

ニューラルネットワークとフーリエ変換を用いた需要予測手法の開発に関する研究

養田麻里子¹ 斉藤麻紀子¹ 鈴木了太² 岡田明¹ 掛本喜嗣¹

¹ (株) 日本総合研究所
サイエンス事業本部 情報数理グループ
{yohda.mariko, saito.makiko,
okada.akira, kakemoto.yoshitsugu}@jri.co.jp

² 一橋大学
商学部
ryota@mercury.ne.jp

Abstract

本研究は、ニューラルネットワークとフーリエ変換を用いた需要予測の方法論を提案するものである。提案する手法は需要予測を複数の周波数の組合せととらえ、製品属性や経済指標と言った客観的な指標から予測を行うものである。この手法は、過去の販売実績データを持たない新商品の需要予測を対象としている。本研究では、販売実績データを用いて数値計算を行い、提案した手法の検証を行う。

1. はじめに

近年、多くの企業でサプライチェーンマネジメントの導入が進められている。サプライチェーンマネジメントの種々の計画に用いられる情報は需要予測値であり、サプライチェーン計画全体の精度は、需要予測値に大きく依存すると言える。

一般的に、需要予測の時系列分析にはTCSI分離法、ARMAモデル等が用いられる。これらの手法は十分な出荷実績データを必要とするため、ライフサイクルの短い製品や、過去出荷実績データが十分に蓄積されていない製品、特にこれから市場に投入する新発売の製品に適用することは困難である。出荷実績データが十分に無い場合の予測手法として、過去に発売された類似製品の過去出荷実績データを用いた種々の方法があるが、これらの分析には現場の経験と勘が必要とされ、客観的な手法が確立されているとは言い難い。

以上の背景から、本研究は客観的な需要予測システムの開発を目的とし、新発売商品の需要予測手法として階層型ニューラルネットワークとフーリエ変換を適用した方法論の提案を行うものである。提案する手法では、販売実績を複数の周波数の組合せととらえ、商品特性や経済指標といった客観的な指標から、ニューラルネットワークを用いて周波数データの同定を試みる。また、需要予測を複数の周波数の組合せととらえることで周期傾向を分析し、応用することが期待できる。

2. ベースとなる理論

2. 1 ニューラルネットワーク

ニューラルネットワークは生物の脳神経回路を計算機上にモデル化した情報処理機構である。これはパターン認識、連想記憶、クラスタリング、予測、最適化などの一般的な手法として知られていて、医学、心理学から工学、経済学など幅広い分野で研究や開発が行われている。本研究では、商品属性と販売実績の複雑な関係を再現するため階層型ニューラルネットワーク^[1]を用いる。

2. 2 フーリエ変換

フーリエ変換^[2]は時系列データを分析する手法の1つで、時系列データから周波数データを取り出し、時系列データの不規則循環を分析する手法である。特に、離散データに対するフーリエ変換(Discrete Fourier transform : DFT)は自然界における様々なアナログ信号をサンプリングしてデジタル信号に置き換える手法としてよく利用される。離散フーリエ変換の計算時間を改良したアルゴリズムは高速フーリエ変換といわ

れる。本研究では、この高速フーリエ変換を用いて販売実績の時系列データから周波数データを算出し、ニューラルネットワークで学習を行う。また学習されたニューラルネットワークが算出した周波数データを時系列データに変換するため、逆離散フーリエ変換 (Inverse Discrete Fourier transform : IDFT) を用いる。

3. モデルの定義

本章では、我々が提案する手法の全体的なプロセスを、図1を用いて解説する。

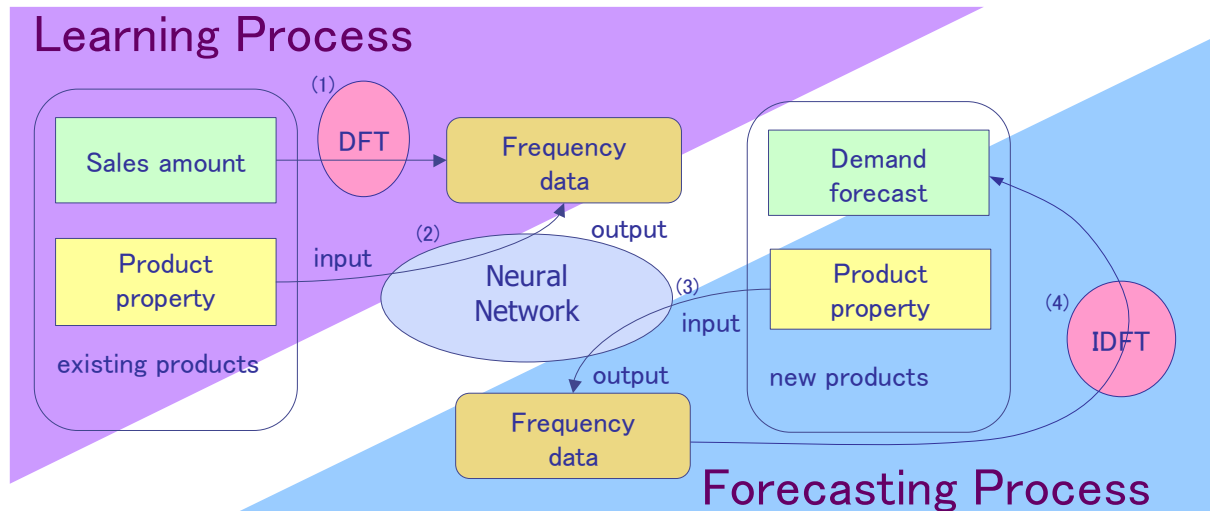


図1. プロセス全体図

1 つ目のプロセスを「学習プロセス」と呼び、現存商品のデータを使ってニューラルネットワークの学習を行う。またこのプロセスは最初のステップとして DFT を含む。次にニューラルネットワークと IDFT を用いて将来需要の予測を行う。このプロセスを「予測プロセス」と呼ぶ。

各プロセスの詳細を解説する。学習プロセスでは、現存商品の販売実績データと商品属性データを用いて学習を行う。まず、最初のステップとして、図中 (1) にある通り販売実績データを DFT で周波数データに変換する。次に、(2) の階層型ニューラルネットワークを構築し学習を行う。ネットワークの各入力ユニットは商品属性データに対応し、出力ユニットは周波数データに対応する。つまり、ニューラルネットワークは商品属性データを入力して、各周波数データを予測できるように学習されるのである。

次に予測プロセスを解説する。このプロセスでは新製品の商品属性データを入力データとして用いる。

(3) で商品属性データをニューラルネットワークに与え、周波数データを得る。そして (4) で IDFT を実行し需要予測データを得る。このプロセスは同時に、ニューラルネットワークの学習の検証プロセスと捉えることもできる。

4. 数値計算

実データを用いて数値計算を行い、提案したモデルの評価と検証を行った。対象としたのは新発売の製品で、販売量の説明変数と考えられる発売後 52 週間の販売量の予測を試みた。

入力データは商品属性のうち、特に客観性が高いと思われる 36 項目を使用した。(表 1) ニューラルネットワークの出力データは、発売後 52 週間の販売量に DFT を実行して得た周波数データとした。数値計算に用いたサンプル数は 41 品目で、うち 28 品目を学習に、13 品目を検証にそれぞれ用いた。

使用したニューラルネットワークは 3 層からなる階層型ニューラルネットワークで、学習則は誤差逆伝播法である。入力層は 36 ユニット、中間層は 62 ユニット、出力層は 53 ユニットとした。

また今回、さまざまな角度から手法の有用性を検証するため、予測の評価指標として下記の 3 つを設定した。

表 1. 入力データ

1	Shipment beginning year
2	Shipment beginning month
3	Shipment beginning day
4	beginning
5	Standard price
6	This company stock prices of one month before on the market
7	market
8	Weight
9	Size(W)
10	Size(D)
11	Size(H)
12	Best-before date
13	Amount of content
14	Wrapping Form
15	Ecological wrapping
:	:
:	:
30	Age of target
31	Sex of target
32	Number of similar products at competitors
33	Belonging brand
34	Unit of delivery
35	Advanced level
36	On display

1. モデルの MAPE (平均絶対誤差率)

$$MAPE = \frac{1}{P * W} \sum_{w=1}^W \sum_{p=1}^P \frac{|\hat{O}_{p,w} - O_{p,w}|}{O_{p,w}}$$

2. 週ごとの MAPE

$$MAPE(w) = \frac{1}{P} \sum_{p=1}^P \frac{|\hat{O}_{p,w} - O_{p,w}|}{O_{p,w}}$$

3. 製品ごとの MAPE

$$MAPE(p) = \frac{1}{W} \sum_{w=1}^W \frac{|\hat{O}_{p,w} - O_{p,w}|}{O_{p,w}}$$

$O_{p,w}$: w 週の製品 p の販売実績値

$\hat{O}_{p,w}$: w 週の製品 p の販売予測値

前述のデータとニューラルネットワークを用いて、表 2 の設定で学習を行った。学習誤差の推移を図 2 に示す。学習直後は振動があるものの、徐々に学習が収束していることがわかる。本研究では今回提案した手法の他に、同じ入力データからニューラルネットワークを用いて直接販売量の推定を行うことも試みた。前者を Case1、後者を Case2 としてこれらの評価指標から 2 つのケースの比較と検証を行う。

表 2. ニューラルネットワークの設定

Units of Input Layer	36
Units of Hidden Layer	62
Units of Output Layer	53
Learning coefficient	0.3
Inertia coefficient	0.9
Slope of Sigmoid function	1
Allowance Error	2.00E-06




図 2. 学習誤差の推移

まず、表 3 は評価指標 1 である。これは計画期間中の平均誤差率を示している。この表から Case1 の方が、誤差が少ないことがわかる。次に、週ごとにみた誤差率を図 3 に示す。全体的に Case1 の方が誤差率が低くなっていることがわかる。また Case2 に比べて Case1 では予測を大きく外すことが少ない。しかし、予測でもっとも難しいといわれる販売直後の誤差率は Case2 の方が低く、Case1 に比べて良い結果であるといえる。次に、検証に用いた製品ごとの誤差率を図 4 に示す。この図から Case1 の方が良い結果を得ている個数が多いことがわかる。以上のことから全体的に評価して、Case1 の方が良い結果であるといえる。

表 3. モデルの MAPE

Case	MAPE(%)
1	92.3
2	117.5

次に、ニューラルネットワークの出力値を、IDFTを用いて販売予測値に変換した結果の比較を行う。サンプルとして検証に用いた13個の製品のうち、もっとも精度の良かった製品8と、もっとも精度の悪かった製品9を提示する。まず図4の製品8では、Case1の誤差率が11.4%で、Case2の誤差率が33.1%であった。この図からCase1もCase2のどちらも、予測値は実績値のトレンドを追従できていることが確認できる。また、売り上げのボリュームもほぼ推定できており、この結果は十分実用可能な結果といえる。次に製品9の結果を図5に示す。製品9の誤差率はCase1が332.9%、Case2が445.8%であった。この結果はトレンドもボリュームも予測を大きく外している。特に30週目と33週目付近でキャンペーンが行われたと思われるが、それについての推定が全くできていない。これらの原因として、製品9と同じようにキャンペーンを行う製品のデータが含まれておらず、学習が十分でなかったことが考えられる。

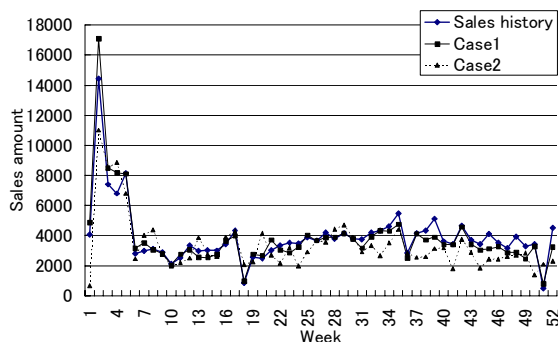


図5. 製品8の予測結果

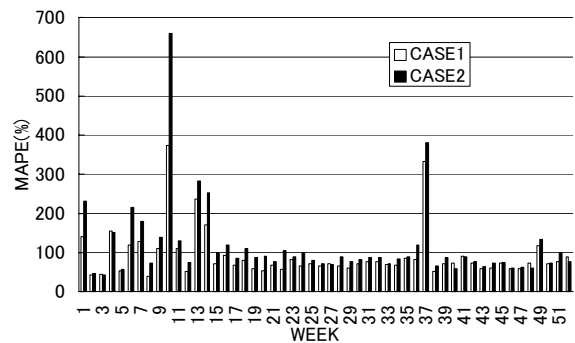


図3. 週ごとのMAPE




図4. 製品ごとのMAPE




図6. 製品9の予測結果

以上の結果から、今回提案した手法の方が、通常のニューラルネットワークを用いて直接販売量を予測するより優れていたと結論できる。しかし、発売直後の販売量を精度良く予測することができなかった。また、キャンペーンについても十分学習することもできなかった。

5. 考察

本研究で、我々はニューラルネットワークと離散フーリエ変換を用いた需要予測モデルを定義した。そして実際の販売実績データを用いてこのモデルの評価を行い、効果的な結果を得ることができた。今後の課題として、今回、販売実績を十分再現できなかったキャンペーンと、発売直後の予測を行うため、学習データの数を増やして検証を再度試みる必要がある。また、上記に有効な周波数データを取り出すためにフィルターの適用を検討したい。

参考文献

- [1] Terrence L. Fine, “Feedforward Neural Networks Methodology”, Springer, 1999
- [2] A. C. Harvey, “Time Series Analysis”, Philip Allan Publishers Limited, Oxford, 1981