

# Les variables latentes

# Qu'est ce que c'est?

## Définitions informelles:

- Variable hypothétique (dont on fait l'hypothèse)
- Variable non-mesurable
- Variable qui synthétise plusieurs variables observées

# Qu'est ce que c'est?

## Définitions formelles:

- Variable qui rend les variables observées indépendantes si l'on en tient compte.  
(→ local independence)
- Variable dont les valeurs correspondent à la valeur attendue si l'on avait répétée la mesure un nombre infini de fois. (→ expected value)
- Variable qu'on ne peut calculer à l'aide de variables observées.
- Variable que l'on a pas observée dans notre échantillon

# Propriétés des variables latentes

- exploratoire versus confirmatoire
- Continue, catégorielle,...
- Identification: moyenne, variance si continue

# Types de modèles

Observées Latentes	Catégorielle	Continue
Catégorielle	Modèles de profils latents	Modèles de classes latentes
Continue	Modèles de réponse à l'item	Modèles d'équations structurales

# A quoi ça sert?

- Synthétiser les données
- S'approcher au plus près des concepts théoriques sous-jacents à ce qui a été mesuré
- Comparer la théorie à l'échantillon

# Exemple: échelle de suppression

- There are things I prefer not to think about.
- Sometimes I wonder why I have the thoughts I do.
- I always try to put problems out of mind.
- Sometimes I stay busy just to keep thoughts from intruding on my mind.
- There are things that I try not to think about.
- Sometimes I really wish I could stop thinking.
- I often do things to distract myself from my thoughts.
- I have thoughts that I try to avoid.
- There are many thoughts that I have that I don't tell anyone.

# Exemple: échelle d'intrusion

- I have thoughts that I cannot stop.
- There are images that come to mind that I cannot erase.
- My thoughts frequently return to one idea.
- I wish I could stop thinking of certain things.
- Sometimes my mind races so fast I wish I could stop it.
- There are thoughts that keep jumping into my head.

# Analyse factorielle

$$Y_i = b_0 + b_1 \xi_{i1} + b_2 \xi_{i2} + \dots + b_K \xi_{iK} + u_i$$

- $Y$  est la valeur d'une variable observée pour le  $i$ ème sujet,
- $b_0$  est l'intercept,
- $b_k$  est la saturation qui donne l'impact du  $k$ ème facteur sur  $Y$ ,  
 $\xi_{ik}$  est le score factoriel du  $k$ ème facteur
- $u_i$  est l'«uniqueness» ou l'erreur du sujet  $i$

# Exemple: analyse factorielle

---

Question	suppression	intrusion
1	<b>.76</b>	-.21
2	<b>.37</b>	.18
3	-.24	<b>.93</b>
4	-.11	<b>.81</b>
5	.03	<b>.78</b>
6	<b>.41</b>	<b>.56</b>
7	.32	<b>.52</b>
8	<b>.37</b>	-.01
9	-.03	<b>.69</b>
10	<b>.55</b>	.20
11	<b>.94</b>	-.17
12	<b>.41</b>	.34
13	<b>.48</b>	.04
14	<b>.86</b>	-.00
15	.25	.22

---

# Et maintenant que faire?

- Que représente le facteur?
  - Une combinaison linéaire de toutes les questions qui maximise le pourcentage de variance expliqué par le facteur.
  - Oui, mais... et au niveau théorique
    - Intrusion
    - Suppression
- Que faire des questions qui avaient des saturations basses sur les deux facteurs?
- Peut-on se fier à cette analyse: conditions d'applications

# Rasch: structure des données

		Item $i$				$r_{\nu}$
		1	2	3	4	
Personne $\nu$	1	0	1	0	1	2
	2	1	1	1	1	4
	3	0	1	1	0	2
	4	1	0	1	0	2
	5	0	1	0	1	2
	6	0	1	0	0	1
	7	0	1	0	0	1
	8	0	1	1	1	3
	$n_j$	2	7	4	4	

# Fréquence des vecteurs de réponse

$\mathbf{x}$					$n(\mathbf{x})$
0	0	0	0	0	2
0	0	0	1	1	4
0	0	1	0	0	2
0	0	1	1	1	2
0	1	0	0	0	2
0	1	0	1	1	1
0	1	1	1	0	1
...					
1	1	1	1	1	3

Nb modalités  
puissance  
nb d'items  
vecteurs  
possibles =

$2^4$  vecteurs  
possibles

# Définition Item Response Theory

- Il existe une ou plusieurs variables latentes qui sous-tendent (causent) les résultats aux items (catégoriels) d'un test.
- On examine la probabilité d'une réponse à une variable manifeste sachant la variable latente.
- Les composantes du comportement dans un test
  - Caractéristique du sujet: la capacité  $\theta_v$
  - Caractéristique de l'item: la difficulté  $\sigma_i$
- La probabilité d'obtenir une certaine catégorie de réponse est une fonction des caractéristiques du sujet et de l'item:

$$\text{Probabilité d'une certaine réponse} = F(\theta_v, \sigma_i)$$

# Calcul de probabilité

$$P(X_{vi} = 1) = e^{(\theta_v - \sigma_i)} / 1 + e^{(\theta_v - \sigma_i)}$$

Probabilité de réponse pour une personne  
avec  $\theta_v = -2.5$  et un item avec  $\sigma_i = -1.15$

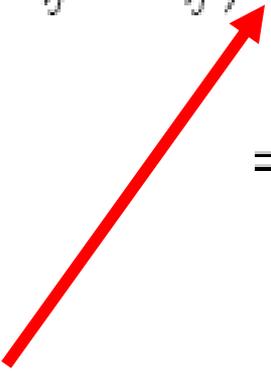
$$\begin{aligned} P(X_{vi} = 1) &= 2.72^{(-2.5 - (-1.15))} / 1 + 2.72^{(-2.5 - (-1.15))} \\ &= 2.72^{(-1.35)} / 1 + 2.72^{(-1.35)} \\ &= 0.26 / 1 + 0.26 = .21 \end{aligned}$$

# Probabilités de réponse pour deux personnes

$\sigma_i$	Personne	
	$\theta_v = -2.5$	$\theta_v = 2.4$
-1.15002	.21	.97
0.49362	.05	.87
0.52554	.05	.87
0.76415	.04	.84
-1.37806	.25	.98
0.57902	.04	.86
0.12744	.07	.91
1.08483	.03	.79
-1.01154	.18	.97
-0.47209	.12	.94
-0.60380	.13	.95
0.31469	.06	.89
-0.04901	.08	.92
0.77523	.04	.84

# Estimation des paramètres

Probabilité de réponse à deux items :

$$\begin{aligned} P(X_{vi} = x_{vi}, X_{vj} = x_{vj}) &= P(X_{vi} = x_{vi}) \cdot P(X_{vj} = x_{vj}) \\ &= \frac{e^{x_{vi}(\theta_v - \sigma_i)}}{1 + e^{(\theta_v - \sigma_i)}} \cdot \frac{e^{x_{vj}(\theta_v - \sigma_j)}}{1 + e^{(\theta_v - \sigma_j)}} \end{aligned}$$


Attention: exigence d'indépendance entre les items ou indépendance locale

# Estimation des paramètres

- Probabilité d'un vecteur de réponse :

$$P(\mathbf{x}) = \prod_{i=1}^k P(X_{vi} = x_{vi}) = \prod_{i=1}^k \frac{e^{x_{vi}(\theta_v - \sigma_i)}}{1 + e^{(\theta_v - \sigma_i)}}$$

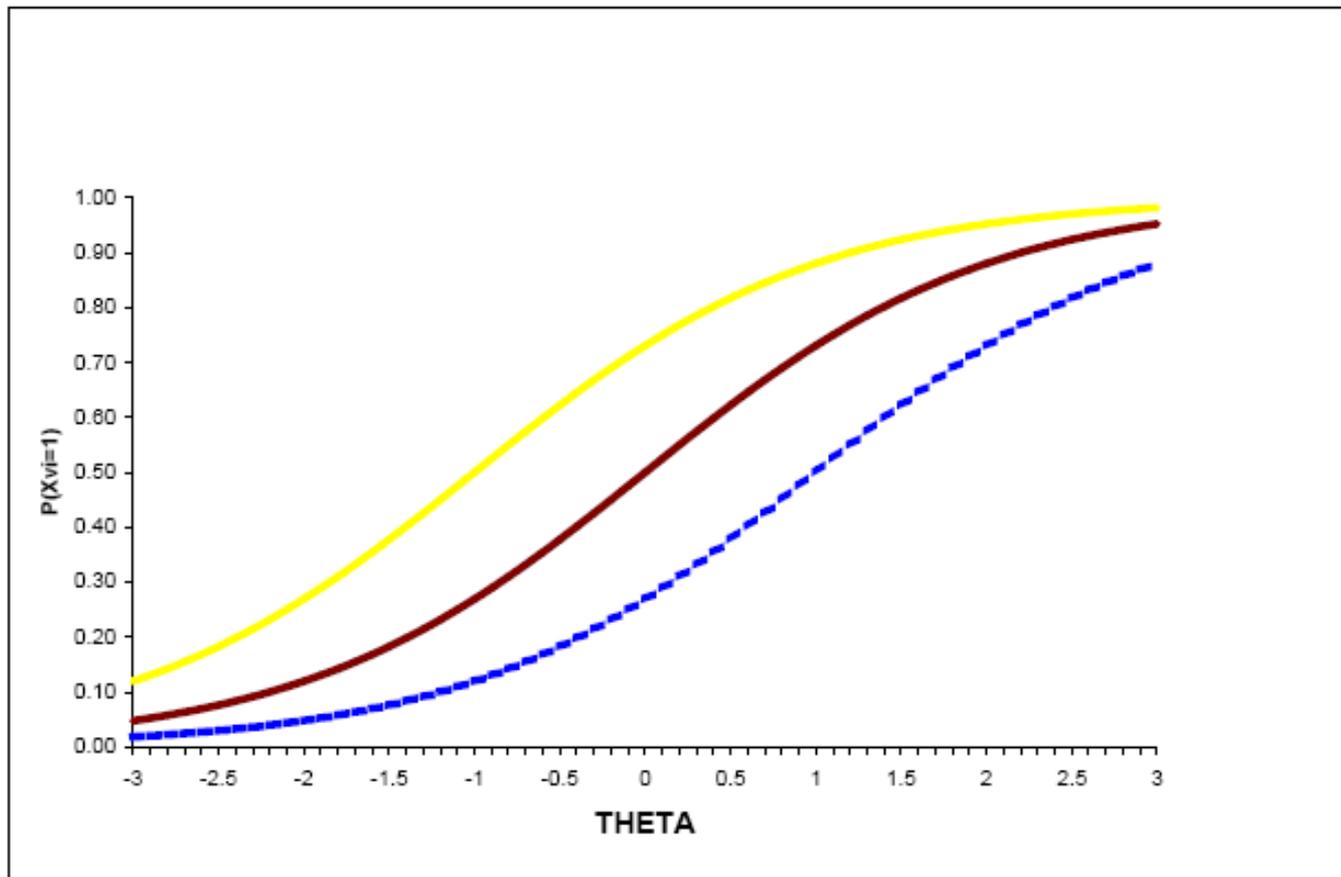
- Probabilité d'une matrice de réponse :

$$P(\mathbf{X}) = \prod_{v=1}^N \prod_{i=1}^k P(X_{vi} = x_{vi}) = \prod_{v=1}^N \prod_{i=1}^k \frac{e^{x_{vi}(\theta_v - \sigma_i)}}{1 + e^{(\theta_v - \sigma_i)}}$$

= fonction de vraisemblance

# Graphiquement

Exemple d'estimation d'un paramètre de personne si on connaît les paramètres des item  $\sigma_1 = -1$ ,  $\sigma_2 = 0$ ,  $\sigma_3 = 1$ :



# Fonction d'information

- Pour le modèle de Rasch, c'est la probabilité de répondre non fois la probabilité de répondre oui.
- Elle est la plus élevée au point d'inflexion de la courbe caractéristique (point où la probabilité vaut .5 et donc où la réponse est la plus incertaine)

# Test d'adéquation du modèle

- Le plus connu: test de Pearson

$$PE = \sum (o_x - e_x)^2 / e_x$$

- Compare les effectifs attendus ayant un certain vecteur de réponse aux effectifs observés



# Problème: test d'adéquation du modèle

- Il y a énormément de vecteurs de réponses possibles
- Les effectifs attendus sont très faibles donc la p-valeur du test de Pearson est fautive
- Solution:
  - Faire un bootstrap
  - Supprimer les valeurs de distance quand les valeurs attendues sont trop faibles
  - ??? À trouver

# Mauvais ajustement des items: indice Q

$$Q_i = \frac{\ln \frac{p(\mathbf{x}_{obs})}{p(\mathbf{x}_{max})}}{\ln \frac{p(\mathbf{x}_{min})}{p(\mathbf{x}_{max})}}, \quad 0 \leq Q_i \leq 1.$$

**Exemple: 7 sujets,  $n_i = 4$**

$\hat{\theta}_v$	-2.5	-1.4	-1.0	0	0.9	1.4	2.4
$x_{obs}$	0	1	0	1	0	1	1
$x_{min}$	0	0	0	1	1	1	1
$x_{max}$	1	1	1	1	0	0	0

$Q_i = 0$ , si  $p(x_{obs}) = p(x_{max})$

$Q_i = 1$ , si  $p(x_{obs}) = p(x_{min})$

# « Graded response model »

$$P(X_{vi} = x) = \frac{\exp(x\theta_v - \sigma_{ix})}{\sum_{s=0}^m \exp(s\theta_v - \sigma_{is})}$$

$$\sigma_{ix} = \sum_{s=0}^x \tau_{is}, \quad \sigma_{i0} = 0 \quad \text{et} \quad \sum_{i=1}^k \sum_{x=1}^m \tau_{ix} = 0$$

# « Graded response model »

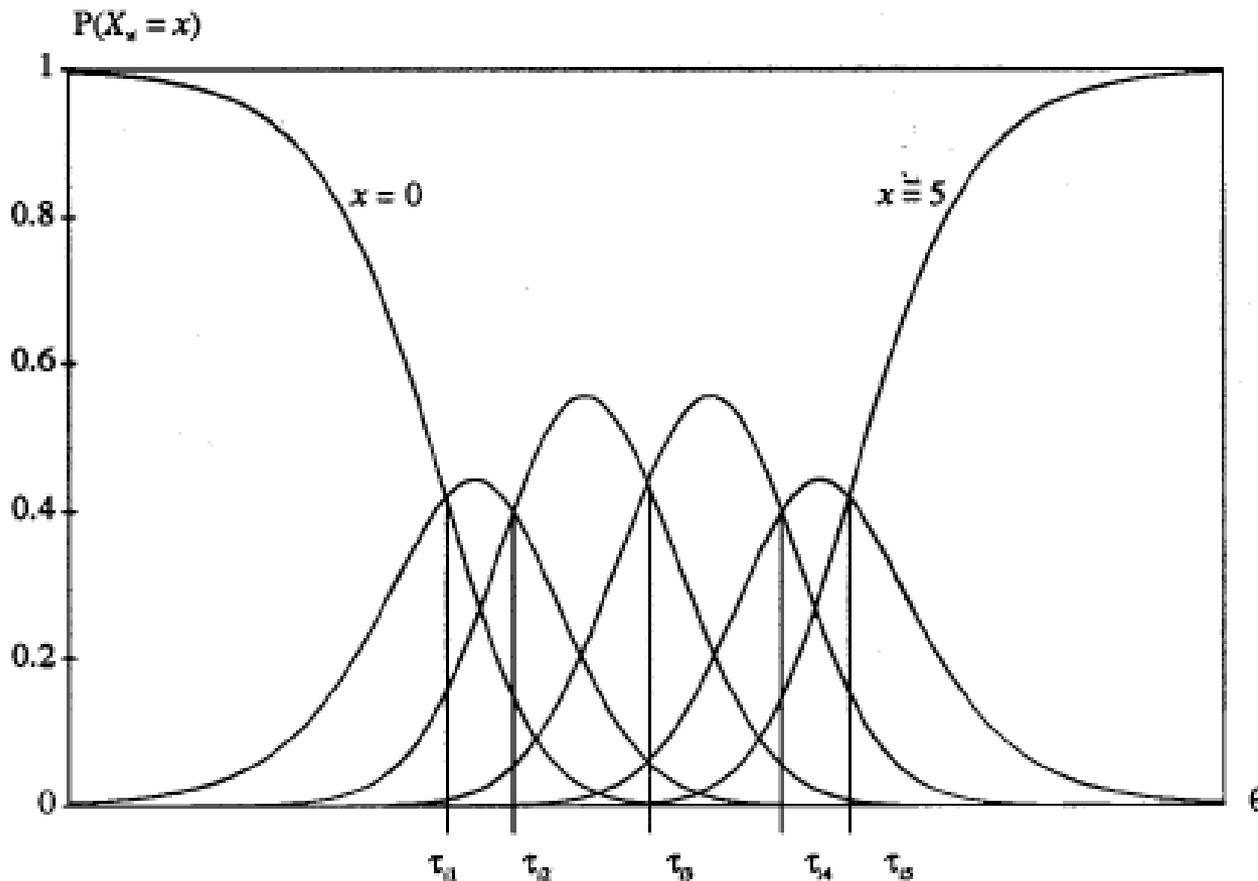


Figure 1. Category characteristic curves for an item with six categories and the threshold parameters  $\tau_1 = -3$ ,  $\tau_2 = -2$ ,  $\tau_3 = 0$ ,  $\tau_4 = 2$ , and  $\tau_5 = 3$ .

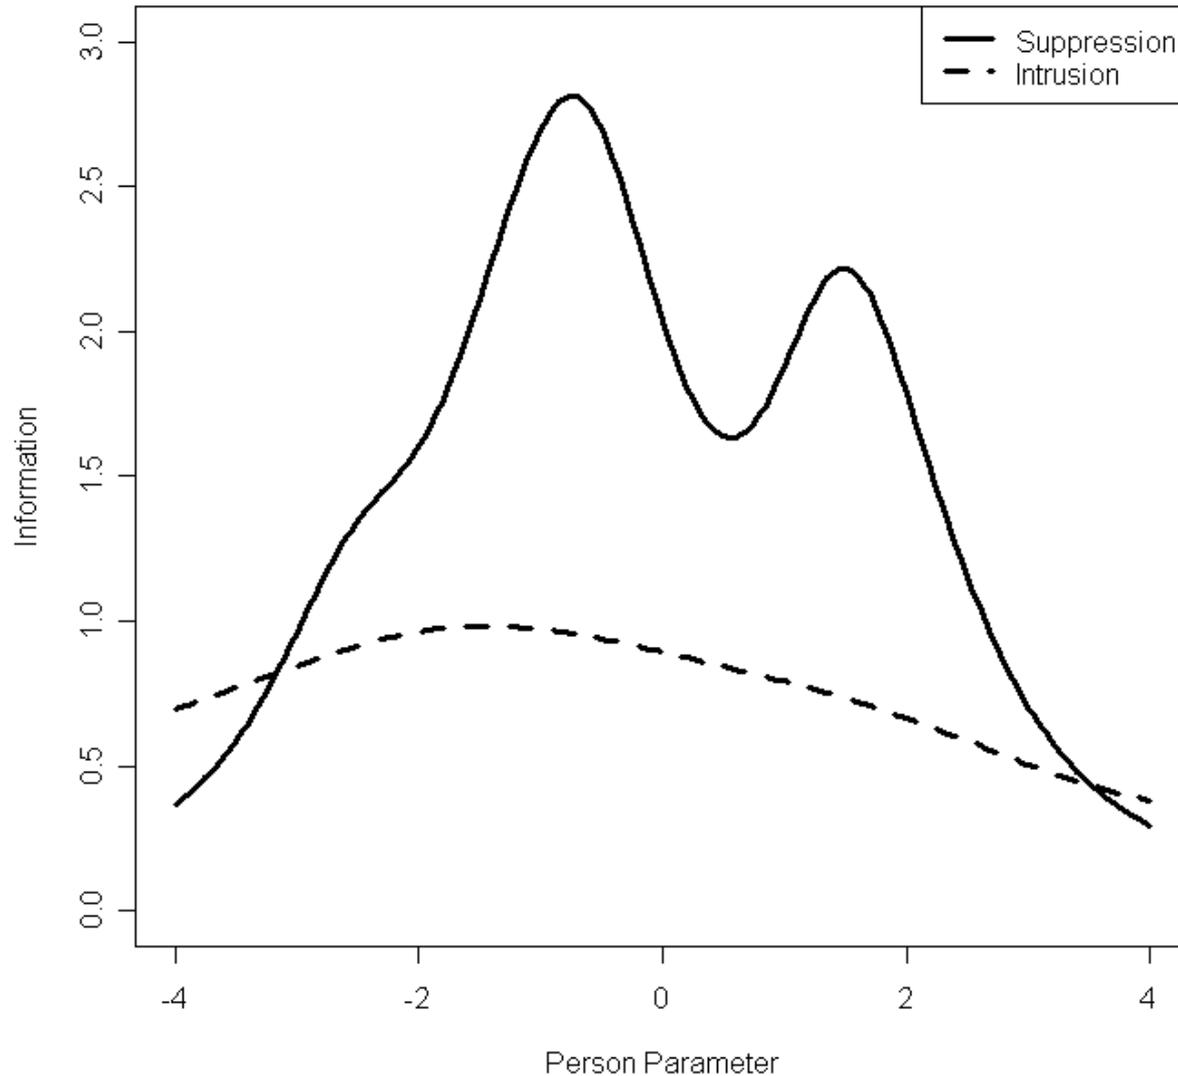
# Exemple: réponse à l'item (graded response model)

Dimension	Modèle	Items	Pearson's $\chi^2$	<i>df</i>	Boot <i>p</i>
Suppression	1A	1, 2, 8, 10-15	6512235.94	1953053	.03
	1B	1, 2, 10-15	788249.50	390561	.03
	1C	1, 2, 10-14	113986.74	78069	.06
	1D	1, 10-14	14758.42	15577	.27
Intrusion	2	3-7, 9	26545.11	15577	.10

# Example: indices Q

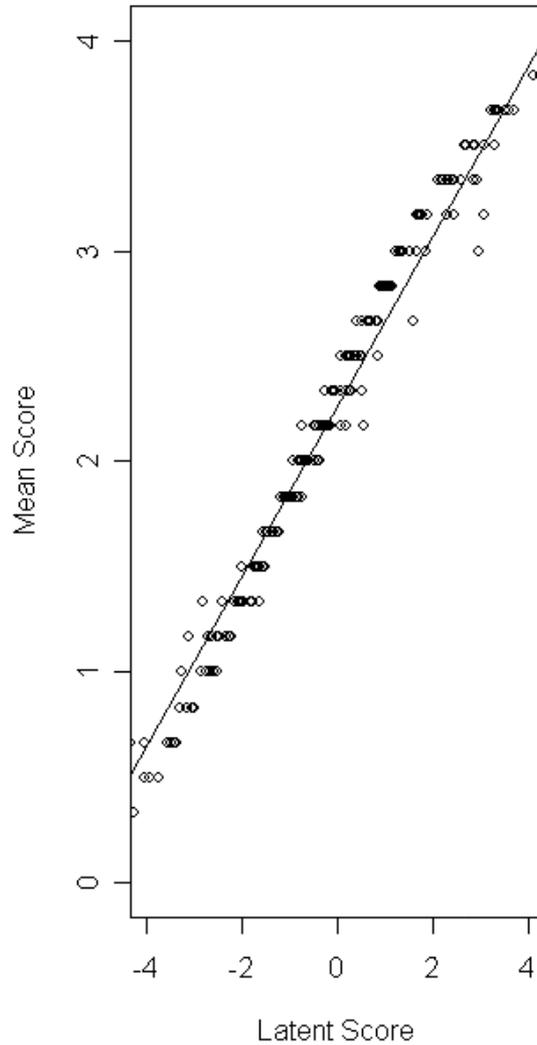
Question	suppression		intrusion	
1	.14	.36		
2				
3			.07	.62
4			.09	.46
5			.09	.49
6			.09	.46
7			.09	.40
8				
9			.08	.59
10	.14	.31		
11	.08	.83		
12	.11	.39		
13	.18	.18		
14	.08	.82		
15				

# Exemple: courbe d'information

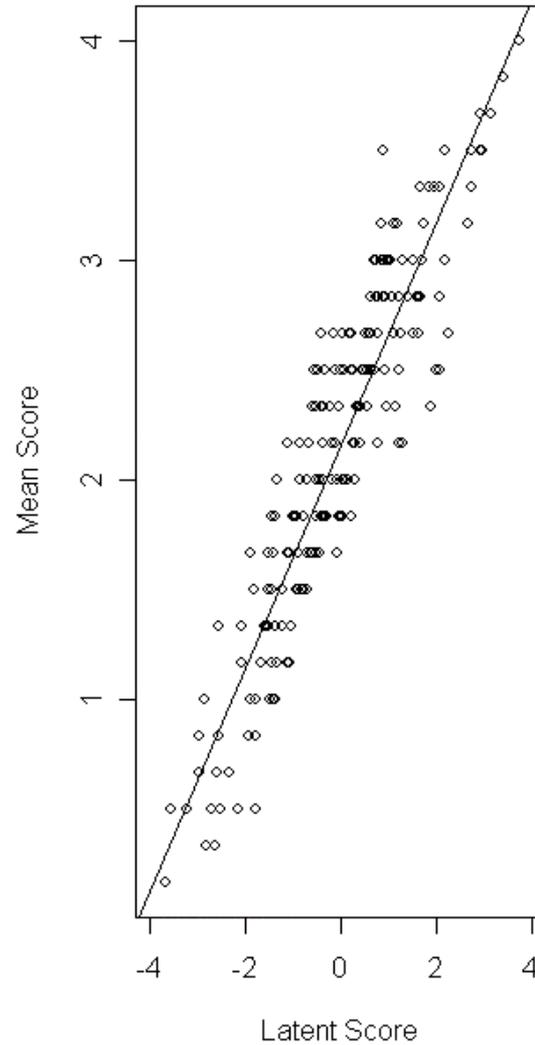


# Exemple: lien latent-observé

**Intrusion**



**Suppression**



# Conclusions

- Pour chaque groupe d'items (suppression et intrusion), plusieurs items ne s'ajustent pas et causent un non-ajustement de l'ensemble du modèle.
- Une fois ces items enlevés, l'échelle de suppression est plus informative que l'échelle d'intrusion.
- L'échelle de suppression correspond moins à un simple score total ( $r=.93$ ) que l'échelle d'intrusion.