

다중 시기 SAR 자료를 이용한 토지 피복 구분을 위한 특징 추출과 융합

박노옥* · 이훈열** · 지광훈*

한국지질자원연구원 지질자원정보센터*, 강원대학교 지구물리학과**

Feature Extraction and Fusion for Land-Cover Discrimination with Multi-Temporal SAR Data

No-Wook Park*, Hoonyol Lee**, and Kwang-Hoon Chi*

Geoscience Information Center, Korea Institute of Geoscience and Mineral Resources*,

Department of Geophysics, Kangwon National University**

Abstract : To improve the accuracy of land-cover discrimination in SAR data classification, this paper presents a methodology that includes feature extraction and fusion steps with multi-temporal SAR data. Three features including average backscattering coefficient, temporal variability and coherence are extracted from multi-temporal SAR data by considering the temporal behaviors of backscattering characteristics of SAR sensors. Dempster-Shafer theory of evidence(D-S theory) and fuzzy logic are applied to effectively integrate those features. Especially, a feature-driven heuristic approach to mass function assignment in D-S theory is applied and various fuzzy combination operators are tested in fuzzy logic fusion. As experimental results on a multi-temporal Radarsat-1 data set, the features considered in this paper could provide complementary information and thus effectively discriminated water, paddy and urban areas. However, it was difficult to discriminate forest and dry fields. From an information fusion methodological point of view, the D-S theory and fuzzy combination operators except the fuzzy Max and Algebraic Sum operators showed similar land-cover accuracy statistics.

Key Words : Multi-temporal SAR Data, Temporal Variability, Theory of Evidence, Fuzzy Logic.

요약 : SAR 자료의 분류에서 토지 피복 구분 분류 정확도의 향상을 위해 이 논문은 다중 시기 SAR 자료를 이용한 분류에서의 특징 추출과 정보 융합 방법론을 제시하였다. 다중 시기 SAR 센서의 산란 특성을 고려하여 평균 후방 산란계수, 시간적 변이도와 긴밀도를 특징으로서 추출하였다. 이렇게 추출된 특징의 효율적인 융합을 위해 Dempster-Shafer theory of evidence(D-S 이론)와 퍼지 논리를 적용하였다. 특히 D-S 이론의 적용시 특징 기반 mass function 할당을 제안하였고, 퍼지 논리의 적용시 다양한 퍼지 결합 연산자의 결과를 비교하였다. 다중 시기 Radarsat-1 자료에의 적용 결과, 추출된 특징들은 서로 상호 보완적인 정보를 제공할 수 있으며 수계, 논과 도심을 효율적으로 구분할 수 있었다. 그러나 산림과 밭은 구분이 애매한 경우가 나타났다. 정보 융합 방법론 측면에서,

D-S 이론과 퍼지 Max와 Algebraic Sum 연산자를 제외한 다른 퍼지 연산자는 서로 유사한 분류 정확도를 나타내었다.

1. 서론

원격탐사 화상 분류를 통한 토지 피복도 혹은 토지 이용도 작성은 원격탐사의 여러 응용 분야 중에서도 자료 처리 관점에서 많은 분류 기법 개발과 사례연구가 진행되어왔다. 기존에는 Landsat, SPOT 등의 중·저해상도 광학 위성 자료를 이용한 연구가 많이 진행되어 왔는데, 최근에는 IKONOS와 QuickBird와 같은 고해상도 위성 자료나 Hyperion과 같은 초다분광 위성 자료를 이용한 분류 연구가 많이 진행되고 있는 상황이다. 화상 분류를 위해서는 적정 분류 기법의 선택뿐만 아니라 토지 피복 구분이 명확한 시기의 자료 선택 또한 중요하다. 그러나 광학 위성 자료를 이용한 분류에서는 구름 등의 기상 상태에 의존적이기 때문에 원하는 시기의 자료 이용이 쉽지가 않으며, 특히 우기인 7월과 8월의 경우 광학 위성 자료 자체의 획득이 매우 어렵다.

이러한 상황을 고려할 때, 자료 이용 측면에서 구름과 같은 기상 상태의 제약 없이 자료 획득이 가능한 SAR 자료를 이용한 분류가 대안이 될 수 있다. 그러나 SAR 자료의 경우, 광학 위성 자료와 달리 영상화 단계에서 수반되는 스펙클 노이즈와 side-looking에 따른 기하학적 왜곡 등으로 인해 상대적으로 자료처리에 많은 어려움이 있다. 또한 현재 가용할 수 있는 인공위성 SAR 자료의 경우 단일 주파수, 단일 편광상태 자료를 제공하기 때문에 여러 분광 밴드를 사용할 수 있는 광학 위성 자료에 비해 한계가 있다. 이러한 단점을 극복하기 위해 텍스처 분석 등을 통해 SAR 자료 자체의 분류 정확도를 향상시키려는 연구(Carr and de Miranda, 1998)가 있었으나, 광학 위성 자료만큼의 만족스러운 분류 정확도를 얻기가 쉽지 않다.

SAR 자료를 분류에 이용할 때 이러한 단점을 극복할 수 있는 대안은 대략 다음 3가지 정도로 요약할 수 있다. 첫 번째 방법으로는 비슷한 시기

에 촬영된 광학 위성 자료와 SAR 자료를 융합하여 분류 정확도를 향상시키는 것이다. 이 경우 서로 다른 파장대의 자료로부터 상호보완적인 (complementary) 정보를 분류에 이용함으로써 분류 정확도를 향상시킬 수 있으며, 베이지안, 퍼지, 인공 신경망 이론 등 많은 방법론 개발이 진행되어 왔다. 그러나 이 경우 SAR 자료만을 이용하였을 때에 비해 향상된 분류 정확도를 얻을 수 있지만, 원하는 시기의 광학 위성 자료 획득의 제한을 내포하게 된다. SAR 자료와 비슷한 시기의 광학 위성 자료의 이용이 힘들 경우, 이전에 획득된 광학 위성 자료와 원하는 시기의 SAR 자료와의 시간적 문맥 정보(temporal contextual information)를 고려하는 것이 대안이 될 수 있다(Bruzzone *et al.*, 1999). 두 번째 방법으로는 다중 주파수, 다중 편광 상태의 SAR 자료를 이용하는 방법이다. 현재 이러한 접근은 항공기 탑재 SAR 자료에 국한적으로 적용되어 왔는데(Lee *et al.*, 2001), 현재 가용 중인 ENVISAT의 dual 편광 상태 자료와 full 편광 상태 자료를 제공할 발사 예정인 L밴드 ALOS와 C밴드 Radarsat-2 자료의 이용이 가능해질 경우 적용이 가능한 방법론에 해당된다. 세 번째로는 단일 주파수, 단일 편광 상태 SAR 자료를 이용하는데 있어서 다중 시기 자료를 이용하는 방법이다. 다중 시기에 따른 토지 이용의 변화가 없다는 가정 하에 이 방법론을 이용할 경우, SAR 시그널의 시계열적 변화를 직접 분석함으로써 토지 피복 구분이 가능해진다. 이 방법론의 경우 기존 연구(Luckman *et al.*, 2000; Quegan *et al.*, 2000; Strozzii *et al.*, 2000; Bruzzone *et al.*, 2004)에서는 유럽의 ERS-1/2 Tandem pair가 유용하게 이용되었는데, 우리나라에서는 이러한 ERS-1/2 Tandem pair의 시계열적인 자료 이용이 불가능하며, 과거 JERS-1 자료나 현재 운영 중인 24일 주기의 Radarsat-1 자료에 적용이 가능하다.

이 논문에서는 SAR 자료를 이용한 토지 피복

분류를 목적으로 세 번째 방법론에 기초하여 다중 시기 SAR 자료로부터 추출 가능한 특징과 분류 방법론에 대해 논의하고자 한다. 우선 다중 시기 SAR 자료의 산란 특성을 고려하여 분류에 이용 가능한 특징을 추출하고자 하였으며, 각 특징들의 특성을 고려한 분류 기법으로 Dempster-Shafer Theory of Evidence(이하 D-S 이론)와 퍼지 논리를 적용하였다(Fig. 1). 충남 삼포천 주변 예당평야 일대의 농업 지역의 다중 시기 Radarsat-1 자료를 대상으로 사례연구를 수행하였다.

2. 적용 방법론

1) 특징 추출

이 논문에서는 다중 시기 SAR 자료의 산란 특성으로 고려하여 평균 후방 산란계수(average backscattering coefficient), 시간적 변이도(temporal variability), 긴밀도(coherence) 등의 3가지의 특징을 추출하여 분류에 이용하였다.

연구지역 특정 화소의 위치를 X 라고 하고, 기본적인 전처리가 완료된 n 개의 다중 시기 SAR 자료 $S_k(X) (k=1, \dots, n)$ 가 있다고 할 때, 첫 번째 특징으로 고려한 평균 후방 산란계수 $\bar{\sigma}_o(X)$ 는 개별 자료의 후방 산란계수로부터 얻을 수 있다(식 1).

$$\bar{\sigma}_o(X) = \sum_{i=1}^n \sigma_{os_i}(X) \quad (1)$$

여기서 $\sigma_{os_i}(X)$ 는 i 번째 자료 $S_i(X)$ 의 후방 산란계수를 나타낸다.

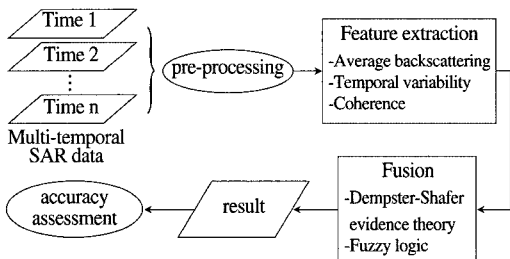


Fig. 1. Work process proposed in this paper for land-cover discrimination with multi-temporal SAR data.

이렇게 추출된 평균 후방 산란계수로부터 일반적으로 낮은 값을 나타내는 수계와 높은 값을 나타내는 도심지의 구분이 가능해진다. 또한 농작물의 생육 상태, 입사각 등에 따라 농경지와 산림의 구분이 자료와 시기에 따라 가능할 수도 있다.

두 번째 특징으로 다중 시기 자료의 특성을 고려하여 다중 시기 후방 산란계수의 변화 양상을 나타내는 시간적 변이도를 고려하였다. 일반적으로 수계의 경우, 바람과 기상 상태 등에 따라 시간적 변화가 심한 편이다. 고요한 수계의 경우 후방 산란이 거의 일어나지 않아 낮은 후방 산란계수값을 나타내나, 바람이 불거나 강우가 있을 경우 표면의 교란이 일어나 이전 상태에 비해 상대적으로 높은 후방 산란계수값을 나타낸다. 또한 농작물의 경우, 작물의 성장이나 농업 활동, 토양 수분의 변화로 시간적 변이도가 크게 나타날 수 있다. 특히 논인 경우, 관개 등으로 인해 봄부터 초여름까지 변화가 심한 편이다. 이에 비해 산림과 도심지의 경우 일반적으로 시간적 변이도가 낮게 나타난다. 따라서 시간적 변이도로부터 수계, 농경지로부터 산림과 도심지의 구분이 가능할 수 있다. 그러나 여기서 주의할 점은 이러한 시간적 변이도의 강도는 SAR 센서의 주파수, 편광상태와 입사각에 의존적이라는 것이다. 파장이 짧은 C 밴드를 사용하는 ERS, Radarsat-1, ENVISAT 등은 상대적으로 긴 파장대인 L 밴드를 사용하는 JERS-1에 비해 농작물의 후방 산란계수값은 비의 성장 초기 단계 이후에는 이미 포화상태에 이르러 그 변화값이 두드러지게 나타나지 않는다. 또한 수계에서의 경우 VV와 HH의 편광상태 및 입사각에 따라 그 변화의 크기가 다르게 나타날 수 있다.

이 연구에서는 시간적 변이도를 나타내는 정량적 지수로 식 (2)의 표준편차를 이용하였다.

$$T(X) = \sqrt{\frac{\sum_{i=1}^n (\sigma_{os_i}(X) - \bar{\sigma}_o(X))^2}{n}} \quad (2)$$

세 번째 특징으로 레이더 간섭(Interferometric SAR)의 부산물인 긴밀도를 이용하였다. 레이더 간섭에서 서로 다른 센서 위치에서 얻어진 두 자

료간의 위상 차이인 간섭 위상은 지표의 기하학적 정보를 포함하는데, 이러한 간섭 위상 정확도의 추정은 간섭쌍의 상호 관계 정도를 나타내는 긴밀도로 표현된다.

두 개의 레이더 간섭쌍을 $S_1(X)$ 와 $S_2(X)$ 라고 할 때, 긴밀도 $\rho(X)$ 는 식 (3)으로 표현된다.

$$\rho(X) = \frac{E[S_1(X)S_2^*(X)]}{\sqrt{E[S_1(X)S_1^*(X)]E[S_2(X)S_2^*(X)]}} \in [0, 1] \quad (3)$$

여기서 $E[\]$ 와 *은 ensemble averaging과 공액복소수 연산을 각각 의미한다.

레이더 간섭에서 상호 관계 정도는 신호대 잡음비, 스펙클 노이즈, 영상의 기하학적 비정합, 위성의 간격, 시간적 변이 등의 영향을 받는데, 이러한 상호 관계 정도를 나타내는 긴밀도는 레이더 간섭에서 간섭도(interferogram)의 질을 평가하는 기준으로 이용이 가능하지만, 지표면의 시간적 안정성을 측정하는 척도로도 이용이 가능하다. 체적 산란과 산란체의 임의적인 이동과 변화와 같은 시간적 변화는 긴밀도를 감소시키게 된다(Lee and Liu, 2001). 따라서 긴밀도로부터 관측 기간 동안의 식생의 변화, 지표면의 변화, 인공적인 변화 등을 반영할 수 있다. 토지 피복 구분과 관련하여, 일반적으로 수계와 산림지역은 산란체의 기하학적 구조의 변화로 인해 낮은 긴밀도를 나타내며, 도심지는 높은 값을 나타낸다.

이러한 긴밀도를 추출하기 위해서는 위성의 두 관측 궤도가 적절한 기선거리(baseline distance)와 시간 간격을 유지해야 하는데, 보통 임계 기선거리는 ERS 위성의 경우 약 1km, JERS-1의 경우 약 4km이다. 그러나 보통 기선거리가 길수록 긴밀도가 떨어져 전반적으로 너무 낮은 긴밀도를 얻게 되며 재촬영 주기가 길수록 긴밀도도 떨어지게 되는데, 이는 SAR 센서의 파장과도 연관이 있기 때문에 적절한 간섭쌍 선택이 중요하다. 유럽의 ERS-1/2 Tandem pair는 비교적 높은 긴밀도를 유지하여 주지만, 우리나라에서는 상대적으로 가용할 수 있는 자료의 수가 극히 제한적이며 대부분 겨울이나 초봄에 촬영된 것이 많아서 적용에 한계가

있다. 그러나 Strozzi *et al.*(2000)에서 논의한 것처럼 하루 간격이 아닌 상대적으로 긴 시간 간격을 가진 간섭도 쌍으로부터 얻어진 긴밀도를 이용할 경우, 상대적으로 안정적인 고정 산란체(permanent scatterer)로 이루어진 도심지와 다른 피복간의 구분이 가능하다.

2) 특징 융합 및 분류

앞에서 논의한 특징들을 분류에 이용할 때, 개별 특징로부터 모든 토지 피복 항목의 구분이 가능한 것은 아니다. 예를 들어 긴밀도로부터는 도심지와 다른 토지 피복을, 시간적 변이도로부터 수계, 농경지와 다른 토지 피복을 구분할 가능성이 크다. 즉 개별 특징에서 구분할 수 있는 정보들은 서로 중복되어 있다기보다는 일종의 상호보완적인 정보를 제공한다고 간주할 수 있다. 따라서 상호보완적인 정보를 제공하는 특징들을 효율적으로 분류에 적용할 수 있는 기법의 선택이 다중시기 SAR 자료를 이용한 분류에서 중요하다.

분류 방법론 측면에서 기존 연구에서는 계층적 임계치 방법(hierarchical thresholding)이나 최대 우도 분류 등을 적용하였는데(Strozzi *et al.*, 2000), 계층적 임계치 방법은 주로 산림과 비산림 등 단순한 클래스 구분에 주로 이용되어 왔으며(Quegan *et al.*, 2000; Luckman *et al.*, 2000) 임계치 설정에 주관성이 따르며, 최대 우도 분류는 보통 다변량 정규 분포를 이루지 않는 특징들의 특성상 적용에 어려움이 있다. 최근 Bruzzone *et al.*(2004)이 RBF 신경망 이론을 적용하였으나, 신경망 이론의 특성상 뉴론, 은닉층의 개수의 조절이 자료의 특성에 따라 달라지기 때문에 일반적인 방법론으로 간주할 수는 없다.

이 연구에서는 상호보완적인 정보를 효율적으로 결합할 수 있는 자료 융합 기법으로 D-S 이론과 퍼지 논리를 각각 적용하였다. 이 두 기법은 주로 다중 센서 자료 융합에 이용되어 왔는데(Hegarati-Masle *et al.*, 1999; Park, 2004; Rottensteiner *et al.*, 2005), 정보의 불확실성을 표현할 수 있는 효율적인 자료처리의 framework을 제공한다.

(1) D-S 이론

Dempster(1967)에 의해 제창된 확률의 상한과 하한 이론을, Shafer(1976)가 확대 정리한 이 이론은 확률통계적 접근과는 달리 확신의 정도가 구간으로 표현되어 자료의 불확실성을 모사할 수 있다. 자료 융합 관점에서 이 이론은 자료 표현(data representation)을 위해 mass function 혹은 BPA (Basic Probability Assignment)를, 자료 결합(data combination)을 위해 Dempster's orthogonal sum을 적용한다. 토지 피복 구분을 목적으로 이 이론의 적용에 대한 자세한 이론은 Mertikas and Zerakis(2001)를 참조할 수 있으며, 여기서는 기본 개념에 대해서만 기술하고자 한다.

자료 표현 방법으로 mass function 혹은 BPA (Basic Probability Assignment)를 통한 확률적인 표현 방법을 이용하지만 기존의 확률/통계적인 배경과는 기본적인 개념이 다르다. 이 이론에서는 우선 상호 배타적인 가설 n 개의 집합인 frame of discernment θ 를 설정하고, θ 의 모든 가능한 부분 집합 즉 2^n 개의 가설에 대해 확신 정도를 할당하게 된다(Fig. 2(a)). Fig. 2(a)에서는 4개의 가설을 고려한 경우를 나타내는데, 이 경우 \emptyset , 단일 가설, 결합 가설 등 총 16개의 가설에 대해 확신 정도를 할당하게 된다. 원격탐사 화상 분류에서 가설은 분류 항목에 해당된다.

θ 의 부분집합에 대한 개개 증거 혹은 자료들이

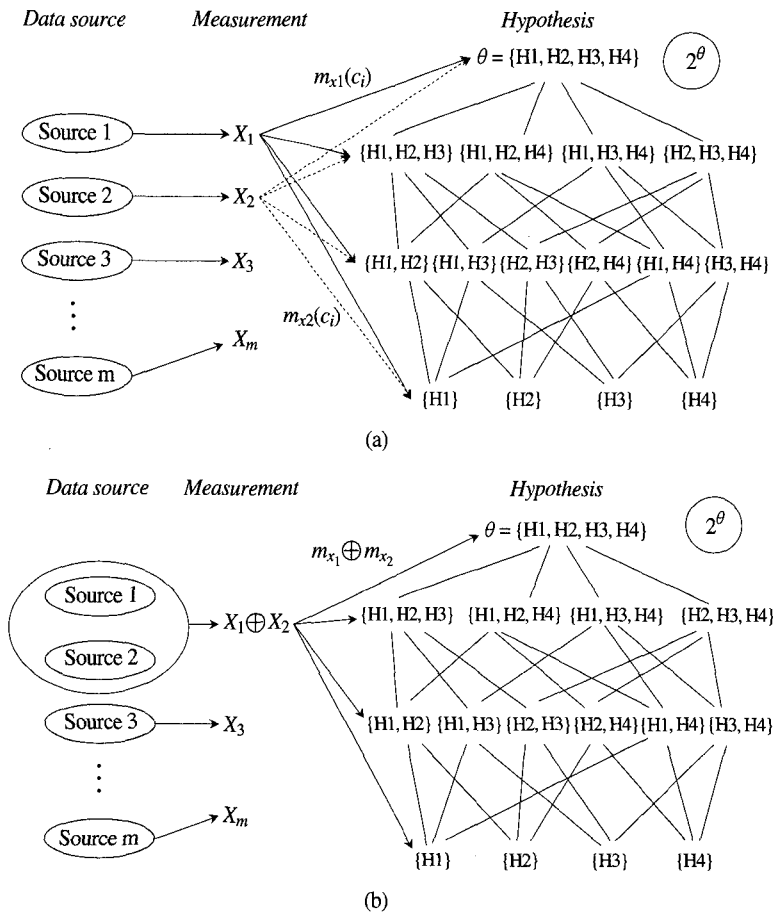


Fig. 2. Schematic diagram of frame of discernment, mass function assignment and combination in case of 4 hypotheses; (a) mass functions of source 1 and 2, (b) orthogonal summation of (a).

지지하는 확신 정도는 mass function 혹은 BPA로 표현되는데 식 (4)의 조건을 만족해야 한다.

$$\sum_{A \subset \theta} m(A) = 1, m(\phi) = 0 \quad (4)$$

이렇게 표현되는 mass function에 기반하여 belief function(Bel)과 plausibility function(Pls)을 식 (5)로 정의한다.

$$\begin{aligned} Bel(A) &= \sum_{B \subset A} m(B) \\ Pls(A) &= 1 - Bel(\bar{A}) = \sum_{B \cap A = \phi} m(B) \\ Bel(A) &\leq P(A) \leq Pls(A) \end{aligned} \quad (5)$$

여기서 A와 B는 가설을 각각 나타낸다.

식 (5)에서 belief function은 특정 가설에 부합 되도록 할당되는 모든 mass function의 합으로 조건부 확률의 하한경계로, plausibility function은 상한경계로 해석할 수 있다. 일반적으로 $Bel(A) \neq Pls(A)$ 이기 때문에 실제 참값은 belief function과 plausibility function의 사이에 존재하게 된다. D-S 이론이 기존 확률 이론과 가장 큰 차이는 여기에 있으며, 신뢰구간으로 표현할 수 있는 [Bel, Pls]로 일종의 불확실성을 표현할 수 있다.

또 다른 확률 이론과의 차이점은 특정 가설에 대해 자료들이 지지하는 확신 정도가 표현되지 않는다. 확신이나 불신을 할 수 없는 아무런 확신 정도가 형성되어 있지 않은 영역으로 인식한다. 예를 들어 $m(A) = 0.6$ 일 경우 1에서 이 값을 빼준 0.4를 확률 이론에서는 A라는 가설에 반대되는 \bar{A} 에 대한 확신으로 표현하여 두 가지 상반된 가설에 대한 확신이 동시에 존재하는 것으로 간주한다. 그러나 D-S 이론에서는 만약 \bar{A} 에 대한 확신 정도를 자료로부터 알 수 없을 경우, 어떤 자료에 의해 확신되고 남은 값을 \bar{A} 에 할당하지 않는다. 대신 이를 아무런 확신이 형성되어 있지 않은 불확실성 영역 $A \cup \bar{A}$ 에 값을 할당하여 $m(A \cup \bar{A}) = 0.4$ 이 된다. 그러므로 모든 가설에서의 확률값의 합이 1이 되어야 하는 확률 이론과는 차이가 있다.

개별 자료들에 대한 mass function이 정의되면 이들의 결합에는 Dempster's orthogonal sum을 이용하여 결합된 mass function을 얻게 되고, 이로부

터 결합 belief function과 plausibility function을 구하게 된다. Fig. 2(b)에서는 Source 1과 Source 2의 mass function의 결합을 도식적으로 나타내고 있다. 일반적으로 p개의 자료 혹은 특징의 mass function $m_i(i=1, 2, \dots, p)$ 의 가설 A에 대한 결합은 식 (6)을 이용하게 되며, Dempster's orthogonal sum은 교환법칙이 성립하기 때문에 결합의 순서에 상관없이 동일한 결과를 나타낸다.

$$\begin{aligned} m_1 \oplus m_2 \oplus \dots \oplus m_p(A) &= \frac{\sum_{B_1 \cap \dots \cap B_p = A} \prod_{i=1, \dots, p} m_i(B_i)}{1 - K} \\ K &= \sum_{B_1 \cap \dots \cap B_p = \phi} \prod_{i=1, \dots, p} m_i(B_i) \end{aligned} \quad (6)$$

여기서 A와 B는 가설을 각각 나타내며, B는 i번째 자료 혹은 특징에 대한 가설을 나타낸다.

(2) 퍼지 논리

Zadeh(1965)에 의해 제안된 퍼지 이론은 명확하게 정의된 경계를 갖지 않는 퍼지 집합을 기본적으로 이용하기 때문에 토지 피복 분류에서 다중 속속도를 고려할 수 있는 장점이 있다.

자료 융합 관점에서 이 이론은 자료 표현을 위해 퍼지 소속 함수를, 자료 결합에 퍼지 결합 연산자를 이용한다. 퍼지 소속 함수는 벨형, 삼각형, 사다리꼴 등의 특정 형태의 함수로 정의하는 방법과 확률밀도함수로부터 정의하는 방법 등 다양하다 (Park, 2004). 일반적으로 자료 융합에 사용하는 퍼지 결합 연산자는 여러 가지가 있는데, n개의 퍼지 소속함수 $[\mu_{E_1}, \mu_{E_2}, \dots, \mu_{E_n}]$ 이 있을 때 주로 이용되어온 결합 연산자를 정리하면 Table 1과 같다.

Table 1. Fuzzy combination operators.

Operator	Equation
Max	$\mu_{Max} = \text{Max}[\mu_{E_1}, \mu_{E_2}, \dots, \mu_{E_n}]$
Min	$\mu_{Min} = \text{Min}[\mu_{E_1}, \mu_{E_2}, \dots, \mu_{E_n}]$
Algebraic Sum	$\mu_{Sum} = 1 - \prod_{k=1}^n (1 - \mu_{E_k})$
Algebraic Product	$\mu_{Product} = \prod_{k=1}^n \mu_{E_k}$
γ	$\mu_{\gamma} = [1 - \prod_{k=1}^n (1 - \mu_{E_k})]^{\gamma} \times \prod_{k=1}^n [\mu_{E_k}]^{1-\gamma} (0 < \gamma < 1)$

Max 연산자와 Min 연산자는 논리적으로 OR와 AND에 해당하며, 자료의 기여도 측면에서 최대값 혹은 최소값을 나타내는 하나의 퍼지 소속함수가 결합에 기여하게 된다. 반면 Algebraic Sum 연산자와 Algebraic Product 연산자를 모든 자료들이 연산에 기여하게 되며, Algebraic Sum 연산자는 최대값보다 큰 값을 결합된 값으로 넘겨주며, Algebraic Product 연산자는 최소값보다 작은 값을 최종 결합 결과로 넘겨주게 된다. γ 연산자는 γ 값에 따라 Algebraic Sum 연산자와 Algebraic Product 연산자의 효과를 조절하는 연산자로(Fig. 3), $\gamma = 0$ 이거나

$\gamma = 1$ 인 경우에는 Algebraic Product 연산자와 Algebraic Sum 연산자로 각각 호환된다.

3. 사례 연구

1) 사용 자료

이 연구에서는 다중 시기 SAR 자료로 Radarsat-1 자료를 이용하여 토지 피복 분류를 목적으로 사례 연구를 수행하였다. 연구지역은 충청남도 당진, 예산을 포함하는 삽교천 주변 예당평야 일대이며(Fig. 4(a)), 토지 피복으로는 논이 주로 위치하고

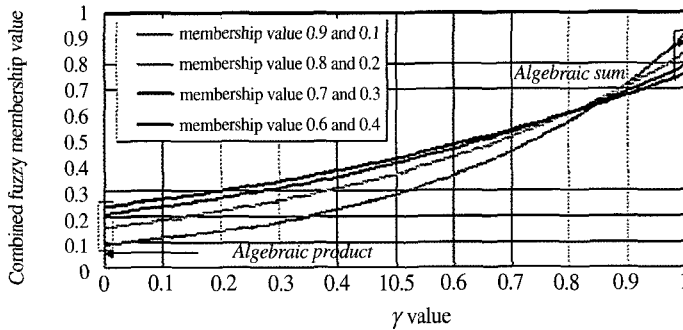


Fig. 3. Behaviors of a fuzzy γ operator with respect to the variations of the γ value.

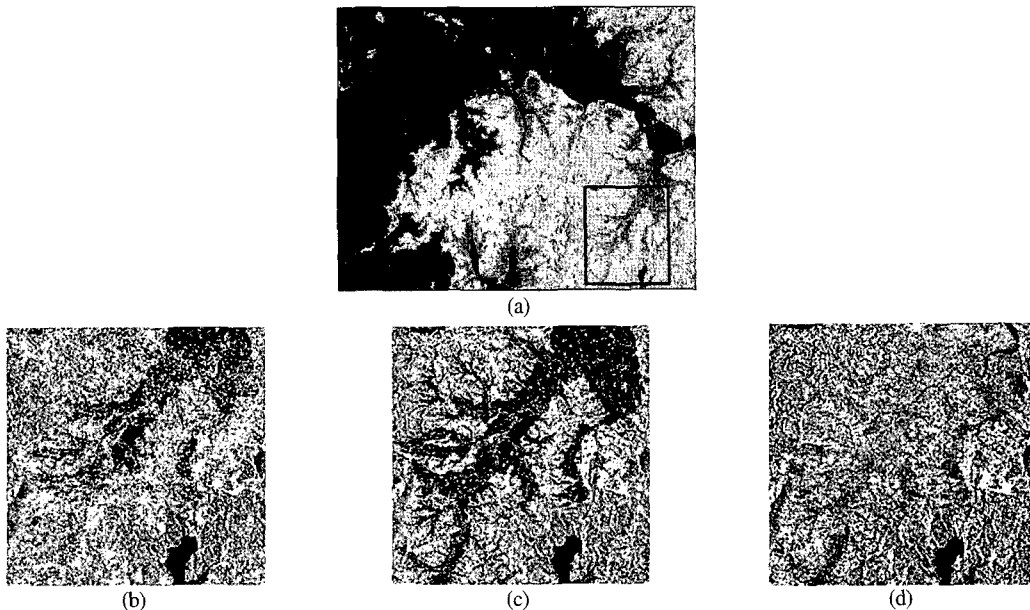


Fig. 4. Location of the study area((a)) and a multi-temporal Radarsat-1 data set used in the study((b) May 6, 2003, (c) May 30, 2003, (d) June 23, 2003).

지형적으로 거의 평탄한 지역에 해당한다. 연구 지역의 토지 피복으로는 수계, 논, 밭, 산림, 도심지 등의 5개를 고려하였다. 감독 분류를 위해 연구 지역의 토지 이용현황도, 과거 광학 위성 자료로부터 훈련집단과 참조집단을 작성하였다.

Radarsat-1 자료는 2003년 5월 6일, 5월 30일, 6월 23일까지 24일 주기로 촬영된 SLC 포맷의 자료를 이용하였는데, 이 자료들은 Ascending orbit로 S5 모드(평균입사각: 39°)로 촬영되었다. 전처

리 과정으로 영상간 정합, time series filtering(De Grandi *et al.*, 1997)을 이용한 스펙클 노이즈 제거, 좌표 등록 등을 수행하였다.

2) 시계열 자료 분석 및 특징 추출

특징 추출 이전에 일련의 전처리를 거친 시계열 자료들의 시각적/통계적 분석을 수행하였다. 다중 시기 자료들을 시각적으로 살펴보면(Fig. 4), 시기적으로 관개, 모내기 등의 시간적 변화를 거

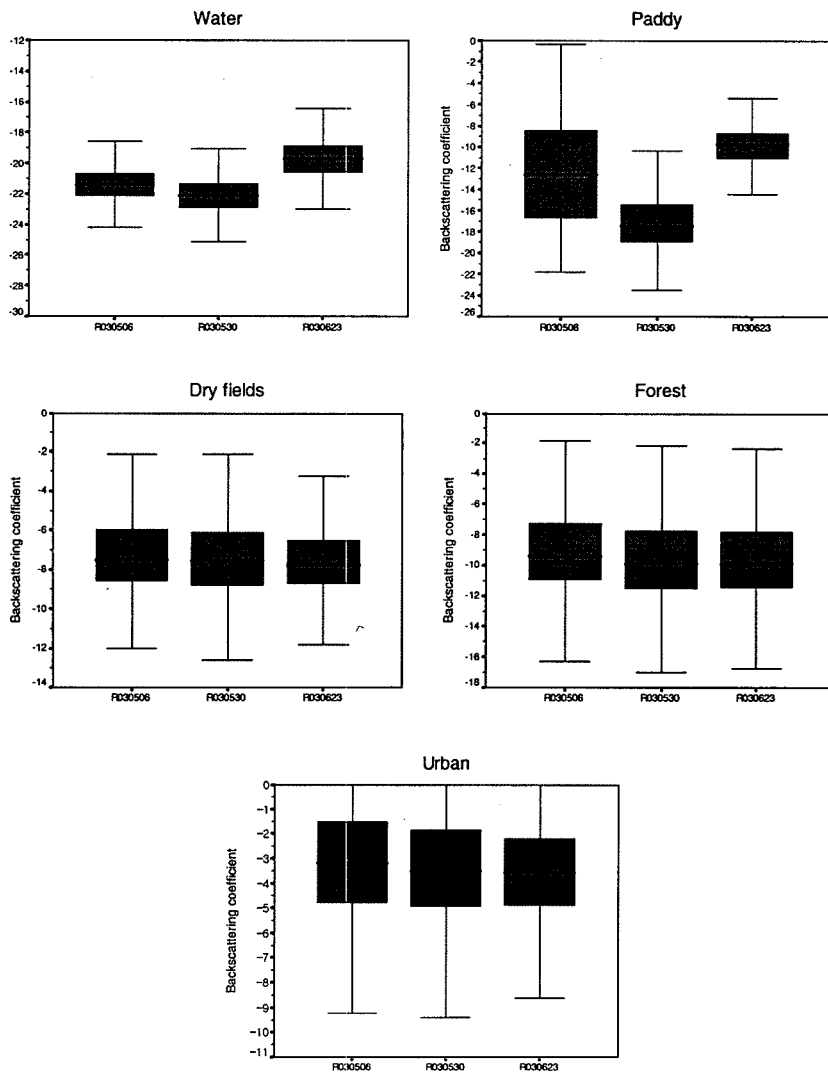


Fig. 5. Temporal variation of backscattering coefficient of each land-cover class. Label on X axis denotes three Radarsat data. For example, R030506 stands for Radarsat-1 data acquired on May 6, 2003).

치는 논 지역의 변화를 확인할 수 있다. 즉 시간이 경과함에 따라 논에 물을 공급해주고, 이후에 벼의 성장에 따라 후방 산란계수가 증가하는 일련의 벼의 성장 과정을 확인할 수 있다. 이러한 양상은 시간적 변이도를 통해 논 특징 추출이 용이하게 한다.

훈련집단으로부터 추출한 5개의 토지 피복에서의 후방 산란계수를 살펴보면 각 토지 피복의 시간적 변화에 따른 특성을 확인할 수 있다. Fig. 5를 살펴보면, 도심지, 밭, 산림지에서는 값의 범위는 다소 변화가 있으나 평균적으로는 세 시기에 걸친 변화가 거의 없는 것으로 나타났으며, 수계의 경우 이 세 개의 피복에 비해 평균값의 시간적 변화가 다소 나타나고 있다. 반면 논에서는 Fig. 4에서 확인한 것처럼 관개, 벼의 성장에 따른 시기적인 SAR 자료의 반응 특성을 잘 반영하고 있다. 즉 5월 6일에 비해 관개 때문에 5월 30일에서는 후방 산란계수의 감소 현상이 나타나고, 6월 23일에는 벼의 성장으로 후방 산란계수의 증가 현상이 나타나고 있다.

Fig. 4의 자료들로부터 2장에서 설명한 특징 추출 이론을 적용하여 평균 후방 산란계수, 시간적 변이도와 긴밀도를 추출하였다. 긴밀도는 기선거리 150m의 5월 6일과 6월 23일 간섭쌍으로부터 추출하였다. 평균 후방 산란계수를 시각적으로 살펴보면(Fig. 6(a)), 높은 값을 나타내는 도심지와 낮은 값을 나타내는 수계의 구분이 가능하다. 논은 경우 5월 30일 자료의 영향으로 밭이나 산림보

다는 낮은 값을 나타내고 있다. 시간적 변이도에서는 Fig. 4와 Fig. 5에서 살펴본 것처럼 논이 시기적으로 관개와 벼의 성장에 따라 높은 시간적 변이도를 나타내고 있다(Fig. 6(b)). 그리고 도심, 밭, 산림에 비해서는 수계에서 상대적으로 높은 시간적 변이도를 나타내고 있으나, 논보다는 낮게 나타나고 있다. 일반적으로 입사각이 23°이며 VV 편광상태인 ERS에서는 수계에서의 시간적인 변이도가 크게 나타나지만, 이 연구에 사용한 Radarsat-1 자료는 상대적으로 큰 입사각(39°), HH 편광상태 그리고 시기에 따른 기상 상태에 따라 적게 나타난 것으로 판단된다. 결론적으로 시간적 변이도로부터 연구지역에서 고려한 5개 토지 피복 항목 중에서 논, 수계와 나머지 피복간의 구별이 가능하게 된다. 긴밀도는 안정적인 고정 산란체로 이루어진 도심지에서 높게 나타나고 있는데(Fig. 6(c)), 이 특징으로부터 도심지와 나머지 피복간의 구별이 가능하게 된다.

3) 특징 융합

앞에서 추출한 세 가지 특징들을 D-S 이론과 퍼지 논리를 이용하여 토지 피복 구분을 수행하였다. 다중 시기 자료에 이용하기 때문에, 토지 피복 구분 과정에서 연구지역에서는 고려하는 시기 동안에 토지 이용의 변이가 없고, 단지 물리적 상태의 변화만 있다는 가정을 하고 분류를 수행하였다.

D-S 이론과 퍼지 논리가 토지 피복 항목간의 애매함과 불확실성을 표현할 수 있는 이론적 배경




Fig. 6. Three features extracted from multi-temporal Radarsat-1 data; (a) average backscattering coefficient, (b) temporal variability, (c) coherence.

을 제공하지만, 실제 적용시에는 여러 가지 고려할 점이 있다. 어떤 자료 융합 방법론을 선택하더라도 설정 가설, 토지 피복 구분 응용의 경우 개별 토지 피복 항목에 대해 개별 자료들을 연관시키는 자료 표현이 분류 결과에 많은 영향을 미치게 된다. D-S 이론의 경우에는 mass function의 설정이, 퍼지 논리의 경우 퍼지 소속함수의 설정이 중요하다. 이 연구에서는 평활화 커널을 이용한 확률밀도함수로부터 mass function과 퍼지 소속함수를 결정하고자 하였다.

D-S 이론에서 mass function의 할당에 대해 공통적으로 통용되는 방법보다는 자료와 응용 목적에 따라 다르게 적용되고 있는 상황이다. 보통의 경우, 개별 자료들이 redundant한 정보를 제공하는 가정 하에 개별 토지 피복 항목에 대한 mass function을 사후확률이나 비모수적 빈도수 분포를 이용하고, frame of discernment θ 에 대한 값을 할당하였다. 그러나 연구 지역의 경우, 앞에서 살펴본 것처럼 개별 특징들이 상호보완적인 정보를 제공하기 때문에 토지 피복 항목간의 결합(union of classes 혹은 compound hypotheses)에 대한 고려가 필요하다. 예를 들어 특정 자료 혹은 특징에 의해 토지 피복 항목 ω_i 와 ω_j 의 구별이 힘들 경우, $m(\omega_i \cup \omega_j)$ 에 0이 아닌 값을 할당할 수 있다. 이 연구에서는 Rottensteiner *et al*(2005)에서 논의한 토지 피복 항목간의 결합의 표현을 위해 $m(\omega_i \cup \omega_j) \neq 0$, $m(\omega_i) = m(\omega_j) = 0$ 의 규칙을 적용하였다. 즉 개별 토지 피복 항목간의 구별이 애매할 경우, 토지 피복

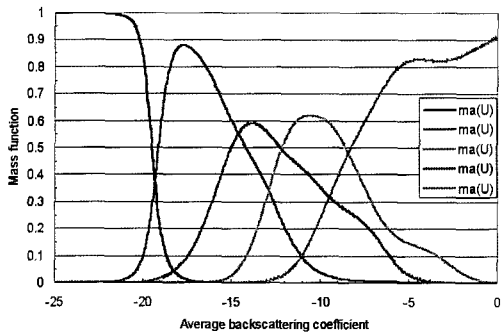
간의 혼재에 mass function 값을 할당하고, 개별적인 항목에는 null 값을 적용하게 된다. Hegerat-Masclé *et al*(1997)에서는 이 연구의 규칙이 무감독 분류에서 특징 공간에서 많은 cluster를 만들기 때문에 $m(\omega_i \cup \omega_j) = m(\omega_i) = m(\omega_j) \neq 0$ 의 규칙을 적용하였다. 그러나 이 연구에서 고려하고 있는 감독 분류에서는 비교적 적은 5개의 토지 피복 항목을 고려하고 있기 때문에 토지 피복 구분이 애매하거나 거의 힘들 경우 0보다 큰 값을 개별적인 토지 피복 항목에 할당할 필요가 없는 것으로 간주하였다. 또한 연구지역의 시간적 변이도나 긴밀도의 특성상, 1개 혹은 2개의 토지 피복과 나머지 토지 피복간의 구분이 애매하기 때문에 특정 토지 피복 항목에 대한 mass function만 구하게 되면, 나머지 토지 피복의 혼재에 대한 mass function은 식 (4)의 정규화 규칙에 의해 1에서 빼주면 간단하게 계산할 수 있는 장점이 있다. 이러한 배경에서 이 연구에서는 시간적 변이도와 긴밀도와 같이 명확한 구분력을 제공하지 않는 특징들에 대해서는 $m(\omega_i \cup \omega_j) \neq 0$, $m(\omega_i) = m(\omega_j) = 0$ 의 규칙을 적용하였다.

각 특징별로 mass function은 평활화 커널 방법을 통해 얻어진 확률밀도함수의 분포를 이용하여 실험적으로 설정하였다. 우선 확률밀도함수의 분포로부터 구분이 가능한 토지 피복 항목을 고려하여 Table 2의 mass function 할당 규칙을 작성하였다. 평균 후방 산란계수에서는 개별 토지 피복들이 구분이 가능하다는 전제하에 확률밀도함수들

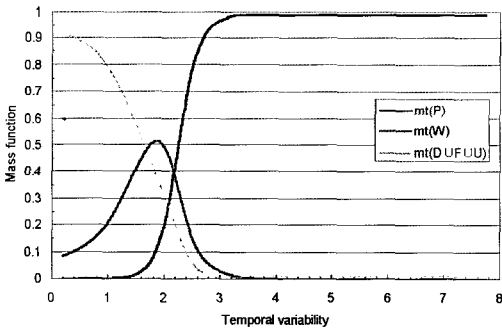
Table 2. Mass functions assigned to each feature. W, P, D, F and U stand for water, paddy, dry fields, forest and urban, respectively.

Class \ Feature	Average backscattering coefficient	Temporal variability	Coherence
W	$m_a(W)$	$m_t(W)$	0
P	$m_a(P)$	$m_t(P)$	0
D	$m_a(D)$	0	0
F	$m_a(F)$	0	0
U	$m_a(U)$	0	$m_c(U)$
DUFUU	-	$m_t(DUFUU)$	-
WUPUDUF	-	-	$m_c(WUPUDUF)$

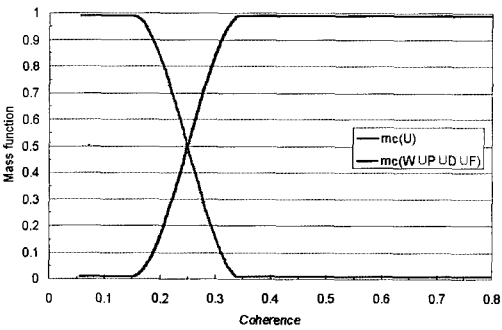
이 식 (4)를 만족하도록 정규화시켜 계산하였다 (Fig. 7(a)). 시간적 변이도에서는 논과 수계의 구분 가능성이 전제하에 논, 수계, 밭U산림U도심의 mass function을 할당하였다(Table 2). 논, 수계의 mass function은 히스토그램에 기반하여 실험적인 모형을 이용하였는데, 하한 임계치값과 상한 임계치값을 설정한 후에 임계치 범위에서 sigmoidal 합



(a)



(b)



(c)

Fig. 7. Mass function distribution assigned for each feature; (a) average backscattering coefficient, (b) temporal variability, (c) coherence. W, P, D, F and U stand for water, paddy, dry fields, forest and urban, respectively.

수를 설정하였다. 수계의 mass function은 수계의 히스토그램을 5개 분류 항목의 히스토그램에 대해 정규화하여 이용하였는데, 이는 베이지안 확률 이론에서 정규화 과정과 유사하다. 그리고 밭U산림U도심의 mass function은 식 (4)의 정규화 규칙에 의해 계산하였다(Fig. 7(b)). 최종적으로 긴밀도에서는 도심이 나머지 피복과 구분이 가능하다는 전제하에 도심, 수계U논U밭U산림에 대해 각각 mass function을 할당하였다(Fig. 7(c)). 우선 구분이 가장 명확한 도심 항목과 나머지 피복의 히스토그램에 기반하여 시간적 변이도에서 논, 수계의 mass function 할당과 유사하게 sigmoidal 함수를 이용하였으며, 수계U논U밭U산림의 mass function은 역시 정규화 규칙에 의해 할당하였다(Fig. 7(c)).

퍼지 논리의 적용에서 퍼지 소속함수는 D-S 이론과 유사하게 평활화 커널 방법에 의해 얻어진 확률밀도함수로부터 Dubois and Prade(1988)의 방법에 따라 결정하였다. 특정 특징의 확률밀도함수가 $P(X)$ 이고, 자료값의 범위가 $[X_{min}, X_{max}]$ 로 주어졌을 때, 특정 토지 피복 항목 ω_k 의 퍼지 소속함수 $\mu_{\omega_k}(X)$ 는 다음 식 (7)에 따라 계산하였다.

$$\mu_{\omega_k}(X) = \sum_{X' \in [X_{min}, X_{max}]} \text{Min}[P(X), P(X')] \quad (7)$$

Fig. 8은 식 (7)에 따라 얻어진 각 특징별 퍼지 소속함수를 나타내고 있다. Fig. 7과 비교하였을 때, 개별 항목간의 분포는 유사하게 나타나는데 이는 두 방법 모두 확률밀도함수에 기반하여 계산이 되었기 때문이다. 평균 후방 산란계수의 경우, 수계와 도심지는 다른 피복 항목과 구분이 명확하게 되고 있으며, 논, 수계의 경우 관계에 따른 후방 산란계수의 감소는 식생으로 덮인 산림과 밭과 일정 부분 가능하게 하고 있다. 그러나 밭과 산림의 경우 분포가 서로 겹쳐있는 부분이 많기 때문에 이 두 항목의 구분이 애매할 것을 예상할 수 있다. 시간적 변이도의 경우, Fig. 7의 mass function 분포와 마찬가지로 논과 다른 항목과의 구분이 가장 명확하며, 수계도 약간 다른 분포를 가지고 있어서 다른 항목과 구분이 가능하게 나타나고 있다. 그러나 도심, 산림, 밭 항목간 분포는 거의 유사하게

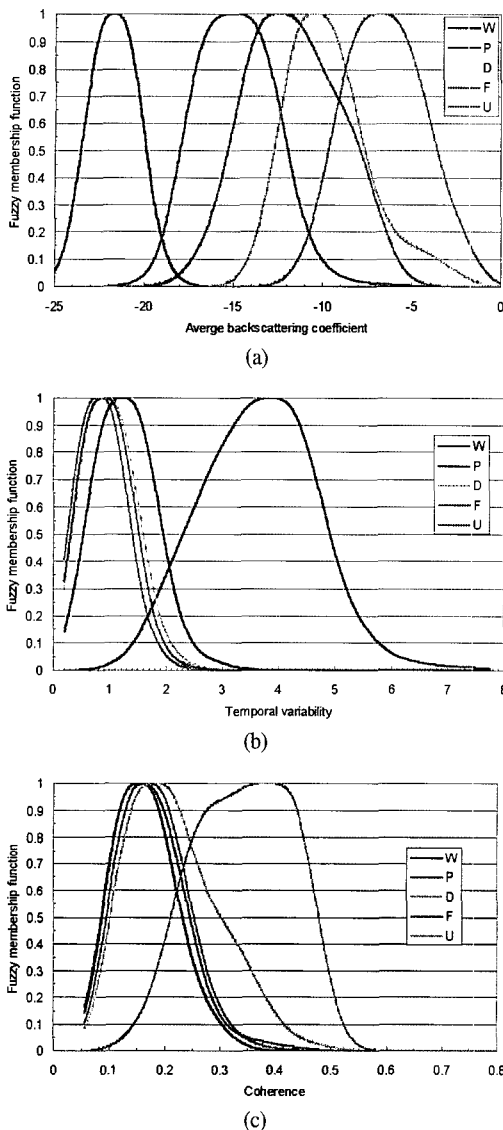


Fig. 8. Fuzzy membership function distribution assigned for each feature; (a) average backscattering coefficient, (b) temporal variability, (c) coherence. W, P, D, F and U stand for water, paddy, dry fields, forest and urban, respectively.

나타나고 있다. 퍼지 이론에서는 이렇게 구분이 애매한 항목들에 대해서는 다중 소속도를 정의하게 되지만, D-S 이론에서는 도심, 산림과 밭 항목의 구분이 애매하다고 간주하고 서로 혼재된 항목으로 설정하였다. 긴밀도에서는 도심지와 다른 항목간의 구분이 가장 명확하게 나타나고 있으며,

시간적 변이도와 마찬가지로 퍼지 논리에서는 각각의 항목에 대해 다중 소속도를 할당하고, D-S 이론에서는 도심을 제외한 항목에 대해서는 혼재된 항목으로 간주하게 하였다. 이러한 mass function과 퍼지 소속함수의 분포에서 알 수 있듯이 개별 특징들은 서로 상호보완적인 정보를 제공하고 있다.

Fig. 7과 Fig. 8의 mass function과 퍼지 소속함수의 결합에는 orthogonal sum과 Table 1의 결합 연산자를 각각 적용하여 최종적으로 결합하였다. 특히 퍼지 논리의 적용시, 퍼지 소속함수의 할당과 더불어 퍼지 결합 연산자의 선택이 중요한데, 이 연구에서는 연구지역의 자료에 대해 가장 좋은 분류 정확도를 나타내는 연산자를 살펴보기 위해 Table 1의 모든 연산자를 적용하였다. 각 이론별로 결합 연산자를 통해 얻어진 결과로부터 각 화소당 토지 피복을 할당하기 위한 결정 규칙으로 D-S 이론에서는 최대 belief function 값을, 퍼지 논리에서는 최대 퍼지 소속함수값을 나타내는 토지 피복을 할당하게 하였다.

4) 분류 결과

Fig. 9는 각 이론을 적용하여 얻어진 최종 분류 결과를 나타내고 있다. 시각적인 분석으로 연구지역의 중앙에 넓게 분포하고 있는 논과 수계, 도심은 Fig. 4의 원 자료의 시각적 판독 특성을 반영하고 있는 것으로 나타났으며, 산림과 밭의 경우 불규칙하게 흩어져 있는 양상이다. D-S 이론의 경우, 식 (6)의 여러 자료들의 mass function의 결합에서 분모에 포함되어 있는 K는 자료간 불일치도를 나타내는데 이를 분류 결과 해석의 보조 자료로 Fig. 9(b)에 함께 제시하였다. 이를 살펴보면, 수계와 도심 항목에서 불일치도가 가장 낮게 나타났으며, 논 항목에서도 상대적으로 낮은 불일치도 값을 나타내었다. 그 외의 산림과 밭의 경우에는 중간 이상의 불일치도 값을 나타내고 있는데, 이는 이 두 항목간의 혼재 혹은 분류의 어려움을 간접적으로 지시한다고 판단된다. 퍼지 논리의 경우, Fig. 9(c)의 Min 연산자의 적용 결과는 Fig. 9(a)




Fig. 9. Classification results; (a) D-S theory, (b) conflict image of (a), (c) fuzzy logic with the Min operator, (d) fuzzy logic with the Algebraic Sum operator.

의 D-S 이론의 적용 결과와 유사한 양상을 나타내고 있으나, Algebraic Sum 연산자의 적용 결과는 상대적으로 잡음에 의한 영향이 두드러지게 나타나고 있다.

Fig. 9의 분류 결과의 정량적 비교를 위해 훈련 집단과 독립적으로 작성된 참조집단으로부터 전체 정확도, 각 토지 피복 항목별 사용자 정확도, 평균 정확도와 카파 계수 등의 통계치를 계산하였다(Table 3). D-S 이론과 퍼지 Max와 Algebraic Sum 연산자를 제외한 다른 퍼지 연산자를 이용한 결과의 분류 정확도가 전반적으로 유사하게 나타났다. 여러 퍼지 소속함수의 결합에서 최대값을 취하는 퍼지 Max 연산자나 최대값보다 큰 값을 연산값으로 넘겨주는 Algebraic Sum 연산자에서는 특정 자료의 최대값 효과가 두드러지게 나타나기 때문에 Fig. 9(c)에서 확인한 것처럼 잡음에 의

한 영향으로 분류 정확도가 떨어지는 것으로 판단된다. 퍼지 γ 연산자에서는 γ 의 변화에 따라 분류 정확도가 큰 차이가 없으나, 값이 증가하여 Algebraic Sum($\gamma=1$)에 접근할수록 분류 정확도가 다소 떨어지는 것을 확인할 수 있다.

개별 토지 피복 항목별 사용자 정확도를 살펴보면, 수계와 논 항목의 분류 정확도는 아주 높은 것으로 판단된다. 이러한 결과는 이 연구에서 추출한 특징들(특히 시간적 변이도)이 이 두 항목과 다른 항목간의 구분에 적합한 정보를 제공하였기 때문인 것으로 판단된다. 그리고 도심지도 80% 후반의 분류 정확도를 나타내어 상대적으로 구분이 잘 되는 것으로 판단된다. 그러나 밭과 산림의 경우 50% 초중반이나 70% 중반대의 상대적으로 낮은 분류 정확도를 나타내고 있다. 이러한 결과는 이미 특징 추출의 과정에서 유추할 수 있었던

Table 3. Accuracy statistics of classification results.

Case	Accuracy	Overall accuracy	Kappa	Average accuracy	User's accuracy				
					Water	Paddy	Dry	Forest	Urban
D-S		83.53	0.732	82.74	99.51	99.10	52.42	72.84	89.84
Min		84.42	0.744	82.82	99.51	98.59	53.08	75.43	87.47
Max		41.26	0.214	36.14	3.02	91.51	23.25	26.67	36.25
Algebraic product		84.48	0.745	82.96	99.51	98.89	53.37	75.47	87.54
$\gamma = 0.1$		84.47	0.745	82.95	99.51	98.89	53.33	75.49	87.54
$\gamma = 0.2$		84.47	0.745	82.94	99.51	98.90	53.33	75.49	87.48
$\gamma = 0.3$		84.44	0.745	82.92	99.51	98.89	53.29	75.42	87.48
$\gamma = 0.4$		84.43	0.745	82.91	99.51	98.89	53.25	75.42	87.48
$\gamma = 0.5$		84.43	0.745	82.89	99.51	98.90	53.27	75.37	87.42
$\gamma = 0.6$		84.43	0.745	82.88	99.51	98.90	53.32	75.31	87.35
$\gamma = 0.7$		84.41	0.744	82.84	99.51	98.90	53.33	75.23	87.22
$\gamma = 0.8$		84.37	0.744	82.79	99.51	98.90	53.36	74.99	87.21
$\gamma = 0.9$		84.22	0.742	82.61	99.51	98.90	53.19	74.64	86.80
$\gamma = 0.95$		83.98	0.738	82.29	99.51	98.92	53.02	73.98	86.04
Algebraic sum		64.54	0.468	51.25	10.26	96.64	40.28	42.25	66.83

것으로, 시간적 변이도로부터 구별이 가능한 논과 수계, 긴밀도로부터 구별이 가능한 도십지와는 달리 밭과 산림은 이 두 특징에서 특별히 구별이 두드러지지 않았다. 결과적으로는 이 두 피복 항목 간의 구별은 평균 후방 산란계수의 특성에 의존할 수밖에 없는데, 평균 후방 산란계수에서도 혼재된 영역이 존재하기 때문에 분류 정확도가 떨어지는 것으로 판단된다.

특정 특징의 결합에 따른 토지 피복 구분 능력의 효과를 살펴보기 위해 세 개의 특징들로부터

두 개의 특징만을 결합하여 이로부터 분류 정확도를 계산하였다(Table 4). D-S 이론의 적용에서 Table 2의 mass function의 정의를 이용하여 시간적 변이도와 긴밀도를 결합할 경우, 밭과 산림의 개별 mass function이 계산되지 않기 때문에 제외하였다. 퍼지 이론의 경우 퍼지 Max와 Algebraic Sum 연산자를 제외한 다른 퍼지 연산자를 이용한 결과의 분류 정확도가 전반적으로 유사하게 나타나서 퍼지 Min 연산자만을 적용하였다. 이러한 결과를 살펴보면, 이 연구에서 고려한 각 특징들이

Table 4. Accuracy statistics obtained with various feature combinations. "avg.," "temp." and "coh." represent the average backscattering coefficient, temporal variability and coherence, respectively.

Case	Accuracy	Overall accuracy	Kappa	Average accuracy	User's accuracy				
					Water	Paddy	Dry	Forest	Urban
D-S	all	83.53	0.732	82.74	99.51	99.10	52.42	72.84	89.84
	avg. + temp.	82.71	0.720	79.59	99.51	98.77	51.51	72.43	75.71
	avg. + coh.	69.31	0.513	74.36	99.48	90.11	51.48	39.84	90.89
Fuzzy	all	84.42	0.744	82.82	99.51	98.59	53.08	75.43	87.47
	avg. + temp.	83.15	0.723	79.79	99.51	98.61	51.29	72.83	76.71
Min	avg. + coh.	66.81	0.496	72.66	98.54	91.46	51.75	37.98	83.59
	temp. + coh.	69.72	0.527	53.11	3.56	98.73	40.73	64.58	57.93

상호 보완적인 정보를 제공한다 하더라도 특징의 결합에 따라 다른 분류 결과를 나타내어 분류 정확도에 반영됨을 확인할 수 있다.

두 이론을 적용한 결과에서 모두평균 후방 산란계수와 시간적 변이도를 고려하였을 때에는 도심지의 사용자 정확도가 다소 떨어지지만 세 특징을 모두 결합하였을 때와 유사하게 나타났다. 이러한 결과는 긴밀도에서 제공하는 정보가 도심지와 다른 피복간의 구별 능력만을 제공하고, 나머지 피복간의 구별 능력이 그다지 뛰어나지 않아서 다른 특징에서 제공하는 정보와 유사한 양의 정보를 제공하기 때문에 특징 결합에서 빠지더라도 큰 변화가 야기시키지 않은 것으로 판단된다. 시간적 변이도를 제외하고 평균 후방 산란계수와 긴밀도를 이용하였을 경우, 논 항목에서 비록 높은 사용자 정확도를 나타내지만(약 90%) 모든 특징을 이용하였을 때에 비해서 8~9% 정도의 분류 정확도가 떨어지게 나타났으며, 특히 산림지에서의 정확도(30% 후반)가 많이 떨어지게 나타나고 있다. 산림지에서의 낮은 분류 정확도는 산림지로 분류된 많은 지역이 논으로 오분류되어 나타난 것으로, 비록 논에서의 사용자 정확도가 높게 나타났더라도 시간적 변이도가 제외될 경우 다른 항목의 논으로의 오분류를 야기할 수 있다는 것을 의미한다. 그러나 도심지의 분류 정확도는 높은 것으로 나타나서 긴밀도의 도심지 구별 능력을 잘 나타내고 있다. 반면 시간적 변이도와 긴밀도만을 이용할 경우에는 수계 영역이 다른 항목으로의 오분류가 되고, 밭과 산림에서의 사용자 정확도도 가장 낮고 도심지에서도 분류 정확도가 떨어지는 것을 확인할 수 있었다.

이러한 결과를 종합해보면, 연구지역에서는 평균 후방 산란계수와 시간적 변이도가 가장 큰 영향을 미치는 것으로 나타났으며, 긴밀도는 도심지 구분에는 좋은 정보를 제공하지만 모든 자료와 함께 결합되었을 때 그 효과가 나타나는 것으로 판단된다.

5) Landsat 자료와의 융합 결과

앞에서 살펴본 것처럼 수계, 논, 도심지에서는

높은 분류 정확도를 나타내었지만, 밭과 산림은 항목간 혼재로 인해 낮은 분류 정확도를 나타내었다. 이는 전술한 바와 같이 이 두 항목의 구별은

다른 특징보다는 평균 후방 산란계수의 특성에 많이 의존했기 때문이다. 이 두 항목의 분류 정확도 향상을 위한 방법으로는 이 두 항목의 구별이 가능하게 하는 새로운 특징을 추출하거나 광학 위성 자료와의 융합을 고려할 수 있다. 이 연구에서는 2003년 4월 30일에 촬영된 Landsat TM 광학 위성 자료와의 융합을 수행하였다.

이중 센서 자료 융합의 효과를 알아보기 위해, Landsat 자료만을 이용한 분류와 모든 자료를 함께 이용한 분류 결과를 비교하고자 하였다. 우선 Landsat 자료의 분류에는 전통적인 최대 우도 분류 기법을 이용하였으며, D-S 이론과 퍼지 논리를 이용한 분류에는 다른 접근을 수행하였다. D-S 이론을 이용한 융합에 Landsat 자료는 다변량 정규 분포의 가정 하에 조건부 확률을 mass function으로 이용하였다. 그리고 퍼지 논리의 적용시에는 평활화 커널을 적용하여 확률밀도분포를 얻은 후에 식 (7)을 이용하여 Landsat 자료의 퍼지 소속함수를 계산하였다. Landsat 자료의 퍼지 소속함수와 다중 시기 Radarsat-1 자료로부터 추출한 세 가지 퍼지 소속함수의 결합에는 퍼지 Min 연산자를 실험적으로 사용하였다.

Fig. 10과 Table 5는 분류 결과와 분류 정확도를 각각 나타내고 있다. Landsat TM 자료만을 이용하였을 경우, 이 연구에서 고려하고 있는 다중 시기 Radarsat-1 기반 분류 결과보다 높은 분류 정확도를 나타내고 있고 산림지에서의 사용자 정확도(약 96%)는 높게 나타나고 있다. 그러나 밭 항목은 55% 정도의 낮은 사용자 정확도를 나타내고 있는데, 이는 오차 행렬에서 논과의 혼재 때문에 나타난 것으로, 4월말 촬영 시기에 따른 결과인 것으로 판단된다. 그러나 다중 시기 Radarsat-1 기반 특징들과 융합을 수행하였을 경우, 전체 정확도는 5%, 카파 계수 0.07, 평균 정확도 8% 정도의 향상이 나타났다. 이러한 결과는 자료 융합의 효율성을 나타내는 것으로, 서로 다른 이중 센서의

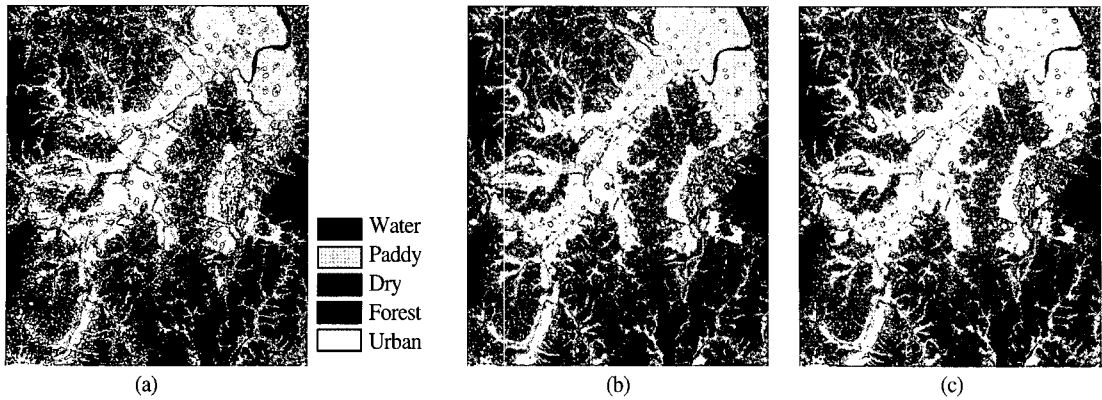


Fig. 10. (a) Maximum likelihood classification of Landsat TM data, (b) D-S fusion of Landsat TM data and three features extracted from multi-temporal Radarsat-1 data, (c) fuzzy Min fusion of Landsat TM data and three features extracted from multi-temporal Radarsat-1 data.

Table 5. Accuracy statistics obtained with Landsat TM data and fusion of Landsat TM data and three features considered in this study.

Case \ Accuracy	Overall accuracy	Kappa	Average accuracy	User's accuracy				
				Water	Paddy	Dry	Forest	Urban
MLC with Landsat only	85.72	0.77	79.48	85.71	96.38	55.71	95.98	63.62
Fusion with D-S	90.82	0.85	88.90	99.51	97.92	65.16	94.17	87.29
Fusion with fuzzy Min	89.99	0.83	87.46	99.40	97.34	63.78	95.21	81.52

상호보완적인 정보 때문에 보다 나은 토지 피복 구분 능력을 나타낸 것으로 판단된다. 사용자 정확도 측면에서, 다른 토지 피복 항목과 비교하였을 때 밭 항목의 분류 정확도는 상대적으로 낮게 나타나고 있다. 그러나 자료 융합의 결과 밭 항목에서 10% 정도의 사용자 정확도의 향상을 가져왔다. 발작물이 광학 센서 자체에서는 시기적으로는 항목으로의 오분류가 많이 일어났으나, 이후 시기의 Radarsat-1 자료로부터 추출된 특징으로 인해 오분류가 감소한 것으로 판단된다.

4. 결론

이 연구에서는 다중 시기 SAR 자료를 이용한 토지 피복 구분을 목적으로 특징 추출과 정보 융합에 대해서 논의하였다. 시계열 SAR 자료의 획득 시기에 따른 산란 특성을 고려하여 평균 후방

산란계수, 시간적 변이도와 긴밀도의 세 가지 특징을 추출하였다. 이러한 특징들을 효율적으로 융합하여 분류를 수행하기 위하여 D-S 이론과 퍼지 논리를 각각 적용하였다. 분류 기법 개발 및 보완의 관점에서, 기존 D-S 이론의 적용시 문제가 되었던 mass function의 할당과 관련하여 상호보완적인 특징의 특성을 고려한 일종의 heuristic 접근법을 제시하였고, 퍼지 논리의 자료 융합에의 적용시 퍼지 결합 연산자의 특성을 분류 정확도의 관점에서 고찰하였다.

세 시기 Radarsat-1 자료를 이용한 사례 연구 수행 결과, 이 연구에서 고려한 특징들은 연구 지역에서 고려하고 있는 토지 피복의 구분에서 상호보완적인 정보를 제공하는 것으로 나타났다. 특히 시간적 변이도는 평균 후방 산란계수에서의 논의 구별을 강조하는 효과를 나타내었는데, 이는 토지 피복의 물리적 변화가 있을 경우 이 특징이 효율적으로 분류 과정에 기여할 수 있음을 나타낸다.

분류 결과, D-S 이론과 퍼지 Max와 Algebraic Sum 연산자를 제외한 다른 퍼지 연산자는 유사한 분류 정확도를 나타내었는데, 퍼지 연산자의 선택 시 이 연산자들은 노이즈를 증폭시키는 효과를 낼 수 있으므로 선택시 주의를 해야 할 것으로 판단된다. 사용자 정확도 측면에서 밭과 산림의 혼재가 두드러졌는데, Landsat TM 자료와의 융합 결과 산림에서의 분류 정확도가 많이 향상되었으며, 밭 항목 역시 향상된 결과를 나타내었다. 또한 자료 융합의 측면에서 광학과 SAR 자료의 결합 역시 광학 위성자료만을 이용하였을 경우에 비해 향상된 분류 정확도를 나타냄으로써 자료 융합의 적용 가능성을 확인할 수 있었다. 그러나 SAR 자료만을 이용한 분류에서 밭과 산림 항목의 낮은 분류 정확도는 앞으로 이 두 항목의 분류 정확도 향상을 위한 방법으로는 이 두 항목의 구별이 가능하게 하는 새로운 특징을 추출하거나 이들의 구별이 가능한 시기나 빔모드의 SAR 자료 선택이 중요할 것으로 판단된다.

일반적으로 SAR 자료를 이용한 분류에서는 산란 특성뿐만 아니라 공간/시간적 문맥 정보가 분류 정확도를 향상시킬 수 있다. 이 연구에서는 고려하는 시기에 토지 용도에 있어서 커다란 변화가 없다는 가정 하에 특징 추출과 분류를 수행하였으나, 만약 이 가정이 위배될 경우 잘못된 분류 결과와 해석을 유발하게 된다. 일반적인 원격탐사 자료의 분류에서는 시간적 문맥 정보가 중요하게 작용하는데, 그동안 공간적 문맥 정보의 반영에 대한 연구에 비해 시간적 문맥 정보는 상대적으로 많이 고려되지 못하여 왔다. 앞으로 이러한 정보들을 모두 분류 과정에 포함시키는 Markov Random Fields와 같은 분류 기법 등을 적용할 예정이다.

참고문헌

- Bruzzone, L., D. F. Prieto, and S. B. Serpico, 1999. A neural-statistical approach to multitemporal and multisource remote-sensing image classification, *IEEE Transactions on Geoscience and Remote Sensing*, 37(3): 1350-1359.
- Bruzzone, L., M. Marconcini, U. Wegmuller, and A. Wiesmann, 2004. An advanced system for the automatic classification of multitemporal SAR images, *IEEE Transactions on Geoscience and Remote Sensing*, 42(6): 1321-1334.
- Carr, J. R. and F. P. de Miranda, 1998. The semivariogram in comparison to the co-occurrence matrix for classification of image texture, *IEEE Transactions on Geoscience and Remote Sensing*, 36(6): 1945-1952.
- De Grandi, G. F., M. Leysen, J.-S. Lee, and D. Schuler, 1997. Radar reflective estimation using multiple SAR scenes of the same target: techniques and applications, *Proceedings of IGARSS 1997*, 1047-1050.
- Dempster, A. P., 1967. Upper and lower probabilities induced by a multivalued mapping, *Annals of Mathematical Statistics*, 38(2): 325-339.
- Dubois, D. and H. Prade, 1988. *Possibility theory: an approach to the computerized processing of uncertainty*, Plenum.
- Hégarat-Masclé, S. L., I. Bloch, and D. Vidal-Madjar, 1997. Application of Dempster-Shafer evidence to unsupervised classification in multisource remote sensing, *IEEE Transactions on Geoscience and Remote Sensing*, 35(4): 1018-1031.
- Lee, H. and J. G. Liu, 2001. Analysis of topographic decorrelation in SAR interferometry using ratio coherence imagery, *IEEE Transactions on Geoscience and Remote Sensing*, 39(2): 223-232.
- 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-
- Bruzzone, L., D. F. Prieto, and S. B. Serpico, 1999. A neural-statistical approach to multitemporal

- 2351.
- Luckman, A., J. Baker, and U. Wegmuller, 2000. Repeat-pass interferometric coherence measurements of disturbed tropical forest from JERS and ERS satellites, *Remote Sensing of Environment*, 73(3): 350-360.
- Mertikas, P. and M. E. Zerakis, 2001. Exemplifying the theory of evidence in remote sensing image classification, *International Journal of Remote Sensing*, 22(6): 1081-1095.
- 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.
- Quegan, S., T. L. Toan, J. J. Yu, F. Ribbes, and N. Floury, 2000. Multitemporal ERS SAR analysis applied to forest mapping, *IEEE Transactions on Geoscience and Remote Sensing*, 38(2): 741-753.
- Rottensteiner, F., J. Trinder, S. Clode, and K. Kubik, 2005. Using the Dempster-Shafer method for the fusion of LIDAR data and multi-spectral images for building detection, *Information Fusion*, 6(4): 283-300.
- Shafer, G., 1976. *A mathematical theory of evidence*, Princeton University Press.
- Strozzi, T., P. B. G. Dammert, U. Wegmuller, J. M. Martinez, A. Beaudoin, J. Askne, and M. Hallikainen, 2000. Landuse mapping with ERS SAR interferometry, *IEEE Transactions on Geoscience and Remote Sensing*, 38(2): 766-775.
- Zadeh, L. A., 1965. Fuzzy sets, *IEEE Information and Control*, 8(3): 338-353.