

因子分析と因果モデル構成の統合を自動化する試み

古田 貴久¹⁾・服部 光宏²⁾・橋詰 倫典³⁾

1) 群馬大学教育学部

2) 太田市立東中学校

3) 群馬大学大学院教育学研究科

(2015年9月30日受理)

An Attempt to Automate the Integration of Factor Analysis and Construction of Causal Models

Takahisa FURUTA¹⁾, Mitsuhiro HATTORI²⁾ and Tomonori HASHIZUME³⁾

1) College of Education, University of Gunma

2) Higashi Junior High School, Ota, Gunma

3) Graduate School of Education, University of Gunma

(Accepted September 30th, 2015)

あらまし

本研究では、因子分析と因果モデル生成との効率的な統合を目標に、因子をランダム・サンプリングで構成し、それらの因子間の因果モデルを、因子間の固定した因果関係を与えた場合と、ベイジアン・ネットワークでデータから動的に構成した場合の2通りの方法で自動探索を試みた。対象としたデータは、2014年に群馬県内の2つの中学校で、技術の「計測と制御」単元で実施した、コンピュータと情報および問題解決に関する意識調査への回答である。因子の総数を4つとして、1,000万回のランダム・サンプリングで全探索空間の0.13%ずつを探索したところ、30~130通りの因果モデルが生成された。因果関係の終端ノードを「プログラミングが好き」とした場合、4因子の因果モデルでは1モデルの統計的妥当性が確認された。が、「IT・理工系職業への関心」を終端ノードとした場合は、妥当なモデルが生成されなかった。得られたモデルの内容は、教材研究上の有益な示唆を与えるものであった。探索空間の広さをいかに制限するかが課題である。

キーワード：因子分析，ベイジアン・ネットワーク，ランダム・サンプリング，情報とコンピュータ

Keywords: factor analysis, Bayesian network, random sampling, informatics and computers

はじめに

知能の構造を明らかにする統計的手法として発達してきた因子分析は、現在では、教育工学や心理学等において、対象の深層構造を探る手法として広く使われてきた。近年では、単に因子を抽出して対象の静的な因子的構造を明らかにするだけでなく、因子間の因果関係を推定し、対象を動的に理解する試みが広がっている (Matsuda, 2012)。

因果的構造を統計的に推定する手法には、斜交回転を行った因子分析によって抽出された因子を、パス解析や CALIS などの共分散構造分析 (CSA)、あるいは、構造方程式モデル (SEM) を適用して、因子間の因果関係を推定する方法がある。これらの手法を用いた分析の基本的な流れは、因子を因果ネットワークのノードに見立て、心理学や教育学的な理論的な検討を根拠に、研究者が、いわばトップダウンに、因子ノード間に因果の方向を指定して、因子間の因果構造モデルを作成する。そして、得られた因果構造モデルの妥当性は、上述の CALIS や SEM などを因子分析に用いたデータに適用し、得られた (A) GFI や AIC などによって評価していく。

しかしながら、実際に、因子分析の結果をもとに、研究者が理論的検討を加えながら因子間の因果関係を推定しても、多くの場合で、(A) GFI が 0.9 を下回り、因果構造モデルを廃却せざるを得ないことが多い。そのようなモデルは、いわば「失敗作」であるため、論文として公刊されることはほとんどないであろう。そもそも、斜交回転の因子分析で得られた因子には、因子間相関はあるものの、因果構造も存在する保証があるわけでもない。因子分析までを行った研究に比べて、CALIS や SEM などを用いて因果構造の分析まで行った研究は少ない理由は、これら因果分析の理論を理解することが容易でないことや、統計パッケージなどの分析手段があまり普及していないこともあるだろうが、(A) GFI などの指標面で妥当なモデルの構成が容易でない、すなわち、成果が出にくいということもあると推測される。

より具体的な手順に即して言えば、最も障害となるのは、おそらく、(1) 因子分析の結果は、本来、

研究者の恣意性を反映したものであって、得られる因子構造は何通りもあり得ること、および、(2) あらたな因子構造が得られるたびに、研究者が、因子間の因果関係を与え直さなくてはならないことであろう。

仮に、因子構造が確定しているのであれば、因子間の因果関係を表した因果モデルの探索は、さほど大きな問題ではない。たとえば、5つの因子が抽出されたとすると、潜在的な因果モデルは、 $3^5 = 59,049$ 通りであるが、この程度であれば、現在のパソコンの性能でも、すべての因果モデルをチェックさせることは十分可能である。

しかしながら、むしろ問題は、因子分析によって得られる因子の構造は、因子分析にどの質問項目を投入したかによって大きく変動することにある。実際、質問紙の開発途中では、何度も因子分析を繰り返かえて、解釈可能性などの観点から、質問項目の取捨選択を行う。また、調査を実施し、データが回収された後でも、探索的因子分析の場合、研究者にとって納得の行く因子構造が得られるまで、いくつかの項目の削除を繰り返かえしながら因子分析を何回も行わなくてはならない。つまり、探索的な研究の途中では、本質的に、因子構造はアприオリに一意に定まるものではなく、さまざまな要因とのバランスを取りながら作り上げられていくものだとみなすべきであろう。

以上から、本研究では、妥当性の高い因子の構造の抽出と、それらの因子が組み込まれた、妥当性の高い因果モデルの構築とを、いかに効率的に両立させるかに焦点を当てる。

因子間の因果関係をデータから推定する手法として、ベイジアン・ネットワークがある。ベイジアン・ネットワークでは、因子間の因果的な構造を、データから確率的に推定する、いわばボトムアップな手法である。学問的には、本来であれば、因子間因果構造は、心理学や教育学などの知見を反映して決定されるべきものであろう。しかしながら、前述のように、因子間の適切な因果関係を、研究者が、理論的にトップダウンに推定することがなかなか容易ではないなら、むしろ、データからボトムアップに推

定して、後付けで理論を整備することは、無意味とは言えないと筆者らは考える。実際、筆者らが得たアンケート・データから抽出された因子から、ベイジアン・ネットワークによって因果構造を推定すると、ときどき、思いもかけない因果構造が提案されるが、その意味を解釈する過程で筆者らの先入観が浮き彫りになる。心理学や教育学では、探索的因子分析は確立された手法と言えるが、探索的因子分析では、実際に因子分析を行って得られた因子構造に対して、後付け的に因子の解釈を与えて、対象に対する研究者の理解を深めることもあるので、ランダム・サンプリングやベイジアン・ネットワークによってボトムアップに対象の因果的構造を得ることを全否定することは、あまり得策ではないと筆者らは考える。

本論文では、質問紙(アンケート)で得られたデータに対して、因子構造と因子間の因果モデルを、ランダム・サンプリングによって効率的に行う計算機実験を行った。質問紙による調査は、群馬県内の2つの中学校で、技術の「計測と制御」の授業中に実施した。計算機実験では、プログラムが、質問項目群からランダムに質問項目を選択し、それらをもとにした因子構造を抽出し、得られた因子に対する因果モデルを構成した。因子構造および因果モデルの数値的な評価は、主に、クロンバックの α 係数と、SEMのAGFIの2点から検討した。

分析対象とした授業実践

因子分析および因果モデル構成の対象としたデータは、群馬県内の2つの中学校で、2014年に行った、「技術」の「計測と制御」単元での授業実践(図1)で行った質問紙調査である。

全7時間の授業の展開は、おおむね以下の通りである。1時間目に、導入として、「計測と制御」の基本概念を説明した。2時間目と3時間目は、Microsoft Excel上のプログラミング言語であるVBAの導入であり、Active Xのボタンの作り方、代入文、If文について説明して、簡単なゲームの作成と改良を行わせた。4時間目以降では、リモレール(Kuwatec製)




図1 技術・「計測と制御」の授業でプラレールを制御しているところ

を装着したプラレール(タカラ・トミー製)の電車に、生徒がVBAで記述したプログラムによって前進・後退・停止を指示する。リモレールはプラレールのモータ車両に搭載するアタッチメントであり、赤外線信号を受信して、プラレールの電車を前進させたり後退させることができる。生徒のパソコンには、本実践用に開発した専用のインタフェースを接続してあり、インタフェースは、VBAで書かれたプログラムからの命令を、電車(リモレール)への赤外線信号に変換して送信する。また、本インタフェースは、プラレールのレールに埋め込んだ位置センサ(光センサ)からの情報を、数値化してパソコンに送り返す機能を持っている。生徒には、位置センサからの情報を参考にしながら、電車を、自分の考える運行パターンに沿って自動運転するVBAのプログラムを作らせた。

本単元の1時間目(初回)と7時間目(最終回)に、Knezek and Christensen(1995; 1997)のComputer Attitude Questionnaire(CAQ)中から、コンピュータ不安に関する質問項目と、問題解決に対する質問項目を抜粋し、それに、生徒の、これまで物作り体験や、情報や理科に対する興味、プログラミングに対する関心や、将来に対する考えを尋ねる質問項目を追加した質問紙(全82項目)を実施した。得られた回答のデータについて、質問ごとに平均値と標準偏差を計算して、不適切な項目(天井効果や

床効果が疑われる質問項目)を除外した。また、初回と最終回の間で平均値がほとんど変わらなかったり、質問項目が内容的にコンピュータや情報とあまり関連性がない、あるいは、意味があいまいだと見なされた項目を削除して、残った59項目を以下の実験で採用した。実験で用いたデータは、2つの学校から得られた、1時間目での回答192名分である。質問紙の詳細は紙面の都合で割愛する。

以下の実験で使用した統計ソフトはWindows7および8上のR(i386, ver.3.2.0)で、主なパッケージはpsych(ver.1.5.4)、psy(ver.1.1)、sem(ver.3.1.5)、deal(ver.1.2.37)である。計算機実験では、これらのパッケージに含まれる関数をバッチ処理で連続実行した。なお、関数の出力を別の関数に与えていくため、一部のパッケージ関数については、別の関数とデータのフォーマットが互いに適合するよう、入出力部分を書き換えた。

実験1 因子間因果モデルを固定した場合

2つの中学校での授業実践を通じて得られた質問紙調査に対する回答を用いて、中学生のコンピュータや情報、及び、問題解決に対する意識構造の因果構造を、回答データからボトムアップに構成することで、自動化する実験を行った。すなわち、因子の数を3~5つとし、ランダム・サンプリングによって因子を構成して、仮の因子構造を生成する。次いで、それら因子間の因果関係のモデルを生成して、得られたモデルを評価するまでを、コンピュータで自動化した。筆者らの関心は授業を通じて生徒のITへの関心を高めることと、理工系職業への関心を高めることなので、「プログラミングが好き」または「IT・理工系職業への関心」を目的因子とした因果モデルをそれぞれ構成させて、それらの目的因子に因果的に寄与する因子のボトムアップな探索を行った。


方 法

目的因子として「プログラミングが好き」と「IT・理工系職業への関心」の2通りを設定した。ここで、目的因子というのは、複数の因子を要因・ノードと


する因果モデルにおいて、他の要因・ノードに後続するだけで、他の要因・ノードに対して先行することのない、最終的な結果に位置づけられる終端因子という意味である。以下では、目的因子以外の因子(要因・ノード)を説明因子と呼ぶ。「因子」と「要因・ノード」は同じものを指すが、因子分析の結果を意識しているときは、因子と呼び、それらの間の因果的關係を意識しているときは要因・ノードと呼んでいる。

目的因子「プログラミングが好き」を構成する質問項目は、「プログラミングは、おもしろい・おもしろそうだ」、「自分でもプログラミングを、やりたい・やってみたい」、「自分でもプログラムが書けると、なにかと便利だ・便利そうだ」の3項目とした。一方の、目的因子「IT・理工系職業への関心」を構成するのは、「将来、ITにかかわる仕事に就きたい」、「将来、科学的なことにかかわる仕事に就きたい」、「将来、自分が望む仕事につくために、理科の勉強がとても重要である」の3項目とした。


実験では、統計パッケージRを用いて、以下の一連の探索処理を自動実行するバッチ・プログラムを作成した。探索処理では、まず、目的因子(「プログラミングが好き」または「IT・理工系職業への関心」)は、それぞれを構成する質問項目3つを、プログラム中で、質問項目の通し番号で与えたデータセットを新規作成した。それ以外の説明因子については、各因子に対して3つずつの質問項目をsample()でランダムに選択して、データセットに追加した。これにより、全4因子モデル(目的因子1個、説明因子3個)の場合は12項目、全5因子モデル(目的因子1個、説明因子4個)の場合は15項目から成るデータセットが構成される。このデータセットのクロンバックの α 係数が0.8よりも大きければ、項目ごとの評定値の合計を求めて、それを各因子を変数とするデータセットに作り替えた。そして、そのデータファイルに、因子数に応じて、図2に示すいずれかの因果構造を出力して、sem()でモデルの評価を行った。すなわち、sem()では、モデルとデータが乖離していないことを帰無仮説とするカイ二乗検定のカイ自乗値を求めた。そして、おおよそ10%



4 因子の因果パス



5 因子の因果パス-1



5 因子の因果パス-2

図2 実験1で与えた固定された因子間因果構造

水準で有意ではないなら、モデルとデータは乖離していないものとして、そのモデルを採択し、クロンバックの α 係数、因果モデル、および `factanal()` で因子分析を行った結果をファイルに出力した。ここで、因子分析の結果もファイルに出力した理由は、因果分析に使用した因子構造は、因子分析に基づいたものではなく、あくまでランダム・サンプリングによって構成されたものである。したがって、同じデータセットに対して因子分析を行っても、ランダ

ム・サンプリングによって構成された場合と同じ因子構造が抽出されるか、確認するためである。以上を1サイクルとして、これを1,000万回実行した。データに含まれる質問項目は59であり、全4因子の場合、そのうち56項目からランダムに9項目を選択しているので、可能な組み合わせ数はおおよそ76億通り (${}_{56}C_9$) である。したがって、探索した範囲は全体の0.13%である。

結 果

表1に、目的因子を「プログラミングが好き」または「IT・理工系職業への関心」とした場合の、因子分析および因子間因果関係が妥当であった、すなわち、クロンバックの α 係数が0.8以上であり、モデルとデータの乖離が統計的に認められず、かつ、AGFIが0.8以上であったモデルの数を示す。因子数を5とした場合、妥当性が確認されたモデルは推定されなかった。

表1 生成された因果モデルの因子の個数（因果構造固定、4因子解）

因子個数	「プログラミングが好き」	「IT・理工系職業への関心」
1	83	42
2	41	16
3	9	1
4	1	0

実験2 因果モデルをベイジアンネットワークモデルで推定した場合

実験1では、因子間の因果関係を図2に示す因果パスに固定して因果モデルの探索を行った。しかしながら、各説明因子は毎回ランダムに構成されるので、それらの因子間因果パスが図2の因果モデルとマッチしていないことのほうが多いであろう。むしろ、新たに構成された因子に合わせて構成し直した因果パスを与えた方が、有効なモデルを効率的に探索するうえで有利だと考えられる。

実験2では、因子間因果パスの推定にベイジアン・ネットワークを用いて、因果構造を動的に構成することの効果調べた。

方 法

実験の方法は、因果構造の推定にベイジアン・ネットワークを使用した以外は、実験1と同じである。ただし、ベイジアン・ネットワークでは、因果構造そのものがボトムアップに構成されるため、特定のノードが末尾に位置するよう指定することはできな

い。そのため、本研究の主眼である、「プログラミングが好き」と「IT・理工系職業への関心」の因子自体は、実験1と同じ内容のものを所与のものとして与え、得られた因果構造のなかから、これらの因子が因果構造の末尾に来るモデルを探すこととした。

実験2では、Rのsemパッケージのcfa()に与える因果モデルを以下のように生成した。すなわち、各ノード（因子）の定義を中間ファイルに出力した後、dealパッケージのベイジアン・ネットワークでノード・因子間の因果パスを推定し、その結果も中間ファイルに出力した。因果パスはdealパッケージのautosearch()で得られるが、今回の実験では、autosearch()がplot()に与える因果構造を、cfa()が受容するフォーマットに書き換えるよう、システムの一部に変更を加えた。得られた中間ファイルをcfa()に与えて因果モデルを設定し、sem()でモデルの評価を行った。なお、jointprior()に与えるimaginary sample sizeは、デフォルトと70の2通りを試した。

結 果

表2に、目的因子を「プログラミングが好き」または「IT・理工系職業への関心」とした場合の、因子分析および因子間因果関係の妥当性が確認されたモデルの数を示す。ベイジアン・ネットワークでモデルを探索した場合も、因子数を5とした場合、妥当性が確認されたモデルは生成されなかった。

表2 生成された因果モデルの因子の個数（ベイジアン・ネットワーク、4因子解）

目的因子	「プログラミングが好き」	「IT・理工系職業への関心」			
I.S.S.	22 (デフォルト)	70			
	22 (デフォルト)	70			
因子個数	1	16	62	17	27
	2	12	26	11	16
	3	1	6	0	1
	4	0	0	0	0

I.S.S. Imaginary Sample Size

考 察

本研究では、因子分析と因果モデル生成の効率的な統合を目標に、因子間因果モデルの構成を、因子番号で因子間の因果関係を固定した場合と、ベイジアン・ネットワークでデータから動的に構成した場合の2通りの方法について、因子・因果モデルの自動探索を試みた。

生成された因子・因果モデルの有用性について

実験1では、目的因子を「プログラミングが好き」とした場合、3つの説明因子を伴う因果モデルが1つだけ生成された。このモデルの構造を図3に示す。なお、今回は、因子分析を主眼としていないので、因子（ノード）の解釈・命名は行っていない。

この因子・因果モデルを見ると、プログラミングへの関心の遠因は、コンピュータを使うことに意義

を感じて、熱心であることであるが、近接因としては、新しい問題に積極的に挑戦する態度を持っていることであると考えられる。したがって、普段から身のまわりに課題を見出し、プログラミングはそのような課題を解決する有効な手段の1つである、ということが理解されれば、彼らのプログラミングへの関心はさらに高まるのではないか、という教材研究上の仮説が、この因果モデルから示唆される。

因子・因果モデル生成の自動化の可能性について

実験1の結果、因子数が4の場合、得られたモデルの総数はおよそ130であった。これは、試行回数(1,000万回)のおよそ0.0013%である。プログラムの実行結果を見ると、99%以上のモデルが棄却された理由は2つある。1つは、質問項目数が15個で、かつ、クロンバックの α 係数が0.8を超えることが難しいこと、もう1つは、SEMを実行して因果モデル

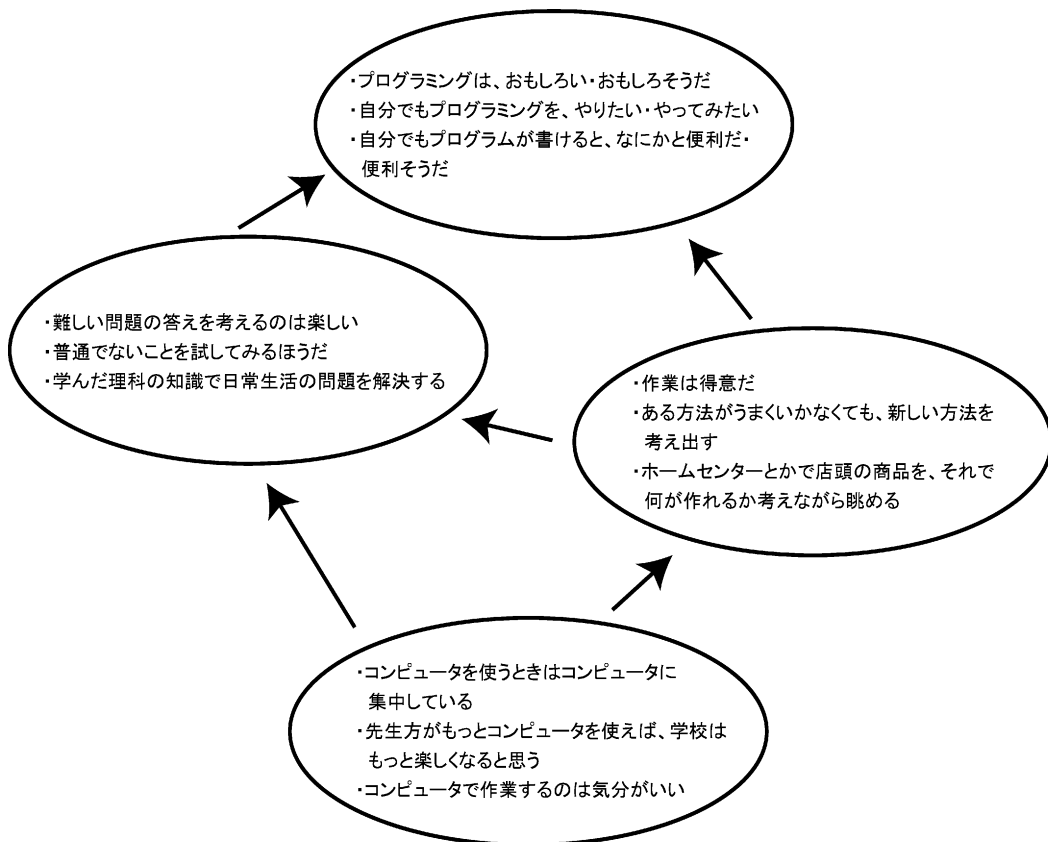


図3 妥当性が確認された因子・因果モデル ($\alpha=0.82$, AGFI=0.93)

ルの評価を行うと、ほとんどのモデルにおいて、モデルとデータの乖離が疑われること（カイ二乗検定が有意になる）がある。

本研究の動機は、因子分析の結果から、モデルとデータの乖離が認められない因果構造を、研究者が構成することが容易に行えないことであった。そのため、因子の構成と、因果モデルの構成を、ランダム・サンプリングによって自動化して、研究の補助とすることを考えたのであるが、今回の結果は、因子分析的に適切な因子構造を持ち、かつ、それをもとにした有効な因果モデルは、そもそも、数そのものが極めて少ない可能性を示している。「はじめに」で述べたように、研究者が専門知識や常識を働かせながら因子分析の結果をもとに構築した因果モデルが、指標的に、モデルとデータが乖離している可能性が疑われたり、実データとのフィットが低かったりして、信頼のおけるモデルが作りにくいことは、このような事情が背景にあると考えられる。

しかしながら、逆に考えれば、そのような作業にこそ、コンピュータを使った（全量）探索が向いているということは、情報工学における教科書的な事実である。理論的検討がなされない点に批判はあると思うが、データから有用な知見を引き出すことを期待するのであれば、ランダム・サンプリングをもとにしたボトムアップなモデル構成も有効であろう。実際、探索的因子分析の実務では、しばしば、さまざまな因子構造を構成しながら、研究仮説そのものを見直している。その意味で、以下に述べる大きな問題点が残るものの、本研究が試みたような、因子構造およびそれらの因果構造を、データからボトムアップに推定することは1つの方法であると考ええる。

因子・因果モデル生成の全自動化への課題

3つの課題を指摘したい。1つ目は、因果モデルの探索空間の広さに関する課題である。因子間の因果関係を固定した場合（実験1）、複数の因果モデルが得られたが、ベイジアン・ネットワークを用いた場合は（実験2）、1つも有効な因果モデルが得られなかった。

ベイジアン・ネットワークが推定する因果構造は、しばしば、研究者が思いつかない因果構造になっていることがある。ベイジアン・ネットワークが提案する因果モデルは、学問的な理論やノードの意味内容を踏まえた因果関係ではなく、研究者が得られた因果モデルに後付け的な解釈を行うことになる。しかしながら、人間（研究者）の先入観を覆す効果を持っている場合がある。

今回の実験について言えば、そのような因果モデルを、因子そのものをランダム・サンプリングによって構成した場合には、信頼性指標をクリアした因子・因果構造を構成できなかった。先にも述べたように、今回の実験で探索した範囲が、理論的な組み合わせ全体の0.13%に過ぎないことが、主な原因と考えられる。しかしながら、1,000万通りの組み合わせを探索することに要した時間はおよそ1日であったため、全ての組み合わせを調べるなら2年程度かかることになる。データからランダム・サンプリングによって、因子構造およびそれら因子間の因果構造を、効率的に自動探索するためには、なんらかの制約条件を付加して、構成可能な因子の探索空間を適切に制限できないと、有効なモデルが得られるか否かは、まったくの偶然任せになると言える。

2つ目の課題は、因果モデルが得られなかった場合、その本当の原因は不明なことである。今回の実験では、目的因子を「プログラミングに対する興味関心」とした場合は、因果モデルが見つかったが、「IT・理工系職業への関心」とした場合には、有効なモデルが見つからなかった。「IT・理工系職業への関心」因子を含む因果モデルが発見できなかった原因として、考えられることは、前述の探索範囲が0.13%であったことに加えて、もともと、「IT・理工系職業への関心」因子を含む有効な因果モデルが存在しなかったことが挙げられる。もし、そもそも有効なモデルが存在しないのであれば、ランダム・サンプリングを用いたモデル探索は、時間の無駄にしかない。分析対象のデータに、有効な因子・因果モデルは存在するかどうかをアприオリに推定することができるなら、この問題は解決するが、現時点で筆者らには推定可能かどうかは不明である。

3点目として、テクニカルな課題であるが、DEALパッケージのjointprior()に与えるimaginary sample size (I.S.S)と、生成されたモデルの関連性について触れたい。豊澤(2015)によると、I.S.Sが大きいとノード間の矢印の数が多い、複雑なモデルが得られるとある。実験1および2では、I.S.S.をデフォルト、したがって最小値とした場合と、70とした場合の2通りを試みた。今回の実験では、デフォルトのI.S.S.は、実行結果を見ると、22であった。

I.S.S.の大きさの違いは、妥当性が確認されたモデルの個数に反映されたようである。すなわち、I.S.S.が大きいと、どちらの目的因子においても、生成された、妥当とされるモデルの数は増加した。このことは、分析対象とする領域や目的因子に依ると思われるので一概には言えないが、因果モデルは、単純なものよりは複雑な、すなわち、因果矢線の数が多い方が、妥当性が確認される可能性が高いようである。I.S.S.の大きさと、妥当なモデルの生成されやすさの関係、および、適切なI.S.S.の決め方については今後の検討課題である。

謝辞

授業実践でご協力を賜った、木村雅士先生(孺恋村立孺恋中学校)と奥木芳明先生(中之条町立中之条中学校)、ならび

に両校の諸先生方に深謝する。また、質問紙の開発ではGerald Knezek教授(University of North Texas)に貴重な助言を頂いた。本研究の一部は、科学研究費補助金の助成を受けた(基盤(C)課題番号24501127)。

文献

- 古田貴久、奥木芳明(2010) 中学校・技術のための鉄道模型制御教材 Grailの開発。群馬大学教育実践研究、27, 173-182.
- 市川雅教(2010) 因子分析。東京：朝倉書店
- Knezek, G. and Christensen, R. (1995). A Comparison of Two Computer Curricular Programs at a Texas Junior High School Using the Computer Attitude Questionnaire (CAQ) Denton, TX: Texas Center for Educational Technology.
- Knezek, G. and Christensen, R. (1997). Attitudes Toward Information Technology at Two Parochial Schools in North Texas. Denton, TX: Texas Center for Educational Technology.
- Matsuda, R.L. (2012). Key advances in the history of Structural Equation Modeling. In R. H. Hoyle, (Ed.) Handbook of Structural Equation Modeling. New York: Guilford.
- 奥木芳明、古田貴久(2005) 児童の問題解決過程における情報活用の実践力尺度の開発。日本教育工学会論文誌, 29(1), 69-78.
- 豊澤英治(2015) 楽しいR。東京：翔泳社。