



Les récents développements de la modélisation par équations structurelles (SEM) : Cas de la régression des moindres carrés partiels (PLS)

Siham MOURAD

Professeure Habilitée à Diriger les Recherches-HDR
Laboratoire de Recherche en Management (LAREM)
Institut Supérieur de Commerce et d'Administration des Entreprises (ISCAE)

Badreddine GBAOUI

Doctorant
Laboratoire de Recherche en Management (LAREM)
Institut Supérieur de Commerce et d'Administration des Entreprises (ISCAE)

This is an open access article under the [CC BY-NC-ND](#) license.



Résumé : La régression des moindres carrés partiels (PLS) a historiquement démontré son efficacité dans les sciences de gestion. Plusieurs chercheurs font appel à cette méthode confirmatoire dans leurs études empiriques. Les étapes de la modélisation par équations structurelle de type PLS sont largement documentés dans la littérature managériale. Récemment, la méthode PLS a connu plusieurs développements théoriques et méthodologiques dans le modèle de mesure et le modèle structurel. L'objectif de cet article est d'examiner les nouvelles avancées de la régression des moindres carrés partiels (PLS).

Mots clés : SEM ; PLS; Développement ; Modèle de mesure ; Modèle structurel.

Abstract : Partial Least Squares (PLS) has historically proven its effectiveness in the management sciences. Many researchers use this confirmatory method in their empirical studies. The steps involved in PLS-SEM are widely documented in management literature. Recently, the PLS method has undergone several theoretical and methodological developments in the measurement and structural models. The aim of this article is to examine new advances in partial least squares (PLS).

Keywords: SEM ; PLS ; Development ; Measurement model ; Structural model

Digital Object Identifier (DOI): <https://doi.org/10.5281/zenodo.10810229>

1. Introduction

La modélisation par équations structurelles (SEM¹) est largement utilisée dans la détermination des relations entre les concepts (Karstadt et al, 2019). Les deux méthodes de la modélisation par equations structurelles sont l'approche basée sur la covariance (CB-SEM²) et l'approche basée sur la variance (PLS-SEM³) (Hair et al, 2022). L'approche basée sur la covariance (CB-SEM) tend à réduire la différence entre la matrice des covariances prédite à travers le modèle théorique et la matrice réelle afin de chercher un bon alignement (Haenlein et Kaplan, 2004). L'approche basée sur la variance (PLS-SEM), quant à elle, permet de maximiser la variance des variables exogènes en se basant sur le pouvoir explicatif des variables endogènes (Haenlein et Kaplan, 2004). La méthode PLS-SEM suit un processus itératif, à travers une régression des construits entre eux et sur leurs indicateurs, afin de retrouver le meilleur ajustement (Fernandes, 2012).

Le choix de la méthode CB-SEM ou PLS-SEM se fait à travers un ensemble de critères tels que (Hair et al, 2022 ; Fernandes, 2012 ; Sarstedt et al, 2019 ; Chin, 2010) : la distribution des données (non spécifiée pour PLS-SEM, distribution normale pour CB-SEM) ; la taille de l'échantillon (petite⁴ pour PLS-SEM, représentative pour CB-SEM) ; le nombre d'indicateurs par construit (élevé pour PLS-SEM, limité pour CB-SEM) ; la complexité du modèle (elevé pour PLS-SEM, faible pour CB-SEM) ; l'objectif de la recherche (exploratoire pour PLS-SEM ; confirmatoire pour CB-SEM) ; les relations récursives (non tolérées pour PLS-SEM ; tolérées pour CB-SEM) ; le pouvoir statistique (puissant pour PLS-SEM ; faible pour CB-SEM) et le traitement des construits d'ordre supérieur (spécifié dans PLS-SEM ; non spécifié dans CB-SEM).

Par conséquent, le constat est que l'utilisation de l'approche CB-SEM doit vérifier un ensemble de critères plus rigides que l'approche PLS-SEM. Dans ce sens, Jöreskog et Wold (1982 : p 270) qualifient l'approche CB-SEM de méthode « dure » et l'approche PLS-SEM de méthode « douce ». Dans cet article, nous nous focaliserons sur la méthode des moindres carrés partiels (PLS-SEM).

L'utilisation d'une modélisation par equations structurelles de type PLS a connu une augmentation exponentielle dans les sciences de gestion (Hair et al, 2022 ; Ali et al, 2018 ;

¹ Structural Equation Modeling

² Covariance Based Structural Equation Modeling

³ Partial Least Square Structural Equation Modeling

⁴ Il existe une taille minimale de l'échantillon à adopter dans PLS-SEM

Lohmöller, 1989). Depuis les premiers travaux pionniers de Hair et al (2012), la méthode PLS-SEM a connu plusieurs développements méthodologiques (Hwang et al., 2020 ; Dijkstra et Henseler, 2015 ; Sarstedt et al, 2016). Certains ont même suscité des controverses (Evermann et Rönkkö, 2023) comme les techniques de traitement de la validité discriminante (Henseler et al, 2015) ou la fiabilité du construit (Hair et al, 2022). Cependant, ces divergences ont permis de solidifier les différentes pratiques afin d'aboutir à une maturation de la méthode PLS SEM (Hair et al., 2020).

Dans cet article, nous commencerons par illustrer les différences entre les indicateurs formatifs et réflexifs. Par la suite, nous exposerons le modèle de mesure PLS SEM de chaque type d'indicateur. Après cela, nous présenterons les étapes du modèle structurel de PLS SEM. Enfin, nous expliquerons les deux principales méthodes de traitement des construits d'ordre supérieur. L'objectif de notre travail n'est pas de relater les différentes étapes de PLS SEM largement utilisées dans les sciences de gestion. Au contraire, nous examinerons les récents développement de PLS SEM qui seront répartis comme suit :

- Le modèle de mesure : le Rho A pour la fiabilité des construits (Dijkstra et Henseler, 2015) ; le HTMT pour la validité discriminante (Hensler et al, 2015) ; la technique de l'intervalle de confiance Bootstrap (Hair et al, 2022) ou l'intervalle de confiance corrigé de biais et accéléré (Efron, 1987) appliquées aux poids extérieurs des indicateurs formatifs ou au HTMT des indicateurs réflexifs ;
- Le modèle structurel : la méthode PLSpredict pour le pouvoir prédictif du modèle (Shmueli, 2016) ; la technique de l'intervalle de confiance Bootstrap (Hair et al, 2022) ou l'intervalle de confiance corrigé de biais et accéléré (Efron, 1987) utilisées pour les coefficients de chemins ;
- Les techniques de traitement des construits d'ordre supérieur : l'approche à indicateurs répétés et l'approche à deux stages (Becker et al, 2012 ; Ringle et al, 2012).

Tout au long de cette recherche, nous essaierons d'expliquer ces nouvelles techniques PLS SEM afin d'encourager plus de rigueur dans ce domaine.

2. Les indicateurs réflexifs et formatifs

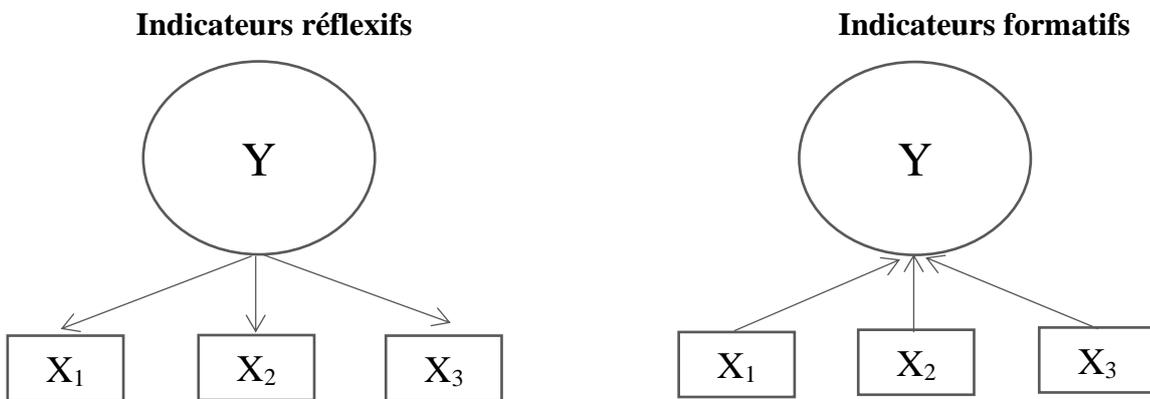
Les indicateurs formatifs sont une construction linéaire du concept. En d'autres termes, les liens de causalité vont des indicateurs vers le construit. L'une des caractéristiques des indicateurs formatifs est qu'ils ne sont pas interchangeables vu que chacun représente une facette du

concept. Par conséquent, les indicateurs ne sont forcément pas corrélés entre eux (Hair et al, 2022). Enfin, les instruments de mesure des indicateurs formatifs sont dénommés : indice de mesure (Hair et al, 2022).

En revanche, les indicateurs réflexifs sont une manifestation du construit (concept) (Hair et al, 2022). Dans cette typologie, les liens de causalité vont du construit vers ses items. Ainsi, les indicateurs sont, d'une façon générale, fortement corrélés entre eux (Hair et al, 2022). Les instruments de mesure réflexifs sont appelés : échelles de mesure (Hair et al, 2022).

La figure 1 permet d'illustrer les indicateurs réflexifs et formatifs.

Figure 1 : Les indicateurs réflexifs et formatifs



Source : Diamatopoulos et al (2008)

La distinction entre les mesures réflexives et formatives se fait selon plusieurs critères comme : le sens de causalité, l'interchangeabilité, la covariance et le réseau nomologique des indicateurs (Jarvis et al, 2004). En se basant sur ces critères, le tableau 1 fournit une comparaison entre les mesures réflexives et formatives :

Tableau 1 : La comparaison entre les mesures réflexives et formatives

Critères de comparaison	Mesures formatives	Mesures réflexives
Le sens de causalité	Des indicateurs vers le construit Les indicateurs sont des aspects du construit	Du construit vers les indicateurs Les indicateurs sont des manifestations du construit

	Des modifications dans les indicateurs amènent forcément à des modifications dans le construit	Des modifications dans les indicateurs n'amènent pas forcément à des modifications dans le construit
	Des modifications dans les indicateurs n'amènent pas forcément à des modifications dans le construit	Des modifications dans le construit amènent forcément à des modifications dans les indicateurs
L'interchangeabilité	Les indicateurs ne sont pas interchangeables	Les indicateurs sont interchangeables
	Les indicateurs ne partagent pas forcément un thème commun	Les indicateurs ont un thème commun
	Lorsqu'on supprime un indicateur, le domaine conceptuel du construit change forcément	Lorsqu'on supprime un indicateur, le domaine conceptuel du construit ne change pas
La covariance	Il n'est pas nécessaire que les indicateurs covarient entre eux	L'existence d'une covariance entre les indicateurs
Le réseau nomologique	Les indicateurs ne doivent pas nécessairement avoir les mêmes antécédents/conséquences	Les indicateurs devraient avoir les mêmes antécédents/conséquences

Source : Jarvis et al (2004)

La méthode PLS-SEM fait appel à deux principales évaluations : le modèle de mesure et le modèle structurel (Hair et al, 2022). Comme indiqué précédemment, les différences entre les indicateurs formatifs et réflexifs se basent sur des critères théoriques et méthodologiques. Cette distinction est aussi vérifiée dans les étapes du modèle de mesure. Par conséquent, avant d'entamer l'algorithme PLS-SEM, il est primordial de spécifier la nature des indicateurs : formatifs ou réflexifs.

3. Le modèle de mesure

Le modèle de mesure est une évaluation des relations entre les indicateurs et leurs construits (Hair et al, 2022). Dans ce qui suit, nous présenterons le modèle de mesure des indicateurs formatifs. Par la suite, nous exposerons le modèle de mesure des indicateurs réflexifs.

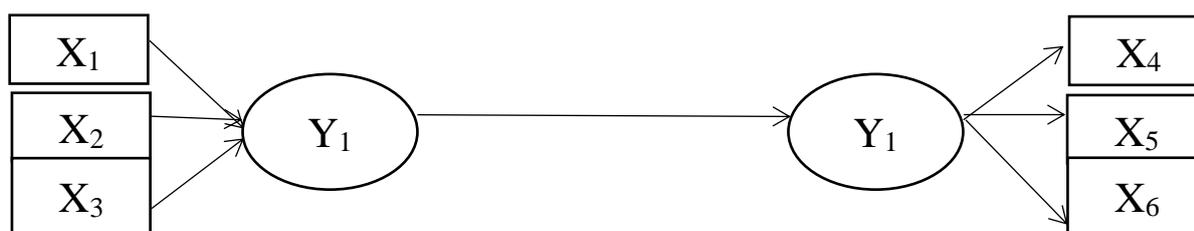
3.1 Le modèle de mesure des indicateurs formatifs

Pour évaluer le modèle de mesure des indicateurs formatifs, il est nécessaire d'apprécier la validité convergente, la colinéarité et les poids extérieurs (Hair et al, 2022).

3.1.1 La validité convergente

La validité convergente évalue le degré dans lequel les indicateurs formatifs expliquent la variance du construit (Hair et al, 2022). Pour cela, Chin (1998) recommande le recours à « une analyse de redondance ». Dans cette méthode, les indicateurs formatifs et leur construit sont reliés au même construit mais avec d'autres indicateurs de type réflexifs, d'où la qualification de « redondant ». Plus précisément, le construit avec des indicateurs formatifs est utilisé comme une variable explicative au construit ayant des indicateurs réflexifs (Cf figure 2) (Hair et al, 2022).

Figure 2 : L'analyse de redondance de la validité convergente des indicateurs formatifs



Source : Hair et al (2022)

La force de la relation indique la validité convergente du construit ayant des indicateurs formatifs (Hair et al, 2022). Dans ce sens, une valeur supérieure à 0,7 entre les deux construits démontre une validité convergente adéquate des indicateurs formatifs (Hair et al, 2022).

En entamant une analyse de redondance, il est nécessaire de spécifier le construit ayant des indicateurs réflexifs. Toutefois, l'utilisation d'un construit à plusieurs indicateurs réflexifs n'est pas toujours recommandé (Hair et al, 2022). En effet, les répondants se retrouvent avec des questionnaires consistants, ce qui peut entraîner des biais dans les réponses tels que des valeurs manquantes ou aberrantes (Hair et al, 2022). D'autant plus que les questions relatives aux indicateurs réflexifs ne constituent que des proxys nécessaires à l'évaluation de la validité convergente (Hair et al, 2022).

Afin d'entamer une analyse de redondance, il est possible d'utiliser des instruments de mesure réflexifs ayant fait l'objet de travaux antérieurs (Hair et al, 2022). Selon une autre approche, il

est aussi envisageable de produire une échelle avec un seul indicateur qui résume l'essence du construit (Sarsted et al, 2016). Afin d'y arriver, Cheah et al (2018) proposent les étapes suivantes :

- **Étape 1 : la génération de l'indicateur**

Dans cette étape, les chercheurs doivent choisir une définition théorique du concept. Par la suite, en se basant sur les échelles de mesure présentes dans la littérature, les chercheurs doivent sélectionner un seul indicateur représentatif du construit. Enfin, un groupe d'experts et des unités de la population cible peuvent vérifier la validité faciale de l'indicateur unique.

- **Étape 1 : la fiabilité de l'indicateur**

En s'appuyant sur les résultats de l'étape 1, les chercheurs doivent administrer un questionnaire avec à la fois l'indicateur choisi et une autre échelle de mesure avec plusieurs indicateurs du même construit. Ensuite, il est souhaitable que les résultats de la formule suivante soient supérieurs à 0,7 :

$$r_{xx} = r^2_{xy}/r_{yy}$$

Avec :

r_{xx} : l'estimation de la fiabilité de l'indicateur

r_{yy} : la fiabilité des indicateurs réflexifs de l'échelle de mesure

r_{xy} : la corrélation entre l'indicateur unique et le construit de l'échelle de mesure

- **Étape 3 : la validité convergente et de critères**

Afin d'évaluer la validité convergente, il faut vérifier la corrélation entre l'indicateur et l'échelle de mesure choisie lors de l'étape 2. Pour cela, une valeur supérieure à 0,7 est souhaitable.

En ce qui concerne la validité de critères, l'indicateur unique doit être suffisamment corrélé à un autre construit avec lequel il est censé être lié. Dans ce sens, la valeur de la relation n'est pas prédéfinie, cela dépend du construit choisi.

3.1.2 La colinéarité

La colinéarité fait référence au degré dans lequel deux indicateurs ou plus sont corrélés. La présence de colinéarité peut s'avérer problématique dans le sens où l'interprétation des données peut être confuses (Hair et al, 2022). Afin de détecter le degré de colinéarité, l'utilisation du facteur d'inflation de la variance (VIF⁵) est recommandé (Hair et al, 2022). Sa formule de calcul est présentée comme suit :

⁵ Varianc Inflation Factor

VIF_x = 1/ Tolérance x

Avec :

Tolérance x : la part de la variance non expliquée d'un indicateur par le reste des indicateurs du même construit

Afin de vérifier l'inexistence totale d'une colinéarité entre les indicateurs formatifs, Hair et al (2022) recommandent que les valeurs du VIF soient inférieures à 3.

Dans le cas où le VIF est supérieur à 3, l'une des solutions envisageables est la suppression d'un indicateur. Par ailleurs, les indicateurs restants doivent suffisamment couvrir le contenu du construit (Hair et al, 2022). Une deuxième solution est de remplacer les deux indicateurs par leurs moyennes. Cependant, cette option peut créer une confusion entre les domaines conceptuels des indicateurs substitués (Hair et al, 2022).

3.1.3 Le poids extérieur des indicateurs formatifs

Le poids extérieur permet de mesurer le degré de pertinence des indicateurs formatifs envers leurs construits (Hair et al, 2022). Techniquement, le poids extérieur des indicateurs résulte d'une régression linéaire multiple où les construits sont considérés comme des variables endogènes et les indicateurs formatifs comme des variables exogènes (Hair et al, 2019a).

En tant que méthode statistiquement fiable, Hair et al (2022) recommandent l'utilisation du bootstrap afin de juger si les indicateurs formatifs ont des poids extérieurs convenables. Cette technique statistique divise l'échantillon en plusieurs sous échantillons tirés au hasard. Par la suite, chaque sous échantillon est utilisé dans le modèle jusqu'à ce qu'un nombre aléatoire, généralement 10 000, soit créé. En utilisant cette méthode, un intervalle de confiance bootstrap est déterminé selon un niveau de confiance (généralement 95% avec un seuil de signification de 5%). Dans le cas où l'intervalle de confiance ne contient pas la valeur 0, l'indicateur formatif a un poids significatif (Hair et al, 2022).

Comme défaut, l'intervalle de confiance bootstrap ne tient pas compte des tailles de l'échantillon et de la distribution des paramètres. Quand la taille minimale⁶ de l'échantillon n'est pas respectée ou que la distribution des paramètres est fortement asymétrique⁷, Hair et al

⁶ La taille minimale peut être déterminée par la table de Hair et al (2017, p 48) qui se base sur les travaux de Cohen (1988,1992).

⁷ Le Skewness est un indice qui permet de juger si les données suivent une loi normale. Généralement, les valeurs comprises entre -1 et +1 indiquent que les données sont *presque* symétriques. Les valeurs entre -2 et +2 sont dans limite acceptables. Les valeurs en dehors de l'intervalle -2 et +2 indiquent une asymétrie significative des données (Hair et al, 2022, p 66).

(2022) encouragent l'utilisation de l'intervalle de confiance bootstrap corrigé de biais et accéléré (BCa⁸) de Efron (1987). Dans ce sens, les règles d'interprétation sont similaires à celles de l'intervalle de confiance bootstrap (Hair et al, 2022).

Dans le cas où les poids extérieurs sont jugés non significatifs, il est nécessaire de vérifier leurs contributions absolues au construit, d'où l'intérêt d'utiliser la charge extérieure de l'indicateur ou plus communément appelée le loading (Hair et al, 2022). Lorsque le poids extérieur est non significatif mais que le loading dépasse le seuil de 0,5, l'indicateur devrait être retenu. Dans le cas contraire, l'indicateur peut être supprimé si théoriquement, il est sans importance. Si la conceptualisation théorique⁹ du construit soutient l'indicateur, il doit être conservé (Cenfetelli et Bassellier, 2009).

Contrairement aux loadings des indicateurs réflexifs, les poids extérieurs diminuent avec le nombre d'indicateurs. En d'autres termes, chaque fois que le nombre d'indicateurs formatifs augmente, il est probable que leurs poids extérieurs soient faibles et donc non significatifs. Par conséquent, la mesure formative du construit ne doit pas dépasser un certain nombre d'indicateur (Cenfetelli et Bassellier, 2009).

Le tableau 2 résume les différentes étapes du modèle de mesure PLS-SEM avec des indicateurs formatifs.

Tableau 2 : les étapes du modèle de mesure PLS-SEM avec des indicateurs formatifs

Étape du modèle de mesure	Critère	Condition d'acceptation	Références
Validité convergente	Analyse de redondance	Force de la relation > 0,7 → Rétention des indicateurs Force de la relation < 0,7 → Suppression des indicateurs	

⁸ Bias Corrected and Accelerated

⁹ La validité du contenu

Colinéarité	VIF	<p>< 3 Rétention des indicateurs</p> <p>> 3 :</p> <p>Solution 1 : Suppression d'un indicateur si le contenu du construit est largement représenté.</p> <p>Solution 2 : Remplacement des deux indicateurs par leurs moyennes si cela ne favorise pas une confusion des domaines conceptuels.</p>	(Hair et al, 2022)
Poids extérieurs	Bootstrap	<p>L'intervalle de confiance (ou BCa) ne contient pas la valeur 0 → Rétention de l'indicateur</p> <p>L'intervalle de confiance (ou BCa) contient la valeur 0 :</p> <p>Si la charge extérieure (Loading) > 0,5 → Rétention de l'indicateur</p> <p>Si la charge extérieure (Loading) < 0,5 → Rétention de l'indicateur dans le cas où il est théoriquement représentatif</p> <p>Si la charge extérieure (Loading) < 0,5 → Suppression de l'indicateur dans le cas où il est théoriquement non représentatif</p>	

Source : Elaboration personnelle

3.2 Le modèle de mesure des indicateurs réflexifs

Afin d'évaluer les modèles de mesure réflexifs, Hair et al (2022) recommandent, dans un premier temps, la vérification de la fiabilité des indicateurs (Loadings) et des construits. Par la suite, ces mêmes auteurs préconisent de s'assurer de la validité convergente et discriminante des construits (Hair et al, 2022).

3.2.1 La fiabilité des indicateurs ou loadings

Les loadings¹⁰ correspondent aux charges factorielles des indicateurs sur les construits. Lorsqu'ils sont élevés, cela indique que les indicateurs partagent une communalité avec le

¹⁰ Les loadings peuvent aussi être appelés « Outer loadings »

construit (Hair et al, 2022). La règle générale est que les indicateurs doivent avoir un loading supérieur ou égal à 0,708. Le choix de ce chiffre peut être expliqué par la variance de l'indicateur qui correspond au carré du loading. Dans ce sens, il est généralement nécessaire d'avoir une variance minimale de 50% qui équivaut au carré de 0,708 (Hair et al, 2022). Dans la pratique, les chercheurs considèrent 0,7 comme acceptable (Hair et al, 2022).

D'une façon générale, les travaux de recherche dans les sciences de gestion obtiennent un loading inférieur à 0,7. Dans ce cas de figure, les indicateurs ayant un loading entre 0,4 et 0,7 ne devraient être supprimés que si cela entraîne une augmentation de la fiabilité et de la validité du construit (discutées dans les paragraphes suivants) au-dessus des seuils préconisés (Hair et al, 2022). Une deuxième considération avant la suppression de l'indicateur est la validité du contenu¹¹. À contrario, les indicateurs ayant un loading en dessous de 0,4 sont automatiquement à éliminer (Bagozzi et al, 1991).

3.2.2 La fiabilité du construit

La fiabilité indique le niveau dans lequel le construit permet d'obtenir la « vraie » valeur du phénomène étudié (Hair et al, 2019a).

Traditionnellement, l'alpha de Cronbach (α) est un indice de fiabilité qui se base sur les corrélations entre les indicateurs (Hair et al, 2022). Sa formule de calcul est présentée comme suit :

$$\alpha = \frac{k\bar{r}}{1 + (k - 1)\bar{r}}$$

Avec :

\bar{r} : la corrélation moyenne entre les indicateurs

k : le nombre d'indicateurs du construit

L'alpha de Cronbach est largement utilisé dans la recherche. Cependant, cet indice a démontré plusieurs limites. Premièrement, l'alpha de Cronbach suppose que tous les indicateurs possèdent les mêmes loadings. Deuxièmement, cet indice est sensible au nombre d'indicateurs (Hair et al, 2022). Ainsi, Hair et al (2022) stipulent que l'alpha de Cronbach peut sous évaluer la fiabilité du construit.

Afin de combler les limites de l'alpha de Cronbach, les chercheurs utilisent l'indice de « fiabilité composite (ρ_c) » qui est calculé en suivant la formule suivante :

¹¹ Le degré dans lequel les indicateurs reflètent le construit

$$\rho_c = \frac{\left(\sum_{i=1}^M l_i\right)^2}{\left(\sum_{i=1}^M l_i\right)^2 + \sum_{i=1}^M \text{var}(e_i)},$$

Avec :

l_i : les loadings des indicateurs

e_i : l'erreur de mesure de l'indicateur

Var (e_i) : la variance de l'erreur de mesure de l'indicateur

Contrairement à l'alpha de Cronbach qui est jugé comme conservateur, la fiabilité composite est assez libérale. Cet indice peut surévaluer la fiabilité du construit (Hair et al, 2022). Ainsi, la fiabilité exacte se situe entre l'alpha de Cronbach et la fiabilité composite (Hair et al, 2022). Dans ce sens, Dijkstra et Henseler (2015) ont proposé l'indice de fiabilité ρ_A qui est calculé comme suit :

$$\rho_A = (\hat{w}'\hat{w})^2 \cdot \frac{\hat{w}'(S - \text{diag}(S))\hat{w}}{\hat{w}'(\hat{w}\hat{w}' - \text{diag}(\hat{w}\hat{w}'))\hat{w}},$$

Avec :

\hat{w} : le vecteur des loadings estimés des indicateurs

\hat{w}' : le vecteur transposé de \hat{w}

$\hat{w}\hat{w}'$: la matrice résultante du produit de \hat{w} avec son vecteur transposé

S : la matrice de covariance empirique des indicateurs de la variable latente

Diag(S) : la diagonale de la matrice de covariance empirique des indicateurs de la variable latente

Diag($\hat{w}\hat{w}'$) : la diagonale de la matrice ($\hat{w}\hat{w}'$)

$\hat{w}'\hat{w}$: le produit scalaire du transposé de \hat{w}

L'indice de fiabilité (ρ_A) se situe généralement entre l'alpha de Cronbach et la fiabilité composite. De ce fait, il est considéré comme un bon compromis entre l'alpha de cronbach, jugé comme conservateur et la fiabilité composite en tant qu'indice libéral (Hair et al, 2019b). En général, les indices de fiabilité du construit doivent être supérieurs à 0,6 pour une recherche exploratoire et supérieurs à 0,7 pour une recherche confirmatoire (Hair et al, 2022).

3.2.3 La validité convergente

La validité convergente correspond à la mesure dans laquelle le construit explique la variance de ses indicateurs réflexifs (Hair et al, 2022). Le principal indice pour mesurer la validité convergente est la variance moyenne extraite (AVE¹²) (Fornell et Lacker, 1988). Sa formule de calcul est définie comme suit :

$$AVE = \left(\frac{\sum_{i=1}^M l_i^2}{M} \right),$$

l_i : les loadings des indicateurs

M : le nombre total d'indicateurs du construit

La variance moyenne extraite (AVE) doit avoir une valeur supérieure ou égale à 0,5 pour que la validité convergente soit admise (Hair et al, 2022). Ainsi, on peut dire que le construit explique plus de 50% de la variance de ses indicateurs.

3.2.4 La validité discriminante

La validité discriminante indique le degré dans lequel un construit mesure, d'une façon unique, un phénomène (Hair et al, 2022).

L'indice majoritairement utilisé pour déterminer la validité discriminante est celui de Fornell et Larcker (1981). Ce critère permet de vérifier si la racine carrée de la variance moyenne extraite de chaque construit est supérieure à sa corrélation la plus élevée avec les autres construits. Par ailleurs, les travaux de Henseler et al (2015) ainsi que ceux de Franke et Sarstedt (2019) ont démontré que le critère de Fornell et Larcker (1981) n'est pas efficace lorsque les valeurs des loadings se situent entre 0,6 et 0,8. Par conséquent, les chercheurs ne peuvent se fier à l'indice de Fornell et Larcker (1981) afin de déterminer la validité discriminante (Radomir et Moisescu, 2019).

Selon les travaux de Chin (1998), un deuxième indice appelé « Cross loading » permet d'établir la validité discriminante. La règle de décision du cross loading est que chaque indicateur doit démontrer une charge factorielle plus élevée avec son construit qu'avec le reste des construits (Gefen et Straub, 2005). Toutefois, cet indice est critique lorsque deux construits sont significativement corrélés (Voorhees et al, 2016).

¹² Average Variance Extracted

Comme solution aux problèmes des deux indices précités, Henseler et al (2015) ont proposé le Hétérotrait-Monotrait (HTMT) qui permet d’obtenir la corrélation réelle entre deux construits (Hair et al, 2022). Le HTMT est calculé selon l’équation suivante :

$$HTMT(Y_1Y_2) = \frac{mean(R_{Y_1Y_2})}{\sqrt{mean(R_{Y_1Y_1}) \cdot mean(R_{Y_2Y_2})}},$$

Avec :

Mean (R_{Y₁Y₂}) : la moyenne des corrélations entre les indicateurs des construits de Y₁ et Y₂

Mean (R_{Y₁Y₁}) : la moyenne des corrélations entre les indicateurs du construit Y₁

Mean (R_{Y₂Y₂}) : la moyenne des corrélations entre les indicateurs du construit Y₂

Afin de vérifier la validité discriminante, l’indice HTMT doit avoir une valeur inférieure ou égale à 0,9 si les concepts étudiés sont très similaires (Henseler et al, 2015) ou une valeur inférieure ou égale à 0,85 si les concepts du modèle de recherche sont distincts (Henseler et al, 2015).

Hormis le calcul standard du HTMT, Hair et al (2022) recommandent l’utilisation du Bootstrap. Dans le cas où la limite supérieure de l’intervalle de confiance est inférieure à 0,9 ou 0,85, cela indique que la validité discriminante est vérifiée (Hair et al, 2022).

Le tableau 3 synthétise les principales étapes qui permettent de vérifier le modèle de mesure dans la méthode PLS-SEM avec des indicateurs réflexifs.

Tableau 3 : les étapes du modèle de mesure de la méthode PLS-SEM avec des indicateurs réflexifs

Étape du modèle de mesure	Indice	Condition d’acceptation	Références
Fiabilité des indicateurs	Loading	<p>Loading → > 0,7 Rétention de l’indicateur</p> <p>0,4 ≤ Loading < 0,7 → Vérification de la fiabilité et la validité du construit</p> <p>Loading → < 0,4 Suppression de l’indicateur</p>	(Hair et al, 2022)

Fiabilité du construit	L'alpha de Cronbach (α) La fiabilité composite (ρ_c) L'indice (ρ_A)	$\geq 0,6$ dans les recherches exploratoires $\geq 0,7$ dans les recherches confirmatoires	
Validité convergente	La moyenne de la variance extraite (AVE)	$\geq 0,5$	
Validité discriminante	Hétérotrait Monotrait (HTMT)	$\leq 0,9$ lorsque les concepts sont similaires $\leq 0,85$ lorsque les concepts sont distincts	(Henseler et al, 2015)

Source : Elaboration personnelle

3.3 Le cas des construits de second ordre

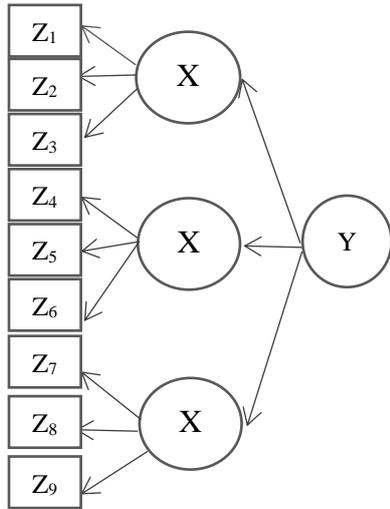
Les construits d'ordre supérieur plus communément appelés modèles à composantes hiérarchiques (Sarstedt et al, 2019) permettent de définir un construit (concept) selon différentes composantes (Cheah et al, 2019 ; Hair et al, 2022). Sur le plan théorique, cette approche peut se faire sur plusieurs niveaux mais d'une façon générale, les travaux de recherche limitent leurs modélisations au deuxième degré : un construit d'ordre supérieur ou de deuxième ordre et des construits d'ordre inférieurs ou de premier ordre (Hair et al, 2022).

Les construits de second ordre peuvent être de différents types : réflexifs-réflexifs, réflexifs-formatifs, formatifs-formatifs ou formatifs-réflexifs (Becker et al, 2012 ; Cheah et al, 2019 ; Ringle et al, 2012).

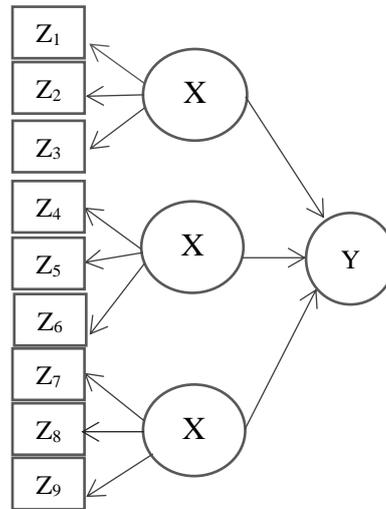
La figure 3 reflète les différents types de construits de seconde ordre (Y) et des construits de premier ordre (X_i).

Figure 3 : Les quatre types de construits de second ordre

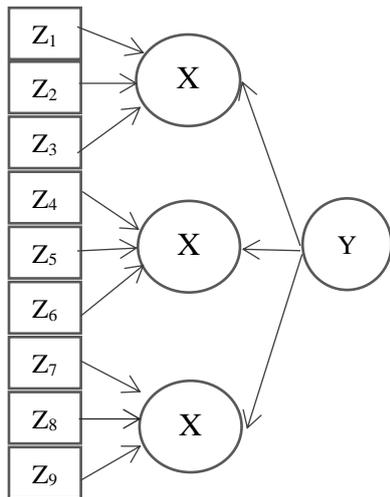
Les construits réflexifs-réflexifs



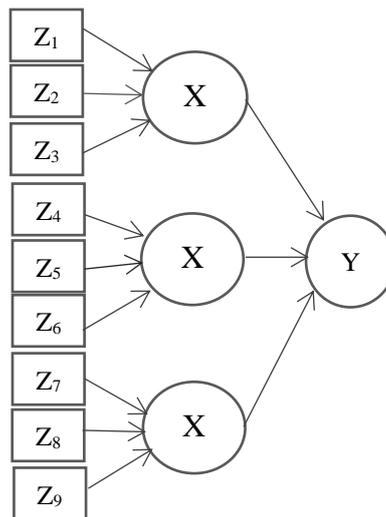
Les construits réflexifs-formatifs



Les construits formatifs-réflexifs



Les construits formatifs-formatifs



Source : Sarstedt et al (2019, p 198)

Dans le cas où un modèle possède des construits de deuxième ordre, les composantes sont considérées comme des indicateurs à ce même construit (Sarsted et al, 2019). Dans ce sens, les mêmes règles d'interprétation et de calcul sont appliquées pour les critères qui déterminent le modèle de mesure des indicateurs formatifs ou réflexifs (Sarstedt et al., 2019).

Après la validation du modèle de mesure, l'étape suivante consiste à évaluer le modèle structurel (Hair et al, 2022).

4. Le modèle structurel

Contrairement au modèle de mesure où l'évaluation se focalise sur les relations entre les variables manifestes et leurs variables latentes, le modèle structurel permet de tester les liens causals entre les construits. Afin d'y arriver, Hair et al (2022) recommandent de vérifier la colinéarité entre les construits, le pouvoir explicatif du modèle, la taille des effets, les chemins structurels ainsi que le pouvoir prédictif du modèle.

4.1 La colinéarité

Dans le modèle structurel, la colinéarité fait référence à deux construits qui sont significativement corrélés (Hair et al, 2022).

La méthode PLS-SEM est une méthode de régressions par les moindres carrés de chaque variable endogène par rapport à des variables exogènes (Hair et al, 2022). Dans ce cas, l'existence d'une colinéarité entre les construits peut biaiser le modèle estimé. Pour cela, il est nécessaire avant tout d'évaluer le degré de colinéarité (Hair et al, 2022).

Le facteur d'inflation de la variance est aussi un indice qui permet de détecter le degré de colinéarité entre les construits (Hair et al, 2022). Les règles d'interprétation appliquées aux indicateurs formatifs sont aussi valables pour les construits, à savoir une valeur du VIF inférieure à 3 afin d'assurer l'absence totale d'une colinéarité au sein du modèle structurel (Hair et al, 2022).

4.2 Le pouvoir explicatif du modèle

Le pouvoir explicatif du modèle structurel est déterminé à travers le coefficient de détermination (R^2) (Hair et al, 2022). Le R carré indique le degré de variance expliquée dans les variables endogènes par l'effet des variables exogènes (Hair et al, 2022). D'une façon générale, des valeurs R carré de 0,19, 0,33 et 0,67 sont interprétées respectivement comme faible, modérée et forte (Chin, 1998).

4.3 La taille de l'effet (f^2)

La taille de l'effet (effect size) f^2 identifie le changement du coefficient de détermination (R^2) lorsqu'une variable exogène est négligée dans le modèle (Hair et al, 2022). Si l'omission d'une variable explicative entraîne une diminution significative du R^2 de la variable à expliquer, cela indique l'importance de la variable omise (Hair et al, 2022). La formule qui permet de calculer la taille de l'effet est définie comme suit (Cohen, 1988, 1992) :

$$f^2 = \frac{R_{\text{included}}^2 - R_{\text{excluded}}^2}{1 - R_{\text{included}}^2}$$

Avec :

R_{included}^2 : la valeur du coefficient de détermination lorsque la variable explicative est incluse

R_{excluded}^2 : la valeur du coefficient de détermination lorsque la variable explicative est omise.

Les valeurs de 0,02, 0,15 et 0,35 du f^2 sont interprétées respectivement comme faible, moyenne et forte (Cohen, 1988, 1992).

4.4 Les coefficients de chemins

Dans le modèle structurel, les coefficients de chemins représentent les relations entre les construits (Hair et al, 2022). En générale, les coefficients de chemins sont compris entre -1 et +1. Une valeur proche de +1 indique l'effet positif d'une variable exogène sur une variable endogène. Par contre, une valeur proche de -1 démontre l'effet négatif d'une variable explicative sur une variable à expliquer. Dans le cas où les coefficients de chemins se rapprochent de 0, cela signifie que les relations entre les construits sont faibles (Hair et al, 2022).

Par ailleurs, afin d'obtenir des coefficients de chemin plus fiables, Hair et al (2022) recommandent l'utilisation du bootstrap. Cette technique génère un test T avec des valeurs p pour tous les coefficients de chemin (Hair et al, 2022). En règle générale, les valeurs du test T doivent être supérieures à 1,65, 1,96 ou 2,57 avec respectivement des seuils de de signification de 10 %, 5% et 1% (Hair et al, 2022). Une autre alternative est que les valeurs p doivent être inférieures au seuil de signification choisi soit 10%, 5% ou 1% (Hair et al, 2022). Une dernière méthode d'interprétation des résultats du bootstrap fait appel aux intervalles de confiance qui peuvent être de 90%, 95% ou 99% avec respectivement des seuils de signification de 10%, 5% ou 1% (Hair et al, 2022). Si l'intervalle de confiance au seuil choisi ne contient pas la valeur 0, l'hypothèse qui stipule l'existence d'un effet de la variable exogène sur la variable endogène est confirmée. Dans le cas contraire, l'hypothèse est infirmée (Hair et al, 2022). Toutefois, comme dans les cas des poids extérieurs des indicateurs formatifs et de la validité discriminante des indicateurs réflexifs, lorsque l'échantillon est en dessous de la taille minimale ou que les paramètres sont significativement asymétriques, l'utilisation de l'intervalle de confiance BCa permet d'avoir des résultats dépourvus de biais (Hair et al, 2022).

Il est à noter que ces trois méthodes de vérification des chemins structurels sont presque semblables (Hair et al, 2022). Cependant, Hair et al (2022) recommandent l'utilisation de la

méthode avec des intervalles de confiance bootstrap vu qu'elle assure une stabilité dans l'estimation des coefficients de chemin.

4.5 Le pouvoir prédictif du modèle

Dans la méthode PLS-SEM, l'évaluation du pouvoir prédictif du modèle se fait généralement en utilisant l'indice Q^2 de Stone-Geisser (Stone, 1974 ; Geisser, 1974).

L'indice Q^2 est une technique statistique qui fait appel au « Blindfolding ». Dans cette approche, l'échantillon est utilisé en supprimant des données et en fournissant leurs valeurs estimatives. Ces valeurs estimatives sont par la suite utilisées dans la prédiction des données omises. Le Blindfolding est alors répété jusqu'à ce que toutes les données soient estimées et prédites (Chin, 1998). Toutefois, les recherches de Shmueli et al (2016) remettent en doute la pertinence de cet indice car l'omission des données permet de garder une structure d'échantillon presque inchangée. Ainsi, l'indice Q^2 n'évalue pas le pouvoir prédictif du modèle (Hair et al, 2022).

Comme remplacement de l'indice Q^2 , Shmueli et al (2016) proposent la procédure de PLSpredict qui divise les données en un échantillon appelé « Training Sample » et un autre dénommé « Holdout sample ». L'échantillon « Training sample » constitue une partie des données utilisées pour estimer le modèle. L'échantillon « Holdout sample » sert à prédire les valeurs des indicateurs d'une variable endogène à travers les valeurs des indicateurs d'une variable exogène dans ce même échantillon tout en utilisant les estimations de l'échantillon « Training sample » (Shmueli et al, 2016). Au moment où les différences entre les valeurs prédictives et réelles sont faibles, le modèle a un excellent pouvoir prédictif. Dans le cas contraire, le modèle a un faible pouvoir prédictif (Shmueli et al, 2016).

L'utilisation de PLSpredict doit se faire en suivant les étapes suivantes (Shmueli et al, 2019) : la division de l'échantillon en plusieurs sous ensemble (Training sample et Holdout sample), le choix du nombre de répétition de l'algorithme PLSpredict et le calcul des indices RMSE et MAE.

Par rapport à la première étape, les travaux de recherche divisent généralement l'échantillon sur $k=10$ (Hair et al, 2022). Dans ce sens, l'échantillon appelé « Training Sample » sera de $K-1=9$ et servira à prédire le sous échantillon restant « Holdout Sample ». Par ailleurs, lors du choix de la valeur k , il faut s'assurer que l'échantillon « Training Sample » respecte la taille minimale requise à travers la formule suivante (Shmueli et al, 2019) :

$$\text{L'échantillon « Training sample »} = \text{L'échantillon total} - (\text{L'échantillon total}/k)$$

La répétition de l'algorithme PLSpredict permet une amélioration considérable des estimations (Shmueli et al, 2019). D'une façon générale, l'algorithme de PLSpredict est répété 10 fois (Witten et al, 2016).

Enfin, les indices (RMSE¹³) et (MAE¹⁴) sont calculés en suivant les formules suivantes :

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad \text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

Avec :

Y_i : la valeur de l'observation i

\hat{y}_i : la valeur prédite de l'observation i

Le RMSE est généralement l'indice le plus recommandé pour définir le pouvoir prédictif du modèle (Hair et al, 2022). Par ailleurs, quand les erreurs de prédiction sont largement asymétriques (en dehors de l'intervalle -2, +2), l'indice donne un résultat pessimiste du pouvoir prédictif du modèle. Dans ce cas, le RMSE peut être remplacé par le MAE (Hair et al, 2022).

L'interprétation du RMSE ou du MAE se fait d'abord en vérifiant que l'indice Q^2 est supérieur à 0. Par la suite, le RMSE ou le MAE sont comparés au modèle de régression linéaire (LM¹⁵) de chaque indicateur des variables endogènes (Shuemeli et al, 2016) :

- Si toutes les valeurs du RMSE ou du MAE < toutes les valeurs du LM des indicateurs des variables endogènes, le modèle a un excellent pouvoir prédictif.
- Si la majorité ou le même nombre des valeurs du RMSE ou du MAE < les valeurs du LM des indicateurs des variables endogènes, le modèle a un pouvoir prédictif moyen.
- Si toutes les valeurs du RMSE ou du MAE > Toutes les valeurs du LM des indicateurs des variables endogènes, le modèle n'a pas de pouvoir prédictif, sinon le modèle a un pouvoir prédictif faible.

Le tableau 4 résume les principales étapes du modèle structurel en appliquant la méthode PLS-SEM :

¹³ Root Mean Square Error : la racine de l'erreur quadratique moyenne

¹⁴ Mean Absolute Error : l'erreur absolue moyenne

¹⁵ Linear Model est une méthode qui exécute une régression linéaire de chaque indicateur d'une variable endogène sur l'ensemble des indicateurs des variables exogènes

Tableau 4 : les étapes du modèle structurel selon la méthode PLS-SEM

Étape du modèle structurel	Indice	Condition d'acceptation	Références
La colinéarité	VIF	$VIF < 3$	(Hair et al , 2022)
Le pouvoir explicatif du modèle	Le coefficient de détermination (R^2)	$0,19 \leq R^2 < 0,33 \rightarrow$ faible $0,33 \leq R^2 < 0,67 \rightarrow$ moyen $R^2 \geq 0,67 \rightarrow$ fort	(Chin, 1998)
La taille de l'effet	L'indice f^2	$0,02 \leq f^2 < 0,15 \rightarrow$ faible $0,15 \leq f^2 < 0,35 \rightarrow$ moyen $f^2 \geq 0,35 \rightarrow$ fort	(Cohen, 1988)
Les coefficients de chemin	Test T	$T > 1,65$ pour un seuil de signification 10% $T > 1,96$ pour un seuil de signification 5% $T > 2,57$ pour un seuil de signification 1% Une valeur p inférieure au seuil de signification choisi	(Hair et al , 2022)
	Bootstrapp	Un intervalle de confiance qui ne contient pas la valeur 0	
Le pouvoir prédictif du modèle	L'indice Q^2 , RMSE, MAE et LM	Étape 1 : $Q^2 > 0$ Étape 2 : Comparaison entre RMSE (MAE) et LM : <ul style="list-style-type: none"> - Si toutes les valeurs du RMSE ou du MAE < toutes les valeurs du LM des indicateurs des variables endogènes, le modèle a un excellent pouvoir prédictif. - Si la majorité ou le même nombre des valeurs du RMSE ou du MAE < les valeurs du LM des indicateurs des variables endogènes, le modèle a un pouvoir prédictif moyen. - Si toutes les valeurs du RMSE ou du MAE > Toutes les valeurs du LM des indicateurs des variables endogènes, le modèle n'a pas de pouvoir prédictif, sinon le modèle a un pouvoir prédictif faible. 	(Hair et al, 2022 ; Schmueli et al, 2016, 2019)

Source : Elaboration personnelle

5. Les méthodes de traitements des modèles ayant des construits d'ordre supérieur

Généralement, il existe deux approches pour le traitement des modèles ayant des construits d'ordre supérieur (Becker et al, 2023) : l'approche des indicateurs répétés (repeated indicators approach) et l'approche à deux stages (two-stage approach).

L'approche à indicateurs répétés est une configuration du modèle de mesure dans laquelle les indicateurs des composantes sont aussi affectés au construits d'ordre supérieur (Hair et al, 2024). Par conséquent, l'indicateur est *répété* deux fois, une affectation à sa composante et une autre au construit d'ordre supérieur (Hair et al, 2024).

L'approche à deux stages est divisée en deux étapes. La première évalue le modèle de mesure des composantes des construits d'ordre supérieur ainsi que les construits à une seule composante. La deuxième étape utilise les scores générés lors de la première étape, ce qui permet d'évaluer à la fois le modèle de mesure des construits de second ordre et le modèle structurel (Hair et al, 2024).

L'approche à deux stages est de deux types : L'approche à deux stages intégrée (The Embedded Two-Stage Approach) (Ringle et al, 2012) et l'approche à deux stages disjoints (The disjoint Two-Stage Approach) (Becker et al, 2012). La différence entre les deux méthodes est que dans l'étape 1 de l'approche à deux stages intégrée, les construits d'ordre supérieur sont modélisés en intégralité (le construit d'ordre supérieur et ses composantes) en suivant l'approche à indicateurs répétés. Par contre, l'approche à deux stages disjoints n'intègre que les construits à une seule composante et les composantes des construits d'ordre supérieur dans l'étape 1, d'où les appellations « intégrées » et « disjoints » (Sarstedt et al, 2019).

Malgré que toutes les approches donnent généralement des résultats semblables (Sarstedt et al, 2019 ; Cheah et al., 2019), l'approche à deux stages disjoints est recommandée par Becker et al (2023). Cela revient au fait que les résultats de l'approche à deux stages disjoints sont facilement interprétables via les logiciels informatiques comme SmartPLS, XLSTAT et WarpPLS. D'autant plus qu'aucun logiciel ne détermine intégralement le modèle de mesure des construits d'ordre supérieur dans une approche à indicateur répétés. Par conséquent, le calcul doit se faire manuellement, ce qui peut fausser les résultats.

6. Conclusion

La modélisation par équations structurelles de type PLS est une méthode d'analyse multivariée largement utilisée dans les recherches en sciences de gestion (Hair et al, 2022 ; Sarstedt et al, 2022). Ce constat peut être expliqué par l'efficacité statistique de PLS SEM ainsi que par la maniabilité des logiciels mis à disposition des chercheurs tels que SmartPLS, XLSTAT et WarpPLS (Becker et al, 2023).

Dans notre article, nous avons cherché à mettre en lumière les nouvelles pratiques de la méthode PLS SEM ainsi que les critiques émises sur certains indices. Pour cela, nous avons essayé d'illustrer la technique bootstrap, l'indice Rho A, le HTMT, le PLSpredict et les deux méthodes de traitement des construits d'ordre supérieur. Ces améliorations pourront perfectionner l'utilisation de PLS SEM dans la recherche en sciences de gestion.

Références bibliographiques

Ali.F, Rasoolimanesh.SM, Sarstedt.M, Ringle.CM et Ryu.K, (2018), An assessment of the use of partial least squares structural equation modeling (PLS-SEM) in hospitality research, *International Journal of Contemporary Hospitality Management*, 30(1), pp 514-538.

Bagozzi.RP, Yi.Y et Phillips LW, (1991), Assessing Construct Validity in Organizational Research. *Administrative Science Quarterly*, 36(3), pp 421-458.

Becker.JM, Cheah.JH, Gholamzade.R, Ringle.CM et Sarstedt.M, (2023), PLS-SEM's most wanted guidance, *International Journal of Contemporary Hospitality Management*, 35(1), pp 321-346.

Becker.JM, Klein.K et Wetzels.M, (2012), Hierarchical Latent Variable Models in PLS-SEM : Guidelines for Using Reflective-Formative Type Models, *Long Range Planning*, 45(5-6), pp 359-394.

Cenfetelli.R et Bassellier.G, (2009), Interpretation of Formative Measurement in Information Systems Research, *MIS Quarterly*, 33(4), pp 689-708.

Cheah.JH, Sarstedt.M, Ringle.CM, Ramayah.T et Ting.H, (2018), Convergent validity assessment of formatively measured constructs in PLS-SEM : On using single-item versus multi-item measures in redundancy analyses, *International Journal of Contemporary Hospitality Management*, 30(11), pp 3192-3210.

Cheah. JH, Ting. H, Ramayah.T, Memon. MA, Cham TH et Ciavolino.E, (2019), A comparison of five reflective–formative estimation approaches : reconsideration and recommendations for tourism research, *Quality & Quantity*, 53(3), pp 1421-1458.

Chin. W, (1998), The partial least squares approach to structural equation modeling, édition de Marcoulides. GA, pp 295-358, Mahwah.

Chin.W, (2010), How to Write Up and Report PLS Analyses. Dans V. Esposito vinzi, W. Chin, J. Henseler et H. Wang (dir), Handbook of partial least squares : concepts, methods and applications, Springer.

Cohen.J, (1992), A power primer : Psychological Bulletin, 112(1), pp 155-159.

Cohen.J, (1988), Statistical power analysis for the behavioral sciences (2^{ème} édition), L. Erlbaum Associates.

Dijkstra.TK et Henseler.J, (2015), Consistent Partial Least Squares Path Modeling, MIS Quarterly, 39(2), pp 297-316.

Efron.B, (1987), Better Bootstrap Confidence Intervals, 82, pp 171-185.

Evermann.J et Rönkkö.M, (2023), Recent Developments in PLS. Communications of the Association for Information Systems, 52(1), pp 663-667.

Fornell.C et Larcker.D, (1981), Evaluating Structural Equation Models with Unobservable Variables and Measurement Error, Journal of Marketing Research, 18(1), pp 39-50.

Franke.G et Sarstedt.M, (2019), Heuristics versus statistics in discriminant validity testing : a comparison of four procedures, Internet Research, 29(3), pp 430-447.

Gefen.D et Straub.D, (2005), A Practical Guide To Factorial Validity Using PLS-Graph : Tutorial And Annotated Example, Communications of the Association for Information Systems, 16, pp 91-109.

Geisser.S, (1974), A predictive approach to the random effect model, Biometrika, 61(1), pp 101-107.

Hair.JF, Hult.G, Ringle.C et Sarstedt. M, (2022), A Primer on Partial Least Squares Structural Equation Modeling (PLS-SEM), Sage, Thousand Oaks, CA.

Hair.JF, Sarstedt.M, Ringle.C et Siegfried.P, (2024), Advanced Issues in Partial Least Squares Structural Equation Modeling, Sage, Thousand Oaks, CA.

Hair.JF, Howard.M et Nitzl.C, (2020), Assessing measurement model quality in PLS-SEM using confirmatory composite analysis, Journal of Business Research, 109, pp 101-110.

Hair.JF, Black.WC, Babin.BJ, Anderson.RE, (2019a), Multivariate data analysis (8^{ème} édition). Cengage.

Hair.JF, Risher.JJ, Sarstedt.M, Ringle.CM, (2019b), When to use and how to report the results of PLS-SEM, European Business Review, 31 (1), pp 2-24.

Henseler.J, Ringle.CM et Sarstedt.M, (2015), A new criterion for assessing discriminant validity in variance-based structural equation modeling., Journal of the Academy of Marketing Science, 43(1), pp 115-135.

Hwang.H, Sarstedt.M, Cheah.JH et Ringle.CM, (2020), A concept analysis of methodological research on composite-based structural equation modeling : bridging PLSPM and GSCA. *Behaviormetrika*, 47(1), pp 219-241.

Jarvis.CB, Mackenzie.SB et Podsakoff.PM, (2004), Un examen critique des indicateurs de construit et des erreurs de spécification des modèles de mesure dans la recherche en marketing et en comportement du consommateur, *Recherche et Applications Marketing*, 19(1), pp 73-97.

Jöreskog.K et Wold.H, (1982), The ML and PLS techniques for modeling with latent variables : Historical and comparative aspects, Dans K. Jöreskog, et H. Wold (dir.), *Systems under indirect observation, Part I*, pp 263-270.

Lohmöller.JB, (1989), *Latent Variable Path Modeling with Partial Least Squares*. Physica-Verlag HD.

Radomir.L et Moiescu.OI, (2019), Discriminant validity of the customer-based corporate reputation scale : some causes for concern, *Journal of Product & Brand Management*, 29(4), pp 457-469.

Ringle.CM, Sarstedt.M, et Straub.DW, (2012), Editor's Comments : A Critical Look at the Use of PLS-SEM in « *MIS Quarterly* ». *MIS Quarterly*, 36(1), pp 3-14.

Sarstedt.M, Hair.JF, Cheah.J, Becker.J et Ringle.CM, (2019), How to Specify, Estimate, and Validate Higher-Order Constructs in PLS-SEM, *Australasian Marketing Journal*, 27(3), pp 197-211.

Sarstedt.M, Hair.JF, Ringle.CM, Thiele.KO et Gudergan.SP, (2016), Estimation issues with PLS and CB SEM : Where the bias lies ! *Journal of Business Research*, 69(10), pp 3998-4010.

Shmueli.G, Sarstedt.M, Hair.JF, Cheah.J, Ting.H, Vaithilingam.S et Ringle.C, (2019), Predictive model assessment in PLS-SEM : Guidelines for using PLSpredict, *European Journal of Marketing*, 53(11), pp 2322-2347.

Shmueli.G, Ray.S, Velasquez Estrada. JM et Chatla.SB, (2016), The elephant in the room : Predictive performance of PLS models, *Journal of Business Research*, 69(10), pp 4552-4564.

Stone.M, (1974), Cross-validatory choice and assessment of statistical predictions, *Journal of the Royal Statistical Society*, 36(2), pp 111-147.

Voorhees.CM, Brady.MK, Calantone.R et Ramirez.E, (2016), Discriminant validity testing in marketing : an analysis, causes for concern and proposed remedies, *Journal of the Academy of Marketing Science*, 44(1), pp 119-134.

Witten.IH, Frank.E et Hall.MA, (2016), *Data mining : practical machine learning tools and technique* (4ème édition).