



저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.



비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.



변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 [이용허락규약\(Legal Code\)](#)을 이해하기 쉽게 요약한 것입니다.

[Disclaimer](#)

조 영 일 교수 지도

석사학위 청구논문

두 시점 종단자료 분석에 활용되는
통계 모형의 비교

: 두 시점-잠재변화점수모형과

두 시점-패널모형

2021

성신여자대학교 대학원

심리학과

박 은 서

두 시점 종단자료 분석에 활용되는
통계 모형의 비교

: 두 시점-잠재변화점수모형과
두 시점-패널모형

조 영 일 교수 지도

이 논문을 석사학위논문으로 제출함

2020년 11월

성신여자대학교 대학원

심리학과

박 은 서

인 준 서

박은서의 석사학위 논문으로 인준함

2020년 11월

심사위원장 (인)

심 사 위 원 (인)

심 사 위 원 (인)

성신여자대학교 대학원

논문개요

본 논문은 두 시점 종단자료 분석에 활용되는 통계 모형인 두 시점-잠재변화점수모형과 두 시점-패널모형을 비교하는 시뮬레이션 연구이다. 이를 위하여 주요 조작 요인인 절편 요인과 기울기 요인의 상관의 크기, 사례수, 절편 간 상관의 크기를 설정하고 기타 조작 요인으로 첫 번째 시점에서 신뢰도의 크기, 첫 번째 시점과 두 번째 시점에서 변수의 분산의 비율, 두 번째 시점의 결정계수의 크기, 두 번째 시점에서 세 가지 분산(기울기 요인, 자기회귀 모수, 커플링 모수)의 크기에 따라 조건을 설정하였다. 이에 따라 통계 프로그램 Mplus와 R을 활용해 15,552($4 \times 4 \times 3 \times 3 \times 3 \times 3 \times 12$)개의 조건을 만족하는 자료를 5세트 생성하였고 분석하였다.

분석 결과, 두 시점-잠재변화점수모형과 두 시점-패널모형에서 서로 다른 커플링(교차지연) 모수 추정치가 추정되었다. 구체적으로, 두 시점-잠재변화점수모형이 두 시점-패널모형보다 모수 편향이 더 작았다. 또한 커플링(교차지연)모수 추정치의 통계적 유의성에 대하여 서로 다른 결과를 보이는 경우를 확인하였다. 커플링(교차지연) 모수 추정치와 모수 추정치의 통계적 유의성은 사례수에 영향을 많이 받는 것으로 확인되었다.

두 모형의 모형 선택 절차를 비교하였을 때 올바른 모형을 선택한 비율을 비교한 결과, BIC, ssBIC와 RMSEA의 성능이 가장 우수한 것으로 나타났다. 추가적으로 두 모형이 커플링(교차지연) 모수 추정치의 통계적 유의성에 대하여 서로 다른 결과를 나타냈을 때 올바른 모형을 선택한 비율을 비교한 결과, AIC와 RMSEA의 성능이 가장 높은 것으로 나타났다. 따라서 두 시점-잠재변화점수모형과 두 시점-패널모형을 비교하여 모형을 선택할 때는 RMSEA에 근거한 의사결정이 바람직한 것을 확인하였다.

본 논문은 두 시점-종단연구에서 어떤 모형을 선택하는지에 따라 종단 관계에 대하여 서로 다른 결론이 도출될 수 있는 것을 확인하였다. 만약 두 시점 종단연구에서 모형 선택에 대한 이론적인 정당성이 없을 경우 두 모형을 비교하여 RMSEA를 근거로 의사결정을 할 것을 제안하였다. 마지막으로, 본 연구의 한계와 후속연구에 대한 제언을 논의하였다.

주요어 : 두 시점 종단연구, 두 시점-잠재변화점수모형, 두 시점-패널모형, 모형 선택, 종단 관계

목 차

논문개요

I. 서론	1
1. 연구의 필요성 및 목적	1
II. 이론적 배경	11
1. 두 시점-잠재변화점수모형	11
2. 두 시점 패널모형	17
3. 두 시점-잠재변화점수모형과 두 시점-패널모형의 비교	22
III. 연구문제 및 가설	27
1. 연구문제 1	27
2. 연구문제 2	27
IV. 연구방법	29
1. 자료 생성	29
1) 몬테카를로 시뮬레이션	29
2) 시뮬레이션 조건	30
2. 자료 분석	37
1) 모수 편향	37

2) 모수 추정치의 차이	38
3) 우도비 검정	38
4) 정보지수	39
5) 모형 적합도 지수	41
V. 연구결과	44
1. 커플링 및 교차지연 모수 편향	44
2. 커플링 모수 추정치와 교차지연 모수 추정치의 차이	49
3. 종단 관계의 존재와 관련하여 두 모형이 서로 다른 결론을 보 이는 빈도	53
4. 올바른 모형을 선택한 비율	57
5. 종단 관계에 대하여 두 모형이 서로 다른 결과를 보일 때, 올바 른 모형을 선택한 비율	61
VI. 논의	64

참고문헌

ABSTRACT(영문초록)

부록

표 목 차

<표 1> 두 시점-잠재변화점수모형과 두 시점-패널모형의 비교	26
<표 2> 시뮬레이션 조건	36
<표 3> 시뮬레이션 조건별 두 시점-잠재변화점수모형과 두 시점-패널모형에 대한 커플링(교차지연) 모수 편향의 주변 평균	47
<표 4> 시뮬레이션 조건별 두 시점-잠재변화점수모형의 커플링 모수 추정치 와 두 시점-패널모형의 교차지연 모수 추정치의 차이에 대한 주변 평균	51
<표 5> 시뮬레이션 조건별 올바른 모형을 선택한 비율	60
<표 6> 중단 관계의 존재에 대하여 두 시점-잠재변화점수모형과 두 시점-패 널모형이 서로 다른 결과를 보일 때 모형 선택절차별 올바른 모형을 선택한 비율	63
<표 7> 연구 결과	69

그림 목 차

<그림 1> 두 시점-잠재변화점수모형의 경로모형	16
<그림 2> 두 시점-패널모형의 경로모형	21
<그림 3> 시뮬레이션 조건별 두 시점-잠재변화점수모형과 두 시점-패널모형에 대한 커플링(교차지연) 모수 편향의 주변평균	48
<그림 4> 시뮬레이션 조건별 두 시점-잠재변화점수 모형의 커플링 모수 추정치와 두 시점-패널모형의 교차지연 모수 추정치의 차이에 대한 주변평균	52
<그림 5> 두 시점-잠재변화점수모형과 두 시점-패널모형이 종단 관계의 존재에 대하여 서로 다른 결과를 보이는 비율	55
<그림 6> 두 시점-잠재변화점수모형(또는 두 시점-패널모형)의 커플링(교차지연) 모수만 통계적으로 유의한 경우의 비율	56

I. 서론

1. 연구의 필요성 및 목적

발달 과학은 전 생애 동안 변하지 않고 유지되는 특성과 변화하는 특성을 이해하고자 하는 학문이다(Overton, Lerner, & Molenaar, 2015). 인간발달 연구자들은 출생에서 죽음에 이르기까지 사람들이 보이는 일관성(consistency)과 변화(change)에 영향을 주는 요인들을 찾으려는 하나의 공통된 목표를 가진다. 구성개념의 수준이 시간이 지나도 변하지 않는 것을 일관성이라고 하며, 구성개념의 수준이 시간이 지나며 변하는 것을 변화라고 한다(Bornstein, Putnick, & Esposito, 2017). 시간의 흐름에 따른 일관성과 변화를 추정하기 위하여 여러 시점에서 구성개념을 반복적으로 측정하고, 구성개념의 변화 또는 이에 영향을 미치는 변인을 분석하는 연구를 종단연구라고 한다(신택수, 2014).

종단연구의 주요 목표는 시간의 흐름에 따른 변산성(variation)을 확인하는 것으로, 시간의 흐름에 따른 변산성은 개인을 중심으로 2개의 분산으로 분해될 수 있다. 구체적으로, 개인 내 변화(intraindividual change)와 개인 간 차이(interindividual difference)이다(Baltes & Nesselraode, 1979)이다. 개인 내 변화란 한 사람이 가지는 속성의 수준이 시간의 흐름에 따라 변화하는 변산성을 의미한다. 예를 들어, 인지능력을 측정하는 검사를 동일한 사람을 대상으로 여러 차례에 걸쳐 실시했을 때, 각 시점의 검사점수 간의 차이가 개인 내 변화이다. 개인의 속성을 나타내는 심리적 구성개념의 수준은 시간의 흐름에 따라 안정적이거나, 혹은 변동적(예. 증가 혹은 감소)일 수 있다. 시간의 흐름에 따른 개인의 속성에 대한 변화를 추정하기 위한 방법 중 한 가지는 동일한 사람을 적어도 두 번 이상 반복측정하는 것이다. 개인 간 차이란, 심리적 구성개념의 수준이 둘 이상의 사람들 간에 서로 다른 것을 의

미한다. 동일한 인지검사를 여러 명에게 실시했을 때, 사람들 간의 검사점수의 차이를 개인 간 차이라고 할 수 있다. 시간의 흐름에 따른 개인 내 변화는 시간을 함수로 하는 변화의 궤적을 그려서 추정할 수 있으며, 개인별 변화의 궤적을 비교하여 개인 간 차이를 추정할 수 있다.

Nesselrode & Baltes(1979)에 따르면, 종단자료를 분석하는 연구자는 개인 내 변화를 통해 변화의 궤적을 확인할 수 있고, 개인 간 차이로 인해 사람들 간에 변화의 궤적이 어떻게 서로 다른지 확인할 수 있다. 추가적으로, 개인 내 변화의 원인(결정 요인)을 추정하고, 개인 내 변화에서 개인 간 차이의 원인(결정 요인)을 확인할 수 있다. 종단연구에서는 시간의 흐름에 따른 변산성, 즉 개인 내 변화와 개인 내 변화에서 개인 간 차이를 확인하고, 이에 대한 설명을 제공하는 것을 연구 문제로 설정한다.

종단연구의 주요 연구 문제를 확인하기 위한 방법 중 한 가지는 변화점수를 추정하는 것이다. 시간의 흐름에 따른 변산성은 개인 내 변화와 개인 간 차이로 분해되기 때문에, 변화점수에 대한 두 개의 모형을 만들어야 한다. 즉, 변화점수에 기초하여 개인 내 변화를 모형화하고, 변화점수 함수에 사용된 모수의 분산을 통해 개인 간 차이를 추정해야 한다. 변화점수에 기초하여 개인 내 변화를 모형화하기 위해서는 동일한 사람을 측정한 관찰점수 간의 차이를 계산해야 한다. 예를 들어, n 번째 사람에 대한 구성개념 Y 의 수준을 두 시점 ($t=1,2$)에서 측정한 관찰점수 $Y[1]_n, Y[2]_n$ 를 가정한다. 이 때 두 관찰점수 간의 차이를 변화점수라고 하녀(McArdle & Nesselrode, 2014), 식 (1)과 같이 나타낸다.

$$D_{yn} = Y[2]_n - Y[1]_n \quad \text{식 (1)}$$

식 (1)을 통해 추정된 n 개의 변화점수(D_{yn})의 평균과 분산을 구할 수 있다.

변화점수의 평균이 통계적으로 유의할 경우, 시간의 흐름에 따라 구성개념의 수준이 변화한 것을 의미한다. 변화점수의 평균이 0보다 클 경우 구성개념의 수준이 증가한 것을 의미하며, 이를 이득점수(gain score) 또는 성장점수(growth score)라고 한다. 반대로, 변화점수의 평균이 0보다 작을 경우 구성개념의 수준이 감소했음을 의미하며, 이를 손실점수(loss score) 또는 감소점수(decline score)라고 한다.

변화점수의 평균이 통계적으로 유의하더라도 모든 개인들이 증가하거나 감소하는 것을 의미하지 않는다. 만약 변화점수의 평균이 0과 통계적으로 유의하게 다르고 분산이 통계적으로 유의할 경우, 변화점수의 분산이 클수록 사람마다 변화하는 정도의 차이가 더 큰 것을 의미한다.

하지만 Cronbach & Furby(1970)은 관찰점수의 차이값으로 변화점수를 추정할 때 발생하는 문제점을 설명하였다. 각 시점의 관찰점수 Y 는 고전검사이론에 근거하여 진점수와 측정오차로 분리되는데(Lord & Novick, 1968), 동일한 구성개념을 두 시점에서 측정한 관찰점수 $Y[1]_n, Y[2]_n$ 는 진점수 $y[1]_n, y[2]_n$ 과 각 시점의 측정오차 $e[1]_n, e[2]_n$ 으로 구성되며 식 (2)와 같이 나타낸다.

$$\begin{aligned} Y[1]_n &= y[1]_n + e[1]_n \\ Y[2]_n &= y[2]_n + e[2]_n \end{aligned} \quad \text{식 (2)}$$

측정오차 $e[1]_n, e[2]_n$ 는 각 측정 시점에서 무선적으로 발생하는 오차점으로 평균이 0, 진점수 y 와 독립적이며, 오차점수 간에도 서로 독립적이라는 특징이 있다. 식 (1)과 식 (2)를 이용하여, 관찰점수 간의 변화점수를 식 (3)으로 나타낼 수 있다.

$$\begin{aligned}
D_{yn} &= Y[2]_n - Y[1]_n && \text{식 (3)} \\
&= (y[2]_n + e[2]_n) - (y[1]_n + e[1]_n) \\
&= (y[2]_n - y[1]_n) + (e[2]_n - e[1]_n) \\
&= e[2]_n - e[1]_n \\
&= \Delta e_n
\end{aligned}$$

식 (3)에서 진점수 y 는 시간이 흘러도 변화하지 않았음을 가정하기 때문에 $y[1]_n$ 과 $y[2]_n$ 의 차이는 0이 되고, 변화점수는 측정오차의 변화만으로 추정된다. 측정오차의 변화만으로 변화점수를 추정하면 변화점수의 평균, 상관도 측정오차의 특성을 따르기 때문에 시간의 흐름에 따른 구성개념 수준의 변화를 체계적으로 설명하지 못하게 된다.

변화점수로 구성개념의 수준의 변화를 체계적으로 설명하지 못하는 것은 곧 변화점수의 신뢰도가 낮은 것을 의미한다. 신뢰도는 측정하고자 하는 구성개념을 일관적으로 측정하는 측정의 일관성이다(Stanley, 1971). 신뢰도 추정을 위하여 관찰점수의 분산을 측정오차에 의한 분산과 진점수에 의한 분산으로 분리하며, 식 (4)와 같이 나타낸다. 신뢰도는 관찰점수 분산에 대한 진점수 분산의 비율로 추정하며, 식 (5)와 같이 나타낸다.

$$\sigma_Y^2 = \sigma_y^2 + \sigma_e^2 \quad \text{식 (4)}$$

$$r_{YY} = \frac{\sigma_y^2}{\sigma_Y^2} \quad \text{식 (5)}$$

관찰점수로 추정된 변화점수의 신뢰도는 식 (6)과 같이 나타낼 수 있다.

$$r_{\Delta\Delta} = \frac{\sigma_{\Delta y}^2}{\sigma_{\Delta Y}^2} \quad \text{식 (6)}$$

변화점수의 신뢰도는 관찰점수 변화의 분산에 대한 진점수 변화의 분산의 비율이라고 할 수 있다. 앞에서 논의하였듯이, 식 (3)에서 추정된 변화점수는 진점수 간의 차이가 없음을 가정하기 때문에 $\sigma_{\Delta y}^2$ 는 0이며 변화점수의 신뢰도 또한 0이 된다. 즉, 관찰점수로 추정한 변화점수는 신뢰롭지 못한 점수이며, 변화를 체계적으로 설명하지 못하는 것을 의미한다.

이러한 한계점과 관련하여 Nesselroade(1972)는 변화점수에 대한 다른 접근을 제안하였다. 구체적으로, Cronbach & Furby(1970)가 시간의 흘러도 진점수의 수준이 변화하지 않는다고 가정한 것과 다르게, 시간이 흐르면 진점수의 수준이 변화하는 것을 가정하였다. 식 (2)과 같이 관찰점수가 진점수와 오차점수로 이루어지는 것은 동일하지만, 두 번째 시점에서 Y 의 관찰값 $Y[2]_n$ 은 이전 시점의 점수 $Y[1]_n$ 와 관찰되지 않은 진점수의 변화 Δy 와 측정오차 $e[2]_n$ 으로 구성되며 식 (7)과 같다.

$$\begin{aligned} Y[1]_n &= y[1]_n + e[1]_n \\ Y[2]_n &= y[1]_n + \Delta y_n + e[2]_n \end{aligned} \quad \text{식 (7)}$$

시간의 흐름에 따라 진점수의 수준이 변화하였기 때문에 $Y[2]_n$ 와 $Y[1]_n$ 의 차이는 더이상 측정오차의 변화로만 구성되지 않고, 진점수의 변화와 측정오차의 변화의 합으로 구성되며 식 (8)로 표현할 수 있다. 식 (8)에서 진점수의 분산이 더 이상 0이 아니기 때문에, 신뢰도 또한 0이 아닌 값을 갖게 된다.

$$\begin{aligned} D_{yn} &= Y[2]_n - Y[1]_n \\ &= (y[2]_n + e[2]_n) - (y[1]_n + e[1]_n) \\ &= (y[2]_n - y[1]_n) + (e[2]_n - e[1]_n) \\ &= \Delta y + (e[2]_n - e[1]_n) \\ &= \Delta y_n + \Delta e_n \end{aligned} \quad \text{식 (8)}$$

Nesselroade(1972)의 가정을 토대로 만약 측정오차를 통제하고 변화점수를 추정한다면 오차의 변화를 포함하지 않는 진정한 변화를 추정할 수 있다. 측정오차를 통제하기 위한 대표적인 방법은 구조방정식모형(structural equation modeling; SEM)을 사용하는 것이다. 구조방정식모형은 여러 개의 측정변수에서 공통분산을 추정하고, 공통분산으로 요인을 추정하는 통계적 기법이다. 측정변수들이 공통적으로 설명하는 부분만으로 요인을 추정하였기 때문에, 요인은 측정오차를 포함하지 않는다. 구조방정식모형을 통해 구성개념의 수준의 진정한 변화를 추정할 수 있기 때문에, 많은 연구자들이 종단자료분석에 구조방정식모형을 활용하고 있다. 종단자료 분석을 위한 구조방정식모형은 대표적으로 잠재성장모형(latent growth model; LGM), 자기회귀교차지연모형(autoregressive cross-lagged model; ARCL), 잠재변화점수모형(latent change score; LCS) 등이 있다.

잠재성장모형(McArdle, 1986; Meredith & Tisak, 1984)은 관심 있는 관찰변수를 반복적으로 측정하여 변화를 시간변수나 공변인의 함수로 표현하는 종단모형이다. 관심변수의 시간에 따른 변화를 성장궤적이라 하며, 성장궤적의 절편과 기울기를 추정하는 것이 주요 목적이다(김수영, 2015).

자기회귀교차지연모형(Bollen & Curran, 2006)은 연구자에 따라 인과모형(causal model; Bentler, 1980; Kenny, 1979), 교차지연패널모형(cross-lagged panel model; Mayer, 1986), 선형패널 모형(linear panel model; Greenberg & Kessler, 1982) 등으로 불리며, 간명성을 위해 패널모형으로도 불린다. 자기회귀교차지연모형은 자기회귀모형을 다변량 모형으로 확장하여 두 변인 간의 교차지연 효과를 추정하는 모형이다(홍세희, 박민선, 김원정, 2007). 자기회귀 효과는 한 시점에서 다음 시점까지 동일한 변수를 측정했을 때의 효과를 의미하며, 교차지연 효과는 한 시점에서 다음 시점까지 한 변수가 또 다른 변수에 미치는 효과를 의미한다. 자기회귀 효과와 교차지연 효과를 통하

여 시간의 흐름에 따른 두 변수 간의 상호관계를 확인할 수 있다(Selig & Little, 2012).

잠재변화점수(latent change score model; LCS, McArdle, 2001, 2009; McArdle & Hamagami, 2001) 모형은 잠재성장모형과 교차지연자기회귀모형을 통합한 구조방정식 모형이다. 잠재변화점수는 동일한 구성개념에 대한 시점의 진점수와 바로 이전 시점의 진점수의 차이로 생성되는 일종의 자기회귀요인이다. 한 시점의 진점수는 초기시점의 진점수와 해당 시점까지 누적된 잠재변화점수의 합으로 구성된다. 잠재변화점수모형은 절편요인과 기울기요인을 사용하여 잠재변화점수의 초기값과 변화율을 모형화한다. 잠재변화점수모형에 한 변수가 추가된 이변량 잠재변화점수(Bivariate Latent Change Score; BLCS) 모형은 교차지연 관계를 통해 두 변수의 종단적 상호관계를 확인할 수 있다. 연구자에 따라 잠재차이점수 모형(latent difference score model; LDS)이라고도 불리지만, 본 연구에서는 잠재변화점수모형이라는 용어를 사용하였다(McArdle, 2001; McArdle & Hamagami, 2001).

종단자료 분석에서 다양한 구조방정식모형들을 사용하는 주요한 목적 중 한 가지는 시간의 흐름에 따른 변화의 형태, 즉 궤적을 확인하는 것이다. 시간의 흐름에 따른 변화가 선형성을 가정할 경우, 두 시점 종단자료만으로는 시간에 따른 변화의 형태를 결정하는 것이 불가능하고(Rogosa, 1995), 두 시점의 차이만으로는 변화의 지속성, 지연, 안정성 등을 평가할 수 없으므로(Singer & Willett, 2003), 많은 종단연구자들이 최소한 세 시점 이상으로 자료를 수집할 것을 권장하고 있다(Ployhart & Vandenberg, 2010; Singer & Willett, 2003; Chan, 1998). 종단연구의 시점이 늘어날수록 변화의 형태를 확인하는 것이 용이하지만 연구 참여자가 중도탈락할 가능성이 증가하는 문제점이 발생하게 된다. 연구 참여자의 죽음, 질병, 사고 등의 문제는 연구자가 통제할 수 없는 문제이며, 긴 시간 동안 같은 연구 참여자들과 연락을 유지

하는 것은 쉬운 일이 아니다. 자료의 수집 시점과 비례하여 증가하는 비용 문제 또한 연구자가 간과할 수 없는 문제이다.

종단연구의 이러한 한계와 관련하여, Henk & Castro-Schilo(2016)는 두 시점의 종단자료만으로 시간에 따른 변화를 추정할 수 있는 두 시점 종단연구를 제안하였다. 두 시점 종단연구를 통하여 연구자는 두 시점 동안의 변화를 추정하거나, 종단자료를 수집하는 동안 초기의 두 시점에서 수집된 자료에서 변화를 미리 확인하고 모든 자료를 수집한 이후 전체 시점의 변화와 비교할 수 있다(Finch & Shim, 2018). 다만 두 시점 종단자료만으로는 변화의 궤적을 확인하기에는 정보가 충분하지 않기 때문에 일반적인 종단연구처럼 변화의 궤적을 확인하는 것이 아니라 개인 내 변화에 대한 개인들 간의 분산으로 시간의 흐름에 따른 변화를 추정하게 된다.

두 시점 종단자료 분석에는 활용될 수 있는 통계 모형도 제한적이다. 종단연구에서 가장 대표적으로 사용되는 잠재성장모형의 경우 모형 적합도를 위한 충분한 자유도가 없기 때문에 두 시점 종단연구에서 사용할 수 없다(Finch & Shim, 2018). 따라서 Henk & Castro-Schilo(2016)는 두 시점 종단연구를 위한 모형으로 두 시점 잠재변화점수모형(Two-Wave Latent Change Score model; 2W-LCS), 잠재변화점수 매개모형(LCS mediation model; Selig & Preacher, 2009), 두 시점 패널모형(two-wave panel model; 2WPM; Little et al., 2007)을 제안하고, 세 모형을 이용하여 한 구성개념의 변화가 다른 구성개념의 변화를 예측하는 변화-변화 이론(change to change)을 검증하였다.

Henk & Castro-Schilo(2016)의 연구에서는 미국의 건강 및 은퇴연구에서 제공하는 패널자료인 RAND HRS(RAND version of Health and Retirement Study; RAND, 2013)을 이용하여 라틴계 미국인들의 우울증의 변화가 인지 건강의 변화를 예측하고, 인지 건강의 변화가 장애의 변화를 예측하는지를

검증하였다. 분석 결과, 동일한 자료로 분석하였음에도 세 모형은 서로 다른 결과를 보였다. 구체적으로, 두 시점-잠재변화점수와 잠재변화점수 매개모형으로 분석한 결과, 라틴계 미국인들의 우울증의 변화가 인지적 건강의 변화를 예측하며, 인지적 건강의 변화가 장애의 변화를 예측하는 것을 검증하였다. 반면에 두 시점-패널모형으로 분석한 결과 우울증의 변화, 인지적 건강의 변화, 장애의 변화가 관련되지 않았으며 시점의 변화에 따른 각 구성개념의 변화만을 예측하는 것으로 나타났다.

Henk & Castro-Schilo(2016)의 연구는 두 시점 종단자료 분석에 활용될 수 있는 세 가지의 통계 모형을 제안하였으며, 어떠한 모형을 선택했는지에 따라서 상반된 연구결과로 나타날 수 있다는 것을 확인하였다. 하지만 분석에 사용한 패널 자료가 이상적인 조건을 만족하지 않는다는 한계점을 가진다. 구체적으로 라틴계 표본 내에 상당한 양의 결측치가 있었으며, 자료가 리커트 척도에서 응답되고 정규분포를 따르는 것으로 가정하였지만 실제로는 이분형 응답 문항이 포함되었다. 이는 실제 패널 자료를 분석에 활용하였기 때문에 생기는 한계점으로, 추후 연구에서는 절편과 기울기 요인 등 모형의 주요 모수와 사례수 등의 조건에 대하여 작은 값, 중간 값, 큰 값을 만족하는 수준을 설정하고 그 수준에 따라 분석 결과가 모형마다 어떻게 다른지 검증하는 시뮬레이션 연구가 진행될 필요가 있다.

본 연구에서는 Henk & Castro-Schilo(2016)의 연구를 확장하여 두 시점-잠재변화점수모형과 두 시점-패널모형을 비교하고자 한다. 두 모형은 시간의 흐름에 따라 두 변수가 서로 영향을 미치는 종단 관계를 확인할 수 있다는 공통점을 갖고 있다. 두 시점-패널모형은 두 시점-잠재변화점수모형에 내재된 관계이며, 수학적 비교를 통해 두 모형의 내재된 관계를 설명할 수 있다. 선행연구의 한계를 보완하기 위하여 절편과 기울기 요인 간의 상관, 사례수, 두 변수의 절편 간의 상관 조건을 다양한 수준으로 설정하고 두 모형

간에 결과를 비교하는 몬테카를로 시뮬레이션 연구를 실시하고자 한다. 몬테카를로 시뮬레이션은 연구자가 관심 있는 모수를 만족하는 이론적인 분포에서 표본을 생성하고 가설을 검증하는 방법이다(김수영 & 석혜은, 2015). 실제 자료로 다양한 조건별 모델 수행을 확인하기에는 한계가 있기 때문에, 몬테카를로 시뮬레이션 연구를 통하여 자료를 생성하고 분석할 수 있다.

시뮬레이션을 통해 생성된 두 모형을 크게 두 가지 측면에서 비교하고자 한다. 첫 번째로, 두 모형이 종단 관계의 존재에 대하여 어떻게 다른지를 비교하기 위하여 커플링 모수와 교차지연 모수의 추정치와 통계적 유의성을 확인한다. 구체적으로, 커플링 모수와 교차지연 모수 추정치를 비교하여 두 모형이 종단 관계에 대하여 얼마나 다른지를 비교하고, 커플링 모수 추정치와 교차지연 모수 추정치의 통계적 유의성을 비교하여 종단 관계의 존재에 대하여 얼마나 다른 결론을 나타내는지 비교하고자 한다. 두 번째로, 시뮬레이션을 통해 생성된 두 모형의 우도비, 정보지수, 모형 적합도 지수를 비교하여 어떤 모형이 더 적합한지 확인하고자 한다. 우도비의 차이가 통계적으로 유의할 경우 더 복잡한 모형인 두 시점-잠재변화점수모형을 선택한다. 정보지수는 AIC, BIC, ssBIC를 사용하며 더 낮은 정보지수 값을 갖는 모형을 선택한다. 모형 적합도는 CFI, RMSEA 및 SRMR 값을 비교하여 더 적합한 모형을 선택한다. 구체적으로, 각 모형의 CFI 값이 0.9 이상인 좋은 적합도인지 확인하고, 두 모형 중 더 높은 CFI 값을 갖는 모형을 선택한다. RMSEA도 마찬가지로 각 모형의 RMSEA가 좋은 적합도인지 확인하고, 두 모형 중 더 낮은 RMSEA 값을 갖는 모형을 선택한다. 마지막으로 각 모형의 SRMR 값이 .08 이하인 좋은 적합도를 갖는지 확인하고, 두 모형 중 더 낮은 SRMR 값을 갖는 모형을 선택한다. 마지막으로, 두 모형이 종단 관계에 대하여 서로 다른 결과를 나타낼 때도 두 모형의 모형선택절차들을 비교하여 어떤 모형 선택절차가 가장 적합한지를 확인하고자 한다.

II. 이론적 배경

1. 두 시점-잠재변화점수모형¹⁾

두 시점-잠재변화점수(Two-wave Latent Change Score; 2W-LCS)모형은 두 시점 종단연구를 위해 잠재변화점수모형의 측정시점을 2로 고정한 모형이다(Henk & Castro-Schilo, 2016). 잠재변화점수모형은 잠재변화점수를 추정하여 시간에 따른 개인 내 변화를 확인하는 구조방정식모형이다. 연구자는 잠재변화점수모형을 사용하여 변화 과정에서 발생하는 역동성을 확인하고, 변화에 대한 가설을 검증할 수 있다(Ferrer & McArdle, 2010).

잠재변화점수모형은 시간에 따른 변화와 역동성을 확인하는 것이 목적이기 때문에, 발달 및 신경과학 연구에서 자주 사용되는 연구모형이다. 발달 연구에서 잠재변화점수모형을 사용한 예로 Ahmed, Wagner, & Lopez(2014)의 연구가 있으며, 1학년부터 4학년까지의 읽기 및 쓰기 능력에 대한 종단자료를 잠재변화점수모형으로 분석하여 두 능력의 발달 경로를 확인하고 상호관계를 검증하였다. 신경과학 연구의 경우 생애과정 인지훈련 연구에서 고강도 훈련 개입에 따른 뇌와 행동의 상호관계를 검증한 Kievit 외(2018)의 연구가 있다.

잠재변화점수모형을 사용한 연구에서 시간에 따른 변화를 확인하기 위해 변화점수를 추정하는데, 관찰변수로 변화점수를 추정할 경우 측정오차로 인해 변화점수의 신뢰도가 감소하는 문제점이 있다. 따라서 오차를 포함하지 않는 진점수의 변화점수인 잠재변화점수를 추정해야 한다. 두 시점-잠재변화점수모형에서 잠재변화점수를 추정하기 위해 두 시점($t=1,2$)에서 반복하

1) 정확한 명칭은 두 시점-이변량 잠재변화점수모형이지만 편의를 위하여 두 시점-잠재변화점수모형으로 설명하였다. 마찬가지로 논문의 이후 내용에서 두 시점-잠재변화점수모형은 모두 두 시점-이변량 잠재변화점수모형을 의미한다.

여 측정된 $i(1, \dots, i, \dots, I)$ 번째 사람의 잠재변수 X 의 관찰점수 x_{it} 는 잠재진점수 f_{xit} 와 오차점수 ϵ_{it} 로 구성되며, 식 (9)와 같이 나타낼 수 있다(Usami et al., 2016).

$$x_{it} = f_{xit} + \epsilon_{it} \quad \text{식 (9)}$$

잠재진점수 f_{xit} 의 절편과 분산은 0으로 고정된다. 오차점수 ϵ_{it} 는 평균이 0, 분산이 ψ_x^2 인 정규분포를 따른다. 잔차분산 ψ_x^2 은 모형의 판별을 위해 시점별로 동일한 값으로 고정한다. 잠재진점수 f_{xit} 는 두 번째 시점의 진점수 f_{xi2} 와 두 번째 시점과 첫 번째 시점 간의 잠재변화점수 Δf_{xi2} 로 구성되며, 식 (10)으로 나타낸다(Usami et al., 2016). 두 시점의 자료만 수집되기 때문에, 2W-LCS 모형은 한 사람 당 하나의 잠재변화점수가 추정된다.

$$f_{xi2} = f_{xi1} + \Delta f_{xi2} \quad \text{식 (10)}$$

잠재변화점수(Latent change score; LCS)의 절편과 분산은 0으로 고정된다. 두 번째 시점에서 추정되는 잠재변화점수 Δf_{xi2} 는 모든 시점에서 일정한 변화(constant change)를 나타내는 기울기 요인($\alpha_i \cdot S_{xi}$)과 이전 시점에 비례하는 변화(proportional change)를 나타내는 요인($\beta_x \cdot f_{xi1}$)으로 모형화되며, 식 (11)과 같이 나타낸다(Usami et al., 2016).

$$\Delta f_{xi2} = (\alpha_i \cdot S_{xi}) + (\beta_x \cdot f_{xi1}) \quad \text{식 (11)}$$

기울기 S_{xi} 는 변화의 기울기를 나타내는 잠재변수이다. 변화 궤적의 평균을 나타내는 절편은 잠재변수의 초깃값과 동일한 값을 갖기 때문에 식 (12.1), (12.2)로 나타낸다(Usami et al., 2016).

$$I_{yi} = f_{yi1} \quad \text{식 (12.1)}$$

$$I_{xi} = f_{xi1} \quad \text{식 (12.2)}$$

기울기 요인의 크기를 나타내는 기울기 요인의 요인부하 α_i 는 시점에 따라 변하는데, 일반적으로 $t=1$ 일 경우 0(예. $\alpha_1=0$), $t \geq 2$ 일 경우 1으로 고정된다(예. $\alpha_2=1$). 하지만 실제 연구 상황에서는 일반적으로 모든 시점에서 동일한 기울기 요인부하값(예. $\alpha=1$)을 가정한다(Usami, Hayes, & McArdle, 2015; McArdle, 2009). 두 시점-잠재변화점수모형도 두 시점만으로는 기울기 요인을 추정할 수 없기 때문에, 마찬가지로 기울기요인을 1로 고정한다. 기울기 요인은 첫 번째 시점에서 $x=0$ 일 때 두 번째 시점에서 x 의 기댓값으로, 회귀식의 절편과 개념상 유사한 의미를 갖는다. 기울기요인은 모집단 평균 μ_{01} 과 이에 대한 개인들의 분산 U_{1i} 으로 추정되는 무선효과이며, 식 (13)으로 나타낸다(Kaploma & Wickrama, 2020).

$$S_{xi} = \mu_{01} + U_{1i} \quad \text{식 (13)}$$

I_{xi} 는 첫 번째 시점의 잠재변수와 동일한 값으로, 이후 시점의 잠재변수에 비례적인 영향(β_x)을 미친다. 이전 시점에 비례하는 효과(β_x)는 무선효과인 기울기요인과 달리, 개인들마다 동일한 값으로 가지는 것을 가정한다.

두 시점-잠재변화점수 모형에 변수 Y 를 추가적으로 투입하면 두 시점-이

변량 잠재변화점수(Two-wave Bivariate Latent Change Score; 2W-BLCS) 모형으로 확장되며, 두 시점-이변량 잠재변화점수모형의 경로모형은 그림 (1)과 같다. 두 시점-이변량 잠재변화점수모형은 두 시점에서 두 잠재변수가 서로 영향을 주고받는 관계에서 두 잠재변수의 시간에 따른 변화를 탐지한다. 두 시점-이변량 잠재변화점수모형은 두 변수 각각의 잠재변화점수 Δf_{xi2} , Δf_{yi2} 가 추정되며, 식 (14), (15)로 나타낸다(Usami et al., 2016).

$$y_{it} = f_{yit} + \epsilon_{yit}, \quad x_{it} = f_{xit} + \epsilon_{xit} \quad \text{식 (14)}$$

$$f_{yi2} = f_{yi1} + \Delta f_{yi2}, \quad f_{xi2} = f_{xi1} + \Delta f_{xi2} \quad \text{식 (15)}$$

두 잠재변화점수는 일정한 효과 α_i 와 비례적인 효과 β_x 외에 이전 시점에서 또 다른 변수의 상태에 비례하는 요인($\gamma_y \cdot f_{xi1}$, $\gamma_x \cdot f_{yi1}$)이 추가되며, 식 (16.1), (16.2)로 나타낼 수 있다.

$$\Delta x_{i2} = (\alpha_x \cdot G_x) + (\beta_x \cdot x_{i1}) + (\gamma_y \cdot y_{i1}) \quad \text{식 (16.1)}$$

$$\Delta y_{i2} = (\alpha_y \cdot G_y) + (\beta_y \cdot y_{i1}) + (\gamma_x \cdot x_{i1}) \quad \text{식 (16.2)}$$

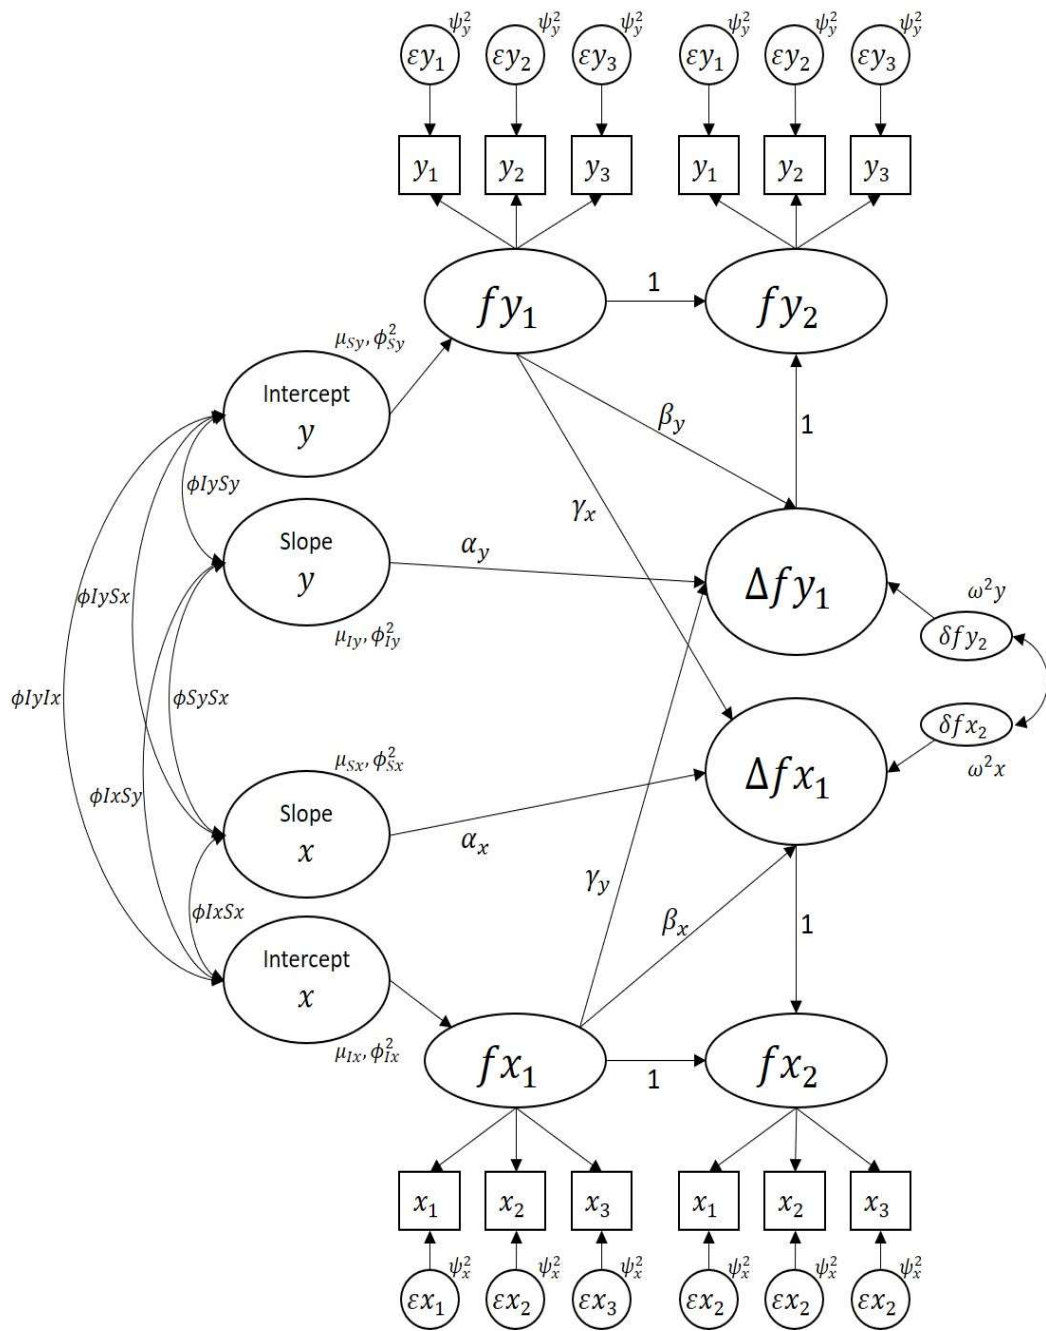
즉, 두 시점-이변량 잠재변화점수모형은 세 개의 요소로 구성된다: (1) 기울기 요인 α , (2) 이전 시점에서 같은 변수의 영향을 추정하는 자기회귀 모수 β , (3) 변수 간의 인과(중단) 관계를 추정하는 커플링 모수 γ . 세 종류의 모수(α , β , γ) 모두 추정과 식별을 단순화하기 위해 모든 시점에서 일정한 값으로 제약을 받는다.

β_x, β_y 는 이전 시점의 동일한 변수에 영향을 받는 자기회귀 모수로, 첫 번째 시점의 잠재진점수 f_{yi1} , f_{xi1} 를 통해 각각의 잠재변화점수 Δf_{yi2} , Δf_{xi2} 를 얻

마나 예측할 수 있는지를 의미한다(Usami et al., 2015). γ_x, γ_y 는 첫 번째 시점의 또 다른 변수에 영향을 받는 교차지연 효과를 나타내는 커플링 모수이다. γ_x, γ_y 를 통해 첫 번째 시점의 한 변수와 두 번째 시점에서 또 다른 변수 간의 영향의 방향을 확인할 수 있다. 만약 $\gamma_y = 0$ 이고 $\gamma_x \neq 0$ 일 경우, Y 만이 X 에 일방적으로 영향을 미치는 관계로 해석할 수 있으며, 반대로 $\gamma_x = 0$ 이고 $\gamma_y \neq 0$ 일 경우 X 가 Y 에 일방적으로 영향을 미치는 관계로 해석할 수 있다. $\gamma_y \neq 0, \gamma_x \neq 0$ 일 경우, 두 변수 X, Y 가 상호간에 영향을 미치는 관계로 해석할 수 있다(Kaploma & Wickrama, 2020).

예를 들어, 읽기 능력(y)과 쓰기 능력(x)의 종단관계를 두 시점-잠재변화점 수모형으로 검증한다고 가정할 때 읽기 능력의 비례효과 β_y 는 첫 번째 시점의 읽기 능력 수준으로 읽기 능력의 잠재변화점수를 얼마나 예측하는지를 의미한다. β_y, β_x 의 값이 클수록 읽기 및 쓰기 능력에 대한 첫 번째 시점의 점수로 각 능력의 잠재변화점수를 더 많이 예측하는 것을 의미한다. 커플링 효과 $\gamma_y = 0$ 이고 $\gamma_x \neq 0$ 일 경우, 읽기 능력은 쓰기 능력에 영향을 미치지 않지만, 쓰기 능력은 읽기 능력에 영향을 미치지 않는 관계이다. 반대로 $\gamma_x = 0$ 이고 $\gamma_y \neq 0$ 일 경우, 쓰기 능력은 읽기 능력에 영향을 미치지 않지만, 읽기 능력이 쓰기 능력에는 영향을 미치지 않는 관계를 의미한다. $\gamma_y \neq 0, \gamma_x \neq 0$ 일 경우, 읽기 능력과 쓰기 능력이 상호 간에 영향을 미치는 관계임을 의미한다.

$\delta_{yit}, \delta_{xit}$ 는 모든 시점 t 와 i 번째 개인에서 상호간에 독립적임을 가정하는 잔차이다. $\delta_{yit}, \delta_{xit}$ 는 평균이 0이고 각각의 잔차 분산이 ω_y^2, ω_x^2 인 정규분포를 따르며, 둘 간의 공분산은 ω_{yx} 이다. 모형 적합도를 증가시키고 부적절한 해석의 위험을 방지하기 위해 잔차 분산은 0으로 고정한다(Usami et al., 2016).



<그림 1> 두 시점-잠재변화점수모형의 경로모형(Usami et al., 2016)

2. 두 시점 패널모형

두 시점 패널모형(Two-wave panel model; 2WPM)²⁾은 자기회귀교차지연모형³⁾의 시점 수를 2로 제한한 모형이다(Little, Selig, & Card, 2007). 자기회귀교차지연모형은 두 변수 간의 종단 관계를 추정하기 위한 모형으로, 모든 변수의 현재 시점의 값이 과거에 대한 함수로 이루어지는 것을 가정한다. 모형의 가정을 토대로 시간의 흐름에 따른 변수들의 상호관계를 검증하고, 어떤 변수가 종단적으로 우세한지 검증한다.

2012년에 출판된 자기회귀교차지연모형을 사용한 전체 논문 중 45%가 두 시점 종단자료를 사용한 것으로(Hamaker & Grasman, 2015), 많은 연구자들이 두 시점 패널모형을 사용하고 있다. 그 예로 우울, 외로움 및 사회적 접촉과 인터넷 중독의 상호관계 연구(Yao & Zhong, 2014), 성찰 및 반추와 자기 수용 및 공감의 상호관계 연구(Boyras & Waits, 2015) 등이 있다. 두 시점 패널모형은 두 변수를 두 시점에서 측정한 것으로 시간이 지남에 따라 각 변수가 어떻게 변하는지에 확인하고, 한 변수에 대한 첫 번째 시점의 수준이 두 번째 시점의 다른 변수의 수준에 미치는 영향을 확인하는 것이 목적이다(Finch & Shim, 2018).

두 시점 패널모형에서 두 변수 X 와 Y 의 진정한 종단 관계를 추정하기 위해, 진점수와 오차점수를 분리한다. 즉, 시점 t 에서 i 번째 사람의 관찰점수 x_{it} , y_{it} 은 각각 진점수 f_{yit} , f_{xit} 와 측정오차 e_{it} 로 구성되며, 식 (17.1), (17.2)로 나타낼 수 있다.

-
- 2) 두 시점-패널모형의 시점 수를 제한하지 않은 기존 모형에 대한 다양한 명칭이 있지만 편의를 위하여 두 시점-패널모형으로 설명하였다.
 - 3) 자기회귀교차지연모형(Bollen & Curran)을 포함하여 인과모형(Bentler, 1980; Kenny, 1979), 교차지연 패널모형(Mayer, 1986), 선형 패널모형(Greenberg & Kessler, 1982) 등 다양한 이름이 있지만 본 논문에서는 편의상 자기회귀교차지연모형으로 설명하였다.

$$y_{it} = f_{yit} + \epsilon_{it} \quad \text{식 (17.1)}$$

$$x_{it} = f_{xit} + \epsilon_{it} \quad \text{식 (17.2)}$$

진점수 f_{yit}, f_{xit} 는 정규성과 선형 관계를 가정하며, 또한 두 시점 간의 시간 간격이 짧은 것을 가정한다. 진점수 f_{yit}, f_{xit} 을 통해 추정된 두 변수 간의 종단관계는 식 (18.1), (18.2)로 나타낼 수 있다(Usami et al., 2015). 두 변수 간의 종단 관계는 세 개의 요인으로 구성된다: (1) 시점 효과, (2) 자기회귀 효과, (3) 교차지연효과.

$$y_2 = y_{01} + \beta_{y1}y_1 + \gamma_{y1}x_1 + \delta_1 \quad \text{식 (18.1)}$$

$$x_2 = x_{01} + \beta_{x1}x_1 + \gamma_{x1}y_1 + \delta_1 \quad \text{식 (18.2)}$$

첫 번째 요인 y_0, x_0 는 시점효과로, 횡단 효과라고도 한다. 시점 t 에서 모든 관찰 단위에 공통적인 시점별 효과를 통제하는 것이 목적으로, 모든 관찰 시점에서 제한을 받지 않는 절편이다.

두 번째 요인 자기회귀 효과(autoregressive effect; AR)는 동일한 변수에 대한 이전 시점의 점수로 이후 시점의 점수를 예측하는 효과이다. 현재 측정값을 과거의 측정값으로 구성된 함수에 의해 회귀시키는 구조이기 때문에, 과거의 측정치가 현재를 예측하는 중요한 근거라고 할 수 있다(신탉수, 2014). 또한 자기회귀 효과를 통해 한 시점에서 다음 시점까지의 구성개념의 안정성을 설명할 수 있다. 안정성(stability)은 시점 간에 분산이 일정하게 유지되는 것으로, 잠재변수가 시간이 흐름에 따라 일정하게 유지되는 정도를 의미한다(윤태희 & 조영일, 2016).

자기회귀 계수 β_x 와 β_y 는 선형회귀계수로, 그 값이 클수록 과거 측정값으

로 현재 측정값이 예측되는 설명량이 큰 것을 의미한다. 예를 들어, 자기회귀 계수가 0에 가까운 작은 값이면, 시간이 지남에 따라 구성개념이 더 크게 변화했다는 것을 의미한다. 반대로, 자기회귀 계수가 1에 가까울수록, 구성개념은 더 안정적인 상태라고 할 수 있다. 자기회귀 계수가 0일 경우 구성개념에 대한 현재 시점의 수준이 과거 수준에 독립적인 것을 의미한다 (Zyphur et al., 2019).

교차지연 효과(Cross-lagged effect; CL)는 한 변수에 대한 이전 시점의 수준으로 다른 변수에 대한 현재 시점의 수준을 예측하는 효과이다. 즉, f_{xi1} 을 통해 f_{yi2} 를 예측하며, f_{yi1} 으로 f_{xi2} 를 예측하는데 각각의 교차지연 계수가 γ_x, γ_y 이다. 두 변수 간의 상호 관계에는 시간 순서가 존재하기 때문에, 두 변수 간의 상호 관계는 인과 관계로 해석할 수 있다.

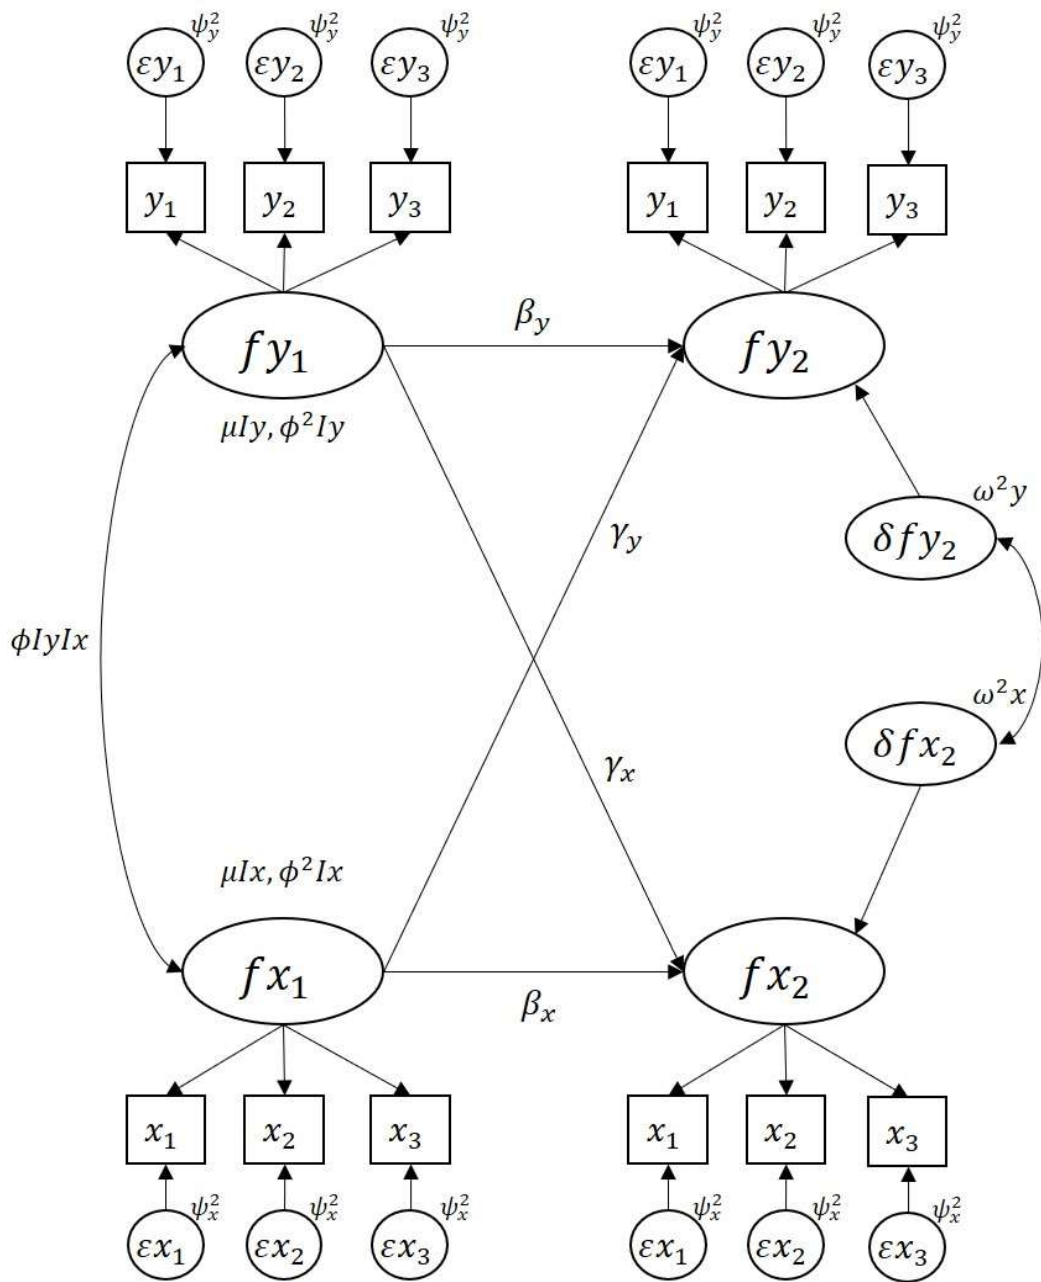
두 변수의 교차지연 계수를 해석할 때는, 각 변수들의 교차지연 계수를 해석하는 것 외에도 두 변수 중 어떤 변수가 인과적으로 우세한지 확인할 수 있다. 두 변수 간의 인과적 우위성을 비교하기 위하여 교차지연 계수를 표준화한다. 표준화된 교차지연 계수 간에는 상대적인 크기를 비교할 수 있기 때문에 어떤 변수가 더 강한 인과적 우위성을 갖고 있는지 확인할 수 있게 된다(Bentler & Speckart, 1981).

예를 들어, 읽기 능력(y)과 쓰기 능력(x)의 종단관계를 두 시점-패널모형으로 검증한다고 가정한다. 읽기 능력의 자기회귀 계수 β_y 는 첫 번째 시점의 읽기 능력으로 두 번째 시점의 읽기 능력을 예측(설명)하는 정도를 의미한다. β_y 의 값이 클수록 시간이 지나도 읽기 능력의 수준이 유사한 것을 의미하며, 반대로 그 값이 작을수록 읽기 능력의 수준의 변화가 큰 것을 의미한다. 교차지연효과는 이전 시점의 읽기 능력으로 현재 시점의 쓰기 능력을 예측하고, 이전 시점의 쓰기 능력으로 현재 시점의 읽기 능력을 예측하는 것을 의미한다. 두 교차지연계수를 표준화하였을 때, 더 큰 표준화된 교차지연계수값을 갖는

능력이 인과적으로 우세하다고 해석할 수 있다.

첫 번째 시점에서 x 와 y 두 변수 간에는 상관이 존재하기 때문에, 첫 번째 시점에서 교차지연효과가 발생할 가능성을 배제하기 위해 변수의 초기 수준은 통제된 상태에서 교차지연효과를 해석하게 된다. 즉, f_{yi} 의 초기 수준인 f_{yi1} 를 통제된 상태에서 f_{xi1} 으로 f_{yi2} 를 예측하며, 마찬가지로 f_{xi} 의 초기 수준인 f_{xi1} 를 통제된 상태에서 f_{yi1} 으로 f_{xi2} 를 예측한다.

δ_{x2} 와 δ_{y2} 는 두 번째 시점에서 x 와 y 에 대한 잔차이다. δ_{x2} 는 평균이 0, 분산이 ω_x^2 인 정규분포를 따르는 것을 가정하며, δ_{y2} 는 평균이 0, 분산이 ω_y^2 인 정규분포를 따르는 것을 가정한다. 잔차분산 ω_x^2 와 ω_y^2 는 상관관계임을 가정한다(Bollen & Curran, 2006)



<그림 2> 두 시점-패널모형의 경로모형(Usami et al., 2016)

3. 두 시점-잠재변화점수모형과 두 시점-패널모형의 비교

두 시점-잠재변화점수 모형과 두 시점-패널모형은 각각 잠재변화점수모형과 자기회귀교차지연모형의 시점 수를 2로 제한한 모형이다. 잠재변화점수모형과 자기회귀교차지연모형은 두 변수 X, Y 의 종단(인과) 관계를 추론하지만, 두 모형의 역사와 분석 목적에는 차이가 있다(표 1).

잠재변화점수모형은 잠재성장곡선모형의 확장으로 심리측정 분야에서 개발되었다(McArdle, 1986, 1988; McArdle & Anderson, 1990; McArdle & Epstein, 1987; Meredith & Tisak, 1984, 1990; Steyer, Eid, & Schwenkmezger, 1997). 잠재성장곡선모형은 두 변수 간의 변화에 대한 종단연합을 검증할 수 있지만, 변화의 방향성을 평가할 수 없는 한계점이 있다. 반면에 잠재변화점수모형은 잠재성장곡선모형과 유사하지만, 효과의 방향성을 평가할 수 있다는 장점을 가진다(Klopach & Wickrama, 2019). 잠재변화점수모형은 공분산과 평균 구조에 제한을 두고, 시간에 따른 변화를 검증하는 것이 주요 목적이다(Usami, Hayes, & McArdle., 2015).

자기회귀교차지연모형은 경제학에서 미래의 값을 예측하기 위해 시계열 자료에 사용된 벡터 자기회귀모형(다변량 자기회귀모형 또는 준단순모형; Jöreskog, 1974)에서 시작되었다(Wold, 1938). 자기회귀모형(Yule, 1921)과 교차지연상관(Campbell, 1963)이 구조방정식모형의 틀에서 합해진 모형이 자기회귀교차지연모형이다. 잠재변화점수모형과는 달리, 자기회귀교차지연모형은 공분산구조에만 근거하여 시간에 따른 변화를 확인한다(Usami, Hayes, & McArdle, 2015).

이변량 잠재변화점수모형과 자기회귀교차지연모형은 두 변수 간의 종단연합을 추정하는 구조방정식모형이다. 따라서, 두 변수 간의 종단관계를 검증하는 모수가 두 모형에서 가장 중요한 모수이다. 종단관계를 검증하는 모수

는 잠재변화점수 모델의 경우 커플링 모수라고 하며, 자기회귀교차지연모형에서는 교차지연 모수라고 한다. 두 모수의 해석은 동일하지만, 커플링 모수의 유의성은 한 변수가 다른 변수에서 변화에 영향을 미치는 경향을 의미한다(McArdle & Grimm, 2010).

잠재변화점수모형과 자기회귀교차지연모형 모두 시간에 따른 두 변수 간의 종단 관계를 확인하는 목적은 동일하지만, 개인의 변화에 대한 가설을 표현하고 검증하는 방식에서 차이점을 갖는다. 자기회귀교차지연모형에서는 변화값을 추정할 수 없지만, 잠재변화점수 모델에서는 명시적인 모수값으로 나타낼 수 있다(McArdle, 2009). 따라서, 두 모형으로 동일한 자료를 분석하더라도 서로 다른 분석 결과를 얻을 수 있다. Usami et al.(2015)는 두 모형으로 동일한 패널자료를 분석하고, 각 모형의 분석 결과를 비교하였다. 두 모형은 적합도 지수와 모수 추정치에 대해 큰 차이를 보였다. 자기회귀교차지연모형의 적합도지수만 괜찮은 적합도를 보였다. 두 모형의 커플링(교차지연) 모수는 모두 통계적으로 유의하였지만, 효과의 방향이 서로 다른 결과를 보였다. 잠재변화점수모형에서 시간이 흐름에 따라 체중의 감소가 키의 증가를 예측한 반면에, 자기회귀교차지연모형에서 시간이 흐름에 따라 체중의 감소가 키의 감소를 예측하였다.

Usami 외(2015)는 두 모형이 종단 관계에 대해 서로 다른 결과를 나타내는 것을 설명하기 위해 두 모형 간의 관계를 수학적으로 설명하였다. 두 모형의 수학적 관계를 토대로 두 시점-잠재변화점수모형과 두 시점-패널모형의 관계를 수학적으로 설명할 수 있다. 두 모형의 비교를 위해, 식 (19.1), (19.2)와 식 (20.1), (20.2)를 합하여 식 (21.1), (21.2)로 표현한다.

$$f_{yi2} = f_{yi1} + \Delta f_{yi2} \quad \text{식 (19.1)}$$

$$f_{xi2} = f_{xi1} + \Delta f_{xi2} \quad \text{식 (19.2)}$$

$$\Delta f_{yi2} = \alpha_i S_{yi} + \beta_y f_{yi1} + \gamma_y f_{xi1} \quad \text{식 (20.1)}$$

$$\Delta f_{xi2} = \alpha_i S_{xi} + \beta_x f_{xi1} + \gamma_x f_{yi1} \quad \text{식 (20.2)}$$

$$f_{yi2} = f_{yi1} + \beta_y f_{yi1} + \gamma_y f_{xi1} + \delta_{yi2} \quad \text{식 (21.1)}$$

$$f_{xi2} = f_{xi1} + \beta_x f_{xi1} + \gamma_x f_{yi1} + \delta_{xi2} \quad \text{식 (21.2)}$$

앞에서 논의했듯이, 식(20.1), (20.2)의 기울기요인부하 α_i 는 1로 고정한다. 두 모형 간의 관계는 식 (21.1), (21.2)에서 $1 + \beta_y y_{i1} = \beta_y^*$, $1 + \beta_x x_{i1} = \beta_x^*$ 을 가정할 때 더 명확해진다.

$$f_{yi2} = S_{yi} + \beta_y^* f_{yi1} + \gamma_y f_{xi1} + \delta_{yi2} \quad \text{식 (22.1)}$$

$$f_{xi2} = S_{xi} + \beta_x^* f_{xi1} + \gamma_x f_{yi1} + \delta_{xi2} \quad \text{식 (22.2)}$$

식 (22.1), (22.2)의 기울기요인이 모든 개인에 대해 동일하다고 가정하면 S_{yi} , S_{xi} 는 두 시점-패널모형의 x_{02} , y_{02} 과 동일해진다. 즉, S_{yi} , S_{xi} 는 더 이상 무선효과가 아닌 고정효과로 회귀식의 절편과 동일한 의미를 갖게 된다. 두 시점-잠재변화점수모형의 기울기와 두 시점-패널모형의 절편이 동일하다 ($S_{yi} = y_{02}$, $S_{xi} = x_{02}$)고 가정하는 것은 기울기 요인점수에 관련된 두 분산 (ϕ_{Sy}^2, ϕ_{Sx}^2)과 다섯 개의 공분산(ϕ_{SySx} , ϕ_{SyIy} , ϕ_{syIx} , ϕ_{IySx} , ϕ_{IxSx})이 모두 0으로 고정된 것을 암시한다. 기울기요인의 분산을 0으로 고정함에 따라 기울기 요인이 모집단에서 불변함을 가정하게 된다. 따라서, 두 시점-패널모형과 두 시점-잠재변화점수모형의 수학적 차이는 무선효과의 추정 방식이라고 할 수 있다. 연구자가 성장 패턴의 개인차를 설명하고자 한다면, 두 시점-패널모형보다

는 두 시점-잠재변화점수모형을 선택하는 것이 합리적이라고 할 수 있다.

두 모형의 내재된 관계와 관련하여 Usami et al.(2015)는 잠재변화점수모형만 적용하거나, 또는 자기회귀교차지연모형만으로 분석하는 것은 변수 간의 종단(인과) 관계에 대한 잘못된 결론을 도출할 수 있다고 경고하였다. 구체적으로, 잠재변화점수모형에서 기울기요인(S_{yit}, S_{xit})과 잠재변수에 대한 이전 시점의 점수(f_{yit-1}, f_{xit-1}) 간에 높은 상관을 가질 경우, 다중공선성으로 인해 비례 모수(β_x, β_y)의 불안정한 추정이 발생하고, 이로 인해 간접적으로 커플링 모수(γ_x, γ_y) 또한 불안정한 추정이 발생하게 된다. 절편과 기울기 요인 간의 상관(ϕ_{IySy}, ϕ_{IxSx})이 높을 때 다중공선성의 영향은 더 커지게 된다. 이에 따라, 본 연구에서는 다양한 절편과 기울기 요인 간의 상관 조건을 설정하고, 그에 따른 결과를 비교하고자 한다.

<표 1> 두 시점-잠재변화점수모형과 두 시점-패널모형의 비교

모형	두 시점-잠재변화점수모형 (2W-LCS)	두 시점-패널모형 (2WPM)
역사	<ul style="list-style-type: none"> - 심리측정 분야에서 개발 - 잠재성장모형을 확장한 모형 - 잠재성장모형과 자기회귀교차지연모형을 통합한 모형 	<ul style="list-style-type: none"> - 경제학에서 개발 - 벡터 자기회귀모형을 확장한 모형 - 자기회귀모형과 교차지연상관을 통합한 모형
변화의 추정	<ul style="list-style-type: none"> - 공분산 및 평균 구조에 근거하여 시간에 따른 변화를 검증 - 변화값을 명시적인 모수값으로 추정 가능 - 기울기요인의 무선흐과를 가정하므로, 성장패턴의 개인차 설명 가능 - 커플링 모수로 두 변수 간의 종단 관계를 설명 - 개인 간 차이와 개인 내 변화 과정을 분리 	<ul style="list-style-type: none"> - 공분산 구조에 근거하여 시간에 따른 변화를 검증 - 변화값을 명시적인 모수값으로 추정 불가 - 기울기요인의 고정효과를 가정함 - 교차지연 모수로 두 변수 간의 종단 관계를 설명 - 변화의 평균궤적을 보고하지 않음
공통점	<ul style="list-style-type: none"> - 두 변수 X, Y의 종단(인과) 관계를 추론하기 위한 모형 - 종단 관계의 방향성 평가 가능 - 시점의 수를 2로 제한한 모형 	

Ⅲ. 연구문제 및 가설

연구문제 1: 두 변수 간의 종단 관계와 관련하여 두 시점-잠재변화점수모형과 두 시점-패널모형은 언제, 그리고 얼마나 자주 통계적으로 다른 결과를 나타내는가?

[가설 1-1] 표본 크기, 절편과 기울기 간의 상관, 절편 간의 상관 조건의 수준에 따라 두 모형의 커플링(교차지연) 모수 γ_x, γ_y 의 편향이 다를 것이다.

[가설 1-2] 표본 크기, 절편과 기울기 간의 상관, 절편 간의 상관 조건의 수준에 따라 두 모형 간의 커플링(교차지연) 모수 γ_x, γ_y 추정치의 차이가 다를 것이다.

[가설 1-3] 두 모형은 표본 크기, 절편과 기울기 간의 상관, 절편 간의 상관 조건에 따라 두 변수 간의 종단 관계에 대해 서로 다른 결과를 나타낼 것이다.

연구문제 2: 어떤 모형 선택절차에 근거하여 두 시점-잠재변화점수모형과 두 시점-패널모형 중 올바른 모형을 선택하는 것이 가장 효과적인가?

[가설 2-1] 표본 크기, 절편과 기울기 간의 상관, 절편 간의 상관의 다양한 조건에서 CFI와 RMSEA에 근거한 의사결정을 할 때 올바른 모형을 선택(예. $P_s \neq 0$ 이면 두 시점-잠재변화점수 모형을 선택하고, $P_s = 0$ 이면 두 시점-패널모형을 선택)한 비율이 가장 높을 것이다.

[가설 2-2] 표본 크기, 절편과 기울기 간의 상관, 절편 간의 상관의 다양한 조건에서 두 모형이 두 변수 간의 종단 관계에 대해 서로 다른 결과를 나타낼 때, CFI와 RMSEA에 근거한 의사결정을 할 때 올바른 모형을 선택한 비율이 가장 높을 것이다.

IV. 연구방법

1. 자료 생성

1) 몬테카를로 시뮬레이션

본 연구에서는 통계 프로그램 Mplus와 R에서 생성한 가상자료를 몬테카를로 시뮬레이션(Monte Carlo Simulation) 방법으로 분석함으로써 본 연구에서 제기된 연구문제와 관련 가설을 검증하였다. R(R Development Core Team, 2019)은 광범위한 통계 및 그래픽 기술을 제공하는 컴퓨터 프로그램으로, 자료의 조작 및 계산과 다양한 도표의 출력이 가능하다(Venable & R Development Core Team, 2009). R은 기본적으로 제공되는 내장 함수(Built-In Function)⁴⁾ 외에도 사용자가 직접 목적에 부합하는 사용자 정의 함수(User-Defined Function)의 집합인 패키지(package)를 개발하여 배포할 수 있는 확장 가능한 프로그램이다. Mplus는 횡단 및 종단자료, 결측값 등이 포함된 다양한 자료를 분석하는 유연한 통계 프로그램이다. Mplus는 몬테카를로 시뮬레이션을 지원하여 다양한 유형의 데이터를 생성할 수 있으며, 몬테카를로 시뮬레이션을 통해 생성된 자료의 전체 및 일부를 저장하거나 불러오는 유용한 기능을 제공한다(Muthén & Muthén, 2017).

몬테카를로 시뮬레이션 방법은 모형을 평가하는 경험적인 방법이자 특정 조건에서 효과를 평가하는 일종의 실험이다(Paxton et al., 2001). 컴퓨터 프로그램으로 가상의 분포를 만족하는 자료를 생성하여 실제로는 만족하기 어려운 인위적인 조건에서 통계적인 추정치의 성능을 연구할 수 있다(김수영 & 석혜은, 2015).

4) 프로그래밍 언어에서 함수(Function)는 반복적으로 사용될 수 있는 문장의 형태를 의미하며, R에서 함수는 특정 기능을 수행하는 일종의 명령어이다.

2) 시뮬레이션 조건

기울기 요인⁵⁾을 고정효과로 가정할 때($\phi_{SySx} = \phi_{SyIy} = \phi_{SyIx} = \phi_{IySx} = \phi_{IxSx} = \phi_{Sx}^2 = \phi_{Sy}^2 = 0$ ⁶⁾), 두 시점-패널모형의 시뮬레이션 데이터가 생성된다. 분석 결과를 용이하게 하기 위해 변수 X 와 Y 값에 동일한 모수값을 설정하였다. 선행연구인 Usami(2016) 외의 연구를 참고하여 표본크기와 절편 및 기울기 간의 상관, 절편 간의 상관 세 가지 주요 시뮬레이션 조건을 설정하였으며, <표 2>에 제시하였다. 세 가지 시뮬레이션 조건 외에 시뮬레이션 데이터를 생성하기 위하여 측정의 신뢰도, 시점 간 변수의 분산의 비율, 회귀계수 β_x , T_2 에서 분산의 비율의 6개 추가 시뮬레이션 조건을 설정하였다. 또한 세 가지 주요 시뮬레이션 조건의 효과에 대한 해석을 용이하게 하기 위하여 기울기 요인 간의 공분산, 절편과 기울기요인 간의 공분산, 잔차 분산, 요인의 평균, T_1 에서 준거 변수의 분산을 특정 값으로 고정하였다. 6가지의 추가 시뮬레이션 조건과 모수 제약 또한 마찬가지로 선행연구인 Usami(2016) 외의 연구를 참고하였다.

본 연구에서는 4(표본 크기)×4(절편과 기울기 간의 상관)×3(두 변수의 절편 간의 상관)=48개의 관심 조작요인과 3(신뢰도)×3(시점 간 변수의 분산 비율)×3(T_2 에서 회귀계수 β_x)×12(T_2 에서 세 모수에 대한 분산의 비율)=324개의 추가 조작요인으로 자료를 생성하였다. 그리고 다섯 개의 데이터 세트를 무선적으로 생성하여 총 48×324×5=77,760개의 서로 다른 데이터 세트를 생성하였다.

5) 두 시점에 따른 변화의 기울기를 나타내는 요인

6) 기울기요인의 고정효과를 가정하면 기울기 요인과 절편 요인 간의 공분산 ($\phi_{SySx}, \phi_{SyIy}, \phi_{SyIx}, \phi_{IySx}, \phi_{IxSx}$)과 기울기 요인의 분산 ϕ_{Sx}^2, ϕ_{Sy}^2 이 모두 0으로 고정된다.

(1) 표본 크기

표본크기는 선행연구를 참고하여 설정하였다. 표본크기는 200, 500, 1,500, 3,000 네 가지로 설정하였다(Usami et al., 2016). 많은 연구자들이 구조방정식 모형의 표본 크기를 설정할 때 ‘N:q 규칙⁷⁾’에 근거하여 설정하며, 많은 연구자들이 20:1을 권장하고 있다(Kline, 2011; Jackson, 2001; Jackson, 2003; Tanaka, 1987). 두 시점-잠재변화점수모형의 자유 모수의 수는 17, 두 시점-패널모형의 자유 모수의 수는 38개이다. 두 모형의 자유 모수의 수를 고려하여 최소한으로 요구되는 표본 크기보다 작은 조건과 충분히 큰 표본 크기 조건을 설정하였다.

(2) 절편과 기울기 간의 상관

선행연구를 참고하여 절편 요인과 기울기 요인 간의 상관을 설정하였다. 절편 요인은 변수의 초깃값을 나타내는 요인이며, 기울기 요인은 시간의 흐름에 따른 증가율을 나타내는 요인이다. 따라서 절편 요인과 기울기 요인 간의 상관은 변수의 초깃값과 증가율 간의 상관을 나타낸다. 변수 X의 절편과 기울기 간의 상관, Y의 절편과 기울기 간의 상관($r_{IS} = r_{IxSx} = r_{IySy}$)은 .0, .2, .4, .6 네 가지로 설정하였다. 절편과 기울기 간의 상관은 식 (23)으로 추정한다(Usami et al., 2016).

$$r_{IS} = \frac{\phi_{IySy}}{\phi_{Iy}\phi_{Sy}} = \frac{\phi_{IxSx}}{\phi_{Ix}\phi_{Sx}} \tag{23}$$

(3) 두 변수의 절편 간의 상관

선행연구를 참고하여 두 변수의 절편 요인 간의 상관을 설정하였다. 절편

7) N은 표본 크기(sample size)를, q는 자유 모수(free parameter)의 수를 나타낸다.

요인은 변수의 초깃값을 나타내는 변수로, 두 변수의 절편 요인 간의 상관은 두 변수의 초깃값 간의 상관을 의미한다. 두 변수의 절편 간의 상관(r_{IyIx})의 작은 값, 중간 값, 큰 값으로 나누어 비교하기 위하여 .2, .5, .8 세 가지로 설정하였으며, 절편 간의 상관은 식 (24)로 추정한다(Usami et al., 2016).

$$r_{IyIx} = \frac{\phi_{IyIx}}{\phi_{Iy}\phi_{Ix}} \quad \text{식 (24)}$$

(4) 신뢰도

선행연구를 참고하여 첫 번째 시점의 신뢰도를 설정하였다. 종단연구에서 신뢰도는 시간에 따른 변화의 안정성을 의미한다(Tisak & Tisak, 1996). 신뢰도의 작은 값, 중간 값, 큰 값으로 나누어 비교하기 위하여 .2, .5, .8 세 가지로 설정하였으며, 신뢰도를 식 (25)로 추정한다(Usami et al., 2016).

$$\rho_1 = \frac{V(y_{i1})}{V(y_{i1}) + V(\epsilon_{yi1})} = \frac{V(x_{i1})}{V(x_{i1}) + V(\epsilon_{xi1})} = \frac{\phi_{Iy}^2}{\phi_{Iy}^2 + \psi_y^2} = \frac{\phi_{Ix}^2}{\phi_{Ix}^2 + \psi_x^2} \quad \text{식(25)}$$

(5) 시점 간 변수의 분산 비율

선행연구를 참고하여 두 시점 간 변수의 분산의 비율을 설정하였다. 시점 간에 분산의 비율은 잠재변수가 시간이 흐름에 따라 일정하게 유지되는 정도를 의미하는 안정성(stability)에 영향을 미친다. 안정성이 작은 조건, 중간 조건, 큰 조건에서 비교하기 위하여 1.05, 1.50, 3.00 세 가지로 설정하였다. 시점 간 변수의 분산 비율을 추정하는 식은 식 (26)로 나타낸다(Usami et al., 2016).

$$k = \frac{V(y_{i2})}{V(y_{i1})} = \frac{V(S_{yi} + (1 + \beta_y)y_{i1} + \gamma_y x_{i1} + \delta_{yi2} + \epsilon_{yi2})}{\phi_{Iy}^2 + \psi_y^2} \quad \text{식 (26)}$$

$$= \frac{V(x_{i2})}{V(x_{i1})} = \frac{V(S_{xi} + (1 + \beta_x)x_{i1} + \gamma_x y_{i1} + \delta_{xi2} + \epsilon_{xi2})}{\phi_{Ix}^2 + \psi_x^2}$$

(6) 결정계수 R^2

선행연구를 참고하여 두 번째 시점에서 식 (22.2)의 결정계수를 설정하였다. 결정계수는 회귀식에 의해 설명력을 의미하며, 크기가 1에 가까울수록 설명력이 높은 것을 의미한다. 식 (22.2)의 결정계수를 구하는 식은 식 (27)과 같다. 결정계수 R^2 은 작은 값, 중간 값, 큰 값으로 나누어 비교하기 위하여 .2, .5, .8 세 가지로 설정하였다. R^2 이 클수록 두 번째 시점의 회귀식에서 설명되는 분산이 큰 것을 의미한다(Usami et al., 2016).

$$\begin{aligned} R^2 &= 1 - \frac{V(\delta_{yi2})}{V(y_{i2})} = 1 - \frac{\omega_y^2}{V(S_{yi} + (1 + \beta_y)y_{i1} + \gamma_y x_{i1} + \delta_{yi2})} && \text{식 (27)} \\ &= 1 - \frac{V(\delta_{xi2})}{V(x_{i2})} = 1 - \frac{\omega_x^2}{V(S_{xi} + (1 + \beta_x)x_{i1} + \gamma_x y_{i1} + \delta_{xi2})} \end{aligned}$$

(6) T_2 에서 분산의 비율

선행연구를 참고하여 기울기요인의 분산(P_s), 자기회귀모수의 분산(P_b), 커플링(교차지연)모수의 분산(P_g)을 설정하였다. 세 가지 분산은 각각 식 (28.1), (28.2), (28.3)으로 추정된다. $(P_s, P_b, P_g) = (0.080, 0.900, 0.020), (0.050, 0.900, 0.050), (0.020, 0.900, 0.080), (0.000, 0.900, 0.100), (0.320, 0.600, 0.080), (0.200, 0.600, 0.200), (0.080, 0.600, 0.320), (0.000, 0.600, 0.400), (0.560, 0.300, 0.140), (0.350, 0.300, 0.350), (0.140, 0.300, 0.560), (0.000, 0.300, 0.070)$ 으로 총 열두 가지로 설정하였다. 분산의 값이 클수록 두 번째 시점에서 각 모수에서 설명되는 분산의 총량이 큰 것을

의미한다. $P_s = 0$ 은 기울기의 분산이 $0(\phi_{Sx}^2 = \phi_{Sy}^2 = 0)$ 인 고정효과가 가정되므로 시플레이션 데이터는 두 시점-패널모형에서 생성되는 것을 의미한다(Usami et al., 2016).

$$P_s = \frac{V(S_{yi})}{V(y_{i2}) - V(\delta_{yi2})} = \frac{\phi_{Sy}^2}{V(y_{i2}) - \omega_y^2} \quad \text{식 (28.1)}$$

$$= \frac{V(S_{xi})}{V(x_{i2}) - V(\delta_{xi2})} = \frac{\phi_{Sx}^2}{V(x_{i2}) - \omega_x^2}$$

$$P_g = \frac{V(\gamma_y x_{i1})}{V(y_{i2}) - V(\delta_{yi2})} = \frac{\gamma_y^2 \phi_{Ix}^2}{V(y_{i2}) - \omega_y^2} \quad \text{식 (28.2)}$$

$$= \frac{V(\gamma_x y_{i1})}{V(x_{i2}) - V(\delta_{xi2})} = \frac{\gamma_x^2 \phi_{Iy}^2}{V(x_{i2}) - \omega_x^2}$$

$$P_b = 1 - P_s - P_g \quad \text{식 (28.3)}$$

(7) 모수 제약

주요 조작 요인의 효과의 해석을 용이하게 하기 위해⁸⁾, 기울기요인 간의 공분산($\phi_{y_s x_s}$), 다른 변수의 절편과 기울기 간의 두 개의 공분산($\phi_{y_s x_i}$, $\phi_{y_i x_s}$), 잔차분산(ω_{yx})은 0으로 제한하였다⁹⁾. 추가적으로, 매우 작은 값의 모수로 인해 발생할 수 있는 반올림 계산 오류를 피하기 위해 요인평균을 $\mu_{1x} = \mu_{1y} = 50$, $\mu_{sx} = \mu_{sy} = 20$ 으로 설정하고, T_1 에서 준거변수의 분산을 $V(y_{ji}) = \phi_{Iy}^2 + \psi_y^2 =$

8) 모수 제약으로 잠재변화점수모형의 모든 모수를 고유한 값으로 고정하였다.

9) 잔차 분산을 0으로 고정하여 모형 적합도를 증가시키고 부적절한 해석의 위험을 방지하였다 (Usami et al., 2016).

$V(x_{j1}) = \phi_{Ix}^2 + \psi_x^2 = 1$ 으로 설정하였다(Usami et al., 2016).

<표 2> 시뮬레이션 조건

	조건	값
관심 조작요인	기울기 요인과 절편 요인 간의 상관 (r_{IS})	.0
		.2
		.4
		.6
	표본 크기 (I)	200
		500
		1500
		3000
	두 변수의 기울기 요인 간의 상관 (r_{IyIx})	.2
		.5
.8		
.8		
첫 번째 시점에서 측정 신뢰도 (ρ_1)	.2	
	.5	
	.8	
	.8	
첫 번째 시점과 두 번째 시점 간의 변수들의 분산의 비율 (k)	1.05	
	1.50	
	3.00	
	3.00	
기타 조작요인	두 번째 시점의 결정계수 (R^2)	.2
		.5
		.8
		.8
	두 번째 시점에서 세 종류의 분산의 비율 (P_s, P_g, P_b)	0.080, 0.900, 0.020
		0.050, 0.900, 0.050
		0.020, 0.900, 0.080
		0.000, 0.900, 0.100
		0.320, 0.600, 0.080
		0.200, 0.600, 0.200
		0.080, 0.600, 0.320
		0.000, 0.600, 0.400
		0.560, 0.300, 0.140
		0.350, 0.300, 0.350
		0.140, 0.300, 0.560
		0.000, 0.300, 0.700

주. 관심 조작요인: $4(r_{IS}) \times 4(I) \times 3(r_{IyIx}) = 48$

기타 조작요인: $3(\rho_1) \times 3(k) \times 3(R^2) \times 12(P_s, P_g, P_b) = 324$

관심 조작요인 \times 기타 조작요인 = $48 \times 324 = 15,552$

2. 자료 분석

시뮬레이션으로 생성된 자료를 생성한 후 동일한 자료에 대하여 두 시점-잠재변화점수모형과 두 시점-패널모형으로 분석을 실시하고 그 결과를 비교하였다. 결과를 비교하기 위하여 모수 편향(Parameter Bias), 모수 추정치의 차이를 확인하고, 모형 선택절차의 수행을 비교하였다. 모형 선택절차에는 우도비 검정(Likelihood Ratio), 정보지수(Information Criteria), 모형 적합도 지수(Model Fit Indices)가 포함된다.

1) 모수 편향(Parameter Bias)

시뮬레이션을 통하여 생성된 자료에서 얻은 모수 추정치와 시뮬레이션 조건을 통하여 생성된 모수가 얼마나 유사한지 확인하였다. 각 모형의 커플링(교차지연) 계수 γ_y, γ_x 를 구하고 전집의 값과 비교했으며, 식 (29)로 추정한다(Usami et al., 2016).

$$\text{Bias} = \frac{|\hat{\gamma}_y - \gamma_y| + |\hat{\gamma}_x - \gamma_x|}{2} \quad \text{식(29)}$$

$\hat{\gamma}_y$ 와 $\hat{\gamma}_x$ 는 각각 변수 y 와 x 에 대한 커플링(교차지연) 모수의 추정치를 나타내며, γ_x 와 γ_y 는 각각 변수 y 와 x 에 대한 커플링(교차지연)의 모수를 나타낸다. 편향이 클수록 모수값과 실제 자료를 통하여 추정된 모수 추정치의 차이가 큰 것을 의미한다.

2) 모수 추정치의 차이

두 시점-잠재변화점수모형의 커플링 모수 추정치와 두 시점-패널모형의 교차지연 모수 추정치의 차이를 추정하여 종단관계에 대하여 두 모형이 얼마나 서로 다른지 비교하였으며, 식 (30)과 같다(Usami et al., 2016).

$$\frac{|\widehat{\gamma_{y2W-LCS}} - \widehat{\gamma_{y2WPM}}| + |\widehat{\gamma_{x2W-LCS}} - \widehat{\gamma_{x2WPM}}|}{2} \quad \text{식(30)}$$

$\widehat{\gamma_{y2W-LCS}}$ 은 두 시점-잠재변화점수모형의 변수 y 와 x 에 대한 커플링 모수 추정치를 나타내며, $\widehat{\gamma_{y2WPM}}$ 은 두 시점-패널모형의 변수 y 와 x 에 대한 교차지연 모수의 추정치를 나타낸다. 모수 추정치의 차이가 클수록 두 모형이 추정하는 종단 관계에 대한 차이가 큰 것을 의미한다.

3) 우도비 검정(Likelihood Ratio; LR)

우도비 검정은 두 모형의 우도비를 계산해 두 모형간의 우도비가 유의한 차이가 있는지 검정하는 방식이다. 모형 A와 모형 B를 비교하기 위한 로그 우도함수 식은 식 (31)로 표현할 수 있다.

$$G = -2\ln \mathcal{L}_A - (-2\ln \mathcal{L}_B) \quad \text{식 (31)}$$

$\ln \mathcal{L}_A$ 는 모형 A의 로그 우도함수, $\ln \mathcal{L}_B$ 는 모형 B의 로그 우도함수값을 나타낸다. G 는 각 모형의 로그 우도함수에 (-2)를 곱한 값의 차이값이다. G 는 χ^2 분포를 따르기 때문에 χ^2 차이 검정을 통한 모형 비교가 가능하다. χ^2 분포의 자유도는 두 모형에서 추정되는 미지수 개수의 차이값이다.

두 개의 모형 A, B에 대해 모형 A의 독립변수가 모두 모형 B에 포함되며,

모형 B는 추가적인 독립변수를 포함하는 내재된 관계를 가정할 경우, χ^2 차이 검정의 영가설은 ‘모형 A와 모형 B의 적합도가 같다’이며, 식 (32)로 나타낼 수 있다.

$$H_0 : -2\ln \mathcal{L}_A = -2\ln \mathcal{L}_B \quad \text{식 (32)}$$

χ^2 차이 검정이 유의할 경우 더 복잡한 모형 B를 선택해야 하며, 유의하지 않을 경우 더 단순한 모형 A를 선택해야 한다(홍세희, 2005).

본 연구의 목표는 두 시점 이변량 잠재변화점수모형과 두 시점 패널모형을 비교하는 것이기 때문에, 두 모형의 D 값의 유의성을 확인해야 한다. 두 시점-잠재변화점수모형과 두 시점-패널모형은 기울기 요인의 공분산과 기울기 요인의 분산 $\phi_{S_y}^2 = \phi_{S_x}^2 = \phi_{I_x S_x} = \phi_{I_y S_y} = \phi_{S_y I_x} = \phi_{S_y S_x} = \phi_{I_x S_x} = 0$ 을 가정할 때 두 시점 패널모형으로 감소하는 것이기 때문에 D 값의 자유도는 7이 된다. 유의수준 5%에서 자유도가 7인 χ^2 분포의 임계치는 14.067이다. 유의수준 5%에서 영가설을 기각하게 될 경우 더 복잡한 모형인 두 시점 이변량 잠재변화점수모형을 선택해야 한다. 반대로 영가설을 채택하게 될 경우 더 단순한 모형인 두 시점 패널모형을 선택한다.

4) 정보지수(Information Criterion; CI)

정보지수는 모형의 비교를 위한 지수로 우도비 검정과 마찬가지로 내재된 관계의 모형 비교를 위해 사용이 가능하며, 내재되지 않은 관계의 모형도 비교가 가능하다. 대표적인 정보지수로 Akaike 정보지수(Akaike's information criterion; AIC, Akaike, 1973), 베이저안 정보지수(Bayesian information criterion; BIC, Schwarz, 1978), sample-size adjusted BIC(ssBIC; Sclove, 1987) 등이 있다. 정보지수의 일반적인 형태는 식 (33)과 같다.

$$-2\log[ML(k)] + a(n)m(k) \quad \text{식 (33)}$$

모형 k 의 우도함수에 -2 를 곱한 $-2[ML(k)]$ 는 모형의 적합도를 의미한다. $m(k)$ 는 모형 k 에서 추정된 모수의 수로, 모형의 간명성을 의미한다. n 은 표본 크기를 의미하며, $a(n)$ 은 추가적인 모수 추정치를 의미하는 일종의 패널티 항이다.

AIC는 모형의 적합도와 간명성을 고려하는 지수이며, BIC와 ssBIC는 모형 적합도, 간명성 외에도 표본크기를 함께 고려하는 지수이다. AIC, BIC, ssBIC는 각각 식 (34), 식 (35), 식 (36)으로 나타낸다(Solve, 1987).

$$AIC = -2\log[ML(k)] + 2[m(k)] \quad \text{식 (34)}$$

$$BIC = -2\log[ML(k)] + \log(n)[m(k)] \quad \text{식 (35)}$$

$$ssBIC = -2\log[ML(k)] + \log\left(\frac{n+2}{24}\right)[m(k)] \quad \text{식 (36)}$$

식 (32)의 $a(n)$ 을 어떻게 정의하는지에 따라 서로 다른 정보지수가 추정된다. 구체적으로, AIC는 $a(n)$ 을 표본의 크기와 관계없이 항상 2로 고정한다. BIC는 $a(n)$ 을 $\log(n)$ 으로 계산하며, ssBIC는 $\log\left[\frac{n+2}{24}\right]$ 으로 계산한다. 표본 크기가 8보다 크면 BIC는 AIC보다 더 가혹하게 모수 추정치에 패널티를 부과하게 되는데, 이로 인하여 BIC가 AIC에 비해 더 작은 모형을 선호하게 된다. 표본크기가 176보다 클 경우 ssBIC는 AIC보다 큰 값이 추정된다(Henson, Resise, & Kim, 2007).

5) 모형 적합도 지수(Model Fit Indices)

구조방정식모형의 장점 중 한 가지는 이론 모형에 대한 통계적 평가가 가능한 점이다. 이론 모형이 실제 자료에 얼마나 잘 부합되는지를 평가하고 이를 바탕으로 모형을 수용할 것인지를 결정할 수 있다. 본 연구에서는 CFI, RMSEA 그리고 SRMR을 통해 모형을 평가하고자 한다.

CFI(Comparative Fit Index; Bentler, 1990)는 기저모형에 비해 이론모형이 자료를 얼마나 잘 설명하는지 보여주는 상대적 적합도 지수의 한 종류이다. 기저모형(base model)은 측정변수들 간에 관계가 없다고 가정하는 모형으로, 최악의 모형 또는 영 모형(null model)이라고 불린다. 이론모형은 이론에 따라 측정 변수들 간의 관계를 적절히 설정한 모형을 의미한다. CFI의 공식은 식 (37)과 같다.

$$CFI = \frac{\lambda_b - \lambda_t}{\lambda_b} = \frac{F_{ob}^{\sim} - F_{ot}^{\sim}}{F_{ob}^{\sim}} \quad \text{식 (37)}$$

λ_b 는 기저모형의 전집오류를, λ_t 는 이론모형의 전집오류를 나타낸다. CFI 값을 구할 때, 전집오류 값을 구하는 것이 불가능하기 때문에 기저모형의 표본오류 F_{ob}^{\sim} 와 이론모형의 표본오류 F_{ot}^{\sim} 를 대신 사용하여 CFI 값을 계산한다. CFI 값은 0부터 1.0 사이의 값으로 .95 이상이면 좋은 적합도 지수를 나타내며, 0.9 이상이면 적합한 모형으로 간주한다(Bentler, 1990). 본 연구에서는 더 높은 CFI 값을 갖는 모형을 더 좋은 모형으로 선택해야 한다.

CFI는 전집오류를 바탕으로 계산하기 때문에 표본크기에 영향을 받지 않는다는 장점이 있지만, 모형의 간명성을 고려하지 않기 때문에 모형이 불필요하게 복잡해도 좋은 CFI 값이 나올 수 있다는 단점이 있다. 따라서, 모형의 간명성을 고려하는 적합도 지수와 함께 고려하는 것이 권장된다(홍세희, 2000).

RMSEA(Root Mean Square Error of Approximation; Steiger & Lind, 1980)는 이론모형의 적합도를 다른 모형의 적합도와 비교해 상대적으로 평가하지 않고, 자료와 이론모형이 자료와 얼마나 잘 부합되는지를 절대적으로 평가하는 절대적 적합도 지수이다. RMSEA를 구하기 위한 공식은 식 (38)과 같다.

$$\text{RMSEA} = \sqrt{\frac{F_o^{\sim}}{df}} \quad \text{식 (38)}$$

F_o^{\sim} 는 표본크기에 영향을 받지 않고 모형의 적합도를 고려하기 때문에, CFI와 마찬가지로 표본크기에 영향을 받지 않는다. CFI와 다르게 RMSEA 값을 구할 때 F_o^{\sim} 를 모형의 자유도 df 로 나누어 모형의 간명성도 고려한다(홍세희, 2000).

RMSEA 값은 하한값은 0이며 상한값에는 제한이 없다. RMSEA 값은 작을수록 좋은 적합도를 나타낸다. 구체적으로, RMSEA < .05이면 좋은 적합도 (close fit), RMSEA < .08이면 괜찮은 적합도 (reasonable fit), RMSEA < .10이면 보통 적합도 (mediocre fit), RMSEA > 1.0이면 나쁜 적합도(unacceptable fit)라고 한다(Browne & Cudeck, 1993). 본 연구에서는 더 낮은 RMSEA 값을 갖는 모형을 더 좋은 모형으로 선택해야 한다.

SRMR(Standardized Root Mean Square Residual)은 RMR(Root Mean Square Residual)을 표준화한 적합도 지수이다. RMR은 공분산 잔차, 즉 관찰된 공분산과 예측된 공분산 간의 차이를 기반으로 하기 때문에, 완벽한 모형일수록 0에 가까운 값을 가진다. RMR은 표준화된 값이 아니기 때문에 관찰변수의 척도에 따라 그 범위가 달라지기 때문에 RMR 값을 해석할 때 문제가 발생하게 된다. 이를 해결하기 위해 SRMR은 표집된 공분산 행렬과 예측 공분산 행렬을 상관행렬로 변환하여 차이값을 계산하며, 식 (39)으로 나타낸다.

$$SRMR = \sqrt{\frac{2 \sum_{i=1}^p \sum_{j=1}^i \left[\frac{(s_{ij} - \hat{\sigma}_{ij})^2}{(s_{ii}s_{jj})} \right]}{p(p+1)}} \quad \text{식(39)}$$

SRMR의 하한값은 0으로, 값이 작을수록 좋은 적합도를 나타낸다. 구체적으로, SRMR ≤ .08이면 좋은 적합도 지수를 나타낸다(Hu & Bentler, 1999). 다만 SRMR은 공분산 구조를 기반으로 하고 평균 구조에 대하여 고려하지 않기 때문에 모형에 따라 해석을 주의하여야 한다(Kline, 2015).

V. 연구결과

1. 커플링 및 교차지연 모수 편향

두 변수가 서로 영향을 미치는 종단 관계에 대한 두 모형의 차이를 확인하기 위하여 각 조건에 따른 커플링(교차지연) 모수의 편향을 추정하였다. 그 결과, 두 시점-잠재변화점수모형에 대한 편향의 총 평균은 0.563, 두 시점-패널모형에 대한 편향의 총 평균은 0.449로 두 시점-잠재변화점수모형에 대한 모수 편향이 더 큰 것으로 나타났다. 추가적으로, 시뮬레이션 조건의 수준에 따른 편향을 비교하기 위하여 편향의 주변 평균을 추정하였으며 결과를 <표 3>에 제시하였다. 주변 평균이란 요인의 수준별로 평균을 추정하는 것을 의미한다.

첫 번째로 절편 요인과 기울기 요인 간의 상관 조건의 수준에 따른 두 시점-잠재변화점수모형과 두 시점-패널모형의 모수 편향을 확인하였다. 그 결과, 두 시점-잠재변화점수모형의 경우 절편 요인과 기울기 요인의 상관이 0일 때($r_{IS} = 0$) 0.56280, .2일 때($r_{IS} = .2$) 0.56246, .4일 때($r_{IS} = .4$) 0.56344, .6일 때($r_{IS} = .6$) 0.56309로 나타났다. 두 시점-패널모형의 경우 절편 요인과 기울기 요인의 상관이 0일 때($r_{IS} = 0$) 0.44905, .2일 때($r_{IS} = .2$) 0.44868, .4일 때($r_{IS} = .4$) 0.44965, .6일 때($r_{IS} = .6$) 0.44914로 나타났다. 두 모형 모두 절편 요인과 기울기 요인의 상관 조건의 수준에 따라 모수 편향이 통계적으로 유의한 차이가 없는 것으로 나타났다.

두 번째로, 사례 수 조건의 수준에 따른 두 시점-잠재변화점수모형과 두 시점-패널모형의 모수 편향을 확인하였다. 그 결과, 두 시점-잠재변화점수모형의 경우 사례 수가 200일 때($I = 200$) 0.57361, 500일 때($I = 500$) 0.56332, 1,500일

때($I=1,500$) 0.55771, 3,000일 때($I=3,000$) 0.55715로 나타났다. 사례 수 수준에 따른 두 시점-잠재변화점수모형의 모수 편향은 통계적으로 유의한 차이가 있었다. 구체적으로, 사례 수가 200인 조건은 사례 수가 500, 1,500, 3,000인 조건보다 모수 편향이 큰 것으로 나타났다. 두 시점-패널모형의 경우 사례 수가 200일 때($I=200$) 0.45505, 500일 때($I=500$) 0.44967, 1,500일 때($I=1,500$) 0.44605, 3,000일 때($I=3,000$) 0.44574로 나타났다. 사례 수 수준에 따른 두 시점-패널모형의 모수 편향은 통계적으로 유의한 차이가 있었다. 구체적으로, 사례 수가 200인 조건과 사례수 500인 조건의 모수 편향은 동일한 것으로 나타났으며, 사례 수가 500, 1,500, 3,000인 조건의 모수 편향은 동일한 것으로 나타났다.

세 번째로 절편 요인의 상관의 수준에 따른 두 모형의 모수 편향을 확인하였다. 두 시점-잠재변화점수모형에 대한 모수 편향은 절편 요인의 상관이 .2일 때($r_{IyIx} = .2$) 0.56399, .5일 때($r_{IyIx} = .5$) 0.56182, .8일 때($r_{IyIx} = .8$) 0.56304로 나타났다. 절편 요인의 상관의 수준에 따른 두 시점-잠재변화점수모형의 모수 편향은 통계적으로 유의한 차이가 없었다. 이는 절편 요인의 모든 수준에서 두 시점-잠재변화점수모형의 모수 편향이 같은 것을 의미한다. 두 시점-패널모형에 대한 모수 편향은 절편 요인의 상관이 .2일 때($r_{IyIx} = .2$) 0.44965, .5일 때($r_{IyIx} = .5$) 0.44870, .8일 때($r_{IyIx} = .8$) 0.44904로 나타났다. 절편 요인 간의 상관의 수준에 따른 두 시점-패널모형의 모수 편향은 통계적으로 유의한 차이가 없었다. 이는 절편 요인의 모든 수준에서 두 시점-잠재변화점수모형의 모수 편향이 같은 것을 의미한다.


시물레이션의 세 가지 조건 중 사례 수 조건의 수준에 따라 편향이 통계적으로 유의하게 차이가 있었다. 구체적으로, 사례 수가 200인 경우(0.456)에 사례 수가 500(0.450), 1500(0.447), 3000(0.446)인 경우보다 편향이 더 큰 것으로 나타났다. 이는 사례 수가 큰 조건보다 작은 조건에서 교차지연 모수값과 모

수 추정치의 차이가 큰 것을 의미한다.

연구 결과를 종합하였을 때, 세 가지 조건의 모든 수준에서 두 시점-잠재변화점수모형의 모수 편향이 두 시점-패널모형의 모수 편향보다 큰 것으로 나타났다. 조건의 수준에 따른 각 모형의 모수 편향을 비교한 결과, 두 모형 모두 사례 수 조건에 대해서만 조건의 수준에 따라 모수 편향이 통계적으로 다른 것을 확인하였다. 두 모형 모두 사례 수가 200일 때 모수 편향이 가장 큰 것으로 나타났다.

<표 3> 시뮬레이션 조건별 두 시점-잠재변화점수모형과 두 시점-패널모형에 대한 커플링(교차지연) 모수 편향의 주변 평균

조건	두 시점-잠재변화점수모형	두 시점-패널모형
전체	0.56295	0.44913
$r_{IS} = 0$	0.56280	0.44905
$r_{IS} = .2$	0.56246	0.44868
$r_{IS} = .4$	0.56344	0.44965
$r_{IS} = .6$	0.56309	0.44914
$I = 200$	0.57361	0.45505
$I = 500$	0.56332	0.44967
$I = 1,500$	0.55771	0.44605
$I = 3,000$	0.55715	0.44574
$r_{IyIx} = .2$	0.564	0.450
$r_{IyIx} = .5$	0.562	0.449
$r_{IyIx} = .8$	0.563	0.449



<그림 3> 시뮬레이션 조건별 두 시점-잠재변화점수모형과 두 시점-패널모형에 대한 커플링(교차지연) 모수 편향의 주변 평균. 오차 막대는 표준오차를 나타낸다.

2. 커플링 모수 추정치와 교차지연 모수 추정치의 차이

두 변수가 서로 영향을 미치는 종단 관계와 관련하여 두 모형의 차이를 확인하기 위하여 두 시점-잠재변화점수모형의 커플링 모수 추정치와 두 시점-패널모형의 커플링 모수 추정치의 차이를 추정하였다. 모수 추정치의 차이가 클수록 두 모형이 추정하는 종단 관계의 차이가 큰 것을 의미한다. 커플링(교차지연) 모수 추정치의 차이의 총 평균은 0.19754였다. 세 가지 조건의 수준에 따른 모수 추정치의 차이를 비교하였으며, 그 결과를 <표 3>에 제시하였다.

첫 번째로 절편 요인과 기울기 요인의 상관 조건의 수준에 따른 모수 추정치를 확인하였다. 그 결과, 절편 요인과 기울기 요인의 상관이 0일 때($r_{IS} = 0$) 0.19766, .2일 때($r_{IS} = .2$) 0.19688, .4일 때($r_{IS} = .4$) 0.19812, .6일 때($r_{IS} = .6$) 0.19750으로 나타났다. 절편 요인과 기울기 요인의 상관의 수준에 따른 모수 추정치를 비교한 결과, 절편 요인과 기울기 요인의 상관의 수준에 따른 커플링(교차지연)모수 추정치는 통계적으로 유의한 차이가 없었다. 이는 절편 요인과 기울기 요인의 상관 조건의 모든 수준에서 모수 추정치가 동일한 것을 의미한다.

두 번째로 사례 수 조건의 수준에 따른 모수 추정치의 차이를 확인하였다. 사례 수가 200일 때($I = 200$) 0.22747, 500일 때($I = 500$) 0.20055, 1,500일 때($I = 1,500$) 0.18521, 사례 수가 3,000일 때($I = 3,000$) 0.17966으로 나타났다. 사례 수 조건의 수준에 따른 모수 추정치를 비교한 결과, 사례 수 조건의 수준에 따른 모수 추정치는 통계적으로 유의한 차이가 있었다. 구체적으로, 사례 수가 200일 때 모수 추정치의 차이가 가장 크고, 뒤이어 500, 1,500, 3,000 순으로 모수 추정치의 차이가 큰 것으로 나타났다.


세 번째로 절편 요인 간의 상관의 수준에 따른 모수 추정치의 차이를 확인하였다. 그 결과, 절편 요인 간의 상관이 .2일 때($r_{IyIx} = .2$) 0.19784, .5일 때

($r_{IyIx} = .5$) 0.19713, .8일 때($r_{IyIx} = .8$) 0.1975로 나타났다. 절편 요인 간의 상관 수준에 따른 모수 추정치의 차이를 비교한 결과, 절편 요인 간의 상관의 수준에 따른 모수 추정치의 차이가 통계적으로 유의하지 않았다. 이는 절편 요인 간의 상관 조건의 모든 수준에서 모수 추정치의 차이가 동일한 것을 의미한다.

결과를 종합하면 다음과 같다. 두 시점-잠재변화점수모형의 커플링 모수 추정치와 두 시점-패널모형의 교차지연 모수 추정치의 차이를 조건의 수준별로 비교한 결과, 사례 수 조건에 대해서만 조건의 수준별로 모수 추정치의 차이가 통계적으로 유의하였다. 사례 수가 200, 500, 1,500, 3,000 순으로 모수 추정치의 차이가 큰 것을 확인하였다.

<표 4> 시뮬레이션 조건별 두 시점-잠재변화점수모형의 커플링 모수 추정치와 두 시점-패널모형의 교차지연 모수 추정치의 차이에 대한 주변 평균

조건	모형 간 커플링(교차지연) 모수 추정치의 차이
전체	0.19754
$r_{IS} = 0$	0.19766
$r_{IS} = .2$	0.19688
$r_{IS} = .4$	0.19812
$r_{IS} = .6$	0.19750
$I = 200$	0.22474
$I = 500$	0.20055
$I = 1,500$	0.18521
$I = 3,000$	0.17966
$r_{IyIx} = .2$	0.19784
$r_{IyIx} = .5$	0.19713
$r_{IyIx} = .8$	0.19765



<그림 4> 시뮬레이션 조건별 두 시점-잠재변화점수 모형의 커플링 모수 추정치와 두 시점-패널모형의 교차지연 모수 추정치의 차이에 대한 주변평균. 오차 막대는 표준 오차를 나타낸다.


3. 종단 관계의 존재와 관련하여 두 모형이 서로 다른 결론을 보이는 빈도

<그림 5>는 두 시점-잠재변화점수 모형과 두 시점-패널모형이 종단 관계의 존재에 대하여 서로 다른 결과를 보이는 경우의 비율을 나타낸다. 두 모형이 종단(인과) 관계의 존재에 대하여 서로 다른 결과를 보이는 경우는 모형 간의 커플링(교차지연) 모수 γ_y 또는 γ_x (또는 둘 다)의 통계적 유의성이 서로 다른 것을 의미한다. 예를 들어, 두 시점-잠재변화점수 모형의 γ_x 는 통계적으로 유의한 반면에, 두 시점-패널모형의 γ_x 는 통계적으로 유의하지 않을 때 두 모형 간의 종단 관계의 존재에 대하여 서로 다른 결과를 보였다고 할 수 있다. 두 모형 중 두 시점-잠재변화점수모형에만 포함되는 기울기 요인, 절편 요인 ($\phi_{Sy.Sx}, \phi_{Sy.Iy}, \phi_{Sy.Ix}, \phi_{Iy.Sx}, \phi_{Ix.Sx}$), 기울기 요인과 절편 요인의 분산($\phi_{Sy}^2, \phi_{Sx}^2, \phi_{Iy}^2, \phi_{Ix}^2$)으로 인하여 종단 관계에 대하여 두 모형 간에 서로 다른 결과가 추정된다(Usami et al., 2015).


두 모형이 종단 관계에 대하여 서로 다른 결과를 보인 비율은 0.48%로 나타났다. 표준오차는 0.02보다 작았다. 이 중 사례 수가 200인 조건에서 두 모형이 종단 관계에 대하여 서로 다른 결과를 보인 비율이 가장 높은 것으로 나타났다(1.92%). 반대로 사례 수가 500, 1500, 3000인 조건에서 두 모형은 종단 관계의 존재에 대하여 항상 일치하는 결과를 보인 것으로 나타났다(0%). 이는 사례 수가 큰 조건보다 200 이하의 작은 조건에서 두 모형이 서로 다른 결과를 보이는 확률이 높은 것을 의미한다.

두 모형이 종단 관계에 대하여 서로 다른 결과를 보이는 것을 구체적으로 확인하기 위하여 각 모형의 커플링(교차지연) 모수만 통계적으로 유의한 비율을 확인하였으며, 그 결과를 <그림 6>에 제시하였다. 그 결과, 두 시점-패널모

형의 교차지연 모수 추정치만 통계적으로 유의한 경우에 대한 비율이 두 시점-잠재변화점수모형의 커플링 모수 추정치만이 통계적으로 유의한 경우에 대한 비율이 더 높은 것으로 나타났다. 동일한 자료에 대하여 두 모형에서 서로 다른 결과가 나타나는 것은 두 시점-잠재변화점수에만 포함되는 기울기 요인의 공분산과 기울기 요인과 첫 번째 시점의 잠재변수 간에 발생하는 다중공선성 (multicollinearity) 때문이다. 다중공선성으로 인해 자기회귀 모수(β_y 및 β_x)의 추정이 불안정해지고, 이는 커플링 또는 교차지연 모수(γ_y 및 γ_x)의 불안정한 추정에 간접적으로 영향을 미치게 된다(Usami et al., 2015)



<그림 5> 두 시점-잠재변화점수모형과 두 시점-패널모형이 종단 관계의 존재에 대하여 서로 다른 결과를 보이는 비율. 오차 막대는 표준 오차를 나타낸다.



<그림 6> 두 시점-잠재변화점수모형(또는 두 시점-패널모형)의 커플링(교차지연) 모수만 통계적으로 유의한 경우의 비율. 오차 막대는 표준 오차를 나타낸다.

4. 올바른 모형을 선택한 비율

모형 선택 절차(우도비 검정, 정보지수, 모형적합도 지수)의 성능을 비교하기 위하여 시뮬레이션 조건에 따른 모형 선택 절차의 성능, 즉 올바른 모형을 선택한 비율을 확인하였다. 두 시점-패널모형은 기울기 요인의 고정효과를 가정하기 때문에 기울기 요인의 분산 $P_s = 0$ 을 가정하며, 두 시점-잠재변화점수모형은 기울기 요인의 무선효과를 가정하기 때문에 기울기 요인의 분산 $P_s \neq 0$ 을 가정한다. 따라서 올바른 모형을 선택하는 것은 두 시점-잠재변화점수모형과 두 시점-패널모형을 비교하여 하나의 모형을 선택할 때 두 번째 시점의 기울기 분산의 비율 $P_s = 0$ 인 조건에서 두 시점-패널모형을 선택하고, 그 외에 $P_s \neq 0$ 인 조건에서는 두 시점-잠재변화점수모형을 선택하는 것을 의미한다.

전체 조건에서 모형 선택절차별로 올바른 모형을 선택한 비율을 비교한 결과, BIC와 ssBIC의 성능이 가장 우수하였으며, 모형 적합도 지수 중에서는 RMSEA의 성능이 가장 우수하였다. 조건의 수준에 따른 모형 선택절차의 성능을 비교하기 위하여 세 가지 조건의 모든 수준에서 모형 선택절차의 성능을 확인하였으며, 그 결과를 <표 5>에 제시하였다.

첫 번째로, 절편 요인과 기울기 요인의 상관 조건의 수준에 따른 모형 선택절차의 성능을 비교하였다. 구체적으로, 절편 요인과 기울기 요인의 상관이 0일 때($r_{IS} = 0$) BIC(0.75000), ssBIC(0.750000)의 성능이 가장 우수하였으며, 모형 적합도 지수 중에서는 RMSEA(0.69630)의 성능이 가장 우수하였다. 절편 요인과 기울기 요인의 상관이 .2일 때($r_{IS} = .2$) BIC(0.75000)의 성능이 가장 우수하였으며, 모형 적합도 지수 중에서는 RMSEA(0.69552)의 성능이 가장 우수하였다. 절편 요인과 기울기 요인의 상관이 .4일 때($r_{IS} = .4$) BIC(0.75000)의 성능이 가장 우수하였으며, 모형 적합도 지수 중에서는 RMSEA의 성능(0.69378)이 가

장 우수하였다. 절편 요인과 기울기 요인의 상관인 .6일 때($r_{IS} = .6$) BIC(0.75000)의 성능이 가장 우수하였으며, 모형 적합도 지수 중에서는 RMSEA(0.69851)의 성능이 가장 우수하였다.

두 번째로 사례 수 조건의 수준에 따른 올바른 모형을 선택한 비율을 비교하였다. 그 결과, 사례 수가 200일 때($I=200$) BIC(0.75000)의 성능이 가장 우수하였으며, 모형 적합도 지수 중에서는 RMSEA(0.66559)의 성능이 가장 우수하였다. 사례 수가 500일 때($I=500$) BIC(0.75000), ssBIC(0.75000)의 성능이 가장 우수하였으며, 모형 적합도 지수 중에서는 RMSEA(0.68555)의 성능이 가장 우수하였다. 사례 수가 1,500일 때($I=1,500$) BIC(0.750000), ssBIC(0.750000)의 성능이 가장 우수하였으며, 모형 적합도 지수 중에서는 RMSEA(0.70787)의 성능이 가장 우수하였다. 사례 수가 3,000일 때($I=3,000$) BIC(0.750000), ssBIC(0.750000)의 성능이 가장 우수하였으며, 모형 적합도 지수 중에서는 RMSEA(0.72510)의 성능이 가장 우수하였다.

세 번째로 절편 요인 간의 상관 조건의 수준에 따른 올바른 모형을 선택한 비율을 비교하였다. 그 결과, 절편 요인 간의 상관인 .2일 때($r_{IyIx} = .2$) BIC(0.75000)의 성능이 가장 우수하였으며, 모형 적합도 지수 중에서는 RMSEA(0.69479)의 성능이 가장 우수하였다. 절편 요인 간의 상관인 .5일 때($r_{IyIx} = .5$) BIC(0.75000)의 성능이 가장 우수하였으며, 모형 적합도 지수 중에서는 RMSEA(0.69834)의 성능이 가장 우수하였다. 절편 요인 간의 상관인 .8일 때($r_{IyIx} = .8$) BIC(0.75000)의 성능이 가장 우수하였으며, 모형 적합도 지수 중에서는 RMSEA(0.69495)의 성능이 가장 우수하였다.

추가적으로, 올바른 모형을 선택한 결과를 이분형 변수로 코딩(1=올바른 모형 선택, 0=올바르지 않은 모형 선택)하여 두 모형 간의 커플링(교차지연) 모수 추정치(γ_x, γ_y)의 차이와 상관분석을 실시하였다. 상관분석 결과, RMSEA를 제외한 모든 모형 선택 절차의 상관계수는 통계적으로 유의하지 않았다. 이는

RMSEA를 제외한 모든 모형 선택 절차가 모수 추정치의 차이와 어떠한 정적 혹은 부적 관계도 갖지 않는 것을 의미한다. RMSEA는 두 모형의 커플링(교차 지연) 모수 추정치의 차이와 부적인 상관 관계($r=-0.015$, $p<.001$)로 나타났다. 이는 모수 추정치의 차이가 작을수록 RMSEA의 성능이 좋아지는 관계를 의미한다.

<표 5> 시뮬레이션 조건별 올바른 모형을 선택한 비율

조건	우도비 검정	AIC	BIC	ssBIC	CFI	RMSEA	SRMR
전체	0.68255	0.74762	0.75000	0.74979	0.25067	0.69603	0.26986
$r_{IS} = 0$	0.68318	0.74861	0.75000	0.75000	0.25087	0.69630	0.26908
$r_{IS} = .2$	0.68066	0.74748	0.75000	0.74964	0.25072	0.69552	0.27063
$r_{IS} = .4$	0.68447	0.74702	0.75000	0.74969	0.25041	0.69378	0.26980
$r_{IS} = .6$	0.68189	0.74738	0.75000	0.74985	0.25067	0.69851	0.26991
$I = 200$	0.68488	0.74907	0.75000	0.74918	0.25267	0.66559	0.26512
$I = 500$	0.68323	0.74738	0.75000	0.75000	0.25000	0.68555	0.26759
$I = 1,500$	0.68143	0.74676	0.75000	0.75000	0.25000	0.70787	0.27202
$I = 3,000$	0.68066	0.74727	0.75000	0.75000	0.25000	0.72510	0.27469
$r_{IyIx} = .2$	0.68268	0.74749	0.75000	0.74988	0.25050	0.69479	0.27029
$r_{IyIx} = .5$	0.68268	0.74784	0.75000	0.74992	0.25085	0.69834	0.26887
$r_{IyIx} = .8$	0.68229	0.74753	0.75000	0.74958	0.25066	0.69495	0.27041

5. 종단 관계에 대하여 두 모형이 서로 다른 결과를 보일 때, 올바른 모형을 선택한 비율

두 시점-잠재변화점수모형과 두 시점-패널모형이 종단 관계에 대하여 서로 다른 결과가 나타나는 경우 올바른 모형을 선택한 비율을 <표 6>에 제시하였다. 두 모형이 종단 관계에 대하여 서로 다른 결과가 나타나는 경우 올바른 모형을 선택하는 것은 두 모형의 커플링(교차지연) 모수(γ_x, γ_y)의 통계적 유의성이 서로 다를 때, 기울기 요인 $P_s = 0$ 이면 두 시점-패널모형을 선택하고 $P_s \neq 0$ 이면 두 시점-잠재변화점수모형을 선택한 비율을 의미한다.

전체 조건에서 가장 우수한 성능의 모형 선택절차는 AIC(0.77480)였으며, 모형 적합도 지수 중에서는 RMSEA(0.69973)가 가장 우수한 성능을 보였다. 조건의 수준에 따라 모형 선택절차의 성능을 비교하여 <표 6>에 제시하였다. 첫 번째로 절편과 기울기 요인의 상관 조건에서 상관이 0일 때($r_{IS} = 0$) AIC(0.73684), ssBIC(0.73684)의 성능이 가장 우수하였으며, 모형 적합도 지수 중에서는 RMSEA(0.63158)의 성능이 가장 우수하였다. 절편과 기울기 요인의 상관이 .2일 때($r_{IS} = .2$) AIC(0.81319), BIC(0.81319), ssBIC(0.81319)의 성능이 가장 우수하였으며, 모형 적합도 지수 중에서는 RMSEA(0.73626)의 성능이 가장 우수하였다. 절편과 기울기 요인의 상관이 .4일 때(r_{IS}) AIC(0.71951)의 성능이 가장 우수하였으며, 모형 적합도 지수 중에서는 RMSEA(0.65854)의 성능이 가장 우수하였다. 절편과 기울기 요인의 상관이 .6일 때($r_{IS} = .6$) AIC(0.81905), BIC(0.81905), ssBIC(0.81095)의 성능이 가장 우수하였으며, 모형 적합도 지수 중에서는 RMSEA(0.76190)의 성능이 가장 우수하였다.

두 번째로 사례 수 조건의 수준에 따른 모형 선택절차의 성능을 비교하였다. 그 결과, 사례 수가 200일 때($I=200$) AIC(0.77480)의 성능이 가장 우수하

였으며, 모형 적합도 지수 중에서는 RMSEA(0.69973)의 성능이 가장 우수하였다. 사례 수가 500, 1,500, 3,000 조건에서는 모든 모형 선택절차의 비율이 0으로 나타났는데, 이는 사례 수가 500, 1,500, 3,000일 때 두 모형이 종단 관계에 대하여 서로 다른 결과를 보인 경우가 없었기 때문이다.

세 번째로 절편 요인 간의 상관 조건의 수준에 따른 모형 선택절차의 성능을 비교하였다. 절편 요인 간의 상관이 .2일 때($r_{IyIx} = .2$) AIC(0.69672), BIC(0.69672), ssBIC(0.69672)의 성능이 가장 우수하였으며, 모형 적합도 지수 중에는 RMSEA(0.62295)의 성능이 가장 우수하였다. 절편 요인 간의 상관이 .5일 때($r_{IyIx} = .5$) AIC(0.79710), ssBIC(0.79710)의 성능이 가장 우수하였으며, 모형 적합도 지수 중에서는 RMSEA(0.74638)의 성능이 가장 우수하였다. 절편 요인 간의 상관이 .8일 때($r_{IyIx} = .8$) AIC(0.81081)의 성능이 가장 우수하였으며, 모형 적합도 지수 중에서는 RMSEA(0.68919)의 성능이 가장 우수하였다.

<표 6> 종단 관계의 존재에 대하여 두 시점-잠재변화점수모형과 두 시점-패널 모형이 서로 다른 결과를 보일 때 모형 선택절차별 올바른 모형을 선택한 비율

조건	우도비 검정	AIC	BIC	ssBIC	CFI	RMSEA	SRMR
전체	0.69169	0.77480	0.76944	0.77212	0.23056	0.69973	0.23861
$r_{IS} = 0$	0.64211	0.73684	0.72632	0.73684	0.26316	0.63158	0.28421
$r_{IS} = .2$	0.74725	0.81319	0.81319	0.81319	0.18681	0.73626	0.18681
$r_{IS} = .4$	0.69512	0.71951	0.70732	0.70732	0.29268	0.65854	0.29268
$r_{IS} = .6$	0.68571	0.81905	0.81905	0.81905	0.19048	0.76190	0.20000
$I = 200$	0.69169	0.77480	0.76944	0.77212	0.23056	0.69973	0.23861
$I = 500$	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000
$I = 1,500$	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000
$I = 3,000$	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000
$r_{IyIx} = .2$	0.64754	0.69672	0.69672	0.69672	0.30328	0.62295	0.30328
$r_{IyIx} = .5$	0.70290	0.79710	0.78986	0.79710	0.21014	0.74638	0.21014
$r_{IyIx} = .8$	0.74324	0.81081	0.79730	0.79730	0.20270	0.68919	0.21622

Ⅵ. 논의

두 시점-잠재변화점수모형과 두 시점-패널모형은 두 시점 종단자료 분석에서 활용되는 대표적인 통계 모형으로, 두 시점에서 시간의 흐름에 따른 변화를 추정한다. 시간의 흐름에 따라 두 변수가 서로 영향을 미치는 효과를 두 시점-잠재변화점수모형의 경우 커플링 효과라고 하며, 두 시점-패널모형의 경우 교차지연 효과라고 한다. 시간의 흐름에 따라 두 변수가 서로 영향을 미치는 효과를 추정하는 목적은 동일하지만, 통계적인 가정이 다르기 때문에 동일한 자료를 분석하더라도 변화에 대한 서로 다른 결론이 도출되기도 한다. 두 모형이 가지는 대표적인 차이점은 다음과 같다. 첫 번째로, 두 시점-잠재변화점수모형은 변화를 모수값으로 추정할 수 있는 반면에, 두 시점-패널모형은 변화를 모수값으로 추정하지 않는다. 두 번째로, 두 시점-잠재변화점수모형은 공분산 및 평균 구조를 기반으로 하는 통계 모형인 반면에, 두 시점-패널모형은 공분산 구조만을 기반으로 하는 통계 모형이다. 세 번째로, 두 시점-잠재변화점수모형은 기울기 요인의 무선 효과를 가정하는 반면에, 두 시점-패널모형은 기울기 요인의 무선 효과를 가정하지 않는다. 고정효과는 모집단 전체에서 효과가 동일한 것을 가정하는 효과이며, 무선 효과는 개인차로 설명되는 효과이다. 두 시점-잠재변화점수에서 무선 효과는 잠재성장요인인 절편 요인(I_{it})과 기울기 요인(S_{it}) 간의 분산과 기울기 요인의 공분산으로 나타낸다. 두 시점-패널모형은 무선효과를 가정하지 않기 때문에 절편 요인과 기울기 요인에 대한 가정을 하지 않는다. 이와 관련하여 Usami 외(2016)는 기울기 요인의 무선효과에 대한 정당성을 포함한 이론적인 가정을 고려하여 올바른 모형을 선택해야 한다고 제안하였다. 만일 기울기 요인의 무선효과에 대한 이론적인 가정이 있다면 두 시점-잠재변화점수모형을 선택하고, 이론적인 가정이 없을 경우 두 시점-패널모형을 선택해야 한다. 하지만 모든 연구에서 기울기 요인의 무선효

과에 대한 정당성을 설명할 수 있는 것은 아니다. 이러한 경우에는 두 시점-잠재변화점수모형과 두 시점-패널모형 모두 분석하고 커플링(교차지연) 모수의 통계적 유의성과 적합도 지수를 비교하여 최적의 모형을 선택해야 한다.

본 연구는 다양한 조건에서 두 모형을 비교하여 연구자들의 최적의 모형 선택을 돕고자 하였다. 이를 위하여 (1) 두 변수 간의 이변량 종단 관계의 존재에 대하여 두 시점-잠재변화점수모형과 두 시점-패널모형이 어떤 경우에 그리고 얼마나 자주 통계적으로 다른 결과를 보이는지를 확인하고, (2) 이러한 경우에 어떤 모형 선택절차를 통하여 모형을 선택해야 하는지 확인하기 위하여 몬테카를로 시뮬레이션 연구를 실시하였다. 연구 결과는 다음과 같이 정리할 수 있다.

연구 문제 1에서 두 변수 간의 이변량 종단 관계의 존재에 대하여 두 시점-잠재변화점수모형과 두 시점-패널모형이 통계적으로 다른 결과를 보이는 경우를 확인하였다. 각 모형의 커플링(교차지연) 모수 편향을 추정한 결과 두 모형 모두 사례 수 조건의 수준에 따라 모수 편향이 통계적으로 유의하게 차이가 있었으며, 사례 수가 200인 조건에서 모수 편향이 가장 큰 것으로 나타났다. 각 모형의 커플링(교차지연) 모수 편향을 비교한 결과, 두 시점-잠재변화점수모형의 편향이 두 시점-패널모형의 편향보다 큰 것으로 나타났다. 따라서, ‘가설 1-1. 표본 크기, 절편과 기울기 간의 상관, 절편 간의 상관 조건의 수준에 따라 두 모형의 커플링(교차지연) 모수 γ_x, γ_y 의 편향이 다를 것이다.’ 는 지지되었다.

추가적으로, 두 모형이 종단 관계를 얼마나 다르게 추정하는지를 확인하기 위하여 두 모형의 각 변수에 대한 커플링(교차지연) 모수 추정치의 차이를 추정하였다. 기울기 요인 및 절편 요인의 상관 조건과 절편 요인의 상관 조건의 다양한 수준에서 유사한 수준의 모수 추정치가 추정되었지만, 사례 수 조건에 따라 모수 추정치의 차이가 달라지는 것을 확인하였다. 구체적으로, 사례 수가

작을수록 모수 추정치의 차이가 큰 것으로 나타났다. 따라서, ‘가설 1-2. 표본 크기, 절편과 기울기 간의 상관, 절편 간의 상관의 다양한 조건에 따라 두 모형 간의 커플링 모수 γ_x, γ_y 추정치의 차이가 달라질 것이다.’ 는 지지되었다.

조건에 따라 두 모형이 종단 관계의 존재에 대하여 얼마나 자주 통계적으로 다른 결과를 보이는지 살펴보기 위하여, 각 모형의 커플링(교차지연) 모수 추정치에 대한 통계적 유의성을 확인하였다. 만약 두 모형 중 한 모형의 모수 추정치만이 통계적으로 유의한 경우, 두 모형은 두 변수 간의 종단 관계에 대하여 서로 다른 결과를 나타냈다고 할 수 있다. 시뮬레이션 조건 중 기울기 요인과 절편 요인 간의 상관 조건과 절편 요인 간의 상관 조건의 수준에 따른 비율이 유사하였지만, 사례 수 조건에서 사례 수가 200일 때 비율이 가장 높고 사례 수가 500, 1500, 3000인 조건에서는 항상 동일한 결과를 보인 것으로 나타났다. 구체적으로, 두 시점-잠재변화점수모형의 커플링 모수만 통계적으로 유의한 경우보다 두 시점-패널모형의 교차지연 모수만이 통계적으로 유의한 경우가 더 많았다. 이는 다중공선성에 영향을 받아 두 시점-잠재변화점수모형의 표준오차가 더 크기 때문이다. 따라서, ‘가설 1-3. 두 모형은 표본 크기, 절편과 기울기 간의 상관, 절편 간의 상관 조건에 따라 두 변수 간의 종단 관계의 존재에 대하여 서로 다른 결과를 나타낼 것이다.’ 는 지지되었다.

연구문제 2는 올바른 모형을 선택하는 것과 관련하여 모형 선택 절차의 성능을 비교하기 위하여 모형 선택절차들의 올바른 모형을 선택한 비율을 비교하였다. 올바른 모형을 선택하는 것은 기울기 요인의 분산 $P_s \neq 0$ 일 경우 두 시점-잠재변화점수모형을 선택하고, $P_s = 0$ 일 경우 두 시점-패널모형을 선택하는 것을 의미한다. 그 결과, BIC가 가장 우수한 성능으로 나타났으며, 모형 적합도 지수 중에서는 RMSEA가 가장 우수한 성능으로 나타났다. 따라서 ‘가설 2-1. 표본 크기, 절편과 기울기 간의 상관, 절편 간의 상관의 다양한 조건에서 CFI와 RMSEA에 근거한 의사결정을 할 때 올바른 모형을 선택(예,

$P_s \neq 0$ 이면 두 시점-잠재변화점수 모형을 선택하고, $P_s = 0$ 이면 두 시점-패널 모형을 선택)한 비율이 가장 높을 것이다.’ 는 지지되지 않았다. 연구문제 1의 결과를 바탕으로 종단 관계와 관련하여 두 모형이 서로 다른 결과를 나타낼 때, 모형 선택절차에 따른 올바른 모형을 선택한 비율을 확인하였다. 그 결과, AIC가 가장 우수한 성능으로 나타났으며, 모형 적합도 지수 중에서는 RMSEA의 성능이 가장 우수한 것으로 나타났다. 따라서, 가설 ‘2-1. 표본 크기, 절편과 기울기 간의 상관, 절편 간의 상관의 다양한 조건에서 CFI와 RMSEA에 근거한 의사결정을 할 때 올바른 모형을 선택(예. $P_s \neq 0$ 이면 두 시점-잠재변화점수 모형을 선택하고, $P_s = 0$ 이면 두 시점-패널모형을 선택)한 비율이 가장 높을 것이다.’ 는 지지되지 않았다. 연구 결과에 따르면 모든 경우 혹은 종단 관계에 대하여 서로 다른 결과를 보이는 경우에서도 일관적으로 우수한 성능의 모형 선택절차는 RMSEA로 나타났는데, 이는 선행 연구 Usami 외(2016)의 연구에서는 CFI와 RMSEA가 가장 좋은 수행을 보인 것과는 차이가 있다. 선행 연구와 비교하였을 때 CFI의 성능이 비교적 좋지 않은 것은 두 모형 모두 CFI의 범위가 0.98~1.00이었기 모형 간에 CFI의 차이가 근소하여 비교가 어려웠기 때문이다.

본 연구의 결과를 정리하면 다음과 같다(<표 7> 참고). 두 모형이 가지는 통계적인 가정의 차이로 인하여 동일한 자료로 분석하더라도 두 시점-잠재변화점수모형의 커플링 모수 추정치와 두 시점-패널모형의 커플링 모수 추정치 값이 동일하지 않다. 두 시점-잠재변화점수모형이 기울기 요인을 가정하기 때문에 다중공선성의 영향을 받아 두 시점-패널모형의 교차지연 요인보다 더 큰 값의 모수 추정치가 추정된다. 또한 모수 추정치의 통계적 유의성이 서로 다른 경우를 확인하였는데, 이는 동일한 자료이더라도 종단 관계의 존재에 대하여 서로 다른 결과를 얻을 수 있는 것을 의미한다. 특히 사례 수가 200일 때 모형 간의 모수 추정치의 차이가 가장 컸으며, 종단 관계

에 대하여 서로 다른 결과를 보이는 빈도 또한 사례 수가 200일 때 가장 큰 것으로 나타났으며, 사례 수가 500 이상이었을 때 종단 관계의 존재에 대하여 항상 동일한 결과를 보이는 것으로 나타났다. 이는 사례 수가 큰 경우보다 사례 수가 작은 경우에서 종단 관계에 대한 두 모형 간의 차이가 큰 것을 의미한다. 따라서 두 시점 종단연구를 실시할 때 기울기 요인에 대한 정당성을 설명하지 못하고 사례 수가 200 이하이면 두 모형 간의 비교를 통하여 올바른 모형을 선택하는 것을 권장한다.

앞에서 논의하였듯이, 연구자가 모형 선택에 대한 충분한 이론적 근거를 갖지 못한다면 두 모형의 χ^2 , AIC, BIC, ssBIC, CFI, RMSEA, SRMR을 비교하여 더 적합한 모형을 선택해야 한다. 이 중 가장 우수한 성능의 모형 선택 절차를 확인하기 위하여 모형선택절차별 올바른 모형을 선택한 비율을 비교하였다. 그 결과, BIC, ssBIC가 올바른 모형을 선택한 비율이 가장 높았다. 모형 적합도 지수 중에서는 RMSEA가 가장 높은 것으로 나타났다. 두 모형 간에 종단 관계의 존재에 대하여 서로 다른 결과를 보이는 경우에는 AIC가 가장 높은 수행을 보였으며, 모형 적합도 지수 중에서는 RMSEA가 가장 높은 것으로 나타났다. 따라서 모형 선택에 대한 충분한 이론적 근거가 충분하지 못하여 모형을 비교할 때 RMSEA를 기준으로 올바른 모형을 선택할 것을 권장한다.

<표 7> 연구 결과

모수 편향	<ul style="list-style-type: none"> - 모수편향$_{2W-LCS} >$ 모수편향$_{2WPM}$ - 사례 수가 작을수록 모수편향이 큰 것으로 나타났음
종단 관계의 존재	<ul style="list-style-type: none"> - 두 시점-잠재변화점수모형의 커플링모수 추정치의 통계적 유의성과 두 시점-패널모형의 교차지연모수 추정치의 통계적 유의성이 서로 다른 경우가 존재함 - 두 시점-잠재변화점수모형의 커플링 모수 추정치만 통계적으로 유의한 경우가 두 시점-패널모형의 교차지연 모수 추정치만 통계적으로 유의한 경우보다 빈도가 더 적은 것으로 나타남 - 두 시점-잠재변화점수모형의 기울기 요인이 첫 번째 시점의 잠재변수와 다중공선성이 발생하여 커플링 모수의 불안정한 추정에 영향을 미치기 때문
올바른 모형을 선택한 비율	<ul style="list-style-type: none"> - 올바른 모형을 선택하는 것과 관련하여 모형 선택절차 중 BIC, ssBIC의 성능이 가장 우수하였음 - 두 모형이 종단 관계의 존재와 관련하여 서로 다른 결론을 나타낼 때는 AIC의 성능이 가장 우수하였음 - 두 결과를 종합하였을 때 공통적으로 RMSEA의 성능이 우수하였으므로, 모형을 선택할 때 RMSEA를 기준으로 삼을 것을 제안함

본 연구는 Henk & Castro-Schilo(2016)을 선행연구로 하여 두 시점 종단자료 분석에 활용될 수 있는 통계모형인 두 시점-잠재변화점수모형과 두 시점-패널모형을 비교하였다. 선행연구와 동일한 통계모형을 이용하여 연구를 진행하였지만 선행연구가 패널자료를 사용하여 가진 한계점을 보완하기 위하여 절편과 기울기 요인의 상관, 표본크기, 두 변수의 절편 간의 상관의 수준에 따라 분석 결과가 어떻게 달라지는지 확인하는 몬테카를로 시뮬레이션 연구를 실시하였다. 선행연구에서 한 구성개념의 변화가 다른 구성개념의 변화를 예측하는 단일 방향의 변화를 검증한 것과 달리 본 연구에서는 두 변수의 변화가 서로 영향을 미치는 상호 변화를 검증하였다. 연구 결과, 선행연구와 마찬가지로 동일한 자료에 대하여 두 모형으로 분석을 실시하였을 때 상반된 결과가 도출될 수 있음을 확인하였다. 두 연구의 결과를 종합하여 변화의 방향에 관계 어떤 모형을 선택하는지에 따라서 모형별로 변화에 대하여 서로 다른 결과가 도출하는 것을 확인하였다. 선행연구에서는 변화에 대한 모수값과 통계적 유의성만을 비교하였지만, 본 연구에서는 모형 간에 모형 선택절차를 비교하여 모형 선택에 대한 실질적인 근거를 추가적으로 제안하였다.

본 연구의 의의는 다음과 같다. 첫째, 국내에서는 다소 생소한 두 시점 종단연구와 두 시점-종단모형에 대하여 소개하였다. 국내에서는 주로 잠재성장모형을 활용한 종단연구가 많이 실시되는데, 잠재성장모형은 최소한 3시점 이상을 필요로 한다. 이로 인하여 국내에서 두 시점 종단연구는 생소한 개념이었으며, 많은 연구가 진행되지 않았다. 본 연구는 두 시점 종단연구의 대표적인 모형인 두 시점-잠재변화점수모형과 두 시점-패널모형을 소개하여 연구자들이 시점의 수에 제한받지 않고 연구를 설계할 수 있도록 하였다.

둘째, 국내에서는 다소 생소한 잠재변화점수모형을 소개하였다. 국내 종단연구에서 주로 사용되는 통계 모형은 잠재성장모형, 자기회귀교차지연모형으로 잠재변화점수모형은 국내에서 비교적 활용이 많이 되지 않는 종단모형

이다. 본 연구에서는 잠재변화점수모형을 소개하여 연구자들이 종단연구에 활용할 수 있는 모형 선택의 폭을 넓히고자 하였다.

셋째, 두 시점 종단연구에서 모형 선택의 실질적인 근거를 마련하였다. 일반적으로 연구자는 이론적인 근거를 토대로 연구에 적합한 통계 모형을 선택해야 하지만 통계 모형을 선택하는 이론적인 근거가 충분하지 않은 경우도 존재한다. 본 연구는 다양한 조건에서 두 시점 종단모형을 비교하여 이론적인 근거 외에도 모형을 선택하는 현실적이고 실용적인 근거를 마련하고자 하였다. 연구결과를 바탕으로 사례 수를 최소 500 이상으로 설정하여 자료를 수집할 것을 제안한다. 하지만 심리학 분야에서 종단연구를 설계할 때 두 시점뿐이어도 500명의 연구 참여자를 수집하고 관리하는 것은 현실적으로 어려운 경우가 많기 때문에 현실적인 이유로 사례수를 500 이상 수집하기 어려운 조건이라면 필수적으로 두 모형 다 분석을 실시하고 RMSEA를 근거로 더 적합한 모형의 분석 결과를 채택할 것을 제안한다.

본 연구의 한계점과 향후 연구 과제는 다음과 같다. 첫째, 사례 수 조건에 대해서만 모수 편향 및 종단 관계에 대하여 서로 다른 결론을 도출한 비율이 차이가 있었다. 특히, 사례 수가 200일 때는 두 모형이 종단 관계에 대하여 서로 다른 결론을 도출했던 것에 비하여 사례 수가 500, 1500, 3000인 조건에서 두 모형이 종단 관계에 대하여 서로 다른 결론을 도출하지 않은 결과를 고려하여 사례 수가 300, 400인 조건을 추가할 것을 제안한다.

둘째, 시뮬레이션 조건에 따른 연구결과를 단순화하기 위하여 두 변수 x 와 y 에 대하여 동일한 모수값을 지정하였으며, 생성된 자료에 결측치가 포함되지 않았다. 실제 연구 장면에서 두 변수의 모수값이 동일한 경우는 많지 않으며, 종단 연구의 특성상 자료에 결측치가 포함되는 경우가 많다. 따라서 현실적인 조건을 반영하여 두 변수의 모수값을 서로 다른 조건을 설정하고, 자료에 결측치를 포함할 것을 제안한다.

셋째, 모형을 설계할 때 한 개의 잠재변수당 세 개의 측정변수로 이루어지는 포화모형으로 모형을 설계하였다. 포화모형이기 때문에 모든 자료에 대하여 괜찮은 적합도 지수가 추정되었고, 특히 CFI의 경우 0.98~1.00 사이로 작은 범위가 추정되었다. 이로 인하여 올바른 모형을 선택하기 위하여 CFI 값을 비교할 때 모형 간에 비교가 잘 이루어지지 않았을 수 있다. 따라서, 잠재변수 당 측정변수의 수를 늘려 산출되는 모형 적합도 지수의 범위를 늘려서 CFI를 포함한 적합도 지수의 성능을 다시 확인해볼 필요가 있다.

참고문헌

- 김수영, 석혜은. (2015). 잠재성장모형의 사용을 위한 표본크기 결정. **한국심리학회지: 일반**, **34**(2), 599-617.
- 신태수. (2014). 인간발달연구에서의 종단자료 분석: 잠재성장모형을 중심으로. **인간발달연구**, **21**, 1-28.
- 윤태희, & 조영일. (2014). 부모-자녀 애착이 자살생각에 미치는 영향에서 자아존중감과 우울의 종단적 매개효과 연구. **한국심리학회지: 발달**, **27**(3), 61-90.
- 홍세희. (2000). 구조 방정식 모형의 적합도 지수 선정기준과 그 근거. **Korean Journal of Clinical Psychology**, **19**(1), 161-177.
- 홍세희. (2005). *이항 및 다항 로지스틱 회귀분석*. 서울: 교육과학사,
- 홍세희, 박민선, 김원정. (2007). 인터넷 중독과 부모와의 의사소통 사이의 자기회귀 교차지연 효과 검증: 성별간 다집단 분석. **교육심리연구**, **21**(1), 129-143.
- Akaike, H. (1998). Information theory and an extension of the maximum likelihood principle. In *Selected papers of hirotugu akaike* (pp. 199-213). Springer, New York, NY.
- Ahmed, Y., Wagner, R. K., & Lopez, D. (2014). Developmental relations between reading and writing at the word, sentence, and text levels: A latent change score analysis. *Journal of educational psychology*, *106*(2), 419.
- Baltes, P. B., & Nesselroade, J. R. (1979). History and rationale of longitudinal research. In *Longitudinal research in the study of behavior*

and development (pp. 1-39). Academic Press.

- Bentler, P. M. (1980). Multivariate analysis with latent variables: Causal modeling. *Annual Review of Psychology, 31*(1), 419-456.
- Bentler, P. M. (1990). Comparative fit indexes in structural models. *Psychological Bulletin, 107*(2), 238.
- Bentler, P. M., & Speckart, G. (1981). Attitudes “cause” behaviors: A structural equation analysis. *Journal of Personality and Social Psychology, 40*(2), 226.
- Birnbaum, A. (1968). Some latent trait models and their use in inferring an examinee’s ability, Contributed chapter. *Statistical theories of mental test scores*, Chapters-17
- Bollen, K. A. (1989a). A new incremental fit index for general structural equation models. *Sociological Methods & Research, 17*(3), 303-316.
- Bollen, K. A. (1989b). *Structural equations with latent variables*. New York: Wiley.
- Bollen, K. A., & Curran, P. J. (2006). *Latent curve models: A structural equation perspective*. (Vol. 467). John & Wiley & Sons.
- Bornstein, M. H., Putnick, D. L., & Esposito, G. (2017). Continuity and stability in development. *Child Development Perspectives, 11*(2), 113-119.
- Boyratz, G., & Waits, J. B. (2015). Reciprocal associations among self-focused attention, self-acceptance, and empathy: A two-wave panel study. *Personality and Individual Differences, 74*, 84-89.
- Browne, M. W., & Cudeck, R. (1993). Alternative ways of assessing model fit. Testing structural equation models. In K. A. Bollen & J. S. Long

- (Eds.), *Testing structural equation models* (pp.136-162). Newbury Park, CA: Sage
- Campbell, D. T. (1963). From description to experimentation: Interpreting trends as quasi-experiments. In C. W. Harris (Eds.), *Problems in Measuring Change* (pp. 212-242.). Madison: University of Wisconsin Press.
- Chan, D. (1998). The conceptualization and analysis of change over time: An integrative approach incorporating longitudinal mean and covariance structures analysis (LMACS) and multiple indicator latent growth modeling (MLGM). *Organizational Research Methods, 1*(4), 421-483.
- Cronbach, L. J., & Furby, L. (1970). How we should measure "change" : Or should we? *Psychological Bulletin, 74*(1), 68-80.
- Finch, W. H., & Shim, S. S. (2018). A comparison of methods for estimating relationships in the change between two time points for latent variables. *Educational and Psychological Measurement, 78*(2), 232-252.
- Greenberg, D. F., & Kessler, R. C. (1982). Equilibrium and identification in linear panel models. *Sociological Methods & Research, 10*(4), 435-451.
- Hamaker, E. L., Kuiper, R. M., & Grasman, R. P. (2015). A critique of the cross-lagged panel model. *Psychological Methods, 20*(1), 102-116.
- Henk, C. M., & Castro-Schilo, L. (2016). Preliminary detection of relations among dynamic processes with two-occasion data. *Structural Equation Modeling: A Multidisciplinary Journal, 23*(2), 180-193.
- Henson, J. M., Reise, S. P., & Kim, K. H. (2007). Detecting mixtures from structural model differences using latent variable mixture modeling: A comparison of relative model fit statistics. *Structural Equation*

Modeling: A Multidisciplinary Journal, 14(2), 202-226.

- Hu, L. T., & Bentler, P. M. (1999). Cutoff criteria for fit indexes in covariance structure analysis: Conventional criteria versus new alternatives. *Structural equation modeling: a multidisciplinary journal*, 6(1), 1-55.
- Jackson, D. L. (2001). Sample size and number of parameter estimates in maximum likelihood confirmatory factor analysis: A Monte Carlo investigation. *Structural Equation Modeling*, 8(2), 205-223.
- Jackson, D. L. (2003). Revisiting sample size and number of parameter estimates: Some support for the N: q hypothesis. *Structural equation modeling*, 10(1), 128-141.
- Jöreskog, K. G. (1974). Analyzing psychological data by structural analysis of covariance matrices. In R. C. Atkinson, D. H. Krantz, R. D Luce & P. Suppas (Eds.), *Contemporary developments in mathematical psychology* (pp. 1-56). San Francisco: Freeman.
- Kenny, D. A. (1979). *Correlation and causality*. New York: Wiley-Interscience.
- Kenny, D. A., & Zautra, A. (2001). Trait-state models for longitudinal data. In L. Collins & A. Sayer (Eds.), *New methods for the analysis of change* (pp.243-263), Washington, DC: American Psychological Association
- Kievit, R. A., Brandmaier, A. M., Ziegler, G., Van Harmelen, A. L., de Mooij, S. M., Moutoussis, M. et al. (2018). Developmental cognitive neuroscience using latent change score models: A tutorial and applications. *Developmental cognitive neuroscience*, 33, 99-117.
- Kline, R. B. (2011). *Principles and practice of structural equation modeling* (3. Baski). New York, NY: Guilford.

- Kline, R. B. (2015). *Principles and practice of structural equation modeling*. Guilford publications.
- Klopach, E. T., & Wickrama, K. (2020). Modeling latent change score analysis and extensions in mplus: A practical guide for researchers. *Structural Equation Modeling: A Multidisciplinary Journal*, 27(1), 97-110.
- Little, T. D., Preacher, K. J., Selig, J. P., & Card, N. A. (2007). New developments in latent variable panel analyses of longitudinal data. *International Journal of Behavioral Development*, 31(4), 357-365.
- Mayer, L. S. (1986). On cross-lagged panel models with serially correlated errors. *Journal of Business & Economic Statistics*, 4(3), 347-357.
- McArdle, J. J. (1986). Latent variable growth within behavior genetic models. *Behavior Genetics*, 16(1), 163-200.
- McArdle, J. J. (1988). Dynamic but structural equation modeling of repeated measures data. In *Handbook of multivariate experimental psychology* (pp. 561-614). Springer, Boston, MA.
- McArdle, J. J. (2001). A latent difference score approach to longitudinal dynamic structural analyses. In R. Cudeck, S. du Toit, & D. Sorbom (Eds.), *Structural Equation Modeling: Present and Future* (pp. 342-380). Lincolnwood, IL: Scientific Software.
- McArdle, J. J. (2009). Latent variable modeling of differences and changes with longitudinal data. *Annual Review of Psychology*, 60, 577-605.
- McArdle, J. J., & Anderson, E. (1990). Latent variable growth models for research on aging. In J. E. Birren & K. W. Schaie (Eds.), *Handbook of the Psychology of Aging* (pp. 21-43). New York: Plenum Press.
- McArdle, J. J., & Epstein, D. (1987). Latent growth curves within

- developmental structural equation models. *Child Development*, 58(1), 110-133.
- McArdle, J. J., & Grimm, K. J. (2010). Five steps in latent curve and latent change score modeling with longitudinal data. *Longitudinal research with latent variables* (pp. 245-273). Springer.
- McArdle, J. J., & Hamagami, F. (2001). Latent difference score structural models for linear dynamic analyses with incomplete longitudinal data. In L. M. Collins & A. G. Sayer (Eds.), *Decade of behavior. New methods for the analysis of change* (pp. 139-175). American Psychological Association.
- McArdle, J. J., & Nesselroade, J. R. (2014). *Longitudinal data analysis using structural equation models*. American Psychological Association.
- Meredith, W., & Tisak, J. (1984). "Tuckerizing" curves. Paper presented Psychometric Society annual meetings, Santa Barbara, CA,
- Meredith, W., & Tisak, J. (1990). Latent curve analysis. *Psychometrika*, 55(1), 107-122.
- Muthén, L. K., & Muthén, B. (2017). *Mplus user's guide: Statistical analysis with latent variables*, user's guide Muthén & Muthén.
- Nesselroade, J. R. (1972). Note on the "longitudinal factor analysis" model. *Psychometrika*, 37(2), 187-191.
- Nesselroade, J. R., & Cable, D. G. (1974). " Sometimes, it's okay to factor difference scores" -the separation of state and trait anxiety. *Multivariate Behavioral Research*, 9(3), 273-284.
- Overton, W. F., Lerner, R. M., & Molenaar, P. (2015). *Handbook of child psychology and developmental science; volume 1: Theory and*

method(7th ed.). New York: Wiley.

- Paxton, P., Curran, P. J., Bollen, K. A., Kirby, J., & Chen, F. (2001). Monte carlo experiments: Design and implementation. *Structural Equation Modeling, 8*(2), 287-312.
- Ployhart, R. E., & Vandenberg, R. J. (2010a). Longitudinal research: The theory, design, and analysis of change. *Journal of Management, 36*(1), 94-120.
- RAND HRS. (2013). Data, Version M. Produced by the RAND Center for the Study of Aging, with funding from the National Institute on Aging and the Social Security Administration. Santa Monica, CA:RAND.
- R Development Core Team(2011). R: A language and environment for statistical computing. *R Foundation for Statistical Computing, Vienna*. URL: <https://www.R-Project.org>,
- Rogosa, D. (1980). A critique of cross-lagged correlation. *Psychological Bulletin, 88*(2), 245.
- Rogosa, D. (1995). Myths and methods: "Myths about longitudinal research" plus supplemental questions. In J. M. Gottman (Ed.), *The Analysis of Change* (pp. 3-66). Mahwah, NJ: Lawrence Erlbaum.
- Schwarz, G. (1978). Estimating the dimension of a model. *The Annals of Statistics, 6*(2), 461-464.
- Sclove, S. L. (1987). Application of model-selection criteria to some problems in multivariate analysis. *Psychometrika, 52*(3), 333-343.
- Selig, J. P., & Little, T. D. (2012). Autoregressive and cross-lagged panel analysis for longitudinal data. In B: Laursen, T. D. Little, & N. A. Card (Eds.), *Handbook of developmental research methods* (pp.

265-278). The Guilford Press.

- Selig, J. P., & Preacher, K. J. (2009). Mediation models for longitudinal data in developmental research. *Research in Human Development, 6*(2-3), 144-164.
- Singer, J. D., Willett, J. B., & Willett, J. B. (2003). *Applied longitudinal data analysis: Modeling change and event occurrence*. Oxford university press.
- Stanley, J. C. (1971). Reliability. In RL thorndike (Ed.) *Educational measurement*(2nd ed., pp. 356-442). Washington, DC: American Council on Education,
- Steiger, J. H., & Lind, J. C. (1980). Statistically based tests for the number of common factors. *In the annual meeting of the psychometric society*. Iowa City, IA. 1980
- Steyer, R., Eid, M., & Schwenkmezger, P. (1997). Modeling true intraindividual change: True change as a latent variable. *Methods of Psychological Research Online, 2*(1), 21-33.
- Tanaka, J. S. (1987). "How big is big enough?": Sample size and goodness of fit in structural equation models with latent variables. *Child development, 58*, 134-146.
- Tisak, J., & Tisak, M. S. (1996). Longitudinal models of reliability and validity: A latent curve approach. *Applied Psychological Measurement, 20*(3), 275-288.
- Usami, S., Hayes, T., & McArdle, J. J. (2015). On the mathematical relationship between latent change score and autoregressive cross-lagged factor approaches: Cautions for inferring causal

relationship between variables. *Multivariate Behavioral Research*, 50(6), 676-687.

- Usami, S., Hayes, T., & McArdle, J. J. (2016). Inferring longitudinal relationships between variables: Model selection between the latent change score and autoregressive cross-lagged factor models. *Structural Equation Modeling: A Multidisciplinary Journal*, 23(3), 331-342.
- Willett, J. B. (1989). Some results on reliability for the longitudinal measurement of change: Implications for the design of studies of individual growth. *Educational and Psychological Measurement*, 49(3), 587-602.
- Wold, H. O. (1938). *A Study in the Analysis of Stationary Time Series*. (2nd ed., 1954). Uppsala, Sweden: Almqvist and Wicksell.
- Yao, M. Z., & Zhong, Z. J. (2014). Loneliness, social contacts and Internet addiction: A cross-lagged panel study. *Computers in Human Behavior*, 30, 164-170.
- Yule, G. U. (1921). On the time-correlation problem, with especial reference to the variate-difference correlation method. *Journal of the Royal Statistical Society*, 84(4), 497-537.
- Zyphur, M. J., Allison, P. D., Tay, L., Voelkle, M. C., Preacher, K. J., Zhang, Z., et al. (2019). From data to causes I: Building a general cross-lagged panel model (GCLM). *Organizational Research Methods*, 23(4), 65-687.

ABSTRACT

A Comparison of Statistical Models for Analyzing Two-wave Longitudinal Data :2W-LCS and 2WPM

Park Eunseo
Department of Psychology
The Graduate School of
Sungshin University

This paper is a simulation study comparing two-wave latent change score model and two-wave panel model, which are statistical models used for analyzing two-wave longitudinal data. To achieve this study, controlled factors of followings were set the size of correlation between intercept factor and slope factor, the sample size and correlation between intercept factors. Other controlled factors of followings were set; measurement reliability at the first time point, the ratio of variance of the variables between the first and second time points, three kinds of proportions of variance(slope factors, variance due to the autoregressions and variance due to the coupling(cross-lagged) parameters) in the regression at the second

time point. Accordingly, 5 sets of data satisfying 15,552 ($4 \times 4 \times 3 \times 3 \times 3 \times 3 \times 12$) conditions were randomly created and analyzed using statistical programs Mplus and R.

The simulation results show that different coupling (cross-lagged) parameter estimators were estimated in two-wave latent change score model and two-wave panel model. Specifically, the parameter bias of two-wave latent change model was smaller than that of two-wave panel model. In addition, different results were shown for the statistical significance of the coupling (cross-lagged) parameter estimator. Also, the estimated value and statistical significance of the coupling (cross-lagged) parameter were significantly affected by the number of sample size.

When comparing the model selection procedure of two models, in regard to the proportion of selecting the correct model, the performance of BIC, ssBIC and RMSEA were found to be the highest. In addition, performances of AIC and RMSEA were highest when comparing the ratio of selecting the correct model while the two models showed different results for the statistical significance of the coupling (cross-lagged) parameter estimator. Therefore, it was confirmed that model selection based on RMSEA is the most desirable procedure when selecting a model by comparing the two-wave latent change score model and the two-wave panel model.

This paper confirmed that different conclusions about the longitudinal relationship can be drawn based on the model selection

in a two-wave longitudinal study. If there is no theoretical justification of model selection in a two-wave longitudinal study, this paper suggests to compare two models and decide based on RMSEA. In conclusion, the limitation of this study and suggestions for follow up study are discussed.

Key Words: Two-wave longitudinal study, Two-wave latent change score model, Two-wave panel model, model selection, causal inference

<부록 1> 두 시점-잠재변화점수모형의 Mplus 코드

TITLE : Two wave latent change score

DATA:

FILE="data.csv";

VARIABLE:

NAMES = x1_t1 x2_t1 x3_t1
 x1_t2 x2_t2 x3_t2
 y1_t1 y2_t1 y3_t1
 y1_t2 y2_t2 y3_t2;

USEVARIABLES = x1_t1 x2_t1 x3_t1
 x1_t2 x2_t2 x3_t2
 y1_t1 y2_t1 y3_t1
 y1_t2 y2_t2 y3_t2;

MODEL:

!! x variable

! latent variables

x1 by x1_t1@1
 x2_t1(L1)
 x3_t1(L2);

x2 by x1_t2@1
x2_t2(L1)
x3_t2(L2);

[x1_t1@0]; [x2_t1@0]; [x3_t1@0];
[x1_t2@0]; [x2_t2@0]; [x3_t2@0];
x1_t1(psix); x2_t1(psix); x3_t1(psix);
x1_t2(psix); x2_t2(psix); x3_t2(psix);

[x1@0]; [x2@0];
x1@0;
x2@0;

!diff scores
dx by x2@1;
[dx@0]; dx@0;

!autoregressions
x2 on x1@1;

!proportional change
dx on x1;

!constant change
sx by dx@1;

[sx@20]; sx;

ix by x1@1;

[ix@50]; ix;

!! y variable

!latent variable

y1 by y1_t1@1

 y2_t1(L3)

 y3_t1(L4);

y2 by y1_t2@1

 y2_t2(L3)

 y3_t2(L4);

[y1_t1@0]; [y2_t1@0]; [y3_t1@0];

[y1_t2@0]; [y2_t2@0]; [y3_t2@0];

y1_t1(psiy); y2_t1(psiy); y3_t1(psiy);

y1_t2(psiy); y2_t2(psiy); y3_t2(psiy);

[y1@0]; [y2@0];

y1@0;

y2@0;

!diff scores

dy by y2@1;

[dy@0]; dy@0;

!autoregressions

y2 on y1@1;

!proportional change

dy on y1;

!constant change

sy by dy@1;

[sy@20]; sy;

iy by y1@1;

[iy@50]; iy;

!!coupling

!proportional

dy on x1;

dx on y1;

!constant

sy with sx @0;

sy with ix @0;

iy with sx @0;

iy with ix;

iy with sy;

ix with sx;

OUTPUT:

<부록 2> 두 시점-패널모형의 Mplus 코드

TITLE : Two wave panel model

DATA:

FILE="data.csv";

VARIABLE:

NAMES = x1_t1 x2_t1 x3_t1
 x1_t2 x2_t2 x3_t2
 y1_t1 y2_t1 y3_t1
 y1_t2 y2_t2 y3_t2;

USEVARIABLES = x1_t1 x2_t1 x3_t1
 x1_t2 x2_t2 x3_t2
 y1_t1 y2_t1 y3_t1
 y1_t2 y2_t2 y3_t2;

MODEL:

!latent variables

!x variables

x1 by x1_t1@1
 x2_t1 (L1)
 x3_t1 (L2);

```
x2 by x1_t2@1
      x2_t2 (L1)
      x3_t2 (L2);
```

```
! y variables
```

```
y1 by y1_t1@1
      y2_t1 (L4)
      y3_t1 (L5);
```

```
y2 by y1_t2@1
      y2_t2 (L4)
      y3_t2 (L5);
```

```
! specifying autoregression effects
```

```
x2 on x1(betax);
y2 on y1(betay);
```

```
! specifying cross-lagged effects
```

```
x2 on y1(gammax);
y2 on x1(gammay);
```

```
! specifying covariance between x and y
```

```
x1 with y1;
```

```
OUTPUT:
```