

타겟 분해 기반 특징과 확률비 모델을 이용한 다중 주파수 편광 SAR 자료의 결정 수준 융합

박노욱[†] · 지광훈

한국지질자원연구원 지질자원정보센터

Decision Level Fusion of Multifrequency Polarimetric SAR Data Using Target Decomposition based Features and a Probabilistic Ratio Model

No-Wook Park[†] and Kwang-Hoon Chi

Geoscience Information Center, Korea Institute of Geoscience and Mineral Resources

Abstract : This paper investigates the effects of the fusion of multifrequency (C and L bands) polarimetric SAR data in land-cover classification. NASA JPL AIRSAR C and L bands data were used to supervised classification in an agricultural area to simulate the integration of ALOS PALSAR and Radarsat-2 SAR data to be available. Several scattering features derived from target decomposition based on eigen value/vector analysis were used as input for a support vector machines classifier and then the posteriori probabilities for each frequency SAR data were integrated by applying a probabilistic ratio model as a decision level fusion methodology. From the case study results, L band data had the proper amount of penetration power and showed better classification accuracy improvement (about 22%) over C band data which did not have enough penetration. When all frequency data were fused for the classification, a significant improvement of about 10% in overall classification accuracy was achieved thanks to an increase of discrimination capability for each class, compared with the case of L band SAR data.

Key Words : Polarimetric SAR data, Target decomposition, Decision level fusion.

요약 : 이 논문에서는 토지 피복 분류를 목적으로 C 밴드와 L 밴드 다중 편광 자료의 결정 수준 융합을 수행하여 융합 효과를 살펴보았다. 앞으로 이용이 가능해질 C 밴드 Radarsat-2 자료와 L 밴드 ALOS PALSAR 자료를 모사하기 위해 C 밴드와 L 밴드 NASA JPL AIRSAR 자료를 감독분류에 이용하였다. Target decomposition으로부터 얻어지는 산란 특성과 관련된 특징들을 입력으로 SVM을 분류 기법으로 적용한 후에, 사후확률을 확률비 모델의 틀 안에서 융합하는 결정수준 융합을 수행하였다. 적용 결과, L 밴드가 C 밴드에 비해 피복 구분에 적절한 투과 심도를 나타내어 22% 정도 높은 분류 정확도를 나타내었지만, 결정수준 융합을 통해 개별 토지피복 항목의 구분력의 향상으로 인해 L 밴드 자료의 분류결과에 비해 10% 정도의 보다 향상된 분류 정확도를 얻을 수 있었다.

2007년 2월 6일 접수 ; 2007년 4월 11일 수리.

[†] 교신저자: 박노욱(nwpark@kigam.re.kr)

1. 서론

기존 단일 주파수/편광 상태의 자료만을 제공하던 SAR 시스템과 더불어 앞으로는 다중 편광 자료를 제공하는 SAR 시스템의 이용이 활발해질 것으로 예상된다. 2006년 1월 발사에 성공한 JERS-1 SAR의 후신인 ALOS의 PALSAR는 L 밴드 다편광 자료를 제공하며, C 밴드 다편광 자료를 제공할 Radarsat-2도 발사할 예정이다. 기존 단일 편광 상태의 SAR 자료에 비해 다편광 SAR 자료를 이용할 경우 보다 많은 산란 정보를 얻을 수 있기 때문에 활용성이 높을 것으로 기대된다. SAR 자료의 산란 특성을 이용한 여러 다양한 분야 중에서 육상 분야에서는 작물의 종류, 발육 상태, 토양 수분 등의 모니터링에 주로 이용될 수 있는데(Henderson and Lewis, 1998), 이는 지표면에 대한 물리적인 특성을 반영할 수 있는 SAR 자료의 특성에 기인한 것이다.

기존 다편광 SAR 자료는 주로 항공기 탑재가 대부분이었는데, 대표적인 것으로 NASA JPL의 AIRSAR, DCRS의 EMISAR, DLR의 E-SAR, NASDA-CRL의 Pi-SAR 등이 있다. 이러한 항공기 다편광 SAR 자료로부터 산란특성 분석, 지표 피복 분류 등의 연구가 많이 진행되어 왔다. 기존 단일 편광 SAR 자료와 달리 다편광 SAR 자료의 경우 다소 복잡한 자료처리 과정을 요구하기 때문에, 이를 반영할 수 있는 분석 방법론 개발이 병행되어 왔다. 다편광 SAR 자료로부터 얻어지는 산란 행렬로부터 물리적인 산란과정을 이해하기 위해 Krogager(1992)는 산란 행렬을 기본 3개의 성분으로 분리하고자 하였다. 또한 Cloude and Pottier(1996; 1997)은 상관 행렬의 고유값/고유벡터의 분석을 이용한 target decomposition을 통해 $H/\bar{\alpha}$ 에 기반하여 지표 산란 특성을 8개의 구역으로 나누는 연구를 수행하였으며, 이러한 target decomposition은 일반적인 다편광 SAR 자료의 처리 과정으로 많이 활용되고 있다. Target decomposition에 기반한 다편광 SAR 자료의 분류 연구는 복소 Wishart 분포에 기반한 연구(Lee et al., 1994), Wishart 분포와 $H/\bar{\alpha}/A$ 를 이용한 연구(Lee et al., 1999) 등 다양한데, 이러한 분류 기법은 통계적 특성에 기반한 무감독 분류 연구에 해당된다. 이와 더불어 Freeman and Durden(1998)은 물리적인 산란 특성을 고려한 3성분 분석(double bounce, surface, volume)

을 통해 피복물의 산란 특성을 분석하고자 하였다.

농작물, 산림, 빙하 등 다양한 지표 피복물의 분류와 관련하여 많은 연구들이 다편광 SAR 자료가 기존 SAR 자료에 비해 높은 구분 능력을 나타낸다고 보고하였으며, 개별 주파수별 편광 반응에 대해 분석을 하였다(van Zyl, 1989; Rignot and Drinkwater, 1992; Lemoine, et al., 1994; Foody et al., 1994; Lee et al., 2001). 기존 연구 중에서 Lee et al.(2001)은 NASA JPL AIRSAR 자료를 농작물과 산림 영급 분류에 이용하였다. 이 연구를 통해 L 밴드가 농작물 분류에는 C 밴드나 P 밴드에 비해 분류 능력이 뛰어나며, HH와 VV의 이중 편광이 다편광 자료만큼의 분류 정확도를 나타낸다고 보고하였다. 또한 산림 영급 구분에는 파장이 좀 더 긴 P 밴드가 다른 밴드보다 우수하며, HV가 중요한 편광 상태임을 보고하였다. 이러한 결과는 결국 SAR 자료의 파장 혹은 주파수에 따라 물리적인 특성을 구분하는데 차이가 있음을 나타낸다.

현재까지 다편광 SAR 자료를 이용한 토지 피복 분류에서는 서로 다른 주파수의 다편광 SAR 자료의 분류 특성을 비교 분석한 연구가 대부분이었는데, 다중 주파수 다편광 SAR 자료의 융합 연구는 이에 비해 상대적으로 진행이 많이 되어 있지 않은 상황이다. Ferro-Famil et al.(2001)은 이중 주파수 NASA JPL AIRSAR 자료에 무감독 분류 기법을 적용하여 서로 다른 주파수가 지표 피복 구분에 유용한 정보를 제공한다고 보고하였다. 특정 파장대가 특정 피복에서 우수한 구분력을 보인다는 연구를 통해 관심 있는 지역의 다편광 SAR 자료의 주파수 선정에 도움이 되지만, 서로 상호 보완적인 정보를 제공할 수 있는 서로 다른 주파수의 다편광 SAR 자료의 융합 연구도 필요한 상황이다.

이 연구에서는 앞으로 이용이 가능해질 C 밴드 Radarsat-2 자료와 L 밴드 ALOS PALSAR 자료를 모사하기 위해 C 밴드와 L 밴드 다편광 SAR 자료를 토지 피복 구분에 사용함에 있어서 자료 융합의 효과를 살펴보고자 하였다. 개별 주파수 다편광 자료로부터 산란 특성을 추출하기 위해 고유값/고유벡터의 분석을 이용한 target decomposition에 기반하여 특징들을 추출한 후에, 이러한 특징들을 이용하여 개별 자료의 확률론적 분류 결과로 얻어지는 사후 확률을 결정 수준에서 융합하고자 하였다.

2. 방법론

Fig. 1은 다중 주파수/편광 SAR 자료의 융합과정을 도식적으로 나타낸 것이다. 우선 다편광 자료의 상관행렬로부터 target decomposition을 통해 H , $\bar{\alpha}$, A 등의 특징을 산출한 다음에 패턴 인식 기법중 하나인 support vector machines (이하 SVM)을 적용하여 각 주파수별/토지피복 항목별 사후 확률을 얻었다. 이후 확률비 모델을 적용하여 결정수준 자료 융합을 수행하였다.

1) 산란 특성 특징 추출

개별 주파수 다편광 SAR 자료에 대해서 speckle 제거를 위해 Lee 필터를 적용한 후에 target decomposition을 수행하였다. 이 논문에서는 Cloude and Pottier (1996)에 의해 제안된 target decomposition을 이용하였다. 이 방법은 coherency 행렬 $\langle [T_3] \rangle$ 의 고유치 분해에 기반을 두고 있는데, 자세한 이론 설명은 Cloude and Pottier(1996, 1997)을 참조할 수 있다. Target decomposition을 통해 얻어지는 H , $\bar{\alpha}$, A 등의 특징들은 지표에서 마이크로파의 산란 메커니즘의 추정을 가능하게 하는 지시자로 이용될 수 있다. 비록 이러한 특징들은 산란 계수의 강도에 비해 잡음을 포함하지만, 이 연구에서는 산란 메커니즘을 직접적으로 감독 분류의

과정에 연관시키기 위해 분류를 위한 입력 특징으로 SPAN과 함께 이용하였다.

고유치 분해에 의해 3×3 Hermitian 행렬 $\langle [T_3] \rangle$ 은 다음과 같이 분해될 수 있다.

$$\langle [T_3] \rangle = [U_3][\Sigma_3][U_3]^{-1} = \sum_{j=1}^3 \lambda_j \vec{u}_j \vec{u}_j^{*T} \quad (1)$$

여기서 대각행렬 $[\Sigma_3]$ 은 $\langle [T_3] \rangle$ 의 고유값($\lambda_1, \lambda_2, \lambda_3$)을 포함하며, 3×3 unitary 행렬 $[U_3]$ 은 다음과 같은 $\langle [T_3] \rangle$ 의 고유벡터를 포함한다(Cloude and Pottier, 1996). 식 (1)의 우측에서 $*T$ 는 켈레복소수를 나타낸다.

$$[\Sigma_3] = \begin{bmatrix} \lambda_1 & 0 & 0 \\ 0 & \lambda_2 & 0 \\ 0 & 0 & \lambda_3 \end{bmatrix} \infty > \lambda_1 > \lambda_2 > \lambda_3, [U_3] = [\vec{u}_1, \vec{u}_2, \vec{u}_3] \quad (2)$$

식 (1)과 (2)의 고유값과 고유벡터는 $\langle [T_3] \rangle$ 의 고유치 분해의 주요 파라미터로 간주할 수 있는데, 고유치 분해에 의한 물리적 정보의 해석을 간단히 하기 위해 3개의 부가적인 파라미터들인 H , $\bar{\alpha}$, A 는 $\langle [T_3] \rangle$ 의 고유값과 고유벡터의 함수로 다음과 같이 정의된다.

산란 엔트로피(H)는 coherency 행렬 $\langle [T_3] \rangle$ 의 고유값들의 로그합으로 정의된다.

$$H = -\sum_{i=1}^3 p_i \log_3(p_i) \quad p_i = \lambda_i / \sum_{k=1}^3 \lambda_k \quad (3)$$

여기서 고유값 λ_i 의 확률로 간주할 수 있는 p_i 는 식 (4)로부터 총 산란 파워에 대한 고유값의 상대적인 중요도를

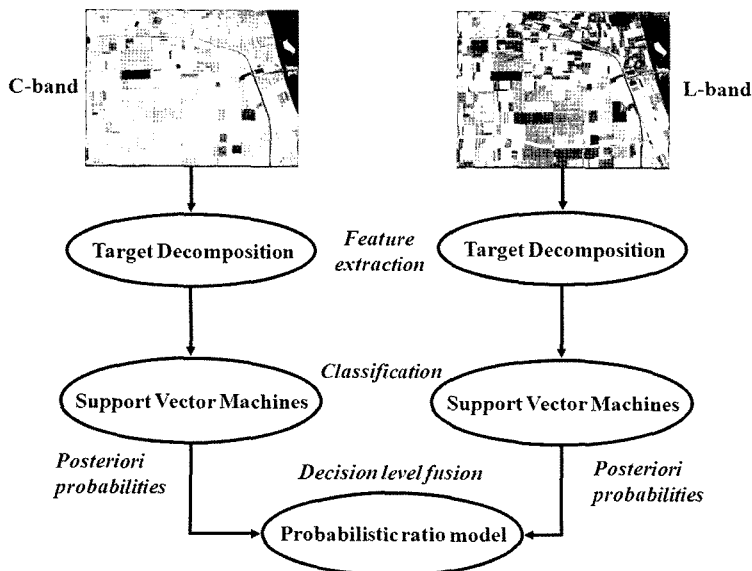


Fig. 1. Schematic flow chart for decision-level fusion of C and L bands polarimetric SAR data.

나타낸다.

$$SPAN = |S_{hh}|^2 + |S_{vv}|^2 + 2|S_{hv}|^2 = \sum_{k=1}^3 \lambda_k \quad (4)$$

H 는 0부터 1 사이의 값을 가지는데, 산란과정의 무작위성의 정도를 나타낸다. H 값이 0인 경우에는, $\lambda_1 = SPAN$, $\lambda_2 = 0$, $\lambda_3 = 0$ 이 되어 산란과정은 pure target에 해당된다. H 값이 1인 경우에는, $\lambda_1 = SPAN/3$, $\lambda_2 = SPAN/3$, $\lambda_3 = SPAN/3$ 이 되어 3개의 pure target의 결합에 의해 이루어지는 distributed target의 무작위 산란에 해당된다. 0과 1사이의 H 값에 해당되는 산란 메카니즘은 고유벡터 $\vec{u}_i (i = 1, 2, 3)$ 에 의해 주어지면서 해당되는 고유값을 가중치로 하는 3개의 pure target의 결합에 의해 이루어진다.

H 와 상호보완적인 파라미터에 해당되는 이방성 A 는 식 (7)과 같이 고유치 분해의 두 번째와 세 번째 고유값의 상대적인 중요도로 표현되는데, 실제적으로 낮은 H 인 경우에 두 번째와 세 번째 고유값은 잡음 영향이 크기 때문에 H 가 0.7이상인 경우에 유효한 것으로 알려져 있다(Cloud and Pottier, 1997).

$$A = \frac{\lambda_2 - \lambda_3}{\lambda_2 + \lambda_3} \quad (5)$$

식 (2)의 고유벡터 $\vec{u}_i (i = 1, 2, 3)$ 는 다음과 같이 α_i , β_i , δ_i , γ_i 등으로 표현될 수 있다(Cloud and Pottier,

1997).

$$\vec{u}_i = [\cos \alpha_i, \sin \alpha_i \cos \beta_i e^{i\delta_i}, \sin \alpha_i \sin \beta_i e^{i\gamma_i}]^T \quad (6)$$

식 (6)의 α_i 의 평균값인 $\bar{\alpha}$ 은 식 (7)으로 정의될 수 있는데, $\bar{\alpha}$ 값이 0인 경우는 거친 표면에 의해 유발된 single bounce 산란을 나타낸다. $\bar{\alpha}$ 값이 45도와 90도인 경우에는, volume 산란과 double bounce 산란을 각각 나타낸다.

$$\bar{\alpha} = \sum_{i=1}^3 p_i \alpha_i \quad (7)$$

2) 결정 수준 자료 융합

일반적으로 자료 융합은 화소, 특징, 결정 및 모델링 수준 등 다양한 수준에서 수행될 수 있다(Fig. 2). 화소 기반 융합은 화상 해석이나 분류 등의 능력을 향상시키기 위해 화소별로 서로 다른 자료들로부터 정보를 결합하는 것으로, 대표적인 것이 고해상도 범색성 화상과 중저해상도 다중 스펙트럴 화상의 융합이다. 특징 기반 융합은 개별 자료로부터 추출한 특징들을 융합하는 것이며, 결정 수준 융합은 보다 높은 개념의 수준에서 정보를 결합하는 것으로 개개 자료들을 개별적으로 처리한 후에 이의 결과 혹은 부산물을 융합하는 것에 해당된다(이상훈, 2003; Park, 2004). 모델링 수준 융합은 개별 자료를 특정 물리적인 모델의 입력으로 사용하여 특성

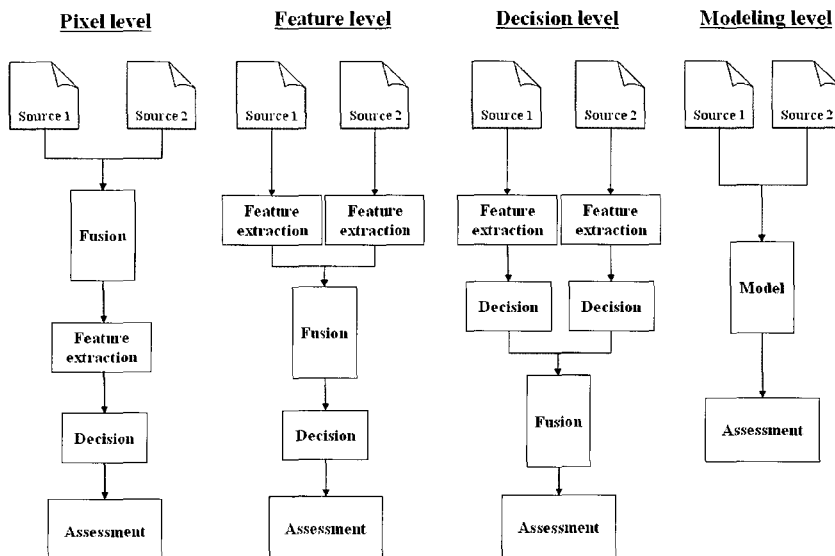


Fig. 2. Various data fusion levels (from Lee(2003); Smits(2003)).

파라미터 등을 추출하는 것에 해당된다(Smits, 2003). 이러한 다양한 수준의 융합 방법론 중에서 결정 수준 융합은 서로 다른 특성의 자료를 동시에 하나의 방법론으로 처리함으로써 왜곡된 정보를 산출할 수 있는 가능성을 줄이기 위해 개별적인 자료 처리의 분류를 수행한 후에 분류 결과가 각 토지피복 항목에 속할 확률을 결합할 수 있기 때문에 상호 보완적이면서도 중복적인 정보의 처리에 효과적이다.

이 연구에서는 다중 주파수 편광 SAR 자료의 융합을 위해 결정 수준에서 수행하였는데, 융합 방법론으로 확률비 모델을 적용하였다. 확률비 모델은 확률추정의 결과들의 결합을 위해 Bordley(1982)가 제안하였으며, 이후 Journal(2002)에 의해 이론적으로 정립되었다. 이 모델은 기존 조건부 독립 혹은 완전 독립의 가정 하에 결합을 수행하는 베이시안 이론의 대안으로 제시된 사후 확률의 결합 방법론이다.

기존에 사후 확률의 결합에 많이 이용되어온 베이시안 결합 규칙은 일반적으로 완전 독립 혹은 조건부 독립의 가정 하에 개별 정보를 결합하여 왔다. 토지 피복 구분을 위해 특정 토지 피복 ω 의 처리를 위해 2개의 자료 A와 B를 고려하였을 때, 사후 확률은 다음과 같이 표시될 수 있다.

$$P(\omega|A, B) = \frac{P(\omega|A) \cdot P(\omega|B)}{P(\omega)} \quad (8)$$

여기서 독립의 가정은 실제적으로 자료사이의 상관성을 추론하기는 쉽지 않기 때문에, 계산상의 편리성으로 인해 많이 차용되어 왔지만, 실제 계산과정에서 확률론적 불일치를 나타낼 수 있다. 만약 $P(\omega|A) = 0.8$, $P(\omega|B) = 0.6$, $P(\omega) = 0.3$ 이라고 할 때, 결합 확률 $P(\omega|B, C)$ 은 1.6으로 계산되어 1을 넘게 된다(Journal, 2002). 토지 피복 분류에서는 각 토지피복별 사후확률의 합을 1로 맞추는 정규화 과정을 거치기 때문에 이러한 개별 토지피복별로 기존 확률 이론과 배치되는 사후 확률의 값을 간과하게 된다.

반면 확률비 모델은 사후확률을 직접적으로 이용하지 않고, 사후확률을 ω 의 발생과 관계된 거리로 변환하여 사용한다. n 개의 자료 D_i ($i=1, \dots, n$)가 주어졌을 때, ω 가 발생에 대한 거리는 다음과 같이 정의된다.

$$x_0 = \frac{1 - P(\omega)}{P(\omega)} \in [0, \infty]$$

$$x_i = \frac{1 - P(\omega|D_i)}{P(\omega|D_i)} \in [0, \infty] \quad (9)$$

$$x = \frac{1 - P(\omega|D_1, \dots, D_n)}{P(\omega|D_1, \dots, D_n)} \in [0, \infty]$$

여기서 x_0 는 자료가 주어지기 전에 토지피복 ω 의 발생에 대한 사전 불확실성을 나타내는 거리 개념으로, 즉 만약 자료가 주어지기 전에 토지피복 A가 확실하게 존재한다면, a 는 0이 되며, 존재 자체가 불가능하면 ∞ 의 값을 가지게 된다. x_i 와 x 는 개별 자료 D_i 와 n 개의 모든 자료 D_i ($i=1, \dots, n$)에 의해 갱신된 거리를 각각 나타낸다.

x_0, x_i, x 로부터 확률비 모델은 다음과 같이 정의된다(Krishnan, 2004).

$$\frac{x}{x_0} = \prod_{i=1}^n \left(\frac{x_i}{x_0} \right)^{\tau_i}, \tau_i \in [-\infty, +\infty] \quad (10)$$

$$P(\omega|D_1, \dots, D_n) = \frac{1}{1+x} \in [0, 1]$$

여기서 τ_i 는 자료 사이의 중복(redundancy)과 관련된 것으로 기존 결정론적 자료 융합 관점의 가중치 혹은 신뢰도와는 개념적으로 다르다. 만약 모든 τ_i 값을 1로 주게 되면, 위 식은 조건부 독립 하에 결합하는 기존 베이시안 결합 규칙과 같게 되지만 확률적 불일치 문제는 발생하지 않는다.

이 연구에서는 확률비 모델의 입력 사후확률값을 C 밴드와 L 밴드 자료로부터 얻기 위해 SVM을 적용하였다. SVM은 통계적 패턴 인식 기법의 하나로, 분류 항목 사이의 margin을 최대로 하는 결정면을 가지는 분류 항목들을 구분한다(Cristianini and Shawe-Taylor, 2000). SVM은 비선형 커널을 이용하여 이진 분류에 적용되도록 고안되었으나 여러 개의 이진 SVM 분류자를 결합함으로써 일반적인 토지 피복 분류에서 고려하는 다중 항목 분류에 이용이 가능하며, 최근에는 초다분광 자료 등 원격탐사 자료의 분류에 많이 이용되고 있다(Foody and Mathur, 2004; Melgani and Bruzzone, 2004; Bazi and Melgani, 2006). SVM를 적용함으로써 최종적인 분류결과 이외에 각 토지피복 항목별 사후 확률을 얻을 수 있는데, 이러한 사후 확률은 C 밴드와 L 밴드 자료의 결정 수준 융합의 입력 확률로 사용되었다.



Fig. 3. C band SPAN image (left) and L band SPAN image (right).

3. 사례연구

1) 연구 지역 및 사용 자료

이 연구에서는 네덜란드 Flevoland 지역에서 1989년 8월에 촬영된 NASA JPL AIRSAR 자료 중에서 C 밴드와 L 밴드 자료를 분석에 이용하였다(Fig. 3). 여기서 C 밴드와 L 밴드 자료는 앞으로 이용이 가능해질 C 밴드 Radarsat-2 자료와 L 밴드 ALOS 자료를 모사하기 위해 사용하였다. 감독 분류를 위한 토지 피복 항목은 총 10개를 고려하였으며, 훈련집단과 참조집단은 SAR 자료와 함께 제공된 ground truth 자료로부터 추출하였다(Table 1). Lee *et al.*(2001)도 동일한 자료를 이용하였으나, 분류 정확도 비교에 감독분류에 사용한 훈련집단을 이용하여 분류 정확도가 과추정될 가능성이 있었으며 수계 영역을 분류 항목으로 포함시켰다. 이 연

Table 1. The number of pixels in training and reference sets.

Class	Training Set	Reference Set
Stem Beans	2940	3059
Potatoes	5784	4601
Lucerne	3230	2124
Wheat	15369	13212
Beet	2295	2062
Rape Seed	7219	6000
Peas	3392	3099
Forest	4891	6461
Grass	1919	1406
Bare Soil	1800	2411

구에서는 공간적으로 중복되지 않는 훈련집단과 참조집단을 각각 추출하였으며, 농작물 등 자연 피복물만을 대상으로 하여 수계는 분류 정확도 계산에서 고려하지 않았기 때문에, 각 집단별 위치는 Lee *et al.*(2001)과 완전히 일치하지 않는다.

2) 적용 결과

Fig. 4는 고유치 기반 target decomposition에 의해 얻어진 C 밴드와 L 밴드의 $H/\bar{\alpha}/A$ 를 나타내고 있다. Fig. 3의 SPAN 자료와 마찬가지로 주파수별로 피복 특성이 다르게 나타남을 확인할 수 있으며, A 값이 C 밴드보다 L 밴드에서 상대적으로 높아졌다. 부가적인 각 토지피복 항목별 산란특성을 살펴보기 위해 $H - \bar{\alpha}$ 공간에서의 분할을 수행하였다. Cloud and Pottier(1997)에 제안된 이 방법은 서로 다른 산란 특성을 $H - \bar{\alpha}$ 공간상에서 8개의 구역으로 나누는 분할에 해당된다(Fig. 5 (a)). C 밴드의 분할 결과를 살펴보면(Fig. 5 (b)), 대부분 표면 산란 특성과 0.6 이상의 중간 혹은 높은 값의 H 를 나타내며 일부 체적 산란 특성을 나타내고 있다. 이는 연구지역이 대부분 농작물로 구성되어 있는 것과 C 밴드의 상대적으로 짧은 파장대에 기인한 것이다. L 밴드 결과에서도 표면 산란 특성이 많이 나타나고 있으나, C 밴드의 높은 값의 H 분포가 낮아진 값에 많이 위치하며 일부 작은 H 값을 보이면서 다중 산란 특성을 나타내는 분포의 수가 늘어난 것을 확인할 수 있다(Fig. 5 (c)). Fig. 5 (b)와 (c)의 결과를 훈련집단과 중첩하여 각 토지 피복별로 상세한 산란 특성을 구한 결과는 Table 2에




Fig. 4. The target decomposition results (H (top), $\bar{\alpha}$ (middle), A (bottom)).

제시되어 있다. C 밴드 결과에서는 대부분 거친 표면 산란 특성의 C6이 우세하며, Bare soil에서는 Bragg surface에 해당되는 C9로 나타났다. Stem beans에서는 C2가 우세하며, 산림과 Grass에서는 구역 체적 산란에 해당하는 C2와 C5의 효과가 혼재되어 나타났다. L 밴드 결과에서도 대부분 C6의 거친 표면 산란 특성이 우세했으나, C 밴드에서는 C2였던 Stem beans가 C5로, C2, C5와 C6이 혼재되어 있던 산림이 C2로, C2와 C5가 혼재되어 있던 Grass가 C6으로 변화하였다. 또한 여러 산란특성이 혼재되어 있던 C 밴드 결과와는 달리

Rape를 제외하고는 모두 대부분 단일 산란특성을 나타내고 있다.

C 밴드와 L 밴드의 각 특징($H/\bar{\alpha}/A$, SPAN)들과 훈련집단의 토지피복항목과의 통계치는 Fig. 6에 제시되어 있다. $H/\bar{\alpha}/A$ 에서는 C 밴드에 비해 L 밴드에서의 값의 분포가 토지피복별로 차이가 있음을 확인할 수 있으며, 두 밴드 모두에서 SPAN에서의 차이가 $H/\bar{\alpha}/A$ 에 비해 두드러지게 나타나고 있다. 이러한 결과로부터 감독분류시 L 밴드 자료를 이용한 분류 결과가 C 밴드에 비해 우수하게 나올 것으로 예측할 수 있다.





Fig. 5. $H\bar{\alpha}$ scattering mechanism identification plane (a). Segmentation results in the $H\bar{\alpha}$ space for (b) C band and (c) L band.

Table 2. Dominant $H\bar{\alpha}$ segmentation result of each land-cover class.

Class	Data	C-band	L-band
Stem Beans		C2 (Anisotropic needle)	C5 (Vegetation)
Potatoes		C6 (Rough surface)	C6 (Rough surface)
Lucerne		C5 (Vegetation) C6 (Rough surface)	C5 (Vegetation)
Wheat		C5 (Vegetation) C6 (Rough surface)	C6 (Rough surface)
Beet		C6 (Rough surface)	C6 (Rough surface)
Rape Seed		C6 (Rough surface)	C6 (Rough surface)
Peas		C6 (Rough surface)	C6 (Rough surface)
Forest		C2 (Anisotropic needle) C5 (Vegetation) C6 (Rough surface)	C2 (Anisotropic needle)
Grass		C2 (Anisotropic needle) C5 (Vegetation)	C6 (Rough surface)
Bare Soil		C9 (Bragg surface)	C9 (Bragg surface)

감독분류를 위한 각 밴드별 $H/\alpha/A$ 와 $SPAN$ 을 입력 특징으로 이용하였으며, SVM을 이용한 분류에서 radial basis function(RBF) 커널을 적용하였다. 확률 비 모델의 적용시 초기확률은 각 토지피복항목별로 동일하게 주었으며, τ 값은 모두 1로 주었다.

Fig. 7은 최종적인 토지 피복 구분 결과를 나타내고 있는데, 최종적인 자료 융합 결과에서는 L 밴드의 영향이 두드러지게 나타나고 있으며, 일부 지역에서는 융합을 통해 C 밴드와 L 밴드의 분류결과와는 다른 토지 피복 항목을 보이고 있다. 또한 분류항목의 혼재로 잡음 효과가 두드러졌던 C 밴드의 분류 결과에 비해 L 밴드 분류 결과와 융합 결과에서는 공간적으로 균일한 분포 양상을 나타내고 있다. 자료 융합에 따른 토지 피복 분류 결과의 변화를 살펴보기 위해 Table 1의 참조집단을

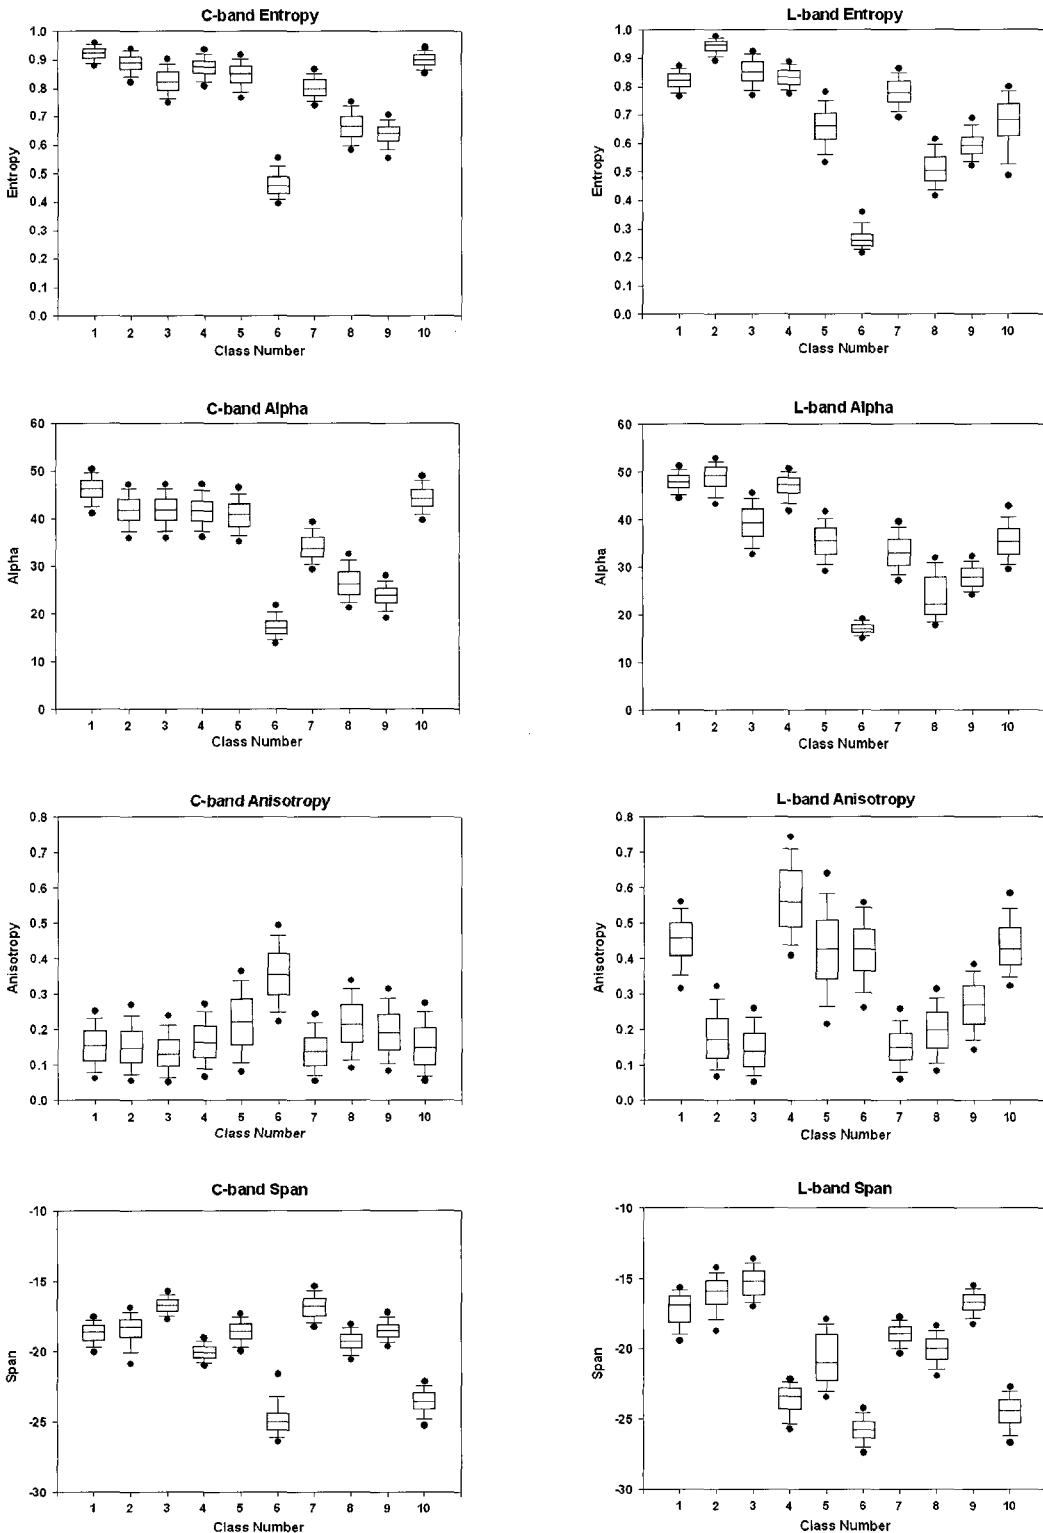


Fig. 6. Box plot of each feature value at the locations of the training set of 10 land-cover classes. The median, 10th, 25th, 75th and 90th percentiles are plotted as vertical boxes with error bars. Dots represents 5th and 95th percentiles. The class number code: 1-Stem Beans, 2-Forest, 3-Potatoes, 4-Lucerne, 5-Wheat, 6-Bare Soil, 7-Beet, 8-Rape Seed, 9-Peas, 10-Grass.

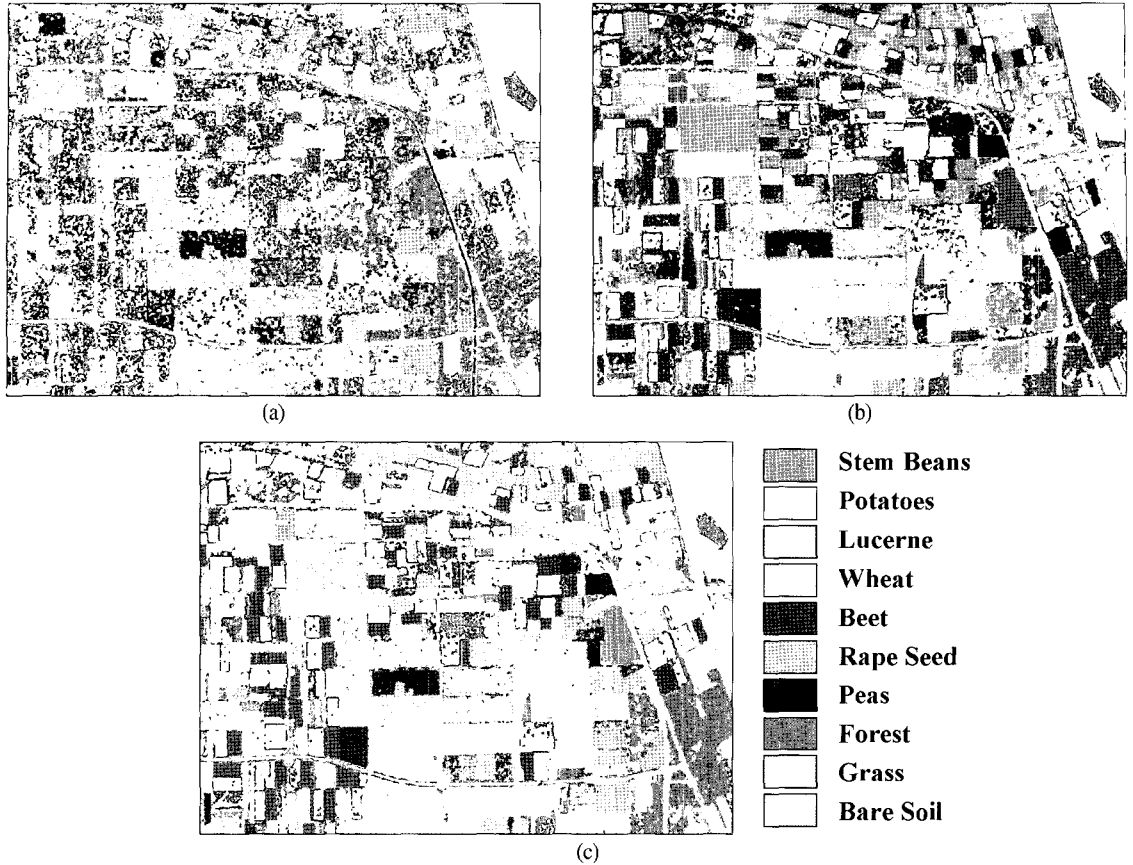


Fig. 7. Classification result, (a) C band, (b) L band, (c) fusion. Water areas are masked out.

이용하여 분류 정확도 통계치를 계산하였다. 단일 주파수 자료의 분류 정확도를 살펴보면(Table 3), 기존 보고와 마찬가지로 L 밴드가 Grass를 제외하고는 C 밴드보

다 우수한 분류 정확도를 나타내었다. 이는 L 밴드가 농작물 구분에 적합한 투과 정도를 나타내는 반면, C 밴드는 짧은 파장 때문에 농작물의 구조와 관련된 정보를 얻을 정도의 충분한 투과 정도를 나타내지 않았기 때문이다. 두드러진 분류 정확도의 차이를 나타내는 분류 항목들은 Forest, Lucerne, Stem beans, Beet 등이었으며, 43%에서 52% 정도까지의 차이를 나타내고 있다. 이들 항목은 C 밴드의 분류 결과에서 각각 Wheat, Potatoes 등으로 오분류되었으며, Stem beans는 주로 Forest로 오분류된 것으로 나타났다. 이러한 결과는 Table 2의 산란특성과 관련이 있는 것으로 보이는데, 예를 들어 Forest의 경우 C2, C5, C6 등으로 다양하게 산란특성이 나타나는데, 일반적인 C2만의 산란특성을 보이지 않기 때문인 것으로 판단된다. L 밴드에서 Grass 항목의 낮은 분류 정확도는 Wheat 항목 일부가 Grass로 분류되어 나타난 결과에 기인한 것이다. C 밴드와 L 밴드 자료를 융합한 결과는 단일 센서 자료에 비

Table 3. Percent classification accuracy statistics.

	C band	L band	Fusion
Overall accuracy	66.32	88.00	97.21
Average accuracy	65.70	85.53	97.36
Stem Beans	47.22	95.00	98.93
Potatoes	62.31	92.76	97.06
Lucerne	36.44	88.49	96.01
Wheat	87.03	92.77	98.67
Beet	33.59	82.11	97.75
Rape Seed	80.37	87.45	93.48
Peas	65.08	73.99	94.96
Forest	49.95	93.49	96.77
Grass	95.77	49.45	99.98
Bare Soil	99.22	99.75	99.96

해 우수한 분류 정확도를 보였는데, L 밴드만을 이용한 결과에 비해 약 10% 정도의 분류정확도의 향상을 나타내었다. 비록 L 밴드만을 이용하였을 때에도 각 항목별로 높은 분류 정확도를 보였지만, 융합에 의해 피복간 구분력이 향상되었다. 개별 자료에서 높은 정확도를 나타내고 있는 Bare soil을 제외하고는 약 3%에서 최대 51%까지의 향상된 분류정확도를 나타내고 있다. 자료 융합의 효과는 Peas와 Grass 항목에서 두드러졌는데, C 밴드와 L 밴드만을 이용한 분류에서 65%와 74%의 정확도를 각각 보였던 Peas 항목에서는 21% 정도의 분류정확도의 향상을 나타내었다. 특히 L 밴드에서 상대적으로 구분력이 떨어졌던 Grass에서는 C 밴드의 영향으로 분류정확도가 C 밴드와 유사하거나 향상된 것으로 나타났다. 이러한 결과를 종합해보면, 기존 연구와 마찬가지로 대규모 농작물 구분에는 L 밴드가 유효하지만, 자료 융합을 통해 상호보완적인 정보의 이용이나 정보의 강화가 이루어져 분류 정확도를 향상시킬 수 있는 것으로 나타났다.

4. 결론

이 연구에서는 토지 피복 구분을 목적으로 C 밴드와 L 밴드 다중 편광 자료의 결정 수준 융합을 수행하여 융합에 의한 효과를 살펴보았다. Target decomposition으로부터 얻어지는 산란 특성과 관련된 특징들을 입력으로 SVM을 적용한 결과, L 밴드가 C 밴드에 비해 연구 지역의 토지 피복 구분에 적절한 투과 심도를 나타내어 전체 정확도 22% 이상의 상대적으로 높은 분류 정확도를 나타내었지만, 융합을 통해 보다 향상된 분류 정확도를 얻을 수 있었다. L 밴드에서 높은 분류정확도를 나타낸 대부분의 토지 피복 항목들의 정확도가 결정수준 융합을 통해 구분력 향상이 강화되어 전체적으로 10% 정도의 향상된 분류 정확도를 얻을 수 있었다. 앞으로 산란 강도와 위상 정보를 포함하고 있는 공분산 행렬로부터 추출할 수 있는 특징들을 이용한 분류 결과와의 비교 연구를 통해 입력 특징의 효과를 분석할 예정이다.

방법론 차원에서 이 연구에서 제시한 결정수준 융합 방법론은 다중 주파수 편광 SAR 자료의 융합 이외에 토지 피복 구분을 위한 다중센서 위성자료를 다루는 문제

에서도 적용이 가능하다. 확률비 모델은 다양한 위성자료의 특성을 효율적으로 이용할 수 있는 틀을 제공하기 때문에 결정수준 자료 융합에 장점이 많다. 가시광선 영역과 적외선 영역의 정보를 제공하는 광학 위성 자료의 경우, 일반적으로 이들 자료의 확률 분포는 다차원 정규 분포로 모델링 될 수 있다. 그러나 마이크로파 영역을 영상화하는 SAR 자료는 이러한 다차원 정규 분포를 이루지 않는 경우가 많다. 따라서 이러한 광학 위성 자료와 SAR 자료를 함께 다차원 정규 분포의 가정하에 기존 광학 위성 자료 처리에 많이 사용해진 최대우도 분류 기법이나 다차원 정규 분포 기반 베이저안 확률 이론을 적용할 경우, 토지 피복 구분 능력의 향상을 보장할 수 없다. 따라서 확률비 모델의 틀 안에서 개별 자료의 특성을 고려한 모델링 기법을 적용할 경우 보다 향상된 자료 융합효과를 얻을 수 있을 것으로 생각된다.

이 연구에서 고려하고 있는 토지 피복 항목은 밭에서 주로 재배되는 농작물이었는데, 우리나라에서 사례연구 지역인 네덜란드처럼 대규모 농경지에서 벼를 제외하고 밭작물이 재배되는 경우는 거의 드물다. 따라서 소규모 지역에서 다양한 밭작물이 재배되는 우리나라의 경우에 사례연구와 같은 많은 농작물의 구분은 현실적으로 쉽지 않다. 우리나라에서 농작물 구분을 목적으로 다중 주파수 편광 SAR 자료를 이용할 경우에는 생육상태 및 연중 변화 등을 고려한 자료의 이용이 중요하게 작용될 것으로 보인다. 이와 관련하여 다중 편광 SAR 자료의 지표 피복 구분력 향상을 보다 정량적으로 분석하기 위해 복잡한 토지피복을 포함하는 지역에 대한 사례연구와 분석결과의 해석을 위해 토지 피복별 편광 특성 분석이 필요하다.

사 사

이 연구는 위성자료 공공활용연구 “지상관측 위성자료 clearing house 구축”의 일환으로 수행되었습니다. 이 연구에 사용된 NASA JPL AIRSAR 자료는 IEEE Geoscience and Remote Sensing Society의 Data Fusion Technical Committee에서 제공받은 것으로 이에 감사드립니다. 논문의 표현을 명확하게 하는데 도움을 주신 익명의 심사위원께 감사드립니다.

참고문헌

- 이상훈, 2003. 퍼지 클래스 벡터를 이용하는 다중센서 융합에 의한 무감독 영상분류, 대한원격탐사학회지, 19(4): 329-339.
- Bazi, Y. and F. Melgani, 2006. Toward on optimal SVM classification system for hyperspectral remote sensing images, *IEEE Transactions on Geoscience and Remote Sensing*, 44(11): 3374-3385.
- Bordley, R. F., 1982. A multiplicative formula for aggregating probability assessment, *Management Science*, 28(10): 1137-1148.
- Cloude S. R. and E. Pottier, 1996. A review of target decomposition theorems in radar polarimetry, *IEEE Transactions on Geoscience and Remote Sensing*, 34(2): 498-518.
- Cloude S. R. and E. Pottier, 1997. An entropy based classification scheme for land applications of polarimetric SAR, *IEEE Transactions on Geoscience and Remote Sensing*, 35(1): 68-78.
- Cristianini, N. and J. Shawe-Taylor, 2000. *An Introduction to Support Vector Machines*, Cambridge University Press, Cambridge, UK.
- Ferro-Famil, L., E. Pottier, and J.-S. Lee, 2001. Unsupervised classification of multifrequency and fully polarimetric SAR images based on the H/A/Alpha-Wishart classifier, *IEEE Transactions on Geoscience and Remote Sensing*, 39(11): 2332-2342.
- Footy, G. M. and A. Mathur, 2004. A relative evaluation of multiclass image classification by support vector machines, *IEEE Transactions on Geoscience and Remote Sensing*, 42(6): 1335-1343.
- Footy, G. M., M. B. McCulloch, and W. B. Yates, 1994. Crop classification from C-band polarimetric radar data, *International Journal of Remote Sensing*, 15(14): 2871-2885.
- Freeman, A. and S. L. Durden, 1998. A three-component scattering model for polarimetric SAR data, *IEEE Transactions on Geoscience and Remote Sensing*, 36(3): 963-973.
- Henderson, F. M. and A. J. Lewis, 1998. *Principles & Applications of Imaging Radar*, John Wiley & Sons, Inc., New York, NY, USA.
- Journel, A. G., 2002. Combining knowledge from diverse sources: an alternative to traditional data independence hypotheses, *Mathematical Geology*, 34(5): 573-596.
- Krishnan, S., 2004. *Combining diverse and partially redundant information in the earth sciences*, Ph.D. Thesis, Stanford University.
- Krogager, E., 1992. Decomposition of the Sinclair matrix into fundamental components with application to high resolution radar target imaging, *Direct and Inverse Methods in Radar Polarimetry*, Part 2, Boerner, W.-M., ed., Kluwer, Dordrecht, The Netherlands, pp. 1459-1478.
- Lee J.-S., M. R. Grunes, and R. Kwok, 1994. Classification of multi-look polarimetric SAR imagery based on complex Wishart distribution, *International Journal of Remote Sensing*, 15(11): 2299-2311.
- Lee J.-S., M. R. Grunes, L. T. Ainsworth, L. Du, D. L. Schuler, and S. R. Cloude, 1999. Unsupervised classification using polarimetric decomposition and the complex Wishart classifier, *IEEE Transactions on Geoscience and Remote Sensing*, 37(5): 2249-2258.
- Lee, J.-S., M. R. Grunes, and E. Pottier, 2001. Quantitative comparison of classification capability: fully polarimetric versus dual and single-polarization SAR, *IEEE Transactions on Geoscience and Remote Sensing*, 39(11): 2343-2351.
- Lemoine, G., F. de Grandi, and A. J. Sieber, 1994. Polarimetric contrast classification of

- agricultural fields using MAESTRO-1 AIRSAR data, *International Journal of Remote Sensing*, 15(14): 2851-2869.
- Melgani, F. and L. Bruzzone, 2004. Classification of hyperspectral remote sensing images with support vector machines, *IEEE Transactions on Geoscience and Remote Sensing*, 42(8): 1778-1790.
- Park, N.-W., 2004. *Multi-source spatial data fusion with geostatistical uncertainty assessment: applications to landslide susceptibility analysis and land-cover classification*, Ph. D. Thesis, Seoul National University.
- Rignot, E. and M. R. Drinkwater, 1992. On the application of multifrequency polarimetric radar observations to sea-ice classification, *Proc. of IGARSS'94*, Pasadena, CA, Aug. 8-12, pp. 2467-2469.
- Smits, P. C., 2003. Geospatial data fusion, IGARSS 2003 Tutorial.
- van Zyl, J. J., 1990. Unsupervised classification of scattering behavior using radar polarimetric data, *IEEE Transactions on Geoscience and Remote Sensing*, 27(1): 36-45.