

ディープラーニングによる航空レーザ測量データからの地すべり地形認識

五大開発株式会社 正会員 ○荒木光一 非会員 柏大吾 非会員 伊藤兎
 非会員 関家史郎 非会員 山森一彦
 国立研究開発法人 土木研究所 非会員 櫻本智美 正会員 藤平大

1. はじめに

航空レーザ測量データ (LP データ) で地すべり地形を判読することにより, 空中写真では判読が困難であった地すべり地形を判読できるようになった. しかしながら, 地すべり地形判読は個人差があるだけでなく, 多大な時間を要する.

これらの問題を解決するために, 我々はディープラーニングによる LP データからの地すべり地形判読に関する研究を行っており, これまでに, ディープラーニングで LP データを地すべり地形と非地すべり地形に分類することが概ね可能であることを確認している [1]. 本稿では, 入力された LP データに地すべり地形の全体または一部が含まれているか否かをディープラーニングで判別できるのかを確認し, その精度を評価する (図-1).

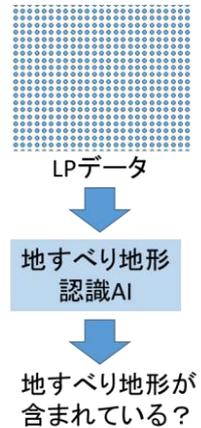


図-1 本研究の概要

2. データ作成

図-2 に, ディープラーニングで用いるデータの作成フローを示す. まず, 図-3 のように地すべり地形を囲む地すべり BOX を作成し, 図-4 のように地すべり地形の全体または一部を含むように地すべり BOX をランダムに拡大縮小・BOX のスライドを行う. そして, この BOX 内の LP データを取得する. 非地すべり地形のデータは, 地すべり地形以外の領域でランダムに非地すべり BOX として作成し, この BOX 内の LP データを取得する.

次に, 地すべり地形と非地すべり地形の LP データを訓練データ・検証データ・テストデータを分割する. 訓練データの非地すべり BOX の LP データ数は地すべり地形より少なかったため, 図-5 のように分割してデータ数を増加させた. 全 LP データに対して, 標高を標高差に変換し, 1000m で正規化した. 訓練データの地すべり地形と非地すべり地形共に, データ数を増加させるために, 左右, 上下, 上下左右の反転によりデータ数を増加させた. ディープラーニングを行うためには全 LP データの高さと幅を統一する必要があるため, リサイズを行う.

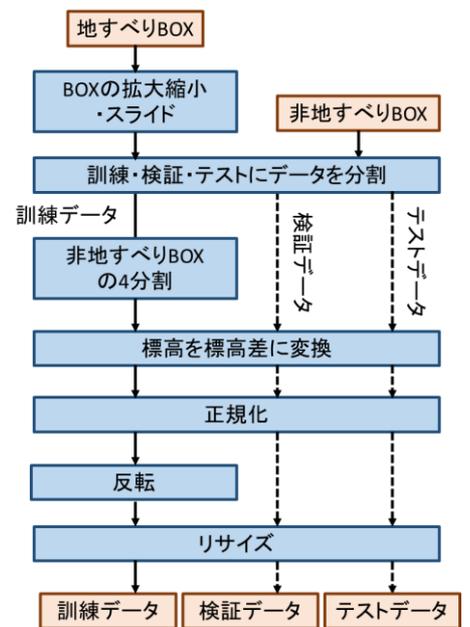


図-2 データ作成フロー



図-3 地すべり BOX (実線) と非地すべり BOX (点線)

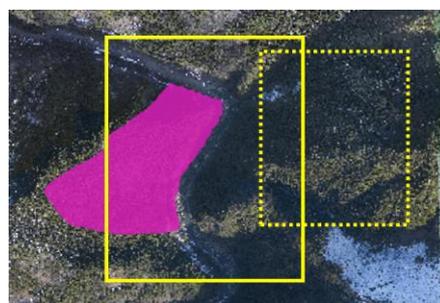


図-4 拡大縮小・スライド処理の例

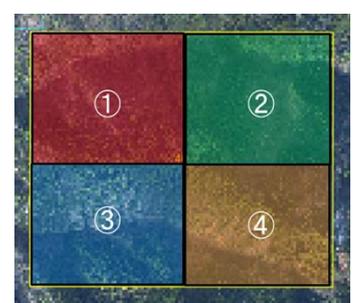


図-5 訓練データの非地すべり BOX の 4 分割

キーワード 地すべり, 地すべり地形判読, LP データ, ディープラーニング

連絡先 〒921-8051 石川県金沢市黒田1丁目35番地 五大開発株式会社 TEL 076-240-6588

表1 訓練・検証・テストのデータ数

地域	地すべり地形			非地すべり地形		
	訓練データ数	検証データ数	テストデータ数	訓練データ数	検証データ数	テストデータ数
奈良	796	20	17	800	20	40
新潟	800	20	307	800	20	17
静岡	204	5	1	240	5	8
高知	796	20	272	800	20	20
合計	2,596	65	597	2,640	65	85

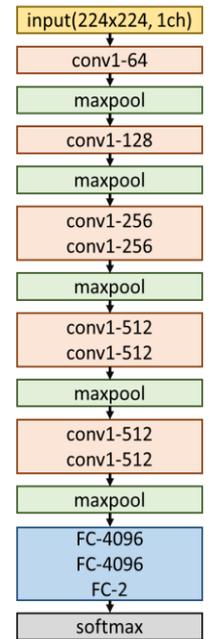


図-6 利用した DNN

3. ディープニューラルネットワーク (DNN)

DNN の構成を図-6 に示す. 図中の conv1 は 1 チャンルの畳み込みニューラルネットワーク, FC は全結合層を示す. conv 1 と FC の後ろの数値はそれぞれフィルタ数とノード数である. conv1 と FC-4096 の活性化関数は ReLU とした. 過学習を抑えるために FC 間には Dropout (レート: 0.5) を挿入し, conv1 と FC では L2 正則化 (ペナルティ: 0.001) を施した. 入力チャンネルは 1 とし, 地すべり地形を含むか否かを判断するため最終層の FC は 2 ノードとした. 最適化手法には SGD を用い, このモーメントムは 0.9 とした. 重みの初期値として conv1 と FC-4096 には He の手法[2], FC-2 には Grolot の手法[3]を用いた.

4. 評価

評価には奈良, 新潟, 静岡と高知の LP データとこれらによる地すべり地形判別結果を用いた. これらのデータから訓練・検証・テストのデータを作成した. 表1 に, 各データ数を示す.

DNN への訓練データの投入ではバッチサイズを 16 とし, 1 エポックの学習が完了したタイミングで訓練データをシャッフルした. SGD の学習率は 0.01, 0.001 の順で変化させて学習させた. 学習率 0.01 においてテストデータの正解率が最も高いモデルの重みを学習率 0.001 の初期値として与えた.

表2 に, テストデータに対する推論結果を示す. 正解率は 79% となった. 図-7 は表2 の赤字部の尤度を示す. 高知の尤度の幅は地すべり地形と非地すべり地形共に広く, 地すべり地形の尤度が 100% に達するデータも存在する. 奈良・静岡・新潟では高知より尤度の幅が小さく, 地すべり地形の尤度は最大で 85% に留まっている. これは, 奈良・静岡・新潟より高知の地すべり地形の特徴を多く捉えていると考えられる. 奈良・静岡・新潟の地すべり地形から特徴を更に抽出するためには, 奈良・静岡・新潟の訓練データ数を増加させるなどを行う必要がある.

5. おわりに

LP データに地すべり地形が含まれているか否かをディープラーニングで判別し, 正解率は 79% となった. 今後は, 判読エリアをグリッド分割したデータに対して推論を行う. また, 地すべり地形の形状抽出も行う予定である.

参考文献

[1] 荒木光一, 柏大吾, 伊藤兎, 関家史郎, 山森一彦, 櫻本智美, 藤平大, “深層学習によるレーザプロファイラデータからの地すべり地形認識の検討”, 2018 年電子情報通信学会総合大会, p.58, 2018 年 3 月.

[2] Kaiming He, Xiangyu Zhang, Shaoqing Ren and Jian Sun, “Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification,” Proc. of International Conference on Computer Vision, pp.1026-1034., 2015.

[3] X. Glorot, Y. Bengio, “Understanding the difficulty of training deep feedforward neural networks,” Proc. of International Conference on Artificial Intelligence and Statistics, pp.249-256, 2010.

表2 テストデータの推論結果

		推論結果	
		地すべり地形	非地すべり地形
正解	地すべり地形	476	121
	非地すべり地形	20	65

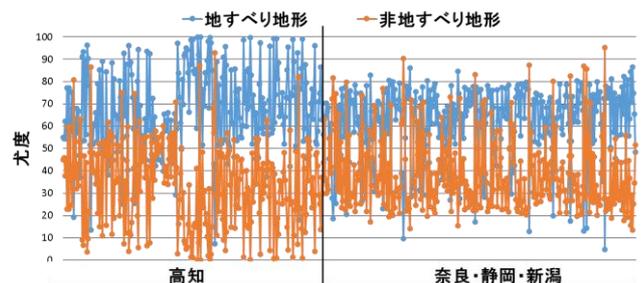


図-7 高知と他の地域における尤度の比較