サポートベクターマシンを用いたSAR画像からの津波被害建物検出法の開発

東北大学 学生会員 ○遠藤 幸夫
 東北大学災害科学国際研究所 正会員 Bruno Adriano
 東北大学災害科学国際研究所 正会員 越村 俊一

1. はじめに

大規模災害の発生直後は、甚大な被害を受けた地域からの情報が断片的となり、被害全容の把握が困難となる。東北地方太平洋沖地震津波では、通信システムの損害により迅速な被害調査が行えず救援活動が難航した。広域被害把握の方策として、Synthetic Aperture Radar（以下、SARとする）によるリモートセンシングが注目されている。

SARは夜間や悪天候時でも緊急観測が可能であり、災害被害把握での活躍が期待されている。また、TerraSAR-Xのような高分解能SARを搭載した衛星センサの打ち上げにより、津波により流出した建物を一棟ベースで抽出することが可能となった。しかしながら、より詳細な被害程度の分類についてはさらなる検証が必要である。例えば、Gokon *et al.*(2015)の提案した決定木を適用した多クラス識別法では、大量の学習データを必要とするので実用化においては課題が残る。

そこで、上記の問題を解決するために、Support Vector Machine（以下、SVMとする）を用いた津波被害建物の多クラス被害検出法を提案する。SVMは少量のデータでも効率的な学習が可能であり、建物の流出・残存といった2クラスの分類においては被害建物を高い精度で検出できると実証されている(Wieland *et al.*2016)。本研究では、津波被害検出において広く用いられているSAR画像間の差分値、相関係数を特徴量として用いる(Liu *et al.*2013)。様々なサイズのピクセルウィンドウで計算した特徴量から多次元的な識別関数をSVMにより学習し、3クラスでの被害分類を試みる。

2. 使用データと解析環境

本研究では、仙台市沿岸部を対象地域とし、2010年10月20日(UTC)と2011年3月12日(UTC)にStripMapモードで被災地を撮影した空間分解能約3mのTerraSAR-X画像を使用する。なお、ウィンドウサイズ3×3のLeeフィルタによりスペックルノイズを低減させる。前処理後のSAR画

図-1 本研究の対象領域と使用データ((a)被災前のTerraSAR-X画像, (b)被災後のTerraSAR-X画像)

表-1 対象地域の被災状況

被害区分	棟数
流出	4115
全壊(補修困難)	834
全壊	615
大規模半壊	1329
半壊(床上浸水)	2716
一部損害(床下浸水)	1130
被災なし	825

像と本研究の対象領域を図-1に示す。

建物の被害データとして、国土交通省による建物被害状況調査を参照する。対象領域内での調査結果を表-1にまとめる。このうち、流出をLevel3、全壊(補修困難)をLevel2、それ以外をLevel1として被災区分を再編成する。

SAR画像の前処理にはENVI(ver.5.4)、その他の画像処理や空間情報処理にはArcGIS(ver.10.1)を使用する。また、SVMの実装はPython(3.6.3)を使用する。

3. 本研究の手法

(1) 建物ごとの変化抽出

前処理を施したSAR画像から後方散乱係数の差分値 $d[db]$ と相関係数 r を式(1), (2)により計算した。

$$d = \bar{I}b_i - \bar{I}a_i \quad (1)$$

$$r = \frac{N \sum_{i=1}^N I a_i I b_i - \sum_{i=1}^N I a_i \sum_{i=1}^N I b_i}{\sqrt{\left(N \sum_{i=1}^N I a_i^2 - \left(\sum_{i=1}^N I a_i \right)^2 \right) \cdot \left(N \sum_{i=1}^N I b_i^2 - \left(\sum_{i=1}^N I b_i \right)^2 \right)}} \quad (2)$$

$I a_i$ と $I b_i$ は被災前、後の画像でのピクセル番号*i*の後方散乱係数であり、 N はウィンドウ内のピクセル数、 $\bar{I} a_i$ と $\bar{I} b_i$ はウィンドウ内での後方散乱係数の平均値である。ウィンドウサイズは 5×5 , 9×9 , 13×13 , 17×17 , 21×21 , 25×25 の6種類を採用し、合計12種類の特性値を求めた。

次に、建物輪郭データと算出した特性値画像を重ね合わせた。この際、衛星方向への建物の倒れ込みを補正するために、全建物の高さが6mだと仮定し、東に7.8m、南に1.4mの輪郭移動を行なった。その後、建物輪郭に内包されるピクセルでの特性値ごとの平均値を計算し、対象建物の変化を表現する特徴量として抽出した。

(2) SVMの適用

本研究では、1対1方式を導入したSVMにより学習データから被害区分と特徴量の関係則を学習する。なお、各クラスあたり100個の建物をランダムに選定し学習データとして使用した。このとき、10回交差検証法を用いて以下の手順によりSVMのチューニングを実行した。

まず、個々の特徴量の平均が0、分散が1となるようにスケールを変換した。次に、過学習を避けるために再帰的特徴量削減を学習データに施した。そして、グリッドサーチにより最適なハイパーパラメーターを決定した。なお、カーネル関数としてRBFカーネルを採用した。

その後、改めて全ての学習データの用いて、チューニングを施したSVMにより識別関数の学習を行なった。

(3) 識別性能の評価

SVMにより学習した識別関数を基に対象領域の建物被害地図を作成し、現地調査との比較を行なった。識別器の汎化能力を評価するために、学習にしようしなかった全データを対象にAccuracy、及びkappa統計量を算出した。

4. 結果

本研究で作成した建物被害地図と現地調査を比較したものが図-2である。また、学習に使用しなかった全ての建物を対象に混合行列を作成すると表-2のようになり、Accuracyが74.5%、kappa統計量が0.55であった。

表-2 識別結果の比較

		現地での被害調査			
		Level3	Level2	Level1	U.A.(%)
識別結果	Level3	2948	200	524	80.3
	Level2	697	217	762	7.7
	Level1	370	317	5227	88.4
	P.A.(%)	73.4	30.0	80.1

図-2 建物被害地図((a)現地での被害調査, (b)SVMによる識別結果)

5. おわりに

本研究では、SVMを用いてSAR画像から津波被害建物を検出する手法を提案し、検証を行った結果、本手法により被害建物を複数の区分に高い精度で分類できると明らかにした。決定木を用いた既往研究では、同様のデータセットを用いて、各クラスあたり700個の学習データにより推定した識別器のkappa統計量が0.47であり、本研究の手法は従来よりも学習効率が非常に良いと言える。

参 考 文 献

Gokon, H., Post, J., Stein, E., Martinis, S., Twele, A., Mück, M., Geiß, C., Koshimura, S., Matsuoka, M.(2015), A Method for Detecting Buildings Destroyed by the 2011 Tohoku Earthquake and Tsunami Using Multitemporal TerraSAR-X Data, *IEEE Geosci. Remote Sens. Lett.*, Vol.12, No.6, pp1277–1281.

Liu, W., Yamazaki, F., Gokon, H., and Koshimura, S. (2013), Extraction of tsunami-flooded areas and damaged buildings in the 2011 Tohoku-oki earthquake from TerraSAR-X intensity images, *Earthq. Spectra*, Vol.29, No.S1 pp.183–200.

Wieland, M., Liu, W., and Yamazaki, F. (2016), Learning Change from Synthetic Aperture Radar Images: Performance Evaluation of a Support Vector Machine to Detect Earthquake and Tsunami-Induced Changes, *Remote Sens.*, Vol.8, pp.792–812.