

マルチチャネル情報を利用した畳込みニューラルネットワークによる SAR 画像解析

○中山良彬, 間普真吾, 呉本亮 (山口大学)

概要 合成開口レーダ (SAR) 画像を用いた被災地域の検出は、豪雨や地震の多い日本において重要な技術である。しかし現在の技術において、被災地域の判読前に行われる処理に掛かるコスト、判読における時間コスト、正確で迅速に判読が出来る人員のコストなど多くのコストを要する事が問題となっている。機械学習を用いて分類する場合、訓練時に用いるサンプルの属するクラスが極端に偏ることで、分類結果も偏る可能性がある。また局所領域のみで分類を行うことが多いため、周囲の状況が見えていない可能性もある。そこで本論文では、2つの提案を行う。1つ目は訓練時に用いるミニバッチに各クラスから同じ数のサンプル数だけランダムに選択し、学習を行う方法である。2つ目は分類対象領域の情報に周辺領域の情報を付加し、サンプルをマルチチャネル情報化する方法である。マルチチャネル情報化には2通りある。1つが分類対象領域を中心とする大きさの異なるパッチ画像を切出し、最大サイズのパッチ画像に合わせてサイズの小さいパッチ画像をゼロパディングする方法である。もう1つが切出した周辺領域ごとに畳込み処理とプーリング処理を行い、生成された特徴マップを合成し分類を行う手法である。従来手法と提案手法を斜面崩壊地域の分類問題に適用し性能評価シミュレーションを行った結果、提案手法の分類性能が優れていることを明らかにした。

キーワード: SAR 画像, 畳込みニューラルネットワーク, 衛星リモートセンシング

1. 序論

被害が広域に及び、複数個所に同時多発する大規模災害が発生した場合、その被害把握にはこれまで航空機調査が行われてきた。しかし調査に時間を要する為、近年では広域を一度に観測できる衛星リモートセンシングが注目されている¹⁾。日本では毎年のように台風や豪雨による被害が発生しており、首都直下型地震や南海トラフ地震のような大規模災害が切迫している為、衛星リモートセンシングによる被害状況の把握は極めて重要である。地震や豪雨は土砂崩れのような斜面崩落を引き起こす。斜面崩落はアクセスが困難な場所や複数個所で発生するため現地での被害把握が困難である。また夜間に被災した場合や被災地が悪天候に見舞われた際、迅速な被害把握を阻害する可能性がある。以上の観点から衛星リモートセンシングによる斜面崩落域の検出に関して多くの研究が行われている。多くの手法では被災前後の光学衛星画像から算出される正規化植生指数 (Normalized Difference Vegetation Index, NDVI) の変化量から斜面崩落域の検出を行っている^{2,3)}。NDVI は観測された可視域赤と近赤外線との反射の度合いを利用して計算される。しかし光学衛星は撮影時に悪天候であると、正しく観測出来ない可能性がある。そこで近年では天候に影響されず観測できる合成開口レーダ (Synthetic Aperture Radar, SAR) 画像から被災地を判読する方法が注目されている。しかし SAR 画像を実用化させるには幾つかの問題がある。SAR 画像にはスペックルノイズと呼ばれる SAR 特有のノイズがあり、判読を困難にしている。それらを除去する処理や被災前後の衛星画像の位置関係を合わせる処理を行う計算コストが掛かる。また広大な画像を迅速に判読するための人的コストが掛かる。SAR 画像の判読には知識や経験が必要になる為、判読を行う人員を集める事が困難である。

これらの問題を解決するため、被災後のみの画像に対して機械学習を用いることにより斜面崩落域を検出する。画像の識別には一般的に畳込みニューラルネットワーク (Convolutional Neural Network, CNN) などの手法が用いられる。衛星画像から被災地の特定を行うには画像をメッシュ状に区切り、それら一つ一つのパッチ画像に対して分類を行う⁴⁾。分類を行うユニットの事を分類器と言う。広大な衛星画像から土砂崩れを特定する為、出来るだけ小さいパッチ画像に分割しその領域が被災しているか正常かを分類する。その際、以下の二つの問題が考えられる。一つ目はパッチ画像による学習において局所領域の特徴のみで学習しなければならない問題である。二つ目は正常クラスに偏っている画像群を分類器の学習に用いることにより、分類結果が正常クラスに偏る問題である。

本論文ではこれらの問題を次の方法により解決する。一つ目の問題については、分類を行う領域を中心として、サイズの異なる画像を切り取り、それらを合成して一枚の画像にすることで分類性能の向上を図る。二つ目の問題については、分類器の一回の訓練に用いるミニバッチに各クラスの画像数が同じになるようランダムに選択することで分類器の推測の偏りを無くす。




Fig. 1: Geometry of SAR

2. 合成開口レーダ (SAR) 画像

合成開口レーダ (synthetic aperture radar, SAR) は航空機や衛星などのプラットフォームに搭載された小さなアンテナを使って仮想の大きなアンテナを合成し、高分解能のレーダ画像を生成する能動型の映像レーダである。能動型のセンサの為、太陽光や雲の有無にかかわらず良好なデータ取得が可能になっている。SAR画像の応用分野は農学、災害、海洋、地学など多岐にわたっている。実利用されている技術もあるが研究途上の分野も多い。

SARはマイクロ波を射出し、地海面から反射されたマイクロ波を受信することにより、画像生成している。Fig. 1にSARの幾何学的構成を示す。アンテナはプラットフォームと垂直方向からオフナディア角 (off-nadir angle) θ_0 でマイクロ波を照射する。照射方向はスラントレンジ (slant-range) 方向と呼ばれ、照射方面ではグラウンドレンジ (ground-range) 方向と呼ばれる。照射方向と直行するプラットフォーム進行方向はアジマス (azimuth) 方向と呼ばれる。照射面での垂線と照射方向のなす角 θ_1 は航空機に搭載されたSARの場合はオフナディア角と殆ど同じになるが、衛星画像の場合は地球表面を考慮するとオフナディア角より数度大きくなる。

SARアンテナから射出されたマイクロ波が伝導体や誘導体に入射すると電流が誘起され誘起電流からマイクロ波を再放射する。これを散乱 (scattering) といい、入射波の反対方向への散乱を後方散乱 (backscattering) という。あくまで散乱に起因する拡散反射を後方散乱と呼ぶため、鏡面反射とは異なる。衛星は後方散乱してきたマイクロ波を受信し、画像再生処理を行う。電磁波の散乱強度は周波数、波長、散乱体の電気的特性 (誘電率など) に強く依存する。このため海水や金属で構成される乗用車などは電流が誘起されやすい為、強く反射する。逆に砂や木などは電流が誘起されづらい為、あまり反射しない。

SAR画像の各画素には受信したマイクロ波の強度が表現されている。反射するマイクロ波は受信する際に干渉し合い、隣接する画素値にノイズを与える。これをスペckルノイズといい、撮影対象の分類を困難にしている⁵⁾。

3. 畳込みニューラルネットワーク

3.1 基本構造

脳の複雑な動きを模倣し、そのメカニズムを応用して様々な問題を解決するアルゴリズムとしてニューラルネットワークが提案された。畳込みニューラルネットワーク (Convolutional Neural Network, CNN) は画像に描かれている物体を認識する為に生物の視覚野に関する神経科学の知見をヒントに提案された NN である。CNN は画像から物体を認識する為に複数の処理層によって認識しやすい形へと処理を行う。一般的な CNN は Fig. 2 のような構造で表現される。Fig. 2 のように CNN は主に畳込み層とプーリング層、全結合層の三種類の層によって構成される。畳込み層は入力された画像に対して任意のフィルタ処理を行う。フィルタ処理を行うことで画像中にある物体を認識する為に有用と




Fig. 2: Structure of CNN

なる特徴を抽出することが出来る。プーリング層は基本的に畳込み層の直後に設置され、畳込み層で得られた特徴の位置感度を低下させる。それによって特定の特徴が画像ごとに異なる位置で発生した場合においてもプーリング層の出力が一定になる。例として画像から猫を認識する際、猫の特徴が画像内の同じ場所にいつも現れることはほとんどない。特徴が多少ずれた場所にあっても認識できる役割をプーリング層は持っている。複数の畳込み層とプーリング層によって抽出された特徴を全結合層によって統合し認識する⁶⁾。

3.2 ミニバッチ学習

CNN の学習では、入力サンプルの与え方に様々なバリエーションがある。その一つが逐次学習であり、一つの入力に対して誤差を計算し内部パラメータの更新を行う方法である。そのほかに、バッチ学習とミニバッチ学習がある。逐次学習は1つのサンプルに対して更新を行うため、サンプルによって更新量が大きく変化する。ノイズの入ったサンプルがあれば更新量は大きく変化し誤差が収束しない可能性がある。バッチ学習は全てのサンプルを用いて修正量を求める学習法である。その為、ノイズには強いが一回あたりの修正に時間が掛かる。ミニバッチ学習は逐次学習とバッチ学習の中間的立場の学習法で、少数のサンプルをひとまとめにし、その単位で内部パラメータの更新をする。このひとまとめにしたサンプル集合をミニバッチという。ミニバッチが含んでいるサンプル数は予め決定するが、この値は学習に大きな影響を与える。この決定を行うための系統的な手法はないが、並列計算資源、誤差の収束のしやすさなどを考慮し、およそ10~100サンプル前後とすることが多い⁶⁾。

3.3 SAR 画像解析への応用と評価方法

本研究では斜面崩落域を機械学習によって検出する。被災後の SAR 画像を分類器に入力し、画像の特徴から斜面崩落域を発見する。本論文で使用した SAR 画像を Fig. 3 に示す。この画像は陸域観測技術衛星 2 号「だいち 2 号」 (ALOS-2) により 2017 年 7 月 7 日に北部九州を撮影したものである。本地域は、2017 年 7 月 5 日から 6 日にかけて発生した集中豪雨により大規模な土砂災害が発生した地域である。図中にある赤い点は元のグレースケールの画像に対して専門家が被災地域の場所をマークしたものである。CNN の入力に用いる画像には、赤いマークなしのものを使用する。CNN を

Table 1: Confusion Matrix

| | | 予測クラス | |
|-------|----------|----------------|----------------|
| | | Positive | Negative |
| 正解クラス | Positive | True Positive | False Negative |
| | Negative | False Positive | True Negative |

SAR 画像解析に応用した場合, SAR 画像をメッシュ状に区切り一つ一つのメッシュ (パッチ画像) を入力する. メッシュ領域内の被災領域を検知するように CNN は学習する. 訓練用サンプルを用いて学習を行った後, テストサンプルを用い性能評価を行う. 性能評価には混同行列 (Confusion Matrix) を用いる. 混同行列は各クラスについて正分類した回数と誤分類した回数を数えた表である. Table 1 に混同行列の一般的な形を示す. 例えばあるサンプルを Positive クラスと予測したとき, 正解が Negative クラスだった場合, 誤って Positive クラスと分類しているため, False Positive の数が 1 増加する. 混同行列からは性能を評価するための指標が計算できる. 評価指標には以下のようなものがある.

(1) 正分類率 (Accuracy)

全てのテストサンプルの内正しいクラスに分類できた割合を示す.

$$Acc = \frac{TP + TN}{TP + FP + FN + TN} \quad (3.1)$$

(2) 適合率 (Precision)

Positive と予測したサンプルの内, 真のクラスが Positive だったサンプルの割合を示す.

$$Precision = \frac{TP}{TP + FP} \quad (3.2)$$

(3) 再現率 (Recall)

Positive クラスのサンプルの内, Positive クラスとして正分類することが出来たサンプルの割合を示す.

$$Recall = \frac{TP}{TP + FN} \quad (3.3)$$

(4) F 値 (F-measure)

適合率と再現率のトレードオフに対してそのバランスを評価する指標である.

$$F - measure = \frac{2Recall \times Precision}{Recall + Precision} \quad (3.4)$$

4 提案手法

本論文では 2 つの手法を提案する. 1 つが入力する画像サンプルマルチチャンネル化である. もう一つは訓練時に用いるミニバッチの作成方法についてである. それぞれの提案手法には以下のような目的がある. 1 つ目の提案手法は分類対象となる領域の周辺情報を付加することで分類精度を向上させることである. 2 つ目は訓練サンプル集合の中で各サンプルが帰属するクラスに偏りがあった場合でも分類精度が低下しないようにする事である. 4.1 節では従来方法の問題点について説明する. 4.2 節, 4.3 節では提案手法の具体的な方法について説明する.




Fig. 3: SAR image

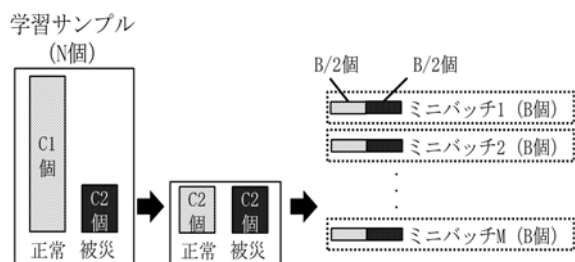


Fig. 4: Selecting method of mini-batch samples

4.1 従来法の問題点

入力画像サンプルについて従来の方法では、分類対象となる領域をパッチ画像として切り取り分類器の入力として訓練とテストを行ってきた。この方法では局所的な領域内にある特徴のみを用いて分類を行う必要があり分類精度が向上できない可能性がある。パッチ画像を大きいサイズにすると分類精度は向上する。しかしながら衛星画像の分類では斜面崩落個所の特定を目的としているため、出来るだけ小さなパッチ画像で分類を行う必要がある。パッチ画像が属するクラスは画像全体に対して斜面崩落域が占める面積の割合によって決定することにし、本論文では割合が 0.4 を上回った場合は危険領域とみなし、下回った場合は正常領域とみなした。この問題に対して、分類対象となる領域そのものとそれを中心とした周辺領域をパッチ画像として切り取る。それらを加工し、ひとまとまりのマルチチャネル画像にする事により、周辺領域の情報を付与し分類精度を向上させる。

従来のミニバッチ学習法では訓練サンプルはクラスとは無関係にランダムに順序が入れ替えられ、ミニバッチを作成し分類器に入力される。衛星画像の分類に対して、この方法を用いて分類器を訓練すると危険クラスの識別精度が低くなる。なぜなら広大な衛星画像の大部分は正常領域であるからである。パッチ画像として分割した場合、正常クラスに属する訓練サンプル数が多く、危険クラスに属する訓練サンプル数が少なくなる。これらの訓練サンプルを用いてミニバッチを作成すると、ミニバッチ内の訓練サンプルも帰属クラスの数に偏りが生じる。この結果、分類器の学習も正常クラスに偏り、正常クラスの分類精度は高くなるが危険クラスの分類精度は低くなる。危険領域の検出を目的としているため、正常領域に対する分類精度のみが向上しても有用ではない。この問題に対し、正常クラスと危険クラスの双方から同じ数だけランダムに選択しミニバッチを作成する方法を提案する。それにより、各クラスに対する学習の偏りを無くし分類性能を向上させる。

4.2 ミニバッチ用サンプル選択法 (提案法 1)




Fig. 5: Overview of Zero Padding Method

提案するミニバッチ用サンプル選択法の概観を Fig. 4 に示す。訓練サンプル集合は危険クラスと正常クラスに分けられる。クラスごとにサンプルを $B/2$ 個ランダムに選出する。選出された B 個のサンプルをミニバッチとしてまとめる。それを用いてネットワークの訓練を行う。訓練を終えると、再び各クラスからサンプルを選出してミニバッチを作成する。この手順について、危険クラスの訓練サンプルが一通り選出されるまで繰り返す。この 1 回のサイクルを 1 エポックとし、予め設定したエポック数に到達するまで繰り返す。

4.3 マルチチャネル画像 (提案法 2)

分類対象領域とその周辺領域をパッチ画像として切り取った後、マルチチャネル情報として組み合わせる。しかし、マルチチャネル画像として CNN に入力するには画像サイズを同じにする必要がある。その方法について 2 パターン提案する。一つがゼロパディング法である。サイズの異なるパッチ画像をマルチチャネル画像にまとめる際、サイズの小さい画像をゼロパディングし、サイズの大きい画像と同じ大きさにする方法である。もう一つがマップ合成 CNN (CCNN) によるものである。サイズの異なるパッチ画像ごとに畳み込み層とプーリング層を適用し、抽出されたマップのサイズを同じにする。それらを合成することによりマルチチャネル画像とする。具体的な方法については 4.3.1 節と 4.3.2 節で説明する。

4.3.1 ゼロパディング法 (提案法 2-1)

ゼロパディング法を用いたマルチチャネル画像生成の概観を Fig.5 に示す。Fig. 5 のように分類領域とそれを中心とした周辺領域について何パターンかパッチ画像として切出す。切出した画像はそれぞれサイズが異なる。1 枚のマルチチャネル画像とするために、小さいパッチ画像はゼロパディングにより最大サイズ画像と同じ大きさの画像にする。それらを 1 枚のマルチチャネル画像としてまとめる。Fig. 5 のように 3 パターン切出した場合、3ch 画像が生成される。

4.3.2 特徴マップ合成 CNN (提案法 2-2)

ゼロパディング法では CNN に入力を行う直前で画像を加工した。マップ合成 CNN (CCNN) では切出し

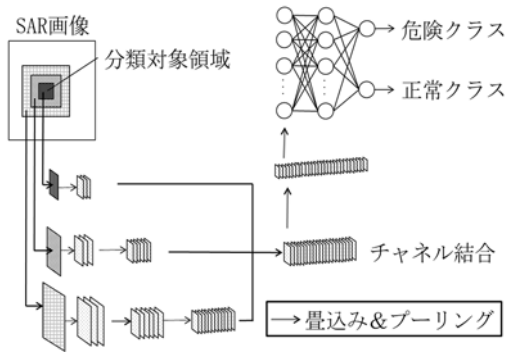


Fig. 6: Overview of CCNN

Table 2: Number of patch images (Simulation1)

| | 訓練用 | テスト用 |
|-----|-------|-------------|
| ABN | 250 | 183 |
| NOR | 13758 | 13825 (183) |

た分類領域と周辺領域をそのまま CNN の入力とする。ネットワークの概観は Fig. 6 のようになる。切出したパッチ画像ごとに畳込み層とプーリング層の処理がなされ、特徴マップの大きさが同じになるまで処理を繰り返し合成する。さらに畳込み層とプーリング層で処理をした後、全結合層の入力とし、最終的に出力層においてクラス分類を行う。これにより、分類に有効な特徴を入力画像ごとに抽出することができる。

5 シミュレーション

本章では提案手法の有効性を検証する。5.1 節ではミニバッチの作成方法における提案法について従来手法と比較する。5.2 節ではマルチチャンネル画像の生成を行う提案手法について従来手法と比較する。これらのシミュレーションでは、Fig. 3 に示す SAR 画像を用いた。

5.1 シミュレーション 1

シミュレーション 1 ではミニバッチ作成法について、従来法との比較を行った。SAR 画像を縦半分に分割し、右側を訓練用領域とし左側をテスト用領域とした。訓練用領域とテスト用領域は 32×32 ピクセルのパッチ画像に分割した。パッチ画像内に危険領域の画素が 40% 以上含まれている場合、そのパッチ画像を危険領域クラスとしそれ以外は正常領域クラスとした。テスト用領域と訓練用領域から抽出された各クラスのパッチ画像の枚数を Table 2 に示す。Table 2 中の ABN は危険領域クラス、NOR は正常領域クラスを表している。訓練用サンプルは全て用い、テスト用サンプルについては、ABN と NOR のサンプルを同数にするため、ランダム抽出により NOR のサンプルを ABN のサンプルと同数にした。使用した CNN の構造を Fig. 7 に示す。




Fig. 7: Structure of CNN (Simulation1)

Table 3: Performance evaluation of the conventional and proposed methods

| | Acc | Precision | Recall | F-measure |
|-----|-------|-----------|--------|-----------|
| 従来1 | 0.5 | 0 | 0 | 0 |
| 提案1 | 0.671 | 0.688 | 0.650 | 0.669 |

conv は畳込み層を表し、pool はプーリング層を表す。各畳込み層で用いられるカーネルサイズは 3、パディング幅は 1、ストライド幅は 1 とした。各プーリング層で用いられるカーネルサイズは 2、パディング幅は 1、ストライド幅は 2 とした。fc 層は全結合層を表し、そのユニット数は 16 とした。

この分類器に対して、従来のミニバッチ学習を適用した場合と提案したミニバッチ学習を適用した場合について比較する。5 回試行し、それらの平均を取ることで、性能比較を行った。Table 3 に、従来法と提案法のミニバッチ学習により得られた各種評価指標を示す。本結果より従来手法は分類が極端に偏っているため、適合率、再現率、F 値が提案手法より非常に低いことが分かる。

5.2 シミュレーション 2

シミュレーション 2 ではパッチ画像のマルチチャンネル画像化を行う提案手法とその他の手法について比較した。シミュレーション 1 と同様に SAR 画像を縦半分にし、右半分を訓練用領域、左半分をテスト用領域とした。シミュレーション 2 で用いられる各手法は 8×8 のパッチ画像を分類することを目的とした。従来法と提案法におけるバリエーションを Table 4 に示す。Table 4 の従来法 2 は $8 \times 8 \times 1$ のパッチ画像を CNN の入力とした場合である。比較法は分類対象となる 8×8 を中心とした 128×128 のパッチ画像である。比較法を用意した理由は、提案手法が最大で 128×128 のパッチ画像を利用して分類を行うため、与える情報を平等にしたときの結果を比較するためである。但し、比較法のクラス分類はあくまで中心の 8×8 の領域にある危険領域の割合に依存する。Table 4 の提案手法 2-1_3ch, 5ch とはゼロパディング法により、それぞれ 3ch と 5ch のマルチチャンネル画像を生成した場合を表しており、2-2_3ch, 5ch は CCNN について、それぞれ

Table 4: Methods for comparison used in Simulation 2

| | チャンネルごとの画像サイズ | | | | | |
|-------|---------------|------|-------|---------|-------|---------|
| | 1ch目 | 2ch目 | 3ch目 | 4ch目 | 5ch目 | |
| 従来手法1 | 8×8 | - | - | - | - | |
| 従来手法2 | 128×128 | - | - | - | - | |
| 提案手法 | zero3ch | 8×8 | 64×64 | 128×128 | - | |
| | zero5ch | 8×8 | 64×64 | 128×128 | - | |
| | CCNN3ch | 8×8 | 32×32 | 64×64 | 96×96 | 128×128 |
| | CCNN5ch | 8×8 | 32×32 | 64×64 | 96×96 | 128×128 |

Table 5: Number of Patch images (Simulation2)

| | 訓練用 | テスト用 |
|-----|--------|---------------|
| ABN | 7812 | 5804 |
| NOR | 204188 | 206196 (5804) |




Fig. 8: Structure of CNN (Conventional method 2)

3ch と 5ch の画像を生成したことを表している. Table 5 に SAR 画像から抽出されたパッチ画像の枚数を示す. 次に従来法 2 で用いた CNN の構造を Fig. 8 に示す. 2-1_3ch, 5ch, 比較法で用いた CNN の構造については Fig. 7 と同様である. 次に 2-1_3ch で用いた CCNN の構造について Fig. 9 に示す. また 2-2_5ch で用いた CCNN の構造について Fig. 10 に示す. 各畳込み層で用いられるカーネルサイズは 3, パディング幅は 1, スライド幅は 1 とした. 各プーリング層で用いるカーネルサイズは 2, パディング幅は 1, スライド幅は 2 とした. fc 層は全結合層を表す. 2-2_3ch での全結合層のユニット数は 256 とした. 2-2_5ch での全結合層のユニットは 64 とした. CCNN では concat 層で入力される全ての特徴マップをチャンネル同士で連結させる処理を行う. この時, 特徴マップ同士は縦横サイズが同じでなければならない. 2-2_5ch 中の zeropadding 層は特徴マップに対してゼロパディングを行う層である. この層を追加することで特徴マップのサイズを合わせている.

各手法を適用した結果を Table 6 に示す. Table 6 に示されている赤字は各評価指標について, 全手法の中で最も高かった数値を表している. この結果から提案法 2-2 の分類性能が高いことが分かる. Fig. 11 に訓練ごとの正分類率の変化を表す. この結果から提案法 2-2 の分類性能が高いことが分かる. Fig. 12 に訓練ごとのテスト誤差の推移を示す. 提案法 2-1 について, 25 エポック周辺で最小の誤差になっている. しかし, その後過学習を起している. 対して提案法 2-2 では過学習を起していない.

6 考察

本論文では二つのシミュレーションを行った. 一つが

Table 6: Performance evaluation indices (Simulation2)

| | Acc | Precision | Recall | F-measure |
|---------|--------------|--------------|--------------|--------------|
| 従来法2 | 0.502 | 0.302 | 0.503 | 0.377 |
| 比較法 | 0.709 | 0.664 | 0.730 | 0.696 |
| 2-1_3ch | 0.721 | 0.643 | 0.761 | 0.697 |
| 2-1_5ch | 0.727 | 0.672 | 0.756 | 0.711 |
| 2-2_3ch | 0.731 | 0.689 | 0.752 | 0.719 |
| 2-2_5ch | 0.731 | 0.665 | 0.782 | 0.719 |

提案ミニバッチ学習と従来のミニバッチ学習の比較である. もう一つがパッチ画像をマルチチャンネル情報化する提案手法の適用である. それぞれのシミュレーションの結果, 提案手法が従来手法より優れていることが分かった.

シミュレーション 1 の結果に関して, 提案法 1 が従来法 1 優れていることが分かった. 従来法 1 の評価指標が極端に低いのは, 分類が正常クラスに偏っていた為であると言える. この結果から提案手法は各クラスの特徴を正しく学習できることが分かった.

シミュレーション 2 の結果から, 各提案手法の分類性能が他の手法より優れている事が分かった. 従来法 2 の結果から, 細かいパッチ画像を用いると正分類が出来ないということが分かった. 比較法は分類対象領域を中心とし, 分類対象領域より大きい 1ch の画像である. クラス分けの方法が中心の分類領域に依存する為, 分類領域の周辺情報を付与した 1ch のサンプルである. 比較法と提案法の結果を比較すると, 提案法の分類評価指標が比較法の分類評価指標より高い数値を示している. この結果から, 周囲の状況も複数のパターンを考慮してマルチチャンネル化することに効果があることが分かった. 提案法について, ゼロパディング法においては 25 エポック周辺で高い正分類率を示したことが Fig. 11 から分かった. それ以降のエポックでは過学習を起していることから, ゼロパディング法による提案手法は高い分類性能があるが学習が安定し

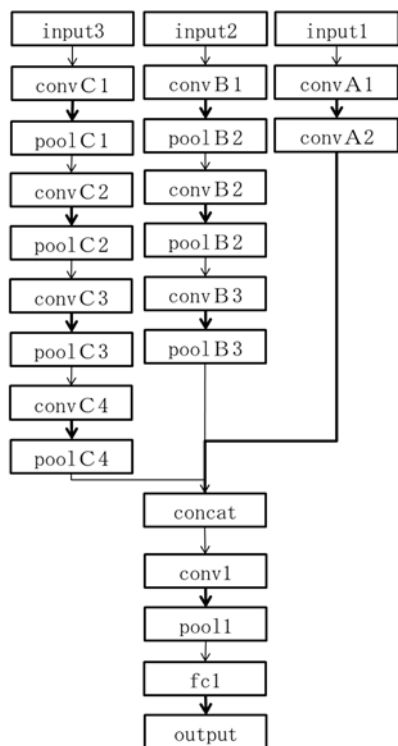


Fig. 9: Structure of CNN (3ch)

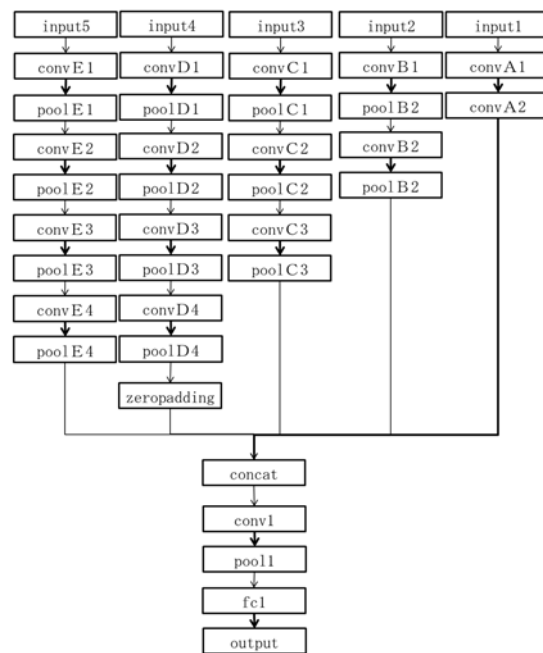


Fig. 10: Structure of CNN (5ch)

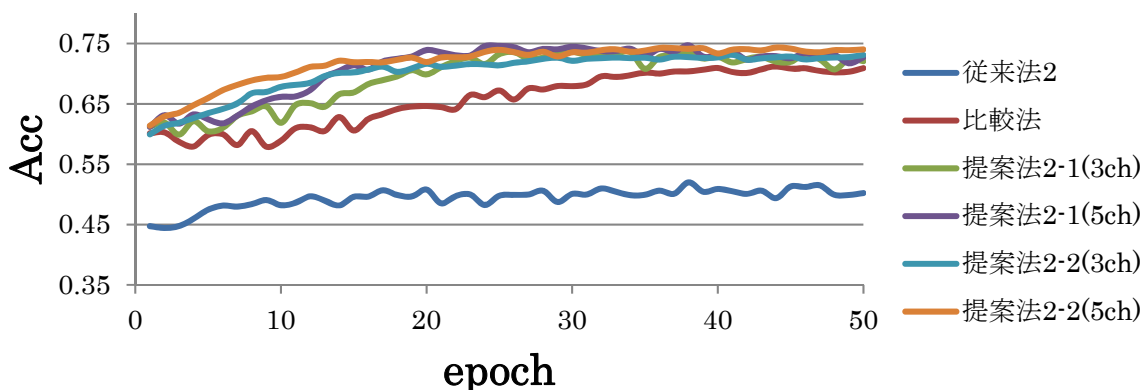


Fig. 11: Transition of Accuracy by Epoch

ないという特徴があると考えた. CNN は過学習を起こすことなくゼロパディング法と同等の分類性能があることから, 高い分類性能と安定性が特徴であると言える. ゼロパディング法が高い分類性能を示した原因として以下の考察を行う. ゼロパディング法ではマルチチャンネル画像を生成する時, 面積の小さい画像を大きい画像に合わせてゼロパディングする. 当該チャンネルの不要な部分をゼロで埋めることで抽出したい画像の特徴を限定することが出来たため, 高い分類性能を引き出すことが出来たと考える. しかし, 訓練エポックが長くなった場合, ゼロで埋めた部分をさらに分類の特徴として学習しようとしたため過学習を起こしたと考える. 一方, CNN はそれぞれの範囲の特徴抽出

を独立して行い, それらを合成し一枚の特徴マップとして分類を行った. ゼロパディング法とは異なり冗長なゼロの領域がない為, 高い分類性能がありながらも過学習が起きづらくなっているのではないかと考えた. しかし, 各手法の適合率は十分に高いとは言えず, ABN クラスサンプルが NOR クラスサンプルに類似しており, 分類が困難なサンプルが多くあると考えた. また本シミュレーションでは分類対象領域内にある危険領域の面積の割合が閾値の 0.4 を超えた場合を ABN クラスサンプルとした為, 割合が閾値周辺であったサンプルデータが正分類できなかった可能性がある. クラス分け条件となる閾値と分類器に用いるパラメータの設定を改善することにより更なる分類性能の向上が




Fig. 12: Transition of Test Error by Epoch

期待できる。

7 結論

本論文では、畳込みニューラルネットワークにより、SAR 画像を解析し、斜面崩落域の検出を可能にする為に二つの手法を提案した。一つがミニバッチ内にある各クラスサンプル数を同じにするミニバッチ学習であり、もう一つが SAR 画像の分類対象領域の周辺情報を加えマルチチャンネル化したパッチ画像によって分類を行う手法である。提案したミニバッチ学習は従来のミニバッチ学習より高い分類精度を示した。このことから、各クラスのサンプル数が極端に偏った場合において提案ミニバッチ学習法の有用性が明らかになった。また、マルチチャンネル画像の提案法が従来法の分類精度を上回ったことにより、分類対象領域の周辺情報を付与する方法の有用性が明らかになった。

考察で記述したように、パラメータの設定が分類精度に関わる為、最適なパラメータの設定が課題である。また CNN は教師あり学習によって学習するため、人手でクラス分けされた多くの訓練データが必要であることが課題として残る。データの作成には時間的コストがかかるため、比較的多く存在する正常時の SAR 画像や、他の場所や日時で起こった災害時の SAR 画像の情報を転用する学習の枠組み作りが必要である。

参考文献

- 1) 鶴殿俊明,吉川和男,野田敦夫,水木正樹,林真一郎,佐藤匠,岡本敦:高分解能 SAR 画像を用いた河道閉塞箇所抽出手法の検討, 砂防学会研究発表会概要集, 188/189, (2012)
- 2) 三浦弘之,翠川三郎:高分解能衛星画像と数値標高モデルを用いた 2004 年新潟県中越地震での斜面崩落地の検出, 日本地震工学学会論文集,第 7 巻,第 5 号, (2007)
- 3) 石出貴大,山崎文雄:ALOS/AVNIR-2 画像を用いた 2008 年岩手・宮城内陸地震における斜面崩壊の検出, 日本地震工学学会論文集,第 10 巻,第 3 号, (2010)
- 4) 郷右近英臣, Joachim POST, Enrico STEIN, Sandro MARTINIS, André TWELE, Matthias MÜCK,越村俊一: TerraSAR-X 画像の機械学習による津波被災地の自動検出, 土木学会論文集 B2 (海岸工学) Vol69, No.2, (2013)
- 5) 日本リモートセンシング学会編著,「基礎からわかるリモートセンシング」,理工図書株式会社, (2011)
- 6) 岡谷貴之,「深層学習」, 講談社 (2015)