

はじめに

複製・競合を考慮した動径基底関数ネットワーク

機械学習手法と動径基底関数ネットワーク

提案手法

実験結果並びに考察

おわりに

# ターミナルアトラクタを考慮した 複製・競合メカニズムによる 効率的な機械学習

Building Efficient Machine Learning  
with Reproduction and Competition Mechanisms  
Incorporating Terminal Attractor

小澤 翔太 (Shota Kozawa)  
[u120014@st.pu-toyama.ac.jp](mailto:u120014@st.pu-toyama.ac.jp)

富山県立大学情報システム工学科 4 年

## 1.1 本研究の背景

2/17

はじめに

複製・競合を考慮した動径基底関数ネットワーク

機械学習手法と動径基底関数ネットワーク

提案手法

実験結果並びに考察

おわりに

基底関数の足し合わせによって非線形関数を近似する手法に動径基底関数ネットワーク（Radial Basis Function Network: RBFN）がある。しかし、基底関数の数は学習前に把握することは困難である。そこで、環境の変化に応じて動的に基底関数の数を変化させるRBFNとして（Reproductive Competitive RBFN: RC-RBFN）が提案されている。

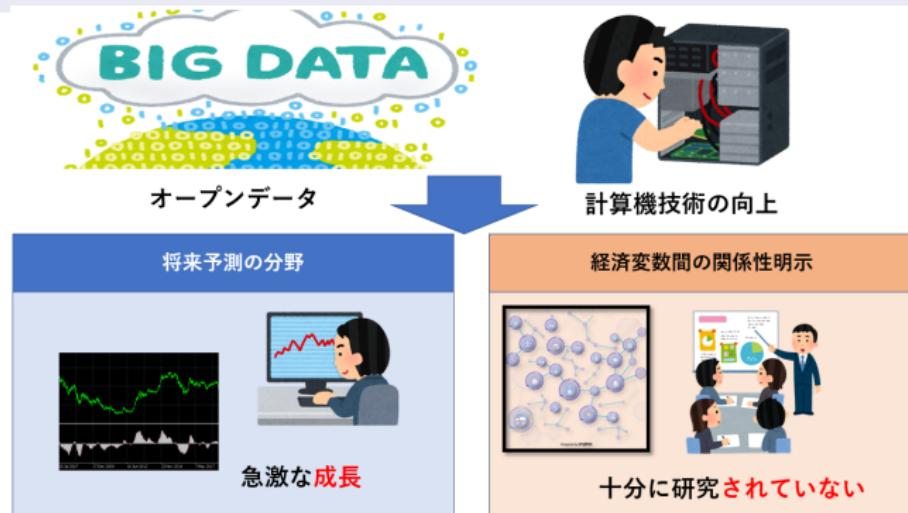


図 1. 背景

## 1.2 本研究の目的

はじめに

複製・競合を考慮した動径基底関数ネットワーク

機械学習手法と動径基底関数ネットワーク

提案手法

実験結果並びに考察

おわりに

RC-RBFN によって基底関数の数の課題は解決されたが、基底関数を複製するにあたって多重積分を行う必要があり、変数の数が多くなるにつれて計算量が膨大になってしまふ。そこで、計算量を考慮した複製方法を提案し、新しい手法でも目的関数に対して精度良く学習を行えていることを示す。

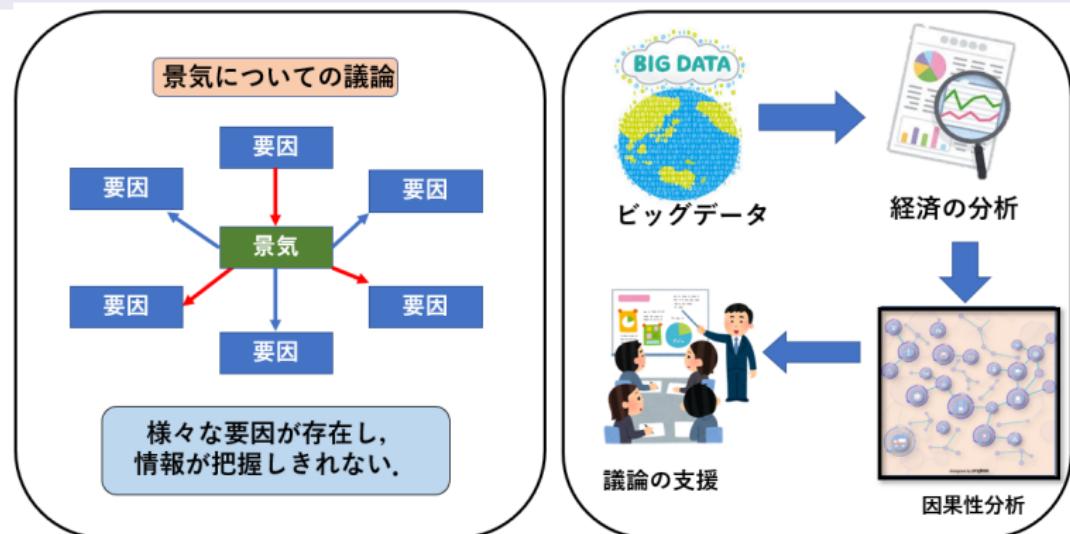


図 2 本研究の目的

## 2.1 競合を考慮した動径基底関数ネットワーク

4/17

はじめに

複製・競合を考慮した動径基底関数ネットワーク

機械学習手法と動径基底関数ネットワーク

提案手法

実験結果並びに考察

おわりに

適者生存型学習則によって学習に不要で冗長なニューロンを削除する機能を備えた RBFN として競合動径基底関数ネットワーク (Competitive RBFN: CRBFN) がある。CRBFN ではシナプス結合荷重間に競合を生じさせ、学習に必要なニューロンのみが自然に生き残り、学習の効率化を図ることができる。



## 2.2 望ましい時刻で収束できるターミナルアトラクタ

5/17

はじめに

複製・競合を考慮した動径基底関数ネットワーク

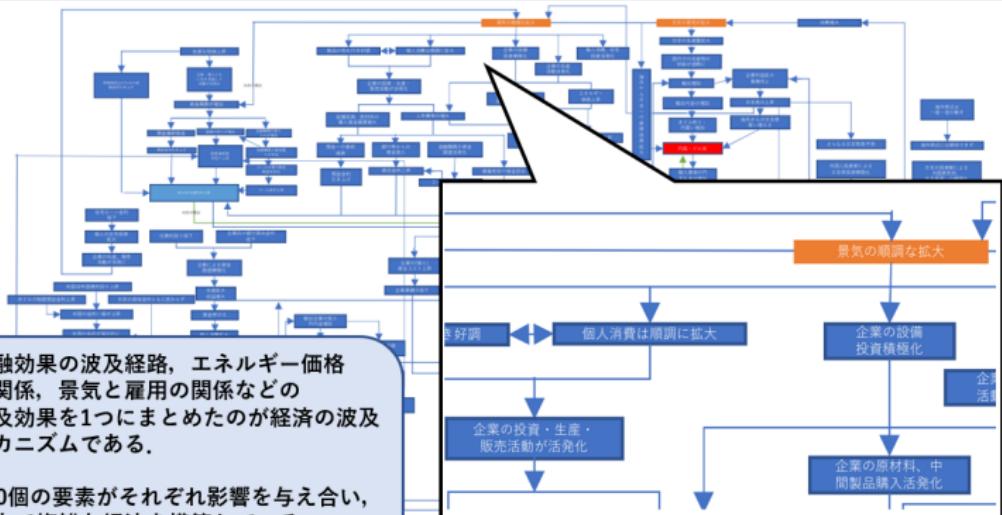
機械学習手法と動径基底関数ネットワーク

提案手法

実験結果並びに考察

おわりに

競合に負けたシナプス結合荷重の平衡解への漸近は指数関数的に行われるため、原理的には有限時間で平衡状態へ到達することができない。そこで、望ましい出力が基底関数を定数倍して足し合わせることで実現できる特別な場合に、学習時間の上限を決定できるターミナルアトラクタを導入する。



## 2.3 基底関数の複製を考慮した関数近似

6/17

はじめに

複製・競合を考慮した動径基底関数ネットワーク

機械学習手法と動径基底関数ネットワーク

提案手法

実験結果並びに考察

おわりに

先に提案された CRBFN に複製機能を組み合わせたニューラルネットワークが RC-RBFN である。この RC-RBFN は、自由エネルギー やエントロピー最大化の観点から基底関数を複製あるいは削除する能力を備えたものとなっている。

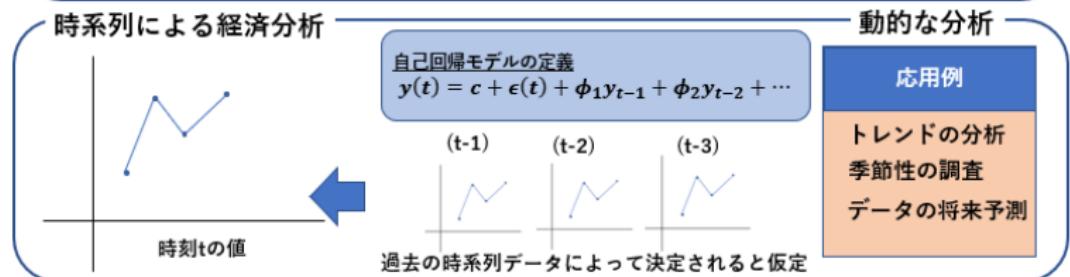
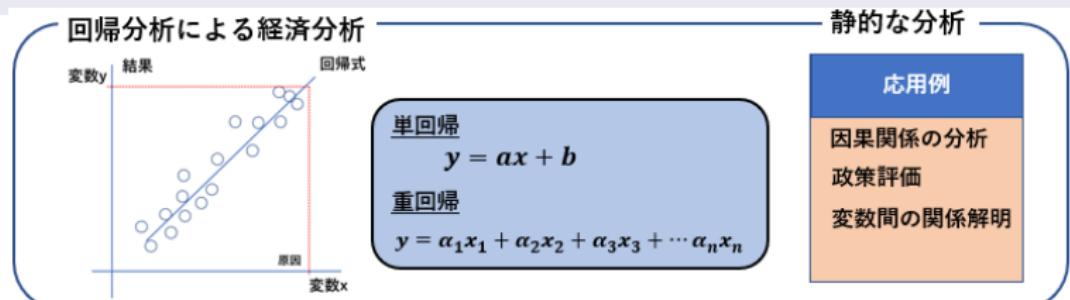


図 5: 基本的な統計的手法

## 3.1 代表的な機械学習の手法について

はじめに

複製・競合を考慮した動径基底関数ネットワーク

機械学習手法と動径基底関数ネットワーク

提案手法

実験結果並びに考察

おわりに

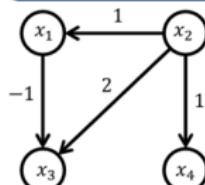
実際に RBFN を活用した研究事例について扱い、RBFN の有用性を確かめる。(画像に研究の紹介に入る)

### LiNGAM

定式化

$$x_i = \sum_{i \neq j} b_{ij} x_j + e_i \quad (i = 1, \dots, p)$$

観測値:  $x_i$   
誤差:  $e_i$   
関係値:  $b_{ij}$



$$\begin{cases} x_1 = x_2 + e_1 \\ x_2 = e_2 \\ x_3 = -x_1 + 2x_2 + e_3 \\ x_4 = x_2 + e_4 \end{cases}$$

#### LiNGAMにおける仮定

- 因果関係を線形モデルで表現する
- 変数が非ガウス性を持つ
- グラフ構造は非循環である。
- 変数が完全に観測されている。

### VARモデル

多変量時系列データ  $x_t$  に対し、自己回帰の次数が  $\tau$  の VAR モデル

定式化

$$x(t) = \sum_{\tau=1}^k B_\tau x(t-\tau) + e(t)$$

$x_{t-\tau}$ : 目的変数ベクトルのラグ  $\tau$   
 $e(t)$ : K 次元の定数ベクトル  
 $B_\tau$ : ラグ  $\tau$  の  $K \times K$  係数行列

#### VARモデルにおける仮定

- 各変数はその過去の値に依存する。
- 誤差項が多変量正規分布に従う。
- 各変数の誤差項は独立

図 6: 統計的手法による因果探索

## 3.2 マルコフ決定過程と強化学習

8/17

はじめに

複製・競合を考慮した動径基底関数ネットワーク

機械学習手法と動径基底関数ネットワーク

提案手法

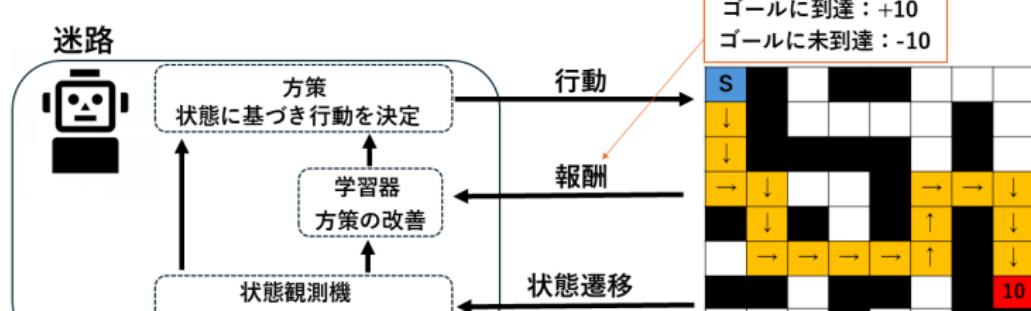
実験結果並びに考察

おわりに

強化学習とはある環境内におけるエージェントが現在の状態を観測し、得られる報酬を最大化するために、どのような行動を取るべきかを決定する機械学習の一分野である。状態空間全体に対する行動価値関数を求めるのは非現実的であるため、RBFN を用いて行動価値関数を近似する研究がある。

### ・強化学習…エージェントの行動規範を獲得

- 行動の良さを報酬で評価
- 報酬が高くなるような方策(行動規範)を試行錯誤しながら獲得
- 獲得した方策を用いてエージェントの行動を決定



### 3.3 逆強化学習の仕組み

9/17

はじめに

複製・競合を考慮した動径基底関数ネットワーク

機械学習手法と動径基底関数ネットワーク

提案手法

実験結果並びに考察

おわりに

逆強化学習は、強化学習の根本的な課題である報酬関数の設計を回避するためのアプローチとして注目されている。逆強化学習ではエキスパートのデモンストレーションデータを利用して報酬関数そのものを推定し、エージェントがその報酬関数に基づいて適切な行動を学習できるようにすることを目標とする。

#### 強化学習

所望の行動をする制御ルールを、主にシミュレーション環境下で学習させる。



シミュレーション環境、  
実ロボットなど



報酬関数

入力

#### 逆強化学習

実際の行動データを与え、報酬関数を学習させる。その後、強化学習で制御ルールを構築。



シミュレーション環境、  
実ロボットなど



実際の行動データ

入力

## 4.1 計算量を考慮した複製方法の提案

10/17

はじめに

複製・競合を考慮した動径基底関数ネットワーク

機械学習手法と動径基底関数ネットワーク

提案手法

実験結果並びに考察

おわりに

目的関数と学習結果の差を計算し、その差の局所最大値(ピーク)を検出することにより複製すべき点を導出する。○(x)は以下のように計算する。

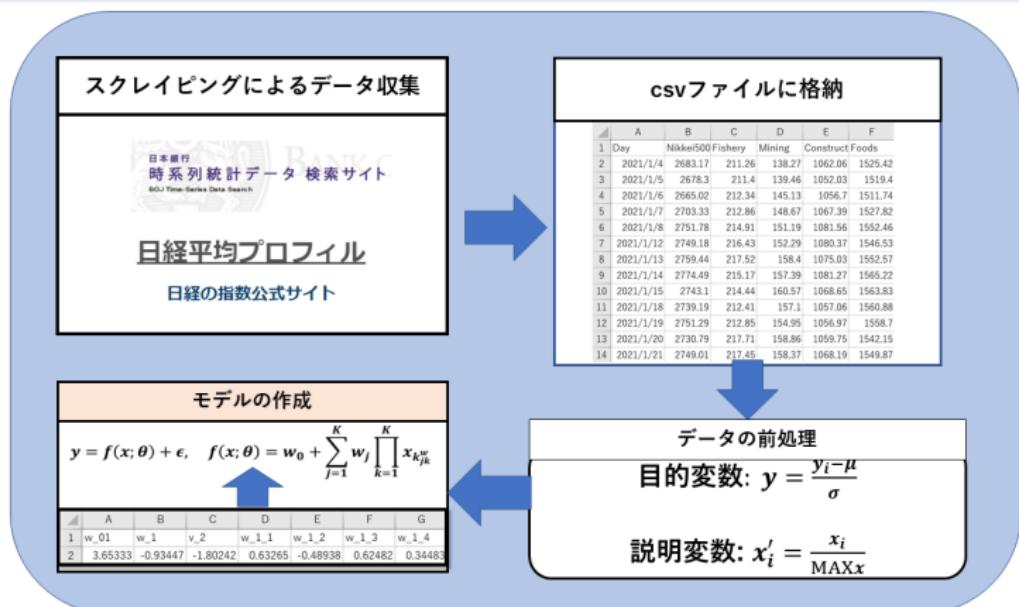


図 9: RF5 の流れ

## 4.2 機械学習への組み込みと高速化手法

11/17

はじめに

複製・競合を考慮した動径基底関数ネットワーク

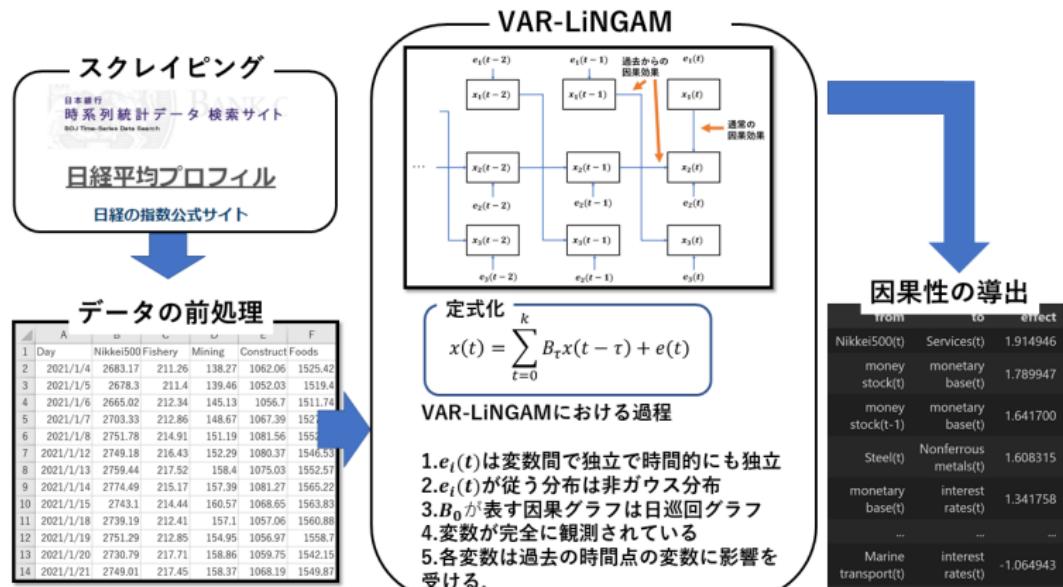
機械学習手法と動径基底関数ネットワーク

提案手法

実験結果並びに考察

おわりに

RBFNによる価値関数や報酬関数の学習を行っている先行研究+ Numbaなどの高速化手法(画像はNumbaの数値比較)



## 4.3 複製・競合を考慮した学習の流れ

12/17

はじめに

複製・競合を考慮した動径基底関数ネットワーク

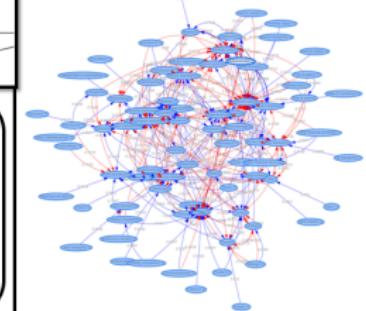
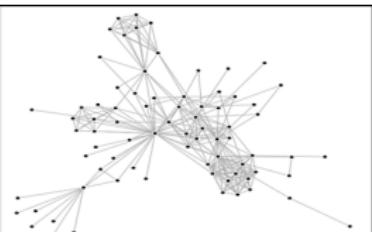
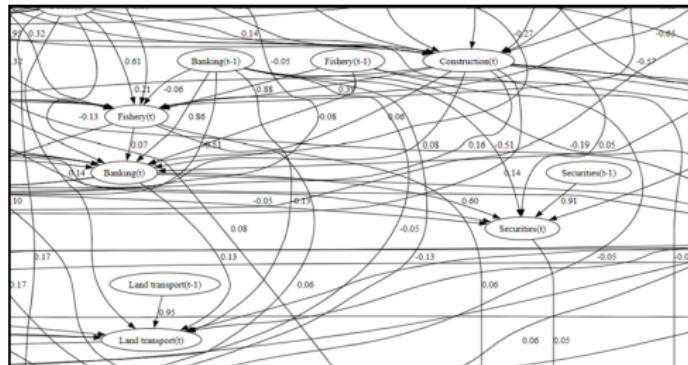
機械学習手法と動径基底関数ネットワーク

提案手法

実験結果並びに考察

おわりに

### 学習の流れ



2Dグラフによる可視化ではエッジが増えると  
スパゲッティ状になってしまい、情報が読み  
取りづらくなってしまう。  
3Dグラフによる可視化はエッジが増えた際に  
2Dグラフよりも可読性に優れている。

図 11: VAR-LiNGAM の実行結果

## 5.1 実験の概要

はじめに

複製・競合を考慮した動径基底関数ネットワーク

機械学習手法と動径基底関数ネットワーク

提案手法

実験結果並びに考察

おわりに

本研究では RC-RBFN を用いた強い非線形性を持つ Xin-She Yang 関数に対して学習を行い、学習によって得られた結果と Xin-She Yang 関数を比較し、得られた RMSE および MAE を指標としてモデルの評価を行う。

データ項目	時間足	データ項目	時間足	データ項目	時間足
水産	日	黒糞	日	金利	月
鉱業	日	鉄鋼	日	マネーストック	月
建設業	日	非鉄・金属	日	マネタリーベース	月
食品業	日	機械	日	エネルギー価格	月
繊維業	日	電気機器	日	日本物価指数(総平均)	月
パルプ・紙業	日	ガス	日		
科学業	日	自動車	日		
医薬品	日	輸送用機器	日		
石油	日	精密機器	日		
商社	日	海運	日		
小売業	日	空運	日		
銀行	日	倉庫	日		
その他金融	日	通信	日		
証券	日	電力	日		
造船	日	サービス	日		
保険	日	ゴム	日		
不動産	日	陸運	日		
鉄道・バス	日	その他製造	日		

今回は経済の波及メカニズムを参考に40個のデータを収集し、実験を行う。市場間データはすべて株価であり、単位は全て円で表記される。物価指数、金利の単位のみ%で表記される。今回は日足と月足のデータを取り扱う。月足のデータは一か月間同じ値をとり続けると仮定し、日足の形に直してデータセットに格納した。

図 12: 本実験で用いるデータ

## 5.2 実験結果と考察

1変数の場合における RNSE, MAE, 累積二乗誤差  $E(\mathbf{w})$  の学習前と学習後の比較を示す。

from	to	effect
Nikkei500(t)	Services(t)	1.914946
money stock(t)	monetary base(t)	1.789947
money stock(t-1)	monetary base(t)	1.641700
Steel(t)	Nonferrous metals(t)	1.608315
monetary base(t)	interest rates(t)	1.341758
...	...	...
Marine transport(t)	interest rates(t)	-1.064943

from	to	effect	probability
0 Transportation instruments(t-1)	Transportation instruments(t)	0.859349	0.987755
1 monetary base(t-1)	monetary base(t)	0.973287	0.985034
2 Petroleum(t-1)	Petroleum(t)	0.909080	0.983673
3 money stock(t-1)	money stock(t)	0.984165	0.982313
4 Communications(t-1)	Communications(t)	0.920379	0.982313
...	...	...	...
3316 Pharmaceuticals(t-1)	gross average(t)	-0.016641	0.300680
3317 Shipbuilding(t-1)	Retail(t)	-0.080427	0.297959
3318 Air transport(t-1)	Retail(t)	-0.050161	0.295238
3319 Air transport(t-1)	Nikkei500(t)	0.047179	0.295238
3320 Electric power(t-1)	Glass & Ceramics(t)	-0.121124	0.281633

海運業界の株価と金利には負の因果関係があると導出されている。これは一般的に知られている関係であり、正しい因果関係が導出されたと言えるだろう。

ブートストラップ法による検定結果で得られた確率を見ると、そのデータの過去のデータから得られる因果性の確率が高く、それ以外のデータから得られる因果性の確率は低くなってしまっている。

これには変数間の関係が時系列によって異なっている可能性が考えられる。

## 5.2 実験結果と考察

はじめに

複製・競合を考慮した動径基底関数ネットワーク

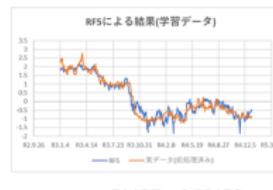
機械学習手法と動径基底関数ネットワーク

提案手法

実験結果並びに考察

おわりに

2変数の場合における RNSE, MAE, 累積二乗誤差  $E(\mathbf{w})$  の学習前と学習後の比較を示す。



学習データに対しての検証では、RF5は局所的な解を捉えられず、RMSEは重回帰の方が低くなった。

部分的に別のアルゴリズムを適用することで対処する必要がある。

テストデータに対するモデルのRMSEはRF5の方が低かった。

RF5では重回帰分析で発見することができなかった汎化性のある数法則を発見したと考えられる。

今後はルールや状況を判断し、そのときに合った手法で数法則の発見を行う必要があると考えられる。

図 14: RF の実行結果

# 6 おわりに

16/17

動画でシステムの流れをお見せします。

はじめに

複製・競合を考慮  
した動径基底関数  
ネットワーク

機械学習手法と動  
径基底関数ネット  
ワーク

提案手法

実験結果並びに  
考察

おわりに

# 6 おわりに

17/17

## まとめ

本研究では RC-RBFN の複製機能が有する計算量の課題について述べ、新たに計算量を考慮した複製方法を提案し、実際に提案手法でも非線形関数を学習可能なことを示した。

## 今後の課題

今後はさらに高次元なデータに対しても学習を行えるように、GPUによる並列化処理や複数台での分散処理などを行う必要がある。また、パラメータの学習率を動的に変化させることができるような仕組みを導入することで、学習の安定化が期待できる。

はじめに

複製・競合を考慮した動径基底関数ネットワーク

機械学習手法と動径基底関数ネットワーク

提案手法

実験結果並びに考察

おわりに