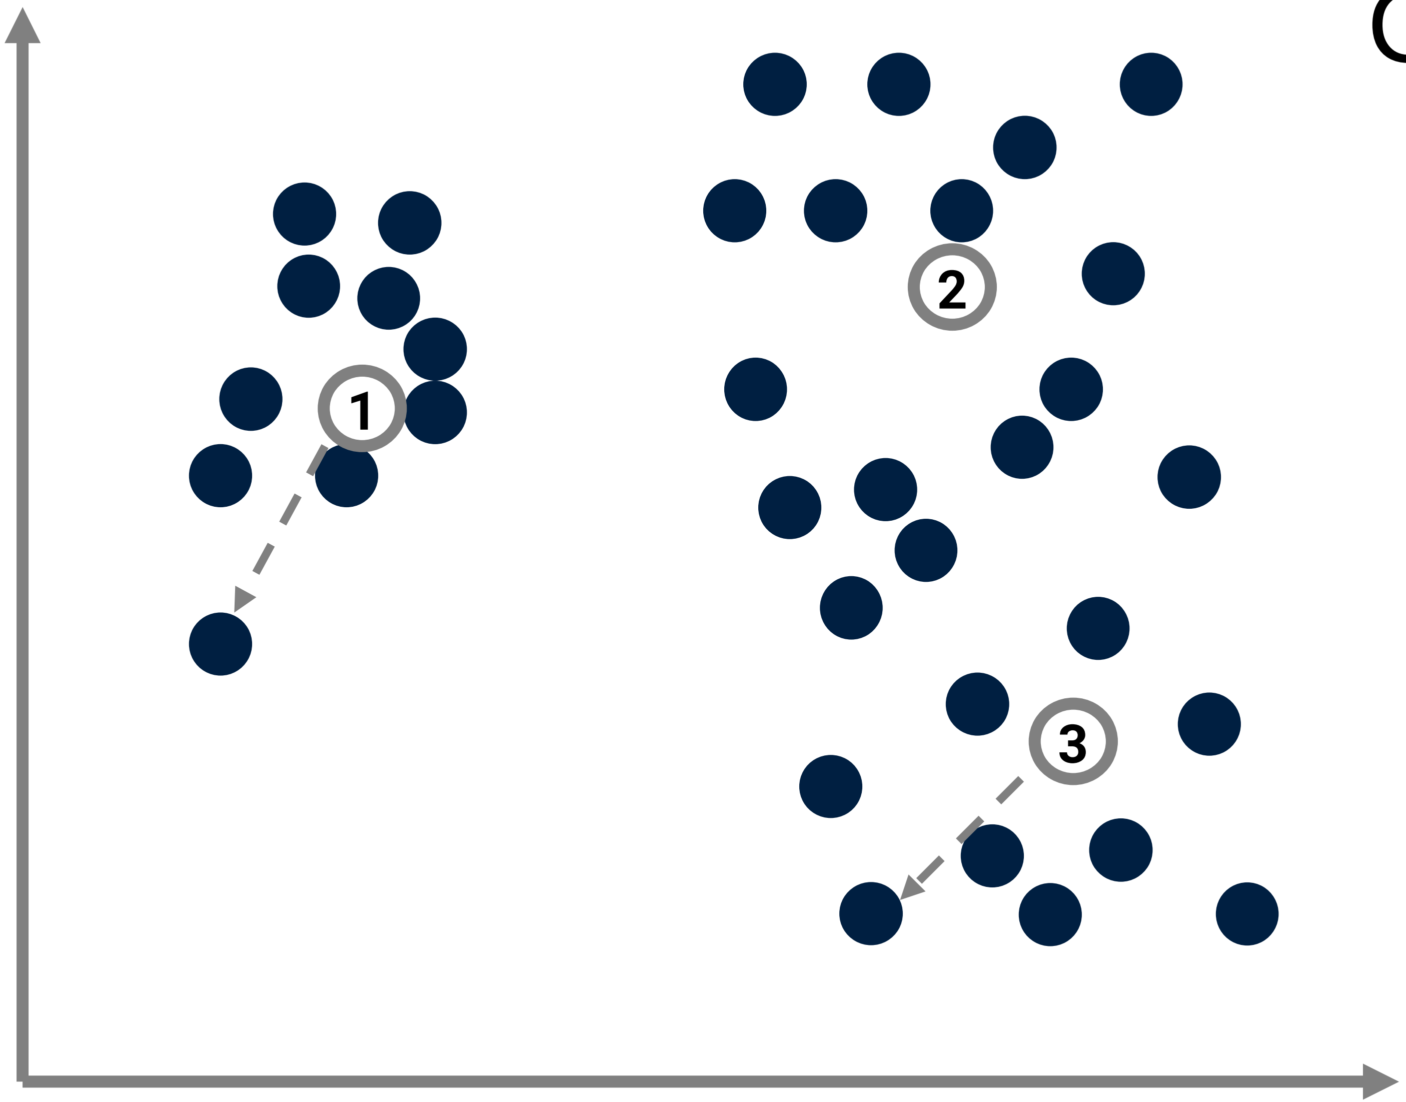

Clustering

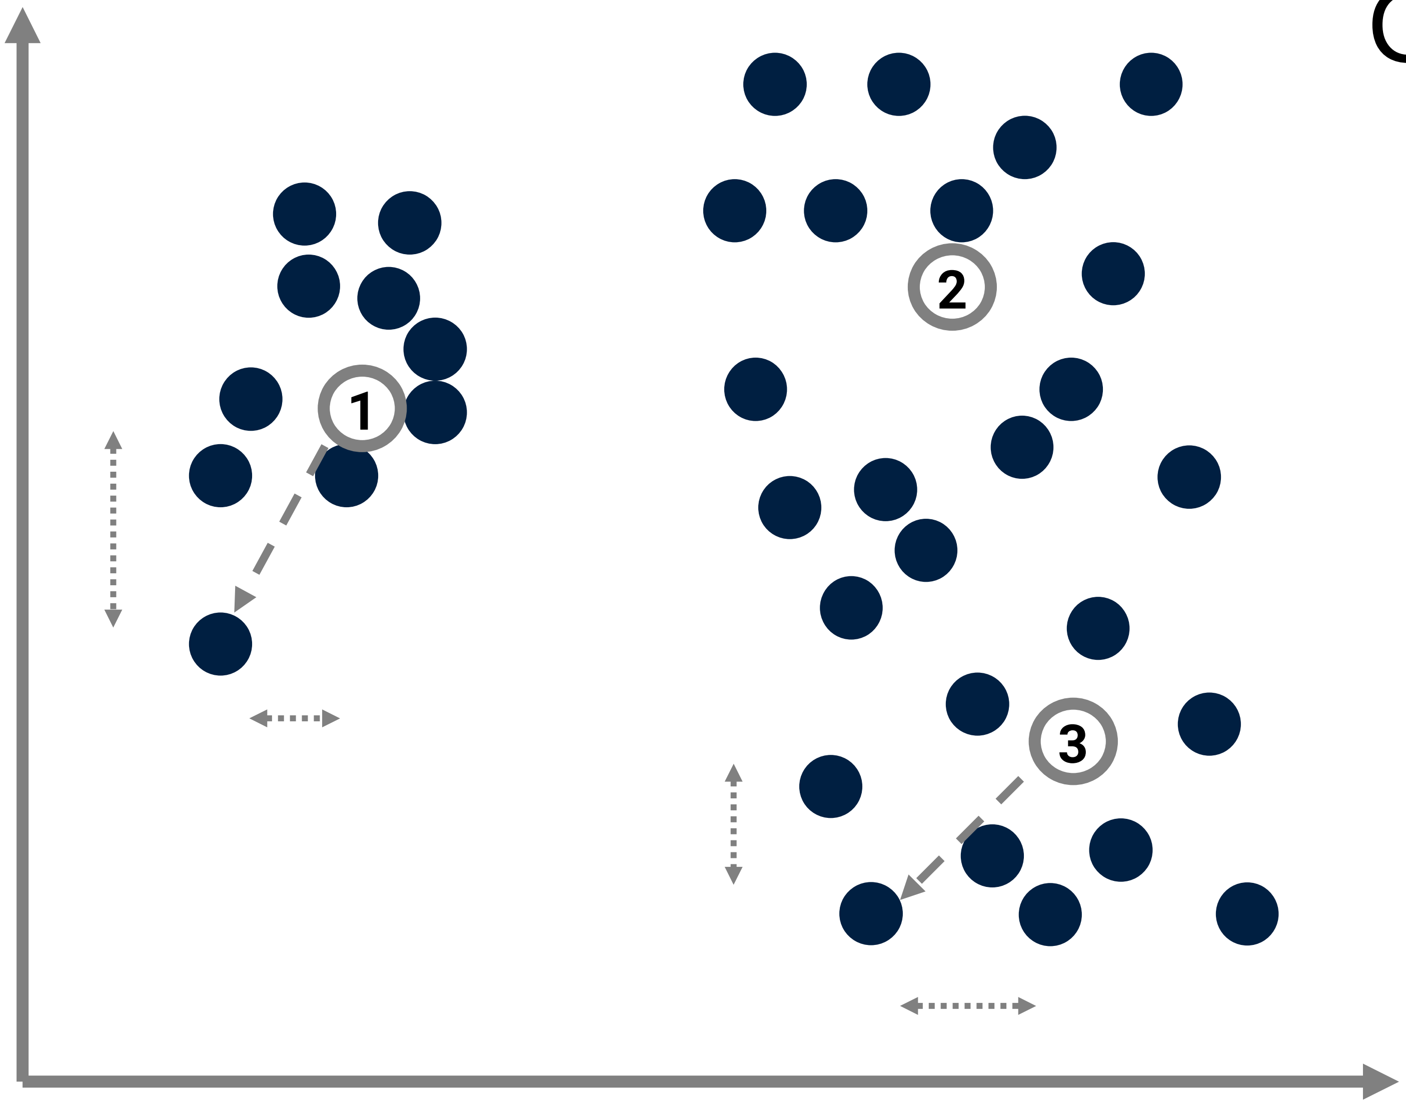

Clustering

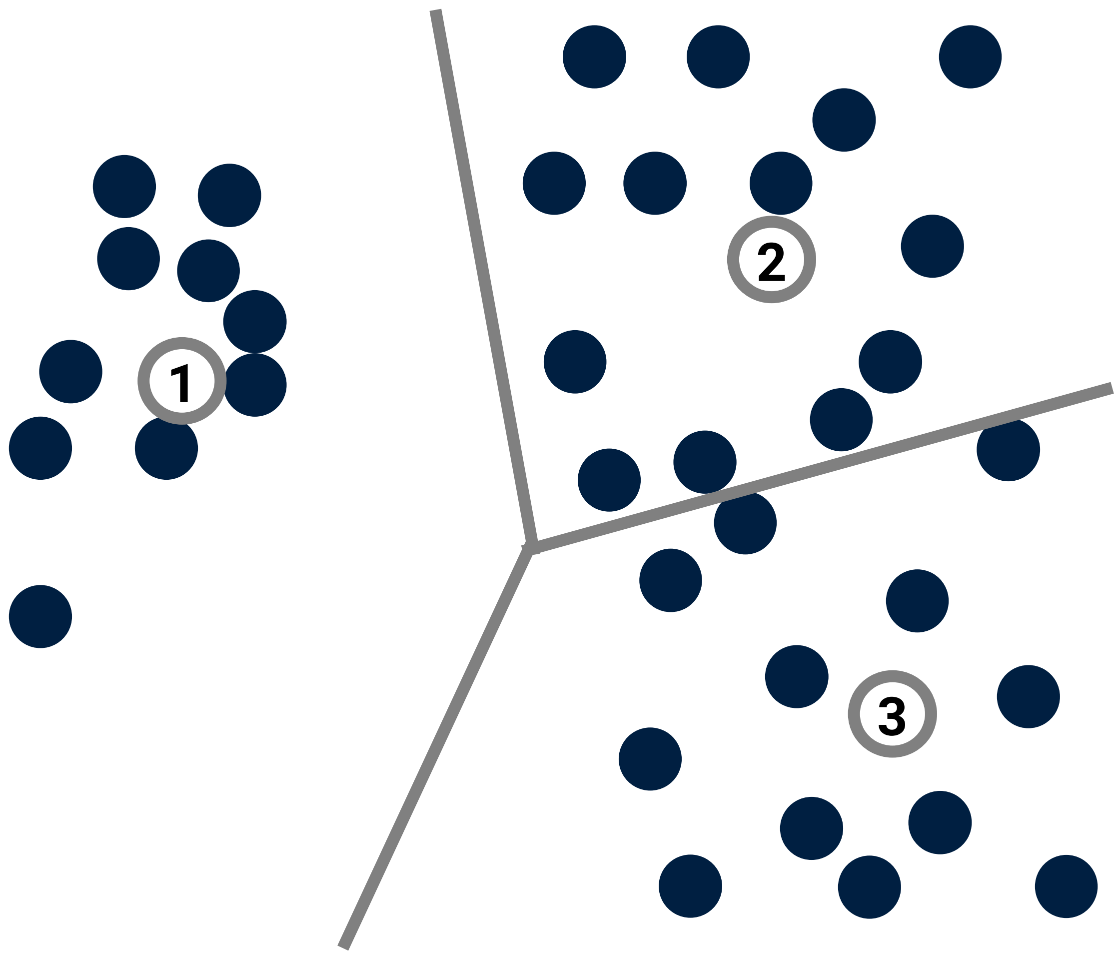

Détection d’anomalies

1, 2, 3, 4, 5, 5, 6, 7, 8, 9, 10, 11, 12

Détection d’anomalies

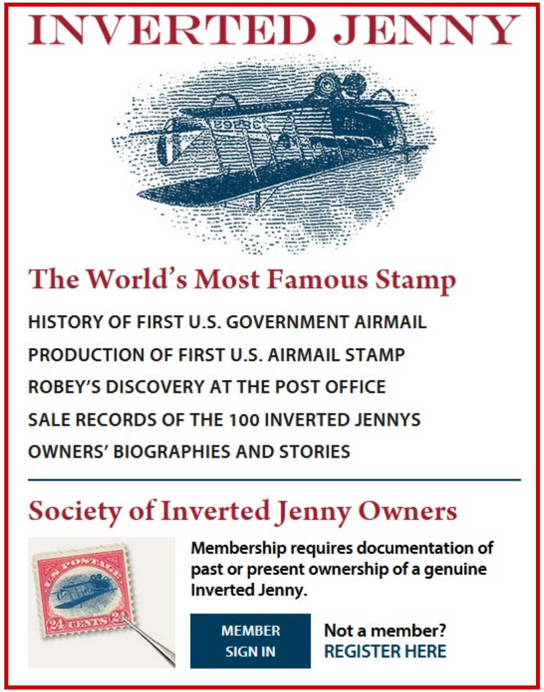

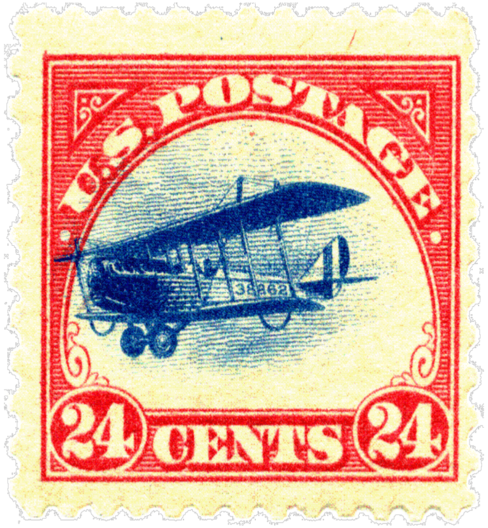

2 000 €

2 000 000 €

Simple pour une raison simple

$K(s) \leq K(f) + K(s \mid f)$

Détection d’anomalies

17.2	21.6	19.3
20.7	18.9	20.6
19.2	18.1	19.1
18.8	18.6	20.1
18.5	15.4	14.8
16.0	18.1	18.4
20.2	20.6	18.4
15.4	17.5	18.4
19.3	15.6	18.4
18.8	17.5	18.4

Apprentissage avec connaissances

One-shot learning

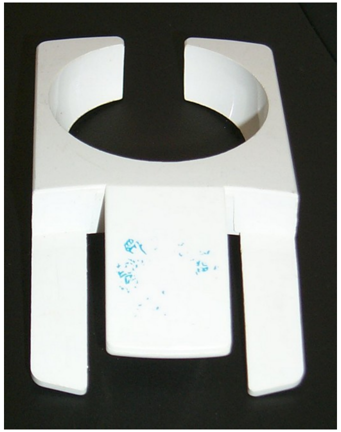

A child learns about four+ new words a day

Goulden, R., Nation, P. & Read, J. (1990). How large can a receptive vocabulary be? *Applied linguistics*, *11* (4), 341-363.

Conclusion

- (Machine) learning is compression
  - Lossy compression
  - Lossless compression
- La complexité donne des critères de compression