

# A Study on Neural Network-Aided Prediction of Pseudo-Range Correction in GNSS Differential Positioning

Kohei NISHIOKA,\* Shinsuke IBI,\* Takumi TAKAHASHI,\*\* and Hisato IWAI\*

(Received June 30, 2023)

In the global navigation satellite system (GNSS), the receiver position is estimated by solving the nonlinear simultaneous equation via the iterative weighted least squares method. However, these nonlinear simultaneous equations include external factors, such as clock errors and multipath, which induce position estimation errors. Although this measurement error due to external factors is difficult to predict with statistical and physical models, it is necessary to predict this error in order to improve positioning accuracy. In this paper, a feed-forward neural network (FFNN) that learns GNSS measurement data collected using multiple base stations to estimate the pseudo-range error is proposed. GNSS measurement data collected in multiple environments are likely to accurately represent the pseudo-range error that depends on the surrounding environment. Correct the pseudo-range error with the correction value estimated by the FFNN and evaluate the positioning result. This paper demonstrates the effectiveness of pseudo-range correction using neural networks trained on multiple base stations.

**Keywords** : GNSS positioning, pseudo-range, differential GNSS, neural network

**キーワード** : GNSS 測位, 擬似距離, ディファレンシャル GNSS, ニューラルネットワーク

## ニューラルネットワークを用いたGNSS相対測位における 擬似距離補正予測に関する検討

西岡 航平, 衣斐 信介, 高橋 拓海, 岩井 誠人

### 1. はじめに

近年, 知的交通システムやスマートフォンでアクセスできる位置情報サービスなど様々なアプリケーションが信頼性の高い位置情報を必要としている<sup>1)</sup>. 全球航法衛星システム (GNSS: Global Navigation Satellite System) は衛星測位システムの総称であり, 最も広く利用されている位置情報を提供するシステムである. GNSS は, 米国の全地球測位システム (GPS: Global Positioning System), 日本の準天頂衛星システム (QZSS: Quasi-Zenith

Satellite System), ロシアの GLONASS, 欧州連合の Galileo, 中国の BeiDou などの各国が運用する測位システムで構成され, 精度, 継続性, 堅牢性を向上させるべく検討が進められている<sup>2)</sup>. さらに, 2016年に Google が Android OS で GNSS 測定値にアクセスできる API を公開したこと<sup>3)</sup>により, スマートフォンの高精度測位に関する研究が広く行われるようになった. このように, GNSS を取り巻く環境は変化しており GNSS 測位の研究が活発化している.

GNSS 測位は, 受信機を 1 機使用する単独測位と受

\* Department of Electronics, Doshisha University, Kyoto  
Telephone: +81-774-65-6355, E-mail: sibi@mail.doshisha.ac.jp

\*\* Graduate School of Engineering, Osaka University, Osaka

信機に加えて基準局を用いる相対測位に大別できる。単独測位は衛星が放送する測距信号を受信し、衛星と受信機の距離についての非線形連立方程式を近似的に解くことで受信機の位置座標を求める。しかし、衛星と受信機のクロック誤差、電離層遅延や対流圏遅延、マルチパスなどの影響により GNSS の測位精度は環境により容易に劣化する。この誤差に対応するために様々な研究が行われてきた。そのうちの 하나가、電離層遅延を補正する Klobuchar モデルであり、単一周波数を対象に、補正精度は目標であった 50% を達成している<sup>4)</sup>。一方、相対測位は基準局が移動局に補正情報を送信することで単一の受信機では達成できない高精度な測位が可能である。

相対測位の一つである DGNS (Differential GNSS) は、基準局で推定した擬似距離の誤差を移動局の補正に用いることで測位精度を向上させる方式である。一方、RTK (Real Time Kinematic) は搬送波位相を用いることにより DGNS 以上に高精度な測位が可能である。しかし、現在のスマートフォンには位置情報サービスとして数 mm 四方チップの低価格受信機が搭載されているため、十分なサービスレベルでの RTK 測位は現実的ではない。以上を踏まえて、スマートフォンの位置情報サービスにおける測位に問題設定を置くため、本検討の比較対象として単独測位および DGNS を選択する。また、スマートフォンの機種に依存しないアプローチを実現すべく、GNSS の中で最も広く用いられている GPS の L1 (1575.42 MHz) 信号のみを用いる。

この GNSS 測位に機械学習を活用する動きがある。機械学習は、利用可能な計算能力の向上とともに近年大きな発展を遂げている技術の一つであり、データという具体例の集まりから計算機に自動的に学ばせる方法をとる。特に注目されている深層学習は、人間の神経系や脳の構造から着想を得たアルゴリズムであり、特徴抽出器を手動で設計することなくデータセットから抽象的な表現を学習する。代表的な深層学習アルゴリズムの一つである順伝播型ニューラルネットワーク (FFNN: Feed Forward Neural Network) は、入力層から出力層まで情報が一方方向にしか流れない構造であり、分類や回帰の問題を解くことができる。それに対して、リカレントニューラルネットワーク (RNN: Recurrent Neural Network) は、処理ユニットがサイクルを形成していることにより過去の状態に関する情報を持つことができ、音声認識やビデオ分類など時系列データを扱う問題に有用である。畳み込み

ニューラルネットワーク (CNN: Convolutional Neural Network) は、畳み込み層とプーリング層を階層的に重ねることで徐々に洗練された特徴抽出を行い、空間的な形状のある特性を読み取ることができるため、画像認識や自然言語処理などの問題に応用されている<sup>5)</sup>。

このように、深層学習はデータから抽象的な表現を抽出することができるため、統計的・物理的モデルで測定誤差を予測することが困難な GNSS 測位領域に対しても適用できる可能性が高い。実際に、多くの研究が GNSS 測定誤差の予測と軽減のために機械学習・深層学習を適用している<sup>6)</sup>。GNSS 測定誤差の一つである電離層遅延は電離層の電子量に依存することから、この電子量を推定する手法として LSTM (Long Short-Term Memory) -CNN モデル<sup>7)</sup>、CNN-GRU (Gated Recurrent Units) モデル<sup>8)</sup> が提案されており、電子量の推定精度が従来モデルを上回っている。また、マルチパス信号の検出では SVM モデル<sup>9)</sup>、CNN モデル<sup>10)</sup>、擬似距離誤差を合わせて推定する FFNN-LSTM モデル<sup>11)</sup> が提案されている。さらに、GNSS 反射測定 (GNSS-Reflectometry) データから風速を推定するために FFNN を用いている手法では、最小二乗法のアプローチと比較して精度が 20% 程度改善している<sup>12)</sup>。このように、多くの研究で機械学習、特に深層学習を用いてモデル化することが難しい GNSS 測定誤差の予測・軽減を実現している。

擬似距離の誤差は衛星と受信機の位置関係や周辺環境に依存し、観測する時間によって衛星の配置状況も変化するため、物理的・統計的モデルで推定することが困難である。しかし、測位精度を向上させるためにはこの誤差を予測する必要がある。そこで本検討では、複数基準局を用いて採取した GNSS 測定データを学習し、擬似距離誤差を調整する FFNN を検討する。複数の環境で採取した GNSS 測定データは、周辺環境に依存する擬似距離誤差を精度良く表現できる可能性が高い。そして、調整した擬似距離誤差を補正值として擬似距離測定値に適用し、測位演算を行うことで従来の単独測位、DGNS と比較して測位精度を高めることを目的とする。

## 2. GNSS 測位の基本原理

### 2.1 GNSS 単独測位

Figure 1 に単独測位の模式図を示す。単独測位では、衛星と移動局 R (Rover) の受信機との距離についての

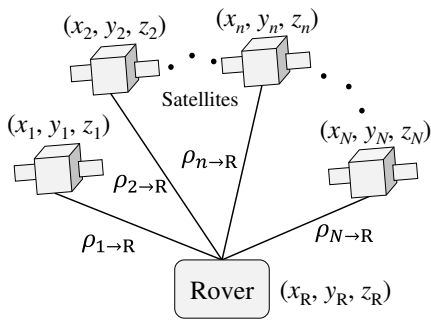


Fig. 1. Single point positioning (SPP) model.

連立方程式を解くことで移動局位置座標を推定する。しかし、この距離には衛星と受信機のクロック誤差、電離層遅延や対流圏遅延、マルチパスなど様々な外乱に起因する距離誤差が含まれているため「擬似距離」と呼ばれる。衛星クロック誤差は測距信号から得られる補正係数を利用して除去することができるが、受信機クロック誤差は個々の受信機によって異なるため、受信機クロック誤差を未知数として連立方程式を定義する必要がある。したがって、未知変数は移動局位置  $(x_R, y_R, z_R)$  および受信機クロック誤差  $s_R$  の4つとなるため、連立方程式を解くために最低4機のGNSS衛星の受信情報が必要となる。

衛星  $n$  の位置座標を  $(x_n, y_n, z_n)$  としたとき、次式の衛星  $n$  と移動局  $R$  との擬似距離  $\rho_{n \rightarrow R}$  について、 $N$  機の衛星からなる連立方程式が成立する。

$$\rho_{n \rightarrow R} = \sqrt{(x_n - x_R)^2 + (y_n - y_R)^2 + (z_n - z_R)^2} + s_R \quad (1)$$

通常は、初期値の周りで線形化を行い逐次的に近似解を求めていく。まず、移動局の位置座標  $(x_R, y_R, z_R)$  と受信機クロック誤差  $s_R$  について適当な初期値  $x_R^{(0)}, y_R^{(0)}, z_R^{(0)}, s_R^{(0)}$  を設定する。このときの擬似距離  $\rho_{n \rightarrow R}^{(0)}$  は次式で表される。

$$\rho_{n \rightarrow R}^{(0)} = \sqrt{(x_n - x_R^{(0)})^2 + (y_n - y_R^{(0)})^2 + (z_n - z_R^{(0)})^2} + s_R^{(0)} \quad (2)$$

次に、実際に測定した擬似距離  $\rho_{n \rightarrow R}$  と推定した擬似距離  $\rho_{n \rightarrow R}^{(0)}$  から、残差  $\Delta \rho_{n \rightarrow R}$  を求めるが、ここで擬似距離に対して大気遅延補正とクロック誤差補正を行う。高度100 km以上の上空に存在する電離層には電波の進行を遅らせる作用があり、さらに電離層を通過した測距信号は地表付近の大気による遅延を受ける。そこで、大気遅延補正を施す必要があり、本検討では電離層

遅延補正にKlobucharモデル、対流圏遅延補正に受信機の高度と衛星の仰角に依存した簡易的なモデルを用いる。また、受信機クロック誤差と同様に衛星クロック誤差の補正も行うことで、さらに誤差が軽減された擬似距離を得ることができる。したがって、電離層遅延補正值  $\mathbf{d}_{io \rightarrow R} = [d_{io,1 \rightarrow R}, d_{io,2 \rightarrow R}, \dots, d_{io,N \rightarrow R}]^T$  と対流圏遅延補正值  $\mathbf{d}_{tr \rightarrow R} = [d_{tr,1 \rightarrow R}, d_{tr,2 \rightarrow R}, \dots, d_{tr,N \rightarrow R}]^T$ 、および衛星クロック誤差  $\boldsymbol{\beta} = [\beta_1, \beta_2, \dots, \beta_N]^T$  を用いると、 $n$  番目の衛星の擬似距離残差  $\Delta \rho_{n \rightarrow R}$  は次式で求めることができる。

$$\Delta \rho_{n \rightarrow R} = (\rho_{n \rightarrow R} + \beta_n - s_R^{(0)} + (d_{io,n \rightarrow R} + d_{tr,n \rightarrow R})) - \rho_{n \rightarrow R}^{(0)} \quad (3)$$

ただし、 $\cdot^T$  は転置を意味する。

次に、 $\rho_{n \rightarrow R}$  の  $x_R, y_R, z_R, s_R$  による偏微分

$$\begin{aligned} \frac{\partial \rho_{n \rightarrow R}}{\partial x_R} &= -\frac{x_n - x_R}{\rho_{n \rightarrow R}} & \frac{\partial \rho_{n \rightarrow R}}{\partial y_R} &= -\frac{y_n - y_R}{\rho_{n \rightarrow R}} \\ \frac{\partial \rho_{n \rightarrow R}}{\partial z_R} &= -\frac{z_n - z_R}{\rho_{n \rightarrow R}} & \frac{\partial \rho_{n \rightarrow R}}{\partial s_R} &= 1 \end{aligned} \quad (4)$$

を用いて  $x_R^{(0)}, y_R^{(0)}, z_R^{(0)}, s_R^{(0)}$  を更新するための変化量  $\Delta x_R, \Delta y_R, \Delta z_R, \Delta s_R$  を求める。

$$\Delta \rho_{n \rightarrow R} = \frac{\partial \rho_{n \rightarrow R}}{\partial x_R} \Delta x_R + \frac{\partial \rho_{n \rightarrow R}}{\partial y_R} \Delta y_R + \frac{\partial \rho_{n \rightarrow R}}{\partial z_R} \Delta z_R + \frac{\partial \rho_{n \rightarrow R}}{\partial s_R} \Delta s_R \quad (5)$$

式(5)において、 $\Delta \mathbf{x} = [\Delta x_R, \Delta y_R, \Delta z_R, \Delta s_R]^T$ 、 $\Delta \boldsymbol{\rho} = [\Delta \rho_{1 \rightarrow R}, \Delta \rho_{2 \rightarrow R}, \dots, \Delta \rho_{N \rightarrow R}]^T$  を用いると、次式の行列表現に書き換えることができる。

$$\Delta \boldsymbol{\rho} = \mathbf{G} \Delta \mathbf{x} \quad (6)$$

ただし、 $\mathbf{G}$  は計画行列であり次式で定義される。

$$\mathbf{G} = \begin{bmatrix} \frac{\partial \rho_{1 \rightarrow R}}{\partial x_R} & \frac{\partial \rho_{1 \rightarrow R}}{\partial y_R} & \frac{\partial \rho_{1 \rightarrow R}}{\partial z_R} & \frac{\partial \rho_{1 \rightarrow R}}{\partial s_R} \\ \frac{\partial \rho_{2 \rightarrow R}}{\partial x_R} & \frac{\partial \rho_{2 \rightarrow R}}{\partial y_R} & \frac{\partial \rho_{2 \rightarrow R}}{\partial z_R} & \frac{\partial \rho_{2 \rightarrow R}}{\partial s_R} \\ \vdots & \vdots & \vdots & \vdots \\ \frac{\partial \rho_{N \rightarrow R}}{\partial x_R} & \frac{\partial \rho_{N \rightarrow R}}{\partial y_R} & \frac{\partial \rho_{N \rightarrow R}}{\partial z_R} & \frac{\partial \rho_{N \rightarrow R}}{\partial s_R} \end{bmatrix} \quad (7)$$

移動局  $R$  から見た各衛星の仰角  $El_{n \rightarrow R} [\text{rad}]$  に応じた重み行列  $\mathbf{V}$  を次式で定義する。

$$\begin{aligned} \mathbf{V} &= \text{diag} [\sigma_1^{-2}, \sigma_1^{-2}, \dots, \sigma_N^{-2}] \\ &\simeq \text{diag} \left[ \frac{\sin^2 El_{1 \rightarrow R}}{0.8^2}, \frac{\sin^2 El_{2 \rightarrow R}}{0.8^2}, \dots, \frac{\sin^2 El_{N \rightarrow R}}{0.8^2} \right] \end{aligned} \quad (8)$$

ただし、 $\text{diag}[\mathbf{a}]$  はベクトル  $\mathbf{a}$  を要素に持つ対角行列を意味し、 $\sigma_n$  は  $n$  番目の衛星と移動局間の擬似距離の標

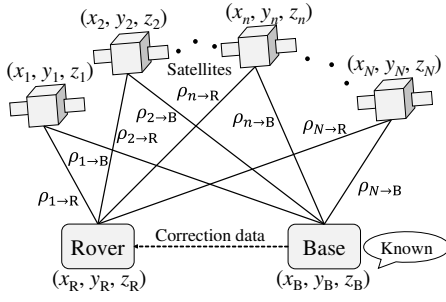


Fig. 2. Differential GNSS model.

準偏差である。仰角  $El_{n \rightarrow R}$  に依存した重みを用いることで、擬似距離の精度が悪い衛星の影響を小さくすることができる。式 (6) は、この行列  $\mathbf{V}$  を用いた重み付き最小二乗 (WLS: Weighted Least Squares) 法により、次式で解くことができる。

$$\Delta \mathbf{x} = (\mathbf{G}^T \mathbf{V} \mathbf{G})^{-1} \mathbf{G}^T \mathbf{V} \Delta \rho \quad (9)$$

得られた  $\Delta x_R, \Delta y_R, \Delta z_R, \Delta s_R$  により初期値を更新する。

$$\begin{aligned} x_R^{(1)} &= x_R^{(0)} + \Delta x_R & y_R^{(1)} &= y_R^{(0)} + \Delta y_R \\ z_R^{(1)} &= z_R^{(0)} + \Delta z_R & s_R^{(1)} &= s_R^{(0)} + \Delta s_R \end{aligned} \quad (10)$$

更新した初期値を用いて式 (2) の状態へと戻る。以上の手順を  $\Delta x_R, \Delta y_R, \Delta z_R, \Delta s_R$  が十分小さくなるまで繰り返すことで、移動局の位置座標  $(x_R, y_R, z_R)$  と受信機クロック誤差  $s_R$  を確定させる。

## 2.2 GNSS 相対測位

Figure 2 に DGNSS の模式図を示す。DGNSS には位置座標の差分を補正情報として基準局 B (Base) から移動局 R に送信する方式と、擬似距離の差分を送信する方式がある。位置座標補正の方式は、基準局と移動局で測位に利用する衛星の組み合わせが同一である必要があるため、適用することが難しく測位精度も低い<sup>13)</sup>。そこで本検討では、擬似距離補正方式の DGNSS を対象とする。基準局 B の擬似距離測定値  $\rho_{n \rightarrow B}$  は式 (1) と同様に次式で表される。

$$\rho_{n \rightarrow B} = \sqrt{(x_n - x_B)^2 + (y_n - y_B)^2 + (z_n - z_B)^2} + s_B \quad (11)$$

DGNSS 測位における基準局の位置座標  $(x_B, y_B, z_B)$  は既知であるため、実際には受信機クロック誤差  $s_B$  の一つの未知変数を重み付き最小二乗法で解くことになる。

擬似距離補正值  $\Delta r_{n \rightarrow B}$  は  $n$  番目の衛星と基準局 B の受信機間の幾何距離  $r_{n \rightarrow B}$ 、受信機クロック誤差  $s_B$ 、衛

星クロック誤差  $\beta_n$  を用いて次式で表すことができる。

$$\Delta r_{n \rightarrow B} = (\rho_{n \rightarrow B} + \beta_n - s_B) - r_{n \rightarrow B} \quad (12)$$

そして、この基準局で生成した  $\Delta r_{n \rightarrow B}$  と移動局の擬似距離測定値  $\rho_{n \rightarrow R}$  の差分を取ることで、補正された擬似距離  $\rho_{n \rightarrow R(\text{corr})}$  を得ることができる。

$$\rho_{n \rightarrow R(\text{corr})} = \rho_{n \rightarrow R} - \Delta r_{n \rightarrow B} \quad (13)$$

最後に、補正した擬似距離  $\rho_{n \rightarrow R(\text{corr})}$  を用いて 2.1 節と同様の計算を行えば、単独測位と比較して精度の良い移動局位置座標を求めることができる<sup>14)</sup>。

## 3. 擬似距離補正値を調整する FFNN

### 3.1 ニューラルネットワークの原理

Figure 3 にニューラルネットワークで標準的な構造を持つ 3 層の FFNN の模式図を示す。FFNN はニューラルネットワークの代表的な構造の一つであり、入力層から出力層まで情報が一方方向にしか流れない。 $k$  番目のデータに対する入力ベクトルを  $\mathbf{i}_k$ 、重み行列を  $\mathbf{W}_1$ 、バイアスベクトルを  $\mathbf{b}_1$ 、活性化関数を  $f$  としたとき、隠れ層における出力ベクトル  $\mathbf{h}_k$  は次式で表される。

$$\mathbf{h}_k = f(\mathbf{W}_1 \mathbf{i}_k + \mathbf{b}_1) \quad (14)$$

また、出力ベクトル  $\mathbf{o}_k$  は重み行列  $\mathbf{W}_2$ 、バイアスベクトル  $\mathbf{b}_2$ 、活性化関数  $g$  を用いると次式で表される。

$$\mathbf{o}_k = g(\mathbf{W}_2 \mathbf{h}_k + \mathbf{b}_2) \quad (15)$$

活性化関数  $f, g$  には次式で表される ReLU 関数と線形関数を用いる。

$$f(a) = \begin{cases} \max(0, a), & \text{ReLU} \\ a, & \text{Linear} \end{cases} \quad (16)$$

一般的に、回帰問題を扱う際は出力層の活性化関数  $g$  に恒等線形関数を用いることが多い。

得られた出力ベクトル  $\mathbf{o}_k$  に対して損失関数  $E$  を定義する。損失関数  $E$  は最小化すべき「モデルの出力ベクトル  $\mathbf{o}_k$  と正解ベクトル  $\mathbf{c}_k$  の誤差」を表す関数であり、損失関数  $E$  を最小化するように各層の最適なパラメータを探索する。本検討では次式で表される平均二乗誤差 (MSE: Mean Squared Error) 関数を用いる。

$$E = \frac{1}{K} \sum_{k=1}^K \|\mathbf{o}_k - \mathbf{c}_k\|^2 \quad (17)$$

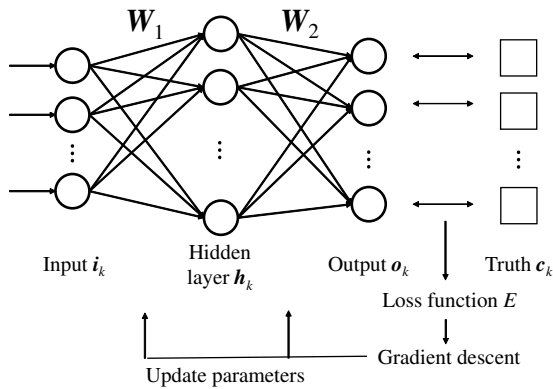


Fig. 3. FFNN model.

ただし、 $K$  はデータ数である。

学習フェーズでは、勾配降下法や最適化手法を用いて損失関数  $E$  が最小となる最適な重み行列  $W_1$ ,  $W_2$  とバイアスペクトル  $b_1$ ,  $b_2$  を見つけ、ネットワークの出力  $o_k$  を正解ラベル  $c_k$  に近づける。推論フェーズでは、学習済みのモデルに対して未知のテストデータを入力し、出力された値を評価してモデルの妥当性を確認する<sup>15)</sup>。

### 3.2 システムアーキテクチャ

移動局 R の擬似距離補正值  $\Delta r_{n \rightarrow R}$  を調整し、DGNSS 測位するシステムアーキテクチャを Fig. 4 に示す。まず、GNSS 受信機から採取した GNSS 測定データから特徴量として、特定のエポックにおける衛星  $n$  の擬似距離残差  $\rho_{n \rightarrow R}$ 、仰角  $El_{n \rightarrow R}$ 、信号強度  $Cn_{n \rightarrow R}$ 、電離層遅延量  $d_{io,n \rightarrow R}$ 、対流圏遅延量  $d_{tr,n \rightarrow R}$  を抽出する。この特徴量が FFNN の入力として隠れ層へ伝播し、ReLU で活性化し、擬似距離補正值  $\Delta r_{n \rightarrow R}$  を出力する。式 (13) と同様に、出力した擬似距離補正值  $\Delta r_{n \rightarrow R}$  を用いて擬似距離測定値  $\rho_{n \rightarrow R}$  を補正する。最後に 2.1 節と同様の計算を行い移動局の位置座標を推定する。

GNSS 測定データを深層学習に適用する際の問題点の一つに「衛星の可視性の変化による GNSS 測定データの不安定性」がある。衛星の仰角や周囲の環境により、各エポックで観測できる衛星の数・組み合わせは時々刻々と変化する。これにより、異なるエポックで採取した GNSS 測定データから抽出できる衛星の数・組み合わせは一定ではない。その結果、各衛星の数・組み合わせに依存したニューラルネットワーク構造は扱いづらい。一方、提案するネットワーク構造は衛星 1 機に対して FFNN が一つ生成されるため、衛星の数・組み合わせに依存せず上記の問題を克服している。

各特徴量の概要と導出方法について説明する。擬似距離残差  $\Delta \rho_{n \rightarrow R}$  は式 (3) で生成される。本ネットワーク構造では、変化量  $\Delta x, \Delta y, \Delta z, \Delta s$  が十分に小さくなったタイミングの擬似距離残差を特徴量に用いる。擬似距離誤差が大きいほど擬似距離残差も大きくなる傾向にあるため、この残差  $\Delta \rho_{n \rightarrow R}$  には擬似距離誤差の大きさを定量的に表すことを期待する。その他の特徴量の概要と導出方法は以下の通りである。

- 衛星の仰角  $El_{n \rightarrow R}$ :

移動局の衛星に対する視線方向と水平面がなす角度である。衛星の仰角は衛星の信号が建物に遮られるかどうかを決定する重要なパラメータであり、GNSS 測定データの品質に大きく影響する。加えて、仰角はマルチパス検出に用いられる特徴量であり、擬似距離誤差に密接に関係している。この仰角  $El_{n \rightarrow R}$  は次式で導出することができる。

$$El_{n \rightarrow R} = \arctan \left( \frac{\hat{u}_{n \rightarrow R}}{\sqrt{\hat{e}_{n \rightarrow R}^2 + \hat{n}_{n \rightarrow R}^2}} \right) \quad (18)$$

ここで、 $\hat{e}_{n \rightarrow R}$  は ENU 座標における移動局位置座標に対する衛星  $n$  の東方向の差分であり、 $\hat{n}_{n \rightarrow R}$  は北方向の差分、 $\hat{u}_{n \rightarrow R}$  は上方向の差分である。 $\hat{e}_{n \rightarrow R}$ ,  $\hat{n}_{n \rightarrow R}$ ,  $\hat{u}_{n \rightarrow R}$  の導出に必要な衛星と移動局の正確な位置座標は不明であるが、擬似距離の測定誤差に比べれば許容できる精度でそれぞれの位置座標を推定することができるため、仰角  $El_{n \rightarrow R}$  を十分な精度で求めることができる。

- 信号強度  $Cn_{n \rightarrow R}$ :

GNSS 測定データの品質に密接に関係のある特徴量であり、重み付き最小二乗法における各衛星の重要度を決定する重み行列  $\mathbf{V}$  を生成する際に仰角  $El_{n \rightarrow R}$  の代わりに用いられることもある。信号強度  $Cn_{n \rightarrow R}$  は、受信機から得られる GNSS 測定データから取得可能である。また、仰角  $El_{n \rightarrow R}$  と同様にマルチパス検出に用いられる特徴量であり、衛星と受信機の位置関係や周辺環境を表現する特徴量として扱うことができる。

- 電離層遅延量  $d_{io,n \rightarrow R}$ :

擬似距離誤差を形成する原因の一つである。高度 100 km 以上の上空に分布する電離層には電波の進行を遅らせる作用がある。受信機が受信する信号は

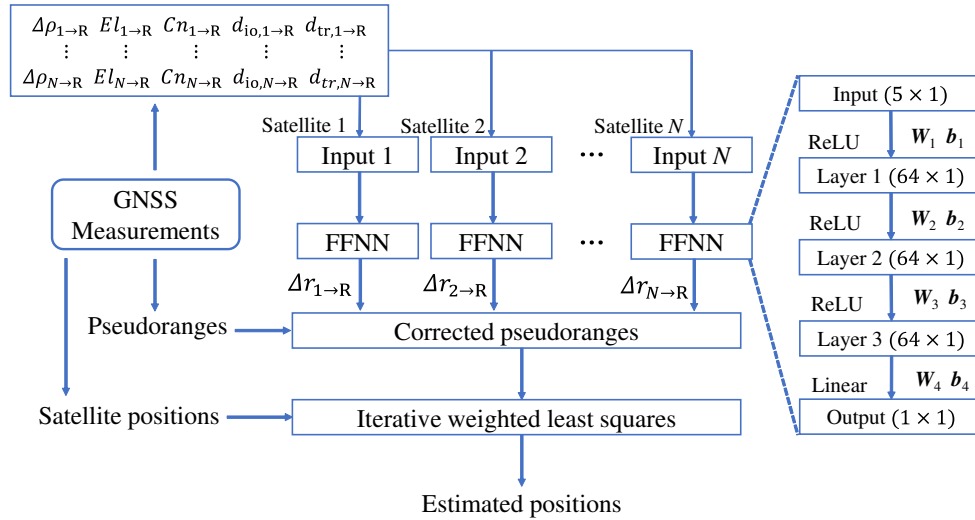


Fig. 4. DGNSS positioning with pseudo-range error correction using FFNN.

電離層がない場合と比較して遅れて到着するため、遅延の分だけ擬似距離が長く測定されることになる。本検討では電離層による影響を半減させる程度である Klobuchar モデルを用いる。Klobuchar モデルでは、GNSS 測定データとして取得できる 8 つの電離層遅延補正係数を利用して電離層遅延量を計算する。

● 対流圏遅延量  $d_{tr,n \rightarrow R}$ :

電離層遅延量  $d_{io,n \rightarrow R}$  と同様に擬似距離誤差を形成する原因の一つであり、2 つを合わせて大気遅延と呼ぶ。電離層を通過した測距信号は地表付近の大気による遅延を受けることになり、海面付近では 2.5 m 程度の大きさとなる。  $d_{tr,n \rightarrow R}$  は気象条件によって増減するが、それほど大きな変化はないので一般的な気象条件を仮定するだけで十分である。したがって、本検討では移動局の高度を  $q$  [m] としたとき次式を用いて導出する。

$$d_{tr,n \rightarrow R} = \frac{2.47(1 - 2.3 \times 10^{-5}q)^5}{\sin El_{n \rightarrow R} + 0.0121} \quad (19)$$

4. 複数基準局の FFNN を用いた DGNSS 測位結果

4.1 データセットの採取

Figure 5 に示す測位器具と u-blox 社の GNSS 受信機 ZED-F9P を用いてデータセットを採取した。本検討は、複数基準局環境を想定しているため、標高 103 m に設置されている基準局 A に加えて、全高 1.7 m の三脚で設置基準局 B, C, D を、全高 1.5 m の三脚で移動局を任




Fig. 5. Positioning equipment.

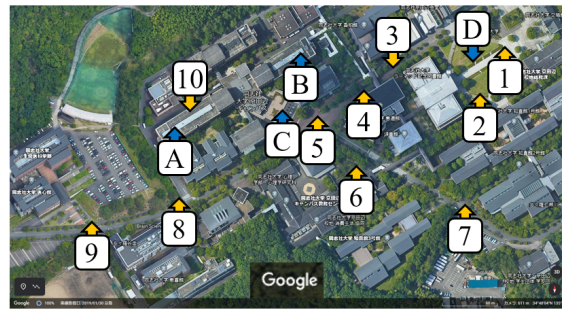


Fig. 6. Collection point for fixed points dataset.

意の地点に設置する。三脚には GNSS アンテナ下方の電波を遮るためのグラウンドプレーンを取り付けている。データセット採取後、RTKLIB 内のソフトウェア rtkconv で ubx フォーマットを RINEX (Receiver Independent Exchange) フォーマットに変換し、RINEX 観測ファイルと RINEX 航法ファイルを得る。RINEX 観測ファイルには擬似距離、搬送波位相、ドップラ周波数、信号強度が RINEX 航法ファイルには衛星軌道情報が格納され



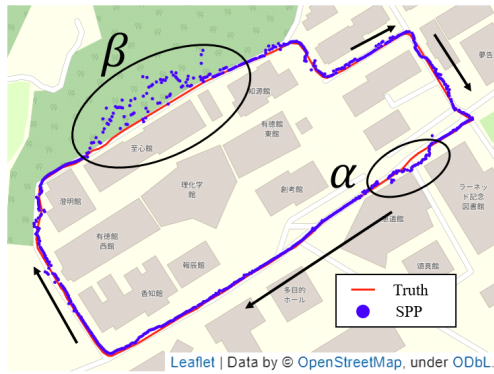


Fig. 7. Collection point for moving points dataset.




Fig. 8. Dataset splitting method.

ており、ここから GNSS 測定データの生の値を抽出できる。

Figure 6 に示す同志社大学京田辺キャンパス内のラベルで定義した固定点のデータセットと Fig. 7 に示す移動点のデータセットで、提案する FFNN-DGNSS の有効性を検証した。固定点データセットでは基準局として地点 A, B, C, D において約 6 時間の採取を行い、それと並行して移動局として地点 1 番から 10 番でそれぞれデータを約 30 分間採取した。1 秒間隔で GNSS 測定データが得られるため、合計データ数は基準局でそれぞれ 21,600 個、移動局でそれぞれ 1,800 個となる。一方、移動点データセットは平均秒速 1.2 m で歩行しながら採取を行っており、固定点データセットと同様に 1 秒に 1 サンプル得られる。基本的に測位精度が良好な 800 個のデータが採取されたが、Fig. 7 の青マークによる SPP 測位結果が示すように区間  $\alpha$ ,  $\beta$  の 2 区間ではマルチパスによって SPP 測位精度が悪化しているため、FFNN で補正することを目的とする。

本検討では、基準局にて補正情報である FFNN をリアルタイムに生成し、移動局に転送するシステムであるため、訓練に用いるデータはテストで用いるデータよりも過去のデータである必要があり、さらに送信する時間

も確保する必要がある。そこで、Fig. 8 のように 1,800 個のテストデータの 1 秒前までの 1,000 秒間における基準局 4 機の GNSS 測定データを訓練に用いる。その結果、テストデータに対応する訓練データ 4,000 個は一定だが、移動局の各地点の採取はそれぞれ別のタイミングで開始しているため、訓練に用いるデータの内容は地点によって変化する。また、各地点の真の位置座標はセンチメートル級の精度で測位することができる RTK で推定した位置座標を利用しており、測位結果を評価する際に利用する。FFNN は Python 向けのライブラリである PyTorch を用いて構築し、学習および推定を行った。

#### 4.2 固定点データでの比較

Figure 9(a) に基準局 4 機で学習した FFNN-DGNSS と単独測位、DGNSS の各地点の平均距離誤差の比較を示す。全地点が都市部や峡谷など GNSS 測位にとって劣悪な環境ではなかったため、全地点の距離誤差は単独測位で 6.0 m を越えず、他地点と比較して劣悪な環境であった地点 3 で 4.63 m、地点 4 で 5.49 m であった。それに伴い地点 1 から地点 10 における平均距離誤差も比較的良好であり、単独測位で 2.26 m、DGNSS で 1.90 m であった。それに対して、FFNN-DGNSS は 1.52 m であり DGNSS と比較して 20% 改善された。特に地点 3、地点 4 のようなマルチパス環境では DGNSS と比較して地点 3 では 4.63 m から 2.24 m の減少で 48% の改善、地点 4 では 5.49 m から 4.34 m の減少で 21% 改善した。しかし、観測環境が良好で単独測位の誤差が 2.0 m 以下の地点 1, 2, 5, 6, 10 では DGNSS と比較して平均で距離誤差が 0.29 m の増加で 37% 悪化した。

直接波が届きやすい地点では、局所的な誤差が小さく大気遅延が支配的である。このような地点では、大気遅延を除去できる従来の DGNSS が FFNN-DGNSS に対して優位であると考えられる。したがって、GNSS 測位にとって良好な環境で FFNN-DGNSS の測位精度を向上させる手法、もしくは FFNN-DGNSS と通常の DGNSS を併用し環境によって切り替える方式などの検討が必要である。以上の結果から、複数基準局を用いた FFNN-DGNSS は GNSS 測位にとって良好な環境では DGNSS と比較して測位精度が悪化した。複数の環境情報を学習したことでマルチパス環境における測位誤差の悪化を大きく軽減することができ、さらに 10 地点の平均距離誤差を 20% 減少させた。

前述したマルチパス環境における測位精度の向上は

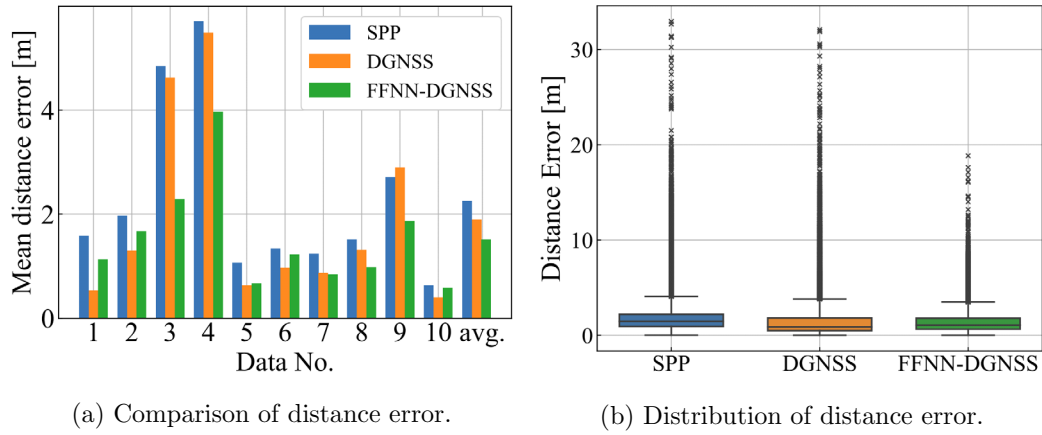


Fig. 9. Distance error of fixed points from FFNN-DGNSS compared with SPP and DGNSS.

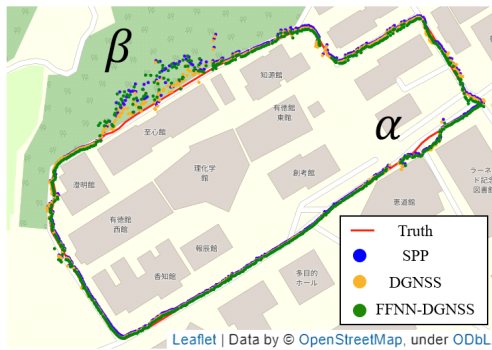


Fig. 10. Trajectories of moving points from FFNN-DGNSS compared with SPP and DGNSS.

Fig. 9(b) に示す箱ひげ図による各方式の誤差分布を比較することでさらに明らかになる。Figure 9(b) は四分位数を用いてプロットしたものであり、色のついた領域は第1四分位点 Q1 から第3四分位点 Q3 までの範囲を示し、水平線は中央値を示す。Q1 と Q3 から縦に伸びている線はそれぞれ  $Q1 - 1.5 \cdot (Q3 - Q1)$ ,  $Q3 + 1.5 \cdot (Q3 - Q1)$  範囲内の最小値、最大値まで伸びており、外れ値は横の線を越えて黒い x 印で示されている。単独測位と DGNSS の外れ値は 5 m から 30 m 以上まで広く分布しており最大で 30 m を超える。それに対して、基準局 4 機で学習した FFNN-DGNSS は最大で 19 m であり、外れ値の抑制に成功している。測位誤差が極端に大きくなるような GNSS 測位にとって劣悪な環境において、FFNN-DGNSS は擬似距離誤差を軽減することにより、DGNSS と比較して安定した測位を行うことが可能である。

### 4.3 移動点データでの比較

Figure 10 に移動点での FFNN-DGNSS と単独測位、DGNSS の軌跡の比較を示す。直接波が届くよう

な GNSS 測位にとって良好な環境では FFNN-DGNSS, SPP, DGNSS いずれも大きな測位誤差は発生していない。しかし、マルチパス環境である区間  $\alpha$ , 区間  $\beta$  では測位誤差が大きく悪化している。この測位誤差を Fig. 11(a) に示した移動平均を用いて平滑化した FFNN-DGNSS の時間による距離誤差の変化で確認する。

各測位方式で 5 m 以上の大きい距離誤差が発生している 40 秒前後、450 秒前後が Fig. 10 の区間  $\alpha$ , 区間  $\beta$  に対応している。軌跡の平均距離誤差は単独測位で 3.23 m であったことに対して、DGNSS が 1.8 m で 44% の改善、FFNN-DGNSS は 2.61 m で 19% 改善された。これは区間  $\alpha$ , 区間  $\beta$  以外の多くの地点で FFNN-DGNSS と DGNSS の測位精度が単独測位を上回っていることに起因する。しかし、FFNN-DGNSS の測位精度は DGNSS と比較して 45% 悪化した。これは Fig. 11(a) の区間  $\beta$  において DGNSS の測位精度が FFNN-DGNSS を大きく上回っていることが原因であり、FFNN-DGNSS は区間  $\beta$  のマルチパス誤差を軽減できなかった。また、4.2 節でマルチパス誤差を軽減できた地点 3, 地点 4 に対応する区間  $\alpha$  においてもマルチパス誤差を軽減できなかった。この違いは、Fig. 8 に示したように訓練に用いたデータの採取した時間帯の違いに起因していると考えられる。つまり、固定点データに対応した訓練データと移動点データに対応した訓練データは異なり、前者からはマルチパス誤差を軽減する特性を得られたが、後者からは得られなかったということであり、訓練に用いるデータによって特性を得られる場合と得られない場合が存在することを確認できた。さらに、Fig. 11(b) に示した FFNN-DGNSS の距離誤差の分布と単独測位、DGNSS との比較において、固定点データの評価で確認できた






Fig. 11. Distance error of moving points from FFNN-DGNSS compared with SPP and DGNSS.

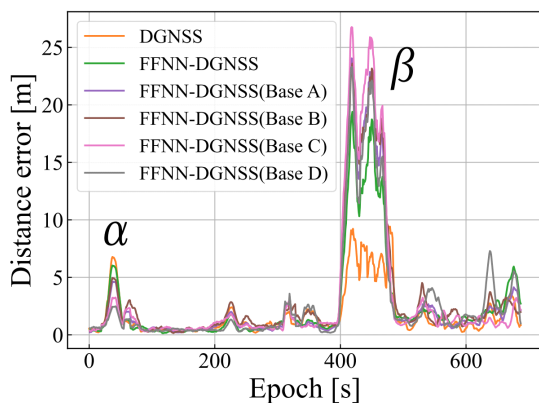


Fig. 12. Distance error of moving points from FFNN-DGNSS learning single and multiple base stations compared with DGNSS.

FFNN-DGNSS の極端な外れ値を抑制する効果を確認できなかった。

4.2 節の固定点での評価では区間  $\alpha$  内に存在する地点 3, 地点 4 で測位精度が向上したことから, 移動点の評価において生成した FFNN は何らかの理由で区間  $\alpha$  における局所的な誤差を学習できなかった可能性が高い。そこで, 局所的な誤差を軽減できなかった原因を特定すべく, Fig. 12 に示すように単一基準局のデータを用いて単一の局所的な誤差を学習した FFNN-DGNSS と基準局 4 機のデータを学習した FFNN-DGNSS, DGNSS の距離誤差の比較を行った。

単一基準局のデータを学習した FFNN-DGNSS の平均距離誤差は, DGNSS および基準局 4 機のデータを学習した FFNN-DGNSS と比較して悪化したが, 区間  $\alpha$  においては単一基準局を学習したすべての FFNN-DGNSS の測位精度が DGNSS を上回った。Figure 13 に示した




Fig. 13. Trajectories of moving points from FFNN-DGNSS learning a single base station (C, D) compared with DGNSS.

特に距離誤差の減少量が大きかった基準局 C, D のデータを学習した FFNN-DGNSS と DGNSS の軌跡の比較からも, FFNN-DGNSS の測位結果が真の位置座標に接近していることが分かる。この測位精度向上は, 基準局 C, D の周辺環境が区間  $\alpha$  と類似していることが優位に働いた結果と考えられ, マルチパス誤差を軽減するためには移動局の周辺環境と類似性が強いデータを学習する必要があることを確認した。一方, Fig. 10 のように周辺環境の類似性が弱い訓練データを同時に学習するとマルチパス誤差への耐性を失ってしまうため, 有効な基準局の訓練データのみ利用する方式や複数基準局の訓練データから有効な特性のみ抽出する手法が必要である。また, 区間  $\beta$  やその他さまざまなマルチパス環境において誤差の軽減を実現するためには, FFNN にさまざまなマルチパス環境を学習させることや, 周辺の環境情報を適切に表現する新しい GNSS 測定データを探索するなどの検討が必要である。

## 5. まとめ

本検討では、ニューラルネットワークの表現能力と擬似距離誤差の周辺環境依存性に着目し、複数の環境で測定したGNSS測定データの学習によって擬似距離誤差の調整を行いDGNSS測位を行うFFNN-DGNSSを提案した。この提案手法を用いて既存技術である単独測位と相対測位の一種であるDGNSSを比較対象として、これらの測位精度を評価した。

提案したFFNN-DGNSSは10点の固定点測位データに対して適用すると、DGNSSと比較して測位精度が平均20%改善し、マルチパス環境では最大で48%改善した。移動点データでの測位では平均で45%悪化した。訓練データに移動局の周辺環境と類似性が強い地点のデータのみを採用した結果、特定の区間で測位精度悪化の軽減を実現できることが確認できた。

今後の課題はオープンスカイ環境での測位精度向上と任意のマルチパス環境における擬似距離誤差を軽減するFFNN-DGNSSを構築することである。そのためには、周辺の環境情報を適切に表現する新しいGNSS測定データの探索、FFNNにさまざまなマルチパス環境を学習させること、および複数基準局の訓練データから有効な特徴を抽出する方式の検討などが考えられる。

## 参考文献

- 1) F. Dovis, L. Ruotsalainen, R. Toledo-Moreo, Z.Z.M. Kassas and V. Gikas, "Recent Advancement on the Use of Global Navigation Satellite System-Based Positioning for Intelligent Transport Systems", *IEEE Intelligent Transportation Systems Magazine*, **12**[3], 6-9 (2020).
- 2) C.J. Hegarty and E. Chatre, "Evolution of the Global Navigation Satellite System (GNSS)", *Proceedings of the IEEE*, **96**[12], 1902-1917 (2008).
- 3) G. Fu, M. Khider and F. van Diggelen, "Android Raw GNSS Measurement Datasets for Precise Positioning", *Proceedings of the 33rd International Technical Meeting of the Satellite Division of The Institute of Navigation (ION GNSS+ 2020)*, 1925-1937 (2020).
- 4) J.A. Klobuchar, "Ionospheric Time-Delay Algorithm for Single-Frequency GPS Users", *IEEE Transactions on Aerospace and Electronic Systems*, **23**[3], 325-331 (1987).
- 5) A. Shrestha and A. Mahmood, "Review of Deep Learning Algorithms and Architectures", *IEEE Access*, **7**, 53040-53065 (2019).
- 6) A. Siemuri, H. Kuusniemi, M.S. Elmusrati, P. Valisuo and A. Shamsuzzoha, "Machine Learning Utilization in GNSS - Use Cases, Challenges and Future Applications", *2021 International Conference on Localization and GNSS (ICL-GNSS)*, 1-6 (2021).
- 7) A. Ruwali, A.J.S. Kumar, K.B. Prakash, G. Sivavara-prasad and D.V. Ratnam, "Implementation of Hybrid Deep Learning Model (LSTM-CNN) for Ionospheric TEC Forecasting Using GPS Data", *IEEE Geoscience and Remote Sensing Letters*, **18**[6], 1004-1008 (2021).
- 8) M. Kaselimi, A. Voulodimos, N. Doulamis, A. Doulamis and D. Delikaraoglou, "Deep Recurrent Neural Networks for Ionospheric Variations Estimation Using GNSS Measurements", *IEEE Transactions on Geoscience and Remote Sensing*, **60**, 1-15 (2022).
- 9) L-T. Hsu, "GNSS Multipath Detection Using a Machine Learning Approach", *2017 IEEE 20th International Conference on Intelligent Transportation Systems (ITSC)*, 1-6 (2017).
- 10) E. Munin, A. Blais and N. Couellan, "Convolutional Neural Network for Multipath Detection in GNSS Receivers", <https://arxiv.org/abs/1911.02347> (2019).
- 11) G. Zhang, P. Xu, H. Xu and L-T. Hsu, "Prediction on the Urban GNSS Measurement Uncertainty Based on Deep Learning Networks with Long Short-Term Memory", *IEEE Sensors Journal*, **21**[18], 20563-20577 (2021).
- 12) M. Asgarimehr, I. Zhelavskaya, G. Foti, S. Reich and J. Wickert, "A GNSS-R Geophysical Model Function: Machine Learning for Wind Speed Retrievals", *IEEE Geoscience and Remote Sensing Letters*, **17**[8], 1333-1337 (2020).
- 13) M. Shao and X. Sui, "Study on Differential GPS Positioning Methods", *2015 International Conference on Computer Science and Mechanical Automation (CSMA)*, 223-225 (2015).
- 14) 坂井丈泰, GPSのための実用プログラミング, (東京電機大学出版局, 東京, 2008).
- 15) 巢籠悠輔, 詳解ディープラーニング 第2版, (マイナビ出版, 東京, 2019).