

# ディープラーニングに基づくドローン飛行エリアの推定 Drone Flying Area Estimation Method based on Deep Learning

浜中 雅俊\*<sup>1</sup>  
Masatoshi Hamanaka

塩見 英樹\*<sup>2</sup>  
Shiomi Hideki

小田 雄一\*<sup>2</sup>  
Yuichi Oda

\*<sup>1</sup> 京都大学  
Kyoto University

\*<sup>2</sup> データ未来研究センター  
datamirai Inc.

We propose a method for predict the flying area of drone. When a drone find another object in the sky, the drone have to speed down or stop for prevent the risk of crash. Then, the drone uses more energy, because rotors of the drone must continue moving while speeding down or stopping. Therefore, we plan to develop a system which controls the traffic of drone by acquiring the positon of each drone.

## 1. はじめに

ディープラーニングを用いてドローンの位置を推定する手法を提案する。衝突を回避するために自動運転中のドローンは、物体を発見すると、速度を低下あるいは停止して回避する。しかし、ホバリング中や低速移動中でもドローンはプロペラの回転を続けているため、回避を行えば行うほどエネルギーを消費することになる。そこで我々は、各ドローンの位置を把握し管制するシステムを構築してドローンのエネルギー効率を向上させること目指している。

従来のドローンでは GPS (グローバル・ポジショニング・システム) による位置検出が行われていたが、ビルの谷間や山の沢や谷では、衛星からの GPS 信号の遮蔽や反射が生じ、正確な位置が求まらない場合があった。また、GPS 信号は微弱であるため、妨害により受信困難となる場合もあった[内山 2014]。

そこで我々は、衛星 3D 地形図を用いてディープラーニング[Hinton 2006]に基づき GPS 信号が受信できない場合でもドローンが飛行しているエリアを推定することを可能とする手法を提案する。従来、ディープラーニングを用いてカメラ画像から人物などの位置を推定する手法は提案されていたが、ドローンのように広範囲を移動する物体が単体で位置を推定する手法は提案されていなかった[Sato 2014]。

衛星 3D 地形図を用いてディープラーニングに基づき位置推定を行う方法について、我々は以下の 5 点の検討を行った。

- **2次元レーザーレーダの使用:** 飛行エリアの推定は、衛星や航空機が取得した 3D 地形図と、ドローンが取得する地表面の形状のパターンマッチングにより実現できる。このとき、航空レーザ測量に用いられる 3次元レーザーレーダを用いて 3D 形状どうしのパターンマッチングを行ったほうが簡単な問題となるが、重量が重くドローンに搭載することは難しい。そこで、本研究では、近年自動車の自動運転などに使用させる小型軽量の 2次元レーザーレーダをドローンに搭載し、2次元の地表断面形状を取得する(図 1)。ドローンによる地表形状ベクトルの取得については 2.1 で述べる。
- **エリア分割:** 衛星や航空機が取得した 3D 地形図とドローンが取得した 2次元の地表断面形状のパターンマッチ

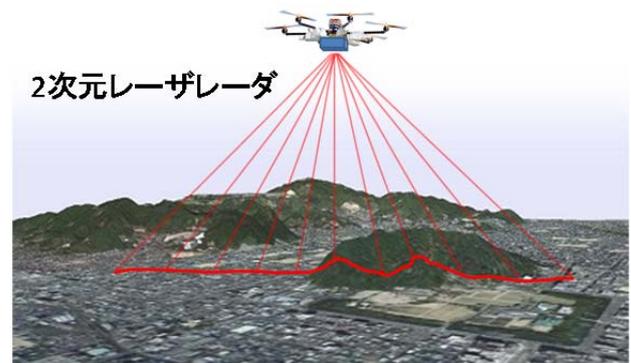


図 1: 地表面の断面形状の取得

ングは、マッチング回数が膨大となり、リアルタイムで処理することが困難である。そこで、我々は推定を行う飛行エリアを分割し、分割された各エリアにラベルを付けることで、位置推定の問題を 2次元の地表断面形状からラベルを推定する機械学習の問題へ置き換える。これにより計算量を大幅に削減することが可能となる。仮に、ドローンの位置をピンポイントで知りたい場合には、分割されたエリア内で 3D 地形図と断面形状のパターンマッチングを行い位置の確定を行えばよい。エリア分割については、2.2 で述べる。

- **ディープラーニングの導入:** 機械学習するのはドローン飛行したときに取得すると想定される 2次元の地表断面形状とドローンが飛行しているエリアのラベルであるが、それらは衛星(あるいは航空)3D 地形図から作成される。衛星 3D 地形図から取得できるデータの量は膨大であるために地表断面形状とそのエリアのラベルとの関係をサポートベクターマシン(SVM)のような手法で求めようとすると、多大な計算時間が必要となるだけでなく、データがメモリに載らず、計算することが困難となる。そこで我々は、機械学習手法としてディープラーニングを導入する。ディープラーニングは、学習データをミニバッチと呼ばれるグループに分割して学習することが可能であるため、多くのデータを用いて学習することが可能で、SVM に比べて容易である。ディープラーニングの一種である DBN (Deep Belief Network)[Hinton 2006]の導入については、3 節で述べる。

- **学習データの抽出率:** ディープラーニングの導入により、2次元の地表断面形状とそのラベルとの関係を学習することが可能となるが、それでも、データ量が多い場合には多大な学習時間がかかってしまう問題がある。ディープラーニングでは、データ件数と学習時間の関係はほぼ比例しているため、学習データをランダムサンプリングするなどして減少させればそれだけ学習時間を短縮することが可能であるが、学習データの量を減少させると今度は精度が減少(エラーレートが上昇)する問題が生じる。4.1では、全データから学習・評価に使用するデータの抽出率の変化によって、性能がどのように変化するかを評価する。
- **マージンの設定:** エリアの境界付近では、類似した地形情報でラベルが異なる場合が生じるため識別が難しい。特に、データの抽出率を低くするとマージン付近でのエリア推定誤りが増加する。そこで学習データについては、エリアの幅に対して一定の割合の幅のマージンを周囲に設け、マージン内にドローンがある場合を学習データから除外することで、性能向上を試みる。4.2, 4.3では、マージンの幅によって性能がどのように変化するかを評価する。

評価実験の結果、エリアの幅に対して5%のマージンを設定して作成した学習データを用いて、層数が11、各層3000ユニットという大規模なネットワークを学習した結果、ドローンが取得した地表面ベクトルから、衛星から取得した3D地形図上のエリアを92.2%の精度で推定可能であることがわかった。

以下、本稿では2節において学習に用いるデータについて説明した後、3節では、ディープラーニングに基づく飛行エリアの推定手法について述べる。そして、4節で評価実験について述べた後、5節でまとめる。

## 2. 学習・評価用データの作成

ドローンの飛行エリアの推定は2つのステップからなる。まず、ドローンに2次元レーザーダを搭載し、地表面の断面形状を取得する。次に、取得した断面形状と人工衛星あるいは航空測量された3D地形図を用いて学習したネットワークを用いてエリアを推定する。本節では、学習・評価用データの作成について述べる。

### 2.1 地表面形状の取得

ドローンに2次元レーザーダを搭載し地表面断面形状を取得する。角度分解能が0.125度であるSICK社のLD-MRSをドローンの鉛直下向きに搭載した場合、上空100メートルを飛行中であれば約20センチ間隔の地表の高度変化を測定することが可能である。そこで、20センチおきに左右に50点ずつ、合計100点の計測点を用意し、その100点とドローンとの高度差を100次元の地表面形状ベクトルとして取得する。

### 2.2 飛行エリアの分割

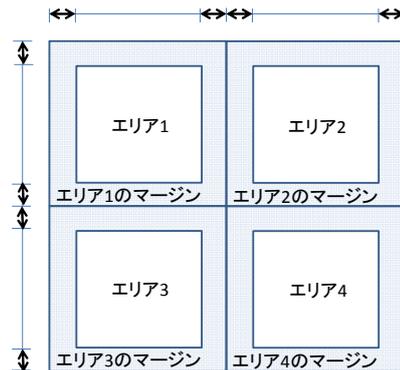
飛行エリアを格子状に分割し、分割で生じた直方体にそれぞれ異なるラベルを付与する。次に、ドローンの位置をランダムに決定し、その時の地表面形状ベクトルを3D地形図から算出したものと、ドローンがいるエリアのラベルの組を学習データとする。4節の評価実験では、手法の基本性能を確認するのが目的であるため、評価データも学習データと同様に、位置をランダムに決定して3D地形図から作成する。その際、同じデータが重複しないように、ドローンの位置が同じものは除外してある。

エリアの境界付近では、類似した地形情報でラベルが異なる場合が生じるため識別が難しい。そこで学習データについては、エリアの幅に対して一定の割合のマージンを周囲に設け、マージン内にドローンがある場合を学習データに含まないようにすることで、性能向上を試みる(図2)。なお、評価実験では、図2bのように縦横高さを含めた3次元空間でのエリア推定について評価する前に、図2aのように高さを100メートルで固定として、高さ方向のエリア分割をしていない場合でのエリア推定の性能についても評価する。

### 2.3 衛星データ

3D地形図のデータとして陸域観測技術衛星ALOS「だいち」のものを用いる[宇宙航空研究開発機構2014]。10cm程度の高分解能の航空地形図も有料で入手可能であるが、どの程度高分解能な3D地図が必要であるかわかっていないため、今回は無料のだいちのものを用いる。だいちの分解能が30mであるため、1/150にすることで、疑似的に分解能20cmの地形図として使用する。エリアは、一辺30mの立方体で、各方向にそれぞれ5個重ねて、125個のエリアを生成した(図2b)。実験では、東経135°40'00"から135°52'29"、北緯35°00'00"から35°12'29"の衛星3D地形図を用い、高さは地上100mから250mの範囲とした。

(a) 2次元でのエリア分割(縦2×横2)



(b) 3次元でのエリア分割(縦5×横5×高さ5)

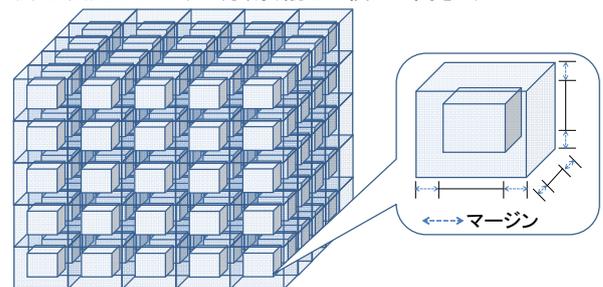


図2: エリアの分割とマージン

### 2.4 データ抽出率

飛行エリアは、縦横高さごとの分解能を20センチとしている。1辺30メートルの立方体を縦横高さ方向に5個重ねた全エリアからデータを取得してくるとすると、ドローンの向いている方位を固定した場合でもデータ件数は4億件を超える。これらのデータをメモリ上に載せて計算することは困難であり、また、データを分割したとしても、学習時間が多大で現実的ではない。そこで、ある一定の抽出率でエリアごとにランダムでデータをサンプリングしてくることで現実的な時間で計算が終了するようにする。

### 3. ディープラーニングに基づく飛行エリア推定

3D 地形図と 2 次元レーザで取得する地表面形状とのパターンマッチは、マッチング回数が非常に多くなるため、通常の方法ではリアルタイムで行うことが難しい。そこで本稿では、ディープラーニングの一手法である DBN (Deep Belief Networks) [2] を用いてリアルタイムで地表面形状から飛行エリアを推定可能とする。

ディープラーニングには、コンボリュージョナル・ニューラルネットワーク (Convolution Neural Network: CNN) [Krizhevsky 2012], 多層パーセプトロン (Multi-Layer Perceptron : MLP) [Rosenblatt 1962], DBN [Hinton 2006] などがあるが、DBN の特長は、プレトレーニングと呼ばれる事前学習を制約付きボルツマンマシン (Restricted Boltzmann Machine: RBM) で行うため、様々なデータに対して汎用的に用いることができる点である。我々の扱う地表面の断面形状というデータは、そこから意味を見つけることが難しいデータであることから、DBN を用いるのが望ましいと考えた。

図 3 は飛行エリアを推定するための DBN である。入力は、100 次元の地表面形状ベクトル、出力は、各エリアを表すラベルである (図 3)。中間層は  $n$  層あり、本稿での実験では簡単のため各層のユニット数はすべて同じとした。入力層と中間層、中間層と中間層、中間層と出力層の間は、全結合のネットワークである。

DBN の学習は、プレトレーニングと呼ばれるラベルデータを用いずに行う教師なし学習と、ファインチューニングと呼ばれるラベルデータを用いた教師付き学習の 2 段階で行われる。

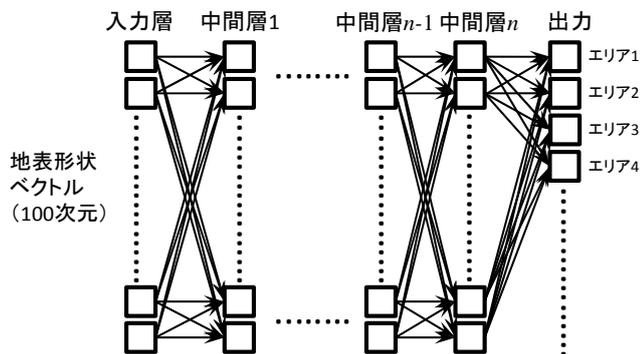


図 3: 位置推定のための DBN

## 4. 実験結果

本節では、まず 2 次元でのエリア分割の性能を確認した後 3 次元でのエリア分割について評価する。

### 4.1 データ抽出率による性能変化 (2 次元)

縦横 30 メートルのエリアを縦横 2 個ずつ並べた計 4 つのエリアの識別性能を、データ抽出率を 4 割、2 割、1 割と変化した時の性能を比較した。全データ数は、225 万件 ((30 メートル (1 辺の長さ) / 0.2 (分解能 20 センチ))<sup>2</sup> (縦横 2 方向) × 4 (エリア数)) である。たとえば 4 割の場合では、90 万件 (225 万 × 0.4) の学習データとなる。評価データは、全データの 1 割の 22.5 万件で、学習データとの重複は無い。4 割以上のデータを使って学習することも可能であるが、GPGPU 上のメモリに載せられるデータ量として 4 割までとした。GPGPU に載せないサイズのデータを載せる場合には、CPU メモリからの転送が必要となり計算時間が大幅に増加してしまう。

表 1 はデータ抽出率を変化させた時の正解率の変化を示したものである。正解率は 1 からエラー率を引いた値で、4 割の時最も高く、2 割、1 割の順に低くなった。すなわち、学習に用いるデータ件数が多いほど正解率は高くなり、件数が少なくなるほど正解率も低くなることが確認された。なお、ネットワーク構造は、中間層数 7、ユニット数は 60、学習 Epoch 数は 3000 とした。

表 1: 抽出率の違いによる正解率の変化 (2 次元)

データ抽出率	4 割	2 割	1 割
正解率 [%]	97.8	86.4	85.0

### 4.2 マージンありなしの比較 (2 次元)

4.1 と同じ 4 つのエリアの識別性能について、マージンを設けた場合と設けなかった場合の性能を比較した。マージンの幅は、エリアの 1 辺 30 メートルの 0% (マージンなし)、1% (幅 30 センチ)、5% (幅 150 センチ) の 3 通りを比較した。学習データは 4.1 の 4 割と同じ 225 万件、評価データは 4.1 と同様の 22.5 万件を用いた。中間層数、ユニット数、学習 Epoch 数も 4.1 と同様である。

表 2 はその結果で、マージン 0 パーセントが一番正解率が高く、マージン 5% で一番性能が低かった。このことから、十分な学習データがある場合には、マージンは小さい、あるいは、ないほうが性能が高いことが確認された。

表 2: マージンの幅による正解率の変化 (2 次元)

マージンの幅	0%	1%	5%
正解率 [%]	97.8	96.7	92.0

### 4.3 マージンありなしの比較 (3 次元)

1 辺 30 メートルの立方体のエリアを、縦横高さ方向にそれぞれ 5 個重ねた 125 のエリアでの推定精度を評価した。学習時間や GPGPU あるいは CPU のメモリ容量には限界があることから、エリア数を増加させていくと、1 エリアあたりの学習データの件数は次第に減少させていかざるを得ない。ここでは学習データが不足していった場合、すなわち抽出率が低い場合でマージンを設定することが有効であるか確認する。

学習データの抽出率は 1 割、評価データの件数は学習データの 4 分の 1 とした。そして、学習/評価データに 1 辺 30 メートルの 5 パーセントの幅のマージン内のデータを含む場合と含まない場合のデータを作成し評価した。

DBN の中間層数は 1 から 15 の 15 通り、ユニット数は 1000、2000、3000 の 3 通りを Epoch 数 300 まで学習を行い、最も性能の高かった中間層数 11、ユニット数各 3000 のネットワークを用いて 3000 Epoch まで学習した。

その結果、学習データにも評価データにもマージン内のデータを含む (a) に比べ学習データでマージン内のデータを含み評価データにはマージン内のデータを含まない (b) のほうが高性能であることから、マージンのデータで検出誤りが多いことが確認できた。学習データにも評価データにもマージン内のデータを含まない (d) が最も高いことから、GPS などで位置を把握して、その確認のためのエリア推定であれば、学習データにマージンを含まないほうが良いことが確認された。一方、学習データにマージン内のデータを含まず評価データにマージンのデータを含んだ (c) の場合に非常に性能が低くなったことから、ドローンの位置を本手法のみで求める場合には、学習データにマージンを含んで学習したネットワークを用いるのが良いことが確認された (表 3)。

図 4 は, (a)から(d)それぞれの学習曲線である. 3000Epoch までの学習時間は約半日である.

表 3: マージンあり/なしの正解率(3次元)

	(a)	(b)	(c)	(d)
学習データ	含む	含む	含まない	含まない
評価データ	含む	含まない	含む	含まない
正解率 [%]	84.7	86.3	72.2	92.2

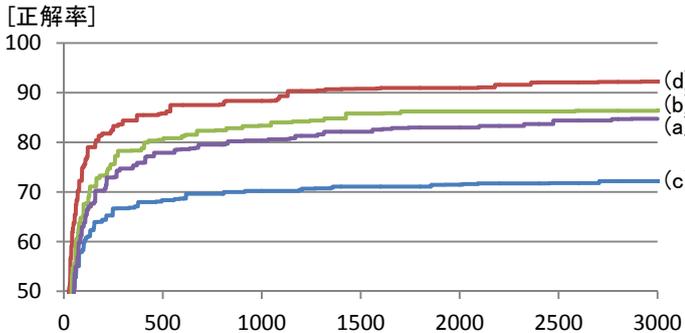


図 4: マージンあり/なし(3次元)の学習曲線 [Epochs]

## 5. おわりに

ディープラーニングで地表面形状を学習することで GPS が使用できない条件下でも位置の推定を可能とする手法について述べた. 1辺 30 メートルの立方体のエリアを縦横高さ方向に 5 つ重ね 125 のエリア生成し, 抽出率 1 割のデータを用いて実験した結果, 5 パーセントのマージンを設定することで性能が 92.2%まで向上することを確認した.

本研究の意義は以下の 3 点である.

- **衛星データに基づく位置推定手法の提案:** ドローンの産業利用が進められているが, 現状の多くのドローンの位置推定は GPS のみで行われている. したがって, 有事に GPS 信号が遮断されたり, 妨害された場合には, 運用が困難になるが, 本研究で提案した手法を併用することで, たとえ GPS が受信できない場合でも位置推定が可能となることを示した.
- **ディープラーニングの導入による計算量の削減:** トマホーク(巡航ミサイル)も事前に入力した衛星データ(レーダー地図)とのマッチングにより位置を検出しているため, 本手法に近いと言える. ただし飛行ルートが決まっていデータ量が少ない上に, 弾頭に 3 次元レーザレーダを積載しているためリアルタイムでマッチングを取ることは難しい. 一方ドローンに搭載するレーザレーダの取得した 2 次元の地形断面と衛星 3D 地形図のマッチングは計算量が大きすぎて通常のマッチング手法では非現実的であったが, ディープラーニングに基づく学習を行い, 学習済みのネットワークをドローンに搭載することで, リアルタイムでの位置推定が可能となった.
- **エリアの境界部分のマージンの提案:** メモリ容量と学習時間の制約から, 識別するエリアの数が増加すると, 1 エリアあたりの学習データが疎になる結果, エリアの境界部分での識別精度が低下する問題があったが, エリアの境界部分にマージンをとり, その部分のデータを学習データから除外することにより, 識別性能が向上することを示した. 今回は, 125 のエリアの識別で 7.5 パーセント正解率に違いが出たが, エリアが数千になった場合には, 正解率にさらに大きな違い出ることが予想される.

本手法を実際に利用する上で以下の 4 つの課題がある.

- **実機の飛行による性能評価:** 本稿では, 手法の基本性能を確認するため, 学習・評価データの両方を衛星データから作成していた. 手法を実際に利用した場合の真の性能を評価するためには, ドローンを実際に飛行して, 実環境での評価が必要である.
- **長距離を飛行の場合のアルゴリズムの構築:** 本稿では, 1 辺 30 メートルの立方体を縦横高さ方向に 5 つ重ねた, 150 メートル立方の中でのエリア識別を行った. 長距離を飛行するドローンのエリアを推定する場合には, 経路全体をエリア分割して学習したネットワークを用いてエリア推定する手法や, 直前にいたエリアの付近にドローンがいると仮定して, その付近の学習済みネットワークを用いてエリア推定する手法など, 複数の方法が考えられる. いずれの方法が良いか評価・検討を行っていく.
- **ピンポイントでの位置推定する場合の検討:** 本稿では, 1 辺 30 メートルの立方体のエリアを推定する手法を提案したが, GPS ポイントのようにピンポイントで位置を知りたい場合には, 推定された 1 つの立方体のエリアの 3D 地形図とドローンが取得した 2 次元地形断面とのパターンマッチングを行う必要が生じる. このとき, エリアの立方体の 1 辺の長さ(今回は 30 メートル)によって, 位置をピンポイントで推定するまでの時間が変わってくることになる. 最も高速に推定できるエリアの 1 辺の長さについて検討する.
- **GPS との連携方法の検討:** 現状では, GPS が取得できないのはビルの谷間や山の沢や谷などの地域である. また, 高精度な位置検出が必要になるのは, ドローン同士がすれ違ったり, ドローンが住宅街へ着陸していくような場合と考えられる. GPS と提案手法をどのように連携させるのが効果的であるかについて検討していく.

今度, 各ドローンの位置を正確に把握したドローンの管制システムを構築し, 多くのドローンを安全に高効率で飛行させることを目指してゆく.

## 参考文献

- [内山 2014] 内山 彰, 勝田 悦子, 上嶋 祐紀, 山口 弘純, 東野 輝夫 : 都市区画における GPS 衛星の見通し判定を用いた位置精度向上法の提案, 情報処理学会論文誌, Vol.55, No.1, pp.389-398, 2014.
- [Hinton 2006] Hinton, G. E., Osindero, S. & Teh, Y.-W. : A fast learning algorithm for deep belief nets. *Neural Comp.* 18, pp. 1527-1554, 2006.
- [Sato 2014] Sato, I. and Niihara, H.: "Beyond Pedestrian Detection: Deep Neural Networks Level-Up Automotive Safety", GPU Technology Conference 2014.
- [Rosenblatt 1962] Rosenblatt, F: *Principles of neurodynamics; perceptrons and the theory of brain mechanisms*, Washington, Spartan Books, 1962.
- [Krizhevsky 2012] Krizhevsky, A., Sutskever, I., and Hinton, G. E.: Imagenet classification with deep convolutional neural networks, *Advances in neural information processing systems*, pp. 1097-1105, 2012.
- [宇宙航空研究開発機構 2014] 宇宙航空研究開発機構: だいち画像を活用した世界最高精度の全世界デジタル 3D 地図の整備について. [http://www.jaxa.jp/press/2014/02/20140224\\_daichi\\_j.html](http://www.jaxa.jp/press/2014/02/20140224_daichi_j.html)