Vol.2019-MPS-125 No.4
2019/9/25

海運経済時系列予測における浸透学習法の学習方法に関する研究

淵上 淳子 [1,2,a)]　高石 一樹 [1]　長尾 智晴 [1]

概要：日本は，原料やエネルギーなどの資源についてほぼ 100%を輸入に頼っており，その貿易量の 99.6%を担う外航海運は，日本の経済や国民生活にとって必要不可欠な産業インフラおよびライフラインとして重要な役割を果たしている．外航海運は世界単一市場のため，熾烈な国際競争は不可避であることから，各社では他社に先んじて対応するべく，海運経済の将来予測への期待が高まっている．一方で，海運のみならず経済時系列予測の既存研究は，過去の観測点のみを使用して将来を予測するため，不確実性の高い将来の変動を精度高く予測することが困難であるという課題がある．本論文では，学習時において未来の観測点を使用する浸透学習法を用いて，浸透の学習方法に関する改善を行い，浸透学習を用いることで従来手法と比較して同等以上の精度が得られることを確認した．

キーワード：ニューラルネットワーク，時系列予測，浸透学習，海運経済，海運市況

A training method of percolative learning model for the shipping market prediction

JUNKO FUCHIKAMI[1,2,a)]　KAZUKI TAKAISHI[1]
TOMOHARU NAGAO[1]

Abstract: Japan depends on imports for almost all resources such as raw materials and energy. In this respect, as an industrial infrastructure and lifeline, oceangoing shipping which support 99.6% of seaborne trade (quantity-wise) is indispensable for Japanese economy and their life. Since the shipping industry is in a single world market, an intense international competition is inevitable. And so, to act in advance of competitors, every companies expect the tool to predict the future of the shipping market. On the other hand, it can be said not only for shipping that the existing research on time series forecasting on economics uses only past observation points, and it is difficult to predict future fluctuations more accurately. In this paper, we propose a training method of percolative learning model. We apply this method to test problems of predicting future shipping market. The results indicate that the proposed method is more accurate and effective than the conventional method.

Keywords: neural network, time-series predictions, percolative learning, maritime economics, shipping market

1. はじめに

日本は，経済活動を支えるために必要な原料やエネルギー資源のほぼ 100%を海外からの輸入に依存しており，その貿易量の 99.6%を担う外航海運は日本経済にとって不可欠な産業インフラとして重要な役割を果たしている．日本のみならず，外航海運は世界の経済発展に不可欠であり，海上輸送量や船腹量（船の輸送力）は増加傾向にある．日本商船隊（日本の船会社が運航する船）は世界の船腹量の約１割を占め世界に貢献しており，さらには日本の経済的安全を保障するために，日本商船隊を適切に整備し規模を維持していくことが極めて重要となる．

1 横浜国立大学大学院環境情報学府
Graduate School of Environment and Information Sciences, Yokohama National University, Yokohama, Kanagawa 240-8501, Japan
2 商船三井システムズ(株)
MOL Information Systems, Ltd., Minato, Tokyo 105-8688, Japan
a) junko-fuchikami-nr@ynu.jp

ⓒ2019 Information Processing Society of Japan

一方で，外航海運業の産業特性として，世界単一市場で事業を行うことが挙げられる．海運自由の原則により，基本的には参入障壁は存在しない．したがって，世界の荷動きが活発になれば運賃・傭船料は高騰し，荷動きが停滞・減少すれば運賃・傭船料は下落するというように市況が変動する．こうした状況下で，安定輸送を持続させるためには，市況変動に対する先見性が求められるため，海運市況の予測は実務家と研究者の双方から注目を集めている．

海運市況は季節性，高ボラティリティ，資本集約性などの特性を備えており，その変動要因は多く複雑である．ここ数十年間，ARIMA に代表される時系列分析手法および統計手法が海運市況予測に使用されてきた．例えば，文献[1]では海運市況の現物と先物の運賃予測に統計手法を用いて，先物価格が現物価格の将来予測に役立つことを示した．文献[2]はドライバルク船の市況分析において，変動の特性は船型やトレードといった船舶の大きさや積荷の種類に依存することを確認した．ただし，文献[3]で述べられている通り，従来の計量経済学的手法では海運市況に隠された非線形特性を把握することは非常に困難な問題である．

この点において，ニューラルネットワーク（NN）は非線形特性を有する問題に適した手法として広く利用されている．海運市況の予測についても同様に，文献[4]では NN に基づく予測モデルが提案され，ドライバルク船のの運賃変動予測へ適用されている．海運市況以外の分野でも，文献[5][6]にて非線形特性を有する時系列予測問題への NN の適用が試みられている．しかしながら，いずれの手法も過去のデータを入力するという点で従来の統計的手法と大きく差異を生み出すことはできていない．

そこで本稿では，テスト時には使用できない未来のデータを使用する浸透学習法[7][8][9]を用いて，海運市況の代表的な指標であるバルチック海運指数の 1 週間後における変動値を予測対象とし，自己系列および関連系列を入力とした予測手法を提案する．2 章で基本方式となる浸透学習法の処理の概要を示し，3 章で提案手法として基本方式からの改良内容に関する処理の詳細を示し，4 章で提案手法の有効性を確認するために行った実験結果について述べ，5 章で研究成果のまとめと今後の課題を示す．

2. 浸透学習法

浸透学習法では 2 種類のデータを使用する．1 つは学習時およびテスト時の双方で利用可能なデータで主データ（Main data）と呼ぶ．もう 1 つは，学習時のみに使用できるデータで補助データ（Auxiliary data）と呼ぶ．経済時系列予測において，現時刻を t ，予測したい時刻を $t + d$ $(d>0)$ と定義した際，学習データは過去一定期間にわたって蓄積されるため，$t + 1$ 以降であっても学習に使用することができる．しかしながら，テスト時においては $t + 1$ 以降のデータは取得不可能であるため，予測に使用することはできない．本手法では，t 以前の過去のデータを主データ，$t + 1$ 以降のデータを補助データとみなし，予測モデルの学習を行う．補助データに未来のデータを入力することで，時系列において双方向からの予測が期待できる．

2.1 基本モデル構造

浸透学習法の基本的なモデル構造を図 1 に示す．モデルは大きく 3 つのネットワークから構成され，それぞれ Aux, Main，Integrated ネットワークと呼ぶ．3 つのネットワークは全て全結合の NN となっている．

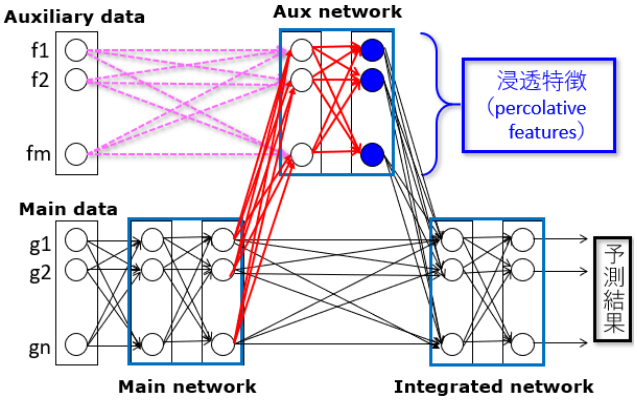

図 1　浸透学習法の基本モデル構造

Figure 1　Basic model structure of percolative learning

2.2 学習方法

学習は事前学習と浸透学習の 2 段階に分けられる．

(1) 事前学習

事前学習フェーズでは，主データと補助データの双方を用い，実際の予測日の変動値を教師データとしてモデルの訓練を行う．訓練誤差が十分に小さくなったところで事前学習フェーズは終了となる．このとき，主データと補助データから表現された共通の特徴（図 1 の青いノードの箇所）を得る．これを浸透特徴（Percolative features）と呼ぶ．

(2) 浸透学習

浸透学習フェーズでは，補助データを入力とするネットワーク（図 1 の桃色破線）からの信号を 1 epoch 毎に減衰させながら，浸透特徴を教師データとしてモデルの訓練を行う．このとき，Main ネットワークの結合荷重は固定したままとし，Main ネットワークの最終層から Aux ネットワークの結合荷重のみ（図 1 の赤色実線）を更新していく．

ここで，1 epoch 毎に補助データの入力を制御するため，2 つのパラメータを導入する．1 つは浸透率（percolating rate）であり α $(0.0 \leqq \alpha \leqq 1.0)$ とする．1 epoch 毎に補助データ X_{aux} は要素毎に α 倍され αX_{aux} となる．もう 1 つは減衰率（decay rate）であり λ とする．浸透学習時には，浸透率の初期値を $\alpha = 1.0$ としてモデルの訓練を開始し，epoch t における浸透率 α を式(1)に従い更新する．

$$\alpha = (1 - \lambda)^{t} \tag{1}$$

減衰率に大きな値を使用すると，急激に浸透率が下がるため，補助データからの入力が 0 に収束したときに主データのみから浸透特徴を再現するのが難しくなる．そこで，減衰率は経験的に小さな値（基本モデルでは λ=0.005）をあらかじめ与えておく．これにより，補助データからの入力信号は指数関数的に減衰し 0 に漸近していく．浸透学習時の訓練誤差は浸透特徴と Main および Aux ネットワークからの出力との平均二乗誤差（MSE）とし，式(2)に定義する．

$$E_p = \frac{1}{n}\sum_{i=1}^{n} ||\Phi_{aux}(\Phi_{main}(X_{main}\,;\,\theta_{main}) + \alpha X_{aux};\,\theta_{aux}) - h_i||_2^2 \quad (2)$$

Main および Aux ネットワークを Φ_{main} および Φ_{aux} とし，各ネットワークのパラメータを θ_{main} および θ_{aux} とし，主データおよび補助データを X_{main} および X_{aux} とし，α を浸透率，h_i を浸透特徴，n をミニバッチサイズとすると，訓練誤差 E_p は式(2)で表される．

2.3 浸透学習法の時系列予測問題への適用

浸透学習法を初めて時系列予測問題へ適用したのは文献[8]である．時系列予測問題に適用する場合，主データは過去のデータ，補助データは未来のデータを用いるため，主データと補助データ間の相関関係が大きくなる．このような場合に図 1 の基本モデル構造を用いると，事前学習において補助データに強く依存するネットワークになり，浸透学習がうまく進まない課題がある．そこで，文献[8]では，基本モデルを改良した図 2 のモデル構造を提案している．基本モデルとの差異は，Aux ネットワークが Aux pre と Aux sub の 2 つに分かれ，計 4 つのネットワークから構成される点と，事前学習が 2 段階に分かれる点であり，浸透学習フェーズは基本モデルと同様の学習方法を用いている．

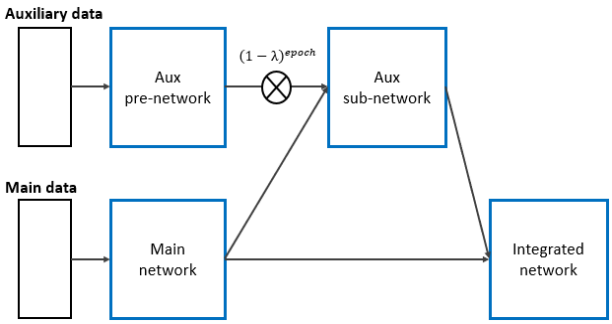

図 2　浸透学習法を時系列問題に適用したモデル
Figure 2　Percolative learning model for time-series predictions

事前学習はステージ 1 とステージ 2 に分けられる．ステージ 1 では，主データのみを用いて実際の予測日の変動値を教師データとしてモデルの訓練を行う．このとき，Main，Aux sub，Integrated の 3 つのネットワークの結合荷重（図 3 の赤色破線）のみを更新する．訓練誤差が十分に小さくなったところでステージ 2 に移る．ステージ 2 では主データと補助データを用いてモデルの訓練を行う．このとき，Aux pre，Main の最終層から Aux sub および Integrated ネットワークの結合荷重のみ（図 4 の赤色破線）を更新する．訓練誤差が十分に小さくなったところで事前学習を終了する．

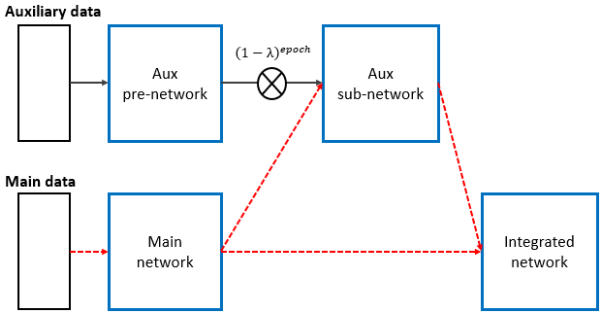

図 3　事前学習（ステージ 1）方法
Figure 3　Pre-training process (Stage I)

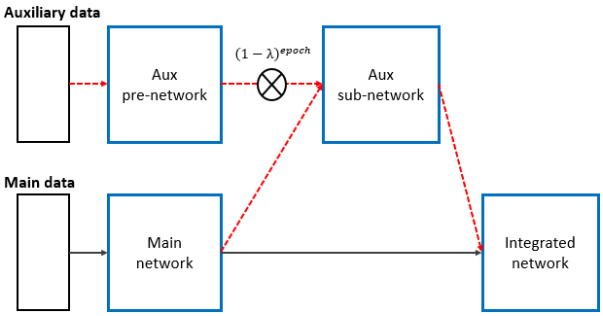

図 4　事前学習（ステージ 2）方法
Figure 4　Pre-training process (Stage II)

事前学習のステージ 1 とステージ 2 を終了した後に，浸透学習を行う．浸透学習フェーズでは，基本モデルと同様に補助データを入力とする Aux pre ネットワークからの信号を 1 epoch 毎に減衰させながら（図 5 の桃色破線），浸透特徴を教師データとしてモデルの訓練を行う．このとき，Main ネットワークの結合荷重は固定したままとし，Main ネットワークの最終層から Aux ネットワークの結合荷重のみ（図 5 の赤色実線）を更新していく．

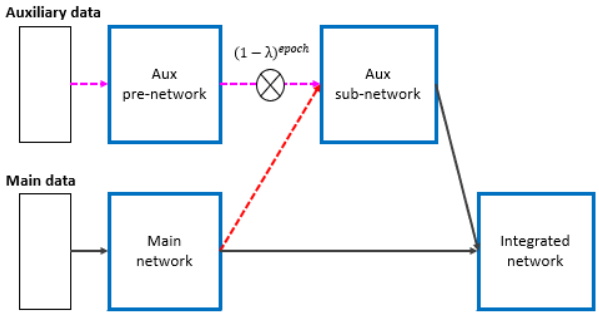

図 5　浸透学習方法
Figure 5　Percolative learning process

3. 提案手法

これまでの研究において，浸透学習法は時系列予測問題に対しても有効であることが確認されたが，浸透学習の方

ⓒ2019 Information Processing Society of Japan

法については十分に研究がなされていない．そこで，本章では浸透学習の改良方法を提案する．

3.1 提案手法 1（減衰方法の改良）

基本モデルの減衰方法は，Aux pre ネットワークからの出力に対して一様に浸透率を乗算する方法である．ところが，補助データの中には主データからの再現性が高いデータと低いデータが混在していると考えられるため，一様に減衰した入力信号と主データとでは，浸透特徴を再現することが難しいと考えられる．そこで，補助データに少しずつ 0 を埋めていく Zero padding 法を提案する．

浸透率 α と減衰率 λ にくわえて，補助データ X_{aux} と同じ次元で且つ要素が 0 または 1 からなる Padding データ P_{aux} を用意する．このとき，P_{aux} は全要素数に対する 1 の要素数の割合が浸透率と一致するように 0 と 1 を含むものとし，且つ 0 と 1 の分布はランダムとする．1 epoch 毎に補助データ X_{aux} を $X_{aux} \odot P_{aux}$（⊙はアダマール積）として，Aux pre ネットワークの入力とする（図 6 の橙色矩形）．浸透学習時には，浸透率の初期値を α =1.0，つまり P_{aux} はすべての要素が 1 の状態からモデルの訓練を開始し，epoch t における浸透率 α を式(3)に従い更新する．

$$\alpha = 1 - \lambda t \tag{3}$$

減衰率に大きな値を使用すると，急激に浸透率が下がるため，補助データの全要素が 0 となったときに主データのみから浸透特徴を再現することが難しくなる．そこで，減衰率は実験的に小さな値をあらかじめ与えておく．これにより，補助データの入力信号は線形に減衰し 0 となる．

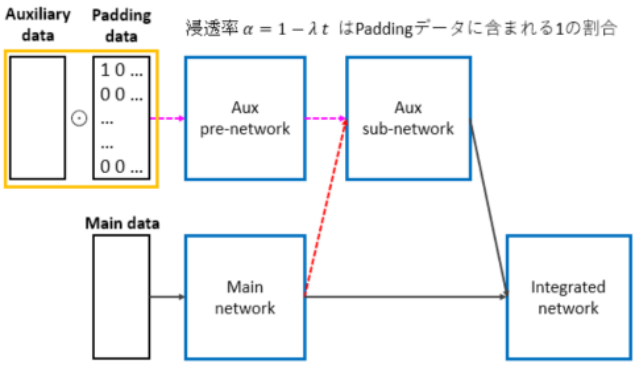

図 6　提案手法 1 の浸透学習モデル

Figure 6　Percolative learning model of proposal method 1

3.2 提案手法 2（事前学習の改良）

基本モデルの事前学習は，補助データのみを用いて Aux pre ネットワークの荷重を更新している．そのため，浸透学習フェーズにおいて，Aux pre ネットワークからの出力が減衰し失われていく分を Main ネットワークからの出力だけで補い浸透特徴を再現するのは難しいと考えられる．そこで，事前学習においても主データを入力に用いる学習方法を提案する．事前学習のステージ 1 とステージ 2 および浸透学習の方法を，図 7，図 8，図 9 に示す．

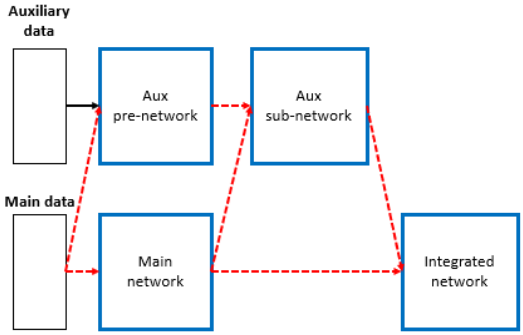

図 7　提案手法 2 の事前学習（ステージ 1）方法

Figure 7　Pre-training process (Stage I) of proposal method 2

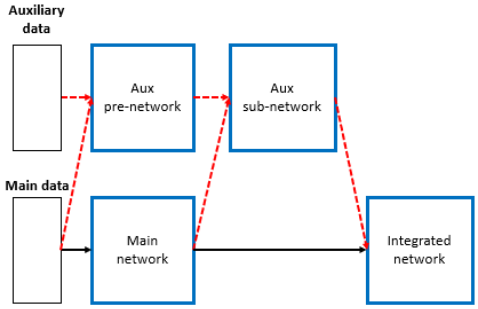

図 8　提案手法 2 の事前学習（ステージ 2）方法

Figure 8　Pre-training process (Stage II) of proposal method 2

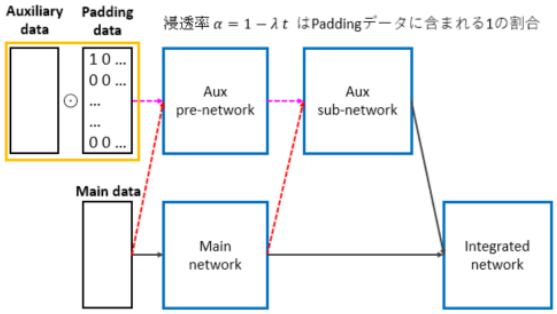

図 9　提案手法 2 の浸透学習方法

Figure 9　Percolative learning process of proposal method 2

3.3 提案手法 3（浸透学習後の追加学習）

浸透学習において期待されるのは，浸透特徴を教師データとしてモデルを訓練することにより，補助データから得られる特徴を主データのみで再現することである．ここで，浸透学習時に Main ネットワークを固定させていた意味は，浸透特徴が再現されると期待したことにある．完全に再現できれば，固定していた Main ネットワークからの出力と再現された浸透特徴を Integrated ネットワークに入力することで良い結果が得られるはずだが，実際には NN は万能ではないため，浸透特徴との訓練誤差は 0 にはならない．そこで，浸透学習後の追加学習を提案する．

追加学習では実際の予測日の変動値を教師データとして，モデルの訓練を行う．このとき Integrated ネットワークの結

ⓒ2019 Information Processing Society of Japan

合荷重のみを更新対象とする．Integrated ネットワークが複数層ある場合，最終層のみを対象とするかすべてを対象とするかは実験的に判断する．また，追加訓練前に結合荷重を初期化するか否かについても実験的に判断する．

4. 海運経済時系列予測の実験

本章では，提案手法 1,2,3 を海運経済時系列予測に用いた実験を行う．また，得られた結果と従来手法による結果を比較し考察を行う．問題設定としては，海運市況の代表的な指標であるバルチック海運指数の 1 週間後における変動値を予測対象とする．使用するデータは，自己系列および関連系列 3 つの計 4 系列とし，提案手法 1,2,3 を適用した実験を行う．実験に用いたデータセットは表 1 の通りである．

表 1　実験に用いたデータセット
Table 1　Maritime index data used for the experiment

	学習	テスト
期間	2010/3/29～2016/10/6	2016/10/7～2017/6/7
件数	1,650 件	167 件

主データと補助データおよび教師データの詳細は表 2，ネットワーク構造は表 3 の通りとした．なお，ネットワーク構造は 2.3 で紹介した文献[8]をもとに，Main ネットワークを 5 層から 3 層に圧縮し第 1 層のノード数を 160 に拡張して，表現力を増やすとともに計算コストを削減した．

表 2　データの詳細
Table 2　Description of each data

データ	詳細
主データ	4 系列の過去 20 日分のデータ（80 ノード）
補助データ	4 系列の翌日以降 10 日分の 5 日移動平均のデータ（40 ノード）
教師データ	自己系列の 1 週間後の変動値

表 3　ネットワーク構造
Table 3　Structure of neural network

ネットワーク	構造
Main network	3 層（160→80→80）の全結合 NN
Aux pre-network	2 層（37→79）の全結合 NN
Aux sub-network	3 層（70→21→133）の全結合 NN
Integrated network	2 層（20→39）の全結合 NN

NN の学習における最適化手法には Adam[10]を，活性化関数には tanh を使用し最終層のみ線形和とする．重みとバイアスの初期値は文献[11]に従い，第一層の重みとバイアスのみ経験的に初期値を e（Napier's constant）倍した．バッチサイズは 100 とし，epoch は事前学習（ステージ 1）を 300，事前学習（ステージ 2）を 400，浸透学習を 5,000 とし，追加学習を 800 とした．損失関数は教師データとネットワークからの出力との平均二乗誤差（MSE）を用いる．評価は MSE と方向的中率で行う．

比較手法として，比較 1 を当日変動率（前日から当日が上昇/下落した場合は 1 週間後も上昇/下落と予想した場合の精度）とし，比較 2 をシンプルな NN（図 3 の事前学習のステージ 1 のみの結果）とし，比較 3 を 2.3 で紹介した基本の浸透学習法とする．各実験結果は表 4,5,6 の通りである．

比較手法と提案手法 1 および 2 の結果を表 4 に示す．この結果から，提案手法 1 の減衰方法は精度向上に効果があることが確認できた．さらに，提案手法 2 の主データを用いた事前学習についても，Aux pre ネットワークに主データの特徴が含まれることで，補助データ減衰時の精度低下を防ぐことができたものと考えられる．

表 4　提案手法 1,2 の実験結果
Table 4　Accuracy results of proposal method 1 and 2

手法	方向的中率	MSE
比較 1（当日変動率）	63.34%	0.293
比較 2（NN）	66.46%	0.152
比較 3（基本の浸透学習）	69.46%	0.143
提案 1（λ=0.001）	70.06%	0.140
提案 1（λ=0.005）	71.26%	**0.139**
提案 1（λ=0.01）	70.66%	0.141
提案 2（λ=0.001）	71.26%	0.144
提案 2（λ=0.005）	**73.06%**	0.142
提案 2（λ＝0.01）	70.06%	0.142

提案手法 3 の実験結果を表 5,6 に示す．この結果から，提案手法 3 の追加学習は，比較手法 3 に対しては効果があることが確認できたが，提案手法 1 または 2 に対しては追加学習をしても効果が得られないことが確認できた．これは，提案手法 1,2 ではある程度の浸透特徴再現ができているため追加学習で精度向上の効果が得られなかったと考えられる．また，比較手法 3 に対して追加学習は有効な手段であることが確認できたものの，提案手法 2 を上回ることはできなかった．さらに，追加学習で更新するノードと荷重およびバイアスの初期化有無については表 6 を参照されたい．最終層のみを対象とするよりも，より多くの情報を持つ Integrated ネットワーク全体を対象として追加学習した方が良い結果を得られることが確認できた．また，興味深い点として，最終層の重みとバイアスを初期化した方が良い結果が得られた．これは，誤った荷重から更新するよりも初期化した状態から更新する方が，より効率的に学習が進むためと考えられる．

ⓒ2019 Information Processing Society of Japan

表 5　提案手法 3 の実験結果
Table 5　Accuracy results of proposal method 3

手法	結果
比較 3 と提案 3	効果あり　69.46%→71.66% （方向的中率が **2.2%改善**）
提案 1 と提案 3	効果なし
提案 2 と提案 3	効果なし

表 6　提案手法 3 のチューニング結果
Table 6　Performance comparison of proposal method 3

比較 3＋提案 3 のチューニング方法	初期化する	初期化しない	最終層のみ初期化する
最終層のみ追加学習	+1.67%	-0.6%	－
Integrated ネットワーク全体を追加学習	+0.4%	-0.6%	**+2.2%**

最後に，提案 2（λ=0.005）における各段階の浸透特徴を可視化したものを図 10 に示す．各図は事前学習（ステージ 1），事前学習（ステージ 2）および浸透学習の各段階が終了した時点において，テストデータを入力したときの浸透特徴の値をヒートマップで可視化したものである．

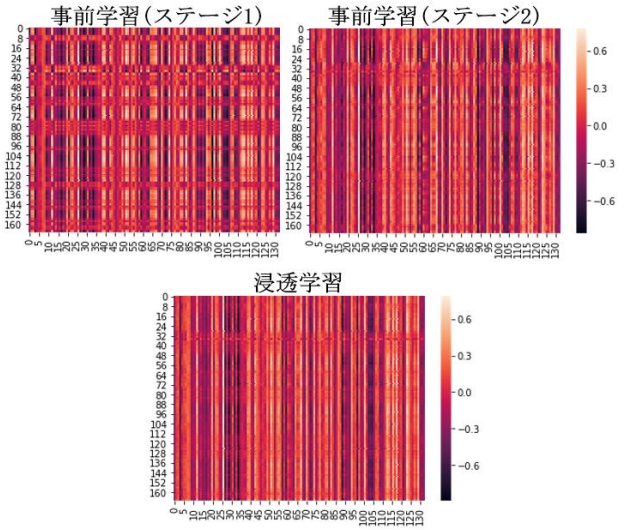

図 10　各段階における浸透特徴の可視化
Figure 10　Visualization of percolative features on each stage

事前学習（ステージ 1）は主データのみで学習した結果で，終了時点の方向的中率は 66%である．事前学習（ステージ 2）は補助データも使用して学習した結果で，終了時点の方向的中率は 98%に達する．補助データを減衰させながら主データのみで事前学習（ステージ 2）終了時点の状態を再現するのが浸透学習になるが，浸透学習後の主データのみしか使用できない状況において，浸透特徴をある程度再現できていることが視覚的にも確認できた．

5. おわりに

本稿では，海運経済時系列予測に浸透学習法を適用し，その学習方法を改良することで浸透効果を高められることを示した．特に減衰方法と事前学習方法を改良することで，精度向上を確認するとともに，視覚的にも浸透している状態を確認した．これにより，浸透学習法は時系列予測問題においても有用な方法であることを示した．実務的な観点からも，将来の変動における上昇/下降を示す方向的中率は重要な判断材料であるため，数%であっても改良されることは実務応用の観点からも価値があるといえる．

今後の課題は，さらなる精度向上のために，事前学習のステージ 2 における過学習を防ぐための学習方法や，補助データの減衰過程における急激な探索空間の変化を抑制するべく，さらに多段に主データを入力する学習方法など，引き続き検討したい．また，補助データに異なるドメインの情報で且つ精度向上に寄与すると思われる情報（例えば，予測日周辺における主要港からの貨物出荷実績など）を用いることで，精度高く且つ説明力もあるような予測モデルを検討していきたい．

参考文献

[1] Batchelor, R., Alizadeh, A. and Visvikis, I.: Forecasting spot and forward prices in the international freight market. International Journal of Forecasting, 2007, vol. 23(1), pp. 101–114.
[2] Jing, L., Malow, P.B. and Hui, W.: An analysis of freight rate volatility in dry bulk shipping markets. Maritime Policy and Management, 2008, vol. 35(3), pp. 237–251.
[3] Stopford, M.: Maritime Economics 3rd edition, 2009, p. 697.
[4] Leonov, V. and Nikolov, V.: A wavelet and neural network model for the prediction of dry bulk shipping indices. Maritime Economics & Logistics, 2012, vol. 14(3), pp. 319-333.
[5] Zhang, Y. and Wu, L.: Stock market prediction of S&P 500 via combination of improved BCO approach and BP neural network. Expert Systems with Applications, 2009, vol. 36, no. 5, pp. 8849-8854.
[6] Ding, X., Zhang, Y., Liu, T. and Duan, J.: Deep Learning for Event-Driven Stock Prediction. Proc. of the 24th International Joint Conference on Artificial Intelligence (IJCAI 2015), 2015, pp. 2327-2333.
[7] 柳元美玖，長尾智晴：学習時のみに使用可能な情報を浸透させるニューラルネット. 情報処理学会第 115 回 MPS 研究会，2017，2017 年 9 月 25 日～26 日，北海道大学.
[8] Takaishi, K., Kobayashi, M., Yanagimoto, M., and Nagao, T.: Percolative Learning: Time-Series Predictions from Future Tendencies. Proc. of 2018 IEEE International Conference on Systems, Man, and Cybernetics (SMC 2018), 2018, October 7-10, 2018, Miyazaki, Japan.
[9] 特許出願済：特願 2017-153613「ニューラルネットワークシステム、機械学習方法及びプログラム」
[10] Kingma, D.P. and Ba, J.: Adam: A Method for Stochastic Optimization. Proc. of the 3rd International Conference on Learning Representations (ICLR 2015), 2015, San Diego, USA.
[11] Glorot, X. and Bengio, Y.: Understanding the difficulty of training deep feedforward neural networks. Proc. of AISTATS, 2010, vol. 9, pp. 249–256.

ⓒ2019 Information Processing Society of Japan