

深層学習とウェーブレットを用いた多変量時系列予測器

Artificial Intelligence Predictor for Multivariate Time Series with Deep-learning and Wavelet Analysis

塩野 剛志*

Takashi Shiono

クレディ・スイス証券株式会社 経済調査部**

Economic Research, Credit Suisse Securities (Japan) Limited

Abstract: The author integrated 1) multiple time-series analysis, 2) deep-learning, and 3) wavelet transform technics to forecast financial and economic time-series data. More specifically, the general purpose predictor was developed, which exploits large number of observable variables by summarizing them into latent factors through deep-learning. This can be regarded as a deep-learning version of Factor Augmented VAR model. As a preprocessing step, all observable variables are decomposed into cyclical components (waves) and a trend component by multiple resolution analysis based on "wavelet transforms". FAVAR model is fitted to the each decomposed series with extrapolating forecasts, and then integrated into the fitted values and forecasts of original series. The back-test for the period from Jan 2015 to Apr 2016 showed good performances of the 1-month- and 3-month-ahead predictions for TOPIX, USDJPY and other economic indicators, compared with the simple VAR model.

1. はじめに

1) 時系列解析 (FAVAR)、2) 深層学習 (Stacked-LSTM)、3) ウェーブレット解析、の3つを組み合わせることで、為替、株価、鉱工業生産など、様々な時系列データに対して一定の予測力を確保できる人工知能予測器 (以下、予測器) を開発した。この予測器は、任意に集めた大量の時系列データから、目標とする変数の予想に役立つパターンを発見し、有限個のファクターに集約する。推定されたファクターは、大量の時系列データをウォッチすることで予測器 (AI) が抱いた「景況感」のようなものである。こうしたファクターを、予測したい変数からなる VAR (多変量自己回帰) モデルに加えることで、その精度を向上させることができた。

同予測器は、市場や経済の「先を読む」ために、日々、市場の値動きや GDP の値だけでなく、関連する大量のデータをウォッチし、「相場感」や「景況感」を形成しているプロの市場参加者 (フォーキャスター) の知的作業を模したものとも言えよう。

外挿 (Out-of-sample) テストの結果、この予測器による予測は、多くの系列について、単純な VAR による予測を明確に上回るパフォーマンスを示した。なお、テストした系列は、ドル円レート、TOPIX、鉱工業生産、第三次産業活動指数、消費者物価、等である。

もっとも、こうした予測器による精度が、専門化されたプロのフォーキャスターを上回るか否か等はテストしておらず、あくまでも、単純な VAR モデルを超えたに過ぎない。

通常、プロのフォーキャスターによる時系列データの予測は、理論的・経験的に想定される因果関係や相関関係 (先行指標) に基づき、重要な変数を選んで回帰分析を行う。他方、VAR のように時系列分析は、データ自身の過去の変動パターンを単純に延長するという意味でより恣意性の低い方法である。良く練られた回帰モデルであれば、その予測精度は手元のデータを全て用いるような VAR よりも高くなり得る。これがプロが回帰モデルを組むことの価値だと判断される。つまり、どのような変数を選んで回帰モデルを組むかがプロのフォーキャスターの恣意であると同時に、腕の見せ所でもある。

今回の予測器では、こうしたプロによる変数選択を模した情報集約アルゴリズムを用いることで、人手で変数を選ぶことなく、シンプルな VAR モデルを

* 連絡先: クレディ・スイス証券株式会社 経済調査部, 〒106-6024 東京都港区六本木 1-6-1 泉ガーデンタワー26 階, Takashi.shiono@credit-suisse.com

** 本稿の中で示された内容や意見は、クレディ・スイス証券の公式見解を示すものではありません

上回る予測精度を得ることに成功した。

2. 分析手法

この予測器は、1) 多変量時系列解析 (FAVAR)、2) 深層学習 (Stacked-LSTM)、3) ウェーブレット解析、の3つを組み合わせることで構築されている。その予測モデルとしての特徴をまとめると以下の通りである。

- 恣意性が低い： 事前に変数間の因果関係を想定する必要がないため、汎用性が高く、様々な分野の時系列データを扱える。
- スケールアップが容易： 大量時系列のファクター化を AI が担うため、変数選択の必要がない。気になるデータはとりあえず取り入れてみるができる。
- 専門化が可能： 同じデータを見ていても、株式市場、債券市場、為替市場ではそれぞれ景況感が異なり得るように、この AI も、予測したい目的変数を入れ替えることで、目的に適応した異なるファクターを学習する。
- 複数タイムスケール： ウェーブレット解析によって周波数毎に分解した系列を学習するため、ファクターも周波数毎に学習される。つまり、AI は短期の景況感、中期の景況感、長期の景況感、というように複数タイムスケールのファクターを学習する。

以下では、この予測器を構成する各技術を簡単に紹介した上で、モデルの全容と推計方法を示す。

2.1 多変量時系列解析：FAVAR

モデルの基本的な枠組みは、バーナンキら[1]が2004年に発案した、FAVAR (Factor Augmented Vector Autoregression) を拡張し、最新の人工知能技術 (深層学習) の成果を取り入れたものである。

まず、FAVAR の土台である VAR (多変量自己回帰) とは、複数の時系列からなるベクトルが、それ自身の過去の値に依存して決まるように定式化された自己回帰モデルである。数式で表せば次の通りである (2 変数で 1 期ラグの場合、 e は誤差項)。

(式 1)

$$Y_t = \Phi Y_{t-1} + e_t, \quad e_t \sim i.i.d. (0, \Sigma) \\ \equiv \begin{bmatrix} y_t^1 \\ y_t^2 \end{bmatrix} = \begin{bmatrix} \phi^{11} & \phi^{12} \\ \phi^{21} & \phi^{22} \end{bmatrix} \begin{bmatrix} y_{t-1}^1 \\ y_{t-1}^2 \end{bmatrix} + \begin{bmatrix} e_t^1 \\ e_t^2 \end{bmatrix}$$

VAR では選択した変数群 (Y) の過去の値以外からの影響は全く考慮しない。しかし、実際の経済時系

列データの動きを、観察可能な有限個の変数だけで十分に説明し尽くせるとは限らない。例えば、物価と GDP という 2 変数 VAR を考えた場合、これらが相互作用しながら動いているのに疑いはないが、この 2 変数だけでダイナミクスが完結するわけではない。物価と GDP はともに、「インフレ期待」や「景況感」といった観察できない変数からの影響も受けていると考えられる。

FAVAR は、こうした点を補うべく、VAR に「潜在ファクター変数」を組み込んだものである。具体的には、以下のような観測式 (observation) と遷移式 (transition) のセットで表される (状態空間表現)。

(式 2)

$$\text{(Observation)} \quad \begin{bmatrix} X_t \\ Y_t \end{bmatrix} = \begin{bmatrix} \Lambda & 0 \\ 0 & I \end{bmatrix} \begin{bmatrix} F_t \\ Y_t \end{bmatrix} + \begin{bmatrix} e_t \\ 0 \end{bmatrix} \\ \text{(Transition)} \quad \begin{bmatrix} F_t \\ Y_t \end{bmatrix} = \Phi(p) \begin{bmatrix} F_{t-1} \\ Y_{t-1} \end{bmatrix} + v_t$$

ここで F は潜在ファクター変数であり、説明の対象となるターゲット変数 (Y) と合わせて VAR モデルを形成する (遷移式、 v は推移誤差項)。先ほどの例で言えば、遷移式は物価、GDP、インフレ期待、景況感、という 4 変数の VAR となる。

しかし、このままではファクターが観察不可能であり、遷移モデルのパラメーター Φ を推定することはできない (Φ の p はラグ次数)。そこで、情報変数 (X) と観測式が必要となる (e は観測誤差項)。情報変数 (X) は、任意に集めた大量の時系列データを想定しており、その値は潜在ファクターの値に回帰される。つまり、観察された情報変数 (X) の動きを手がかりとして、未知の潜在ファクター (F) を逆算し、ターゲット変数 (Y) の予測に活用する、という仕組みである。

この際、情報変数 (X) から潜在ファクター (F) への変換をどのように行うかが FAVAR モデルの要となる。バーナンキら[1]は主成分分析によって大量の X (120 変数) から少数の主成分 (1~5 次元) を抜き出し、それを F とする方法を提示した。また、Belviso and Milani [2]は、上の遷移式と観測式を状態空間モデルと看做し、マルコフ連鎖モンテカルロ (MCMC) 法によってパラメーターと潜在ファクターを同時推定する例を示している。いずれにせよ、大量の情報変数から何らかの共通パターンを抽出し、それを潜在ファクターとしてターゲット変数の予測に用いるという発想は共通である。

一方、本稿では、こうした「大量情報からのパターン抽出と集約化」が、人工知能技術である深層学習 (ディープ・ラーニング) の得意とするプロセスで

ある点に目を付け、FAVAR を深層学習の枠組みで捉え直して推計することを試みた。

2.2 深層学習 : Stacked LSTM

本稿では、FAVAR をひとつの多層ニューラル・ネットワークと看做し、潜在ファクターをニューラル・ネットワークの隠れ層として定式化する。

具体的には、FAVAR をニューラル・ネットワークに置き換える場合、潜在ファクター（隠れ層）の自己回帰性を表現できる RNN（Recurrent Neural Network）の枠組みを用いるのが適切である。特に、ラグ次数が長期に渡る可能性も考慮すると、LSTM（Long Short-Term Memory）モデルとして定式化するのがよいだろう。LSTM は、音声認識や機械翻訳など、過去の情報が現在の情報の意味に大きく影響するような長期記憶の時系列データを学習するために拡張された RNN であり、長期記憶過程の多い経済時系列データを学習する際にも適している²。この LSTM は、上図の多層ニューラル・ネットワークで言えば中間層に位置し、その出力が次の層だけでなく、自分自身の入力として再帰する構造を持つことになる³。

以上のように、FAVAR を LSTM を用いた多層ニューラルネットワークとしてモデル化すると、以下のように図式化できる。

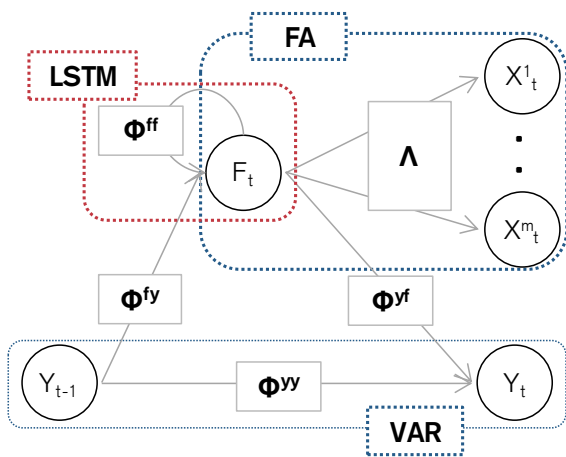


図 1: LSTM を用いた FAVAR のグラフィカル・モデル

こうして LSTM を用いて定式化された多層ニューラルネットワークの本質的な仕組みは、上述の FAVAR と何

² LSTM の詳細は Gers, FA., et al. [3]などを参照されたい。

³ その際、LSTM は直前の自己状態だけでなく、遠い過去の自己状態からの影響も考慮する長期記憶性を持つ。これは、LSTM がその内部にメモリを持ち、新規入力情報のメモリへの追加と、既存情報のメモリからの忘却（クリア）を選択しながら教師データへのフィットを高めるように学習をするためである。

も変わらない。強いて言えば、パラメーターの推定が、ニューラルネットに依拠した方法（確率勾配降下法）によって行われるだけである。なお、本稿では、LSTM の学習に Chainer という Python の深層学習用モジュールを用いている。

2.3 ウェーブレット解析 : 多重解像度分解

本稿では、FAVAR をひとつの多層ニューラル・ネットワークと看做し、潜在ファクターをニューラル・ネットワークの隠れ層として定式化している。

LSTM 多層ニューラルネットワークとして表現された FAVAR の学習を、経済時系列データを直接使っても良いのだが、本稿では、データをウェーブレット変換によって多重解像度解析してから学習することで、さらなる予測精度の向上を図る。

ウェーブレット変換は、時系列データにおける周期成分の混じり方（周波数分布）の時間的な変化を解析することを目的に考案されたものである。ここでは特に、ウェーブレット変換の重要な応用である「多重解像度解析」を使用する。詳しい解説は田中 [4]等の専門の文献に譲るが、直感的に言えば、「ウェーブレット変換による多重解像度解析」は、周期の短い成分から長い成分へと逐次、原系列から寄与度を抜き出すことで、周期別に分解された時系列を作成する方法である⁴。

LSTM の深層学習は、音声認識などの周期時系列データを扱う際にその有効性が実証されてきた。そのため、ウェーブレット解析によって、経済時系列データを周期データに分解してから、周期毎に特化したニューラルネットワークの学習を行うことで、精度向上が期待できる。

2.4 FAVAR-LSTM をウェーブレット解析後のデータで学習

本稿で用いる観測データ（Y と X）は、文末図表 5 に示した通り、全部で 257 系列であり、日本、米国、EU、中国の主要な経済データを集めたものである。

予測したい変数をターゲット（Y）として選び、そ

⁴ なお、一般に、ウェーブレット変換では端点（始点と終点）付近の結果に歪みが生じやすい。このため、なんらかの方法でデータの前後に架空のデータを継ぎ足すことでこの緩和が図られる。最も頻繁に行われるのはデータを一から繰り返すことだが、この方法だとデータにトレンドがある場合にかえって歪みが大きくなる。そのため、本稿では、端点間の段差を緩和するため、HP フィルターを用いて事前に原データをトレンド成分とサイクル成分に分解し、サイクル成分のみを多重解像度解析の対象とした。その上で、サイクル成分に AR モデルをフィットさせて予測値を継ぎ足し、ちょうどその予測期間と減衰テイルが同じになるような窓関数を適応して両端をゼロにしてから、データを反復させた。こうして得られた多重解像度解析の結果は窓関数の掛かった AR 予測値を含んでいるため、その部分は破棄する。こうすることで、原データの終点（最新実績値）付近のウェーブレット変換を正確に行うことが出来る。

れ以外を情報変数 (X) として、FAVAR-LSTM モデルを推定する。今回は、(1) 金融市場で典型的に重要な例として、ドル円レートと TOPIX の 2 変数をターゲットとした「ストラテジスト・モデル」。並びに、

(2) マクロ経済動向を意識し、鉱工業生産、第三次産業活動指数、消費者物価の 3 変数をターゲットとした「エコノミスト・モデル」の二つを推定する。

全データ期間は 2005 年 10 月～2016 年 4 月までの月次である。なお、モデル学習用の期間は 2007 年 10 月～2014 年 12 月までとし、2015 年 1 月以降のデータは外挿テストのために使用する。

学習に先立って、原データを全てウェーブレット解析によって、(1) 2 ヶ月、(2) 4 ヶ月、(3) 8 ヶ月、(4) 16 ヶ月、(5) 32 ヶ月、(6) 64 ヶ月、(7) 128 ヶ月の各周期成分と、(8) 長期トレンド成分に分解する。

分解された (1) ～ (8) のデータそれぞれについて FAVAR-LSTM の学習と外挿予想を行い、最後に合算して原系列を再構築する。

3. 分析結果

改めて、FAVAR を使用する目的は、単純な VAR では捉えきれない「期待」や「景況感」のような潜在変数の影響を、観察された大量の時系列データの動きを手がかりに捕捉し、ターゲット変数の予測に活かすこと、であった。

そのため、FAVAR の予測パフォーマンス評価は、ターゲット変数のみからなる単純 VAR による予測との比較によって行うのが自然である。単純 VAR と比較して予測精度が向上していれば、それは、大量の時系列データから予測に有用なパターンを発見・抽出できたことを意味する。

通常、こうした大量データ・ウォッチを通じた「相場感」や「景況感」の形成によってターゲット変数への高い予測力を得ることは、プロの予測者（フォーキャスター）の経験や経済現象への洞察力に依るところが大きい。もし FAVAR-LSTM の予測力が VAR を明確に超えていれば、この人工知能 (AI) モデルが、そうしたプロの知的作業を模倣することで同様の精度向上に成功したことになる。

実際に、ドル円と TOPIX を予測した「ストラテジスト・モデル」と、日本のマクロ経済変数を予測した「エコノミスト・モデル」について、2015 年 1 月～2016 年 4 月までの外挿テストを行った結果を図表 2 にまとめた。なお、外挿テストではテスト期間の各月から推計した 1 ヶ月先予測と 3 ヶ月先予想の 2 パターンを計算した。

| | 1ヶ月先 | | 3ヶ月先 | |
|---------------|-------|------|-------|-------|
| | AI予測器 | VAR | AI予測器 | VAR |
| TOPIX (ポイント) | 41.6 | 74.0 | 88.6 | 136.0 |
| ドル円 (円) | 0.9 | 1.5 | 1.4 | 3.9 |
| 鉱工業生産 (%) | 1.1% | 1.7% | 1.7% | 2.2% |
| 第三次産業活動指数 (%) | 0.4% | 0.8% | 0.5% | 2.0% |
| 消費者物価 (%) | 0.2% | 0.2% | 0.4% | 0.4% |

図 2: モデル予想の平均絶対誤差 (2015 年 1 月～2016 年 4 月)

原系列に VAR モデルを適応して得た予測と FAVAR-LSTM (AI 予測器) から得た予測の平均絶対誤差を比較してみると、「ストラテジスト・モデル」、「エコノミスト・モデル」共に、全てのターゲット変数について、後者の明確な優位が確認された。

例えば、TOPIX に関する予測誤差は、VAR で 1 ヶ月先: ±74 ポイント、3 ヶ月先: ±136 ポイントだが、AI 予測器では 1 ヶ月先: ±42 ポイント、3 ヶ月先: ±89 ポイントであった (図表 3)。また、ドル円レートの予測誤差は、VAR で 1 ヶ月先: ±1.5 円、3 ヶ月先: ±3.9 円だが、AI 予測器では 1 ヶ月先: ±0.9 円、3 ヶ月先: ±1.4 円であった (図表 4)。

エコノミスト・モデルについても図表 2 の通り、AI 予測器の精度優位が確認された。




図 3: TOPIX の外挿 1 ヶ月先予想



図 4: ドル円レートの外挿 1 ヶ月先予想

4. 課題

注意が必要なのは、この予測器 (FAVAR-LSTM) の予測精度が、専門化されたプロのフォーキャスターを上回ったわけではない、ということである (そういったテストは行っていない)。あくまでもシンプルな VAR モデルとの比較で予測精度の向上が見られたに過ぎない。

また、予測器は経済現象の因果関係や動学メカニズムを理解している訳ではない。単に、ターゲット変数の予想に役に立つことを目的とした情報収集と集約化を行っただけである。なぜそのような予測になるのか説明を求めても、AI 自身に答える術はない (推定されたパラメータを見ながら開発者が後講釈することはできるが)。

また、汎用性があるといっても、学習を行う際の環境パラメータ設定には試行錯誤が必要となる。例えば、パラメータの学習は有限回のトライ&エラーの反復で行われるが、その反復回数や、パラメータを更新する際の変化の大きさ (学習率と呼ばれる) 等は、学習するデータの特性に合わせて開発者が人手で調整する必要がある。

つまり、様々な分野に応用できるとは言え、本稿の予測器はあくまでもスペシャリスト型の AI であり、作業対象 (各時系列データ) の特性を開発者が見極め、AI が働きやすいようにモデル構造や環境を整えてやる必要がある。言い換えれば、予測器によって高い予測パフォーマンスを出すには、開発者が経済データやその変動メカニズムについて十分に理解していることが欠かせない。

参考文献

- [1] Bernanke, B. S., Boivin, J., and Eliasziw, P., (2004) "Measuring the Effects of Monetary Policy: A Factor-Augmented Vector Autoregressive (FAVAR) Approach", NBER Working Paper 10220.
- [2] Belviso, F., and Milani, F., (2006) "Structural Factor-Augmented VARs (SFAVARs) and the Effects of Monetary Policy", The B.E. Journal of Macroeconomics, 2006, vol. 6, issue 3, pages 1-46.
- [3] Gersl, F.A., Schmidhuber, J., Cummins, F., (1999) "Learning to forget: continual prediction with LSTM", Neural Comput. 2000 Oct;12(10):2451-71.
- [4] 田中 勝人: 現代時系列分析, 岩波書店, (2006)

| | | | | | | |
|----|----|------|------------------|-----|--------|--------------|
| 1 | 日本 | 生産 | 鉱工業生産指数 | 60 | 対外収支 | 貿易収支 |
| 2 | | | 消費財 | 61 | | サービス収支 |
| 3 | | | 投資財 | 62 | | 所得収支 |
| 4 | | | 生産財 | 63 | | 直接投資収益 |
| 5 | | | 出荷 | 64 | | 経常収支 |
| 6 | | | 在庫率 | 65 | | 対外直接投資 |
| 7 | | | 最終財在庫率 | 66 | | 対内直接投資 |
| 8 | | | 生産財在庫率 | 67 | | ドル円 |
| 9 | | | 大口電力使用量 | 68 | | ユーロ円 |
| 10 | | | 第3次産業活動指数 | 69 | | ウォン円 |
| 11 | | | 全産業活動指数 | 70 | | 元円 |
| 12 | | 消費 | 消費総合指数 | 71 | | 名目実効 |
| 13 | | | 家計調査消費支出 | 72 | | 実質実効 |
| 14 | | | 実質小売販売 | 73 | 消費者物価 | コア |
| 15 | | | 新車販売（自販連+軽自協） | 74 | | コアコア |
| 16 | | | クレジットカード月次ショッピング | 75 | | 東京コア |
| 17 | | | 道路旅客輸送 | 76 | | 東京コアコア |
| 18 | | | 鉄道旅客輸送 | 77 | | 耐久財 |
| 19 | | | 宅配貨物輸送 | 78 | | 半耐久財 |
| 20 | | | 自動車レンタル | 79 | | 非耐久財 |
| 21 | | | 広告業 | 80 | | サービス |
| 22 | | | 飲食宿泊 | 81 | 企業物価 | CGPI |
| 23 | | | 生活サービス | 82 | | 消費財 |
| 24 | | 住宅 | 住宅着工戸数 | 83 | | 資本財 |
| 25 | | | 実質住宅建築額 | 84 | | 中間財 |
| 26 | | | 首都圏マンション契約率 | 85 | | 粗原材料 |
| 27 | | | 近畿マンション契約率 | 86 | | CSPI |
| 28 | | 設備 | 機械受注コア民需 | 87 | 賃金 | 現金給与総額 |
| 29 | | | 投資財出荷 | 88 | | 所定内 |
| 30 | | | 資本財出荷 | 89 | | 一般所定内 |
| 31 | | | 建設財出荷 | 90 | | パート所定内 |
| 32 | | | 非居住床面積 | 91 | | 派遣サービス価格 |
| 33 | | | 製造業稼働率 | 92 | 地価 | 市街地価格指数6大全用途 |
| 34 | | | コア工作機械受注 | 93 | | 商業地 |
| 35 | | | オフィス空室率東京 | 94 | | 住宅地 |
| 36 | | | 名古屋 | 95 | 住宅価格 | CPI家賃 |
| 37 | | | 大阪 | 96 | | 首都圏マンション価格 |
| 38 | | | リース契約高 | 97 | | 近畿マンション価格 |
| 39 | | 在庫 | 在庫指数 | 98 | センチメント | 景気ウォッチャー家計 |
| 40 | | 公共投資 | 公共工事発注保証実績請負額 | 99 | | 家計先行 |
| 41 | | | 公共工事受注 | 100 | | 企業 |
| 42 | | 純輸出 | 日銀実質輸出 | 101 | | 雇用 |
| 43 | | | 日銀実質輸入 | 102 | | 消費者態度指数 |
| 44 | | | 機械受注外需 | 103 | | 中小企業売上見通し |
| 45 | | | 工作機械受注外需 | 104 | | 短観大企業製造業DI |
| 46 | | 労働市場 | 失業率 | 105 | | 短観大企業非製造業DI |
| 47 | | | 就業者数 | 106 | 貨幣量 | 超過準備 |
| 48 | | | 雇用者数 | 107 | | 現金 |
| 49 | | | 新規求人 | 108 | | マネタリーベース |
| 50 | | | 常用雇用指数 | 109 | | M3 |
| 51 | | | 有効求人倍率 | 110 | | 預金 |
| 52 | | | 労働参加率 | 111 | | 広義流動性 |
| 53 | | | 15才以上人口 | 112 | 金利 | CR |
| 54 | | | 所定内労働 | 113 | | OIS3M |
| 55 | | | 所定外労働 | 114 | | TIBOR3M |
| 56 | | 家計所得 | 実質可処分所得 | 115 | | JGB2 |
| 57 | | | 営業利益 | 116 | | JGB5 |
| 58 | | | ROA | 117 | | JGB7 |
| 59 | | | 売上高経常利益率 | 118 | | JGB10 |
| | | | | 119 | | AA |
| | | | | 120 | | A |
| | | | | 121 | | Baa |

図 5: 観測データのリスト

| | | | | | |
|-----|------|--------------|-----|-------|---------------|
| 122 | 金融仲介 | 銀行貸出 | 185 | 家計 | カンファレンスボード |
| 123 | | 個人 | 186 | | ミシガン大 |
| 124 | | 企業 | 187 | | 名目個人支出 |
| 125 | 株価 | TOPIX | 188 | | 名目個人所得 |
| 126 | | 水産・農林業 | 189 | | 個人貯蓄率 |
| 127 | | 鉱業 | 190 | | 小売売上高 |
| 128 | | 建設業 | 191 | | 住宅着工件数 |
| 129 | | 食料品 | 192 | | 新築住宅販売 |
| 130 | | 繊維製品 | 193 | | 中古住宅販売 |
| 131 | | パルプ・紙 | 194 | | ケースシラー住宅価格指数 |
| 132 | | 化学 | 195 | 消費者物価 | 総合CPI |
| 133 | | 医薬品 | 196 | | コアCPI |
| 134 | | 石油・石炭製品 | 197 | | コアPCE |
| 135 | | ゴム製品 | 198 | 企業 | 耐久財受注 |
| 136 | | ガラス・土石製品 | 199 | | 設備稼働率 |
| 137 | | 鉄鋼 | 200 | 企業物価 | コアPPI |
| 138 | | 非鉄金属 | 201 | 通貨 | マネタリーベース |
| 139 | | 金属製品 | 202 | | M2 |
| 140 | | 機械 | 203 | | 銀行貸出 |
| 141 | | 電気機器 | 204 | 金融市場 | FF rate |
| 142 | | 輸送用機器 | 205 | | OIS3M |
| 143 | | 精密機器 | 206 | | Libor3M |
| 144 | | その他製品 | 207 | | UST2 |
| 145 | | 電気・ガス業 | 208 | | UST10 |
| 146 | | 陸運業 | 209 | | SP |
| 147 | | 海運業 | 210 | | VIX |
| 148 | | 空運業 | 211 | ユーロ圏 | 対外取引 |
| 149 | | 倉庫・運輸関連業 | 212 | | 輸出額 |
| 150 | | 情報・通信業 | 213 | | 輸入額 |
| 151 | | 卸売業 | 214 | 生産活動 | 鉱工業生産 |
| 152 | | 小売業 | 215 | 労働市場 | 失業率 |
| 153 | | 銀行業 | 216 | 家計 | 小売売上高 |
| 154 | | 証券・商品先物取引業 | 217 | | 消費者信頼感指数 |
| 155 | | 保険業 | 218 | 消費者物価 | 住宅ローン貸出 |
| 156 | | その他金融業 | 219 | | CPI |
| 157 | | 不動産業 | 220 | 企業 | コアCPI |
| 158 | | サービス業 | 221 | | PMI製造業 |
| 159 | | REIT | 222 | | PMIサービス |
| 160 | | TOPIX Return | 223 | | ZEW |
| 161 | | 1部総売買代金 | 224 | | ドイツIFO |
| 162 | 商品価格 | 日経商品指数42 | 225 | 企業物価 | 建設生産高 |
| 163 | | トバイ原油 | 226 | | PPI |
| 164 | | CRB | 227 | 通貨 | コアPPI |
| 165 | | CRB食料 | 228 | | M2 |
| 166 | 米国 | 対外取引 | 229 | | M3 |
| 167 | | 輸出額 | 230 | 金融市場 | M1 |
| 168 | | 輸入額 | 230 | | ECB repo rate |
| 169 | 生産活動 | 鉱工業生産 | 231 | | OIS3M |
| 170 | | 売上在庫比率 | 232 | | Libor3M |
| 171 | | ISM製造・景況 | 233 | | Schatz2 |
| 172 | | ISM新規受注 | 234 | | Bunds10 |
| 173 | | 在庫 | 235 | | Itary2 |
| 174 | | ISM非製・景況 | 236 | | Itary10 |
| 175 | | シカゴPMI | 237 | | BE500 |
| 176 | | フィラデルフィア連銀指数 | 238 | | DAX |
| 177 | 労働市場 | NY連銀指数 | 239 | 中国 | 対外取引 |
| 178 | | ADP | 240 | | 輸出 |
| 179 | | ISM雇用DI、製造業 | 241 | | 輸入 |
| 180 | | 非製造業 | 242 | 生産活動 | 工業生産 |
| 181 | | BLS雇用統計、非農業 | 243 | 家計 | 小売売上高 |
| 182 | | 民間 | 244 | | 消費者信頼感指数 |
| 183 | | 失業率 | 245 | 消費者物価 | CPI |
| 184 | | 週間労働時間 | 246 | 企業 | PMI, NBS |
| | | 時間当たり平均賃金 | 247 | | 固定資本投資 |
| | | | 248 | | 耐久財受注 |
| | | | 249 | 企業物価 | 生産者物価指数 |
| | | | 250 | 通貨、金融 | M2 |
| | | | 251 | | 預金準備率 |
| | | | 252 | | 銀行貸出 |
| | | | 253 | | 貸出基準金利 |
| | | | 254 | | SHIBOR3M |
| | | | 255 | | 国債2年 |
| | | | 256 | | 国債10年 |
| | | | 257 | | ハンセン |
| | | | | | 上海総合 |

図5: 観測データのリスト (続)