HOKKAIDO UNIVERSITY

Title	TerraSAR-Xデータを使用したランダムフォレストによる作付作物の分類
Author(s)	山谷, 祐貴; 薗部, 礼; 谷, 宏 他
Citation	北海道大学大学院農学研究院邦文紀要, 34(2), 1-11
Issue Date	2017-03-30
Doc URL	https://hdl.handle.net/2115/64961
Type	departmental bulletin paper
File Information	3_yamaya.pdf

Hokkaido University Collection of Scholarly and Academic Papers : HUSCAP

北大農研邦文紀要 34(2)：1〜11，2017

TerraSAR-X データを使用したランダムフォレストによる作付作物の分類

山谷祐貴*・薗部礼**・谷宏***
王秀峰***・小林伸行****・望月貫一郎*****
（*北海道大学大学院農学院，**静岡大学農学部，***北海道大学大学院農学研究院，****スマートリンク北海道，*****株式会社パスコ）

Crop Classification by Random Forest Using TerraSAR-X Data

Yuki YAMAYA*, Rei SONOBE**, Hiroshi TANI***, Xiufeng WANG***, Nobuyuki KOBAYASHI****
and Kan-ichiro MOCHIZUKI*****
(* Graduate School of Agriculture, Hokkaido University, Sapporo 060-8589, Japan,
** Faculty of Agriculture, Shizuoka University,
*** Research Faculty of Agriculture, Hokkaido University, **** Smart Link Hokkaido,
*****PASCO Corporation)

Ⅰ．背景と目的

近年，国や地方自治体では，業務合理化の一環として，統計情報の取得に費やすコストの削減がなされている。そのため，農業分野においてはその現状を正確に捉えることが次第に困難になりつつある。また農家レベルでも，農地の賃貸借の進展や法人化に伴う集団化などにより，圃場の特性を熟知した管理が難しくなっている（志賀，2010）[1]。このような状況下において，コストの削減を進める一方で，圃場ごとの作付状況の詳細を今後も継続的かつ長期的・広域的に把握していくためには，従来の現地調査に代わる手法の確立が必要となっている。その中でリモートセンシングの利用は，農業分野において有望な情報収集手段の一つになりうる。

これまでにも，光学センサを用いた作付作物の分類はなされてきた（例えば Nordkvist *et al.*, 2012）[2] が，光学センサによる観測データはヘイズや雲などの影響を受けやすいため，分類精度が低下してしまうおそれがあるとされている（Blaes *et al.*, 2005）[3]。一方でマイクロ波を使用した能動型センサである合成開口レーダ（SAR, Synthetic Aperture Radar）は，昼夜問わず安定した観測が可能であるだけでなく，大気や天候の影響を受けることなくデータを取得することが可能である（Bindlish and Barros, 2001）[4]。そのため，複数のデータを使用した作物の分類には効果的であると考えられる。

そこで本研究では，先行研究（Sonobe *et al.*, 2014）[5] と同様に，パターン認識において高い精度が期待できる機械学習アルゴリズムのランダムフォレスト（Breiman, 2001）[6] を使用し，衛星データにおける作付作物分類の可能性について検討を行った。今回使用した衛星データは，X バンドの合成開口レーダ（SAR）を搭載した TerraSAR-X が観測したものである。また，分類を行うにあたり，SAR データから算出される主要な数値である後方散乱係数だけでなく，散乱成分分解（Cloude, 2007）[7] によって算出される散乱成分も変数として使用した。

本研究ではまず，最高の精度で分類ができるよう，ランダムフォレストにおけるパラメータのチューニングを行った。次に，この結果を用いて，5 時期分の衛星データとそれぞれから得られる 4 つの要素をすべて用いて作付作物の分類を行い，精度を評価した。また，使用する時期数は少なければ少ないほど，衛星データの取得に費やすコストをより下げることができる。加えて，要素数も不要なものは省略した方が簡単に分類できる。したがって，これらの時期数や要素数を削減したうえで分類することによ

り，高い分類精度を維持することが可能であるかどうかに関しても検討した。最後に，これらの結果をもとにして，精度の高いデータ数で作付状況を表すマップを作成した。

II．研究方法

A．対象地域および対象作物

対象地域は，北海道十勝地方の西に位置する芽室町・清水町の畑作地帯であり（東経 142°55′12″～143°05′51″，北緯 42°52′48″～43°02′42″），図 1 に示した。また，分類に用いた圃場のカテゴリーは，秋播き小麦，豆類（小豆・大豆・手亡・金時），馬鈴薯，甜菜，牧草（チモシー・オーチャード），トウモロコシ（デントコーン・スイートコーン）の 6 種類とした*1。

B．使用した衛星データ

使用した衛星データは，X バンドの SAR を搭載した TerraSAR-X（TanDEM-X を含む）の二重偏波（HH 及び VV 偏波）データである。これらは Strip Map モードによって 11 日間隔で取得された 2013 年 6 月 17 日，6 月 28 日，7 月 9 日，7 月 20 日，7 月 31 日の計 5 時期である。観測時の入射角は 42.3° であり，ピクセルスペーシングは 2.75 m とした。

なお，この TerraSAR-X データの処理レベルは，シングルルック・スラントレンジ・コンプレックス（SSC）であったため，ジオコーディングされていないものである。そのため，後方散乱係数を算出した後，オルソ補正を行い，解析できる状態に変換した。この補正には，国土地理院による基盤地図情報ダウンロードサービス（国土地理院，2016）[8] を通じて入手した基盤地図情報数値標高モデル（10 m メッシュ）およびジオイドモデル Earth Gravitational Model 2008（NGA GEOnet Names Server, 2013）[9] を用いた。

これらの偏波データから，プロダクト仕様書（Airbus Defence and Space I Geo-Intelligence, 2014）[10] を基にして，以下の式（1）で HH 偏波及び VV 偏波それぞれの後方散乱係数（σ^0_{HH}, σ^0_{VV}）を算出した。θ_{loc} は衛星の入射角，DN は衛星データのピクセル値，CF は校正係数である。

$$\sigma^0 = 20\log_{10}DN + 10\log_{10}CF + 10\log_{10}(\sin\theta_{loc}) \quad (1)$$

その後，散乱成分分解（Cloude, 2007）[7] により，エントロピ（H）及び平均アルファ角（α）を算出した。なおエントロピとは，SAR データにおける散乱の複雑さを示す指標であり，0 から 1 の値を取る。アルファ角は，反射角の平均を表す数値であり，0° から 90° の値を取る。

これら 4 種類のデータ要素について，それぞれ先行研究（Sonobe *et al.*, 2014）[5] と同様に，圃場ごとに平均値を抽出した。その際，教師データおよび精度検証のためのグランドトゥルース

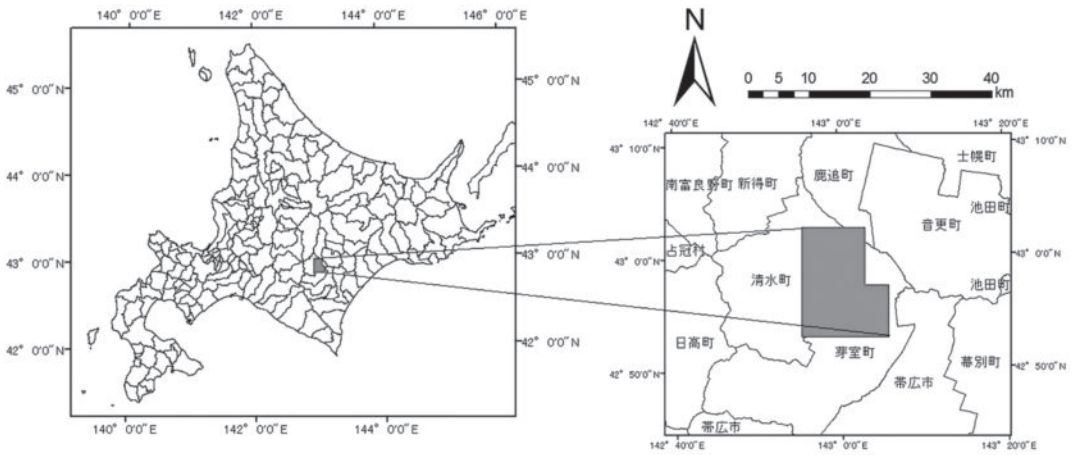

図 1　研究対象地域

として，十勝農業共済組合から提供を受けた圃場ポリゴンを含む GIS データを用いた。このデータには，圃場の位置・形状や作付作物の種類などが記されている。このデータのうち本研究で使用する 6 作目の圃場を抽出して，それぞれの圃場に ID を与えた。また人工被覆や防風林等のピクセルの混入を防ぐため，すべての圃場ポリゴンの内側に 10 m のバッファを生成し，その領域を除いた。このようにして，衛星データ抽出領域の圃場ポリゴンデータを作成した。

C．解析方法

得られた全 5,057 圃場分の圃場データについて，実利用において教師データを無作為に抽出することを想定し，本研究でも先行研究（Hartfield *et al.*, 2013）[11] に倣い，20％の圃場を無作為に抽出した。残りの 80％の圃場はテストデータとし，精度の評価に使用した。テストデータおよび教師データの圃場数は，表 1 に示したとおりである。このテストデータについて教師付き分類を行い，その精度を評価した。分類処理において，本研究では機械学習アルゴリズムの中でも定評のあるランダムフォレストを用いた。また，本アルゴリズムを用いるにあたり，フリー統計ソフトである R（R Core Team, 2016）[12] 及び，randomForest パッケージ（Liaw and Wiener, 2002）[13] を活用した。

ランダムフォレストでは，まず教師データに対してブートストラップサンプリングを行う。ブートストラップとは，重複を許した無作為な抽出のことであり，これによりいくつかのサンプルを作成する。これらのサンプルのうち 3 分の 2 を使用して，分類モデル（決定木）を作成する。ブートストラップサンプルのうち，残りの 3 分の 1 は OOB（out-of-bag）サンプルと呼ばれ，作成した決定木のテストを行う。これらを用いることで，分類モデルにおけるエラー率の評価を実施することができる。このエラー率の評価を行うことにより，作成した決定木の数（n）が十分であるかどうかを評価することができる。

表 1　解析に使用した圃場数

作物	圃場数	
	教師データ	テストデータ
豆類	187	837
甜菜	126	490
牧草	128	468
トウモロコシ	113	479
馬鈴薯	140	564
小麦	305	1,220
合計	999	4,058

なお分類の場合，サンプリングに用いる変数の数は，すべての変数の数の平方根を用いることが勧められている（Breiman, 2001）[6]。そのため，本研究でもそれに倣い，各決定木において用いる変数の数を 4 とした。また，ランダムフォレストではジニ係数の減少量（Mean Decrease in Gini Coefficient）が計算される。ジニ係数の減少量は，高い変数ほど分類に有効であることを示しているため，変数の重要度を推定することが可能となる。本研究においても，ジニ係数の減少量を参考にしてそれぞれの変数の重要性を検討することとした。

分類の精度を評価するために使用した指標は，全体精度（Overall Accuracy, OA）及びカッパ係数（κ）の 2 種類である。κ は，全体精度から分類が偶然的中する率を除いた精度評価指標を示すもので，その値が 0.6 以上となるとある程度高い一致，0.8 以上となると高い一致をしているといえる（Cohen, 1960）[14]。その他，作物ごとの分類精度の評価に，プロデューサーズ精度（PA）及びユーザーズ精度（UA）の 2 種類も使用した。プロデューサーズ精度は作物ごとの分類精度を表しており，ユーザーズ精度は分類結果の精度を表している。

D．研究の流れ

本研究を進めるにあたって，まず OOB サンプルのエラー率から，決定木の数の検討を行った。次にこの決定木の数で，5 時期（6 月 17 日，6 月 28 日，7 月 9 日，7 月 20 日，7 月 31 日）4 要素（σ^0_{HH}，σ^0_{VV}，H，α）の全 20 変数を用いた分類を行った。この結果について，どの程度の精度が得られるかを評価した。最後に，これらの要素数や時期数を削減して使用した場合についても，再度ランダムフォレストを適用した。削減した分類の結果から，時期数や要素数を減

少させたことによって，十分な精度を維持した分類を行うことが可能であるかどうかを検証した。

なお，分類結果の差の有意性は有意差検定統計量 Z（Congalton and Green, 2008）[15] を用いて評価した。この検定結果である Z 値が 1.96 を超えれば，5％の有意水準において，2 つの分類結果に有意な差があると判断することができる。

III. 結果と考察

A．決定木の数の検討結果

OOB サンプルを用いて，決定木の数について検討を行ったところ，決定木の数とエラー率との関係は図 2 のとおりとなった。この結果から，決定木の数がおよそ 50 本以上で OOB サンプルのエラー率が低く安定していることが判明した。分類において，決定木の数が多いことに関しては問題ないとされているため（Breiman, 2001）[6]，決定木の数をそれより大きい n＝200 と設定し，残り 80％のデータを分類して精度を評価した。

B．全変数利用時の分類精度

5 時期 4 要素すべての変数を使用した際の判別効率表は，表 2 に示すとおりとなった。すべての時期・要素を用いた場合において，全体精度は 89.5％であり，κ は 0.869（＞0.8）であった。以上の結果から，ランダムフォレストを

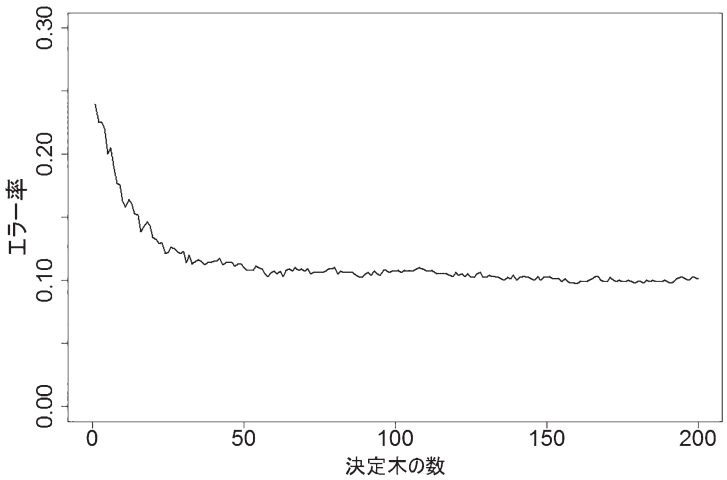

図 2　決定木の数による OOB サンプルのエラー率の変化

表 2　全変数利用時の分類精度

		参照データ							
		豆類	甜菜	牧草	トウモロコシ	馬鈴薯	小麦	計	UA
分類結果	豆類	753	15	2	41	46	6	863	0.873
	甜菜	11	442	1	12	4	0	470	0.940
	牧草	13	4	423	28	9	46	523	0.809
	トウモロコシ	29	26	15	375	8	13	466	0.805
	馬鈴薯	30	2	2	12	490	8	544	0.901
	小麦	1	1	25	11	7	1,147	1,192	0.962
	計	837	490	468	479	564	1,220	4,058	
	PA	0.900	0.902	0.904	0.783	0.869	0.940		
	全体精度	0.895	Kappa	0.869					

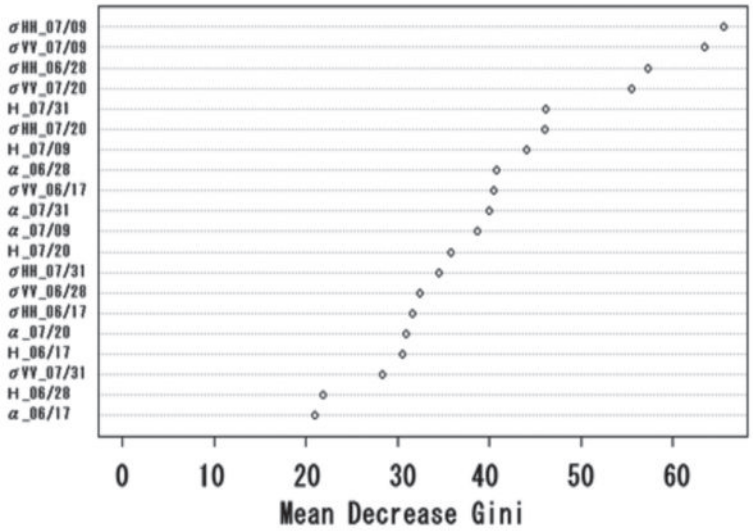

図３　ジニ係数の減少量と変数との関係

TerraSAR-X データに適用することによって，90％近い精度での分類を行うことができた。

また，分類モデル作成時に算出されたジニ係数の減少量（Mean Decrease Gini）とそれぞれの変数との関係は，図３のとおりとなった。ここに示した各パラメータのジニ係数の減少量を要素別に確認していくと，H や α と比較して HH 偏波や VV 偏波の各後方散乱係数の方が特に大きく本結果に寄与していることが判明した。さらに時期別に見ると，７月９日のデータの重要度が最も高く，次いでその前後である６月 28 日や７月 20 日のデータの重要度が高いことが示された。

これらの原因として，７月初旬やその近辺は作物種ごとの生育状況の違いが大きくなっていたことが挙げられる。そのため，それぞれの作物種の群落構造の差も明瞭となり，後方散乱係数の変化がよく出ていたと考えられる。このことは，７月初旬頃に最も生育度合が大きい秋播き小麦において，UA・PA ともに群を抜いて精度が大きくなっていたことからも裏付けられる。

C．要素数別の分類精度

本研究において用いた要素は，σ^0_{HH}，σ^0_{VV}，H，α の４種類であったが，これらの要素を削減して分類を行い，その精度評価を行った。いずれか１要素を用いた場合，後方散乱係数の２要素を用いた場合（$\sigma^0_{HH}+\sigma^0_{VV}$），散乱成分の２要素を用いた場合（$H+\alpha$）のそれぞれについて同様にランダムフォレストによる分類を実施した。以上の分類結果を４要素すべて用いた 3.2 の結果と比較し，全体精度や κ にどれほどの差異が現れるかを評価した（表３）。

表３によると，４要素すべてを用いた場合と比較して，要素数の削減により精度は低下することが明らかとなった。特に１要素しか用いなかった場合について見ると，全体精度は 73.0～77.8％であり，すべて用いた場合より 20 ポイント程度低く，κ は 0.665～0.725 であった。２要素を用いた場合については全体精度・κ ともに上がり，全体精度は 83.0～84.1％となったが，κ は 0.8 前後であった。

つづいて，１要素・２要素のみを用いた場合について，すべての要素を用いた場合との間でそれぞれ有意差検定統計量 Z を算定した（表４）。この結果より，すべての要素を用いた分類結果は，１要素・２要素のみを用いた場合と比較して５％の有意水準において有意な差のある高い分類精度であることが明らかとなった。従って，要素数を削減することは精度の低下につながり，高精度な分類を維持することが困難になると判断した。

表 3　要素数別の分類精度

		σ0HH	σ0VV	σ0HH＋σ0VV	α	H	α＋H	All
PA	豆類	0.722	0.768	0.817	0.724	0.766	0.847	0.900
	甜菜	0.861	0.841	0.878	0.567	0.729	0.739	0.902
	牧草	0.808	0.774	0.850	0.684	0.598	0.838	0.904
	トウモロコシ	0.503	0.539	0.658	0.539	0.666	0.716	0.783
	馬鈴薯	0.729	0.670	0.771	0.729	0.809	0.860	0.869
	小麦	0.902	0.878	0.907	0.893	0.864	0.920	0.940
UA	豆類	0.689	0.688	0.751	0.647	0.828	0.822	0.873
	甜菜	0.894	0.866	0.898	0.584	0.704	0.767	0.940
	牧草	0.724	0.687	0.758	0.606	0.628	0.769	0.809
	トウモロコシ	0.560	0.590	0.706	0.594	0.617	0.713	0.805
	馬鈴薯	0.731	0.738	0.850	0.853	0.774	0.900	0.901
	小麦	0.921	0.915	0.933	0.907	0.860	0.941	0.962
全体精度		0.778	0.770	0.830	0.730	0.766	0.841	0.895
Kappa		0.725	0.715	0.789	0.665	0.710	0.803	0.869

表 4　4 要素全てを用いた場合との Z 検定結果

要素	Z 値
σ0HH	14.80
σ0VV	15.70
σ0HH＋σ0VV	8.66
α	20.24
H	16.17
α＋H	7.26

表 5　各時期数における使用したデータ

時期数	日付
1 時期	7/9
2 時期	6/28，7/9
3 時期	6/28，7/9，7/20
4 時期	6/28，7/9，7/20，7/31
5 時期	6/17，6/28，7/9，7/20，7/31

D．時期数別の分類精度

今回使用したデータは 5 時期であったが，これらをすべては使用せず一部の時期のみ使用した場合，全体精度や κ にどれほどの差異があるのか評価した。なお，各時期数において用いた値は，最も精度の高い時期の組み合わせのものである（表 5）。

時期数ごとの分類精度の結果では，どの時期数に対しても小麦の UA，PA は常に高い値を示した（表 6）。この原因としては，小麦が他の作物に比べて生育時期が早く，後方散乱係数などにも差異が大きかったために，少ない時期数でも他の作物と区別しやすかったことが考えられる。また，甜菜の UA や PA が 2 時期までの間で高い値を示したのも，移植栽培であるために同様の理由となると考えられる。

また，時期数と全体精度および κ 係数との関係をグラフにして比較した（図 4）。その結果，総じて時期数の削減に応じて全体精度・κ 係数ともに下降していくことが判明した。ただし，4 時期の全体精度は 88.6%，κ は 0.859 であり，5 時期すべてを用いた場合と 5 %の有意水準で有意な差はなかった（Z＝1.22）。いっぽう，3 時期と 4 時期の間の Z 値は 3.43（＞1.96）と有意な差があった。しかし，3 時期のデータを用いた場合の全体精度は 86.1%，κ は 0.828 であり，3 時期にしてもある程度高い精度を維持していた。

2 時期まで減らした場合でも，全体精度は 84.6%，κ は 0.809 となっており，まだ精度は高かった。また，3 時期との Z 値は 2.02（＞1.96）となっており，有意な差が見られた。1 時期のみの使用では，全体精度は 77.5%と低く，κ も 0.721 と，高い一致はしなかったことが確認された。

以上の結果より，5 時期すべてのデータを用いなくても，十分な精度が得られることが示さ

表 6　時期数別の分類精度

	時期数	1	2	3	4	5
PA	豆類	0.787	0.839	0.853	0.891	0.900
	甜菜	0.800	0.867	0.869	0.882	0.902
	牧草	0.694	0.842	0.878	0.895	0.904
	トウモロコシ	0.551	0.706	0.724	0.789	0.783
	馬鈴薯	0.768	0.853	0.855	0.858	0.869
	小麦	0.879	0.895	0.914	0.932	0.940
UA	豆類	0.792	0.818	0.827	0.879	0.873
	甜菜	0.798	0.928	0.932	0.927	0.940
	牧草	0.649	0.720	0.758	0.788	0.809
	トウモロコシ	0.620	0.741	0.727	0.786	0.805
	馬鈴薯	0.738	0.841	0.878	0.888	0.901
	小麦	0.878	0.936	0.953	0.959	0.962
全体精度		0.775	0.846	0.861	0.886	0.895
Kappa		0.721	0.809	0.828	0.859	0.869

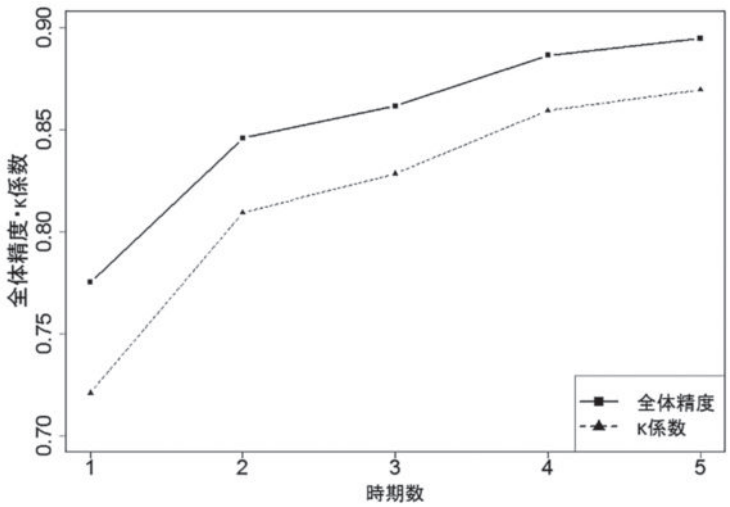

図 4　時期数による精度の変化

れた。特に 5 時期と 4 時期とでは精度がほぼ変わらず，3 時期や 2 時期でも κ は 0.8 を上回る十分高い精度を得られることが確認された。そのため，2 時期以上のデータを用いれば高い精度で分類できると考えられる。また，さらに高い精度が必要な場合は，4 時期以上のデータを用いることが望ましいと考えられる。

E．作付マップの作成

図 5 に，4 時期のデータを用いて作成した作付マップを示す。このように，ランダムフォレストによって分類した結果より，作付マップを作成することができた。また，図 6 にはこの作付マップにおいて誤分類された圃場を黒で示した。

誤分類された箇所は各地に点在しているが，それらの多くは数箇所の誤分類された圃場の集団や，面積の小さな圃場であることが判明した。前者の場合，倒伏による植え直しや植え替えなどにより，作付作物そのものを途中から変更した可能性や，作況調査の際に隣あった圃場の入力をあべこべにした，などヒューマンエラーの可能性が考えられる。後者の場合，異常値のピ

図 5　ランダムフォレストによる作付マップ

クセルが平均値の算出で大きく影響を与えてしまった可能性が考えられる。

IV. 結　　論

本研究では，TerraSAR-X の HH 及び VV 偏波データについて，機械学習アルゴリズムであるランダムフォレストを使用し，作物の分類を行った。同時に，高い分類精度を維持しつつデータ数を削減することが可能であるかどうかという視点からも検討を進めた。使用した要素は，後方散乱係数（σ^0_{HH}，σ^0_{VV}）と，散乱成分分解により算出された H，α の 4 要素であった。また衛星データには，6/17～7/31 に 11 日間隔で取得した 5 時期の TerraSAR-X データを使用した。

その結果，5 時期 4 要素すべてを用いた場合，90％近い精度を得ることができた。要素数を削減すると精度は大きく下がり，高精度の維持は望めないことが確認された。一方で，時期数を削減した場合はある程度高い精度を維持するこ

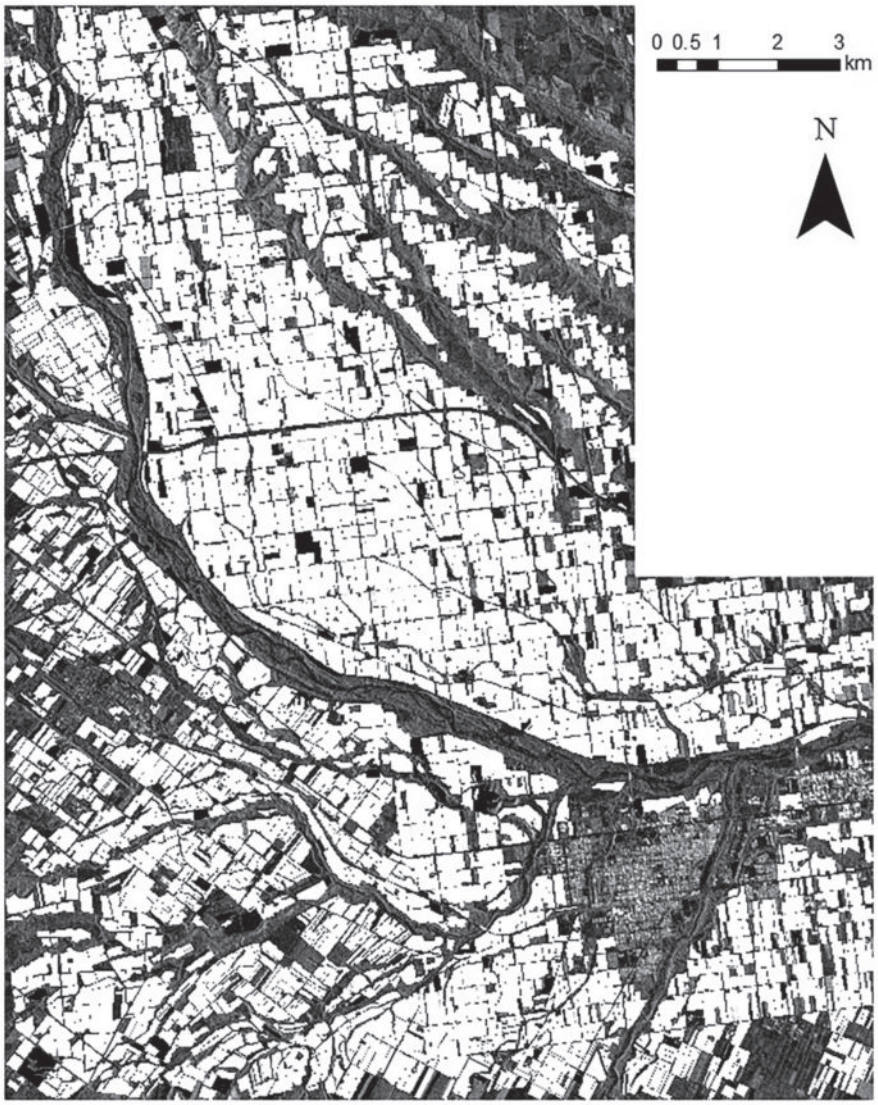

図 6　誤分類の生じた圃場

とが可能となった。特に 2 時期以上のデータ数があれば十分高く，4 時期以上あれば更に精度が高くなるため，より低コストでの作物分類が可能となると結論付けた。

今後は 4 偏波データや C バンドなどを用いた手法や他の分類アルゴリズムを使用することによって，今回のような少ない観測日数で分類精度を更に高くすることができるか検討する予定である。また，実利用において教師データを減少させることは不可欠であるため，教師データの減少による精度の維持についても併せて検討する。

引 用 文 献

1．志賀弘行．農業分野における衛星画像の利用．〈http://www.alic.go.jp/joho-s/joho07_000102.html〉, 2010 updated, 2016.9.13 refered.

2．Nordkvist, K., A. Granholm, J. Holmgren, H. Olssona and M. Nilsson. Combining optical

satellite data and airborne laser scanner data for vegetation classification. Remote Sensing Letters, 3(5), 393–401, 2012.

3. Blaes, X., L. Vanhalle and P. Defourny. Efficiency of crop identification based on optical and SAR image time series. Remote Sensing of Environment, 96 (3–4), 352–65, 2005.

4. Bindlish, R. and AP. Barros. Parameterization of vegetation backscatter in radar-based, soil moisture estimation. Remote Sensing of Environment, 76, pp. 130–137, 2001.

5. Sonobe, R., Tani, H., Wang, X., Kobayashi, N. and Shimamura, H. Random Forest classification of crop type using multi-temporal TerraSAR-X dual-polarimetric data. Remote Sensing Letters, 5(2), 157–164, 2014.

6. Breiman, L. Random forests. Machine Learning, 45(1), pp.5–32, 2001.

7. Cloude, S. R. The dual-polarization entropy/alpha decomposition: a pulsar case study, Proc. POLInSAR, Frascati, Italy, pp. 1–6, 2007.

8. 国土地理院. 基盤地図情報ダウンロードサービス.
〈http://fgd.gsi.go.jp/download〉, 2016 updated, 2016.9.26 参照.

9. NGA GEOnet Names Server. Earth Gravitational Model 2008 (EGM2008).
〈http://earth-info.nga.mil/GandG/wgs84/gravitymod/egm2008/〉, 2013 updated, 2016.9.26 referred.

10. Airbus Defence and Space I Geo-Intelligence. Radiometric Calibration of TerraSAR-X Data.
〈http://www.geo-airbusds.com/files/pmedia/public/r465_9_tsx-x-itd-tn-0049-radiometric_calculations_i3.00.pdf〉, 2014 updated, 2016.9.26 referred.

11. Hartfield, K., S. Marsh, C. Kirk and Y. Carriere. Contemporary and historical classification of crop types in Arizona. International Journal of Remote Sensing, 34 (17), 6024–6036, 2013.

12. R Core Team. R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria.
〈http://www.R-project.org/〉, 2016 updated, 2016.9.28 referred.

13. Liaw, A. and M. Wiener. Classification and Regression by Random Forest. R News 2, pp.18–22, 2002.

14. Cohen, J. A coefficient of agreement for nominal scales. Educational and Psychological Measurement, 20, pp.37–46, 1960.

15. Congalton, R. G. and K. Green. Assessing the accuracy of remotely sensed data: Principles and practices. Boca Raton, Florida, United States: CRC Press, 2008.

Summary

This paper presents crop classification using satellite data to establish a mapping method in place of the existing ground survey. We calculated four variables of sigma naught, and polarimetric parameters from TerraSAR-X HH-VV dual-polarization data, and assessed the accuracy of classification performed by machine learning algorithm “Random Forest”. The result showed about 90% of accuracy when we used five dates’ imagery and four variables, respectively. And accuracy assessment was done under the condition when the number of variables or scenes was reduced. The accuracy became worse when the number of variables was reduced, but it can be maintained when the number of dates was reduced, thus these results confirm that crop classification with the lower cost will become possible.