

# 高頻度電力需要データを用いた 製造業活動のナウキャストモデリングモデルの構築

Real-time Economic Indicator of Manufacturing Industry  
based on High-frequency Electricity Demand Data

水門善之<sup>1,2\*</sup> 和泉潔<sup>1</sup>

坂地泰紀<sup>1</sup> 島田尚<sup>1</sup> 松島裕康<sup>1</sup>

Yoshiyuki Suimon<sup>1,2</sup> Kiyoshi Izumi<sup>1</sup>

Hiroki Sakaji<sup>1</sup> Takashi Shimada<sup>1</sup> Hiroyasu Matsushima<sup>1</sup>

<sup>1</sup> 東京大学大学院工学系研究科システム創成学専攻

<sup>1</sup> Department of Systems Innovations, School of Engineering  
The University of Tokyo

<sup>2</sup> 野村証券株式会社金融経済研究所経済調査部

<sup>2</sup> Economic Research Department, Financial and Economic Research Center  
Nomura Securities Co., Ltd.,

**Abstract:** 景気の先行きを考える上で、製造業の生産活動の活況度合いをいち早く把握することは重要である。製造業が生産活動を行う際には電力が消費される点を踏まえ、本研究では、大手電力会社が公表する5分ごとの電力需要データに着目することで、製造業の活動状況を高い速報性をもって推計するナウキャストモデリングモデルを構築した。具体的には、日中の電力需要の高頻度データに対して主成分分析を行うことで、電力消費の変動パターンを表す主成分ファクターを抽出し、それらを用いて、製造業の生産活動を推計する正規化回帰モデルを構築した。なお、製造業等の生産活動を表す公式統計としては、経済産業省が集計する鉱工業生産指数が挙げられるが、本提案手法に基づくと、同指数の公表よりも一カ月程度早い製造業活動の推計が可能となった。更に、本手法に基づく生産指数の推計結果は、同指数の公表前に集計された市場予想平均値と比較して、高い予測精度が実現できることを確認した。

## 1. はじめに

昨今、経済分析において、従来の経済統計を補完する形で、様々なデータを活用する流れが進んでいる。これらは、オルタナティブデータと呼ばれ、高頻度の売上データや物流データ、多様な経済活動を捉えたビッグデータ、更には経済動態を物理的に観測した画像や、様々なテキストといった非構造化データなど多岐に渡る。オルタナティブデータを使用するメリットは、その情報の豊富さに加え、速報性の高さも挙げられる。例えば、速報性に特化した経済動態把握を目的として、クレジットカードの決済データや、小売店での販売時点情報管理 (POS : Point of Sale) データ、様々な商業用データを統合的に用

いて、消費動向をリアルタイムかつ高精度で推計する分析等が行われており[1][2]、これらは既に金融ビジネスにおける経済分析業務では不可欠なアプローチとなっている。

更に、消費動向に加えて、景気全般の動向を捉える上では、製造業の生産活動の活況度合いをいち早く把握することが重要である。鉱業・製造業の生産活動状況を捉えた政府統計としては、経済産業省の鉱工業生産指数が挙げられる。ただし、同指数は対象月の集計結果が翌月末に公表されることから、公表までに若干の時間差が存在する。一方、計測の精度は劣るものの、速報性の高い観測データを用いて、製造業の生産活動を推計する方法もある。例えば、製造業の生産活動が活発化する場面においては、工

\* Email: d2018ysuimon@socsim.org

場等の稼働時間が長くなる傾向を踏まえ、衛星写真の夜間光データを用いて夜間活動の状況を観測する手法等が挙げられる[3]。実際、雇用者の所定外労働時間と製造業の生産活動の間にはある程度の相関関係があることから、このような手法は有効だろう。一方で、昨今、政府が主導する働き方改革[4]の推進を受けた生産性の向上等に伴って、所定外労働時間と工場の生産活動の連動性は崩れつつあり、所定外の労働時間に着目する計測手法は、構造的な問題を抱えていると言えよう。

これらの点を踏まえ、本研究では社会構造の変化に耐えうる、より安定性の高い製造業の生産指数の推計手法を提案したい。具体的には、製造業が生産活動を行う際に使用する電力の消費量に着目することで、製造業の生産活動の把握を行う。仮に、働き方改革等の推進に伴って単位時間当りの労働生産性が改善し、労働時間に着目した従来手法の推計精度が低下するような場合においても、製造業の生産活動の過程で使用される電気エネルギーの単位エネルギー当りの生産性（生産量）が大きく変わらない限り、電力データに着目する生産活動の計測手法は有効であると考えられる。

## 2. 高頻度電力データと製造業活動

### 2.1 高頻度データを用いた経済動向の観測

東京電力や関西電力といった大手電力会社は、毎時間もしくは5分ごとの電力の消費実績を公表している。本研究では、このような電力需要の高頻度データに着目することで、経済動向のリアルタイムでの把握（ナウキャスト）手法を提案する。現状、多くの経済データは月次、もしくは日次で公表されるものが主だが、本手法を用いると、毎時間単位での経済動態の把握が可能となり、細かい粒度での経済の変動特性の解明が期待できる。この点を踏まえ、本研究では、日中の電力消費の変動パターンを分析することで、速報性の高い生産活動指数を作成する。

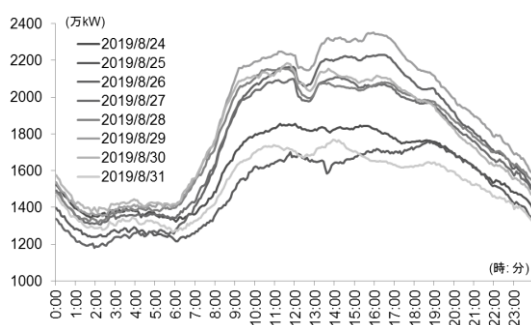


図2: 一日の電力消費の推移

図2に、実際に関西電力が公表している5分ごとの電力消費データ[5]を掲載した。大まかではあるが、昼にかけて電力消費は増加し、夜にかけて需要が低下していく傾向が見て取れる。このような電力需要の時間ごとの変化特性を計量的に把握するため、本研究では毎時間ごとの電力消費実績の日次データを対象に主成分分析（PCA: Principal Component Analysis）を行った。




図3: 主成分分析の結果（寄与度）

主成分分析の結果は図3、4に示した。図3に示した各主成分ファクターの寄与度によると、一日の間の電力需要の変化の約99%は3つのファクターによって説明されることが分かる。図4にこれら3つのファクターの固有ベクトルを掲載した。これによると第1ファクターが電力需要の水準、第2ファクターが昼過ぎにかけての電力需要、第3ファクターが夜間にかけての電力需要を意味すると解釈できよう。




図4: 主成分分析の結果（固有ベクトル）

このように日次ごとに算出される各主成分ファクターの月次集計値を図5に掲載した。一般に電力の消費量は、鋳工業の生産活動といった産業用の需要以外にも、サービス業の活動や人々の生活等における様々な需要の影響を受ける。また、冷暖房利用のための電力需要のように、気温の影響を強く受けるものも存在するとみられる。実際、図5に各主成分ファクターと気温（東京、大阪、名古屋の平均値）の関係を掲載したが、第2ファクターは、気温と顕著に連動する電力需要の変動が反映されていること

が分かる。また、寄与度の88%を占める第1ファクターは、気温が高くなる時期に上昇する一方、気温が低くなる時期にも上昇するという傾向が見られており、冷暖房等の需要を反映している可能性も窺える。もちろん、電力需要の高頻度データには、気温以外の要因に起因する産業用需要等の様々な主体の経済活動も反映されているとみられる。

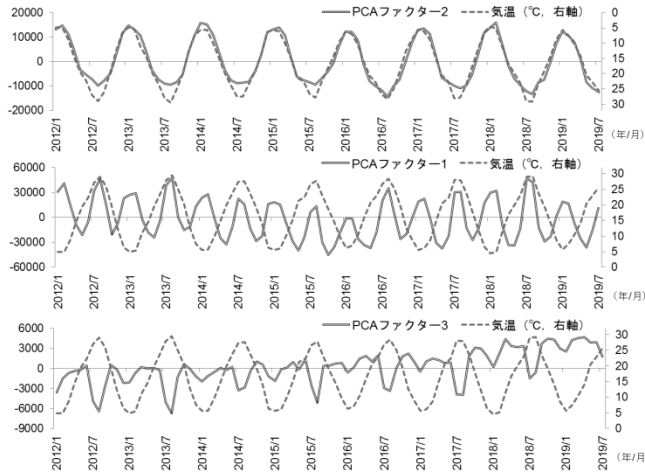


図 5: 主成分ファクターと気温の関係

## 2.2 製造業生産活動と産業用電力需要

本研究では、電力需要の高頻度データの変動特性に着目することで鉱工業の生産活動をモニタリングするモデルを構築するが、その前に、電力需要のデータと鉱工業生産の関係を振り返りたい。製造業の生産活動と電力需要の関係については、これまでも様々な研究にて確認されている[6][7]。これらを踏まえ、図6に電気事業連合会が公表している10社電力会社の合計電力需要量の実績値の推移を掲載した。同連合会は、合計の電力需要量に加えて、産業用需要を表す大口電力の需要も同時に公表していることから、全電力需要を産業用とそれ以外の用途に分類することができる。




図 6: 電力需要の内訳の推移

同統計が示す大口電力の需要量には製造業等の産業用需要が反映されていると見られる。このことを確認するために、大口電力の需要量と鉱工業生産指

数の原系列と比較すると、実際、両者の動きは連動していることが分かる(図7)。ただし大口電力の需要を表す系列は、2016年4月からの電力小売全面自由化の開始等に伴って2016年度以降の公表が停止されていることから、現在(2019年10月本稿執筆時点)は同様の手法で生産活動の推計を行うことはできない。ただし、少なくとも電力需要量には鉱工業の生産活動の需要が反映されていることを示す内容と言えよう。




図 7: 鉱工業生産指数と大口電力需要量

## 3. 生産活動のナウキャストिंग

### 3.1 電力需要情報を用いたモデル構築

これらを踏まえ、以下では電力需要データを用いた鉱工業生産活動のナウキャストिंगモデルを構築する。またモデルの構築には、経済産業省による製造工業生産予測調査の結果も併せて使用する。同調査は、製造工業約760企業を対象(2019年3月調査時点回収率92.8%)として、先行き2カ月の生産見込数量を集計したものであり、目先の生産活動に関する情報を含んだ統計である。本研究では、製造工業生産予測調査(生産計画、当月見込、原系列指数)を含む、以下の表1に示した3種類の系列の組み合わせを説明変数とし、鉱工業生産指数(原系列指数)を被説明変数としたモデルを構築する。モデルの推計の際には、各データを平均0、分散1の系列に変換したものを用いる。また、前述の通り、電力需要のデータは季節性の影響を強く受けるため、説明変数Iと説明変数IIの組については、各月のダミー変数を導入する。

説明変数Ⅰ.	製造工業生産予測調査 各月の合計電力需要 各月のダミー変数
説明変数Ⅱ.	製造工業生産予測調査 主成分第1-5ファクター 各月のダミー変数
説明変数Ⅲ.	製造工業生産予測調査

表 1: 説明変数の組み合わせ

本研究では、これらの説明変数を用いて、線形回帰、リッジ回帰、ラッソ回帰、エラスティックネットといった各種回帰モデルを用いた推計を行う。各モデルの説明は本稿巻末の補論を参照されたい。また本研究では、各推計時点において、(推計時点のデータを除く)過去2年分(もしくは3年分)のデータを用いてモデルの学習(モデルパラメータの推計)を行う。その後、推計月においては、学習済みのモデルに基づき、各種説明変数を用いて鉱工業生産指数の推計を行う(図8)。なお、モデルの学習及び生産指数の推計には、製造工業生産予測調査のデータが存在している2013年2月以降の月次データを使用する。また、各主成分ファクターについては各月の月平均値を説明変数として使用する。

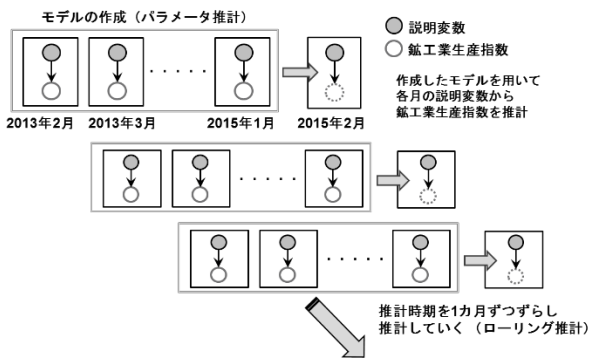


図8: モデルの作成と鉱工業生産指数推計の流れ

このように、各種手法に基づいて算出した、鉱工業生産指数の推計精度を評価する為に、生産指数の推計値と実績値の二乗平均平方根誤差(RMSE: Root Mean Squared Error)を確認した(表2)。電力需要のデータを用いたモデルは、いずれのモデルを用いた場合でも、製造工業生産予測調査のみに基づく従来型手法に比べて、推計精度が向上していることが分かる。この結果を踏まえ、以下ではリッジ回帰(学習期間2年)を生産指数の推計モデルとして採用する。

RMSE	説明変数Ⅰ 製造工業予測調査、 電力合計需要、各月ダミー		説明変数Ⅱ 製造工業予測調査、 PCA5ファクター、各月ダミー		説明変数Ⅲ 製造工業生産予測調査	
	学習期間 2年	学習期間 3年	学習期間 2年	学習期間 3年	学習期間 2年	学習期間 3年
	線形回帰	1.15	1.20	1.24	1.40	2.01
リッジ回帰	1.13	1.18	1.16	1.29	2.01	2.01
ラッソ回帰	1.17	1.20	1.21	1.28	2.09	2.06
エラスティックネット	1.22	1.19	1.19	1.28	2.09	2.06

表2: 各種モデルに基づく鉱工業生産指数の予測誤差比較

### 3.2 市場予想を上回る高い推計精度

表3に、リッジ回帰の説明変数の組を「モデルⅠ: 製造工業生産予測調査・各月の合計電力需要・各月のダミー変数」とした場合、及び「モデルⅡ: 製造

工業生産予測調査・第1~5主成分ファクター・各月のダミー変数」とした場合の推計結果と、鉱工業生産指数の実績値とのRMSE(前年比ベースで算出、サンプル期間は図中に掲載)を掲載した。両者ともに推計精度は良好だが、両モデルの算出値の平均(合成モデル)を予測値とした場合、推計精度に若干の改善が見られた。更に、モデルの推計精度の比較対象として、市場予測値(Bloomberg調査中央値[8])のRMSEも掲載した。これらの結果を踏まえると、市場予想値に比べて本稿提案モデルの推計精度の高さが分かるだろう。

RMSE サンプル期間	市場予想	モデルⅠ (説明変数Ⅰ)	モデルⅡ (説明変数Ⅱ)	合成モデル (モデルⅠ・Ⅱ)
2017-2019年	1.54	1.08	1.08	1.03
2015-2019年	1.54	1.12	1.16	1.10

表3: 鉱工業生産指数の推計・予測誤差比較

実際に、図9に、鉱工業生産指数の実績値と、合成モデルによる推計値、市場予想値(いずれも前年比ベース)を併せて掲載した。時期によって予測精度の優劣は異なるものの、提案モデルにより、概ね安定的な予測が達成できていることが見て取れる。また、市場予想値は概ね統計発表日の一週間前頃から公表されるが、本モデルの推計値は統計発表日の約一カ月前に算出可能となることから、先行性は非常に高い。そのため、本モデルは、速報性と予測精度の両面から、市場予想よりも優れた予測が行えていると言えよう。




図9: 鉱工業生産指数の実績値と推計値・市場予想値

## 4. 結論

本研究では、製造業が生産活動を行う際には電力が消費される点を踏まえ、大手電力会社が公表する日中の電力需要の高頻度データの変動パターンを解析することで、製造業の活動状況を高い速報性をもって推計するナウキャストモデルを構築した。具体的には、日中の電力需要の高頻度データに対して主成分分析を行うことで、電力消費の変動パターンを表す主成分ファクターを抽出し、それらを説明

変数として、製造業の生産活動を推計する正則化回帰モデルを構築した。また、製造業等の生産活動を表す公式統計としては、経済産業省が集計する鉱工業生産指数が挙げられるが、本提案手法に基づく、同指数の公表よりも一カ月程度早い製造業活動の推計が可能となった。更に、本手法に基づく生産指数の推計結果は、同指数の公表前に集計された市場予想平均値と比較して、高い予測精度が実現できることを確認した。

## 補論

本研究では線形回帰モデルに加えていくつかの正則化回帰モデルに基づく推計モデルの実装を行った。モデルの概要は以下を参照されたいが、アウトオブサンプルでの推計精度向上の為に汎化性能を意識したモデル選択を行った。

### 線形回帰

線形回帰モデルは、下式の通り目的変数 $y$ を説明変数 $x_1 \sim x_n$ の線形和で表現するモデルである。

$$y = w_0 + w_1x_1 + \dots + w_nx_n + \varepsilon \quad (\varepsilon \text{は誤差項})$$

係数 $w_0 \sim w_n$ は残差平方和 (RSS, Residual Sum of Squares) を最小化するように推計する。  $i$  番目のサンプルにおける値をそれぞれ  $y^i, x_1^i, \dots, x_n^i$  とする。

$$RSS = \sum_{i=1}^p \{y^i - (w_0 + w_1x_1^i + \dots + w_nx_n^i)\}^2$$

### リッジ回帰

通常の線形回帰では、係数 $w_0 \sim w_n$ が学習データに過剰適合した値を取ってしまう問題 (過学習) が生じる。これに対しリッジ (Ridge) 回帰では、係数 $w_0 \sim w_n$ の推計において、RSS に L2 正則化項を追加することで過学習を抑えている。具体的には下式を最小化するように $w_0 \sim w_n$ を推計する。

$$RSS + \lambda \sum_{k=1}^n w_k^2$$

正則化項である第二項は、係数 $w_0 \sim w_n$ が極端な値を取るほど増大するため、過学習を低減させることができる。  $\lambda (> 0)$  はモデルの学習時にグリッドサーチにより設定する。

### ラッソ回帰

ラッソ (Lasso) 回帰では、係数 $w_0 \sim w_n$ の推計において、RSS に L1 正則化項を追加したものを、最小化するように $w_0 \sim w_n$ を推計する。

$$RSS + \lambda \sum_{k=1}^n |w_k|$$

ラッソ回帰では、L1 正則化項の関数形の特長上、一部の説明変数のウエイト $w_k$ が0と推計されることから、学習の過程においてモデルの変数選択を同時に行うことができる。  $\lambda (> 0)$  は、モデルの学習時にグリッドサーチにより設定する。

### エラスティックネット

エラスティックネット (Elastic Net) では、係数 $w_0 \sim w_n$ の推計において、RSS に L1 と L2 の両正則化項を組み入れたものを、最小化するように $w_0 \sim w_n$ を決定する。

$$RSS + \lambda \sum_{k=1}^n [\alpha |w_k| + (1 - \alpha) w_k^2]$$

$\alpha$  の範囲は  $0 \leq \alpha \leq 1$  とし、 $\alpha = 0$  の場合はリッジ回帰、 $\alpha = 1$  の場合はラッソ回帰となることから、ラッソ回帰において一部の説明変数のウエイトが0になる特性を緩和するモデルとなっている。  $\lambda (> 0)$  は、モデルの学習時にグリッドサーチにより設定する。

## 参考文献

- [1] 水門善之, 柳井都古杜, ビジネスデータを用いた消費のナウキャスト, JCB 消費 NOW, 2019  
<https://www.jcbconsumptionnow.com/info/news-54>, (参照 2019-11-4)
- [2] 水門善之, 柳井都古杜, ビジネスデータを用いた消費のナウキャスト, 野村証券経済解析レポート, 2019
- [3] 水門善之, 福馬智生, 人工衛星の夜間光画像を用いた製造業の業種別の生産活動分析, 人工知能学会第 117 回知識ベースシステム研究会, pp.25-27, 2019
- [4] 厚生労働省, 「働き方改革」の実現に向けて,  
<https://www.mhlw.go.jp/stf/seisakunitsuite/bunya/000148322.html>, (参照 2019-11-4)
- [5] 関西電力, 過去の電力使用実績データ,  
[https://www.kepco.co.jp/energy\\_supply/supply/denkiyoho/download\\_area.html](https://www.kepco.co.jp/energy_supply/supply/denkiyoho/download_area.html), (参照 2019-11-4)
- [6] 内閣府, 平成 23 年度年次経済財政報告, 経済財政白書, 2011
- [7] 梶谷義雄, 横松宗太, 多々納裕一, 安田成, 東日本大震災後の電力供給不足に対する産業部門のレジリエンスの分析, 土木計画学研究・論文集, Vol.69, No.5, pp.181-188, 2013
- [8] Bloomberg Professional Services