

人工知能による 水理水文の予測技術

日本工営（株）

ひとこと まさゆき
一言 正之

自己紹介

学歴・職歴

- 2005年3月 東大 学部卒業 (登坂研)
- 2007年3月 東大 修士卒業 (登坂研)
- 2007年4月 日本工営株式会社 就職
- 2016年4月 東大 論文博士取得 (登坂先生)

地下水・移流分散
実験 & 数値解析

洪水予測

日本工営 中央研究所にて勤務 (10年目)

主な業務経歴など

- 洪水予測システム開発
- 土砂災害予測システム開発
- 津波・高潮、洪水氾濫 浸水想定
など

発表概要

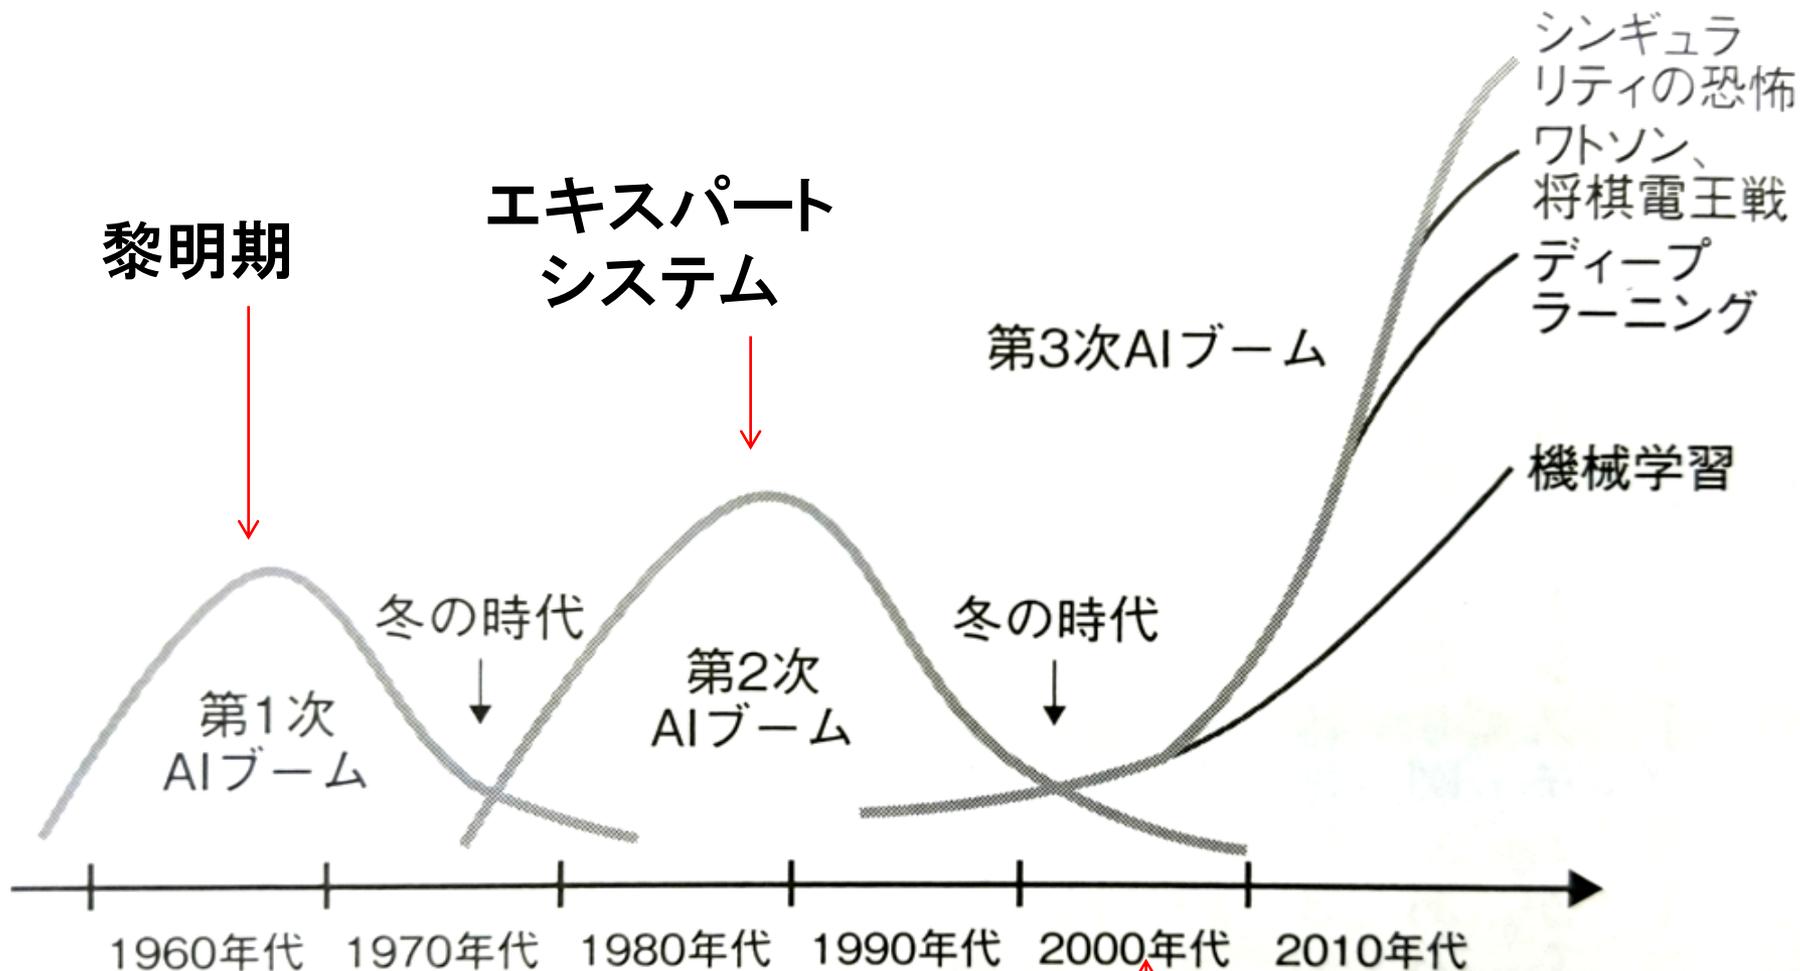
- ① 人工知能とは？
- ② 機械学習の基礎知識
- ③ ニューラルネットワーク
- ④ 洪水予測への活用例
- ⑤ 深層学習（ディープラーニング）
- ⑥ おわりに

人工知能の発展

1997年、チェス	AIがチャンピオンに勝利
2013年、将棋	AIがプロに勝利
2016年、囲碁	AIがトッププロに勝利
202X年、エンジニア？	AIにより失職？

人工知能の歴史

図の出典：松尾豊，『人工知能は人間を超えるか ディープラーニングの先にあるもの』，角川EPUB選書，2015



インターネット、ビッグデータ
計算機のパワーアップ

人工知能とは？

- レベル1：単純な制御プログラム
(エアコンの温度制御、洗濯機の水量制御とか。エセ人工知能。)
 - レベル2：古典的な人工知能
(ルンバ、チェスソフト)
 - レベル3：機械学習を取り入れた人工知能
(自動運転、検索エンジン、メールフィルタ、将棋ソフト)
-
- レベル4：ディープラーニングを取り入れた人工知能
(囲碁ソフト、Google Photosとか画像判別)
- ここまでは
ほぼ実用化
- 人工知能分野の研究開発、投資が過熱。
 - バブルの可能性も？
- ここからは
研究、投資段階

発表概要

- ① 人工知能とは？
- ② 機械学習の基礎知識
- ③ ニューラルネットワーク
- ④ 洪水予測への活用例
- ⑤ 深層学習（ディープラーニング）
- ⑥ おわりに

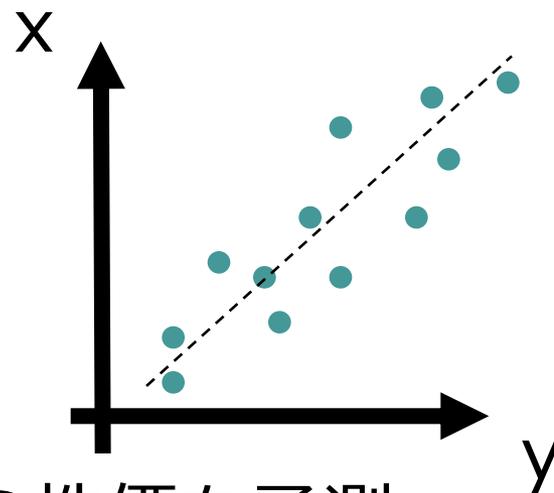
機械学習とは？

→ **分類、回帰**のテクニック + α

回帰と分類

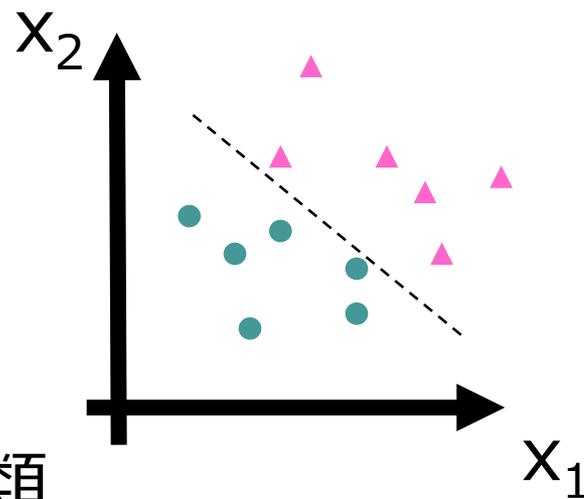
●回帰

気温から、電力需要を予測
現在までの株価の動きから、将来の株価を予測

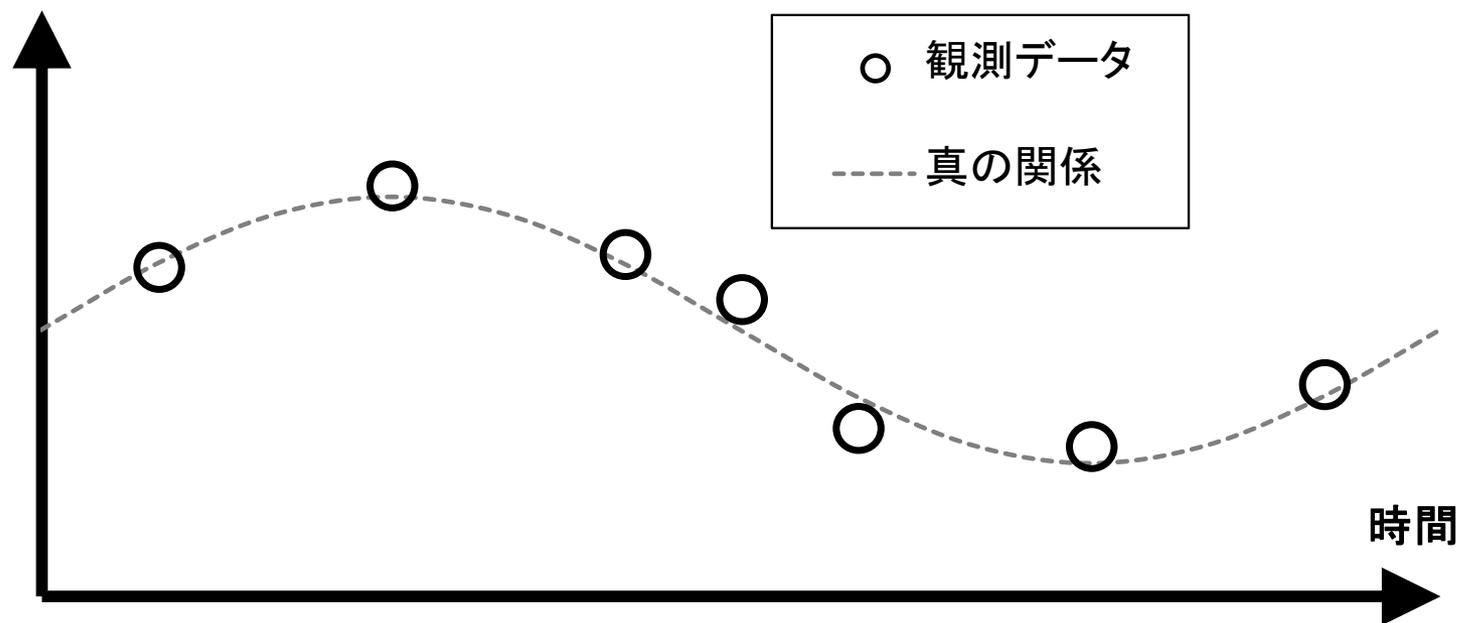


●分類

使用単語から、スパムメールを分類
雨量の累積/強度から、土砂災害の発生・非発生を分類



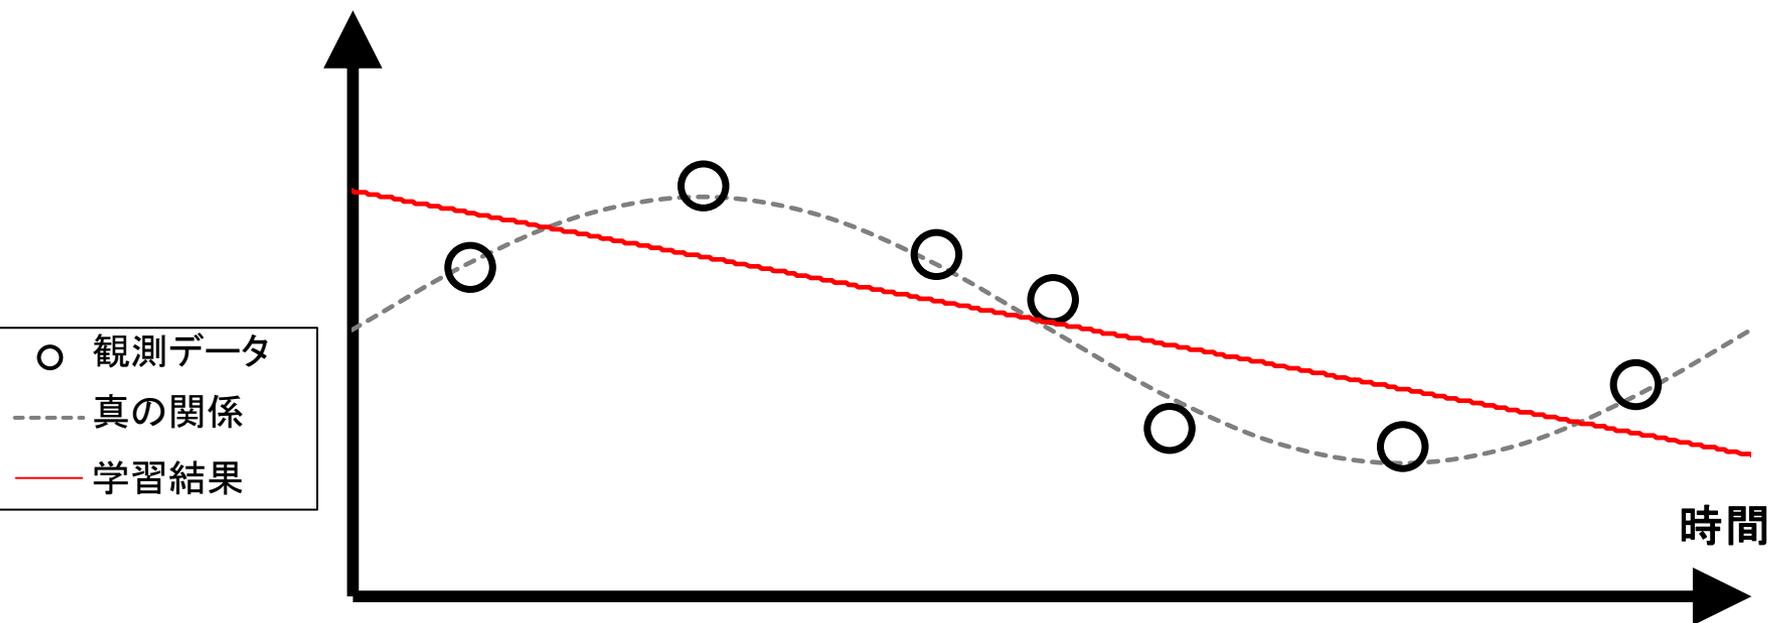
機械学習の例



潮位データ、日射量データのような周期データを想定

機械学習の例

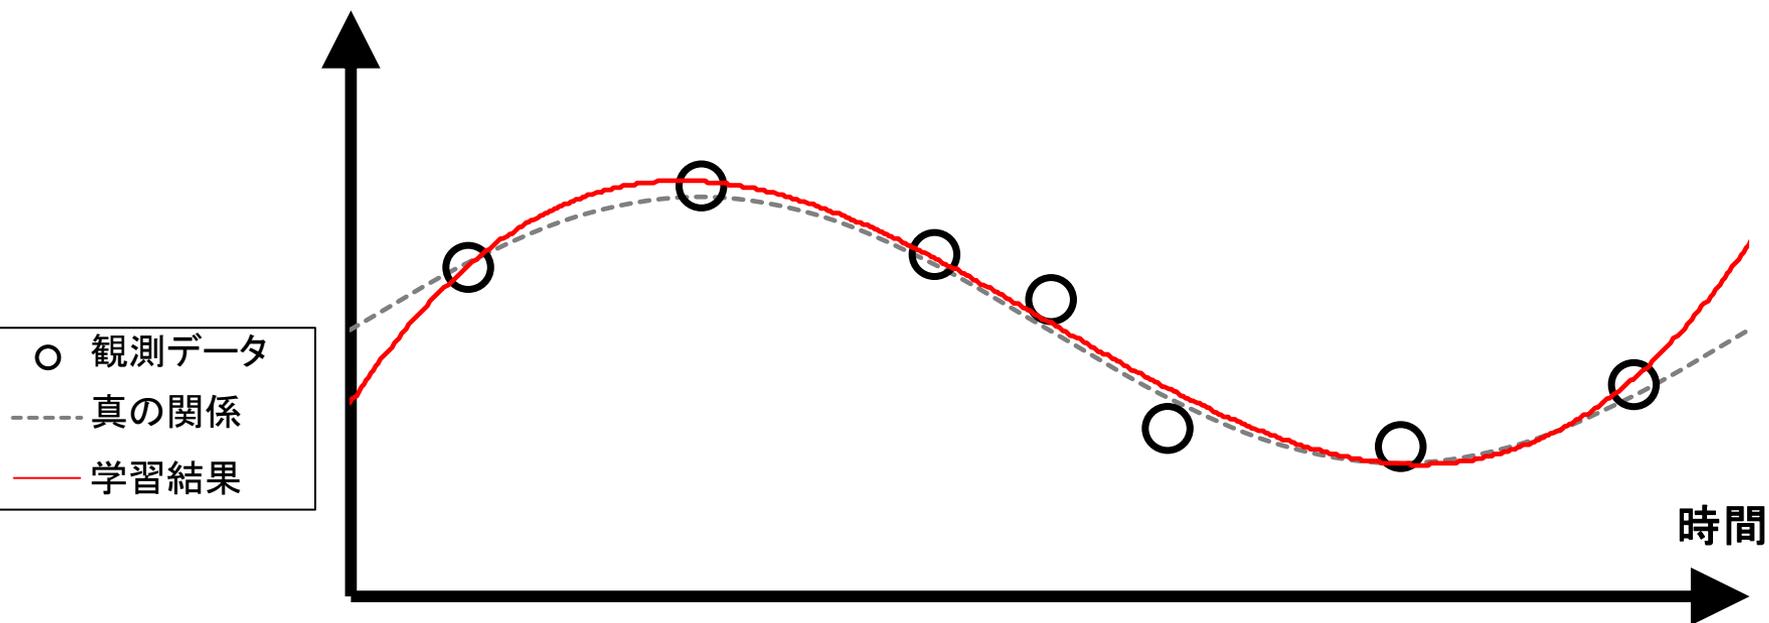
一次関数による当てはめ
(二乗誤差の最小化)



全然あってない。

機械学習の例

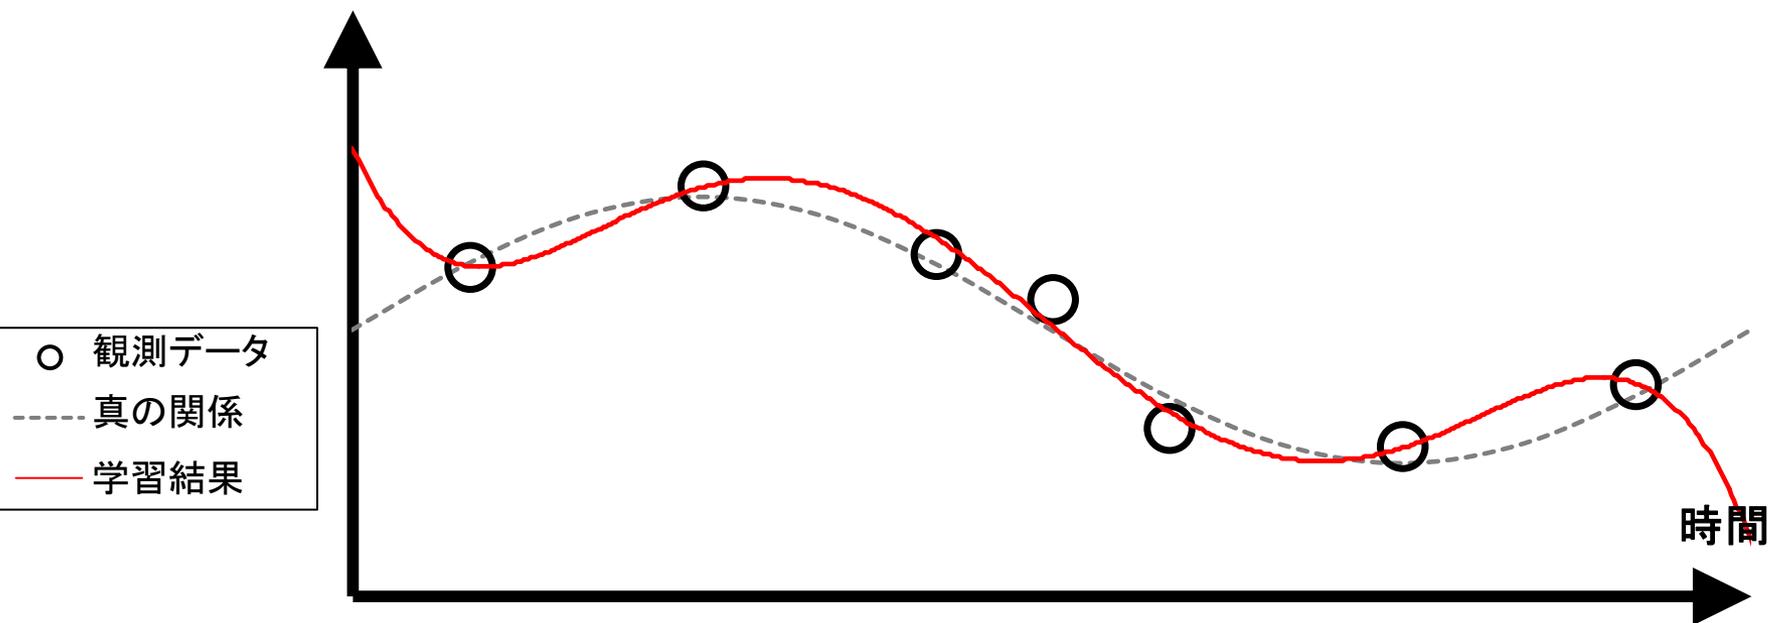
三次関数



良い感じ。

機械学習の例

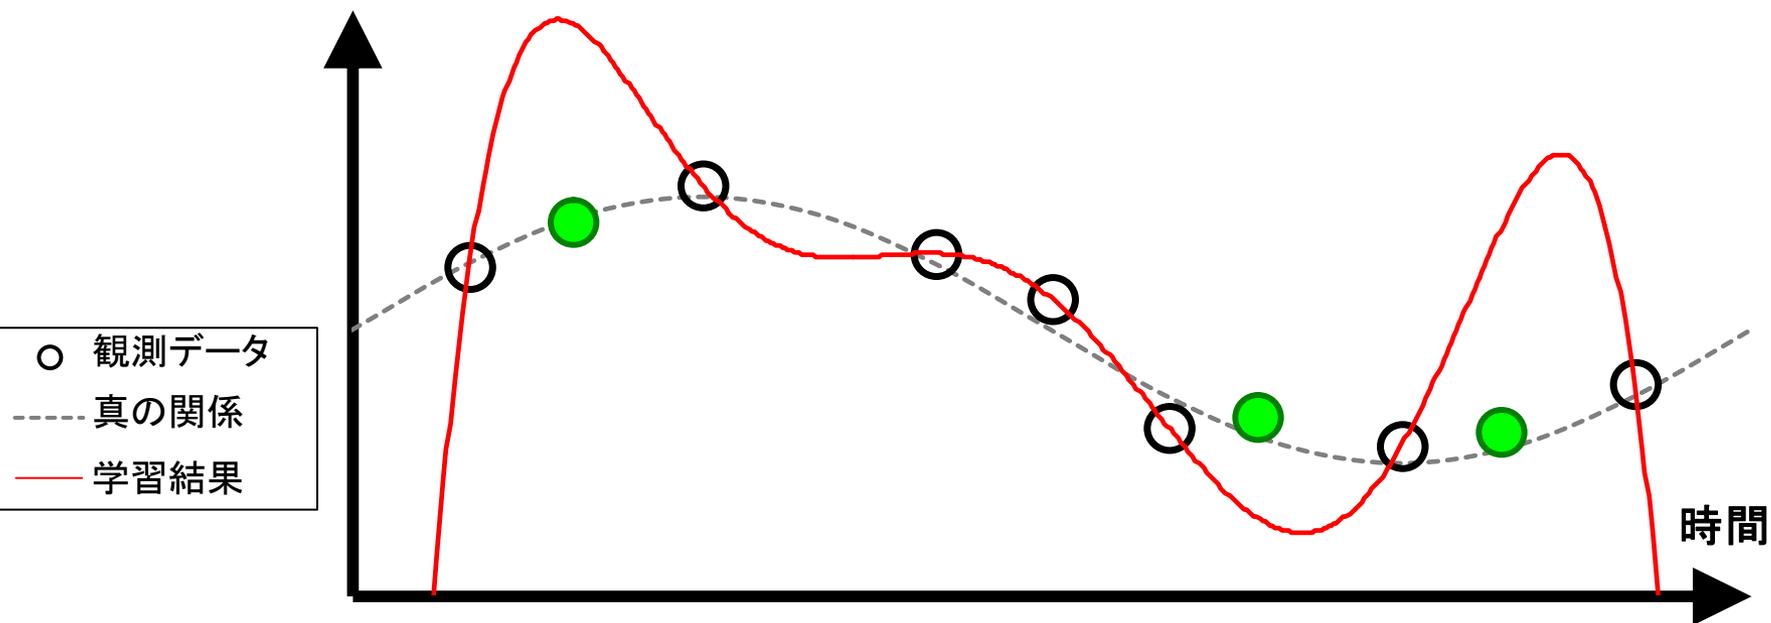
五次関数



ちょっと怪しい。

機械学習の例

六次関数



とても変。

機械学習の例

- データに無理やり合わせるのではなく、**データの真の関係を表現(汎化)**することが重要。
 - 単純すぎるモデルでは、データ間の関連が表現できず、学習が不十分となる。(一次関数の例)
 - 学習をしすぎると、**過学習(オーバーフィッティング)**となりかえって悪化する(六次関数の例)
- ※**データはたくさんあった方が良い。**
- ※**学習用データと、検証用データは分ける**
→ 交差検証など

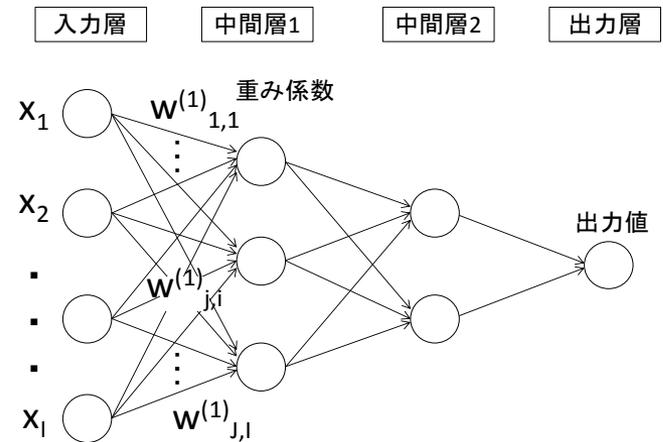
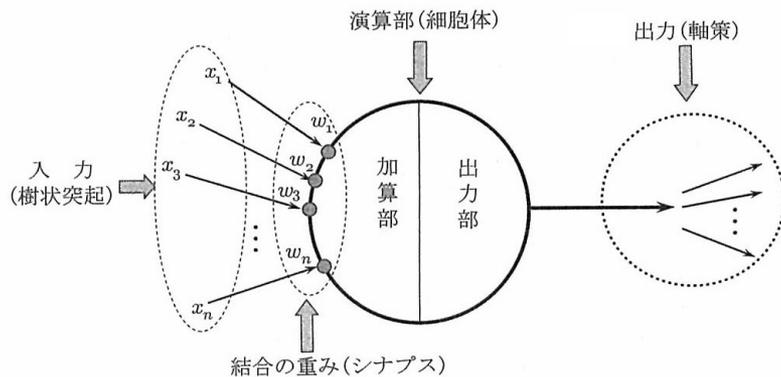
発表概要

- ① 人工知能とは？
- ② 機械学習の基礎知識
- ③ ニューラルネットワーク
- ④ 洪水予測への活用例
- ⑤ 深層学習（ディープラーニング）
- ⑥ おわりに

ニューラルネットワークとは？

Artificial Neural Network ; ANN

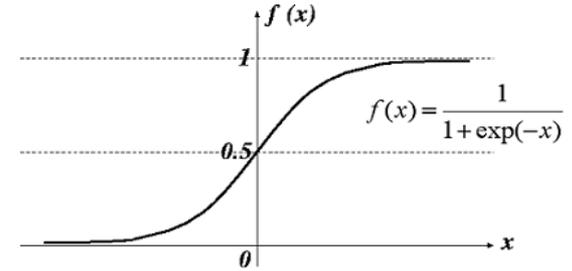
→脳機能に見られる特性を、数学的に表現したモデル。



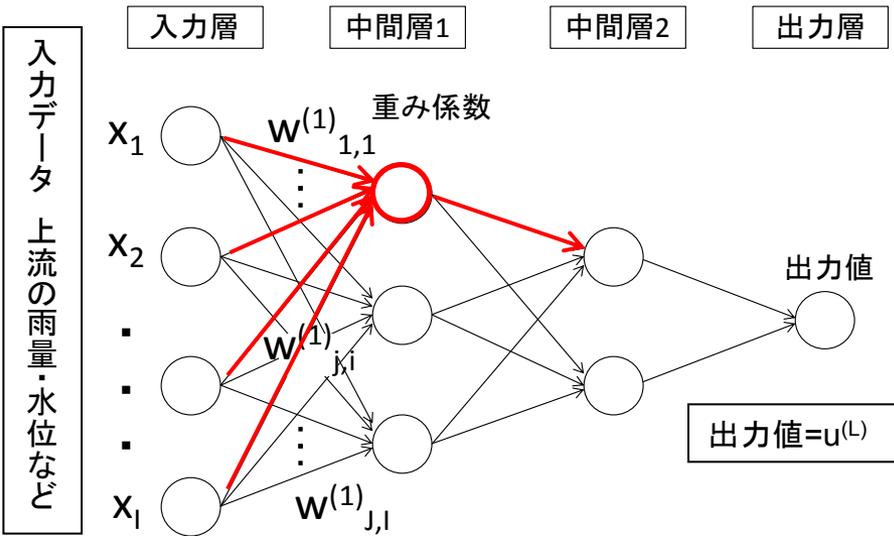
図の出典：熊沢逸夫，『学習とニューラルネットワーク』，森北出版，1998

ニューラルネットワークの概要

- ①各ネットワークに入力値 x が与えられる
- ②入力値 x と、重み係数 w の積を足し合わせて、次の素子への入力 u とする
- ③活性化関数により、各素子からの出力を計算する ($f(u)=z$)
- ④素子からの出力 z を、次のネットワークへの入力 u とする

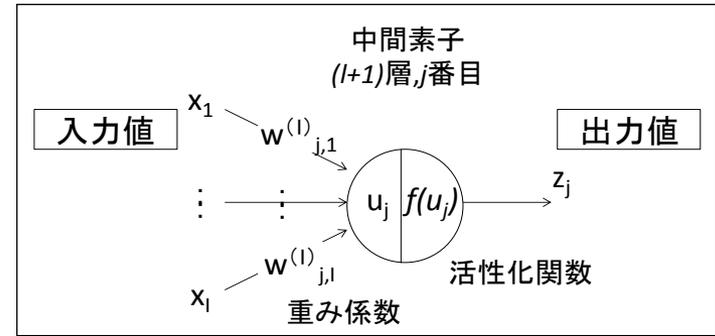


以下、順に出力層まで値が伝達される



入力データ 上流の雨量・水位など

x : 入力値
 u : 素子への層入力
 w : 重み係数
 b : バイアス
 z : 素子からの出力値
 $f(u)$: 活性化関数。
 (ここではシグモイド関数 $f(u) = \frac{1}{1 + \exp(-u)}$ を用いた。)



$$u = b_i + \sum_{i=1}^I w_{ji} x_i \quad z = f(u) = \frac{1}{1 + \exp(-u)}$$

$$\left(\begin{array}{l} \mathbf{u} = \begin{bmatrix} u_1 \\ \vdots \\ u_j \\ \vdots \\ u_J \end{bmatrix}, \mathbf{x} = \begin{bmatrix} x_1 \\ \vdots \\ x_i \\ \vdots \\ x_J \end{bmatrix}, \mathbf{b} = \begin{bmatrix} b_1 \\ \vdots \\ b_j \\ \vdots \\ b_J \end{bmatrix}, \mathbf{z} = \begin{bmatrix} z_1 \\ \vdots \\ z_j \\ \vdots \\ z_J \end{bmatrix}, \\ \mathbf{W} = \begin{bmatrix} w_{11} & \cdots & w_{1J} \\ \vdots & \ddots & \vdots \\ w_{J1} & \cdots & w_{JJ} \end{bmatrix}, \mathbf{f}(\mathbf{u}) = \begin{bmatrix} f(u_1) \\ \vdots \\ f(u_j) \\ \vdots \\ f(u_J) \end{bmatrix} \end{array} \right) \quad \begin{array}{l} \mathbf{u} = \mathbf{W}\mathbf{x} + \mathbf{b} \\ \mathbf{z} = \mathbf{f}(\mathbf{u}) \end{array}$$

ニューラルネットワークの学習手順

学習とは：

ANNの出力と、観測値との誤差を最小化する、**重み係数 w_{ij} の最適化**。

● 目的関数 E :
$$E(w) = \frac{1}{2} \sum_{n=1}^N (d_n - y(x_n; w))^2$$

● **誤差逆伝搬法**による ∇E の計算

(1) 最下層:
$$\frac{\partial E}{\partial w_i^{(L)}} = y(x) - d$$

(2) 第 l 層:
$$\frac{\partial E_n}{\partial w_{ji}^{(l)}} = \delta_j^{(l)} z_i^{(l-1)} \quad \text{ただし} \quad \delta_j^{(l)} = \partial E / \partial u_j^{(l)}$$

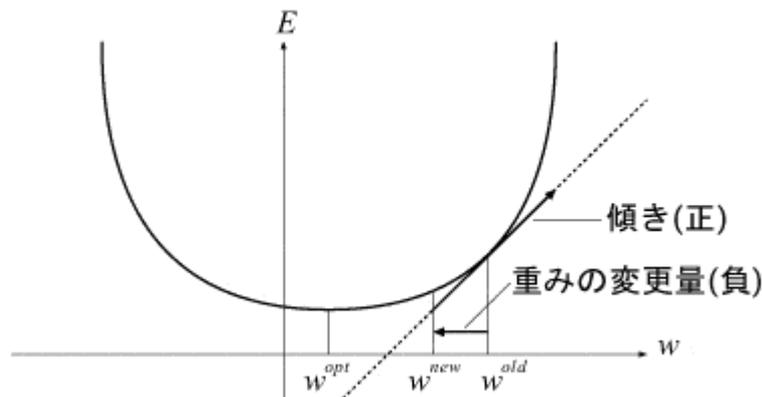
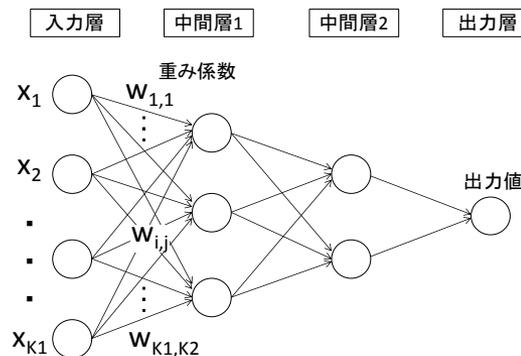
(3) δ に関する漸化式
$$\delta_j^{(l)} = \sum_k \delta_k^{(l+1)} (w_{kj}^{(l+1)} f'(u_j^{(l)}))$$

$\partial E / \partial w$ は下流から順に計算可能、 ∇E が求まる。

● 勾配降下法により重み更新

$$w^{(t+1)} = w^{(t)} - \varepsilon \nabla E$$

E : 目的関数(二乗誤差) y : ネットワークの最終出力
 d : 教師データ(観測値) ε : 学習係数



勾配降下法

発表概要

- ① 人工知能とは？
- ② 機械学習の基礎知識
- ③ ニューラルネットワーク
- ④ 洪水予測への活用例
- ⑤ 深層学習（ディープラーニング）
- ⑥ おわりに

洪水予測の背景

写真出典：国土交通省webページ，台風第18号及び第17号による大雨（平成27年9月関東・東北豪雨）等に係る被害状況等について TEC-FORCEフォトギャラリー，http://www.mlit.go.jp/river/bousai/tec-force/h2709_gouu/index.html

➤ 頻発する洪水・氾濫災害

- 2000.9 東海豪雨（死者10名、2700億円）
- 2004.7 新潟・福島豪雨（16名、21000棟）
- 2008.7 都賀川水難事故（5名）
- 2008.8 雑司ヶ谷下水道事故（5名）
- 2012.7 九州北部豪雨（30名、17000棟）
- 2015.9 鬼怒川（25名）



➤ 温暖化による水害リスクの増大

（国交省；社会資本整備審議会、2008）

➤ 洪水・氾濫災害への対応

- ダムや堤防など治水施設が整備されてきた。
- 同時に、**避難のためのソフト対策**が進められている。
全国109の一級河川に、洪水予測システムが導入済。
- ただし、**適切な避難行動につながらない場合も多い。**

洪水予測システムとは？

- 水位を予測するシステム（⇔はん濫予測）
- 10分に一回（365日常時）、レーダ雨量、予測メッシュ雨量、観測水位などを受信して、6時間先までの予測水位を配信。
- 洪水予報河川では、国による洪水の情報提供が義務（水防法）。
→全国の河川事務所（国交省）で、洪水予測システムを整備。

洪水予測の課題と目標

●洪水予測の課題

- ・実災害時には、洪水予測情報は住民の適切な避難行動につながっていない場合が多い。
- ・河川管理者、市町村長らにとっても、避難勧告等の発令判断は容易でない。

●実時間洪水予測の目標：

洪水・氾濫に対する適切な避難に結び付ける。そのためには、

→①迷わず判断するための予測精度を確保する。

→②避難に間に合うためのリードタイムを確保する。

目標とされるリードタイムや精度は、河川や地域の状況によって異なる。

精度評価方法（不確実性の評価方法）や情報提供方法も、将来の重要な研究課題。

実時間洪水予測の手法

大分類	小分類	長所	短所
統計手法	時系列解析（線形回帰、AR、ARMA、ARIMA、など）	モデル構築が簡便、計算が簡易	降雨-流出の非線形性を表現できない
	機械学習 （ANN、SVM、など）	非線形性を含めた高い表現能力、豊富な使用実績	計算過程がブラックボックス、データが多く必要
	その他（ファジィ、事例ベース、など）	最新の知見を反映	実用化の実績が少なく、適用性・発展性が不明
概念モデル	単位図法	計算が簡単	降雨-流出の非線形性を表現できない
	タンクモデル	計算が比較的簡単、様々な流出波形を表現できる	パラメータの物理性が弱い
	貯留関数	計算が比較的簡単、全国の洪水予測システムで実績	パラメータの物理性が弱い
物理モデル	分布型モデル	降雨-流出の過程を最も詳細に表現、地形データや降雨分布などを反映	モデル構築・チューニングが大変、フィードバックが容易でない
その他	概念モデルを分布させたモデルなど、様々な手法が考えられる		

◎ニューラルネットワーク（Artificial Neural Network ; ANN）は研究実績が豊富。深層学習など新たな手法による精度向上も期待される。

対象流域とデータ

大淀川流域（宮崎県）、樋渡（ひわたし）地点
流域面積：861km² / 幹川延長：52km

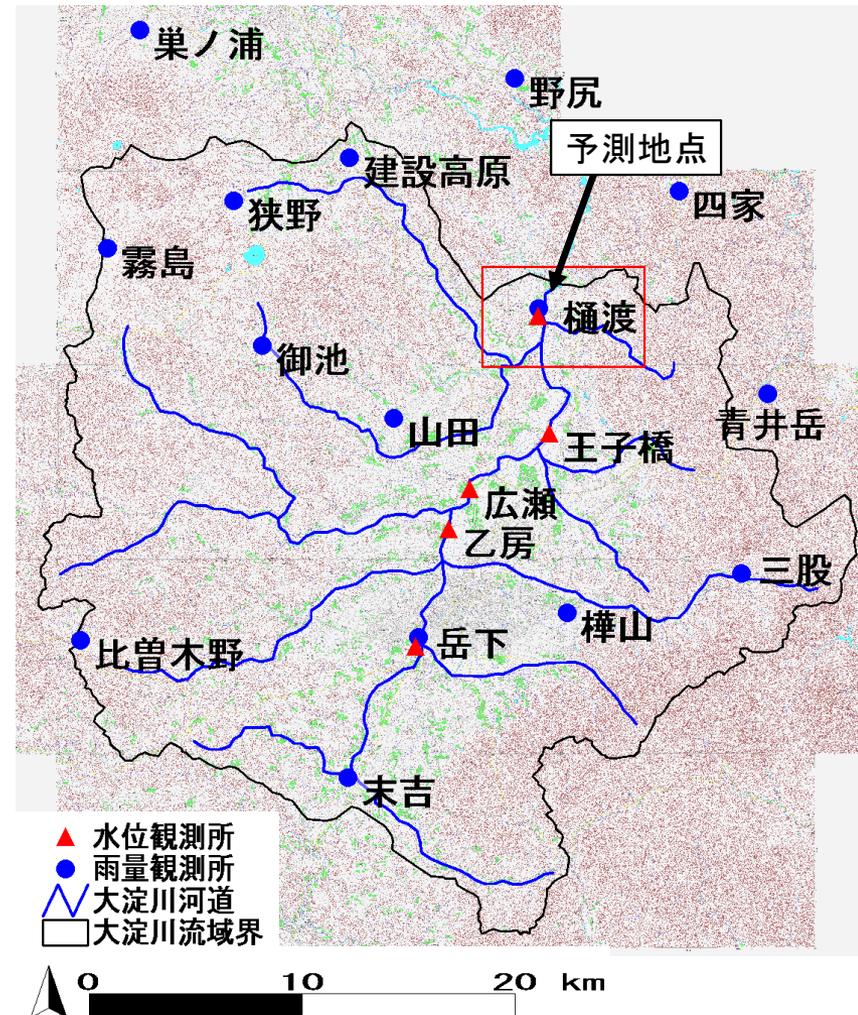
✓大きなダム等が存在しない

✓観測水位データが豊富

1990～2014年の間の上位24洪水を
水水DBより水位雨量データ取得。

ピークから72時間前～48時間後までの
121時間分を1洪水とする。
24洪水×121=2904セットのデータ。

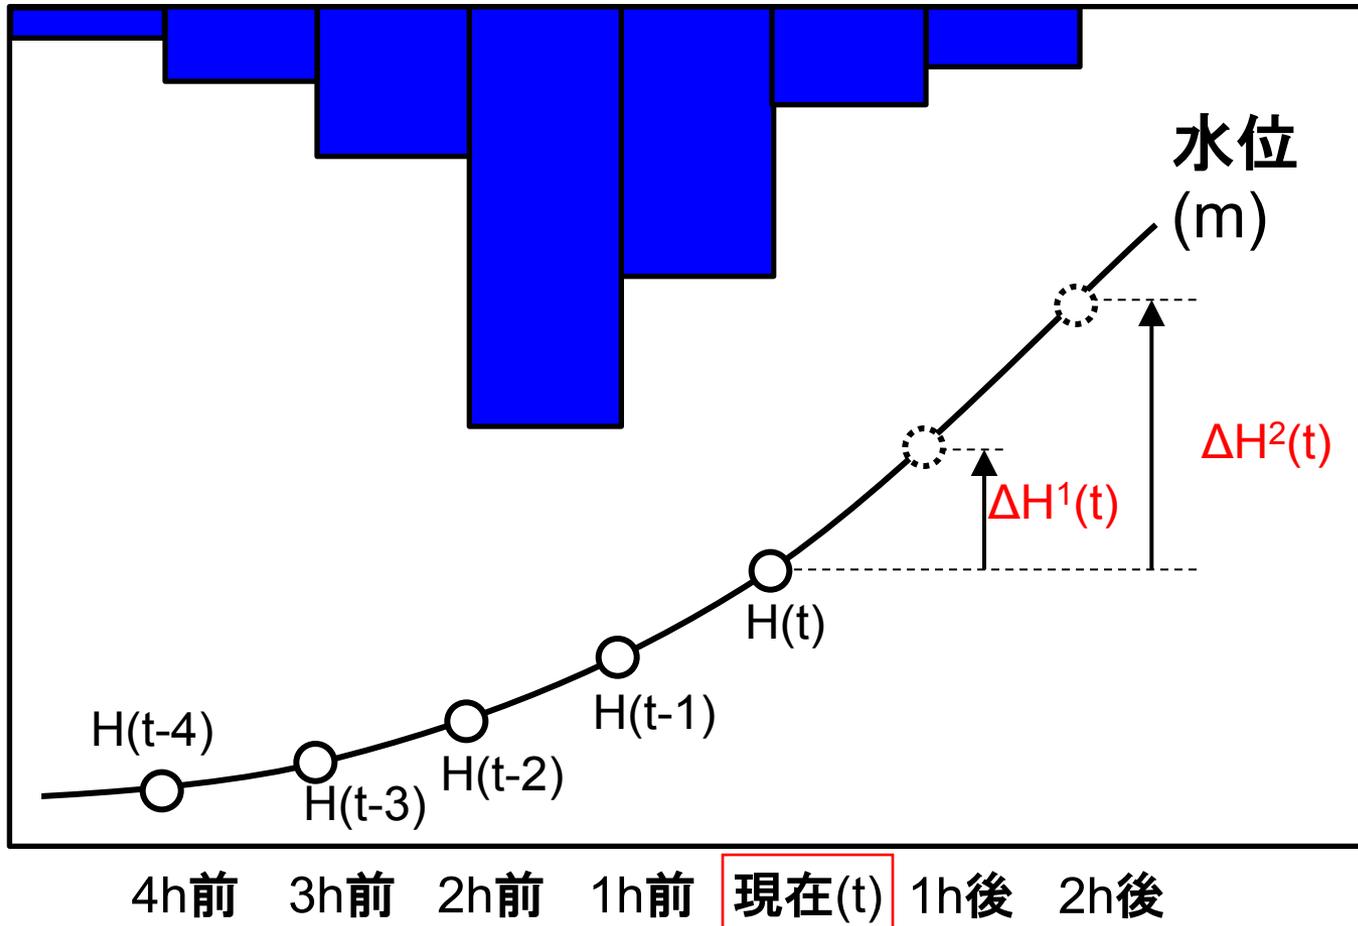
欠測が少なく、**氾濫危険水位（9.2m）**
を超えた4洪水を精度検証対象とした。



水位・雨量データの定義

$R(t-4)$ $R(t-3)$ $R(t-2)$ $R(t-1)$ $R(t)$ $R(t+1)$ $R(t+2)$

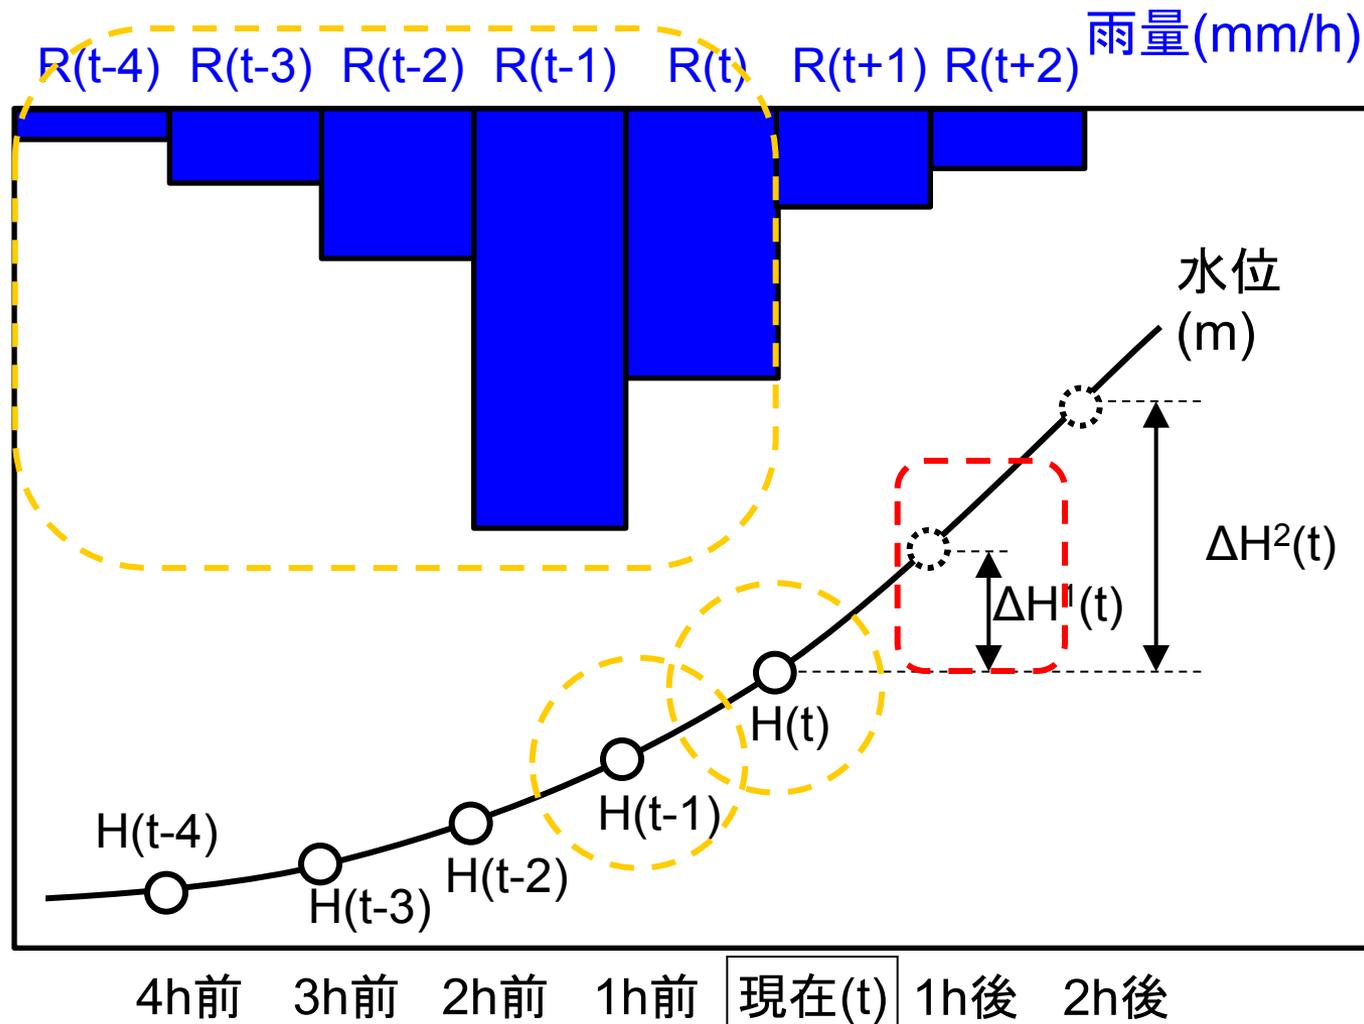
雨量(mm/h)



- ・ データは1時間ごと。観測所ごとに、上記の時系列データが定義される。
- ・ 時刻雨量 $R(t)$:時刻 $(t-1) \sim (t)$ の一時間に降った雨量(mm/h)。
- ・ 水位変化 $\Delta H^n(t)$ が予測対象。

入出力データの例（1時間予測）

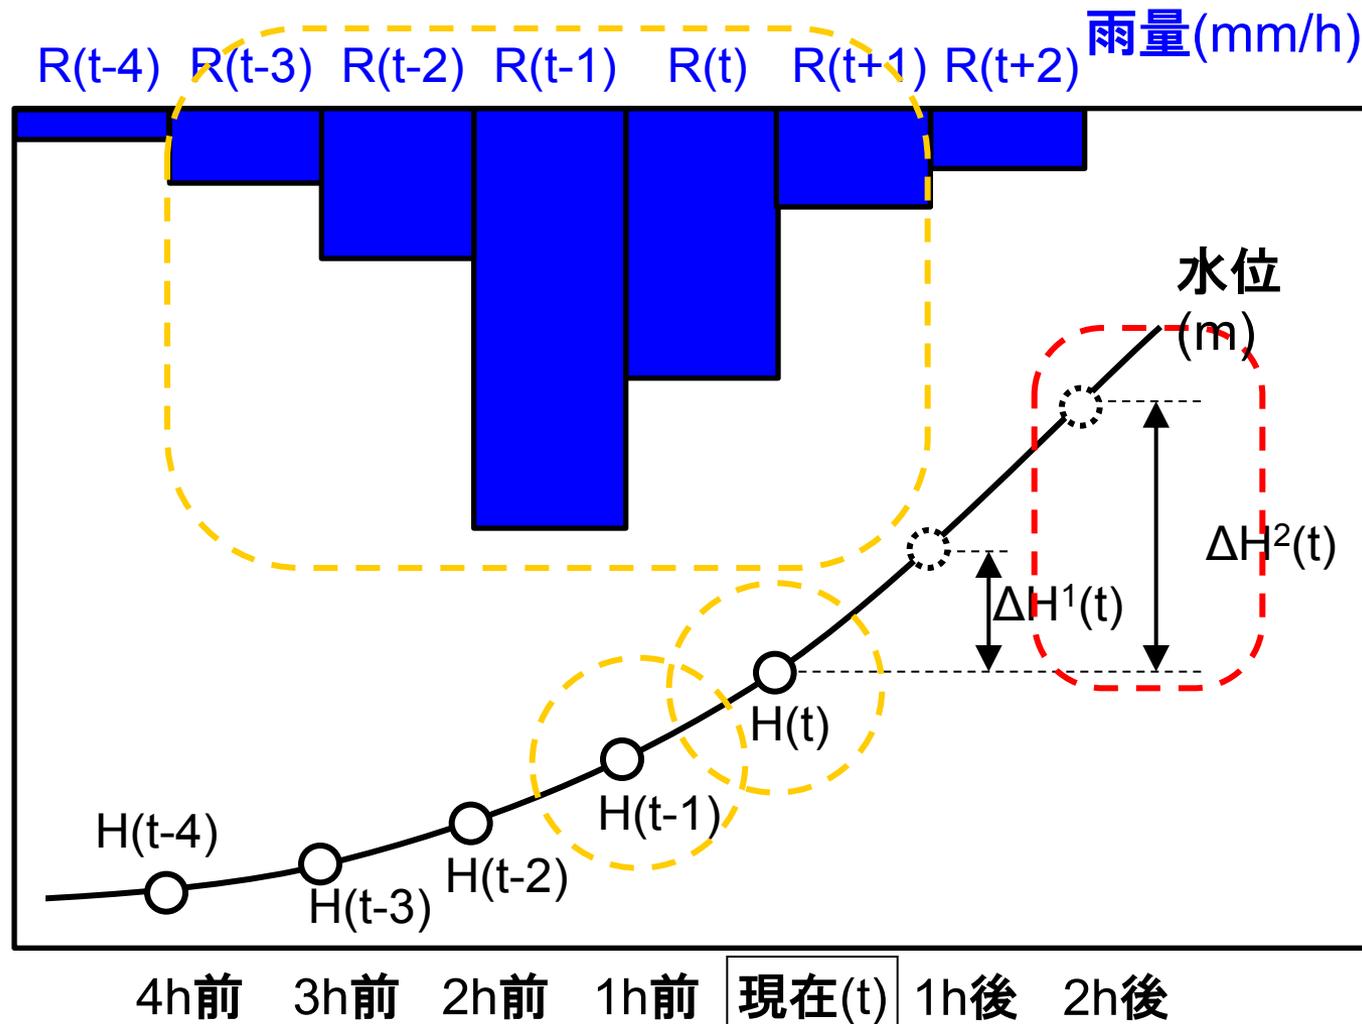
	$\Delta H_{\text{樋渡}}$	$H_{\text{樋渡}}$	$\Delta H_{\text{上流}}$	雨
-4h	○	○	○	○
-3h	○	○	○	○
-2h	○	○	○	○
-1h	○	○	○	○
現	○	○	○	○
+1h	○	○	○	○
+2h	○	○	○	○
+3h	○	○	○	○
+4h	○	○	○	○
+5h	○	○	○	○
+6h	○	○	○	○



- ・ 上図に加え、各水位観測所(5地点)の水位変化 ΔH が入力データとなる。
- ・ 時刻雨量 $R(t)$ は、各雨量観測所(14地点)分が全て入力データとなる。

入出力データの例（2時間予測）

	ΔH 予	H予	ΔH 上	雨
-4h	○	○	○	○
-3h	○	○	○	○
-2h	○	○	○	○
-1h	○	○	○	○
現	○	○	○	○
+1h	○	○	○	○
+2h	○	○	○	○
+3h	○	○	○	○
+4h	○	○	○	○
+5h	○	○	○	○
+6h	○	○	○	○



- ・ 上図に加え、各水位観測所(5地点)の水位変化 ΔH が入力データとなる。
- ・ 時刻雨量 $R(t)$ は、各雨量観測所(14地点)分が全て入力データとなる。
- ・ 未来時刻の水位データは使わない。雨量データは実績値を代用。

ANNの条件設定

入出力データの一覧

● 予測時刻ごとにANNを作成

● 入力データ:

時刻水位 (1地点 × 2時間分)
 水位変化 (5地点 × 3時間分)
 時刻雨量 (14地点 × 5時間分)
 → 計87データ

入力			出力
種別	地点	時刻	
時刻水位	樋渡	-1,0	樋渡の 水位変化
1時間の 水位変化	流域内 5地点	-2,-1,0	
時刻雨量	流域内 14地点	t-5,t-4,t-3,t-2,t-1	

● 予測時間に応じて、入力データの時刻を設定 (右図)

● その他の条件設定はケーススタディ。

項目	設定内容	ケース数
中間素子数	10,20,40,60個	4
学習回数	300,1000, 3000,10000回	4
ドロップアウト率*	0.1, 0.3, 0.5	3
Total		48

	ΔH _{樋渡}	H _{樋渡}	ΔH _{上流}	雨
-4h	○	○	○	○
-3h	○	○	○	○
-2h	○	○	○	○
-1h	○	○	○	○
現	○	○	○	○
+1h	○	○	○	○
+2h	○	○	○	○
+3h	○	○	○	○
+4h	○	○	○	○
+5h	○	○	○	○
+6h	○	○	○	○

	ΔH _予	H _予	ΔH _上	雨
-4h	○	○	○	○
-3h	○	○	○	○
-2h	○	○	○	○
-1h	○	○	○	○
現	○	○	○	○
+1h	○	○	○	○
+2h	○	○	○	○
+3h	○	○	○	○
+4h	○	○	○	○
+5h	○	○	○	○
+6h	○	○	○	○

	ΔH _予	H _予	ΔH _上	雨
-4h	○	○	○	○
-3h	○	○	○	○
-2h	○	○	○	○
-1h	○	○	○	○
現	○	○	○	○
+1h	○	○	○	○
+2h	○	○	○	○
+3h	○	○	○	○
+4h	○	○	○	○
+5h	○	○	○	○
+6h	○	○	○	○

1時間予測 2時間予測 ... 6時間予測

未来時刻の降雨には、実績雨量を当てはめる。
 (雨量誤差は考えない、降雨完全予測。)

※説明は後述

精度検証の手順

洪水番号	ピーク時刻	樋渡水位
1	2005/9/6 9:00	10.65
2	1997/9/16 13:00	9.9
3	2004/8/30 11:00	9.8
4	1993/8/1 22:00	9.5
5	1990/9/29 21:00	9.44
6	2010/7/3 9:00	9.16
7	2011/9/20 14:00	8.8
8	1999/9/14 22:00	8.26
9	1993/8/10 4:00	8.04
10	2004/10/20 11:00	7.7
11	1990/9/19 11:00	7.47
12	1999/8/6 3:00	7.24
13	2007/7/14 16:00	7.11
14	1993/9/3 19:00	6.99
15	1995/6/25 17:00	6.9
16	1996/7/18 21:00	6.84
17	2003/8/8 12:00	6.79
18	1999/7/27 2:00	6.72
19	2014/7/31 19:00	6.61
20	2000/6/3 16:00	6.53
21	2010/6/20 20:00	6.3
22	2014/8/9 10:00	6.08
23	1993/7/7 14:00	6.07
24	1999/8/17 17:00	6.03

検証データ

学習データ

●モデルの適切な評価のため、学習データと検証データは分離（交差検証）

●検証手順：

- ① 24洪水中、23洪水で学習。
- ② 残りの1洪水で検証。

以下、上記①②を同様に繰り返し対象洪水（上位4洪水）について精度検証。

精度検証の手順

洪水番号	ピーク時刻	樋渡水位
1	2005/9/6 9:00	10.65
2	1997/9/16 13:00	9.9
3	2004/8/30 11:00	9.8
4	1993/8/1 22:00	9.5
5	1990/9/29 21:00	9.44
6	2010/7/3 9:00	9.16
7	2011/9/20 14:00	8.8
8	1999/9/14 22:00	8.26
9	1993/8/10 4:00	8.04
10	2004/10/20 11:00	7.7
11	1990/9/19 11:00	7.47
12	1999/8/6 3:00	7.24
13	2007/7/14 16:00	7.11
14	1993/9/3 19:00	6.99
15	1995/6/25 17:00	6.9
16	1996/7/18 21:00	6.84
17	2003/8/8 12:00	6.79
18	1999/7/27 2:00	6.72
19	2014/7/31 19:00	6.61
20	2000/6/3 16:00	6.53
21	2010/6/20 20:00	6.3
22	2014/8/9 10:00	6.08
23	1993/7/7 14:00	6.07
24	1999/8/17 17:00	6.03

検証データ

学習データ

●モデルの適切な評価のため、学習データと検証データは分離（交差検証）

●検証手順：

- ① 24洪水中、23洪水で学習。
- ② 残りの1洪水で検証。

以下、上記①②を同様に繰り返し対象洪水（上位4洪水）について精度検証。

精度検証の手順

洪水番号	ピーク時刻	樋渡水位
1	2005/9/6 9:00	10.65
2	1997/9/16 13:00	9.9
3	2004/8/30 11:00	9.8
4	1993/8/1 22:00	9.5
5	1990/9/29 21:00	9.44
6	2010/7/3 9:00	9.16
7	2011/9/20 14:00	8.8
8	1999/9/14 22:00	8.26
9	1993/8/10 4:00	8.04
10	2004/10/20 11:00	7.7
11	1990/9/19 11:00	7.47
12	1999/8/6 3:00	7.24
13	2007/7/14 16:00	7.11
14	1993/9/3 19:00	6.99
15	1995/6/25 17:00	6.9
16	1996/7/18 21:00	6.84
17	2003/8/8 12:00	6.79
18	1999/7/27 2:00	6.72
19	2014/7/31 19:00	6.61
20	2000/6/3 16:00	6.53
21	2010/6/20 20:00	6.3
22	2014/8/9 10:00	6.08
23	1993/7/7 14:00	6.07
24	1999/8/17 17:00	6.03

検証データ

学習データ

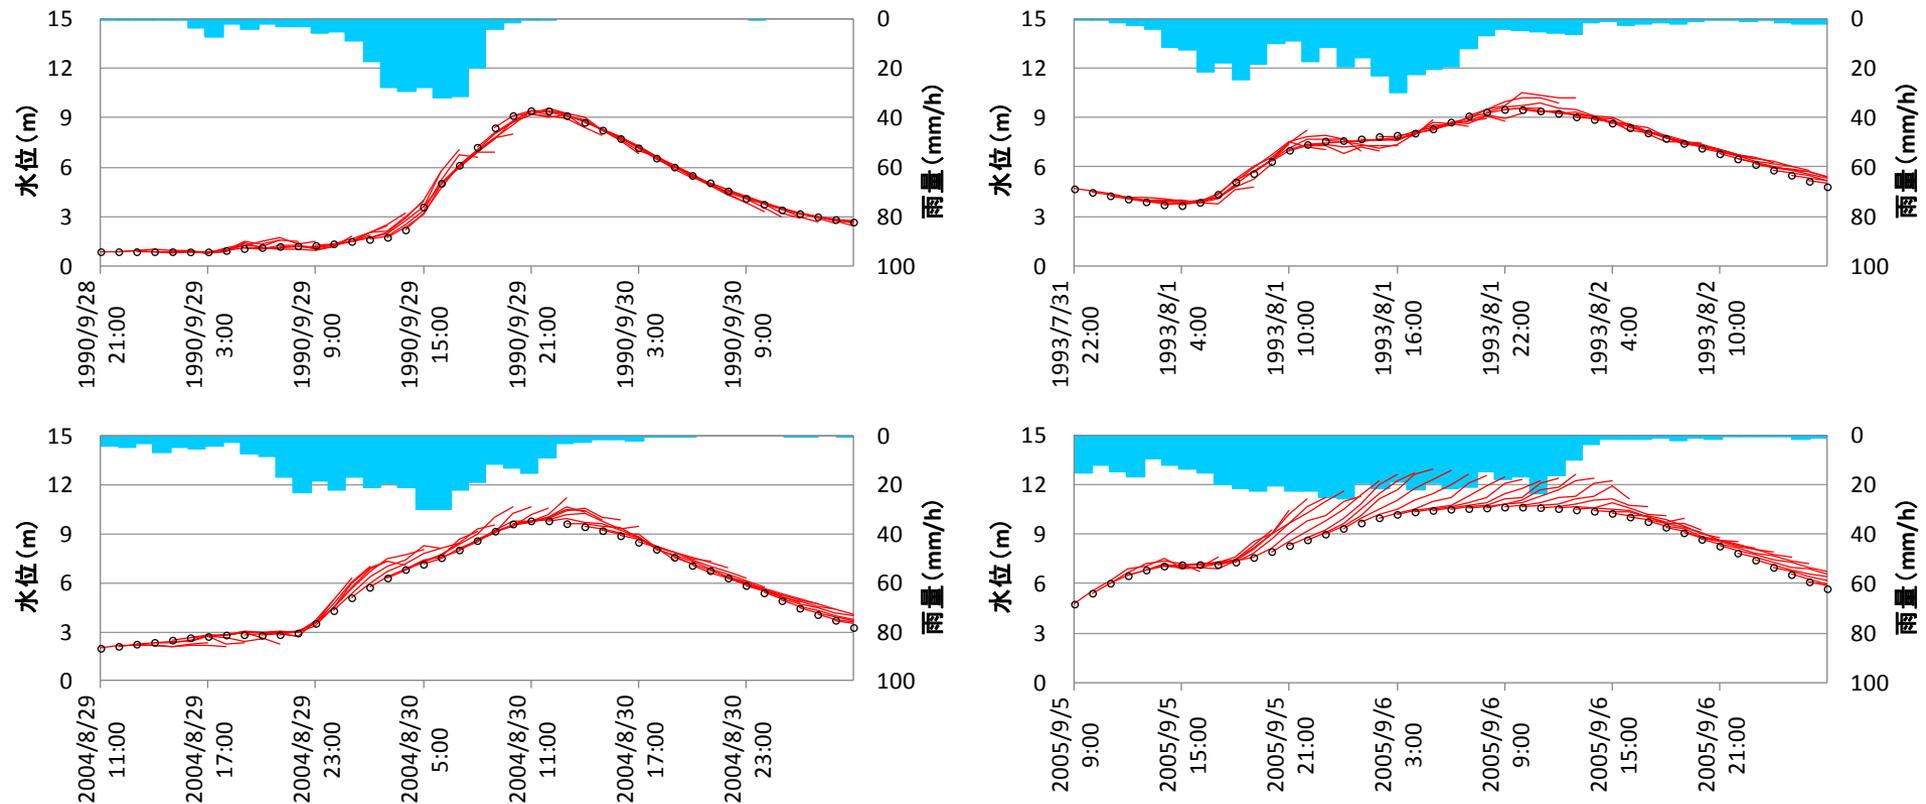
●モデルの適切な評価のため、学習データと検証データは分離（交差検証）

●検証手順：

- ① 24洪水中、23洪水で学習。
- ② 残りの1洪水で検証。

以下、上記①②を同様に繰り返し対象洪水（上位4洪水）について精度検証。

予測計算結果 (1~6時間予測)



- ・ 1~6時間予測まで、再現性は高い。
- ・ 2005年(期間最大洪水)で、やや過大評価の傾向。
→高水時の学習データが不足しているためか、今後の課題。

発表概要

- ① 人工知能とは？
- ② 機械学習の基礎知識
- ③ ニューラルネットワーク
- ④ 洪水予測への活用例
- ⑤ 深層学習（ディープラーニング）
- ⑥ おわりに

ニューラルネットワークの課題

たくさんの観測所の中で、どこのデータが重要か？

各観測所で、何時間分のデータが必要か？

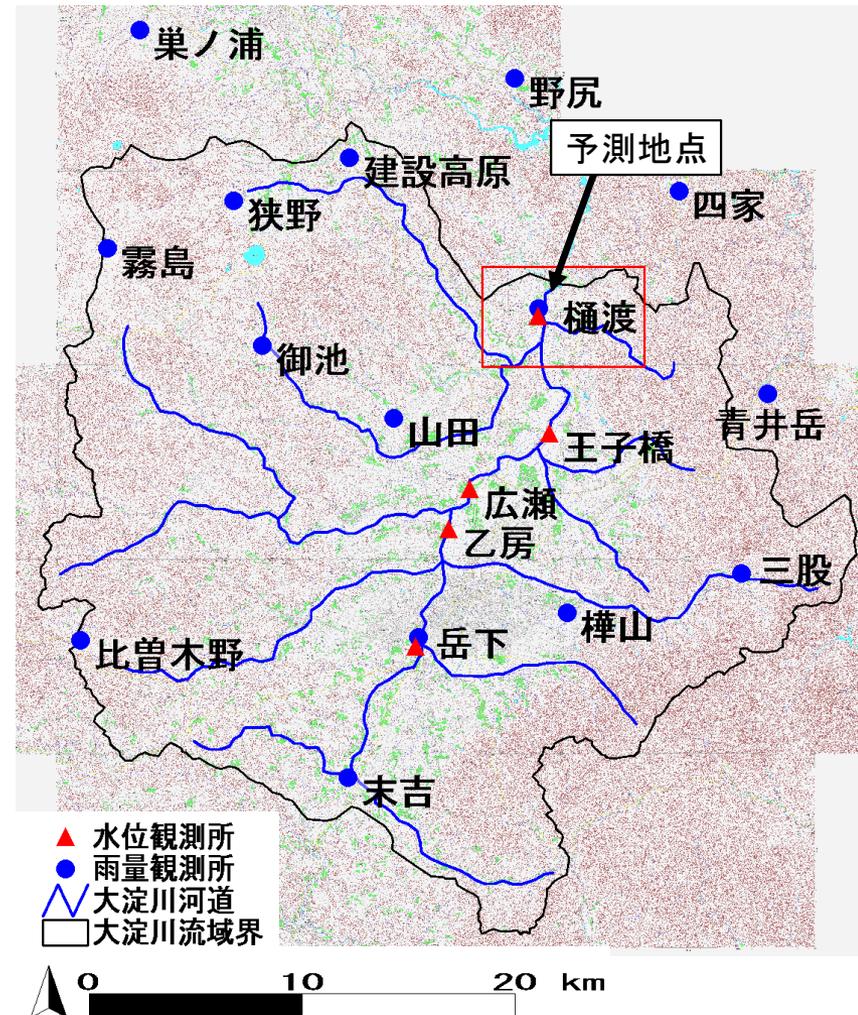


方法1: 人間の判断で設定。

方法2: あらゆるデータをモデルに入力して、後はモデルの学習能力に任せる。



いずれの方法も、複雑な問題では限界がある。



ディープラーニングとは？

- ニューラルネットワークの学習方法の一つ。
深い階層のネットワークの総称。
- 従来のニューラルネットワークよりも、学習能力が高いとされている。

ディープラーニングの既往研究

Hinton 2006

事前学習により、過学習を起こさず多層ANNの学習が可能に

Bengio (2006) Vincent (2010)

自己符号化器の開発

Seide (2011)

音声認識のコンテストで、深層学習を用いた手法が優勝。

Krizhevsky (2012)

画像認識の世界大会で、深層学習を用いたソフトが優勝。

・・・など.



上記以外の分野へは、適用例が少なく未知の領域。

河川水位予測にANN深層学習を適用した研究は報告されておらず、本研究にてモデルの構築・適用を試みる。

深層ネットワークの（従来の）課題

学習とは：

ANNの出力と、観測値との誤差を最小化する、重み係数 w_{ij} の最適化。

● 目的関数 E :
$$E(w) = \frac{1}{2} \sum_{n=1}^N (d_n - y(x_n; w))^2$$

● 誤差逆伝搬法による ∇E の計算

(1) 最下層:
$$\frac{\partial E}{\partial w_i^{(L)}} = y(x) - d$$

(2) 第 l 層:
$$\frac{\partial E_n}{\partial w_{ji}^{(l)}} = \delta_j^{(l)} z_i^{(l-1)} \quad \text{ただし} \quad \delta_j^{(l)} = \partial E / \partial u_j^{(l)}$$

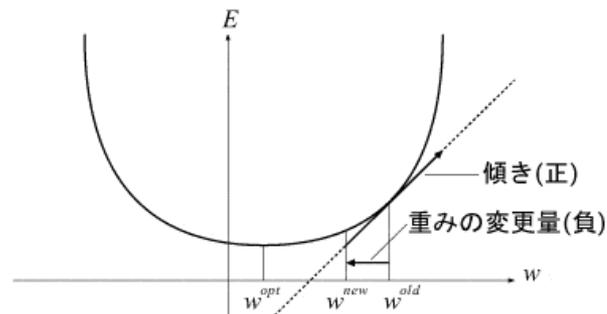
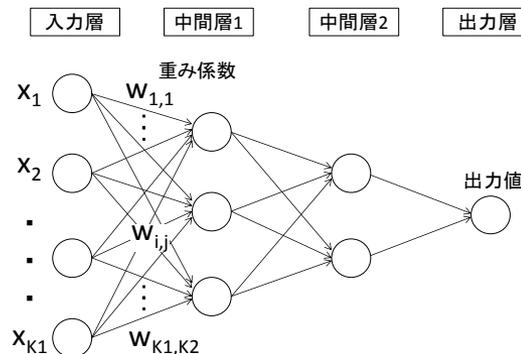
(3) δ に関する漸化式
$$\delta_j^{(l)} = \sum_k \delta_k^{(l+1)} (w_{kj}^{(l+1)} f'(u_j^{(l)}))$$

 $\partial E / \partial w$ は下流から順に計算可能、 ∇E が求まる。

● 勾配降下法により重み更新

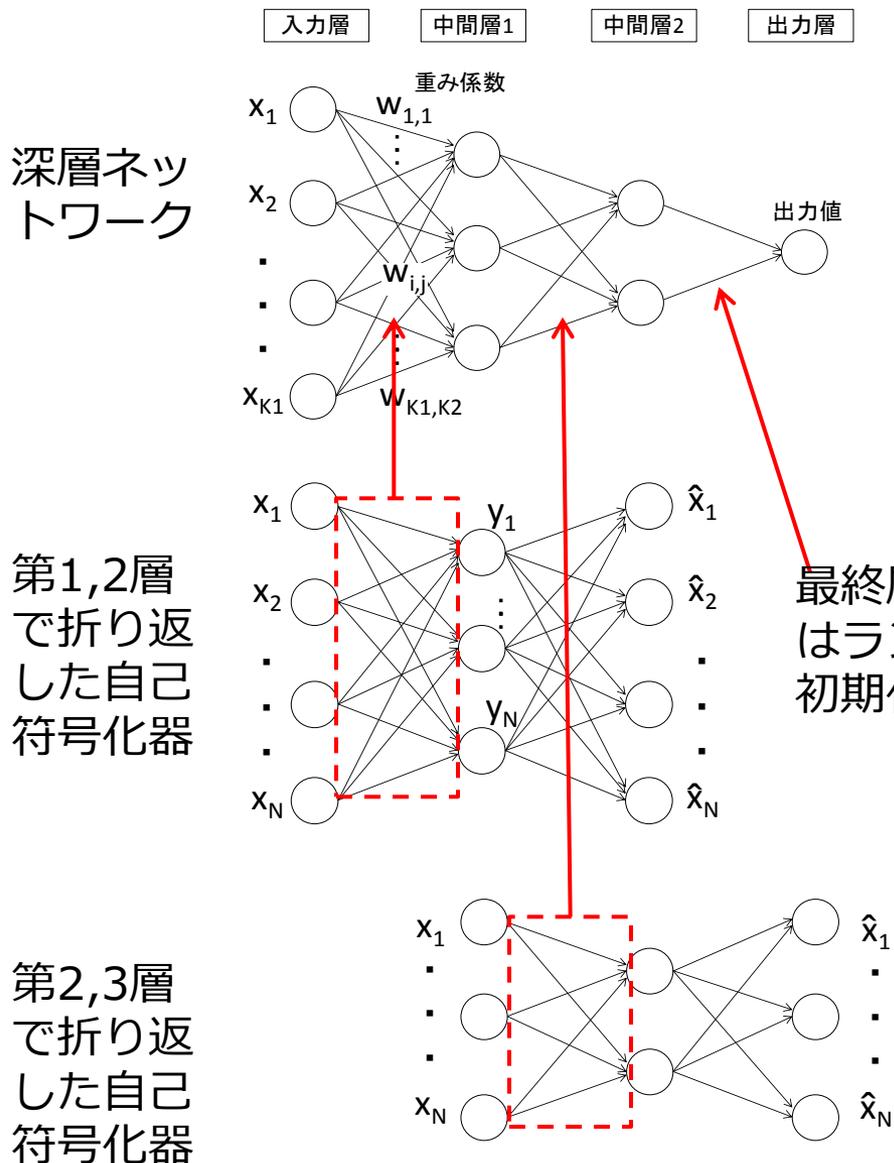
$$w^{(t+1)} = w^{(t)} - \varepsilon \nabla E$$

E : 目的関数(二乗誤差) y : ネットワークの最終出力
 d : 教師データ(観測値) ε : 学習係数

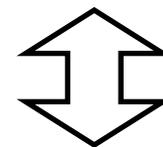


階層の深いネットワークでは、目的関数の微分値 ∇E の算出が困難(勾配消失問題)。

ディープラーニングの概要



- はじめに、**深層ネットワークを小さなネットワーク（自己符号化器）に分割する**。自己符号化器を順次学習し、その時の重み係数を深層ネットワークの初期値とする（**=事前学習**）。



- 従来の学習手法では、**乱数**によって重み係数の初期値を設定。
- 自己符号化器 (Bengio, 2006): 入力と出力ができるだけ同じになるようなネットワーク。
- 他にも、わざとノイズを与えたり、様々な工夫が取り入れられた。

深層学習による洪水予測計算の実施

- 計算設定条件のケーススタディ

ケース番号	学習回数	各層の素子数	ドロップアウト率(p)	デノイジング自己符号化器
1	300	87-10-5-1	0.1	True
2	1000	87-20-10-1	0.3	False
3	3000	87-40-20-1	0.5	
4	10000	87-60-30-1		

- その他の条件一覧

種別	観測所名
学習データ期間	1990~2014の上位24洪水
学習データ種類	樋渡水位, 上流水位変化, 時間雨量
入力降雨	実績雨量を予測雨量に見立てた完全予測データ
データセット数	2904
バッチサイズ	100
予測時間	1時間~6時間
モーメンタム	0.5
学習率	初期値0.1としてAdaGradで自動設定
デノイジングの加算ノイズ	平均0、分散3%の正規乱数

モデルの性能比較

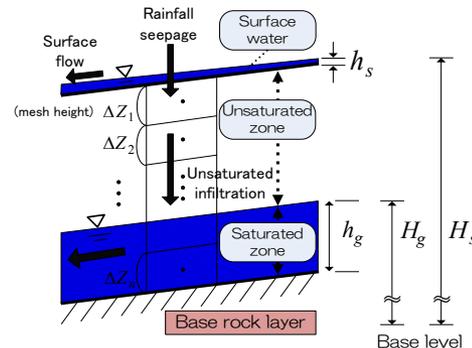
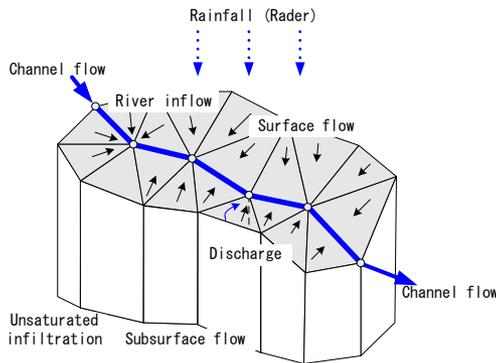
①ディープラーニング

②ニューラルネットワーク（従来型）

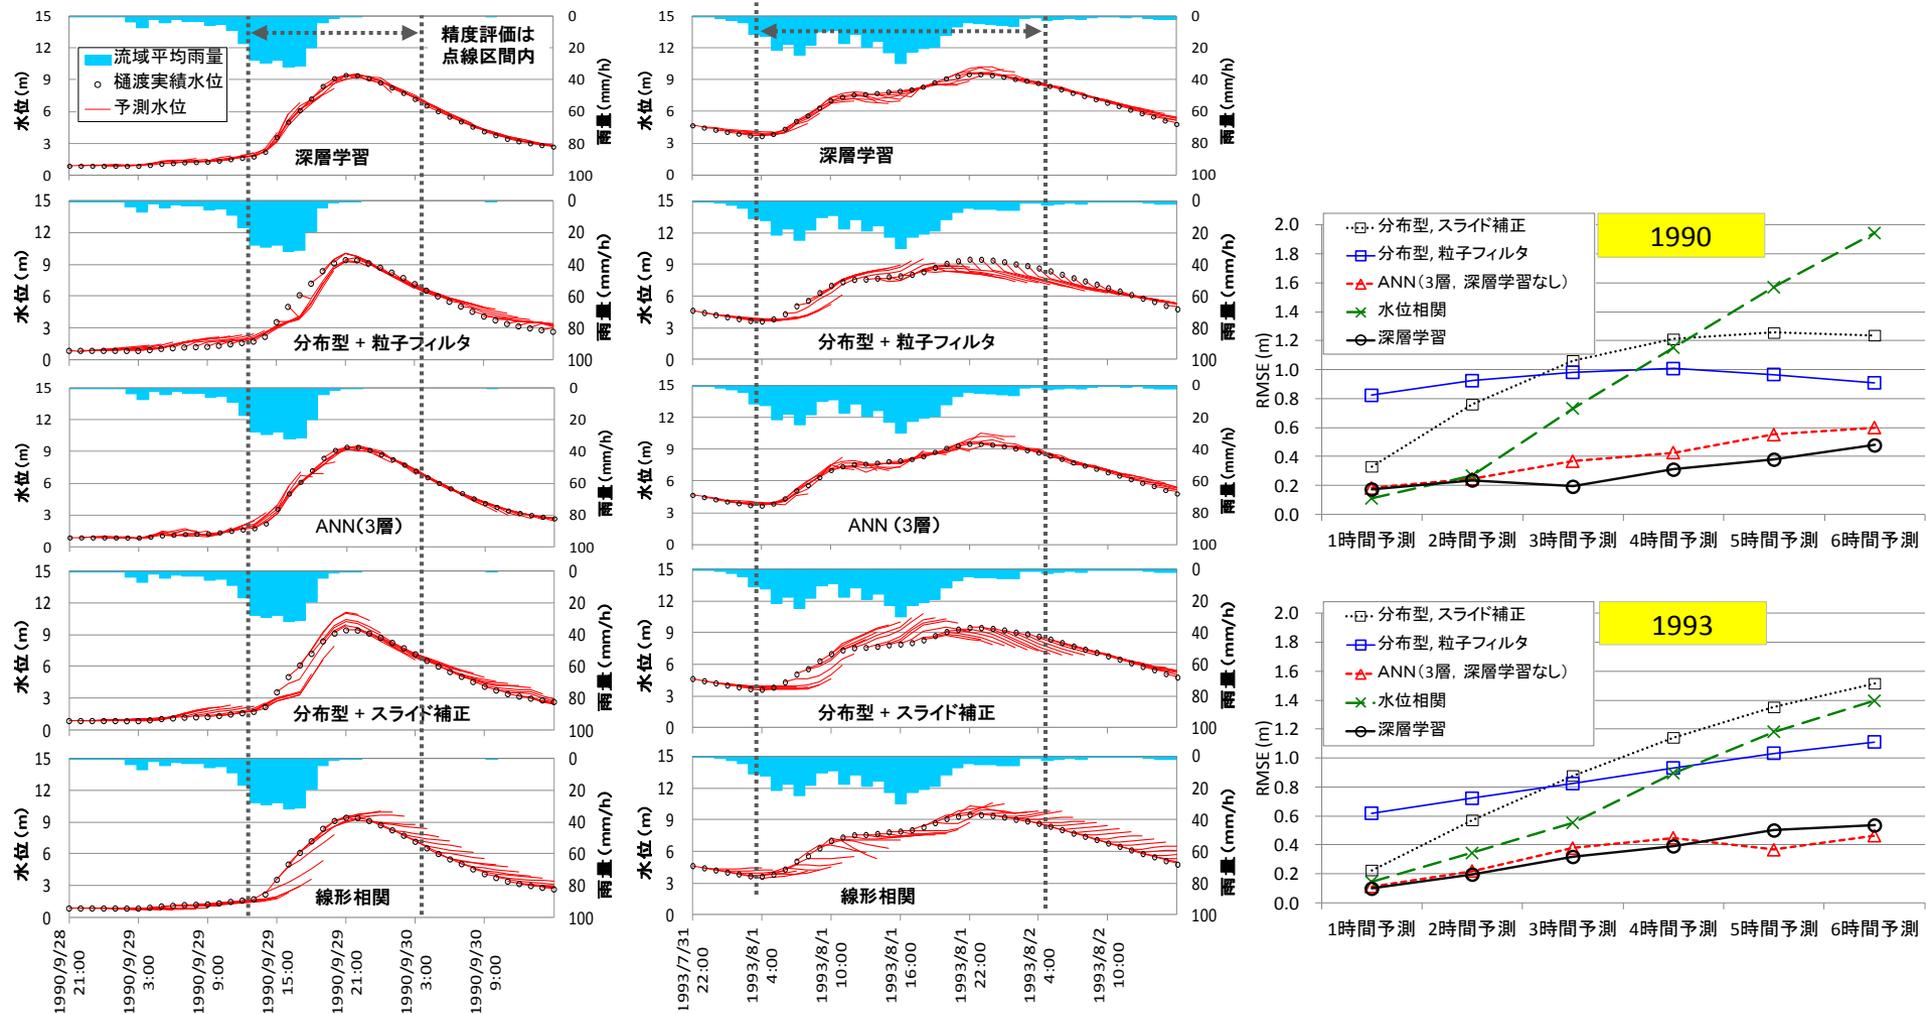
③線形回帰

④分布型 + 粒子フィルタ モデル状態量を粒子フィルタで補正。

⑤分布型 + 誤差スライド 分布型の計算結果に、補正値を上乗せ。
現時刻の（観測水位-計算水位）を補正値とした。

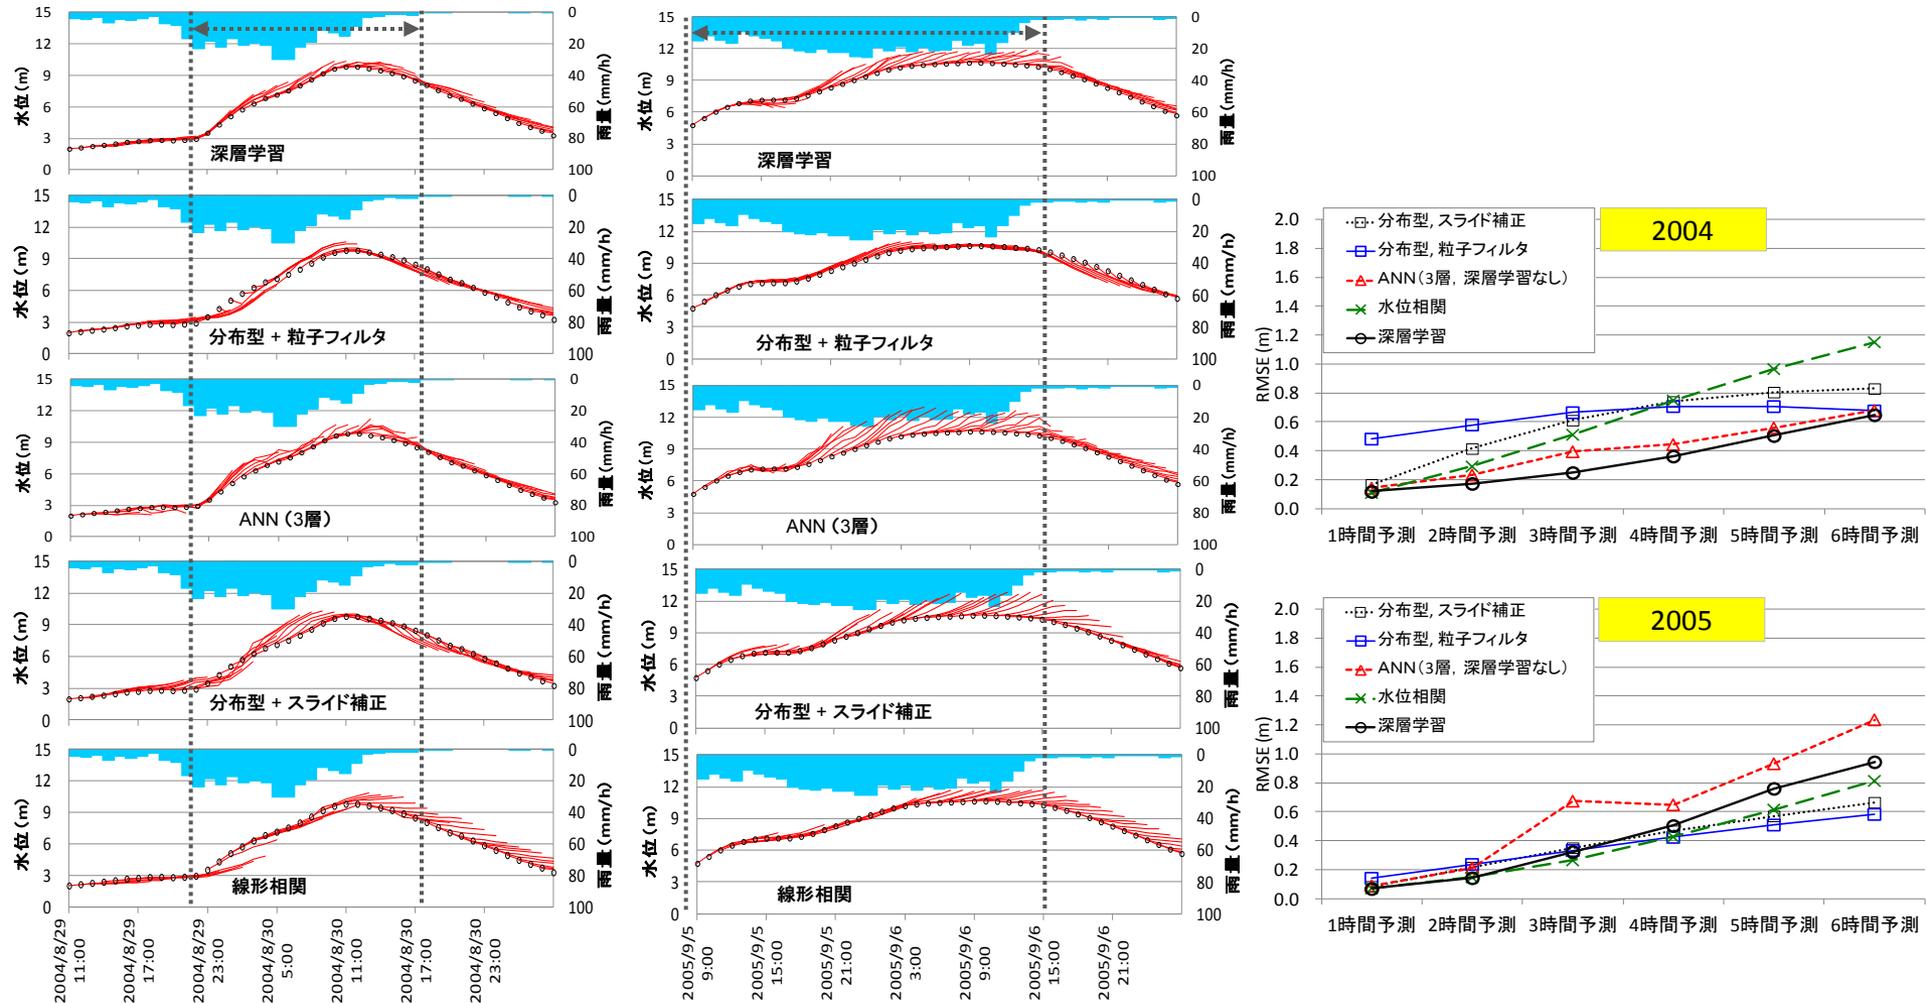


各手法の精度比較 (1990, 1993洪水)



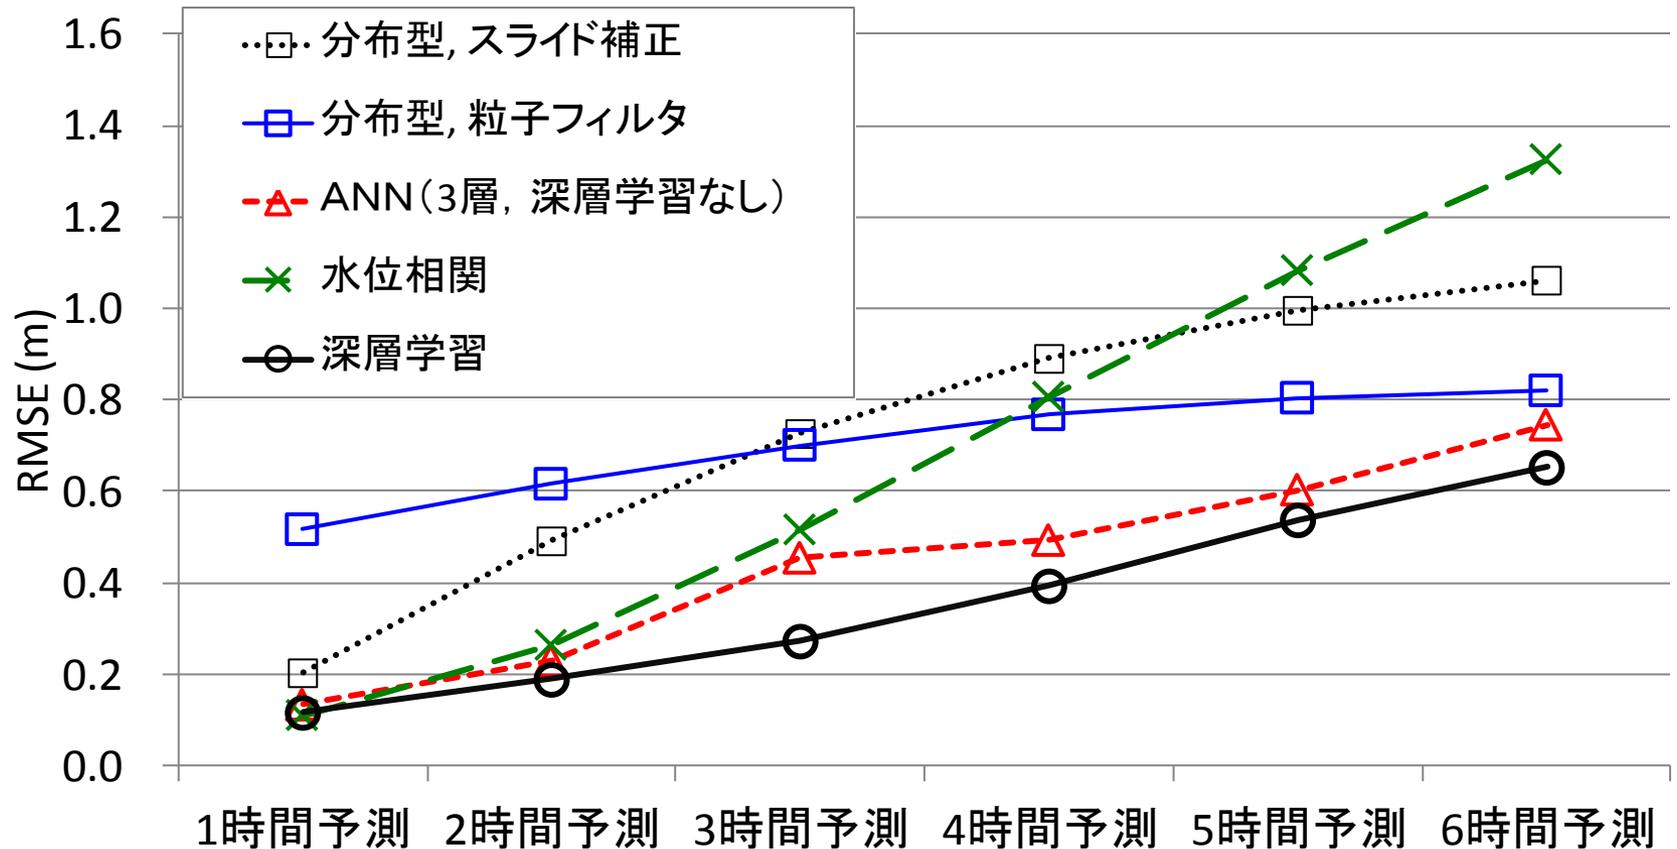
- 1990 : 深層学習が最も良く、ついで3層ANN。分布型、相関モデルは精度悪い。
- 1993 : 深層学習と3層ANNが同程度。分布型、相関モデルは精度悪い。

各手法の精度比較 (2004, 2005洪水)



- 2004 : 深層学習が最も良く、ついで3層ANN。長時間予測では粒子フィルタ
- 2005 : 粒子フィルタが最も良く、他は同程度。3層ANNは精度悪い。

各手法の精度比較 (4洪水平均)

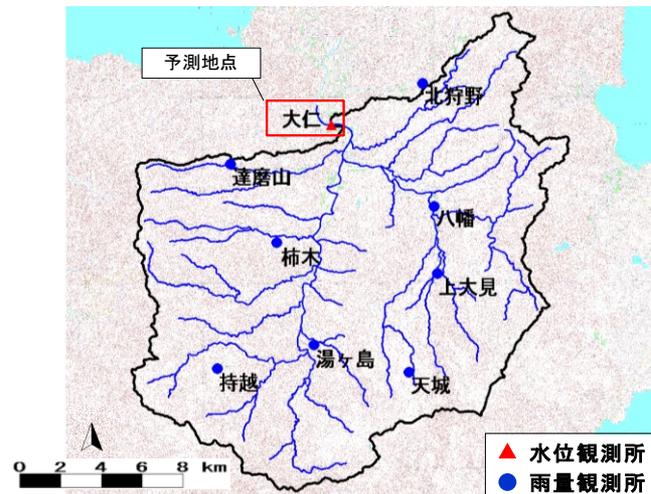
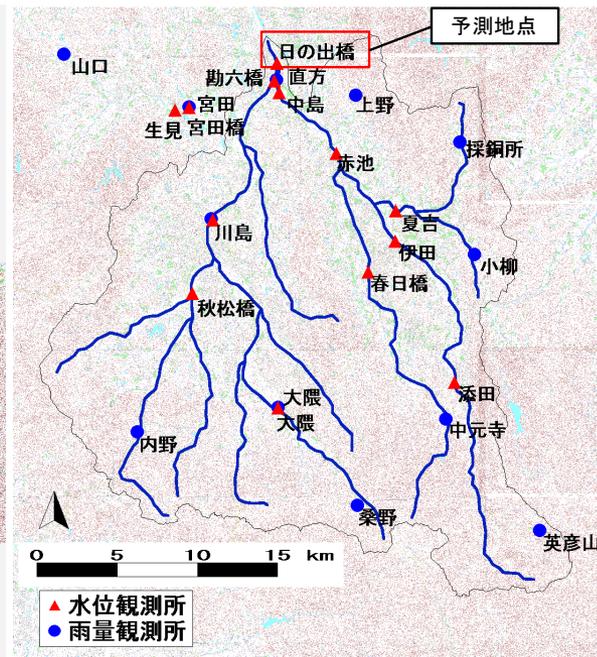
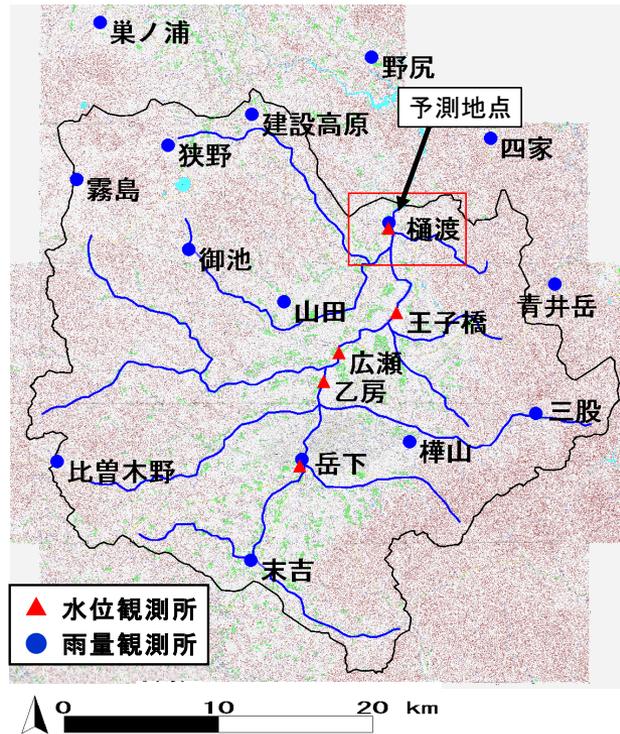


- 1～6時間予測まで、深層学習モデルの精度が最も高い。
- 予測時間が長くなると、分布型（粒子フィルタ）も優位になってくる。

他の検証事例

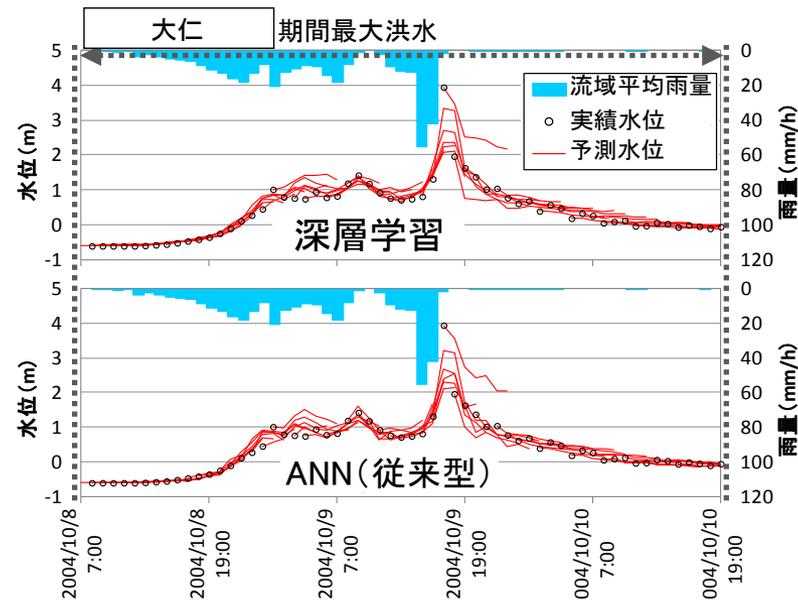
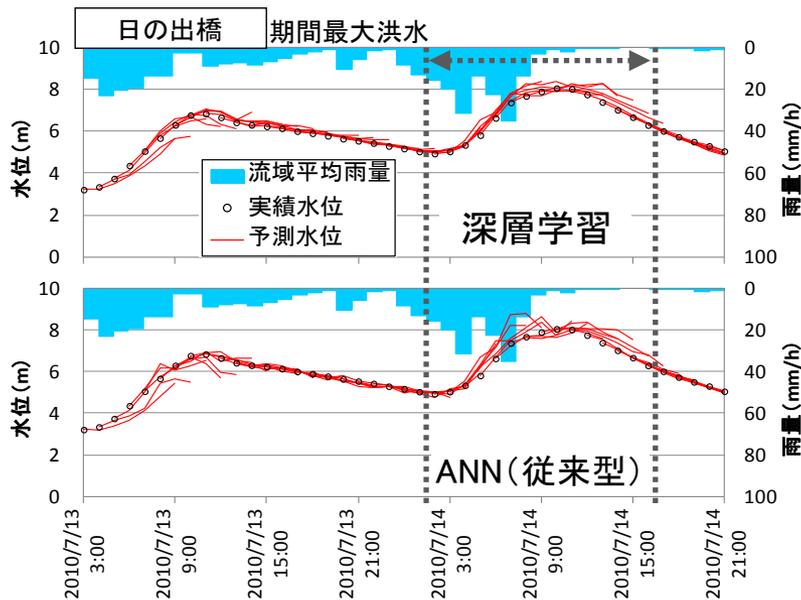
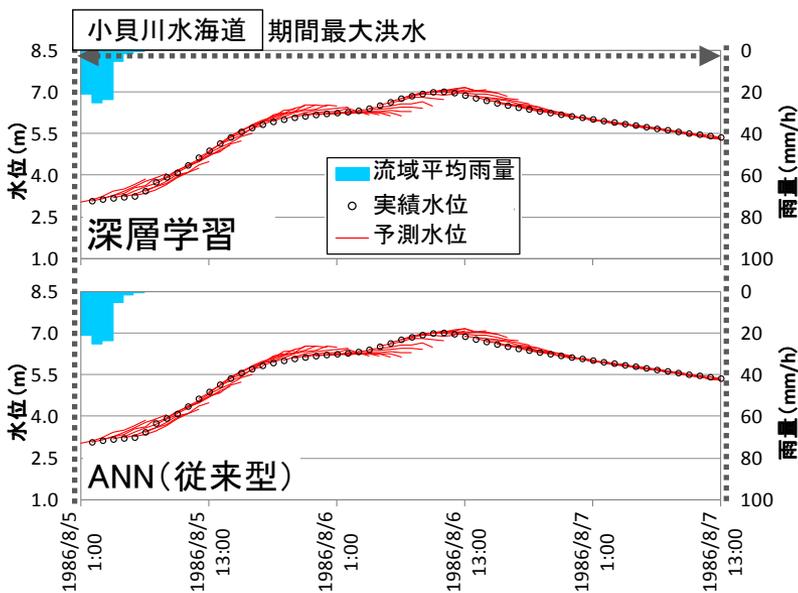
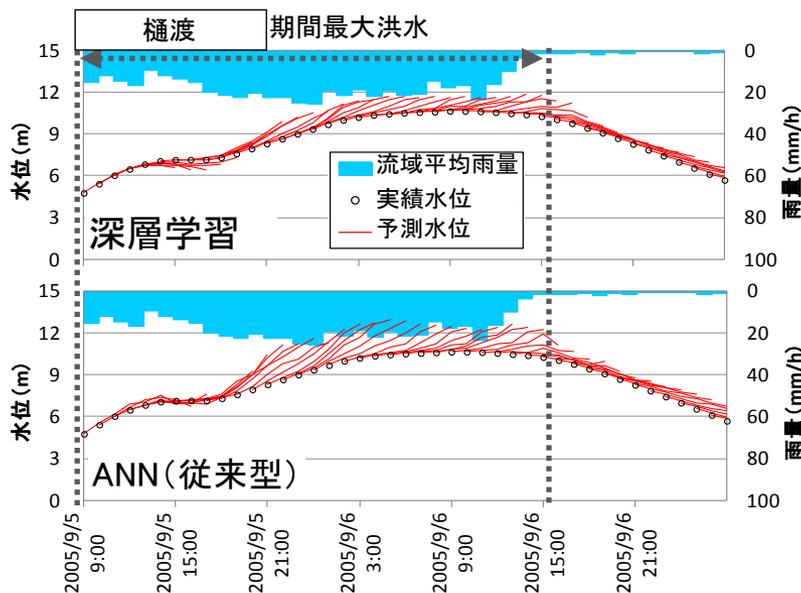
(従来型ANNとディープラーニングの比較)

他流域の事例

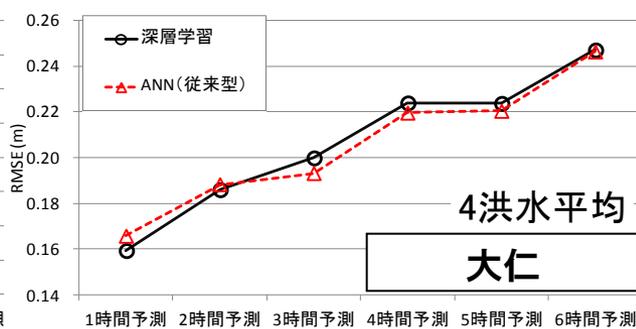
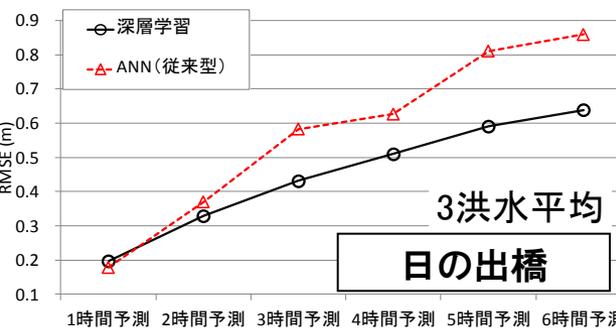
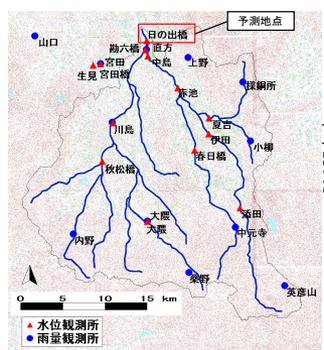
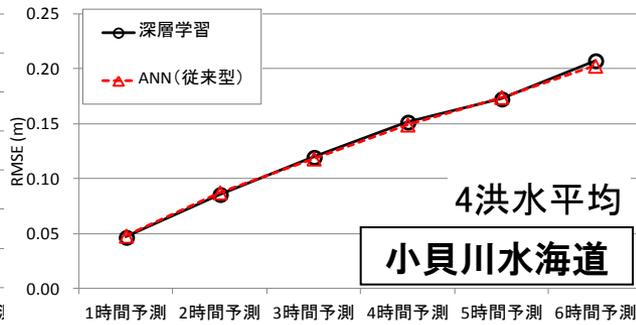
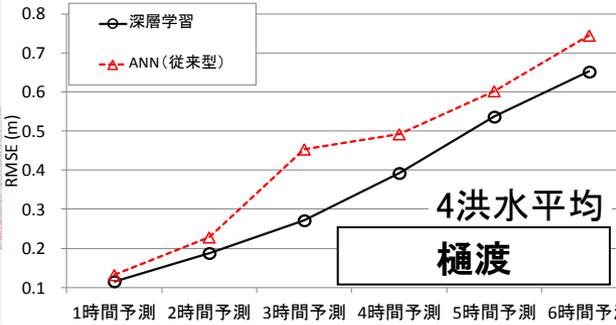
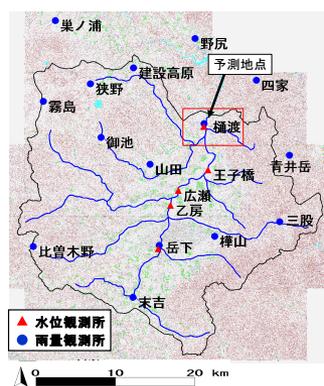


予測地点名	流域名	流域面積	上流の水位観測所数	雨量観測所数
樋渡	大淀川	861.0	4	14
日の出橋	遠賀川	695.0	10	11
小貝川水海道	小貝川	757.5	5	6
大仁	狩野川	322.0	0	8

他流域の事例 (従来型ANNとの比較)



他流域の事例（従来型ANNとの比較）



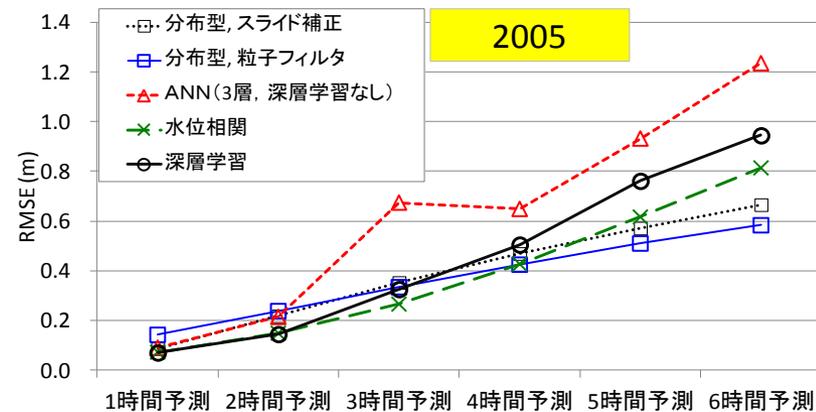
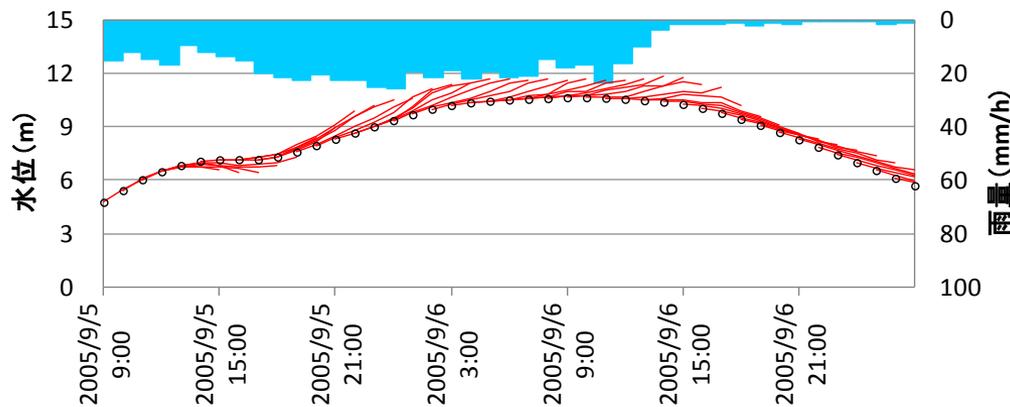
- 複雑な条件（観測データが多数、河道網の形が複雑、等）では、深層学習の効果が高い。
- 単純な条件（観測データが少ない、河道網が単純、等）では、深層学習の効果がでにくい。

発表概要

- ① 人工知能とは？
- ② 機械学習の基礎知識
- ③ ニューラルネットワーク
- ④ 洪水予測への活用例
- ⑤ 深層学習（ディープラーニング）
- ⑥ おわりに

今後の課題

- 期間最大洪水のピーク水位付近で精度低下が見られた。
- ANNを始めとする統計モデルによる予測では、学習経験のない（高水位の）事象に対する適用性が不明とされている。
高水位の予測精度向上は課題として非常に重要。
- 物理型の流出モデルとの組合せにより、入力層を工夫することで、適用性向上の余地がある。



大淀川における、深層学習モデルの計算結果。期間最大の洪水ピーク付近で予測が過大評価、他の手法に比べても精度が劣る。

まとめ、今後に向けて

- ディープラーニングを適用した洪水予測モデルは、他の手法に比べ最も高い精度を示した。
- 人工知能への期待を原動力に、深層学習を中心に技術革新が進んでいる。今後も最新の技術をキャッチしていくとともに、様々な分野への展開を図りたい。
- 現在の取り組み例：
 - 下水道の劣化予測式
 - 高潮のリアルタイム予測モデル
 - 斜面崩壊予測モデル

下水道の劣化予測

公開用劣化DB.xlsx - Microsoft Excel

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S
1	事業分類	自治体種別	管径(mm)	路線延長	取付管本数	スパン内	布設年度	調査年度	経過年数	管種CODE	道路種別	歩車道区	排水種別	土盛り(m)	管の腐食_A	管の腐食_B	管の腐食_C	上下方向	上下方向
2	公共	市H	2700	46.25	10	31	1965	2001	36	18	0	0	0	0	0	0	0	0	0
3	公共	市H	2700	2	2	2	1965	2001	36	2	0	0	0	0	0	0	0	0	0
4	公共	市H	2700	34	2	16	1965	2001	36	2	0	0	0	0	0	0	0	0	0
5	公共	市H	2700	14.58	1	10	1965	2001	36	2	0	0	0	0	0	0	0	0	0
6	公共	市H	2250	140.4	12	94	1971	2001	30	2	0	0	0	0	0	0	0	0	0
7	公共	市H	2250	90.2	10	61	1994	2001	7	2	0	0	0	0	0	0	0	0	0
8	公共	市H	2250	9.45	2	7	1994	2001	7	2	0	0	0	0	0	0	0	0	0
9	公共	市H	2700	20.6	1	10	1969	2001	32	2	0	0	0	0	0	0	0	0	0
10	公共	市H	2700	3.3	1	2	1969	2001	32	2	0	0	0	0	0	0	0	0	0
11	公共	市H	2700	56.1	0	38	1963	2001	38	2	0	0	0	0	0	0	0	0	0
12	公共	市H	2250	46.5	15	31	1966	2001	35	2	0	0	0	0	0	0	0	0	0
13	公共	市H	2400	75.6	23	51	1966	2001	35	2	0	0	0	0	0	0	0	0	0
14	公共	市H	2400	69.5	22	47	1966	2001	35	2	0	0	0	0	0	0	0	0	0
15	公共	市H	2400	21.4	4	14	1965	2001	36	2	0	0	0	0	0	0	0	0	0
16	公共	市H	2400	44.65	12	30	1965	2001	36	2	0	0	0	0	0	0	0	0	0
17	公共	市H	2700	109.1	19	69	1965	2001	36	2	0	0	0	0	0	0	0	0	0
18	公共	市H	1100	44.3	10	18	1972	2001	29	2	0	0	0	0	0	0	0	0	0
19	公共	市H	1100	76.2	0	31	1971	2001	30	2	0	0	0	0	0	0	0	0	0
20	公共	市H	1100	57.2	0	23	1971	2001	30	6	0	0	0	0	0	0	0	0	0
21	公共	市H	1100	16	4	7	1971	2001	30	7	0	0	0	0	0	0	0	0	0
22	公共	市H	1100	5.8	0	2	1971	2001	30	8	0	0	0	0	0	0	0	0	0
23	公共	市H	1100	13	3	5	1971	2001	30	9	0	0	0	0	0	0	0	0	0
24	公共	市H	1100	23	0	9	1971	2001	30	9	0	0	0	0	0	0	0	0	0
25	公共	市H	1100	73.6	0	30	1971	2001	30	10	0	0	0	0	0	0	0	0	0
26	公共	市H	1100	50.5	0	20	1971	2001	30	11	0	0	0	0	0	0	0	0	0
27	公共	市H	1100	32.2	0	12	1971	2001	30	12	0	0	0	0	0	0	0	0	0
28	公共	市H	1500	19.1	4	8	1971	2001	30	12	0	0	0	0	0	0	0	0	0
29	公共	市H	1500	18.3	2	7	1971	2001	30	13	0	0	0	0	0	0	0	0	0
30	公共	市H	1500	31.75	5	13	1971	2001	30	14	0	0	0	0	0	0	0	0	0
31	公共	市H	1500	17.8	3	7	1971	2001	30	15	0	0	0	0	0	0	0	0	0
32	公共	市H	1500	30.1	9	13	1971	2001	30	15	0	0	0	0	0	0	0	0	0
33	公共	市H	1100	38.6	7	16	1971	2001	30	16	0	0	0	0	0	0	0	0	0
34	公共	市H	1100	94.9	27	40	1971	2001	30	16	0	0	0	0	0	0	0	0	0
35	公共	市H	1100	75.6	6	31	1971	2001	30	18	0	0	0	0	0	0	0	0	0
36	公共	市H	1350	94.6	24	39	1971	2001	30	19	0	0	0	0	0	0	0	0	0
37	公共	市H	1500	92.3	18	38	1971	2001	30	20	0	0	0	0	0	0	0	0	0
38	公共	市H	1500	67.3	19	28	1970	2001	31	21	0	0	0	0	0	0	0	0	0
39	公共	市H	1500	102.4	26	43	1970	2001	31	21	0	0	0	0	0	0	0	0	0
40	公共	市H	1100	50.6	20	21	1971	2001	30	22	0	0	0	0	0	0	0	0	0
41	公共	市H	1100	2.2	0	1	1971	2001	30	23	0	0	0	0	0	0	0	0	0
42	公共	市H	1100	35.85	16	15	1971	2001	30	24	0	0	0	0	0	0	0	0	0
43	公共	市H	1100	33.9	13	13	1971	2001	30	25	0	0	0	0	0	0	0	0	0
44	公共	市H	1100	23.8	8	10	1971	2001	30	26	0	0	0	0	0	0	0	0	0
45	公共	市H	1500	35.25	8	14	1971	2001	30	27	0	0	0	0	0	0	0	0	0
46	公共	市H	1500	70.9	21	29	1971	2001	30	28	0	0	0	0	0	0	0	0	0
47	公共	市H	1500	1.8	0	1	1971	2001	30	28	0	0	0	0	0	0	0	0	0
48	公共	市H	1500	81.5	6	33	1971	2001	30	28	0	0	0	0	0	0	0	0	0
49	公共	市H	1500	87	16	36	1971	2001	30	28	0	0	0	0	0	0	0	0	0

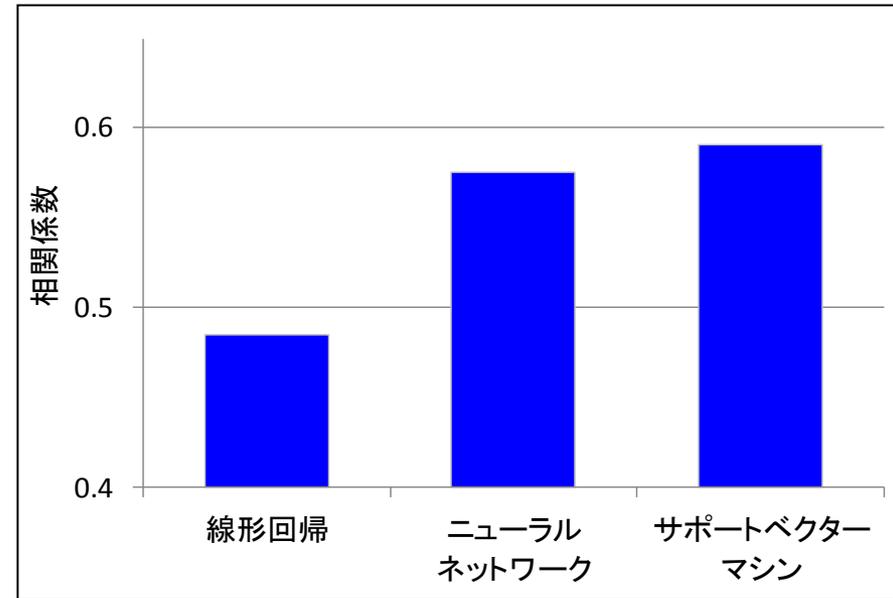
公開用劣化DB.xlsx - Microsoft Excel

劣化DB テーブル仕様書

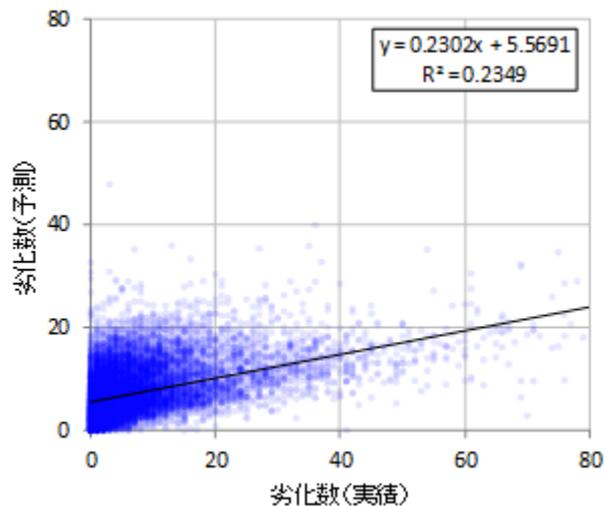
列番号	項目名称	タイプ	サイズ	項目説明
A	事業分類	テキスト型	255	公共：公共下水道
B	自治体種別	テキスト型	255	政令市、市、町村の別及び自治体仮名称（アルファベット）
C	管径(mm)	テキスト型	255	管径・形状
D	路線延長(m)	数値型	倍精度浮動型	路線延長
E	スパン内の管本数	数値型	倍精度浮動型	スパン内の管本数
F	布設年度（西暦）	数値型	長整数型	布設年度を西暦で統一
G	調査年度（西暦）	数値型	長整数型	調査年度を西暦で統一
H	経過年数	数値型	長整数型	経過年数（調査年度（西暦）－布設年度（西暦））
I	管種CODE	数値型	長整数型	管種コード（1:陶管、2:コンクリート管、3:塩ビ管、空白:その他）
J	取付管本数	数値型	長整数型	スパン内の取付管本数
K	道路種別	テキスト型	255	国県市道等の区分
L	歩車道区部	テキスト型	255	歩車道の区分
M	排水種別	テキスト型	255	分合流の区分
N	土盛り(m)	数値型	倍精度浮動型	土盛り（上流側と下流側の平均値）
O	管の腐食_A	数値型	長整数型	調査結果
P	管の腐食_B	数値型	長整数型	調査結果
Q	管の腐食_C	数値型	長整数型	調査結果
R	上下方向のたるみ_A	数値型	長整数型	調査結果
S	上下方向のたるみ_B	数値型	長整数型	調査結果
T	上下方向のたるみ_C	数値型	長整数型	調査結果
U	管の破損_a	数値型	長整数型	調査結果
V	管の破損_b	数値型	長整数型	調査結果
W	管の破損_c	数値型	長整数型	調査結果
X	管のクラック_a	数値型	長整数型	調査結果

下水道の劣化予測

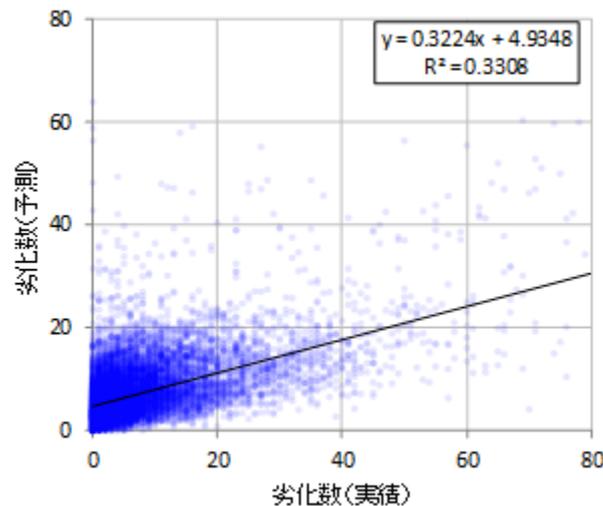
説明変数	目的変数
管径(mm)	<u>劣化数の合計</u>
路線延長(m)	管の腐食
取付管本数	上下方向のたるみ
スパン内の管本数	管の破損
経過年数	管のクラック
土被り(m)	管の継手ズレ
	浸入水
	取付け管の突出し
	樹木根侵入



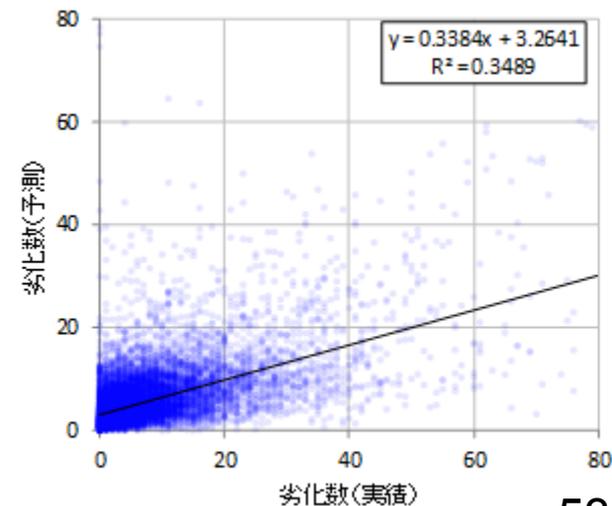
線形回帰



ニューラルネットワーク



サポートベクターマシン



高潮のリアルタイム予測

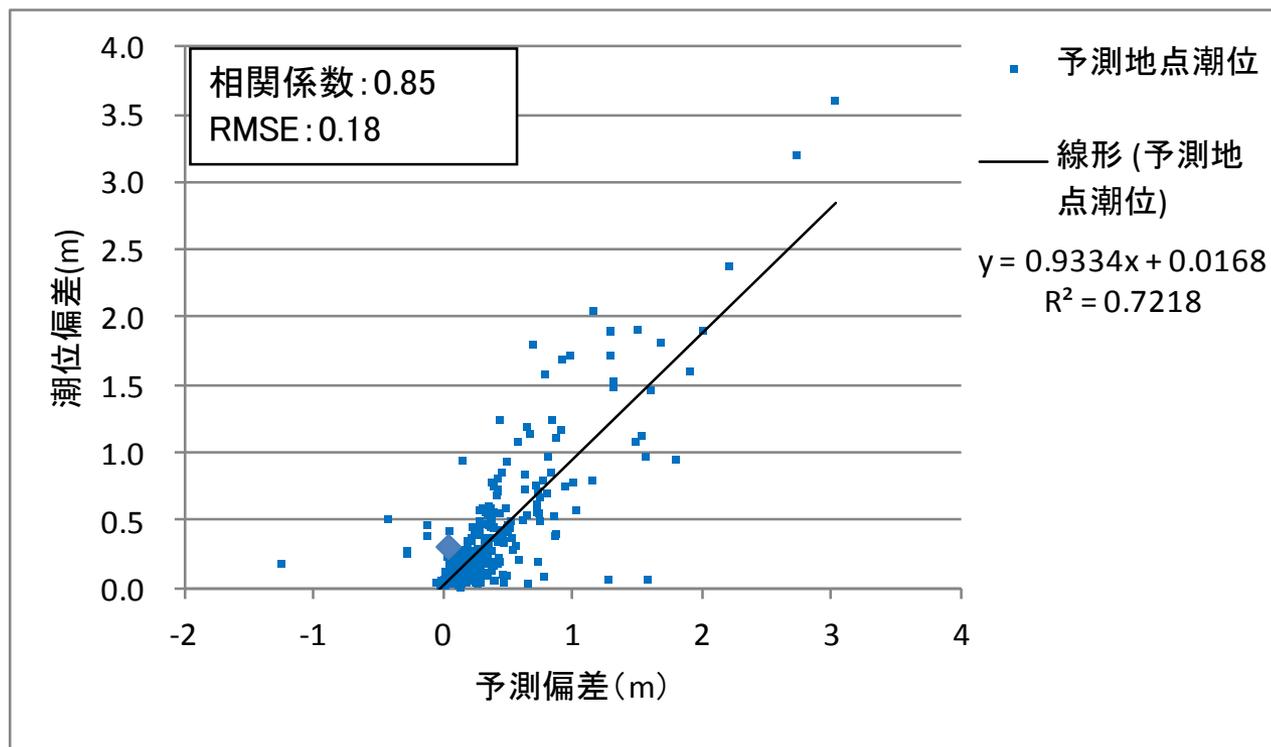
説明変数

目的変数

気圧
台風との距離
位置(東西南北)

予測地点の
潮位偏差

過去の**大量のシミュレーション結果**を**学習**して、台風情報から瞬時に高潮潮位をリアルタイムに予測する。



斜面崩壊の予測

図の出典：六甲砂防事務所webページ
<http://www.kkr.mlit.go.jp/rokko/disaster/history/h26/h26-index.php>

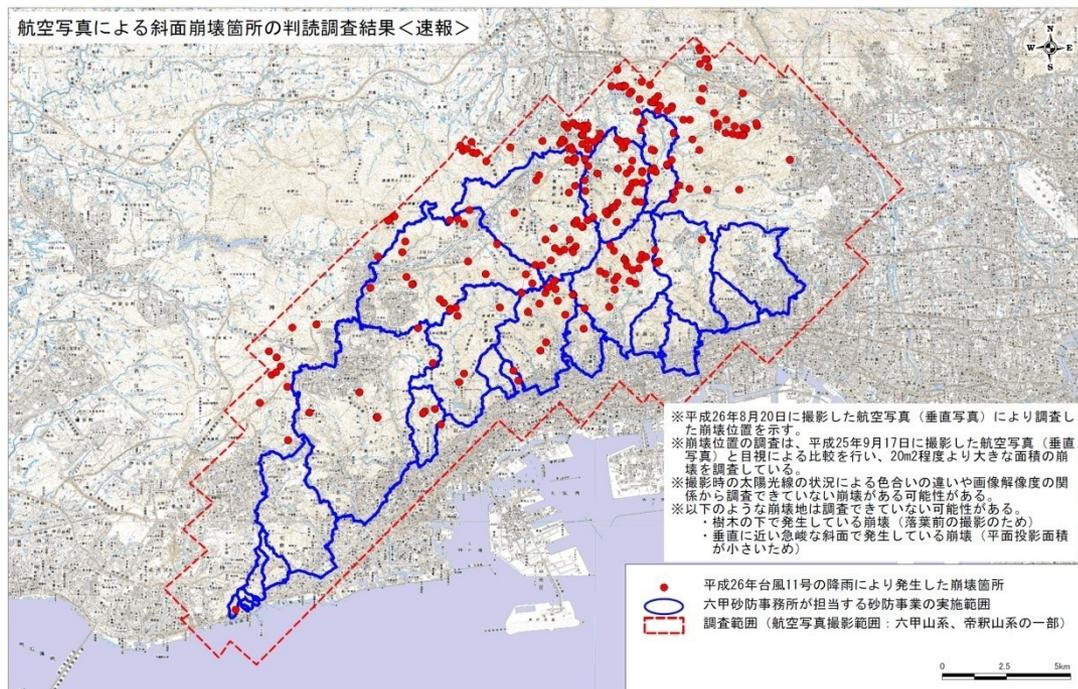
説明変数

目的変数

累積雨量
 雨量強度
 斜面勾配
 地質
 植生
 集水面積
 地形因子
 ...

斜面崩壊の
 有無

過去の斜面崩壊履歴を学習して、降雨状況による崩壊の有無をリアルタイムに予測する。



この地図は、国土地理院発行の数値地図50000（地図画像）『須磨』、『大坂西南部』、『神戸』、『大坂西北部』、『三田』を使用したものである。

以上
ご静聴ありがとうございました

参考文献

一言正之：ニューラルネットワークと物理型モデルを用いた実時間洪水予測の精度向上に関する研究,東京大学博士論文, 2016.

一言正之, 櫻庭雅明, 清雄一：深層学習を用いた河川水位予測手法の開発, 水工学論文集, Vol.60, 2016.

一言正之, 櫻庭雅明：深層学習の適用によるニューラルネットワーク洪水予測の精度向上, 河川技術論文集, Vol.22, 2016.

杉本泰亮, 一言正之：機械学習を取り入れた下水道管路の劣化予測モデルに関する検討, 第54回土木計画学研究・講演集, 2016