

Intérêt des modèles en réseaux pour la modélisation de variables formatives et test de généralisabilité sur six échelles de Wechsler



Corentin Gonthier¹ & Eiko Fried²

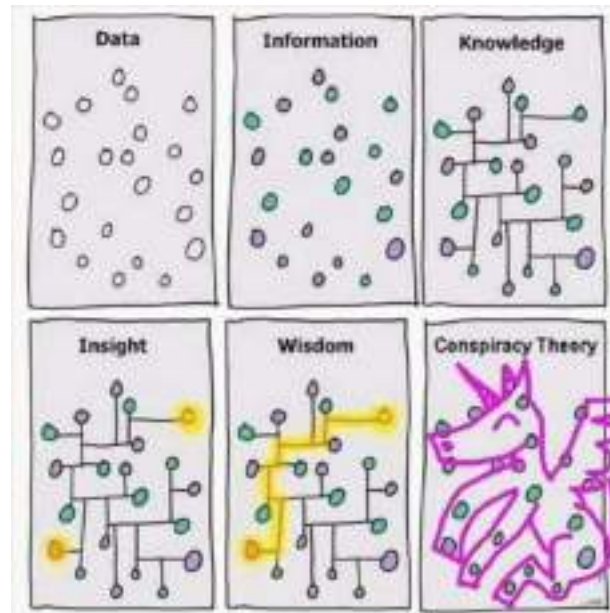
¹ PU en Psychologie – Nantes Université & IUF

² Associate Professor – Leiden University (NL)

corentin.gonthier@univ-nantes.fr

<https://www.univ-nantes.fr/corentin-gonthier>

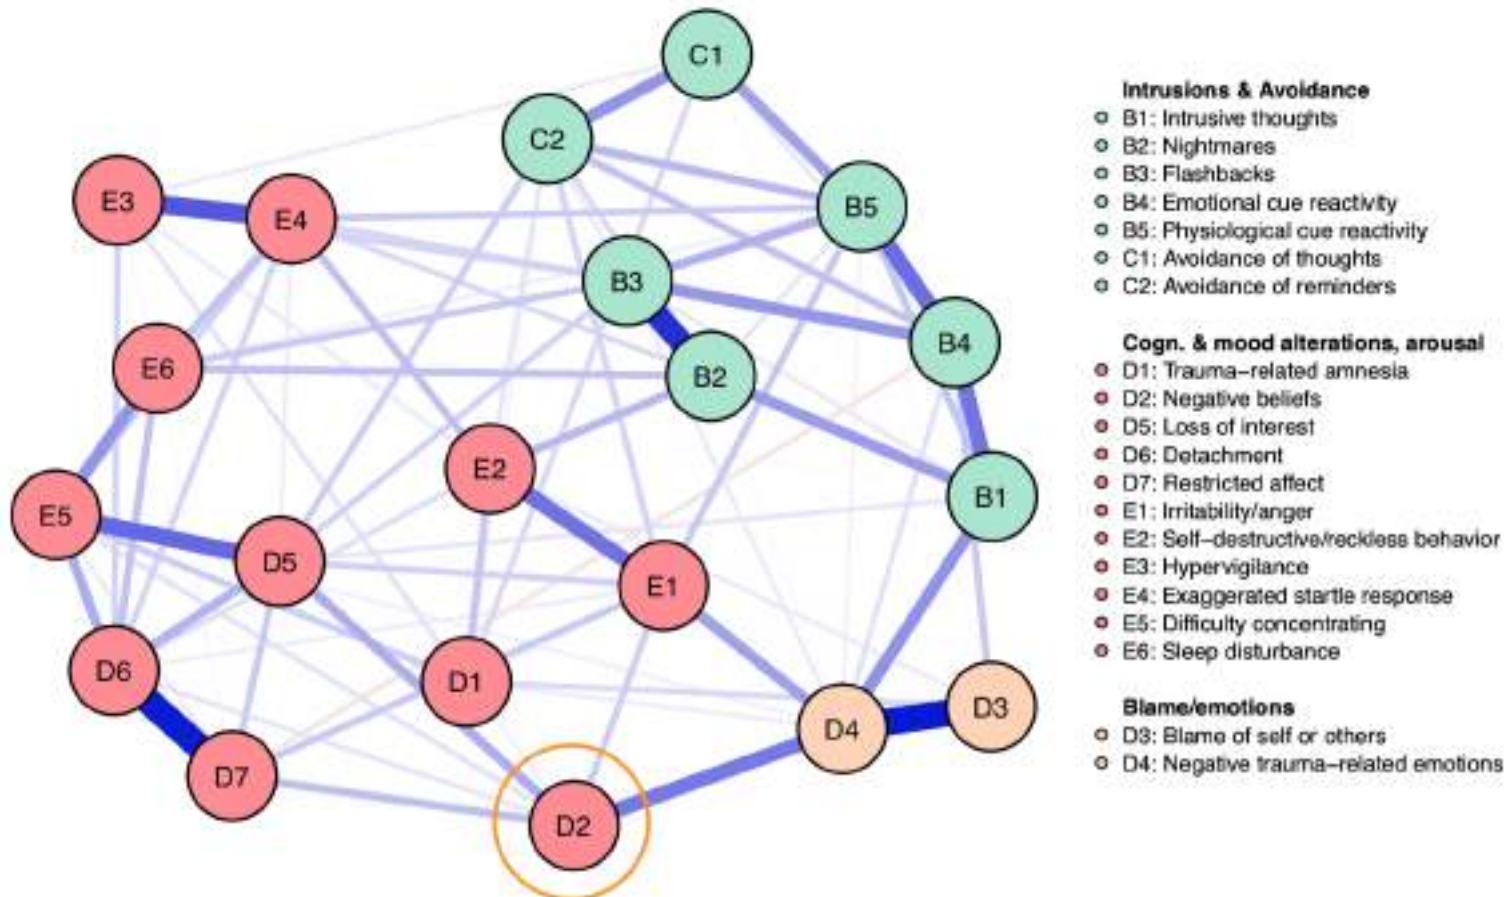
Les modèles en réseaux



Principes de base

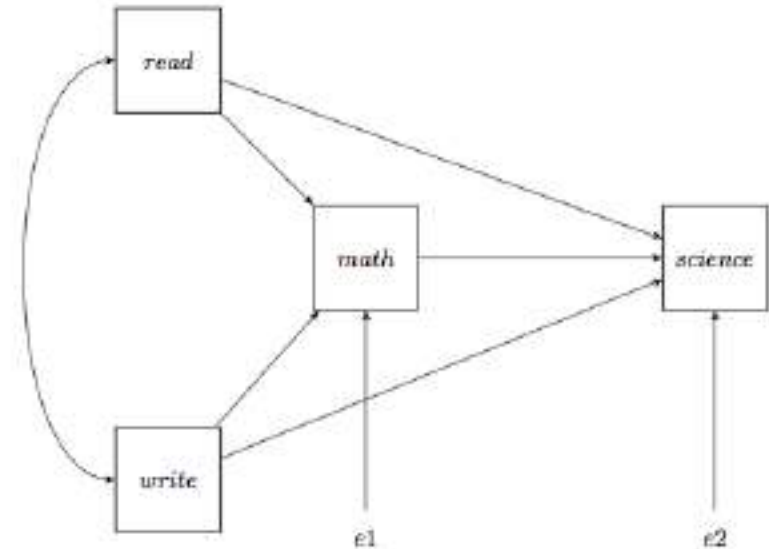

Modèles en réseaux

Idée de réseaux entre variables observées



Modèles en réseaux

Proche d'autres types de modèles...




Principal cas d'application : nombreuses mesures collectées,
pas de statut clair VI/VD, analyse exploratoire des relations

Un réseau a :

- Des nœuds (*nodes* : variables observées)
- Des arêtes (*edges* : relations entre variables), avec
 - Une direction (ou pas)
 - Un poids (ou pas)
 - Un signe (ou pas)

Modèles en réseaux

- Réseaux directionnels : *directed acyclic graphs*
- Conditions : pas de relations réciproques, pouvoir spécifier le sens des relations




- Utile dans le contexte de réseaux temporels
- Réseaux non-directionnels : cas d'application plus général

Les arêtes peuvent être...


- Non pondérées (binaires 1/0)
- Pondérées de façon à représenter :
 - Les corrélations simples entre variables (mais potentiellement expliquées par une autre variable)
 - Les corrélations partielles entre variables : relation entre X et Y en contrôlant pour tous les autres nœuds (absence de relation == indépendance conditionnelle)

Modèles en réseaux

Réseau de corrélations, max-max(graph)



Réseau de corrélations partielles, max-max(graph)



→ Pour chaque nœud :
régression multiple sur tous
les autres nœuds

Réseau non dirigé d'arêtes représentant des associations entre paires de variables en contrôlant toutes les autres variables :


Pairwise Markov Random Fields

- PMRF pour corrélations partielles entre variables numériques : *Gaussian Graphical Model (GGM)*
- PMRF pour associations (relations log-linéaires) entre variables binaires : *Ising model*
- PMRF pour mélange de variables nominales/ordinales/numériques : *Mixed Graphical Model (MGM)*


Modèles en réseaux

- Les corrélations sont rarement strictement nulles
→ peu lisible et peu parcimonieux
- Principe de régularisation : fixer les corrélations trop petites à zéro

Réseau de corrélations, $\text{rscorr}=\text{rscorr}(\text{graph})$



glasso EBIC, $\text{lambda}=0.5$, $\text{rscorr}=\text{rscorr}(\text{graph})$




Modèles en réseaux

- Solution intuitive : régulariser en fixant r à 0 si $p > .05$ (mais problème de comparaisons multiples)
- Solution efficace : régulariser en appliquant une pénalité globale qui fixe les corrélations les plus petites à 0
 - Méthodes les plus courantes : dérivées de LASSO (Least Absolute Shrinkage and Selection Operator) - fixer un seuil tel que la somme des $|\text{corrélations}|$ est inférieure à ce seuil
 - Un paramètre λ contrôle la régularisation ($\lambda = 0$: aucune pénalité)
 - λ généralement sélectionné par extended BIC

Modèles en réseaux

- Extension de LASSO à Graphical LASSO (glasso) : paramètre γ estimé à partir de la matrice de corrélations plutôt que des données brutes
 - Gestion des données manquantes
 - Possibilité de travailler sur une matrice de corrélations polychoriques – gestion des variables ordinales



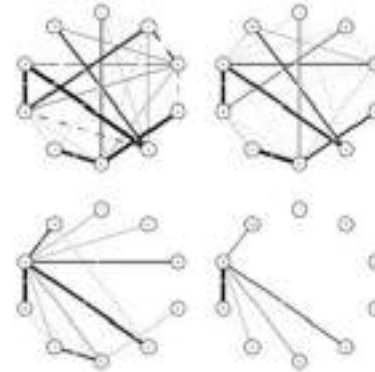
Modèles en réseaux

A




Gaussian graphical model with spurious edges

B



Gaussian graphical model after applying the glasso algorithm with 4 tuning parameter values

C



Gaussian graphical model after applying the glasso algorithm and using the EBIC to select the tuning parameter

Indicateurs


- Quatre types d'indicateurs dans un réseau :
 - 1. Pour le réseau dans son ensemble : ajustement global (EBIC), connectivité globale (somme des $|\text{poids}|$ des arêtes)...
 - 2. Par arêtes : indicateur de poids
 - 3. Par nœuds : différents indicateurs de centralité et de variance expliquée
 - 4. Par groupes de nœuds : communautés

3. Centralité d'un nœud :


- *Degree centrality* : nombre d'arêtes pour ce nœud
- *Strength centrality* : somme des |poids| des arêtes pour ce nœud
- *Closeness centrality* : distance pondérée par rapport à tous les autres nœuds (à quel point ce nœud sera-t-il affecté rapidement ?) → peu stable ?
- *Betweenness centrality* : nombre pondéré de chemins les plus courts possibles qui passent par ce nœud (à quel point ce nœud est-il important pour relier le reste du réseau ?) → peu stable ?
- *Clustering coefficient* : proportion de voisins du nœuds qui sont connectés entre eux
- Etc. exemple d'un nœud haut en clustering et bas en strength centrality

Modèles en réseaux

Pourcentage de variance d'un nœud expliqué par le reste du réseau
(*prédictibilité*) :

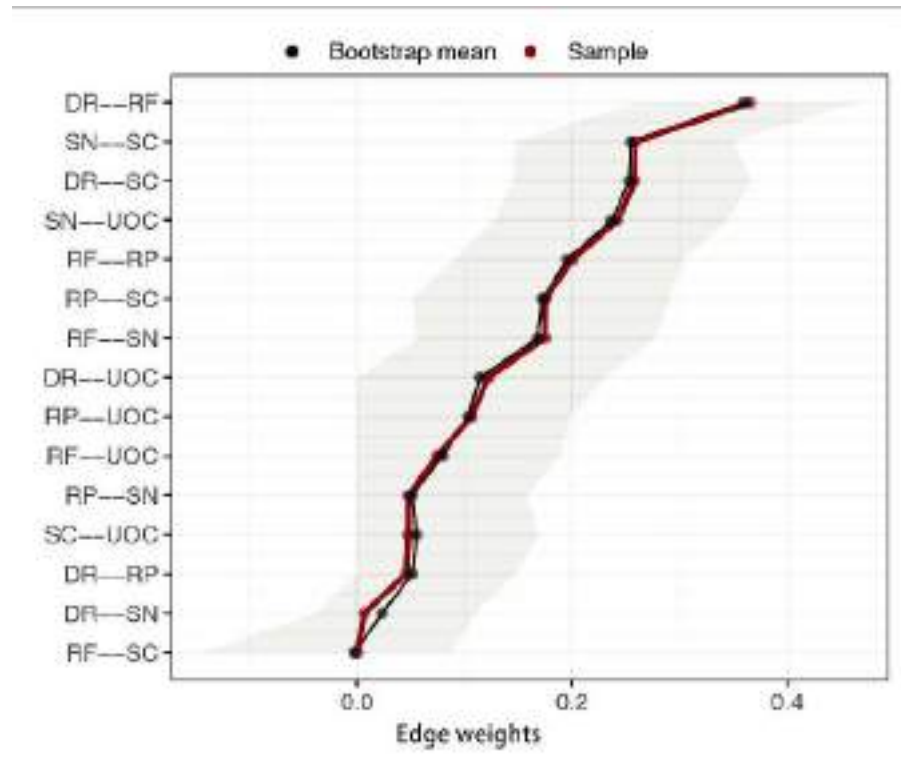


4. Détection de communautés : *exploratory graph analysis*



Modèles en réseaux

Importance de quantifier l'incertitude autour des paramètres estimés (poids des arêtes, centralité) : intervalles de confiance par bootstrap



Remarque : du fait de la régularisation, l'IC à 95% ne contient pas forcément la valeur vraie 95% du temps (e.g. régularisation à 0)

Exemples

Modèles en réseaux

```
library("bootnet")
```

```
Ncor <- estimateNetwork(dataset, default="cor")
```

```
Npcor <- estimateNetwork(dataset, default="pcor")
```

```
Nglasso <- estimateNetwork(dataset, default="EBICglasso", tuning=0.5)
```


```
plot(Ncor, title="correlations", title.cex=1.4, node.width=2)
```

```
plot(Npcor, title="partial correlations", title.cex=1.4, node.width=2)
```


```
plot(Nglasso, title="glasso EBIC", title.cex=1.4, node.width=2)
```

Modèles en réseaux


correlations



partial correlations



glasso EBIC



Modèles en réseaux

```
lay <- averageLayout(Ncor$graph, Npcor$graph, Nglasso$graph)
```

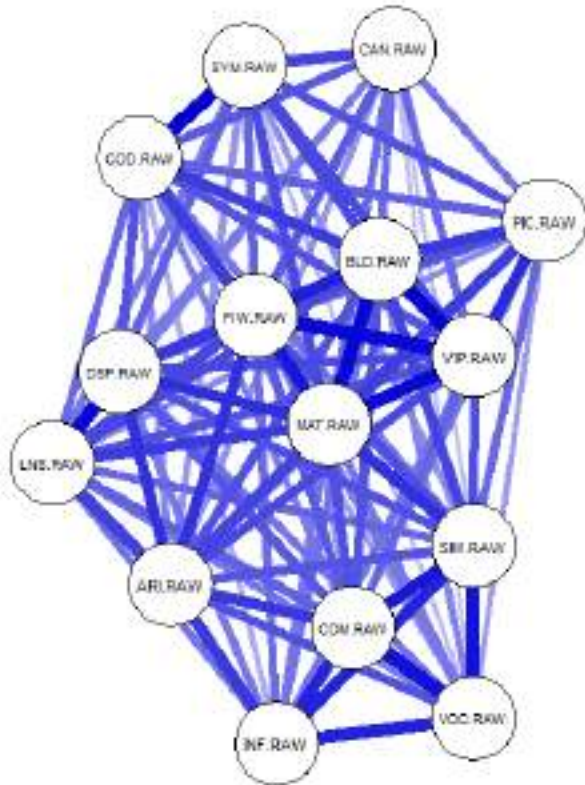
```
plot(Ncor, title="correlations", title.cex=1.4, node.width=2, layout=lay)
```

```
plot(Npcor, title="partial correlations", title.cex=1.4, node.width=2, layout=lay)
```


```
plot(Nglasso, title="glasso EBIC", title.cex=1.4, node.width=2, layout=lay)
```


Modèles en réseaux


correlations



partial correlations



glasso EBIC



Modèles en réseaux


```
plot(Ncor, title="correlations", title.cex=1.4, node.width=2, layout=lay,  
      maximum=1)
```

```
plot(Npcor, title="partial correlations", title.cex=1.4, node.width=2 , layout=lay,  
      maximum=1)
```

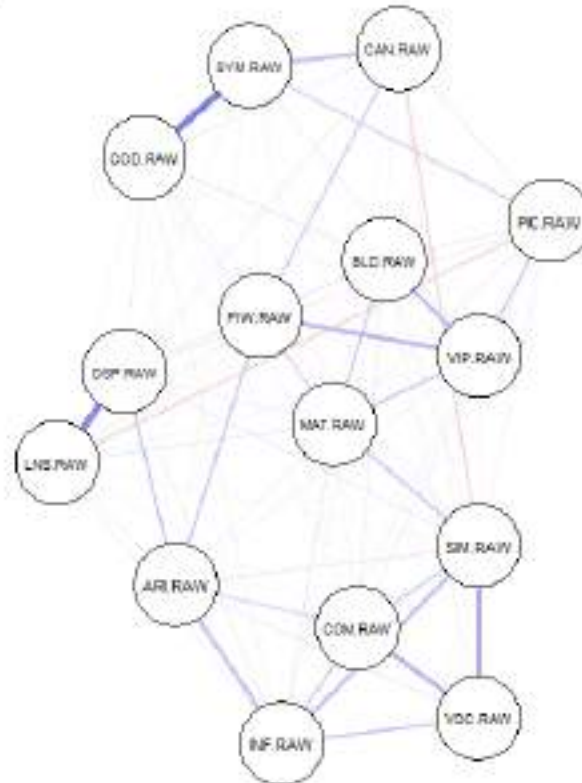
```
plot(Nglasso, title="glasso EBIC", title.cex=1.4, node.width=2 , layout=lay,  
      maximum=1)
```

Modèles en réseaux

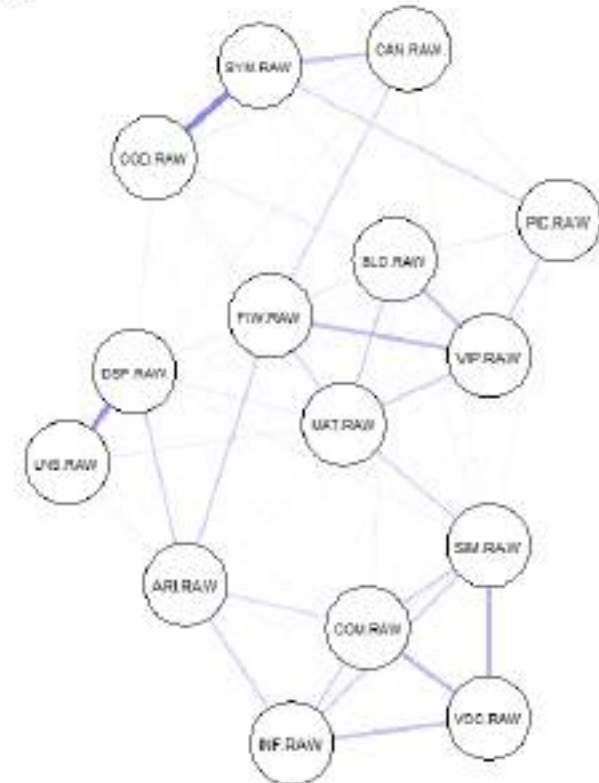
correlations



partial correlations



glasso EBIC



Modèles en réseaux

```
Network<-estimateNetwork(dataset, default="EBICglasso", tuning=0.5)
```

```
Network$graph
```

	ARI.RAW	BLD.RAW	SIM.RAW	DSP.RAW	MAT.RAW	VOC.RAW	SYM.RAW	VIP.RAW	INF.RAW	COD.RAW
ARI.RAW	0.00000000	0.00000000	0.00000000	0.17240060	0.015224883	0.053334251	0.000000000	0.046601329	0.197623594	0.000000000
BLD.RAW	0.00000000	0.00000000	0.05628943	0.08202387	0.193877005	0.000000000	0.028378179	0.253582258	0.000000000	0.108950934
SIM.RAW	0.00000000	0.05628943	0.00000000	0.05855800	0.156043295	0.278160912	0.000000000	0.018197391	0.193189599	0.014566440
DSP.RAW	0.17240060	0.08202387	0.05855800	0.00000000	0.088409539	0.000000000	0.033180167	0.000000000	0.000000000	0.068998081
MAT.RAW	0.01522488	0.19387700	0.15604330	0.08840954	0.000000000	0.000000000	0.030439613	0.185173188	0.000000000	0.097080282
VOC.RAW	0.05333425	0.00000000	0.27816091	0.00000000	0.000000000	0.000000000	-0.009902278	0.000000000	0.221671957	0.000000000
SYM.RAW	0.00000000	0.02837818	0.00000000	0.03318017	0.030439613	-0.009902278	0.000000000	0.058328766	-0.009889536	0.475974888
VIP.RAW	0.04660133	0.25358226	0.01819739	0.00000000	0.185173188	0.000000000	0.058328766	0.000000000	0.000000000	0.000000000
INF.RAW	0.19762359	0.00000000	0.19318990	0.00000000	0.000000000	0.221671957	-0.009889536	0.000000000	0.000000000	0.000000000
COD.RAW	0.00000000	0.10895093	0.01456644	0.06899808	0.097080282	0.000000000	0.475974888	0.000000000	0.000000000	0.000000000
LNS.RAW	0.09760118	0.02914423	0.00000000	0.41798371	0.083608113	0.003537868	0.000000000	0.006287405	0.024290889	0.023693542
FIW.RAW	0.19322235	0.05458861	0.03380492	0.00000000	0.149968854	0.000000000	0.000000000	0.267972174	0.000000000	0.003542481
COM.RAW	0.12238962	0.05490047	0.18976718	0.02111417	0.005847177	0.296535717	0.000000000	0.000000000	0.183801216	0.016401728
CAN.RAW	0.00000000	0.01587960	-0.05910966	0.02959058	0.002572510	0.000000000	0.220009916	0.014124176	0.000000000	0.084251364
PIC.RAW	0.00000000	0.10829760	0.05164378	0.02760856	0.075606026	0.000000000	0.131011426	0.203667105	0.000000000	0.000000000
	LNS.RAW	FIW.RAW	COM.RAW	CAN.RAW	PIC.RAW					
ARI.RAW	0.097601180	0.193222350	0.122389620	0.000000000	0.000000000					
BLD.RAW	0.029144230	0.094588606	0.054900472	0.015879600	0.108297600					
SIM.RAW	0.000000000	0.033804921	0.189767181	-0.059109660	0.051643780					
DSP.RAW	0.417983706	0.000000000	0.021114170	0.029590580	0.027608560					
MAT.RAW	0.083608113	0.149968854	0.005847177	0.002572510	0.075606030					
VOC.RAW	0.003537868	0.000000000	0.290535717	0.000000000	0.000000000					
SYM.RAW	0.000000000	0.000000000	0.000000000	0.220009920	0.131011430					
VIP.RAW	0.006287405	0.267972174	0.000000000	0.014124180	0.203667110					
INF.RAW	0.024290889	0.000000000	0.183801216	0.000000000	0.000000000					
COD.RAW	0.023693542	0.005542481	0.016401728	0.084251360	0.000000000					
LNS.RAW	0.000000000	0.066735483	0.042817548	0.048228500	0.000000000					
FIW.RAW	0.066735483	0.000000000	0.022230501	0.159244390	0.000000000					
COM.RAW	0.042817548	0.022230501	0.000000000	0.000000000	0.031282880					
CAN.RAW	0.048228500	0.159244386	0.000000000	0.000000000	0.081857500					
PIC.RAW	0.000000000	0.000000000	0.031282880	0.081857500	0.000000000					

Modèles en réseaux

vechs(Network\$graph)

	ARI.RAW	BLD.RAW	SIM.RAW	DSP.RAW	MAT.RAW	VOC.RAW	SYM.RAW	VIP.RAW	INF.RAW	COD.RAW
ARI.RAW	0.00000000	0.00000000	0.00000000	0.17240060	0.015224883	0.053334251	0.000000000	0.046601329	0.197623594	0.000000000
BLD.RAW	0.00000000	0.00000000	0.05628943	0.082023075	0.193877005	0.000000000	0.028378179	0.253582258	0.000000000	0.108950934
SIM.RAW	0.00000000	0.00000000	0.058558003	0.156043295	0.278160912	0.000000000	0.018197391	0.193189899	0.014566440	0.000000000
DSP.RAW	0.00000000	0.00000000	0.088409539	0.000000000	0.033180167	0.000000000	0.000000000	0.068998081	0.000000000	0.068998081
MAT.RAW	0.00000000	0.00000000	0.000000000	0.000000000	0.030439613	0.189173188	0.000000000	0.097080282	0.000000000	0.097080282
VOC.RAW	0.00000000	0.00000000	0.000000000	0.000000000	0.000000000	-0.009902278	0.000000000	0.221671957	0.000000000	0.000000000
SYM.RAW	0.00000000	0.00000000	0.000000000	0.000000000	0.000000000	0.000000000	0.058328766	-0.009889536	0.475974888	0.000000000
VIP.RAW	0.00000000	0.00000000	0.000000000	0.000000000	0.000000000	0.000000000	0.000000000	0.000000000	0.000000000	0.000000000
INF.RAW	0.00000000	0.00000000	0.000000000	0.000000000	0.000000000	0.000000000	0.000000000	0.000000000	0.000000000	0.000000000
COD.RAW	0.00000000	0.00000000	0.000000000	0.000000000	0.000000000	0.000000000	0.000000000	0.000000000	0.000000000	0.000000000


[1]	0.000000000	0.000000000	0.172400603	0.015224883	0.053334251	0.000000000	0.046601329	0.197623594	0.000000000	0.097601180	0.193223350	0.122389620
[13]	0.000000000	0.000000000	0.056289426	0.082023075	0.193877005	0.000000000	0.028378179	0.253582258	0.000000000	0.108950934	0.029144230	0.094506604
[25]	0.054900472	0.015879596	0.108297600	0.058558003	0.156043295	0.278160912	0.000000000	0.018197391	0.193189899	0.014566440	0.000000000	0.033504921
[37]	0.185767181	-0.059109656	0.051643776	0.088409539	0.000000000	0.033180167	0.000000000	0.000000000	0.068998081	0.417983706	0.000000000	0.021114170
[49]	0.029590578	0.027608556	0.000000000	0.030439613	0.189173188	0.000000000	0.097080282	0.083608113	0.149968854	0.005847177	0.002572510	0.075606026
[61]	-0.009902278	0.000000000	0.221671957	0.000000000	0.003537862	0.000000000	0.250535717	0.000000000	0.000000000	0.058328766	-0.005829536	0.475974888
[73]	0.000000000	0.000000000	0.000000000	0.220009916	0.131011426	0.000000000	0.000000000	0.006287405	0.267972174	0.000000000	0.014124176	0.203667105
[85]	0.000000000	0.024290888	0.000000000	0.183801216	0.000000000	0.000000000	0.023693542	0.005542481	0.016401728	0.084251364	0.000000000	0.066735483
[97]	0.042817548	0.048238499	0.000000000	0.022230501	0.158244386	0.000000000	0.000000000	0.031282880	0.081857502			

Modèles en réseaux

```
Network<-estimateNetwork(dataset, default="EBICglasso", tuning=0.5)
```

```
Results1 <- bootnet(Network, nBoots = 1000, nCores = 8)
```

```
plot(Results1, labels = T, order = "sample", CIstyle="quantiles")
```




Modèles en réseaux

```
Network<-estimateNetwork(dataset, default="EBICglasso", tuning=0.5)
centralityTable(Network, standardized=F)
```

```
8 graph 1 NA VIP.RAW Betweenness 13.000000000
9 graph 1 NA INF.RAW Betweenness 6.000000000
10 graph 1 NA COD.RAW Betweenness 6.000000000
11 graph 1 NA LNS.RAW Betweenness 0.000000000
12 graph 1 NA FIW.RAW Betweenness 22.000000000
13 graph 1 NA COM.RAW Betweenness 0.000000000
14 graph 1 NA CAN.RAW Betweenness 6.000000000
15 graph 1 NA PIC.RAW Betweenness 1.000000000
16 graph 1 NA ARI.RAW Closeness 0.006987908
17 graph 1 NA BLD.RAW Closeness 0.006246528
18 graph 1 NA SIM.RAW Closeness 0.005862201
19 graph 1 NA DSP.RAW Closeness 0.005507235
20 graph 1 NA MAT.RAW Closeness 0.007253646
21 graph 1 NA VOC.RAW Closeness 0.005184610
22 graph 1 NA SYM.RAW Closeness 0.005016159
23 graph 1 NA VIP.RAW Closeness 0.006566353
24 graph 1 NA INF.RAW Closeness 0.005708734
25 graph 1 NA COD.RAW Closeness 0.005141935
26 graph 1 NA LNS.RAW Closeness 0.004742080
27 graph 1 NA FIW.RAW Closeness 0.007263676
28 graph 1 NA COM.RAW Closeness 0.005004699
29 graph 1 NA CAN.RAW Closeness 0.005305237
30 graph 1 NA PIC.RAW Closeness 0.005121376
31 graph 1 NA ARI.RAW Strength 0.898397809
32 graph 1 NA BLD.RAW Strength 1.025912180
33 graph 1 NA SIM.RAW Strength 1.105330901
34 graph 1 NA DSP.RAW Strength 0.999867278
35 graph 1 NA MAT.RAW Strength 1.087850486
36 graph 1 NA VOC.RAW Strength 0.857142983
37 graph 1 NA SYM.RAW Strength 0.997114769
```


Modèles en réseaux

```
Network<-estimateNetwork(dataset, default="EBICglasso", tuning=0.5)  
centralityPlot(Network, standardized=F)
```



Modèles en réseaux


```
Results2 <- bootnet(Network, nBoots = 1000, nCores = 8, type = "case")  
plot(Results2, perNode=T)
```



Modèles en réseaux

library("EGAnet")

EGA(dataset)



Recommandations et extensions

Quelle taille d'échantillon ?

Quelle complexité du modèle ?

Blanken et al. (2022) :

- pas plus de ~30 nœuds
- plusieurs centaines de participants
- la taille d'échantillon requise augmente quand le nombre réel d'arêtes diminue (e.g. 30 nœuds & 10 arêtes : $N=341$)

Quelle taille d'échantillon ?

Quelle complexité du modèle ?

Si le nombre de participants est trop petit : perte de puissance (beaucoup de liens fixés à 0), mais surtout le réseau sera très instable

→ La réplication sur un échantillon différent donnera des résultats différents, même si le "vrai" réseau est identique

→ Problème de stabilité/répliquabilité (cf. partie suivante)

Attention aux effets de suppression

Correlations


	X1	X2	X3
X1	1	.78	.35
X2	.78	1	.78
X3	.35	.78	1

Partial correlations

	X1	X2	X3
X1	1	.87	-.67
X2	.87	1	.87
X3	-.67	.87	1

Attention aux effets de suppression

X_2 :
faible (noir)
moyen (bleu)
élevé (rouge)



- Pour une valeur donnée de X_2 , la relation entre X_1 et X_3 est négative
- En tenant constante X_2 , un sujet haut en X_1 est forcément bas en X_3
- Puisque X_2 est très corrélée à X_1 et X_3 , il est impossible d'être haut à la fois en X_1 et en X_3 pour une valeur moyenne de X_2


Attention aux effets de suppression

X2 :

faible (noir)

moyen (bleu)

élevé (rouge)



→ Pas forcément de signification psychologie : le phénomène peut se produire juste parce que les corrélations entre variables rendent certaines combinaisons de scores improbables (~paradoxe de Simpson)

Les analyses en réseaux ne sont rien d'autre qu'une série de régressions multiples

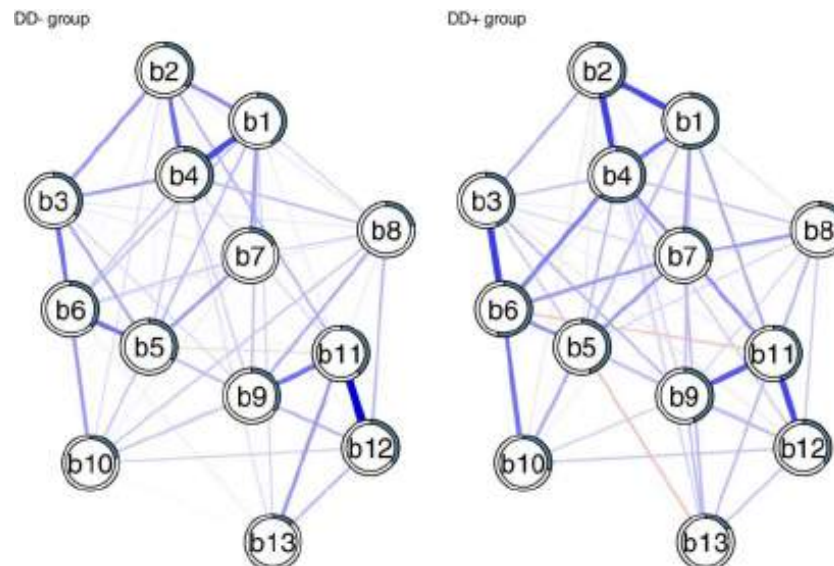
→ Et les conditions d'application ?

- Normalité des résidus – attention aux valeurs extrêmes !!!
- Homoscédasticité (comment la tester ?)
- Absence de multicolinéarité : pas de relations trop importantes entre nœuds (si r_{XY} est trop élevée, instabilité des paramètres estimés et risque accru d'effets de suppression)

Modèles en réseaux

Nombreuses extensions possibles

- Réseaux et groupes distincts : Fused Graphical Lasso (FGL)
- ➔ estimation conjointe dans ≥ 2 groupes
- ➔ régularise la complexité ET la différence entre groupes
- ➔ estime sur $N=200$ au lieu de $n=100$ et $n=100$



Nombreuses extensions possibles

➤ Réseaux et groupes distincts : Network Comparison Test


Trois tests inférentiels de l'équivalence entre plusieurs réseaux

- invariance de la structure du réseau : "aucune arête n'est significativement différente"
- invariance du poids d'une arête : "cette arête en particulier n'est pas significativement différente"
- invariance de la connectivité globale : "la somme des $|arêtes|$ n'est pas significativement différente"

Modèles en réseaux

Nombreuses extensions possibles

- Réseaux et interactions avec une variable continue : moderated network analysis
- "Est-ce que le lien entre deux nœuds varie en fonction d'un troisième nœud ?"




Modèles en réseaux

Nombreuses extensions possibles


➤ Réseaux intra-individuels ($T \geq 100$, $N \geq 1$) :
graphical vector auto-regression (GVAR)

- Temporal : les mesures à t prédisent les mesures à $t+1$
- Contemporaneous : les mesures à t se prédisent entre elles (en contrôlant l'effet du temps)
- Between-persons (si $N > 1$) : les mesures moyennes pour un sujet se prédisent entre elles


Temporal



Contemporaneous



Between-persons




1: Nervous
 2: Wary (control)
 3: Wary (excitatory)
 4: Trouble releasing
 5: Restless
 6: Anxious
 7: Apprehensive expectation
 8: Anhedonia
 9: Depressed mood
 10: Sleep
 11: Energy
 12: Appetite
 13: Fatigue
 14: Concentration
 15: Psychomotor
 16: Suicidal ideation

Modèles en réseaux

Nombreuses extensions possibles

- Réseaux & SEM – mais coût de calcul prohibitif pour un grand nombre d'items




Modèles en réseaux

Nombreuses extensions possibles

- Meta-analytic gaussian network aggregation (à effets fixes, effets aléatoires)


Random-effects MAGNA: pooled / per_study



La modélisation de variables formatives

Variables formatives

Réalisme

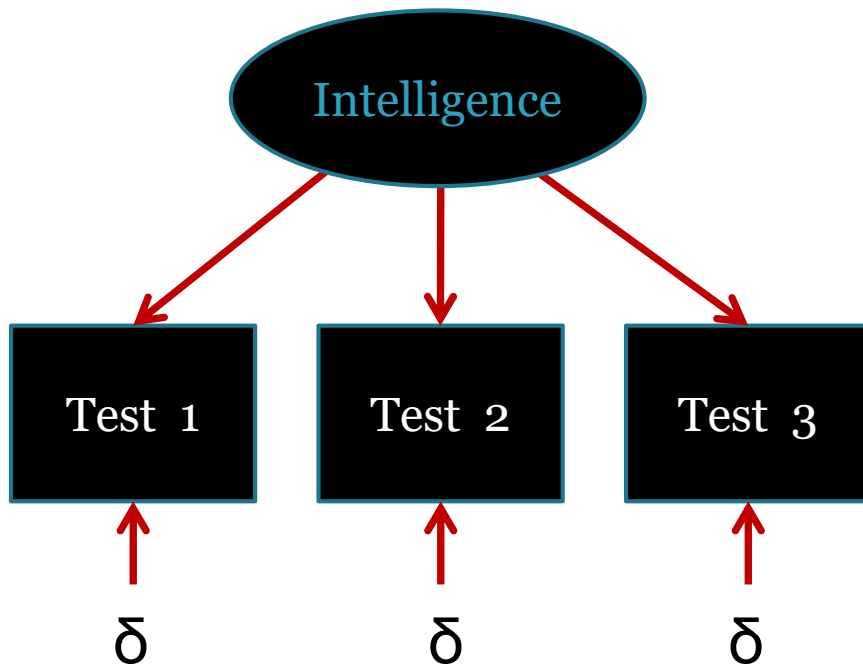


Constructivisme

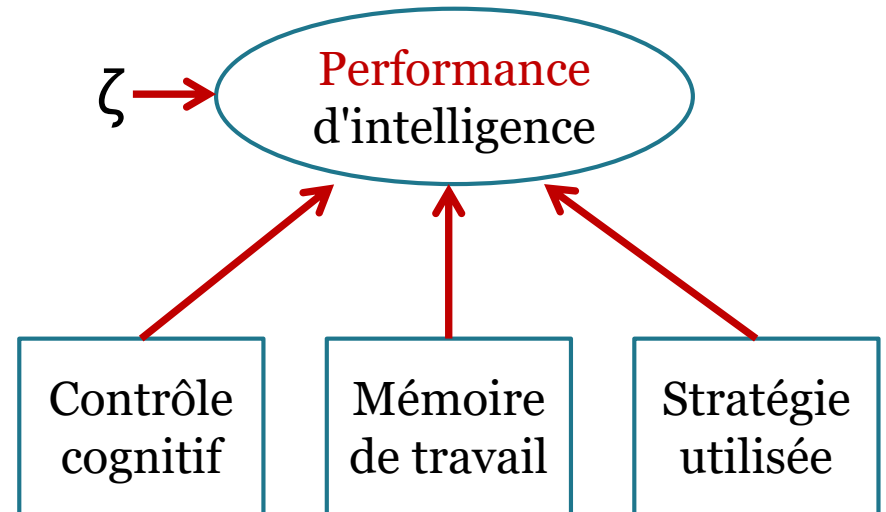


Variables formatives

Réalisme :
variable latente réflexive

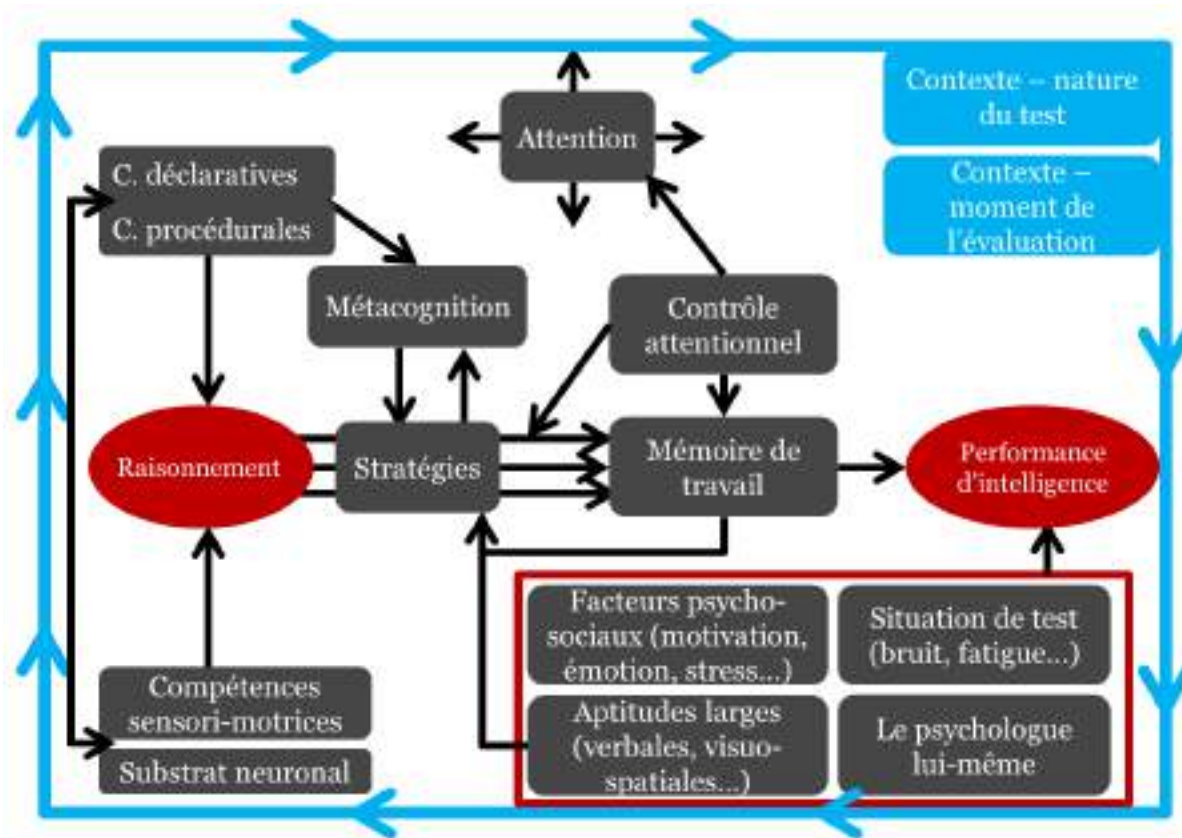


Constructivisme :
variable latente formative



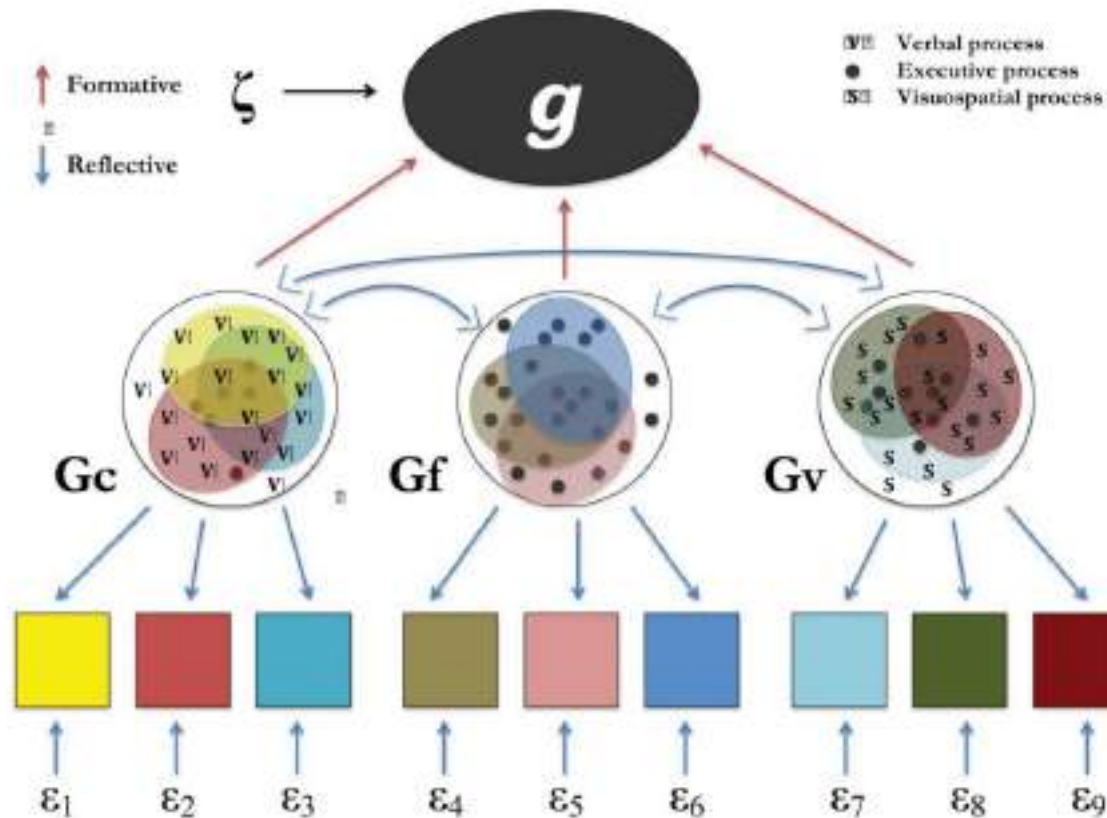
Variables formatives

L'intelligence comme propriété émergente d'un système de processus complexes en interaction dans un contexte donné :




Variables formatives

Process overlap theory (Kovacs & Conway, 2016)



Variables formatives

Dans un réseau : pas de variables latentes !



➤ Indécidabilité de la solution correcte ?

A single g factor is not necessary to simulate positive correlations between cognitive tests

Dennis J. McFarland

Laboratory of Neural Injury and Repair, Wadsworth Center, New York State Department of Health, Albany, NY, USA

In the area of abilities testing, one issue of continued dissent is whether abilities are best conceptualized as manifestations of a single underlying general factor or as reflecting the combination of multiple traits that may be dissociable. The fact that diverse cognitive tests tend to be positively correlated has been taken as evidence for a single general ability or "g" factor. In the present study, simulations of test performance were run to evaluate the hypothesis that multiple independent abilities that affect test performance in a consistent manner will produce a positive manifold. Correlation matrices were simulated from models using either one or eight independent factors. The extent to which these factors operated in a consistent manner across tests (i.e., that a factor that facilitates performance on one test tends to facilitate performance on other tests) was manipulated by varying the mean value of the randomly selected weights. The tendency of both a single factor and eight independent factors to produce positive correlations increased as the randomly selected weights operated in a more consistent fashion. Thus the presence of a positive manifold in the correlations between diverse cognitive tests does not provide differential support for either single factor or multiple factor models of general abilities.

Keywords: Abilities; Simulation; Positive manifold.

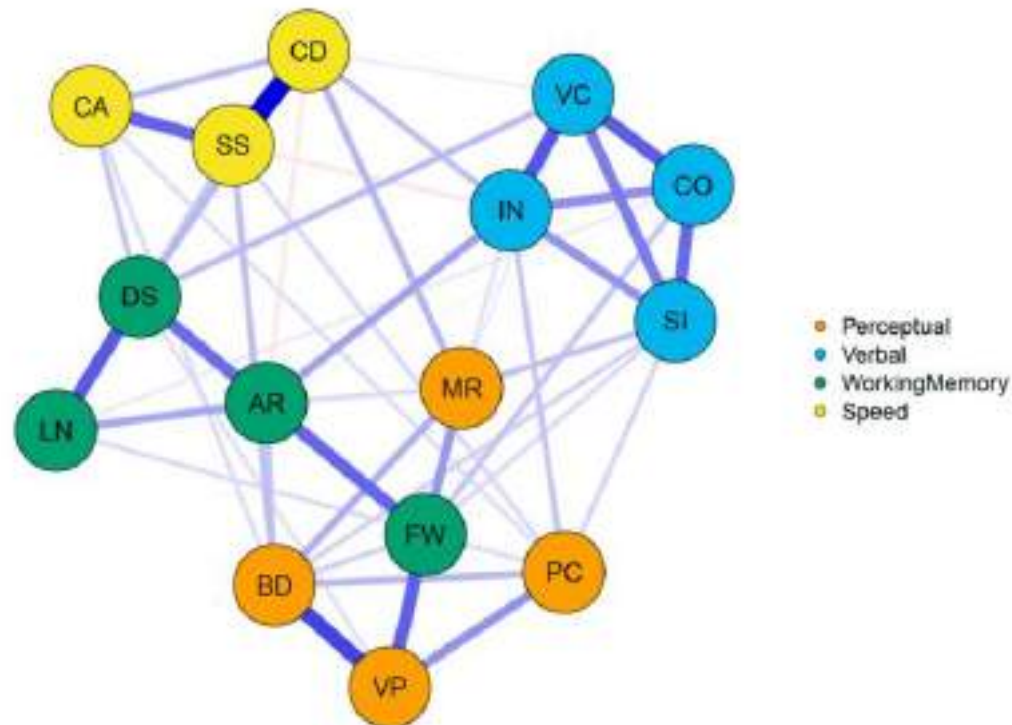
Variables formatives

Table 2. Results of the model comparisons based on analyses in software package Psychometrics.

Model	χ^2 (df)	p-Value	CFI	TLI	RMSEA [CI ₉₀]	AIC	BIC
Network	129.96 (52)	<0.001	0.99	0.99	0.037 [0.029–0.045]	36,848.56	37,189.51
Bifactor	263.41 (75)	<0.001	0.98	0.97	0.048 [0.041–0.054]	36,966.01	37,266.85
Measurement	369.47 (82)	<0.001	0.96	0.97	0.056 [0.050–0.062]	37,058.07	37,323.81
Hierarchical g	376.56 (84)	<0.001	0.97	0.96	0.056 [0.050–0.062]	37,061.16	37,316.87

Note: preferred model in bold.

The AIC and BIC values also suggested that among all models considered, the network model provided the best statistical summary, as it also outperformed the measurement model and the bifactor model. A graphical representation of the network model is given in Figure 2.




SEM vs réseau : que donne une variable latente dans le cas d'un réseau ?

Génération de données :


- 1 variable latente
- 10 variables manifestes ($r=.65$ avec la variable latente)

Variables formatives


Corrélations, `layout=averageLayout(a$graph, b$graph, c$graph)`



Corrélations partielles, `layout=averageLayout(a$graph, b$graph, c$graph)`




lasso EBIC, `lambda=1.5, layout=averageLayout(a$graph, b$graph, c$graph)`




Variables formatives


Réseau de corrélations, $\max\text{-max}(\text{graph})$




Réseau de corrélations partielles, $\max\text{-max}(\text{graph})$



glasso EBIC, $\lambda=0.5$, $\max\text{-max}(\text{graph})$



Variables formatives




SEM vs réseau : que donnent deux variables latentes
dans le cas d'un réseau ?

Génération de données :


- 2 variables latentes
- 10 variables manifestes ($r=.65$ avec la variable latente) x2

Variables formatives


CorrBates, averageLayout



Corrélations partielles, averageLayout




glasso EBIC, lambda=0.5, averageLayout




Variables formatives


Réseau de corrélations, max-max(graph)




Réseau de corrélations partielles, max-max(graph)



glasso EBIC, lambda=0.5, max-max(graph)



Variables formatives




La corrélation partielle entre deux variables peut-elle indiquer la quantité de processus spécifiques communs ?

Génération de données :


- 30 processus aléatoires (gaussiens)
- 10 variables, chacune formée de la somme de 5 processus communs
+ 10 processus pris au hasard

Variables formatives


Réseau de corrélations, $\max\text{-}\max(\text{graph})$



Réseau de corrélations partielles, $\max\text{-}\max(\text{graph})$




glasso EBIC, $\lambda=0.5$, $\max\text{-}\max(\text{graph})$




Variables formatives


Nombre de processus communs



Corrélations



glasso EBIC, lambda=1.5



Corrélation

vechs : $r = .98$

Corrélation

vechs : $r = .85$


Stabilité et généralisabilité

La généralisabilité

- La stabilité est l'un des principaux problèmes des analyses en réseaux
 - Manque fréquent de puissance statistique
 - Effets de suppression peu prévisibles et pas stables
 - Tendance à l'overfitting
- Solution partielle : analyse en bootstrap...
- ...mais quid de la répliquabilité dans un autre échantillon ?

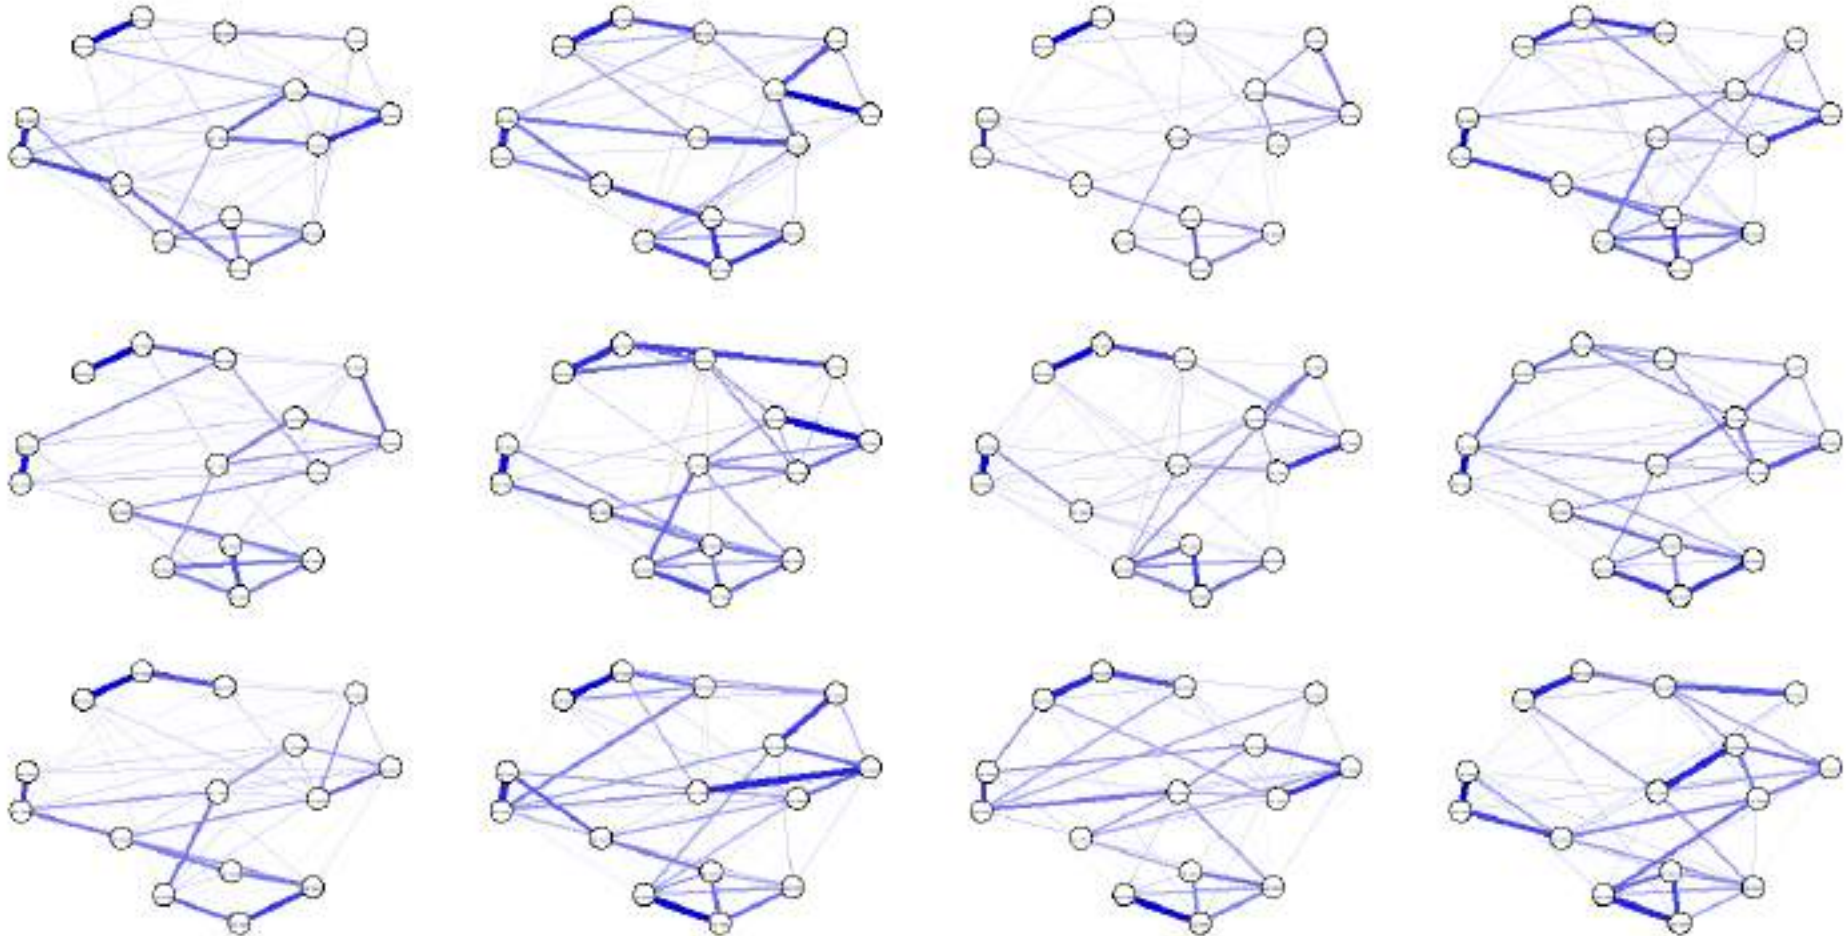
La généralisabilité

Simulations sur $N=50$ (tuning=0.2)




La généralisabilité

Simulations sur $N=100$




La généralisabilité

Simulations sur $N=200$



La généralisabilité

Simulations sur $N=1000$



La généralisabilité

- Qu'en est-il de la réplication des résultats dans des groupes différents avec des niveaux d'aptitude différents, passant la même version du test (même nœuds) ?
- Qu'en est-il de la généralisation des conclusions à des versions différentes du test (nœuds différents) ?

La généralisabilité

Quels indicateurs possibles ?

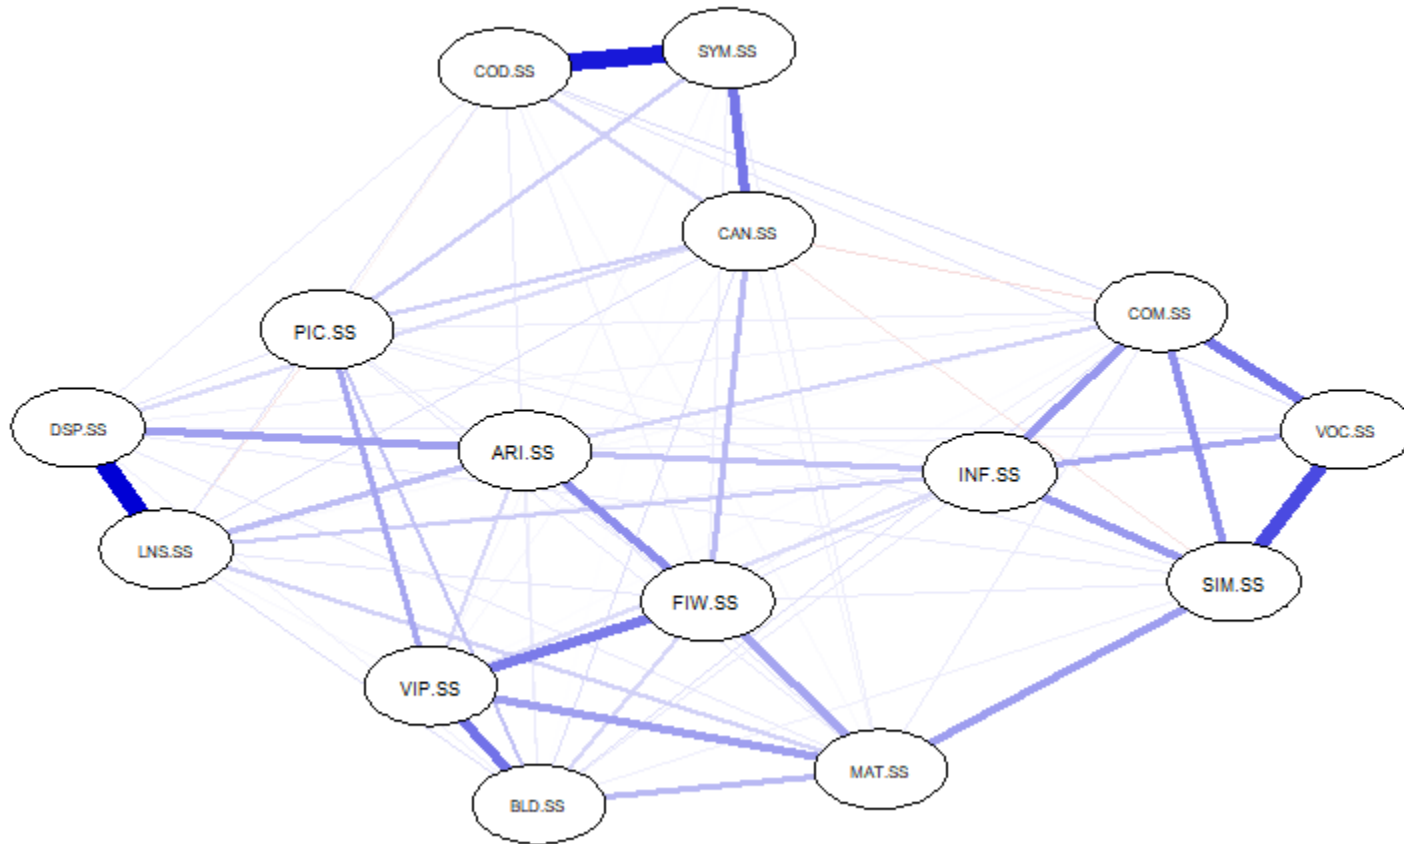
- Réplication sur groupes discrets :
 - Fused graphical lasso + Network comparison test
 - Corrélation entre matrices de poids (*coefficient de similarité*)

- Réplication à travers les valeurs d'une covariable :
 - Moderated network analysis

- Généralisation à une version différente du test :
 - Analyse de communauté
 - Différence d'indices de centralité pour les subtests en commun

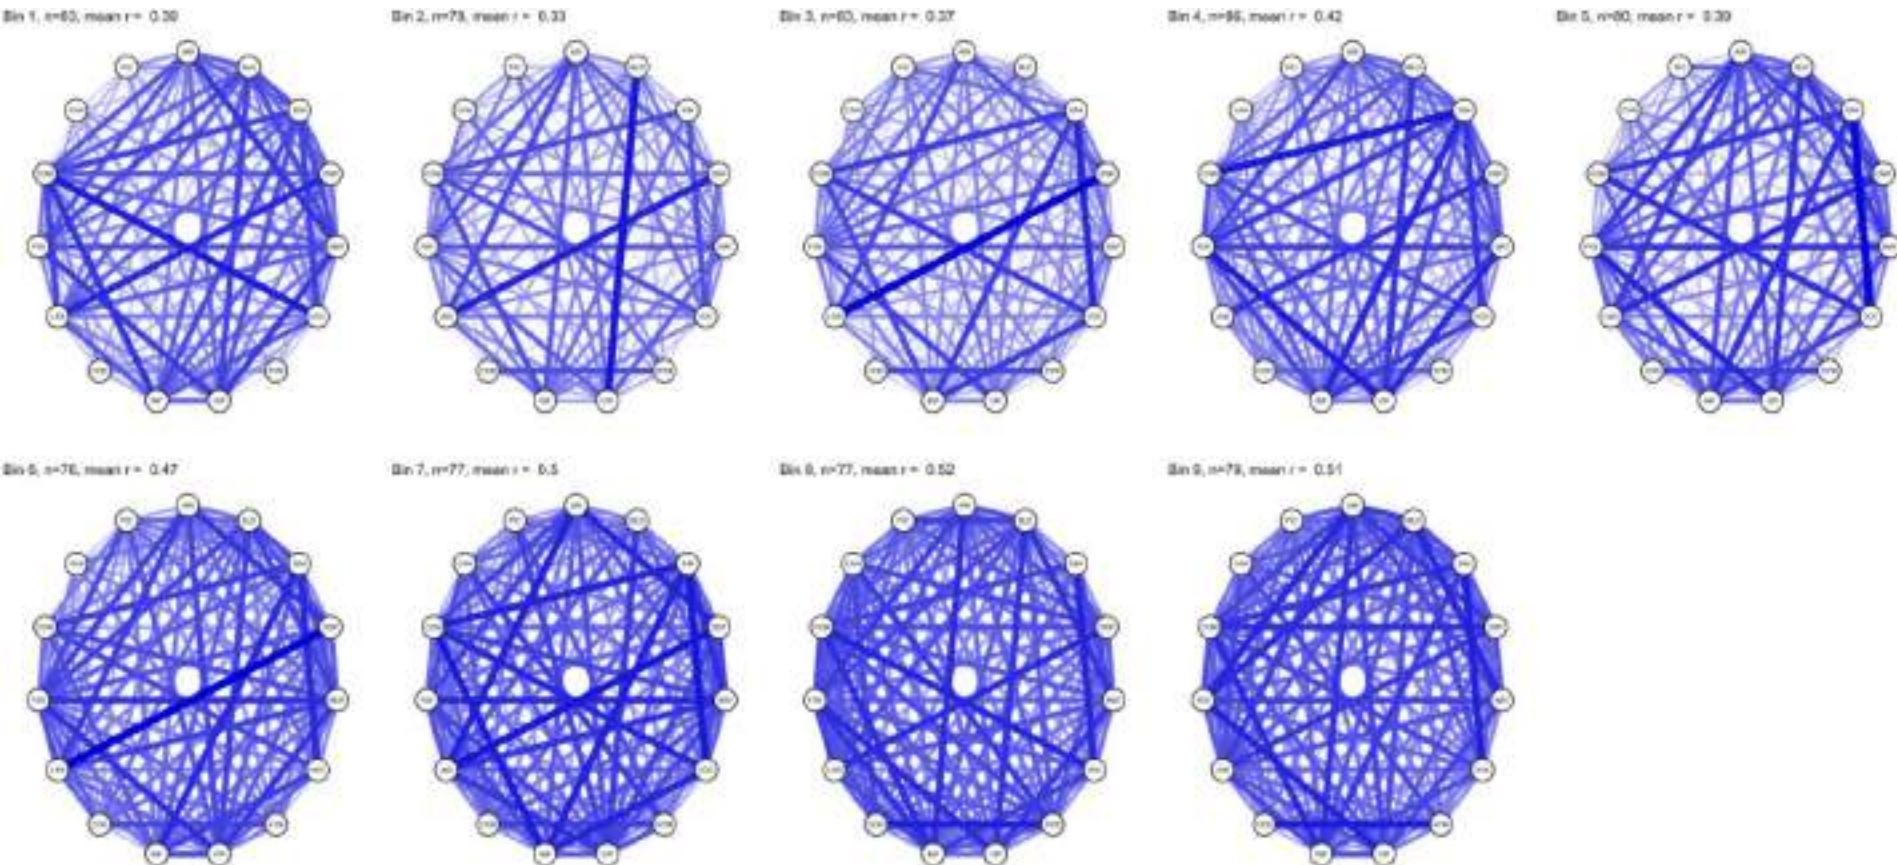
Un test de généralisabilité sur les échelles de Wechsler

WAIS4 (N=726)



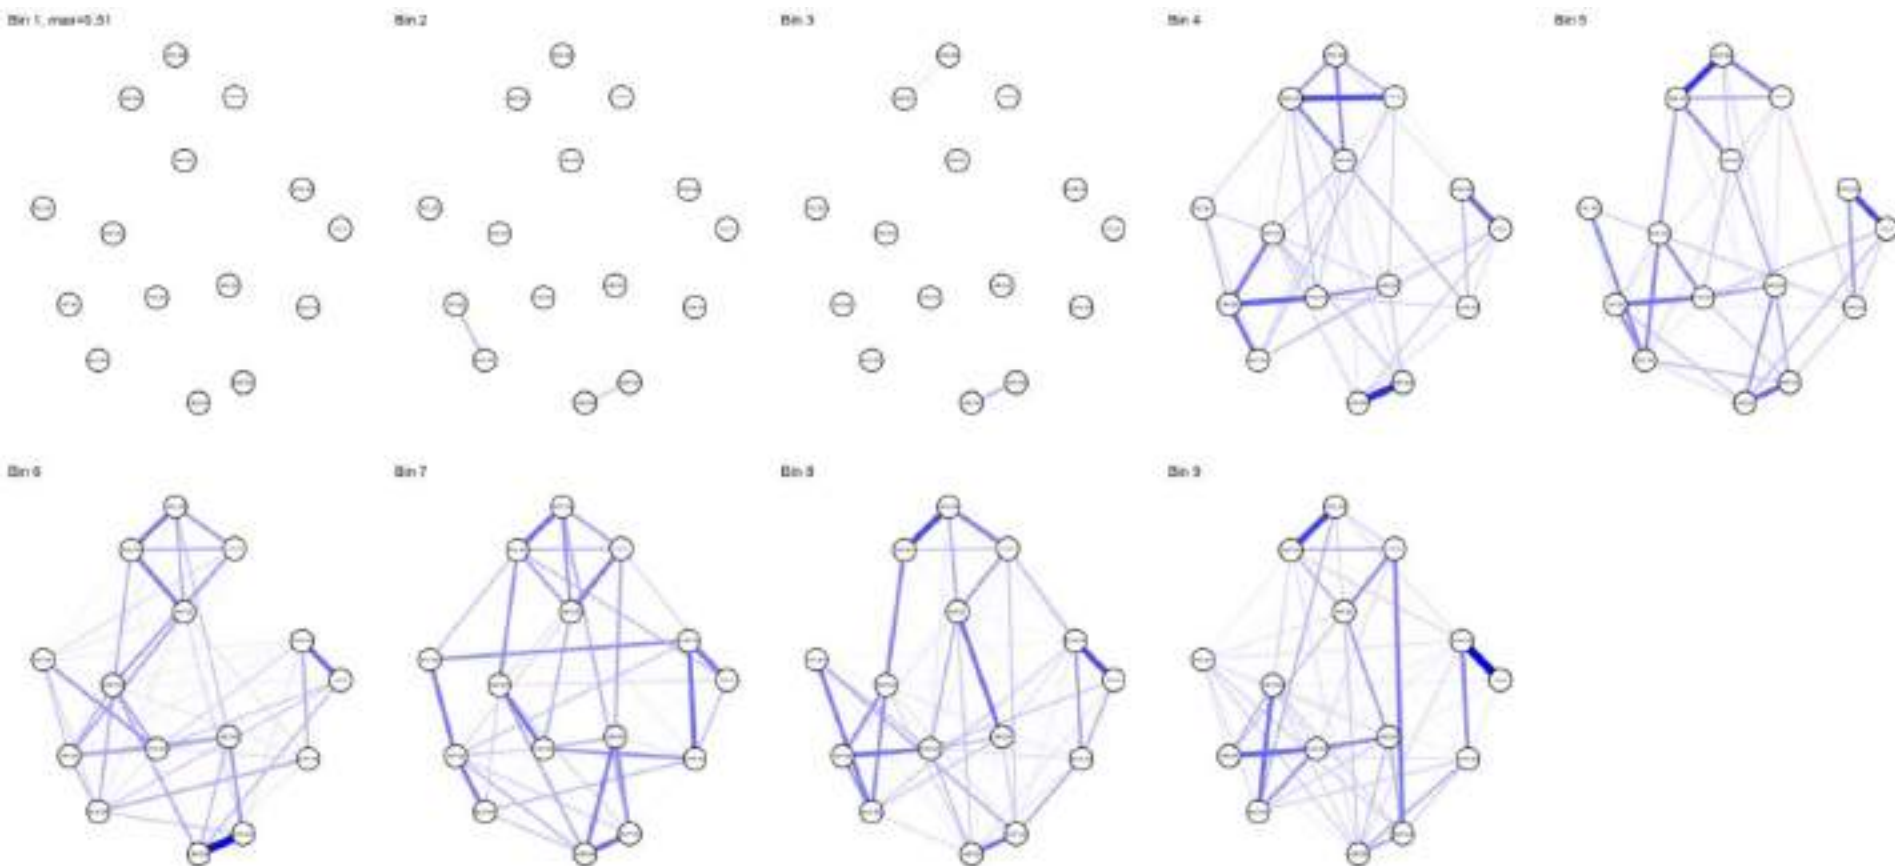
La généralisabilité

Réplication à travers les groupes d'âge ($N \sim 80$) :
réseaux de corrélations estimés séparément



La généralisabilité

Réplication à travers les groupes d'âge ($N \sim 80$) :
réseaux glasso-EBIC estimés séparément




La généralisabilité

Réplication à travers les groupes d'âge (N~80) :
corrélation entre les matrices de poids

`mean(vechs(corTable))`

$r = .61$



La généralisabilité

Réplication à travers les groupes d'âge (N~80) :
network comparison test (comparaisons locales)

```
NCT(WAIS4_1_00,
WAIS4_2_00,
test.edges = TRUE,
edges='all')
```

...x 9 groupes à comparer 2 à 2
... = 36 comparaisons (FWER)

→ % d'arêtes différentes

```
NETWORK INVARIANCE TEST
Test statistic M:  0.3396592
p-value 0.02

GLOBAL STRENGTH INVARIANCE TEST
Global strength per group:  6.173572 5.955143
Test statistic S:  0.2184285
p-value 0.72

EDGE INVARIANCE TEST
```

	Var1	Var2	p-value
16	ARI.SS	BLD.SS	0.64
31	ARI.SS	SIM.SS	0.16
32	BLD.SS	SIM.SS	0.12
46	ARI.SS	DSP.SS	0.42
47	BLD.SS	DSP.SS	0.20
48	SIM.SS	DSP.SS	0.24
61	ARI.SS	MAT.SS	0.00
62	BLD.SS	MAT.SS	0.82
63	SIM.SS	MAT.SS	0.50
64	DSP.SS	MAT.SS	0.94
76	ARI.SS	VOC.SS	0.58
77	BLD.SS	VOC.SS	0.30
78	SIM.SS	VOC.SS	0.72
79	DSP.SS	VOC.SS	0.06

La généralisabilité


Réplication à travers les groupes d'âge (N~80) :

network comparison test (valeurs p pour comparaisons globales)

	StructureInvariance	ConnectivityInvariance
[1,]	0.02	0.72
[2,]	0.84	0.30
[3,]	0.28	0.48
[4,]	0.76	0.06
[5,]	0.70	0.14
[6,]	0.52	0.38
[7,]	0.36	0.12
[8,]	0.50	0.28
[9,]	0.02	0.24
[10,]	0.66	0.12
[11,]	0.34	0.04
[12,]	0.08	0.06
[13,]	0.90	0.18
[14,]	0.46	0.06
[15,]	0.00	0.10
[16,]	0.82	0.62
[17,]	0.76	0.24
[18,]	1.00	0.72
[19,]	0.48	0.72
[20,]	0.34	0.90
[21,]	0.00	0.94
[22,]	0.56	0.08
[23,]	0.32	0.32
[24,]	0.44	0.90
[25,]	0.72	0.58
[26,]	0.04	0.38


La généralisabilité

Réplication à travers les groupes d'âge ($N \sim 80$) :
fused graphical lasso (FGL)



La généralisabilité

Réplication à travers les groupes d'âge ($N \sim 140$) :
fused graphical lasso (FGL)



La généralisabilité

Réplication avec l'âge comme covariable continue :

```
mgm(WAIS4, ruleReg="OR", moderators=1)
```

```
mgm_mod$interactions$indicator
```

```
[[2]]
      [,1] [,2] [,3]
[1,]    1    3    6
[2,]    1   12   16
```

```
showInteraction(object = mgm_mod, int = c(1,3,6))
```

Age-BLD-MAT

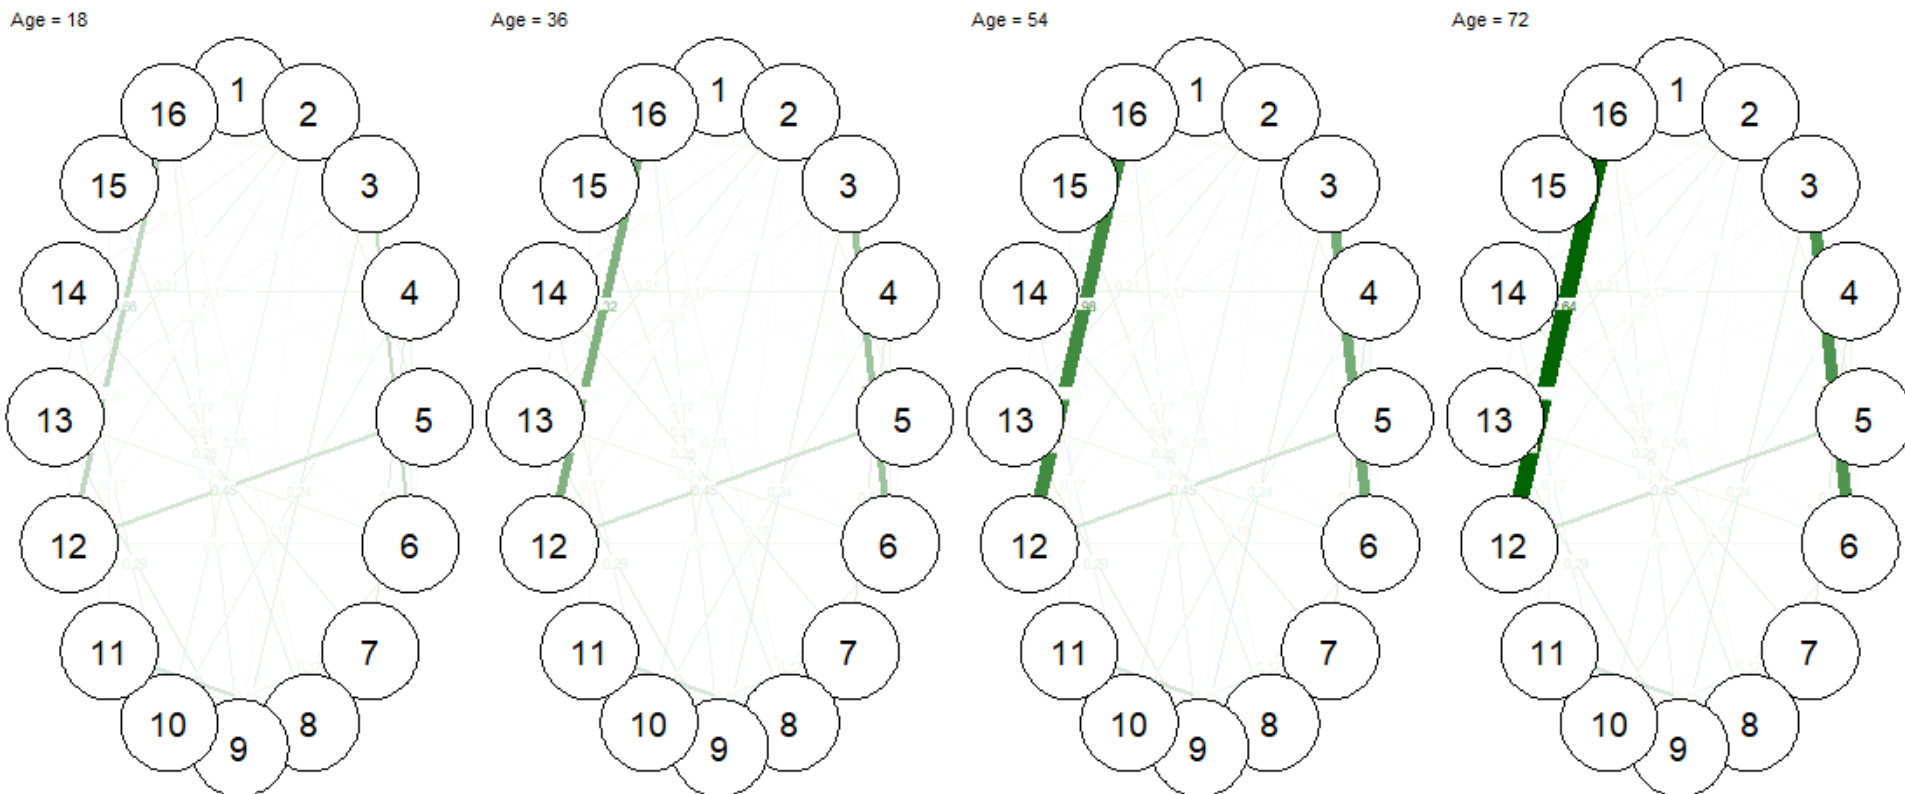
```
Interaction: 1-3-6
Weight: 0.01515795
Sign: 1 (Positive)
```

Age-LNS-PIC

```
Interaction: 1-12-16
Weight: 0.0244032
Sign: 1 (Positive)
```


La généralisabilité

Réplication avec l'âge comme covariable continue :
`condition(object = mgm_mod, values = list('1' = 18))...`



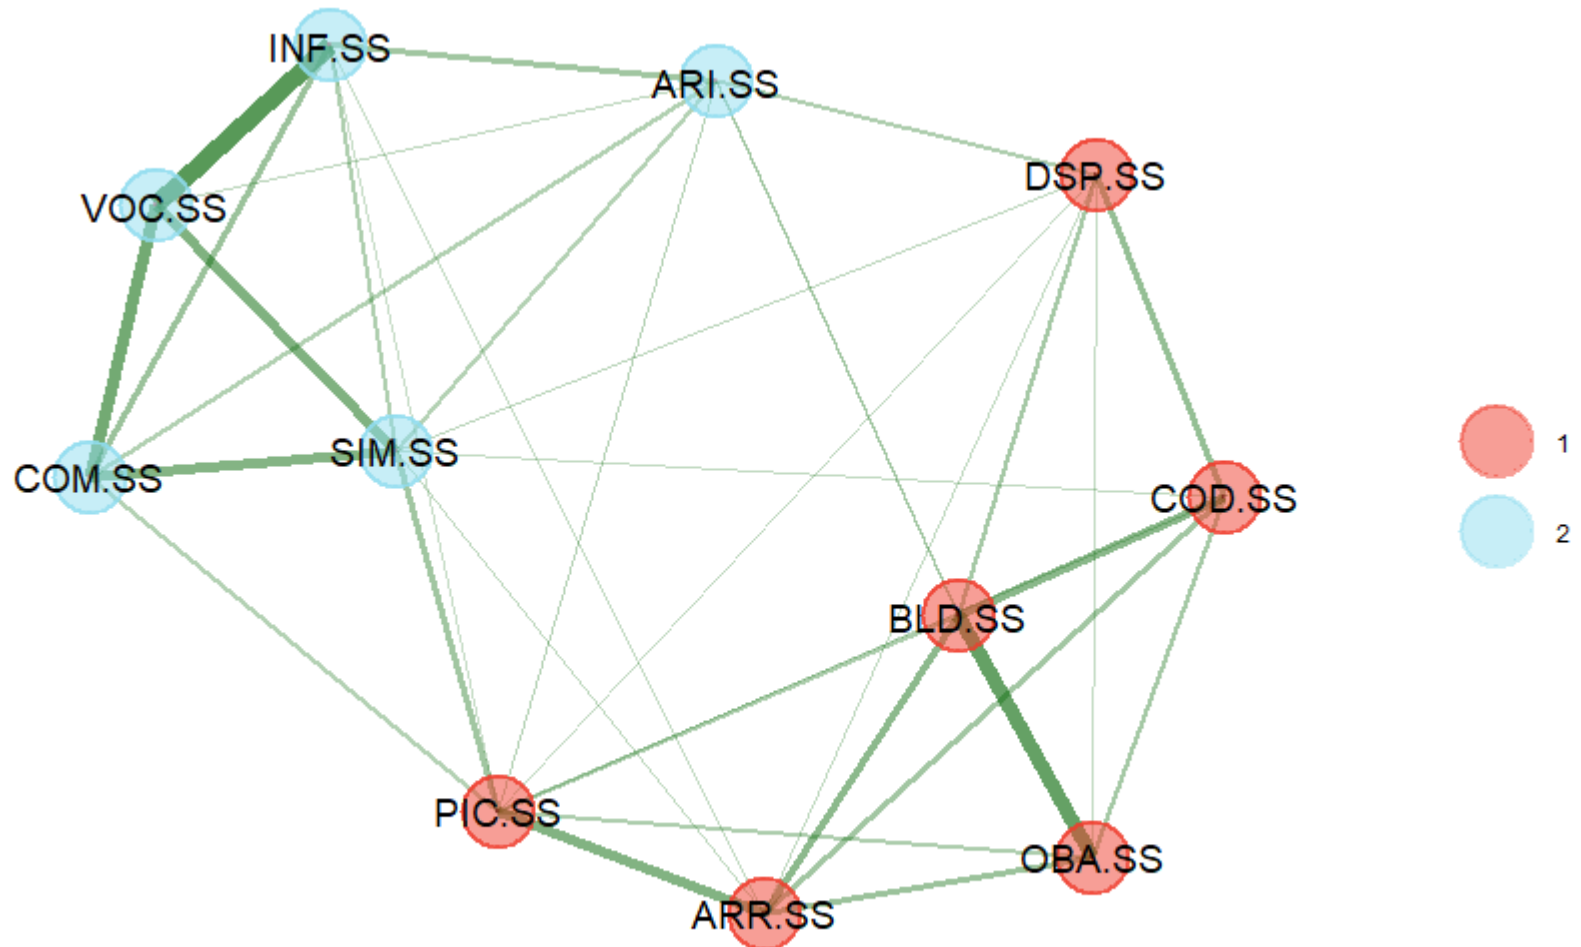
La généralisabilité

Généralisation à travers six versions de l'échelle



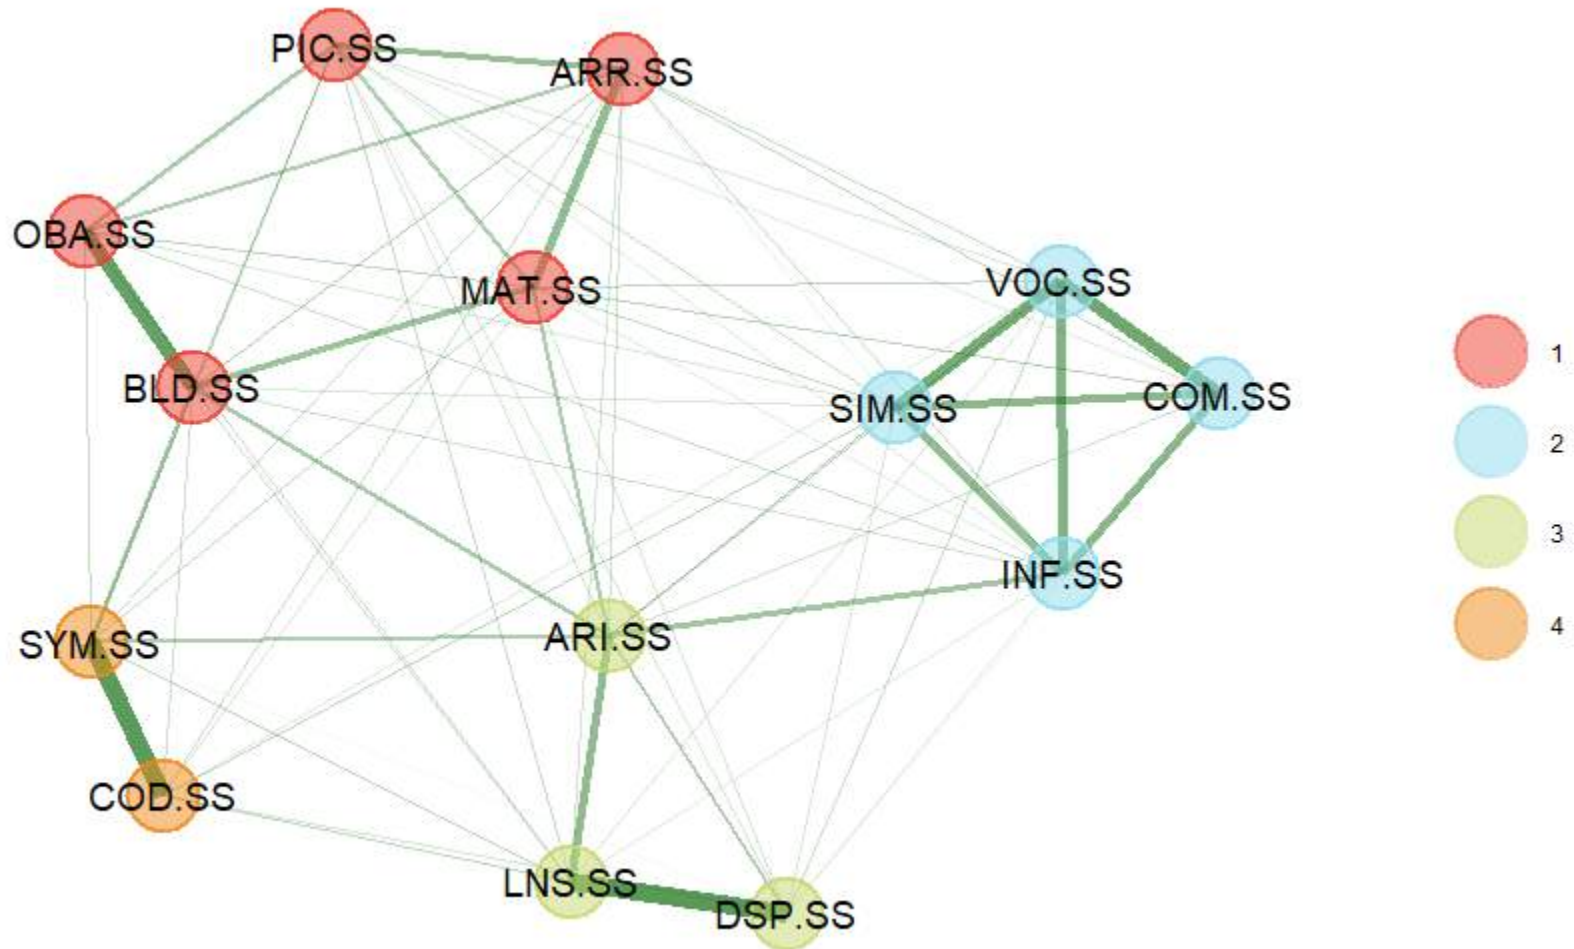
La généralisabilité

WAIS-R



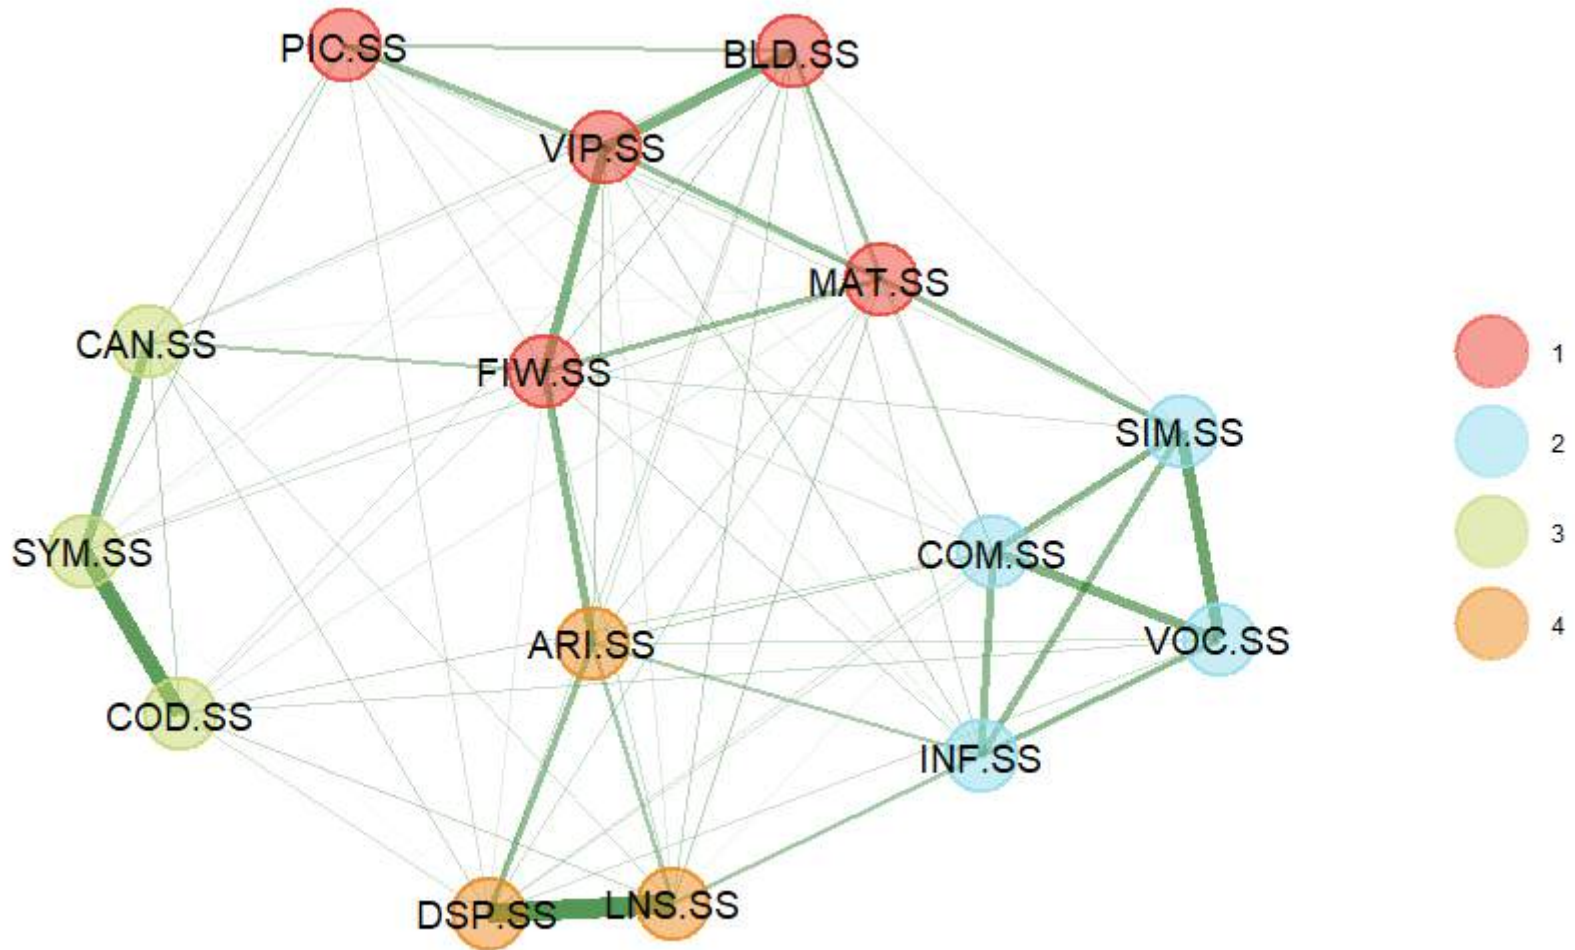
La généralisabilité

WAIS-III




La généralisabilité

WAIS-IV



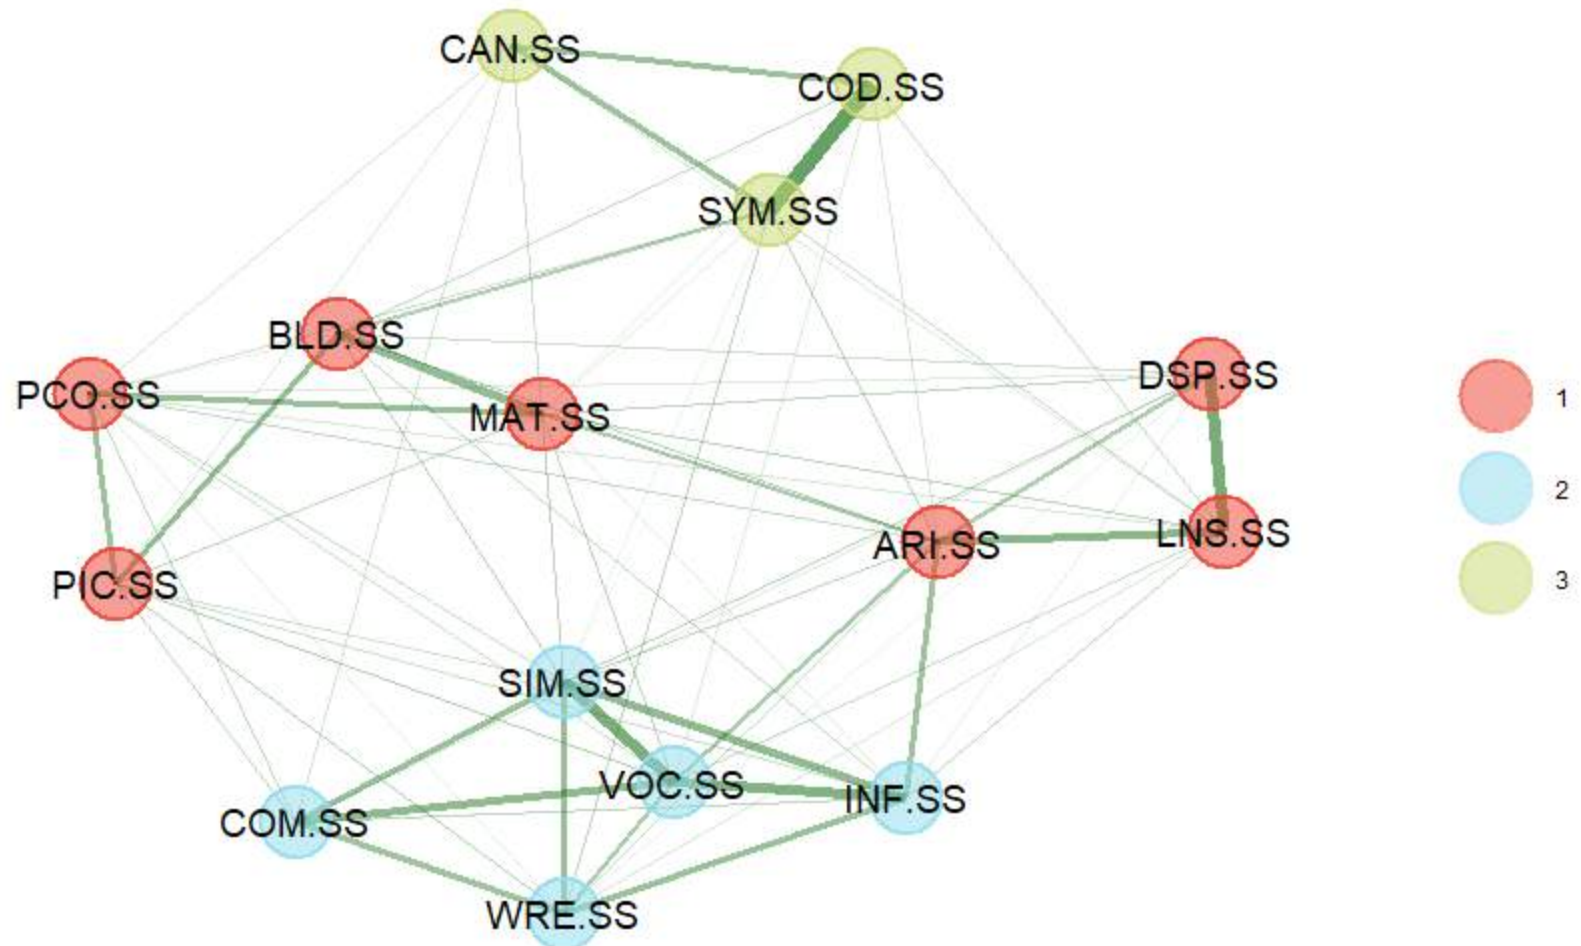
La généralisabilité

WISC-III



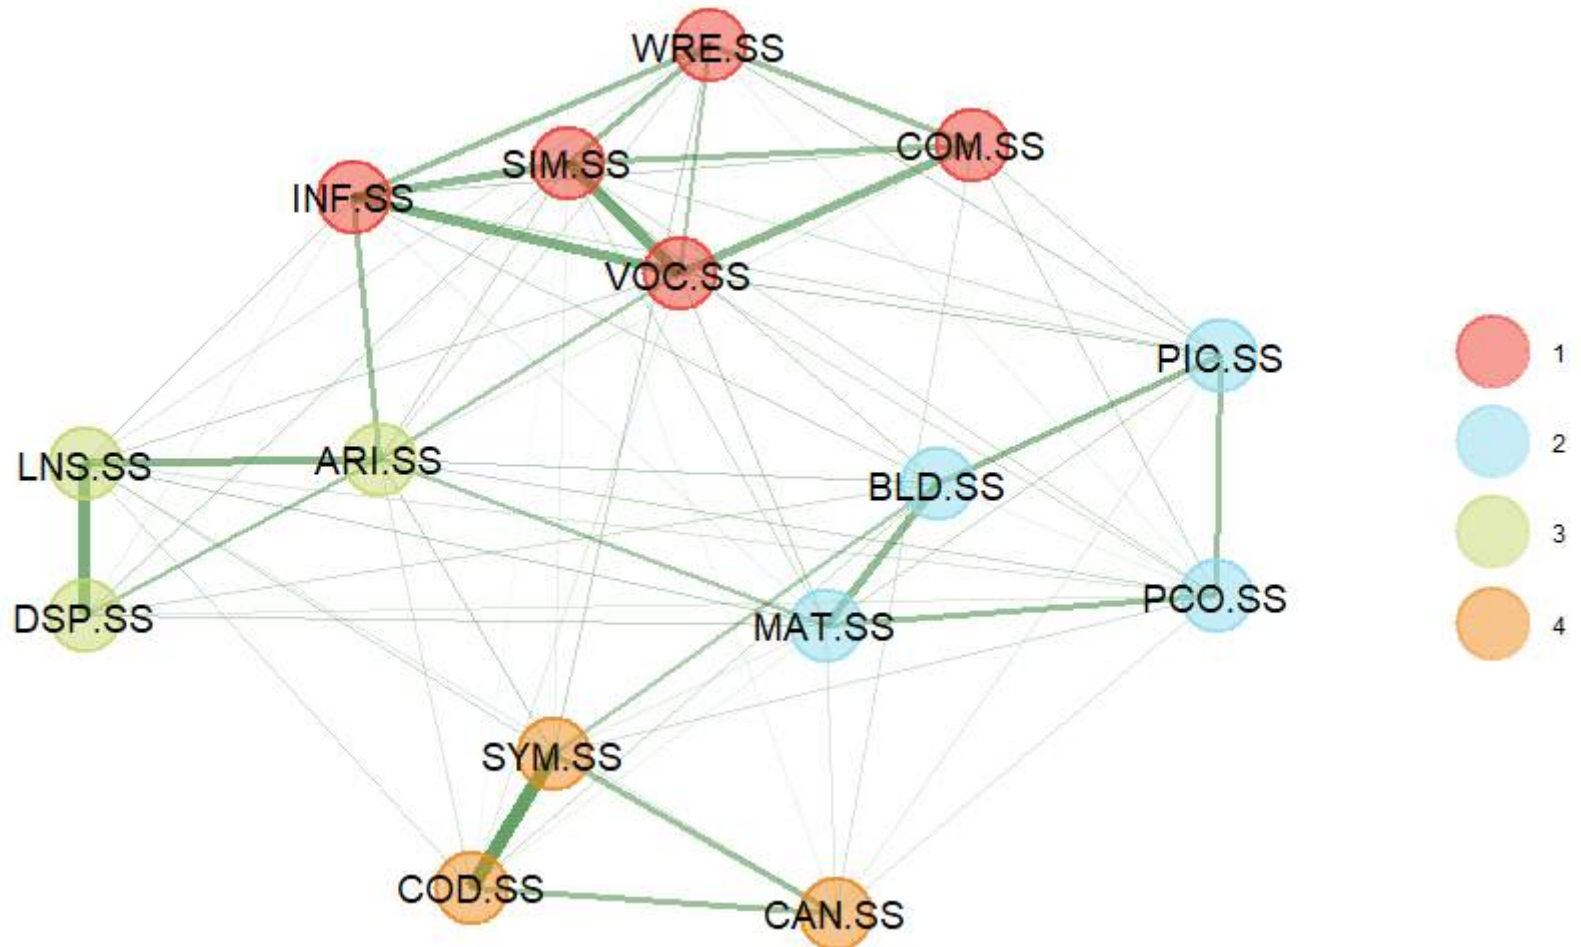
La généralisabilité

WISC-IV



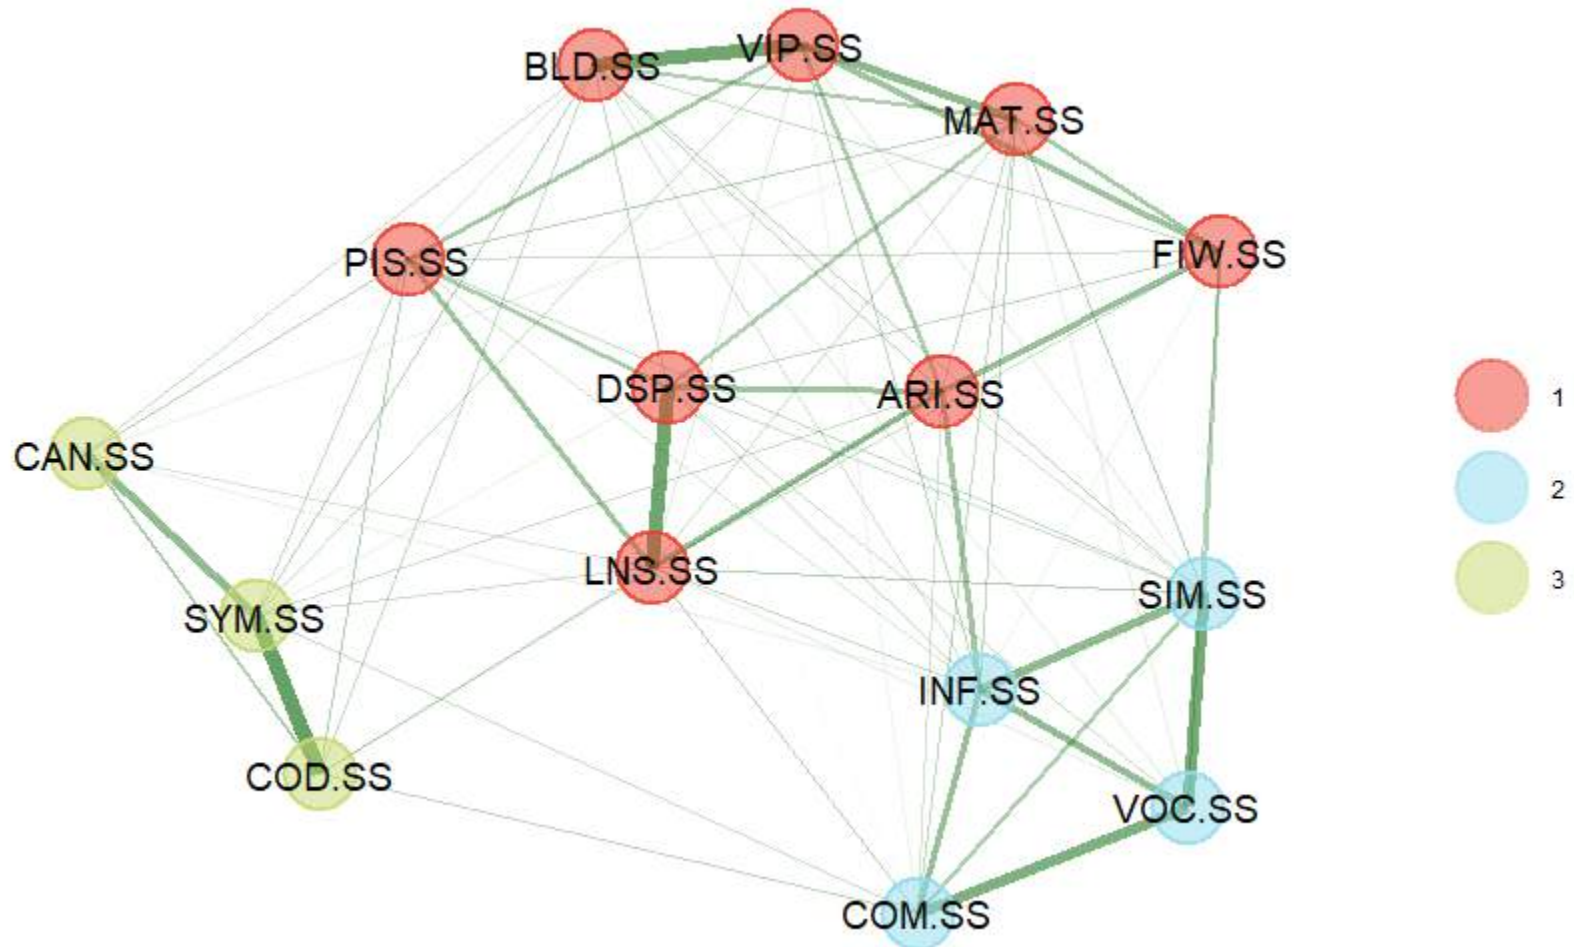
La généralisabilité

WISC-IV (louvain)



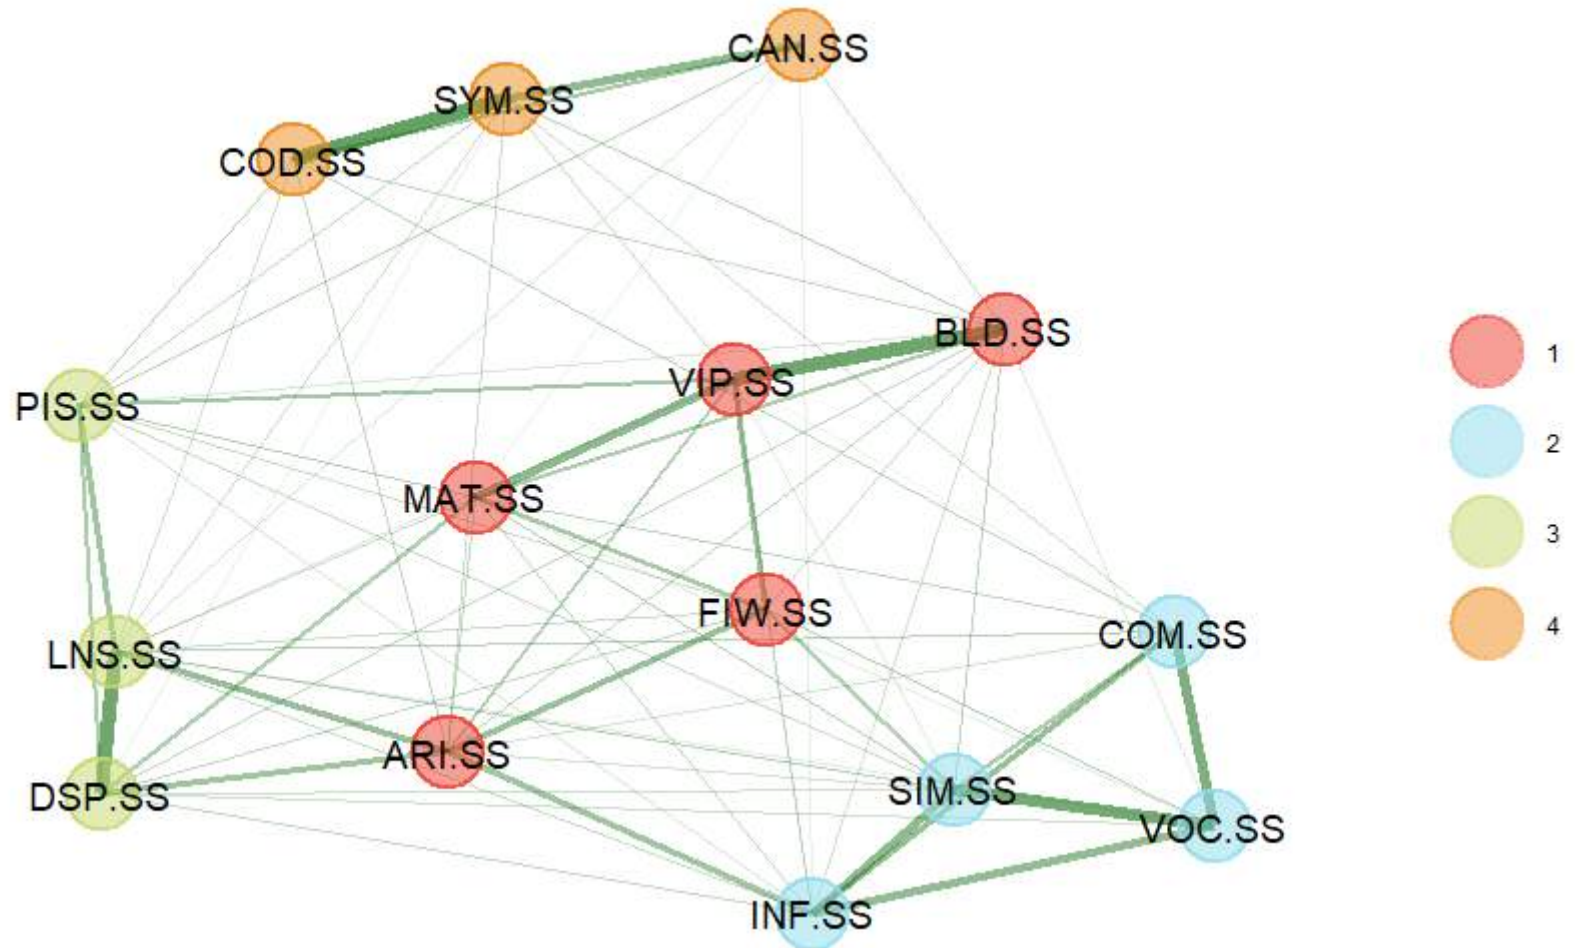
La généralisabilité

WISC-V



La généralisabilité

WISC-V (louvain)



La généralisabilité

Indices de centralité : strength centrality

Subtest	Strength-WAIS3	Strength-WAIS4	Strength-WAISR	Strength-WISC3	Strength-WISC4	Strength-WISC5
ARI.SS	0,82	-0,55	-1,39	0,38	1,03	0,73
ARR.SS	-0,42		-0,07	-0,23		
BLD.SS	1,27	-0,16	1,58	1,59	-0,25	0,07
CAN.SS		-0,53			-1,87	-2,62
COD.SS	-1,54	-1,28	-0,52	-0,85	-0,62	-0,80
COM.SS	0,16	0,96	-0,32	-0,15	-0,46	-0,59
DSP.SS	-1,31	0,09	-1,61	-1,54	-1,05	0,21
FIW.SS		1,34				-0,69
INF.SS	0,34	-0,16	0,38	0,66	0,83	0,64
LNS.SS	0,37	1,29			0,13	1,05
MAT.SS	-0,13	0,22			0,04	0,16
OBA.SS	-0,75		-0,04	-0,19		
PIC.SS	-1,38	-1,87	0,08	-0,46	-0,52	
PIS.SS						-0,75
SIM.SS	0,58	1,39	0,42	0,66	1,51	1,19
SYM.SS	0,16	-0,91		-0,12	0,26	-0,08
VIP.SS		0,81				1,20
VOC.SS	1,83	-0,64	1,51	1,70	1,89	0,29

	Strength.WAIS3	Strength.WAIS4	Strength.WAISR	Strength.WISC3	Strength.WISC4	Strength.WISC5
Strength.WAIS3	1.0000000	0.34414475	0.60111723	0.9165466	0.7545894	0.43546235
Strength.WAIS4	0.3441448	1.00000000	0.01849574	0.1829026	0.2104036	0.36159699
Strength.WAISR	0.6011172	0.01849574	1.00000000	0.8183967	0.4262451	0.09380151
Strength.WISC3	0.9165466	0.18290257	0.81839669	1.0000000	0.7236919	0.39556141
Strength.WISC4	0.7545894	0.21040355	0.42624513	0.7236919	1.0000000	0.75520600
Strength.WISC5	0.4354623	0.36159699	0.09380151	0.3955614	0.7552060	1.00000000

mean $r = .47$

Indices de centralité :

Betweenness centrality : mean $r = .30$

Closeness centrality : mean $r = .58$

Estimated influence : mean $r = .51$

