

# INS/GPS/VS 複合航法への 再帰型ニューラルネットワークの応用

立命館大学 理工学研究科  
情報通信システム研究室  
2年 平田 怜央

# 目次

---

## 1. 研究背景

## 2. ニューラルネットワーク

- 再帰型ニューラルネットワーク

## 3. 実験

## 4. 結果

## 5. 考察

## 6. 展望

# 研究背景

## INS

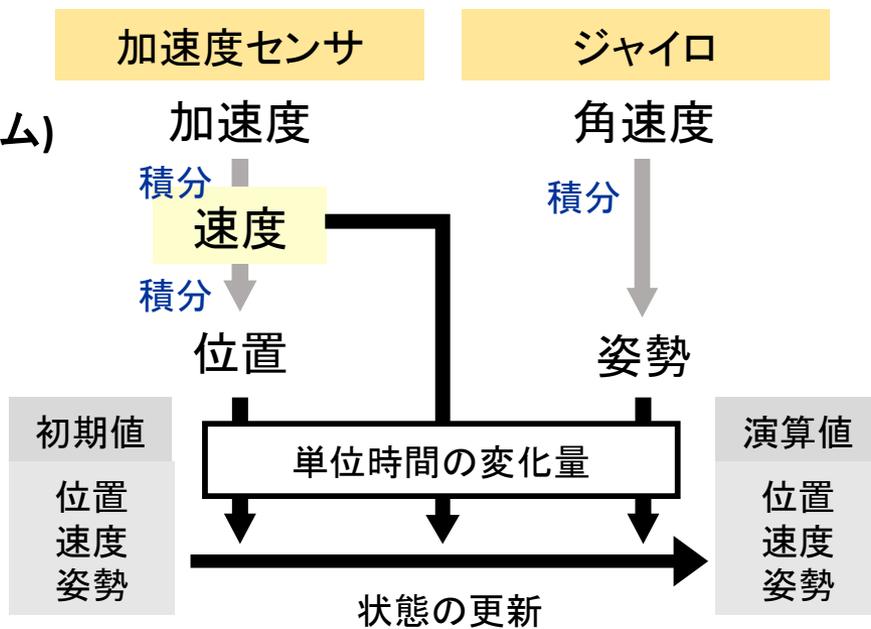
(Inertial Navigation System: 慣性航法システム)

- 外部情報に依存しない
- 高頻度である(50 ~ 100 [Hz])
- × 単独での測位で誤差が蓄積してしまう

積分演算の誤差:

慣性センサのもつバイアス

加速度バイアス, ジャイロバイアス



## GPS

- 高精度に位置測位が可能
- × 都市やトンネルなどでは利用できない



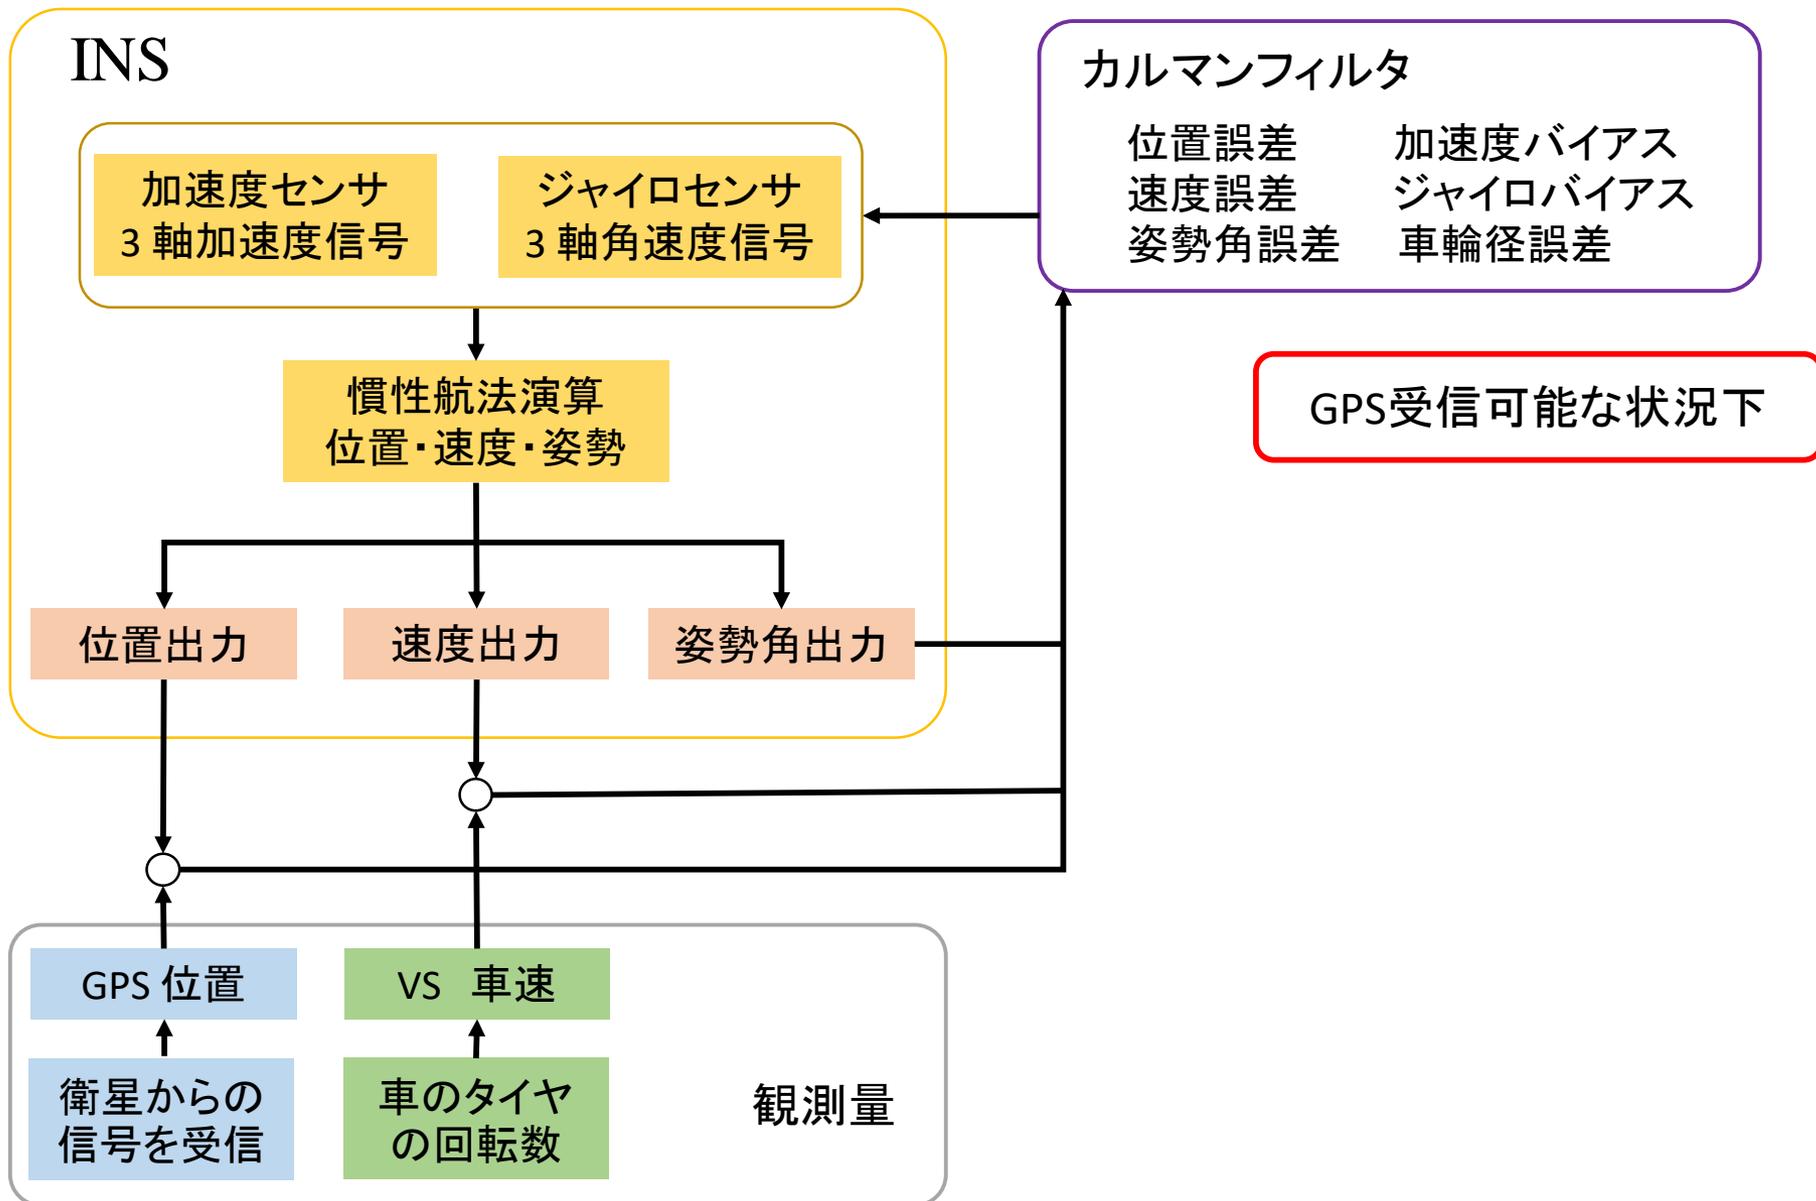
## VS (Vehicle Speed)



高精度 & 高頻度 & 自律性  
INS/GPS/VS 複合航法

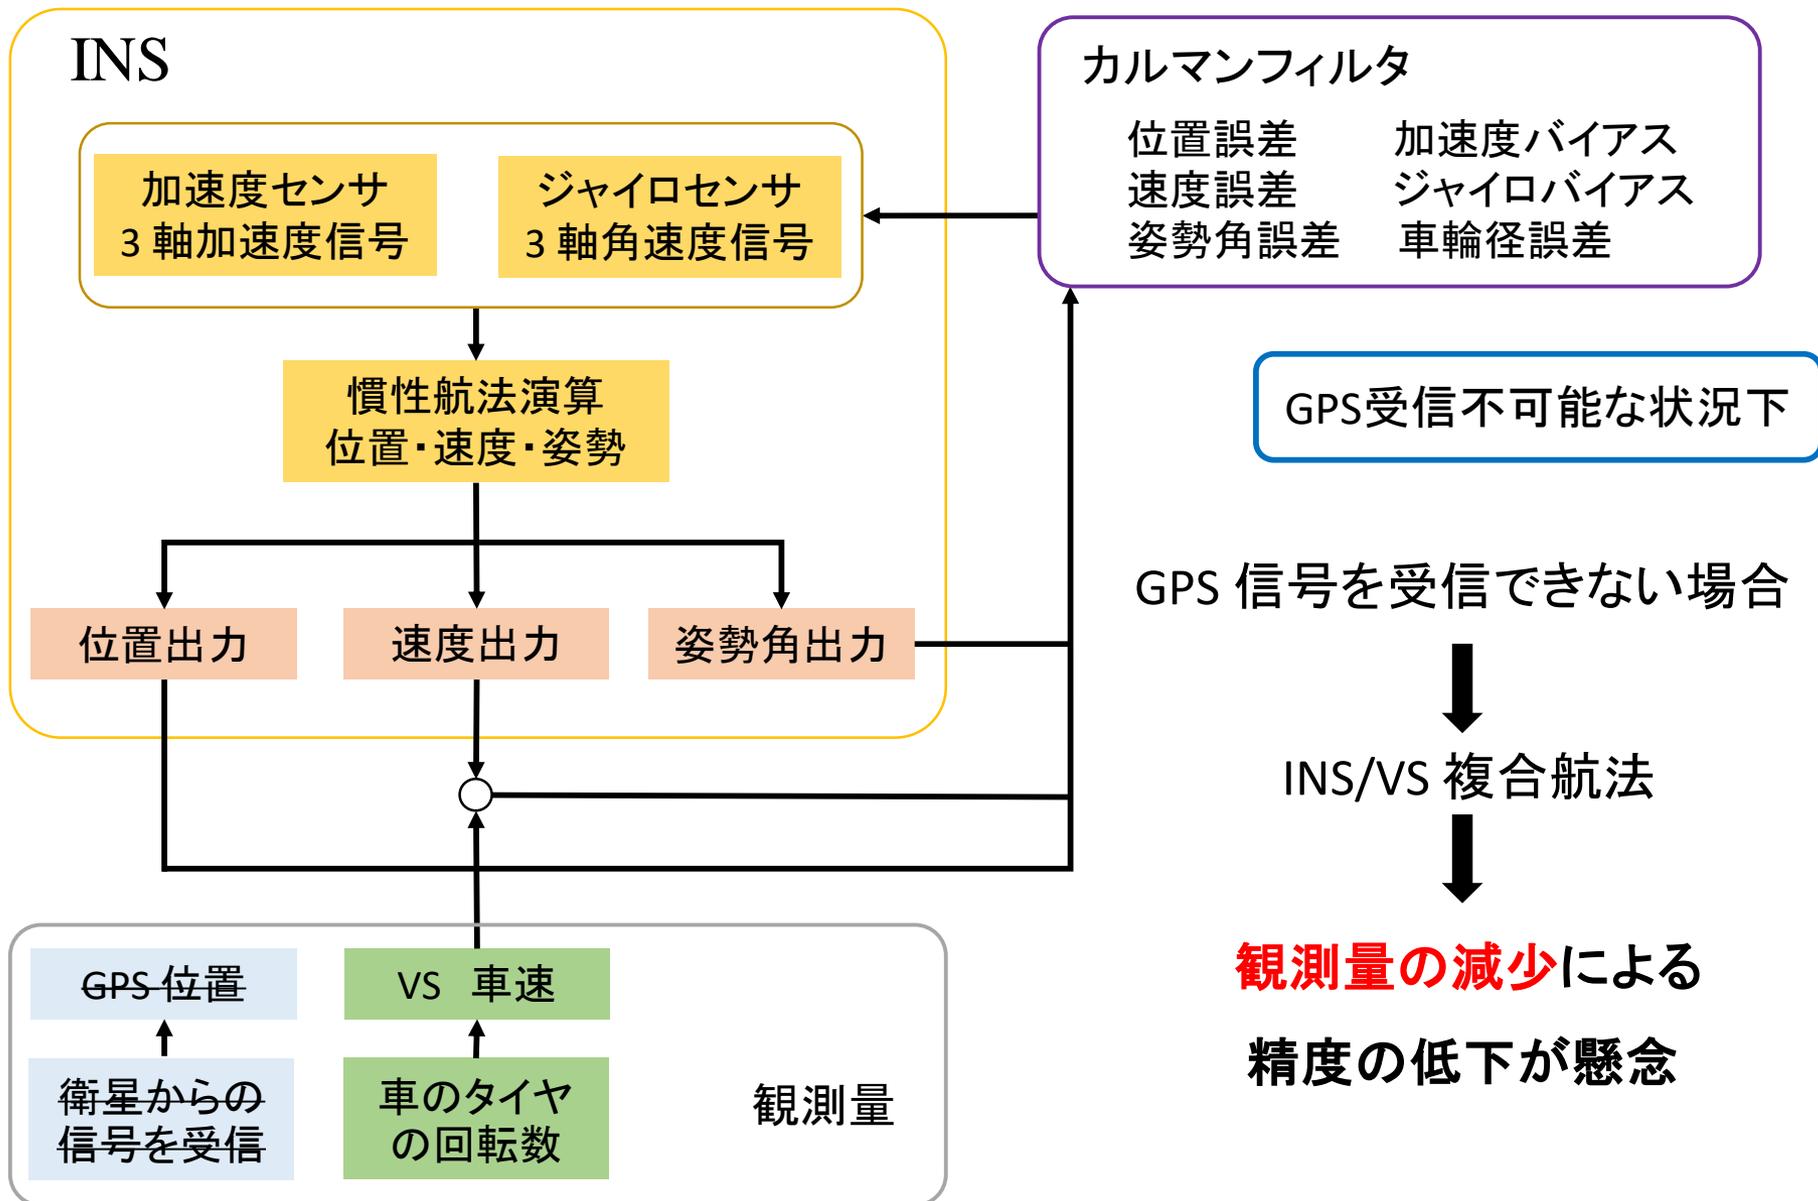
# 研究背景

— INS/GPS/VS 複合航法のシステム構成 —



# 研究背景

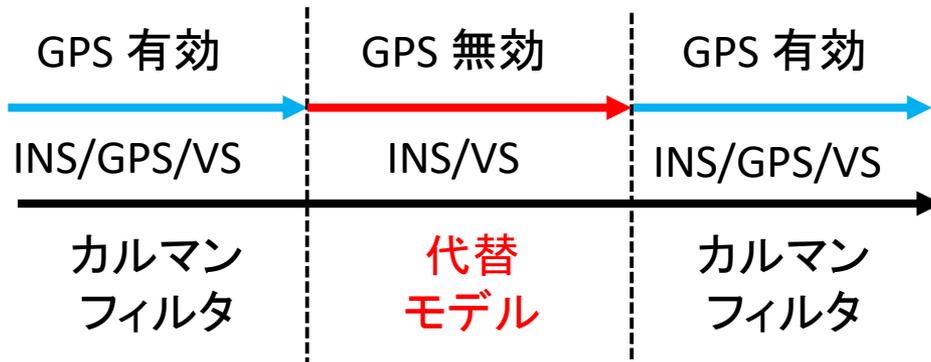
— INS/GPS/VS 複合航法のシステム構成 —



# 研究背景

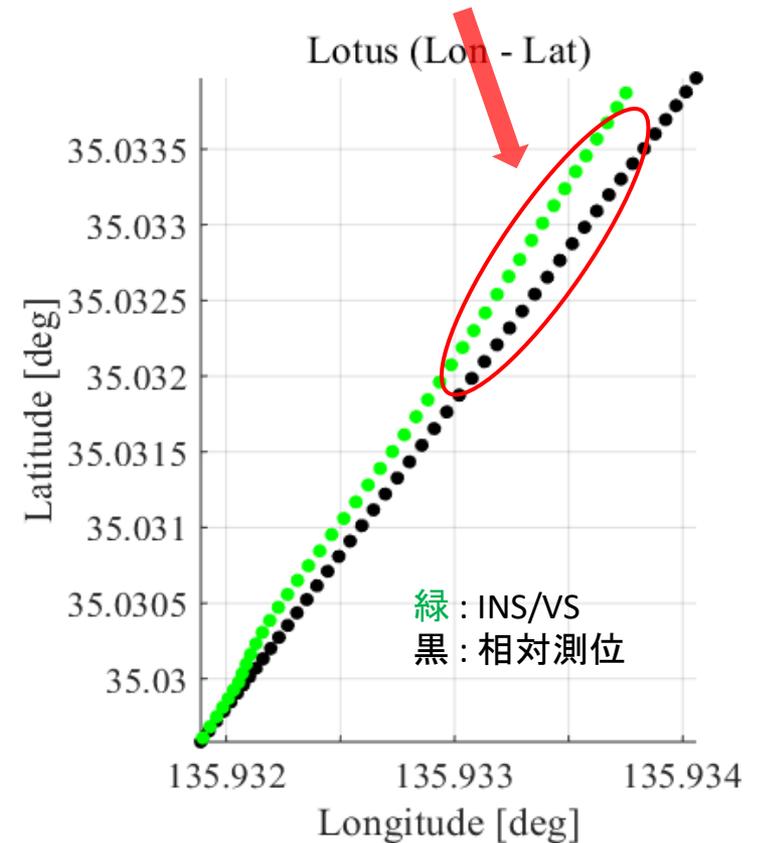
## GPS無効の測位精度

INS/GPS/VS複合航法に比べて劣化する。  
(INS単独の測位からは改善)



ニューラルネットワークでモデルを学習,  
精度の向上を目指す

精度の低下



INS/VS 複合航法と相対測位位置の軌跡の例

# 研究背景

## カルマンフィルター

複数の情報源の統合によるシステムにおいて  
未知の推定値を求めることに用いられる

GPS/INS/VS複合航法において  
**INS 航法誤差**を補正する

既知の誤差モデル  
(位置誤差, 速度誤差, 姿勢角誤差方程式)

- モデリングできない  
(状態量の時間的相関など)
- ガウス性でない  
(マルチパス)
- 機器ごとに異なる特性

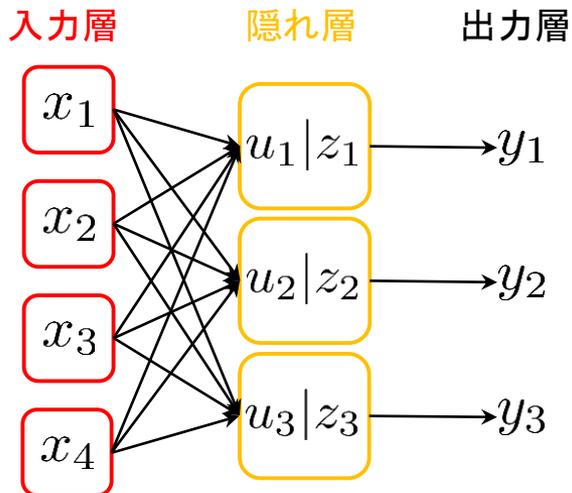
未知の誤差要因で精度低下

## ニューラルネットワークを用いて測位モデルを学習

- ニューラルネットワークの隠れ層によって未知の誤差源をモデル化
  - ・非ガウス性の誤差の発生源を捕捉
  - ・より複雑な誤差モデルに対応
- 再帰型によるネットワーク構築
  - ・長期的な状態の相関の算出
  - ・時間的に深いネットワークによる表現力の向上

# ニューラルネットワーク

脳機能をコンピュータ上で表現する数学モデル  
情報が入力側から出力側に伝搬



- ニューラルネットワーク基本形

$$u_j = \sum_{i=1}^I w_{ji} x_i + b_j$$

$$z_j = f(u_j)$$

- ベクトル表記

$$\mathbf{u} = \mathbf{w}\mathbf{x} + \mathbf{b}$$

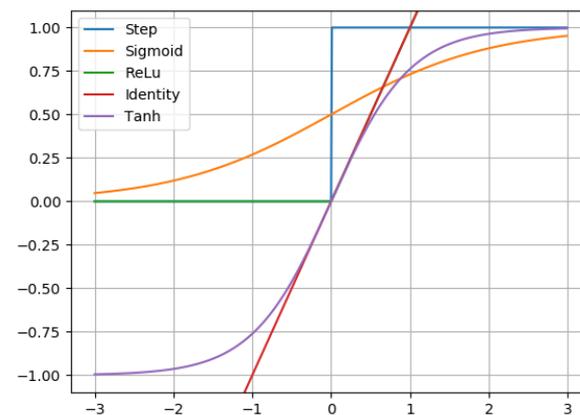
$$\mathbf{z} = \mathbf{f}(\mathbf{u})$$

$w$  : 重みパラメータ  
 $b$  : バイアス

$f(u)$  : 活性化関数

ニューラルネットワークにおいて、  
値がある閾値を超えると  
出力値が大きくなるような関数

ステップ関数 (Step)  
シグモイド関数 (Sigmoid)  
正規化線形関数 (ReLU)  
恒等関数 (identity)  
双曲線正接関数 (tanh)



活性化関数の例

# ニューラルネットワーク

## ニューラルネットワークが扱う問題の種別

- **回帰**

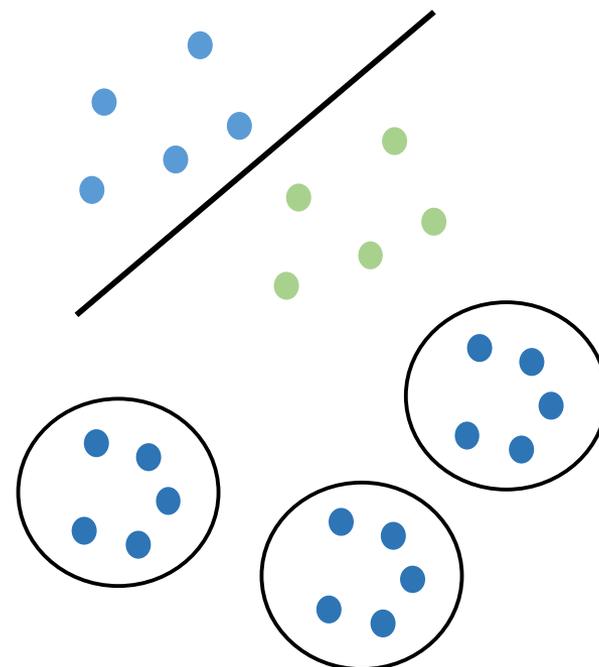
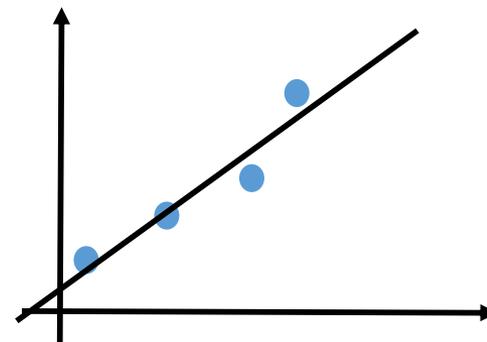
データを入力する → 数値を出力する  
出力が連続値をとる, 次の状態予測

- **分類**

データを入力する → 属性または種類を出力する  
入力を複数に区別する, 画像認識等

- **クラスタリング**

データを入力する → グルーピング結果を出力する  
入力をグループに区別する, データ整理等



# 勾配降下法

- 誤差関数を最小化する(極小値を求める)

$$E(\mathbf{w}) = \frac{1}{2} \sum_{n=1}^N \|\mathbf{d}_n - \mathbf{y}(\mathbf{x}_n; \mathbf{w})\|^2$$

$\mathbf{d}$  : 目標値  $\mathbf{y}$  : 出力

- 誤差関数の勾配

$$\nabla E \equiv \frac{\partial E}{\partial \mathbf{w}} = \left[ \frac{\partial E}{\partial w_1} \cdots \frac{\partial E}{\partial w_M} \right]^T$$

- パラメータ更新

$$\mathbf{w}_{new} = \mathbf{w}_{old} - \mu \nabla E$$

学習率パラメータ:  $\mu$  ( $0 < \mu < 1$ )

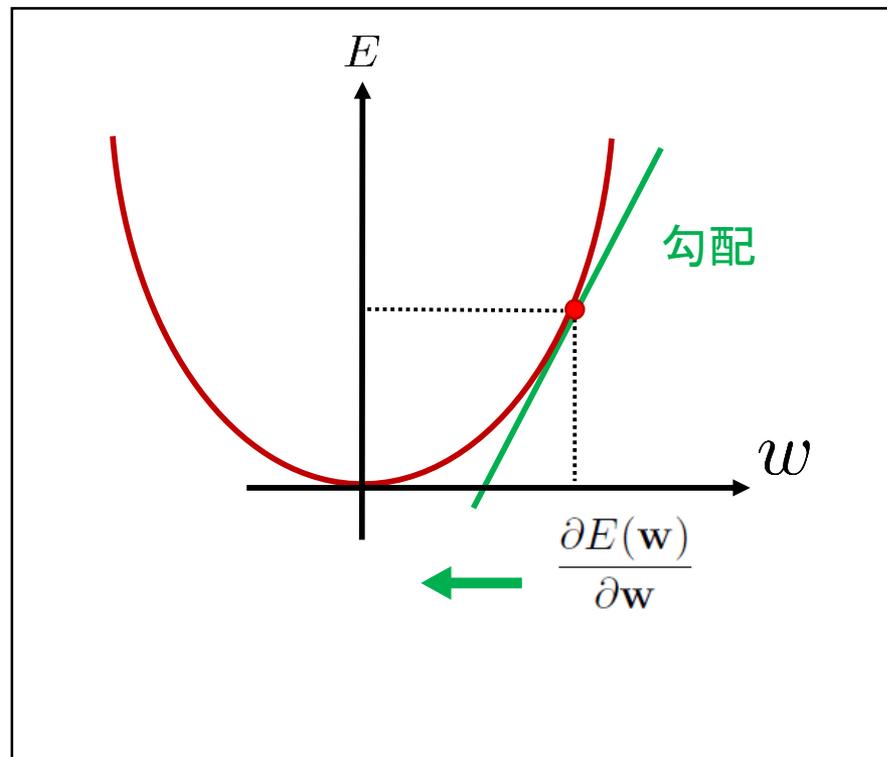
極小解が複数ある場合, 確率的に  
局所解にはまる可能性がある



- 確率的勾配降下法 (SGD)

$$\mathbf{w}_{new} = \mathbf{w}_{old} - \mu \nabla E_n$$

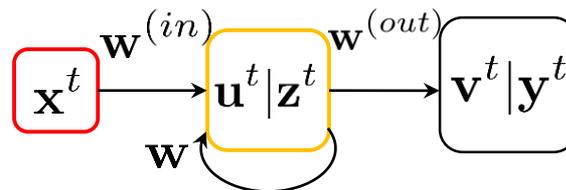
使用するサンプルを取り換えながら更新し  
局所解にはまることを防ぐ.



パラメータ例

# 再帰型ニューラルネットワーク(RNN)

- 内部に帰還路を持つ
  - 情報の記憶, ネットワークの動的変化
- 並びに意味を持つデータに対して利用
  - 現在の状態は過去の状態に影響を受ける
- 過去の入力から1つの出力への写像



活性化関数

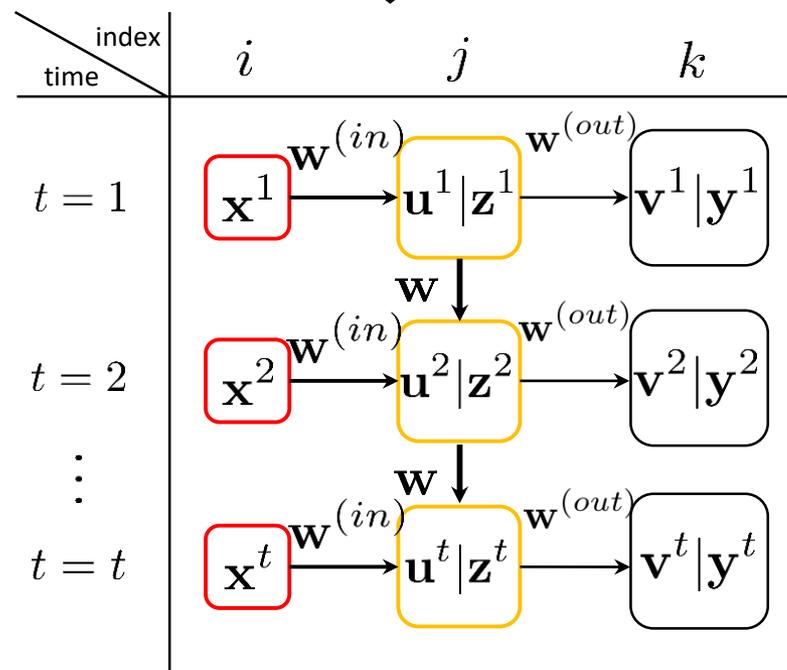
時間方向への展開

$$u_j^t = \underbrace{\sum_i w_{ji}^{(in)} x_i^t}_{\text{重み * 現在の入力}} + \underbrace{\sum_{j'} w_{jj'} z_{j'}^{t-1}}_{\text{重み * 1つ前の状態}}$$

$$z_j^t = f(u_j^t)$$

$$v_k^t = \sum_j w_{kj}^{(out)} z_j^t$$

$$y_k^t = f^{(out)}(v_k^t)$$



# RNN 入力物理量

## 1. INS の位置更新式    2. INS の速度補正式

$$\dot{\lambda} = \frac{v_n}{R_M + h}$$

$$\dot{\varphi} = \frac{v_e}{(R_N + h) \cos \lambda}$$

$$\begin{bmatrix} v_n \\ v_e \\ v_d \end{bmatrix} = \begin{bmatrix} v'_n \\ v'_e \\ v'_d \end{bmatrix} + \begin{bmatrix} a_N \\ a_E \\ a_D \end{bmatrix} - \boldsymbol{\Omega} \begin{bmatrix} v'_n \\ v'_e \\ v'_d \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \\ g \end{bmatrix} \times \Delta T$$

## 3. 加速度座標変換

$$\begin{bmatrix} a_N \\ a_E \\ a_D \end{bmatrix} = C_b^n \begin{bmatrix} a_x \\ a_y \\ a_z \end{bmatrix} = \begin{bmatrix} C_{11} & C_{12} & C_{13} \\ C_{21} & C_{22} & C_{23} \\ C_{31} & C_{32} & C_{33} \end{bmatrix} \begin{bmatrix} a_x \\ a_y \\ a_z \end{bmatrix}$$

## 4. 回転行列生成

$$C_b^n = f(w_x, w_y, w_z)$$

実験	内容	備考, 単位
入力	加速度	機体座標系, 3 軸 [m/s <sup>2</sup> ]
	角速度	機体座標系, 3 軸 [rad/s]
	INS/VS 位置	East, North [m]
	INS/VS 速度	局地座標系, 3 軸 [m/s]
	加速度バイアス	機体座標系, 3 軸 [m/s <sup>2</sup> ]
	ジャイロバイアス	機体座標系, 3 軸 [rad/s]
目標出力	相対測位位置	East, North [m]
出力	位置	East, North [m]

$\lambda$  : 緯度

$\varphi$  : 経度

$h$  : 高度

$v'$  : 前時刻速度

$\Delta T$  : 更新間隔

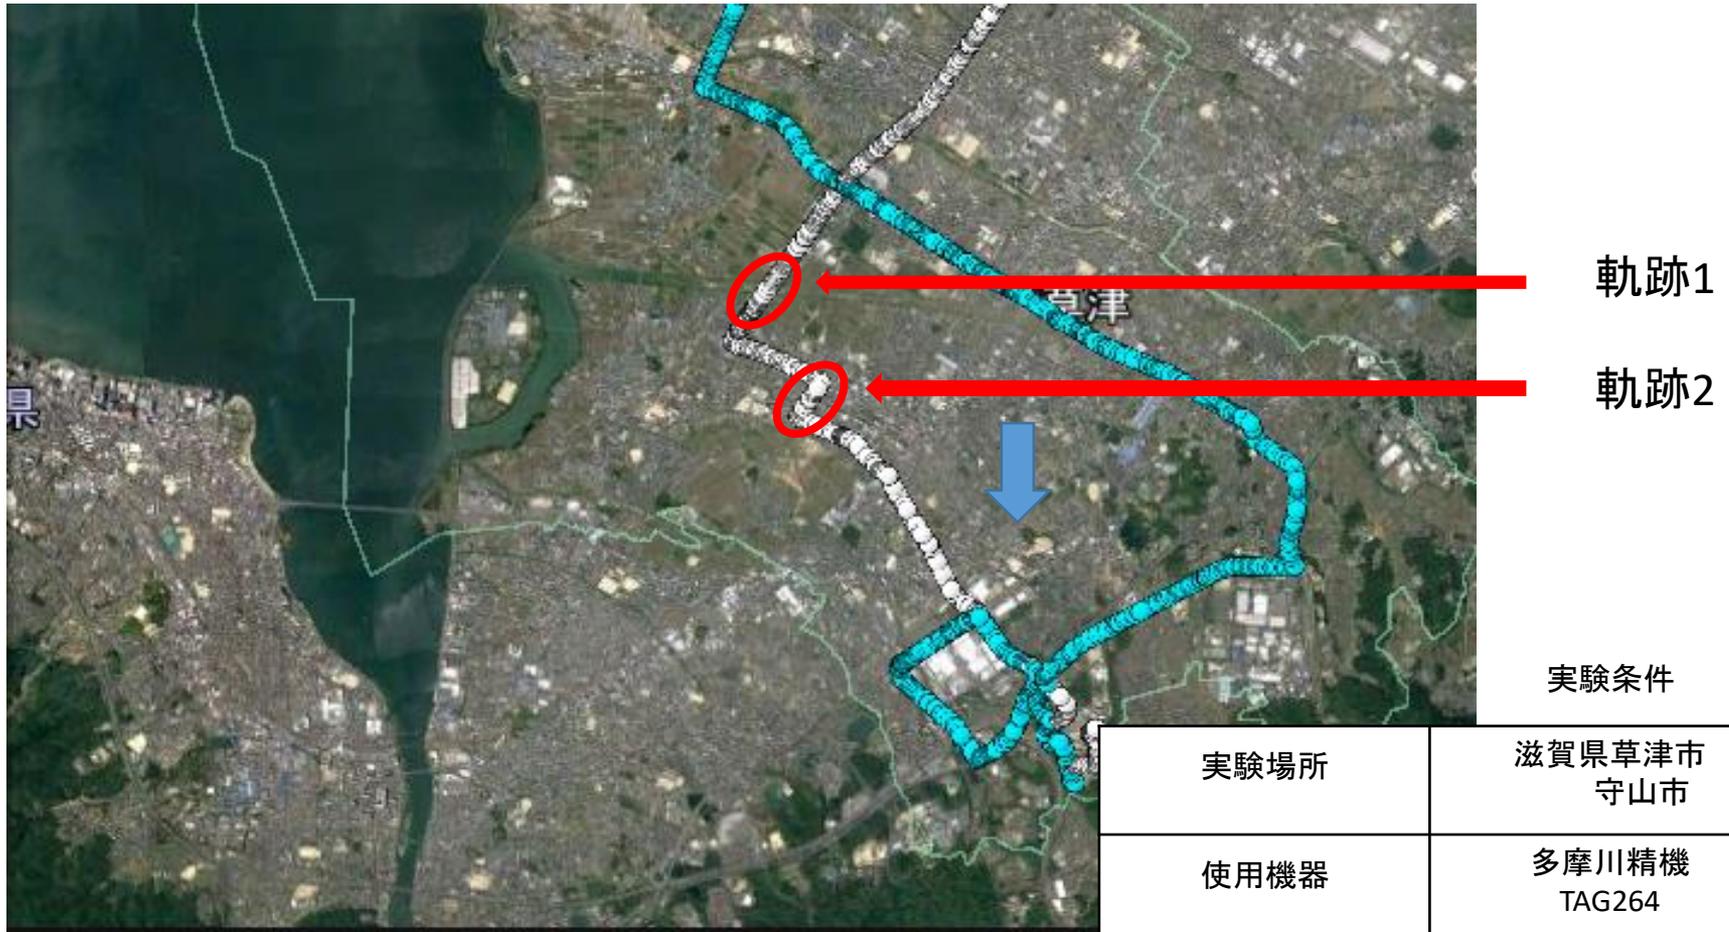
$\boldsymbol{\Omega}$  : コリオリの力による  
角速度ベクトル

$a$  : 加速度

$C_b^n$  : 座標回転行列

$w$  : 角速度

# 実験 (INS/GPS/VS 複合航法)

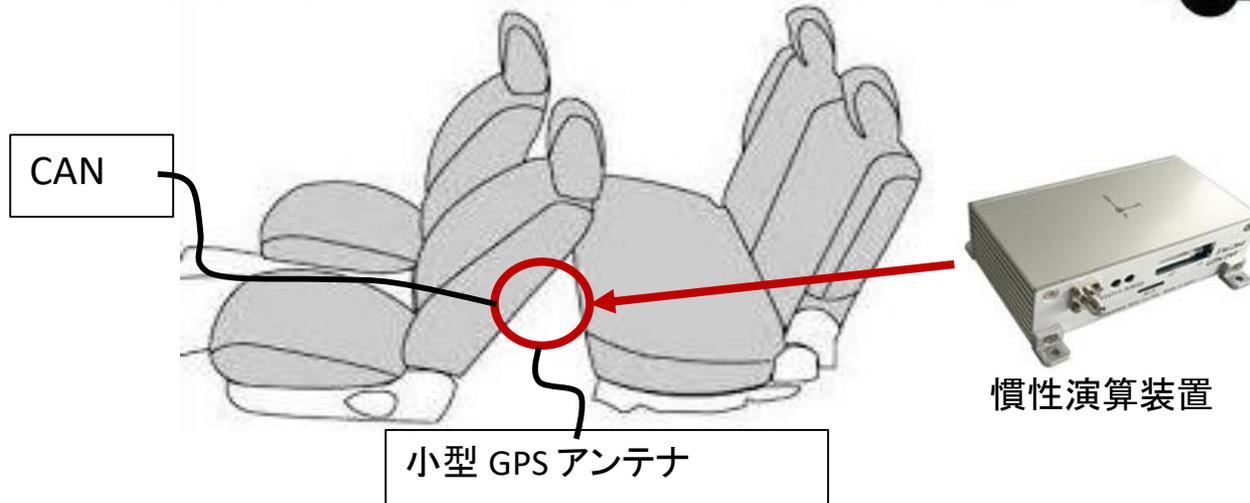


走行ルート例

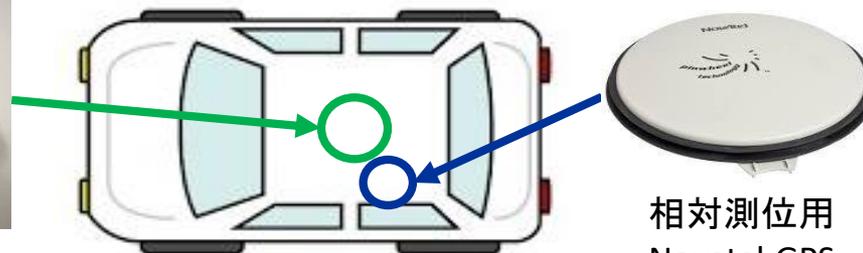
実験場所	滋賀県草津市 守山市
使用機器	多摩川精機 TAG264
データ取得頻度	GPS : 1 [Hz] INS : 100 [Hz]
複合航法出力頻度	1 [Hz]

# 実験条件 (INS/GPS/VS 複合航法)

1. IMU を車の後部座席中央に固定
2. 複合航法用の小型 GPS アンテナを車体上部に設置
3. CAN データ端子にコネクタを接続し VS を取得
4. 相対測位用の GPS アンテナを車体上部中央に設置

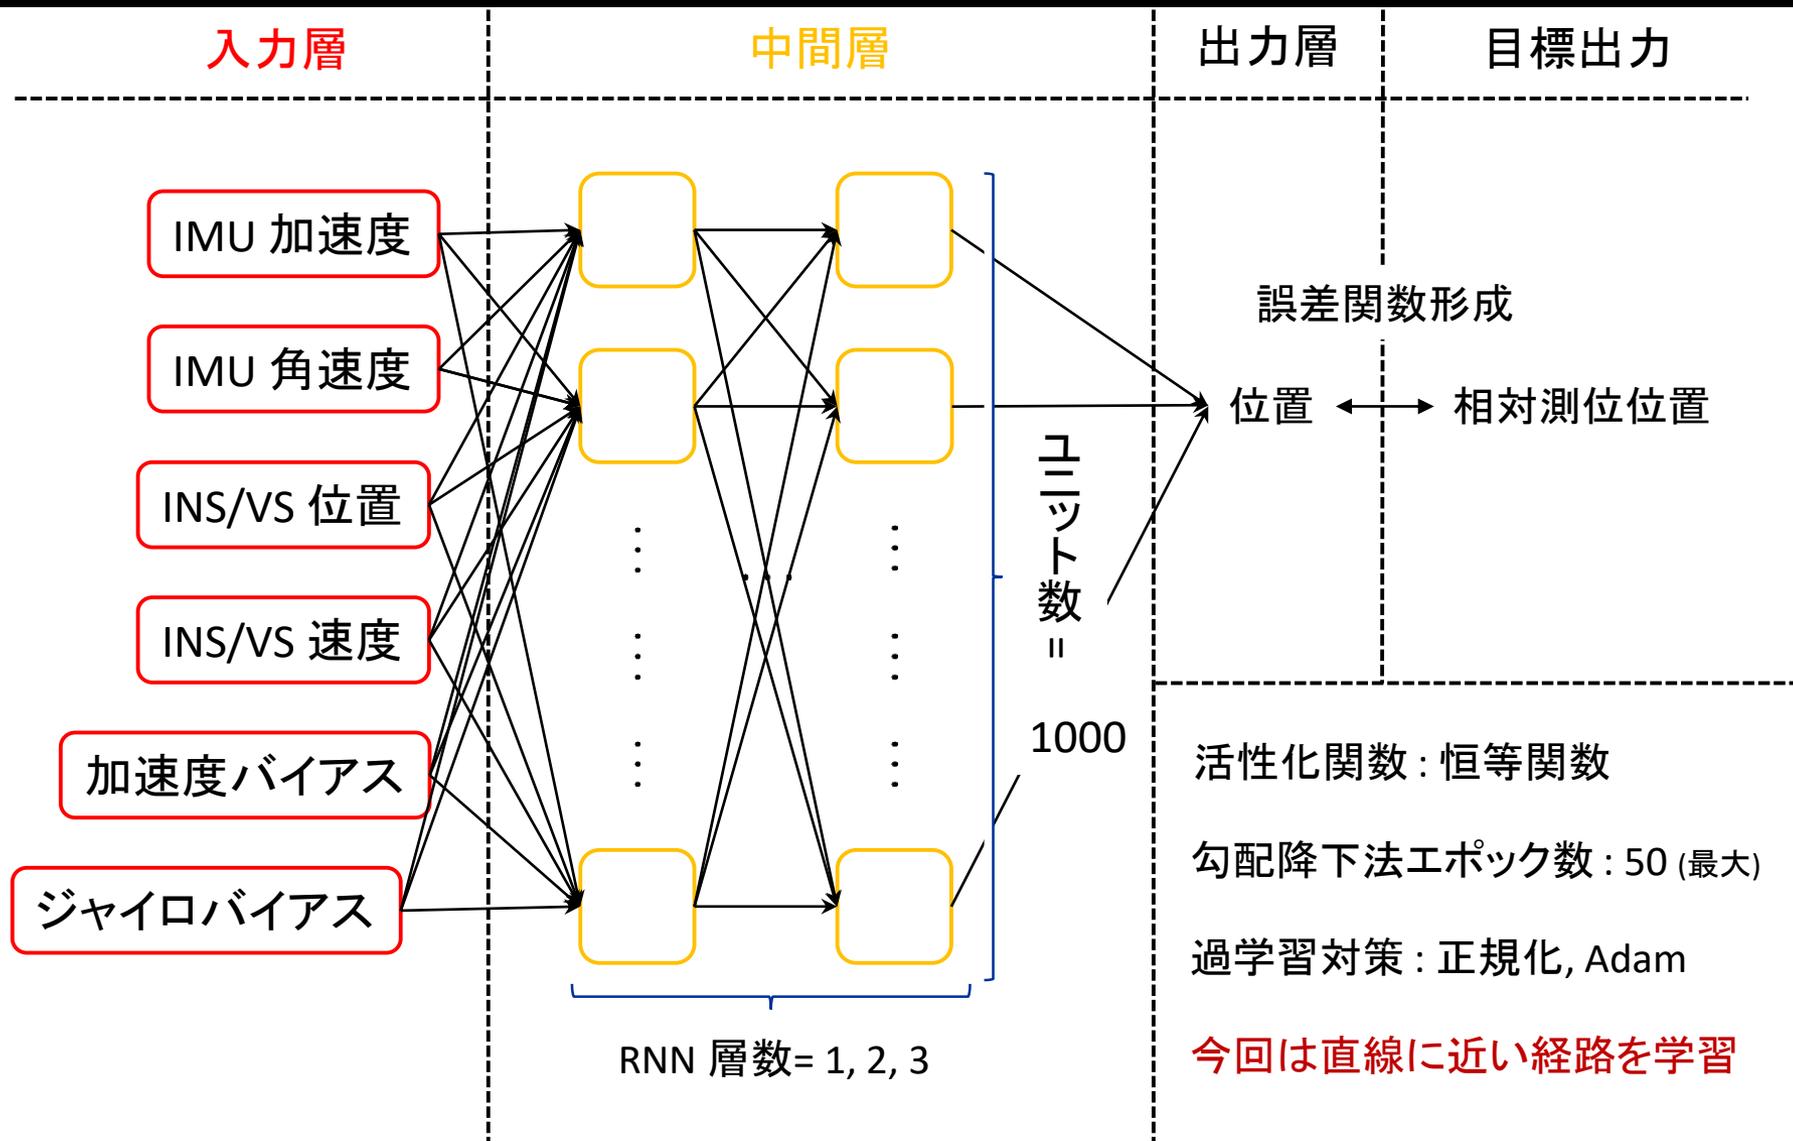


複合航法用  
小型 GPS アンテナ



相対測位用  
Novatel GPS

# 実験条件



# データの前処理

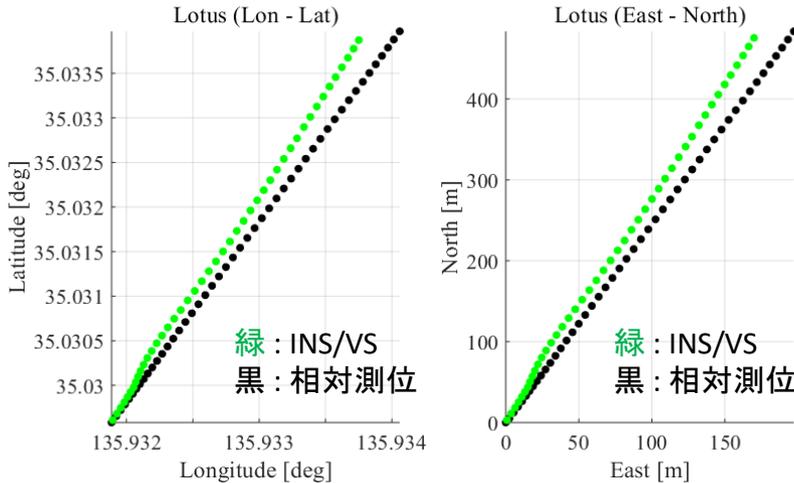
## 1. 位置の座標変換

緯度 : -90 ~ 90 [deg]

データ内での尺度に偏り

経度 : -180 ~ 180 [deg]

→ ENU 座標に変換



使用データ例 : 緯度経度(左) から  
ENU 座標系(右) への座標変換

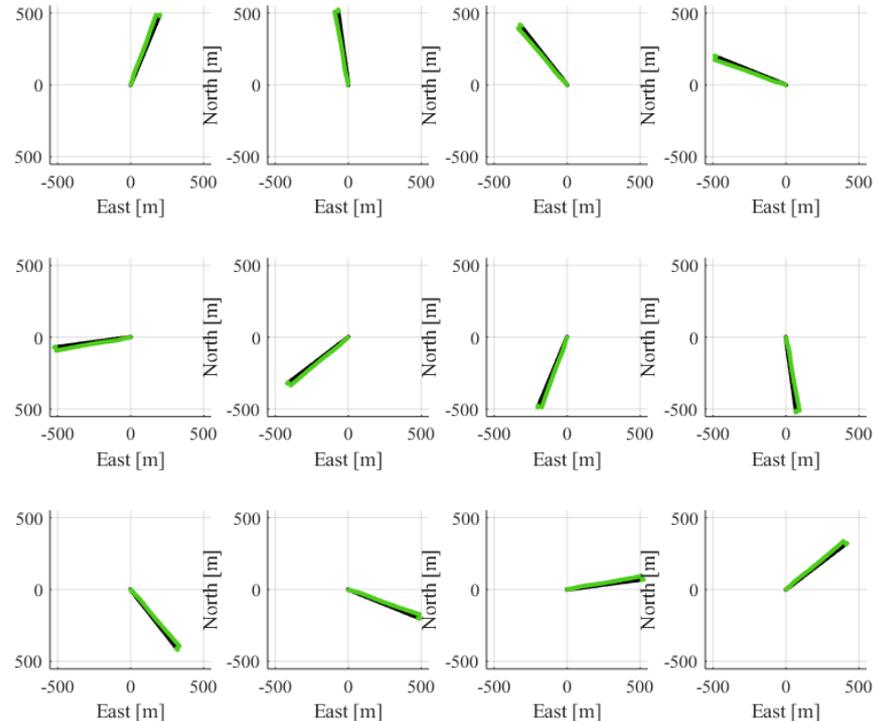
## 2. 回転によるデータ拡張

訓練データの数が種類が少ない

→ 手でデータを拡張する

→ 位置, 速度について

East - North 平面内で任意の角度で回転する



30 [deg] ごとに East - North 平面内で回転

緑 : INS/VIS  
黒 : 相対測位

## 3. 座標から移動量への変換

INS の位置更新式

位置の時間変化量

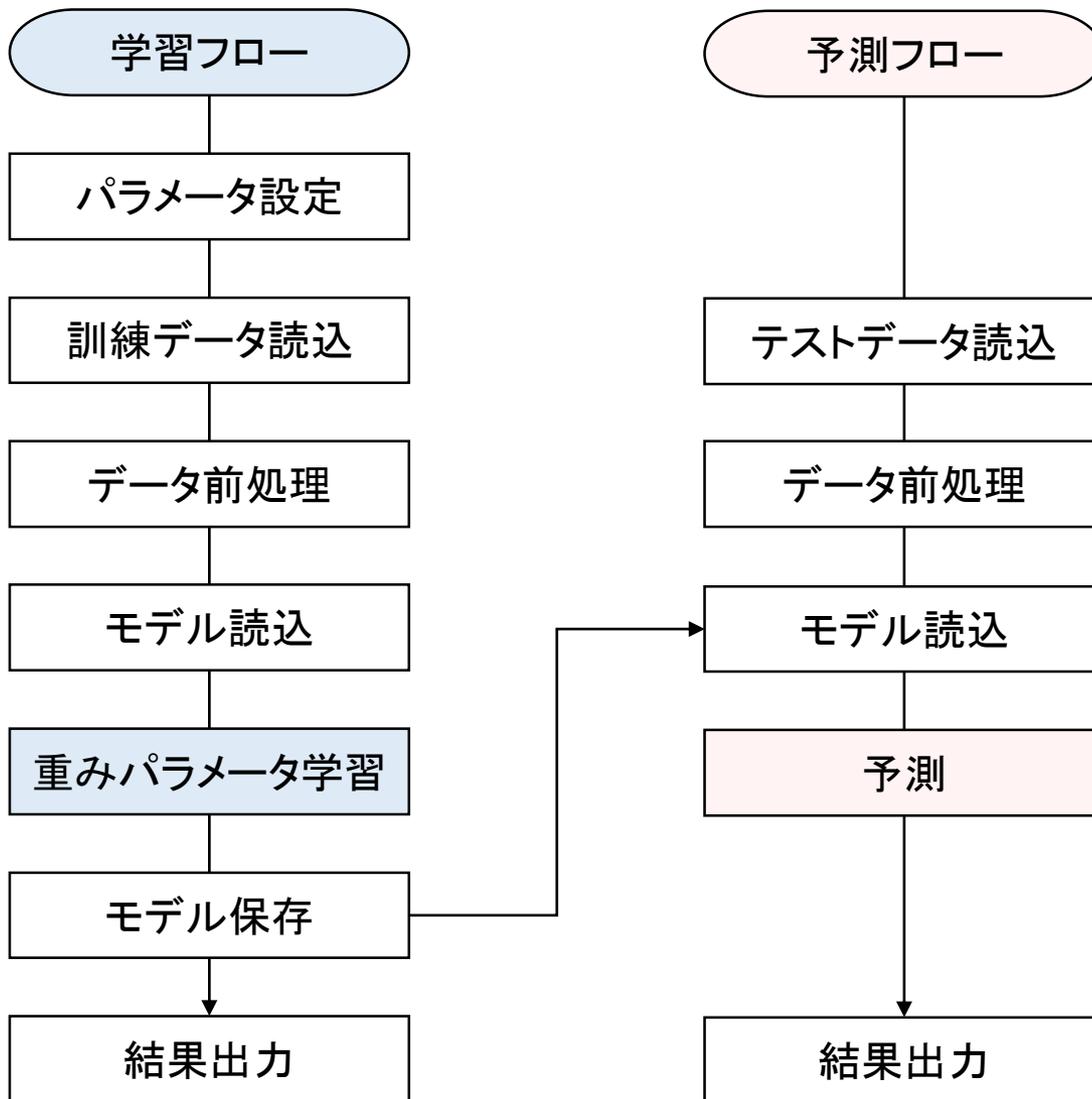
$$\dot{\lambda} = \frac{v_n}{R_M + h}$$

→ 前時刻からの変化量に変換

$$\dot{\phi} = \frac{v_e}{(R_N + h) \cos \lambda}$$

→ データ間の偏りの解消

# 全体の流れ



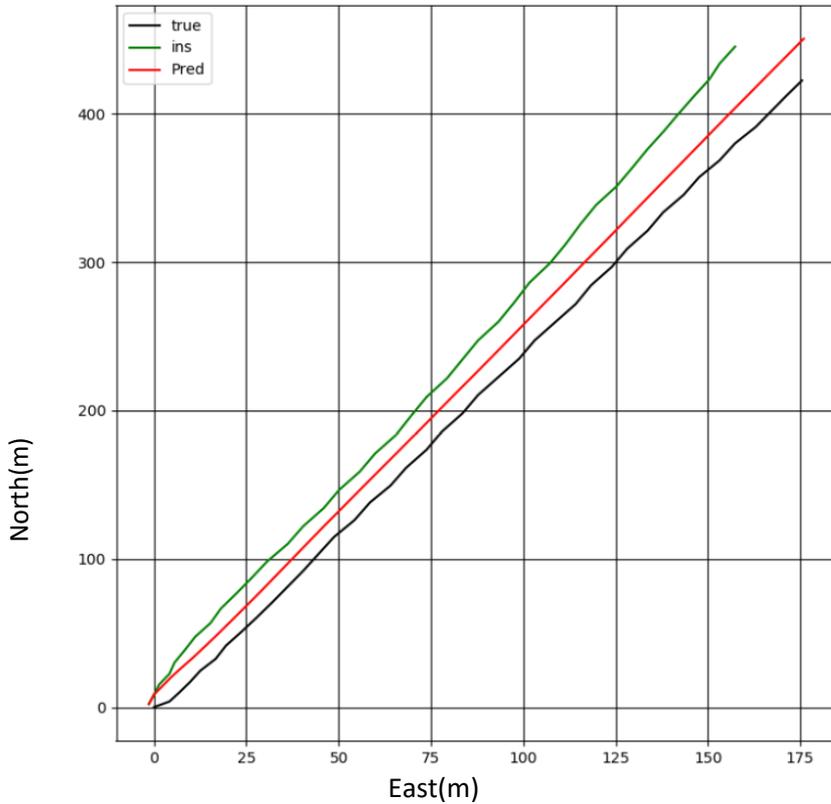
# 実験結果

軌跡1, 軌跡2ともに  
精度が向上した。

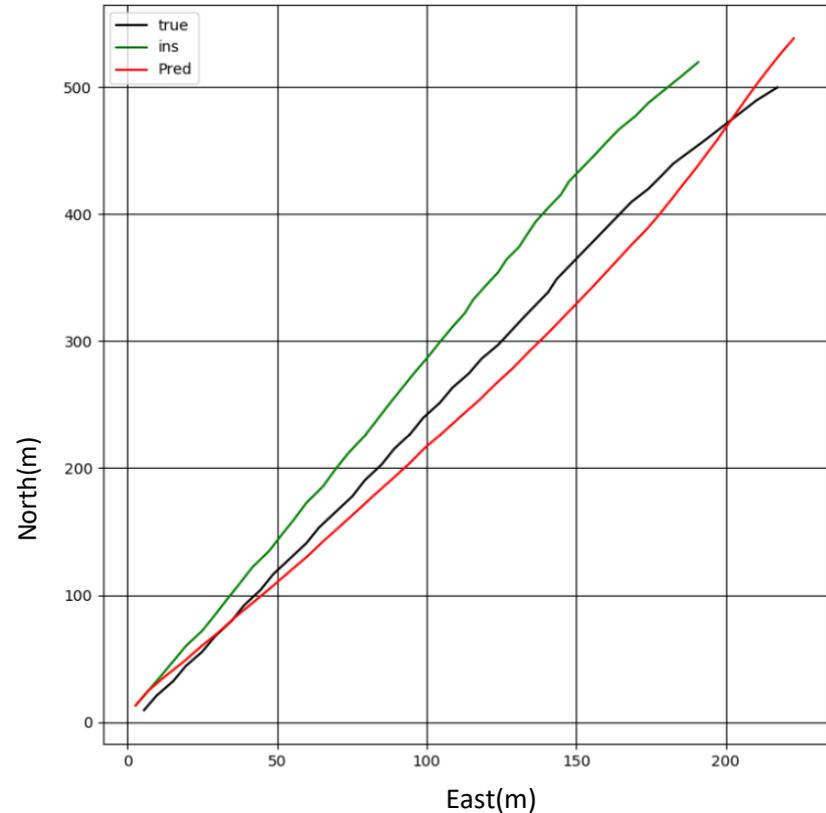


学習コストがかからない  
データの学習, 推定を  
進めていくことがより適切である。

- TRUE
- INS/VS
- RNN



軌跡1 RNN



軌跡2 RNN

# まとめと考察

---

## 全体の結果まとめ

- 誤差平均が INS/VS 複合航法よりも小さい
- 学習コストを考えデータの学習, 推定を進めていくことがより適切である.
- パラメータの最適化の検討を行う必要性

## 実験の特徴

RNN の入力によってINS/VS 位置誤差の情報が表現され

RNN 位置を直接的に推定

# 展望

---

- 様々なパターンでのモデルの学習  
(右左折, 静止, Uターン等)
- 予測結果の評価方法の検討
- 学習パラメータの最適化  
→ 中間層ニューロン数, 勾配降下法エポック数, 学習率, 等
- RNN の入力の物理量の検討
- 実験によるデータ収集  
→ データ数を増やす

ご清聴ありがとうございました

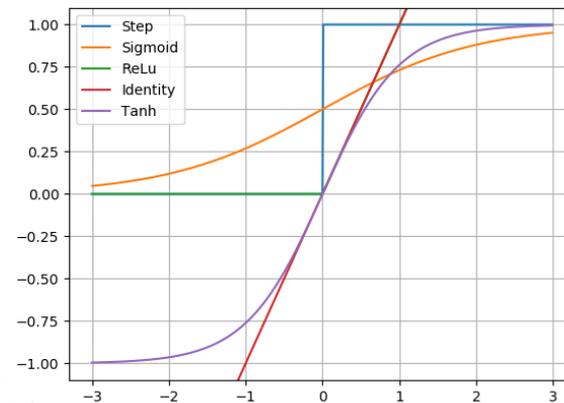
---



# 活性化関数

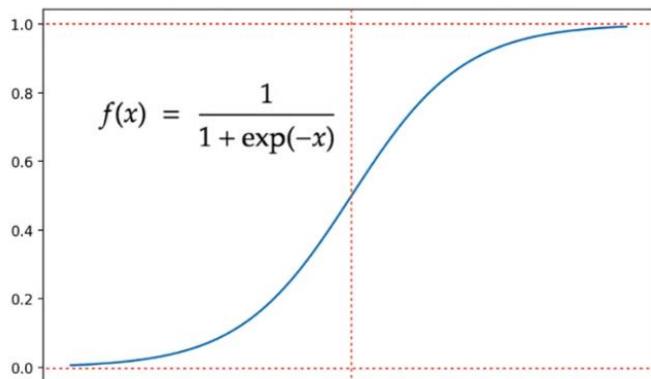
$f(u)$  : 活性化関数

線形変換をした後に適用する関数  
入力信号の総和がどのように活性化するかを決定



活性化関数

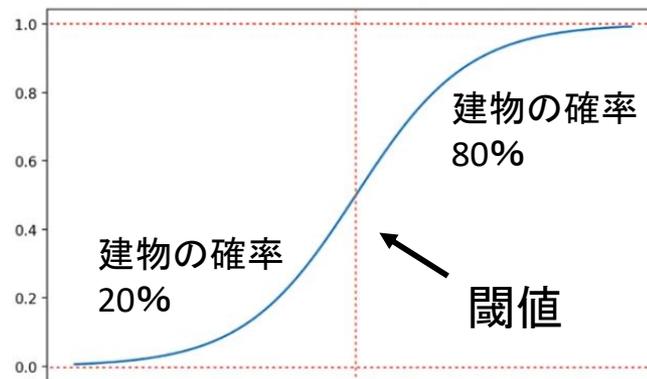
- ステップ関数 (Step)
- シグモイド関数 (Sigmoid)
- 正規化線形関数 (ReLu)
- 恒等関数 (identity)
- 双曲線正接関数 (tanh)



x : 入力x重みの合計+バイアス

f(x) : ニューロンからの出力

シグモイド関数



建物ではない 建物である

物体の判別

- 位置観測方程式

$$y_1 = \delta\lambda(R_M + h) - (dE)(\delta\theta_d) + (dD)(\delta\theta_e) + n_1$$

$$y_2 = \delta\phi(R_N + h) \cos \lambda + (dN)(\delta\theta_d) - (dD)(\delta\theta_n) + n_2$$

$$y_3 = \delta h - (dN)(\delta\theta_e) + (dE)(\delta\theta_n) + n_3$$

- 速度観測方程式

$$y_4 = (1 + \delta\gamma)\delta v_n + \bar{v}_e(\delta\theta_d) - \bar{v}_d(\delta\theta_e) - \delta\gamma v_n^i + n_4$$

$$y_5 = (1 + \delta\gamma)\delta v_e - \bar{v}_n(\delta\theta_d) + \bar{v}_d(\delta\theta_n) - \delta\gamma v_e^i + n_5$$

$$y_6 = (1 + \delta\gamma)\delta v_d + \bar{v}_n(\delta\theta_e) - \bar{v}_e(\delta\theta_n) - \delta\gamma v_d^i + n_6$$

$R_M$  : 地球の子午線曲率半径  $dE, dD$  : レバーアーム補正量  
 $R_N$  : 地球の卯酉線曲率半径 車速観測値  $v^i$  : INS 速度

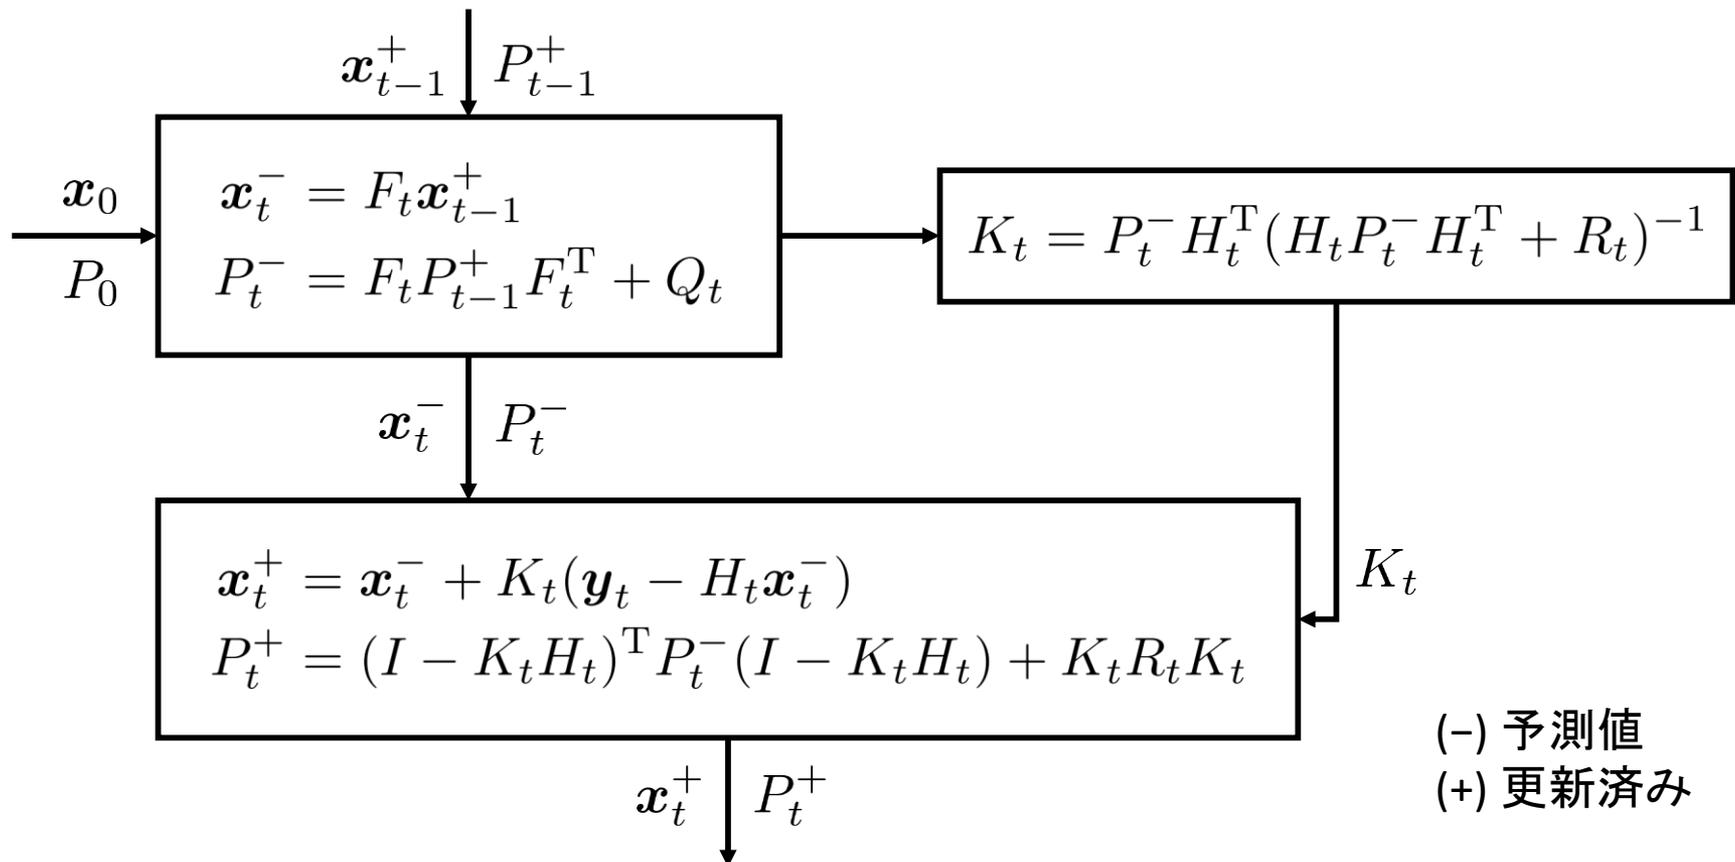
# Kalman Filter

補足2

## 状態空間モデル

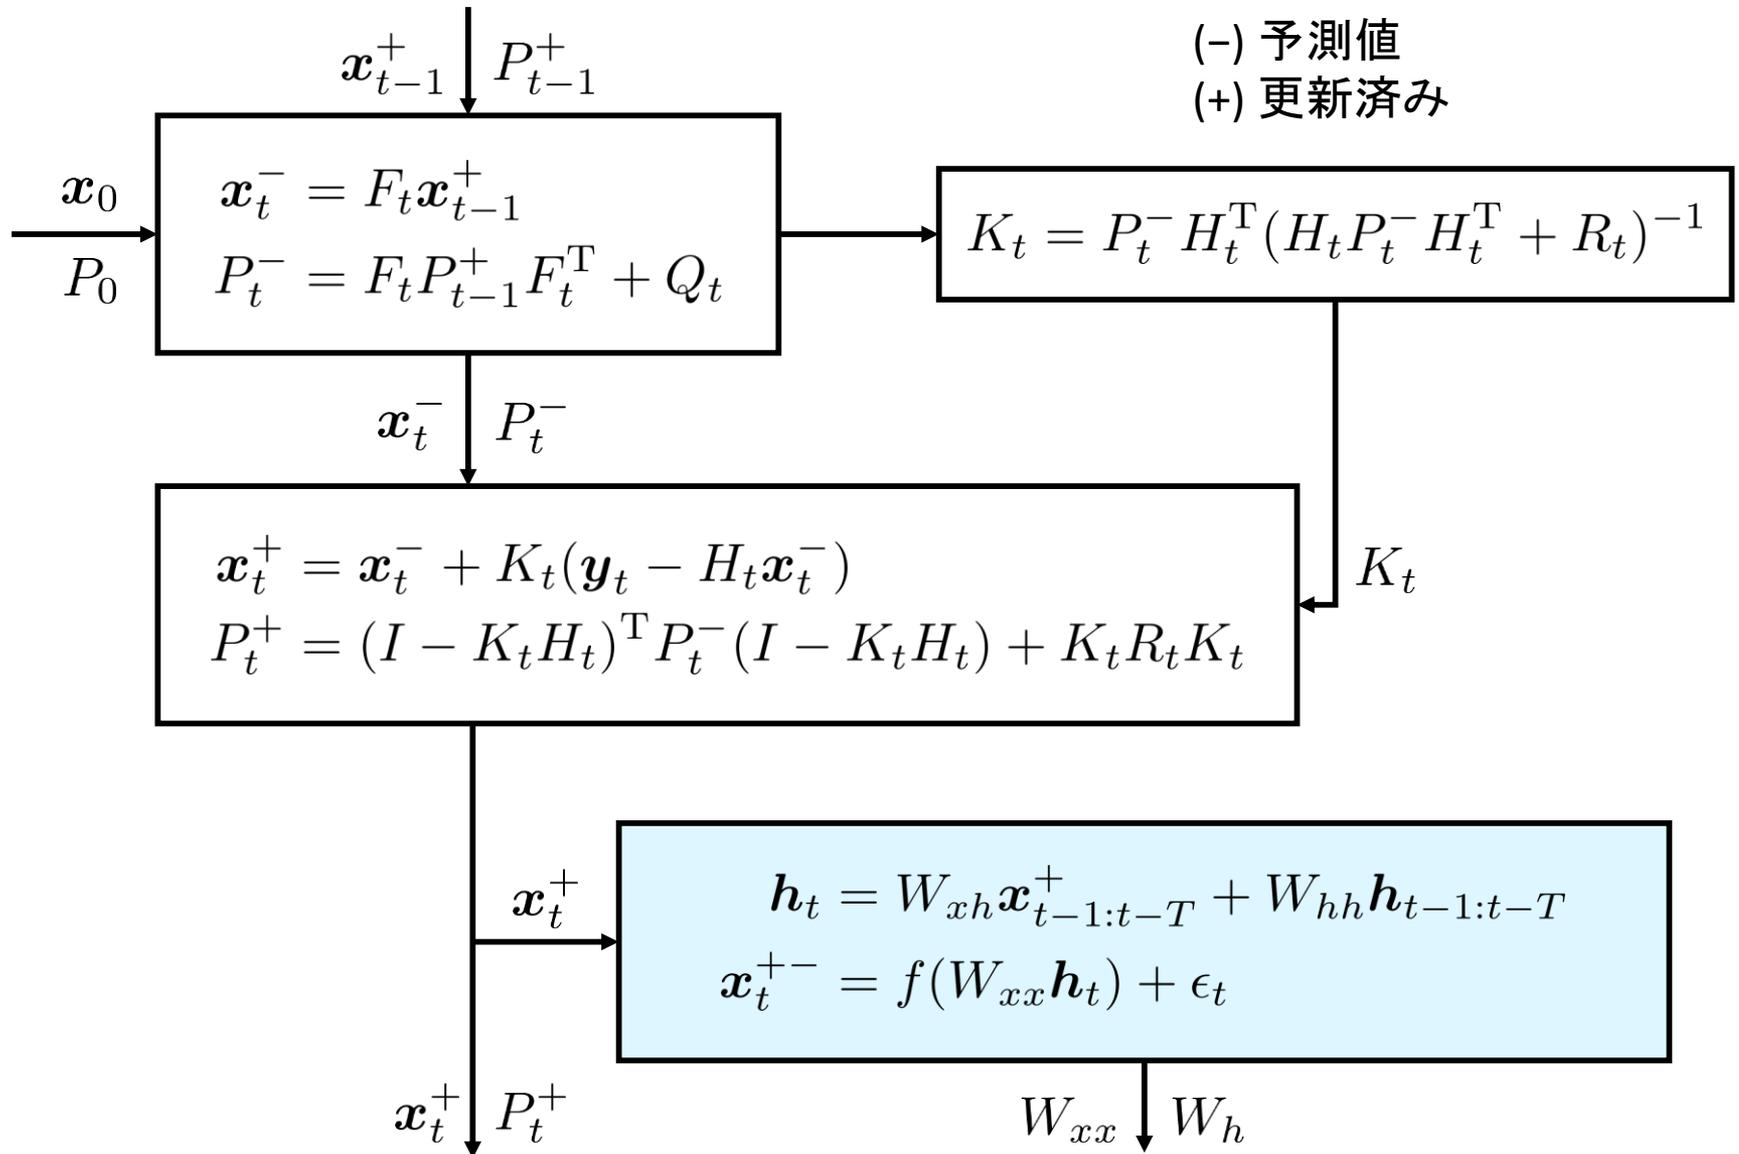
$$\mathbf{x}_t = F_t \mathbf{x}_{t-1} + \epsilon_t \quad \text{状態ベクトル: } \mathbf{x}_t \in \mathbb{R}^n \quad \text{システムノイズ: } \epsilon_t \sim \mathcal{N}(0, Q_t)$$

$$\mathbf{y}_t = H_t \mathbf{x}_t + \omega_t \quad \text{観測ベクトル: } \mathbf{y}_t \in \mathbb{R}^m \quad \text{観測ノイズ: } \omega_t \sim \mathcal{N}(0, R_t)$$



# Deep Kalman Filter

補足3

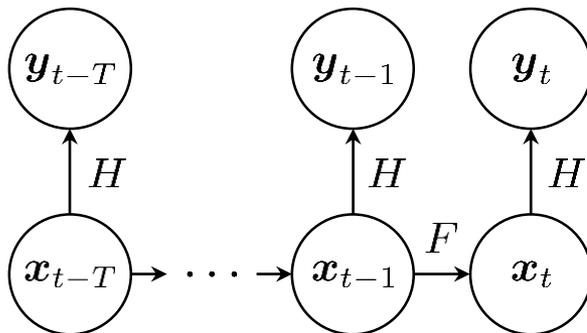


# Kalman Filter vs Deep Kalman Filter

補足4

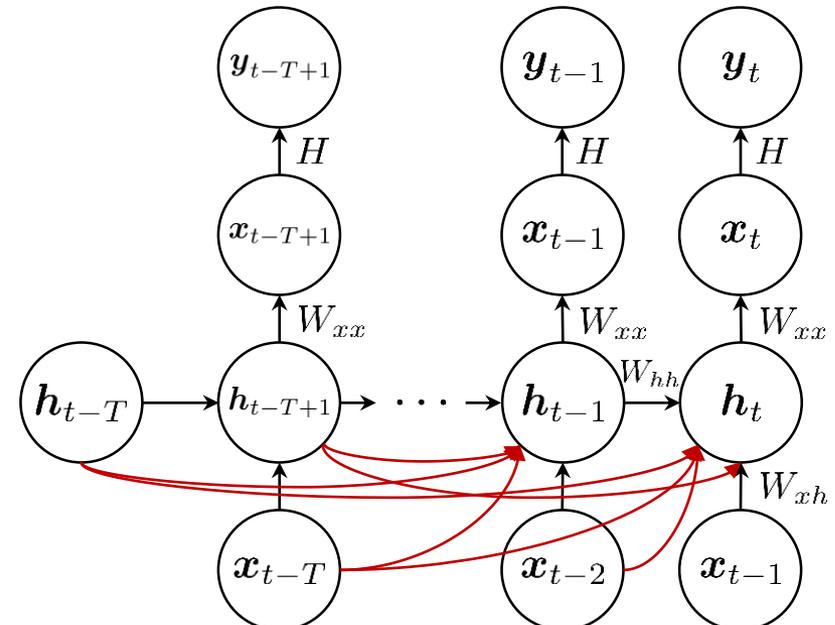
## Kalman Filter

- 各モデルは既知である必要がある
- 雑音はガウス性を仮定
- 現在の状態は前回の状態にのみ依存 (長時間的相関を考慮できない)
- センサごとの誤差モデルでは誤差源に対応できない



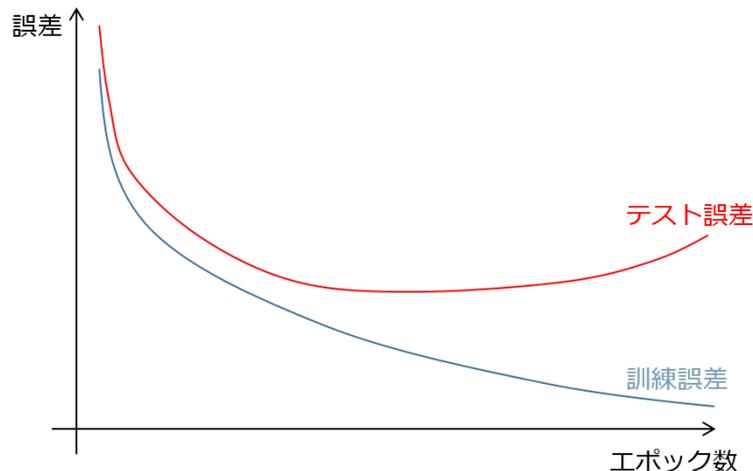
## Deep Kalman Filter

- 観測値からシステムモデルを構築
- 非ガウス性の雑音を扱える
- 現在の状態を過去一定区間の状態によるものと仮定
- バイアスの急激な変化に対応可能か



訓練データとテストデータ → 訓練誤差とテスト誤差

- 訓練誤差  
パラメータの更新で単調減少
- テスト誤差  
訓練誤差との乖離がおこる (過学習)



## 過学習を抑制する学習トリック

### 1. 訓練データに偏りがある → データの正規化

$$x_{ni} \leftarrow \frac{x_{ni} - \bar{x}_i}{\sigma_i}$$

$x_{ni}$  : サンプル  $x_n$  の成分  
 $\bar{x}_i$  : 平均 or 最小値  
 $\sigma_i$  : 分散 or (最大値 - 最小値)

### 2. 自動で学習係数を求める → Adam (Adaptive moment estimation, 2015)

$$m_{t+1} = \beta_1 m_t + (1 - \beta_1) \nabla E(\mathbf{w}^{(t)})$$
$$v_{t+1} = \beta_2 v_t + (1 - \beta_2) \nabla E(\mathbf{w}^{(t)})^2$$
$$\hat{m} = \frac{m_{t+1}}{1 - \beta_1^t}$$
$$\hat{v} = \frac{v_{t+1}}{1 - \beta_2^t}$$

過去の勾配より新しい勾配を重視

頻出の成分より珍しい勾配の成分を重視

$$\mathbf{w}^{(t+1)} = \mathbf{w}^{(t)} - \alpha \frac{\hat{m}}{\sqrt{\hat{v} + \mu}}$$

## 1. 入力値の選択

- 生データのみ  
→ RNN
- 生データ + Kalman Filter 演算結果  
→ 通常の Kalman Filter 結果の補正  
→ Deep Kalman Filter

## 2. ネットワークの構築

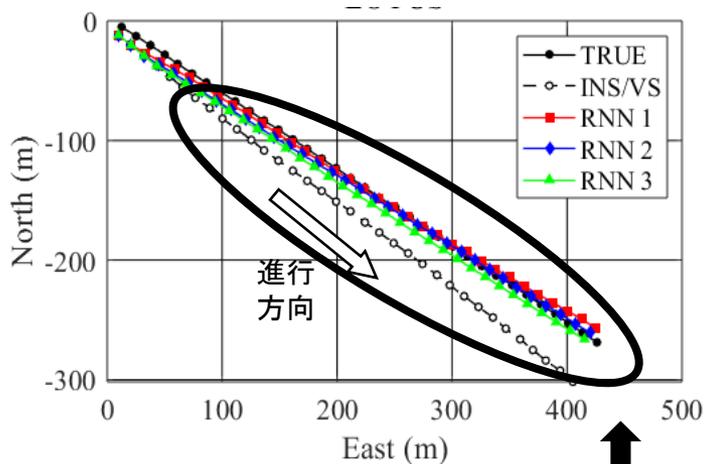
- 情報保持期間の調整  
→ 長期間的相関
- ニューロン (中間層ユニット) の数の調整  
→ 計算コストと表現力とのトレードオフ
- 計算反復回数の調整  
→ 冗長性がある際のコスト軽減

1. 実機を用いて訓練データを集める  
同時に相対測位位置を得て  
真値 (目標出力) を得る
2. RNN のパラメータの調整  
試行を重ねて適切な数を見つける
3. 入力値の要素の検討
  - 要素に加えないほうが精度が上がるものがあるか
  - 生データをどこまで使うか
4. 位置誤差を用いた結果の比較





# 過去の実験結果 $\text{RNN 位置} = \text{前時刻 RNN 位置 (初期値: INS 位置)} + \text{予測された位置変化量}$

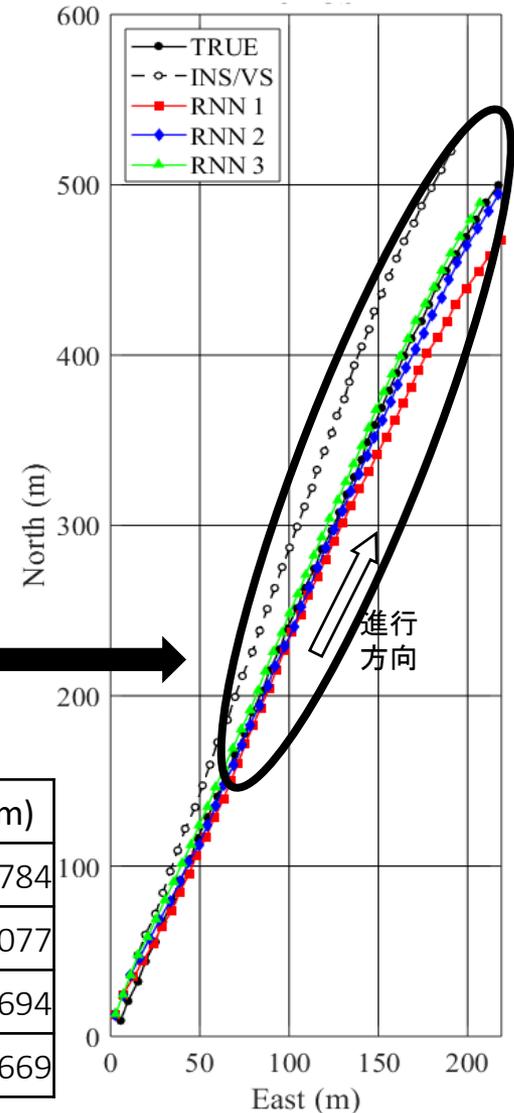


	RMSE (m)
INS/VS	23.700
RNN 1	4.835
RNN 2	7.611
RNN 3	9.857

RNN1, RNN2, RNN3ともに精度が大幅に変化しない。

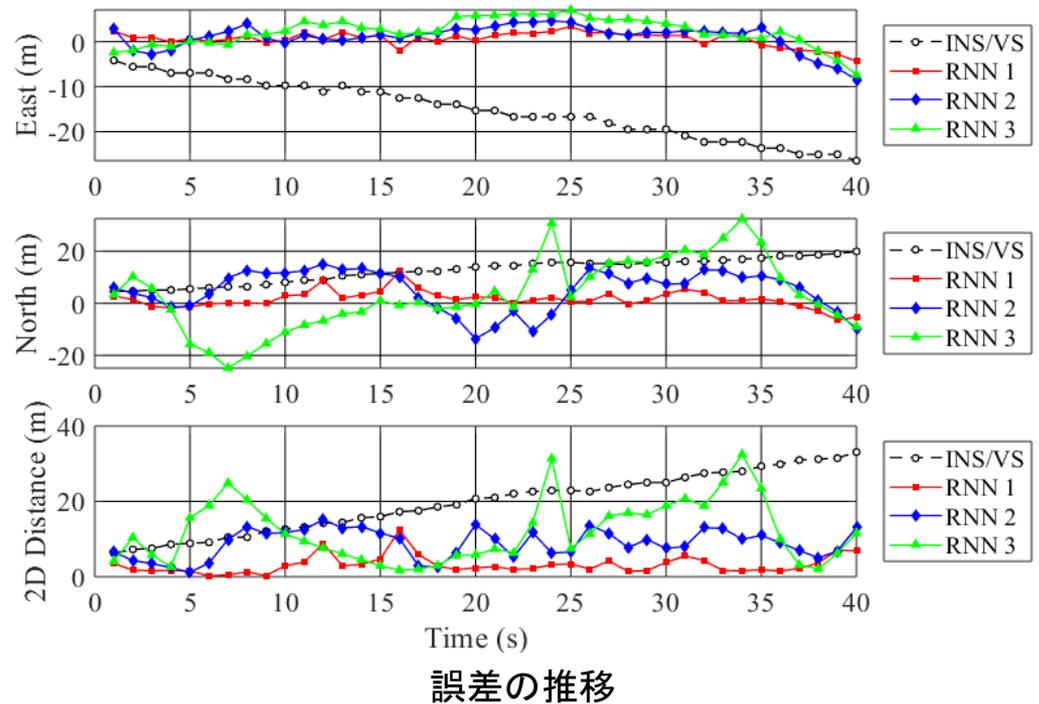
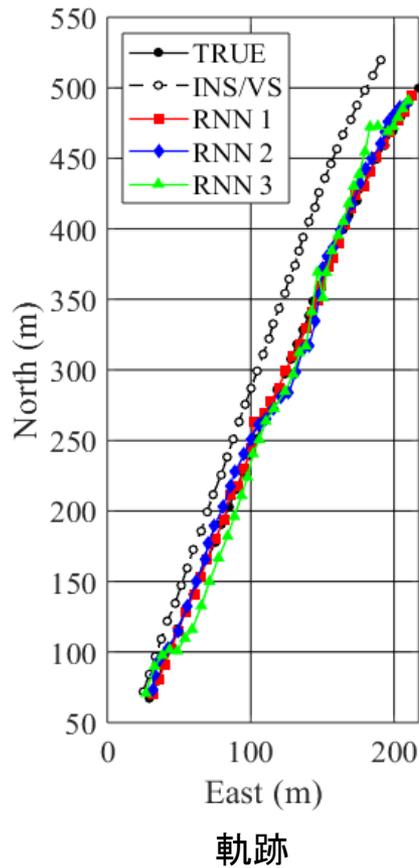


学習コストがかからない  
RNN1によるデータの学習, 推定を進めていくことがより適切である。



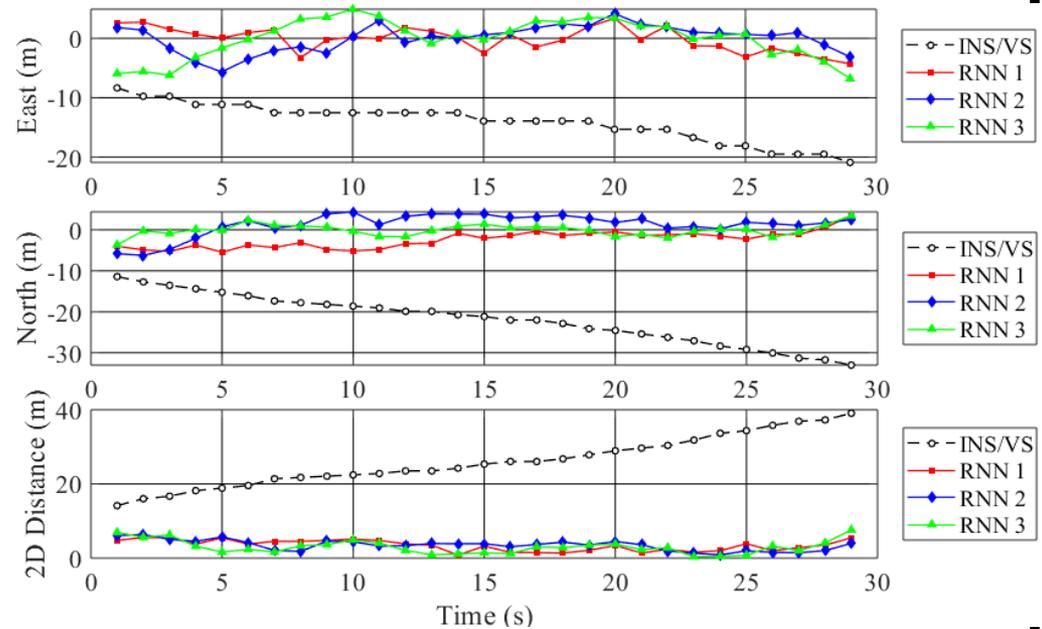
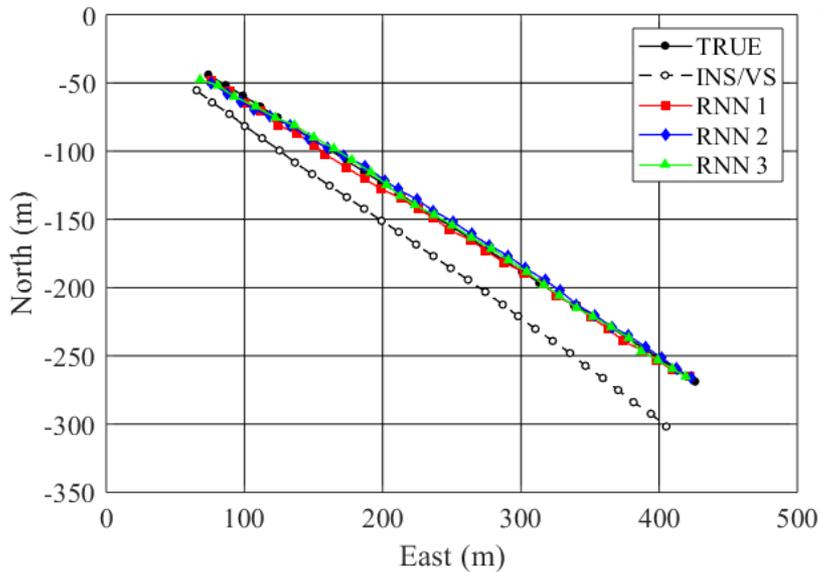
	RMSE (m)
INS/VS	17.784
RNN 1	21.077
RNN 2	6.694
RNN 3	11.669

# 実験結果 1-1 目標出力：相対測位位置



誤差平均 [m]	East	North	2D
INS/Vs 複合航法	-15.142	-21.860	26.035
RNN 1 層	0.568	1.554	3.176
RNN 2 層	0.987	4.947	8.879
RNN 3 層	2.146	3.234	11.966

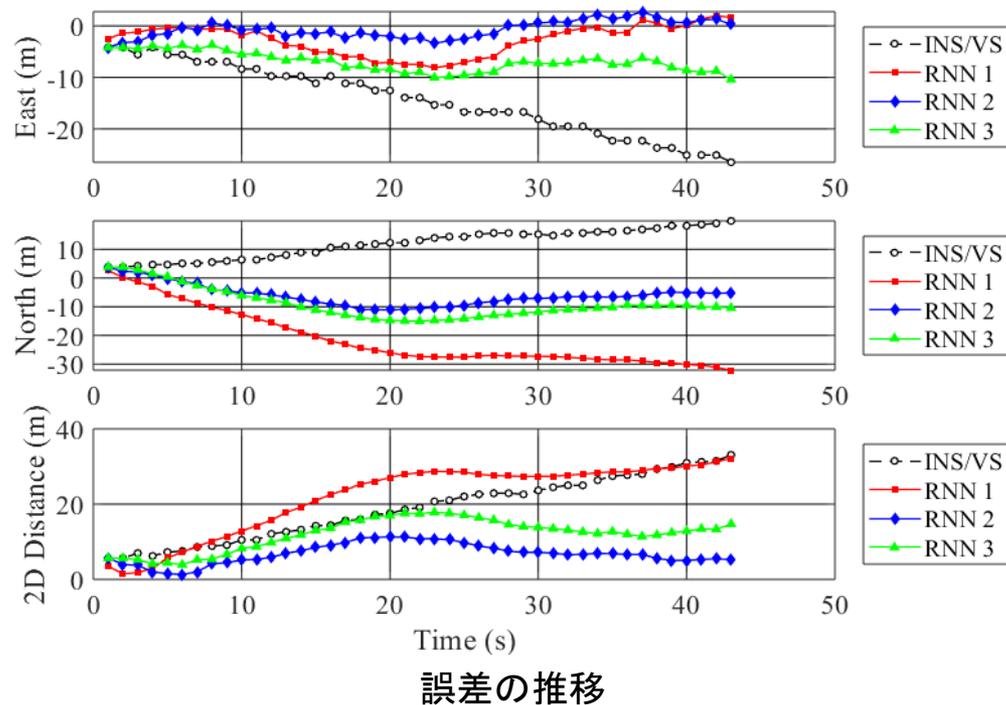
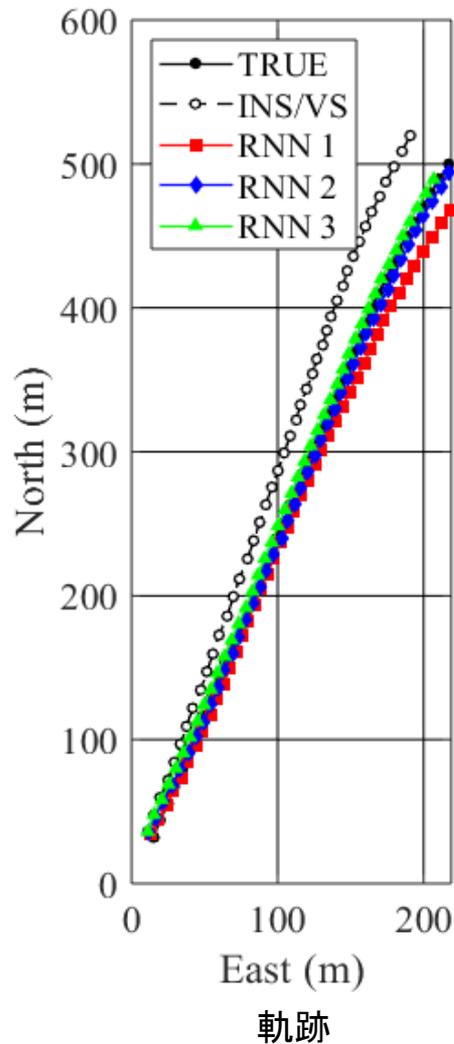
# 実験結果 1-2 目標出力：相対測位位置



誤差の推移

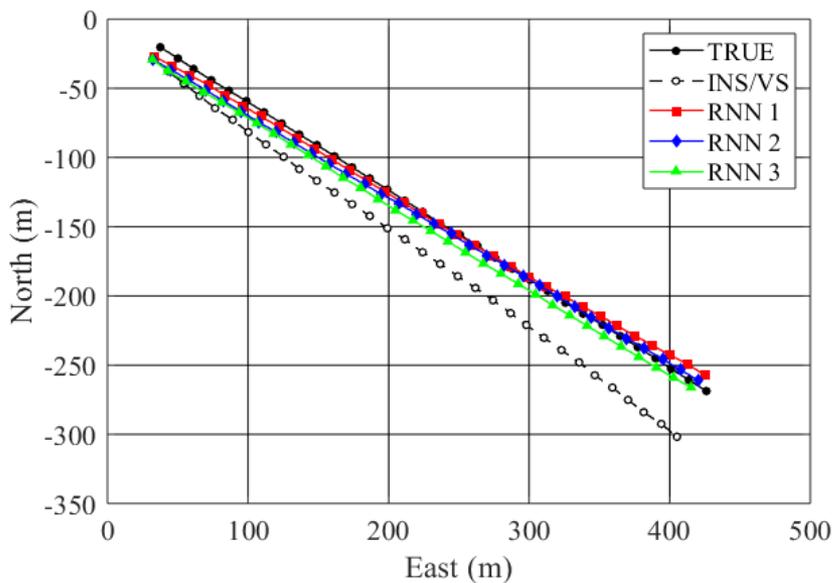
誤差平均 [m]	East	North	2D
INS/VS 複合航法	-14.115	-21.860	26.035
RNN 1 層	-0.162	-2.365	3.414
RNN 2 層	0.039	1.287	3.484
RNN 3 層	-0.062	-0.061	3.013

# 実験結果 2-1 目標出力：相対測位位置変化量

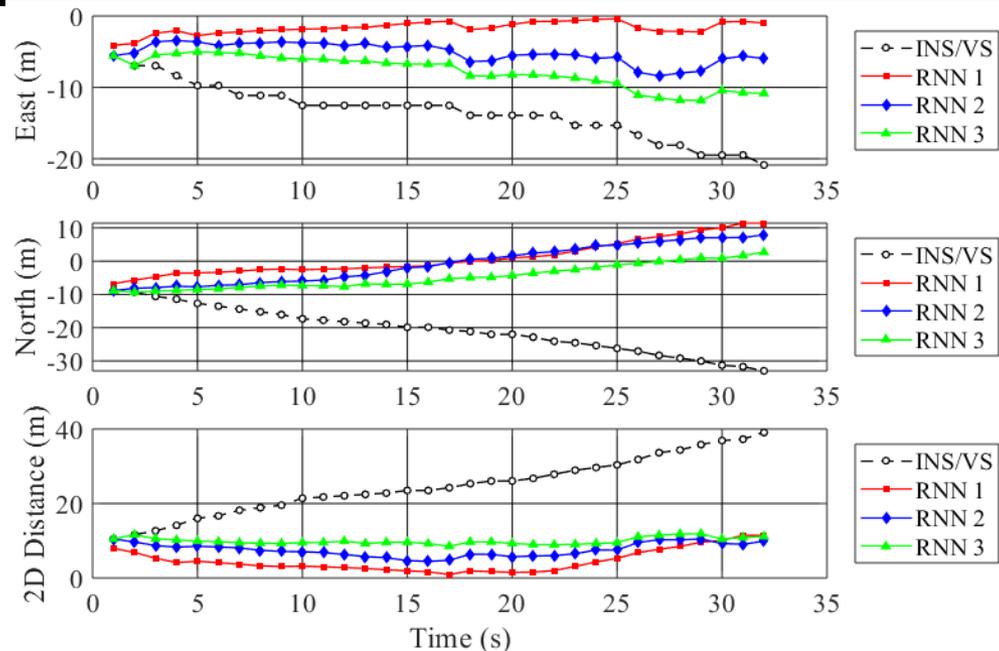


誤差平均 [m]	East	North	2D
INS/Vs 複合航法	-14.115	-21.860	26.035
RNN 1 層	-2.723	-21.333	21.837
RNN 2 層	-0.668	-6.040	6.785
RNN 3 層	-7.008	-8.993	11.992

# 実験結果 2-2 目標出力：相対測位位置変化量



軌跡



誤差の推移

誤差平均 [m]	East	North	2D
INS/Vs 複合航法	-14.115	-21.860	26.035
RNN 1 層	-1.662	0.971	4.636
RNN 2 層	-5.171	-0.843	7.586
RNN 3 層	-7.768	-4.699	9.973

# 実験条件 (実験 2)

