

하이퍼스펙트럴 데이터 분류에서의 평탄도 LDA 규칙화 기법의 실험적 분석

An Experimental Study on Smoothness Regularized LDA in Hyperspectral Data Classification

박래정

Lae-Jeong Park

강릉원주대학교 전자공학과

요 약

고차원 특성과 높은 상관성은 하이퍼스펙트럴 데이터의 주요 특징이다. LDA와 그 변형 선형 투사 방법들이 고차원 스펙트럴 정보로부터 저차원의 특징을 추출하는데 사용되었다. LDA는 학습 데이터가 적은 경우 흔히 발생하는 과대적합으로 인해 일반화 성능이 낮아지는 문제가 발생하는데, 이를 완화하기 위하여 LDA 규칙화(regularization) 방법들이 제시되었다. 그 중, 평탄도(smoothness) 제약에 기반한 LDA 규칙화 기법은 높은 상관성을 갖는 하이퍼스펙트럴 데이터의 특성에 적합한 특징 추출 기법이다. 본 논문에서는 하이퍼스펙트럴 데이터 분류에서 평탄도 제약을 갖는 LDA 규칙화 방법을 소개하고 학습 데이터 조건에 따른 성능을 실험적으로 분석한다. 또한, 분류 성능의 향상을 위한 스펙트럴 정보와 공간적 정보의 상관성을 함께 활용하는 이중 평탄도 LDA 규칙화 기법을 제시한다.

Abstract

High dimensionality and highly correlated features are the major characteristics of hyperspectral data. Linear projections such as LDA and its variants have been used in extracting low-dimensional features from high-dimensional spectral data. Regularization of LDA has been introduced to alleviate the overfitting that often occurs in a small-sized training data set and leads to poor generalization performance. Among them, a smoothness regularized LDA seems to be effective in the feature extraction for hyperspectral data due to its capability of utilizing the high correlatedness. This paper studies the performance of the regularized LDA in hyperspectral data classification experimentally with varying conditions of the training data. In addition, a new dual smoothness regularized LDA is proposed and evaluated that makes use of both the spectral-domain and spatial-domain correlations between neighboring pixels.

Key Words: LDA, hyperspectral data, regularization, smoothness

1. 서 론

고성능 스펙트럴 분해능(spectral resolution)을 갖는 센서의 등장으로 400 nm~2,500 nm 파장 대역의 수백 개의 스펙트럴 밴드의 정보를 갖는 하이퍼스펙트럴(hyperspectral) 영상 획득이 가능해졌다. 하이퍼스펙트럴 영상 장치는 현미경적인 분석에서부터 항공 영상 원격 탐사, 식품 오염 검사 등 다양한 분야에서 활용되고 있다[1,2]. 그림 1에서 볼 수 있듯이, 하이퍼스펙트럴 영상은 일반적인 2차원 영상 정보에 추가적으로 픽셀마다 연속적인 스펙트럴 정보를 갖는 3차원 데이터이다. 물질마다 스펙트럴 시그니처(signature)를 갖기 때문에 하이퍼스펙트럴 영상은 가시광선 대역의 영상보다 물질을 식별하는데 유용한 정보를 제공한다.

하이퍼스펙트럴 영상 분류는 각 픽셀별로 스펙트럴 정보로부터 물질을 분류하는 것으로서, 스펙트럴 밴드가 보통

수백 개 정도이기 때문에 고차원의 저주(the curse of dimensionality) 문제가 발생한다. 이러한 고차원 문제를 해결하기 위하여 많은 스펙트럴 밴드에서 효과적인 밴드만을 찾아내는 방법[3]과 주성분 분석(PCA)과 선형 판별분석(LDA) 등의 차원 축소 방법 등이 사용되었다. 후자의 방법 중에서 LDA는 분류 성능에 효과적이고 추출된 특징의 중요도 해석이 용이하다는 장점이 있다.

하이퍼스펙트럴 영상의 특징 추출에 LDA를 성공적으로 적용하기 위해서는 Houghes 현상[4]이라 불리는 소량 샘플 크기(small sample size, SSS) 문제[5]를 극복해야 한다. 하이퍼스펙트럴 영상을 사용하는 항공 원격 탐사나 식품 오염 검사 등에서 가용 데이터의 개수가 충분하지 못한 경우가 적지 않게 발생하는데, 이 경우에는 공간 차원(스펙트럴 밴드 개수)에 비해 데이터의 개수가 상대적으로 매우 적기 때문에 LDA의 분별 벡터(discrimination vector)가 학습 데이터에 과대적합(overfitted)되어 일반화 성능이 낮아지게 된다. LDA의 과대적합 문제 완화를 위해 LDA의 규칙화(regularization) 방법(R-LDA) 등이 다수 제시되었다[6,7,8]. 대부분의 방법은 LDA의 집단내 분산

접수일자 : 2010년 4월 19일

완료일자 : 2010년 8월 1일

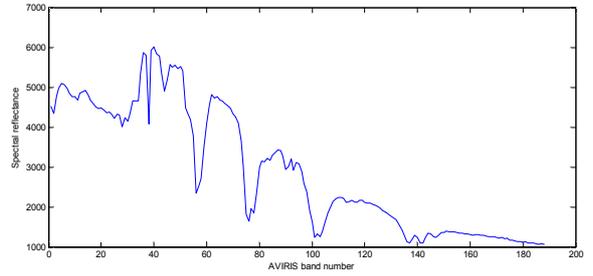
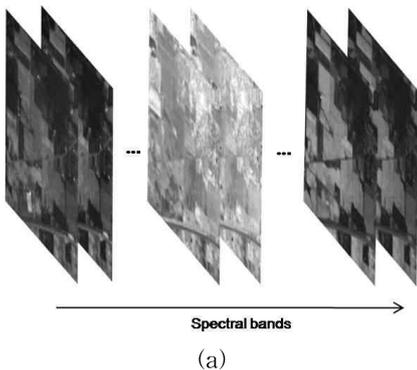
(within-class-scatter) 행렬을 규칙화함으로써 과대적합을 완화하는 방법이다. 다른 접근 방법으로서, 데이터에 내재된 높은 상관도(correlation)를 이용하여 특징을 추출하는 평탄도(smoothness) 규칙화 LDA(S-LDA)가 있다[9,10]. 일반적으로 하이퍼스펙트럴 데이터의 인접 스펙트럴 밴드 간에는 상관도가 매우 높으므로, S-LDA는 다른 LDA 규칙화 방법에 비해 하이퍼스펙트럴 데이터의 저차원 특징 추출 방법으로서 효과적이고 적합할 것으로 추정된다. 하지만, 하이퍼스펙트럴 데이터 분류에서 S-LDA는 거의 다루어지지 않았으며, Yu 등[11]이 하이퍼스펙트럴 분류에 처음으로 적용하였으나 학습 데이터에 따른 성능 분석 등 다양한 조건에서의 실험 및 성능 분석이 제시되지 않았다.

본 논문에서는 하이퍼스펙트럴 데이터 분류에서 특징 추출을 위한 방법으로서 S-LDA를 소개하고 학습 데이터의 조건에 따른 성능을 실험적으로 분석 고찰한다. 또한, 분류 성능을 향상하기 위한 스펙트럴 정보와 공간적 정보의 상관성을 함께 활용하는 이중(dual) S-LDA 방법을 제안하고, AVIRIS 92AV3C 하이퍼스펙트럴 영상 데이터를 사용한 실험을 통하여 성능을 분석한다.

본 논문의 구성은 다음과 같다. 2장에서 하이퍼스펙트럴 영상에 대해 소개하고, 3장에서는 LDA와 R-LDA를 간략히 설명한다. 4장에서는 하이퍼스펙트럴 데이터 분류를 위한 S-LDA를 소개하고 이중 S-LDA를 제안한다. 5장에서 항공 촬영 하이퍼스펙트럴 영상 데이터를 사용하여 S-LDA와 이중 S-LDA의 성능을 분석하고, 6장에서 결론을 맺는다.

2. 하이퍼스펙트럴 영상

2장에서는 독자의 이해를 돕기 위해 하이퍼스펙트럴 영상에 대해 간단히 소개한다. 하이퍼스펙트럴 영상은 2차원 영상 정보에 추가적으로 각 픽셀마다 연속적인 복수개의 파장 대역의 스펙트럴 정보를 갖고 있는 3차원 영상 정보 $I(m, n, \lambda_i)$ 로 표시된다. 여기서 (m, n) 는 픽셀 좌표이고, λ_i 는 특정 파장 대역을 나타낸다. 즉, $I(m, n, \lambda_i)$ 값은 (m, n) 위치에서의 파장 λ_i 에서의 반사율(reflectance)을 나타낸다. 그림 1은 본 논문에서 사용하는, 188개 스펙트럴 밴드 정보를 갖는 하이퍼스펙트럴 데이터 AVIRIS(Airborne Visible InfraRed Imaging Spectrometer) 92AV3C이다. 그림 1 (b)에서 볼 수 있듯이 한 픽셀의 반사율(reflectance)이 스펙트럴 밴드마다 서로 다른 값을 갖는 곡선으로 나타난다. 원리적으로, 물질마다 특정 대역이 아닌 그림 1 (b)에서처럼 여러 파장 대역에서의 반사율 특성이 다르므로 이를 사용하여 각 픽셀에 대응하는 물질을 식별하고 분류할 수 있다.



(b)

그림 1. 하이퍼스펙트럴 영상 정보. (a) 3차원 형태의 표현. (b) 특정 픽셀에서의 스펙트럴 정보.

Fig. 1. A hyperspectral data. (a) 3-D representation. (b) Spectral reflectance curve for a pixel.

3. LDA 기법

이 장에서는 LDA와 규칙화된(regularized) LDA(R-LDA)에 대해서 간단히 소개한다.

3.1 LDA

LDA는 패턴 분류 문제에서 널리 사용되는 차원 감소를 위한 선형 투사(projection) 기법이다[5]. LDA는 수식 (1)의 피셔 (Fisher) 기준[12]을 최적화함으로써 데이터의 집단간 분산 (between-class-scatter)을 최대로 하면서 집단내 분산(within-class-scatter)을 최소화하는 분별 벡터 ψ 를 찾는 기법이다.

$$\max_{\psi} \frac{|\psi^T S_B \psi|}{|\psi^T S_W \psi|} \quad (1)$$

여기서, S_B 는 집단간 분산이고 S_W 는 집단내 분산이다. 최적의 분별 벡터들은 식 (2)의 S_B 와 S_W 의 일반화 고유벡터 (generalized eigenvector)의 집합이다.

$$S_B \psi = \lambda S_W \psi \quad (2)$$

차원에 비해 학습 데이터의 개수가 적은 경우에는 S_W 의 역행렬이 존재하지 않는 특이점(singularity) 문제가 발생하게 되어 LDA를 수정없이 사용하지 못한다. 이 문제의 해결을 위해서 LDA를 적용하기 전에 데이터를 저차원 공간으로 투사한 후 LDA를 사용하는 기법들이 제시되었다. 대표적인 방법으로 Fisherface[13], D-LDA[14], N-LDA[15] 등이 있다.

3.2 R-LDA

전처리 단계를 사용하지 않고 피셔 기준을 규칙화하여 LDA의 단점을 극복하는 기법 중 간단하고 대표적인 것이 S_W 를 $S_W + \alpha I$ (I 는 단위행렬이고, α 는 작은 값을 갖는 양의 실수)로 대체하여 분별 벡터를 구하는 방법(R-LDA)[6]이다. $S_W + \alpha I$ 는 역행렬을 갖기 때문에 R-LDA는 특이점 문제를 해결할 수 있으며 동시에 Fisherface 등에서 활용하지 못했던 S_W 의 영공간(null space)의 정보를 사용함으로써 분류 성능에 보다 효과적인 특징을 추출할 수 있다.

또한, 데이터가 충분하지 않은 경우에 S_W 추정치의 신뢰도가 낮아서 발생하는 분별 벡터의 왜곡의 정도를 완화한다. 한편, 데이터의 특성상 존재하는 상관도를 활용하는 LDA 규칙화 기법이 있다[9,10]. 이 LDA 규칙화 방법(smoothness regularized LDA, S-LDA)은 데이터에 내재된 높은 상관도를 이용하기 위해서 피셔 지수에 평탄도(smoothness) 비용 함수를 제약 조건으로 추가하고 이를 최적화하는 기법이다.

4. 하이퍼스펙트럴 영상 분류를 위한 S-LDA

이 장에서는 S-LDA에 대해서 자세히 소개하고, 하이퍼스펙트럴 영상 데이터의 이중 규칙화 방법을 제안한다.

4.1 S-LDA

그림 1의 (b)에서 볼 수 있듯이, 일반적으로 하이퍼스펙트럴 영상의 인접 스펙트럴 밴드는 높은 상관성을 갖는다. 일반적으로 인접한 파장대역 λ_i 와 λ_{i+1} 에서의 반사율이 급격한 차이가 없기 때문이다. 따라서 S-LDA는 이러한 스펙트럴 차원에서의 평탄도를 S_W 의 페널티 함수로 추가하여 분별 벡터를 구한다. 상세히 설명하면, 하이퍼스펙트럴 영상의 픽셀 분류에서 분별 벡터 ψ 의 페널티 함수를 식 (3)과 같이 정의한다.

$$\Theta_{SPECTRAL}(\psi) = \sum_{i=1}^p (\psi_{i-1} + \psi_{i+1} - 2\psi_i)^2 \quad (3)$$

여기서, p 는 스펙트럴 밴드의 총 개수이다. $\Theta_{SPECTRAL}(\psi)$ 를 사용하여 규칙화한 피셔 기준은 식 (4)와 같다.

$$\max_{\psi} \frac{|\psi^T S_B \psi|}{|\psi^T S_W \psi| + \alpha \Theta_{SPECTRAL}(\psi)} = \max_{\psi} \frac{|\psi^T S_B \psi|}{|\psi^T (S_W + \alpha D^T D) \psi|} \quad (4)$$

여기서, α 는 규칙화의 정도를 조절하는 매개변수이고 ψ 는 $p \times 1$ 벡터이며, D 행렬은 $p \times p$ 1차 계차(first difference) 행렬로서 식 (5)와 같이 표현된다.

$$\begin{bmatrix} -1 & 1 & & & \\ & 1 & -2 & 1 & \\ & & 1 & -2 & 1 \\ & & & \dots & \\ & & & & \dots \\ & & & & & -1 & 1 \end{bmatrix} \quad (5)$$

4.2 Dual S-LDA (DS-LDA)

하이퍼스펙트럴 영상의 픽셀 분류에서, 주위의 이웃 픽셀의 스펙트럴 정보를 추가적으로 이용하면 분류 성능의 향상을 기대할 수 있다. 왜냐하면, 영상 정보의 특성상 경계를 제외하고는 공간적으로 이웃한 픽셀이 같은 클래스에 속할 확률이 높기 때문이다. 일반적으로 2차원 영상에서 이웃 픽셀간의 공간적(spatial) 상관도가 높기 때문에, 이웃 픽셀을 이용하는 경우에 공간적 차원의 평탄도를 추가적으로 유용하게 활용할 수 있다. 즉, 스펙트럴 차원과 공간적 차원에서의 평탄도의 이중(dual) 규칙화를 사용하는 이중 S-LDA(dual S-LDA, DS-LDA)가 가능하다. 이하 DS-LDA에 대해 자세히 소개한다.

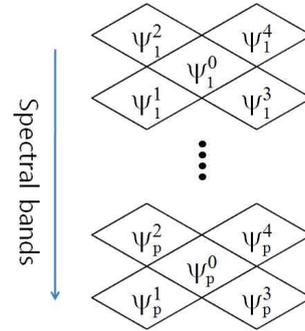


그림 2. DS-LDA에서의 이웃 구조 및 그에 따른 분별 벡터.

Fig. 2. A neighboring structure and the associated discriminant vectors in DS-LDA.

식 (6)은 그림 2에서의 4개의 이웃 픽셀 구조를 가정한 경우의 분별 벡터의 2차원 국소 평탄도를 위한 페널티 함수이다.

$$\Theta_{SPATIAL}(\psi) = \sum_{i=1}^p \{ (\psi_i^1 - \psi_i^0)^2 + (\psi_i^2 - \psi_i^0)^2 + (\psi_i^3 - \psi_i^0)^2 + (\psi_i^4 - \psi_i^0)^2 \} \quad (6)$$

여기서, ψ_i^k ($k \neq 0$)는 ψ_i^0 의 k 번째 이웃 픽셀에 대응되는 분별 벡터의 i 번째 성분이다. 식 (6)을 식 (1)의 LDA 틀에 삽입하기 위해 행렬 형태로 표시하면

$$\Theta_{SPATIAL}(\psi) = \psi^T (A_1^T A_1 + A_2^T A_2 + A_3^T A_3 + A_4^T A_4) \psi = \psi^T D_n \psi \quad (7)$$

이다. 여기서, ψ 는 $5p \times 1$ 벡터로서 $[\psi_1^1, \dots, \psi_p^1, \dots, \psi_1^0, \dots, \psi_p^0, \dots, \psi_1^4, \dots, \psi_p^4]^T$ 이고 A_i 는 $p \times 5p$ 행렬로서 다음과 같이 표현된다. I 는 $p \times p$ 단위행렬이다.

$$\begin{aligned} A_1 &= [I : 0 : -I : 0 : 0] \\ A_2 &= [0 : I : -I : 0 : 0] \\ A_3 &= [0 : 0 : -I : I : 0] \\ A_4 &= [0 : 0 : -I : 0 : I] \end{aligned} \quad (8)$$

스펙트럴 차원에서의 평탄도 페널티 함수는 식 (9)와 같이 표현된다.

$$\Theta_{SPECTRAL}(\psi) = \sum_{k=0}^4 \sum_{i=1}^p (\psi_{i-1}^k + \psi_{i+1}^k - 2\psi_i^k)^2 = \psi^T D_p^T D_p \psi \quad (9)$$

여기서, D_p 은 식 (5)의 $p \times p$ 행렬 D 를 이용하여 식 (10)과 같이 근사화하였다.

$$\begin{bmatrix} D & & & \\ & D & & \\ & & D & \\ & & & D \end{bmatrix} \quad (10)$$

식 (7)과 (9)를 이용하여 규칙화한 피셔 지수는 식 (11)과 같이 표현된다.

$$\max_{\psi} \frac{|\psi^T S_B \psi|}{|\psi^T (S_W + \alpha D_p^T D_p + \beta D_n) \psi|} \quad (11)$$

여기서, α 와 β 는 각각 스펙트럴 차원과 공간적 차원의 규칙화 정도를 나타내는 양수의 매개변수이다. 식 (11)의 해,

즉 분별 벡터 ψ 는 식 (12)의 일반화 고유값(eigenvalue) 문제를 풀어서 구한다.

$$S_B \psi = \lambda (S_W + \alpha D_p^T D_p + \beta D_n^T D_n) \psi \quad (12)$$

5. 실험 결과 및 분석

5.1 AVIRIS 92AV3C 데이터

그림 3은 AVIRIS 92AV3C 하이퍼스펙트럴 영상 데이터는 널리 사용되는 공개 데이터[16]로서, AVIRIS(Airborne Visible InfraRed Imaging Spectrometer)를 이용하여 미국 인디애나주의 북서쪽에 위치한 Indian Pine 지역을 항공에서 촬영한 데이터이다¹⁾. 이미지 크기는 145×145이며 400nm에서 2,500nm 사이의 파장대역의 총 224 스펙트럴 정보로 구성되어 있다. 실험에서는 대기 중 수분에 의해 왜곡된 스펙트럴 대역 등을 제외하여 총 188개의 스펙트럴 밴드를 사용하였다. 이 데이터는 촬영 지역의 대지 형태(land type)와 초목(vegetation)에 대한 16개의 클래스 정보를 제공한다. 표 1은 클래스별 총 픽셀 개수를 나타낸다. 본 실험에서는 학습 데이터의 개수 변동에 따른 S-LDA의 성능을 실험적으로 분석하기 위해서 AVIRIS 92AV3C 데이터를 사용한 기존 연구와 달리, 픽셀 개수가 매우 적은 클래스(#1, #7, #9, #16)의 데이터를 포함하여 사용하였다.



그림 3. AVIRIS 92AV3C 하이퍼스펙트럴 데이터 (검은색은 백그라운드 영역).

Fig. 3. AVIRIS 92AV3C hyperspectral data (black areas are backgrounds).

5.2 실험 결과 및 분석

S-LDA의 특징 추출 성능을 평가하기 위하여 R-LDA와 비교 분석하였다²⁾. 단위 길이 정규화(unit length normalization)를 사용하였으며 추출된 특징의 평가를 위해 분류기는 가장 단순한 1-nearest neighbor 분류기를 이용하여 분류 성능을 측정하였다. 모든 실험은 30회씩 수행하고 평균을 취하였다.

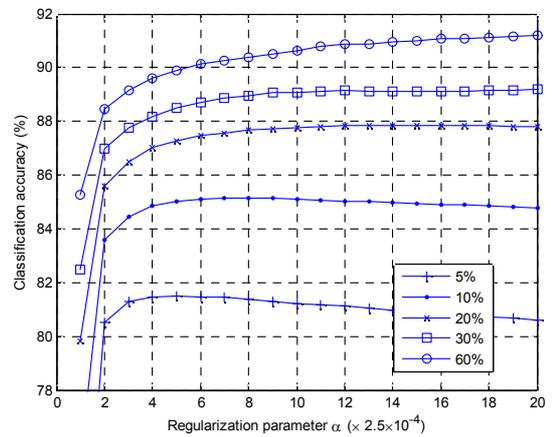
그림 4는 규칙화 계수에 따른 R-LDA와 S-LDA의 분류 성능을 나타낸다. 클래스별 학습 데이터 개수의 변화에 따른 영향을 관찰하기 위해 총 데이터에 대한 학습 데이터의 비율을 각각 5%, 10%, 20%, 30%, 60%로 변화시키면서 실험

1) ftp://ftp.ecn.purdue.edu/biehl/MultiSpec/ 에서 다운로드 가능.
 2) R-LDA 기법이 Fisherface, D-LDA 등의 다른 LDA 방법보다 월등히 좋은 성능을 보였다. 이는 특징 추출 과정에서 S_W 의 영공간을 사용할 수 있기 때문으로 판단된다.

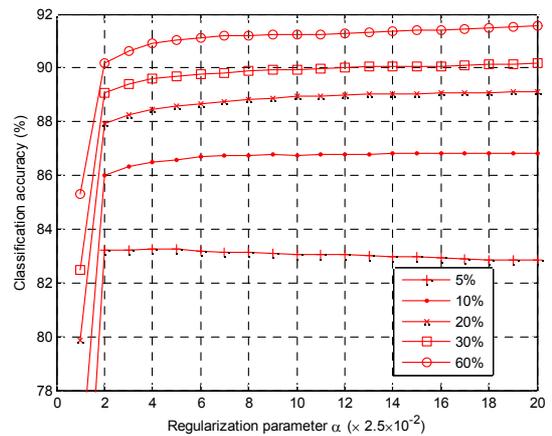
행하였다. 학습 데이터는 수행(run)마다 랜덤하게 선택하였으며 학습 데이터 이외의 데이터를 테스트 데이터로 하여 일반화 성능을 측정하였다.

Table 1. The number of pixels belonging to each class.
 표 1. 각 클래스별 총 픽셀 개수.

클래스	개수	클래스	개수
#1 Alfalfa	54	#9 Oats	20
#2 Corn-notill	1434	#10 Soybeans-notill	968
#3 Corn-min	834	#11 Soybeans-min	2468
#4 Corn	234	#12 Soybeans-clean	614
#5 Grass/Pasture	497	#13 Wheat	212
#6 Grass/Trees	747	#14 Woods	1294
#7 Grass/pasture-mowed	26	#15 Bldg-Grass-Tree-Drives	380
#8 Hay-windrowed	489	#16 Stone-steel towers	95



(a)



(b)

그림 4. 규칙화 계수에 따른 분류 성능 곡선. (a) R-LDA, (b) S-LDA.

Fig. 4. Curves of classification accuracy with respect to the regularization parameter α . (a) R-LDA, (b) S-LDA.

그림 4의 (a)와 (b)를 비교해보면, S-LDA의 분류 성능이 학습 데이터 비율이 5%와 10% 경우에는 약 2% 정도, 그 비율이 20%, 30%인 경우에는 약 1% 정도 R-LDA보다 우수함을 알 수 있다. 성능 차이는 학습 데이터의 개수가 많아질수록 줄어드는 경향을 보여서 학습 데이터 비율이 60%인 경우에 0.2%의 차이를 보인다. 학습 데이터가 많은 경우에는 평탄도 규제가 없이도 S_W 를 신뢰성 있게 추정하기에 충분한 정보가 이용 가능하기 때문이다.

그림 5는 규칙화 계수 값이 최적일 때의 S-LDA와 R-LDA의 클래스별 분류 성능을 나타낸다. 학습 데이터의 개수가 상대적으로 적은 클래스인 #1, #7, #9 (클래스의 총 데이터 개수는 각각 54개, 26개, 20개)에서 S-LDA가 R-LDA보다 약 15% 이상의 높은 분류 성능을 보임을 관찰할 수 있다. 학습 데이터 비율이 20%로 증가하면서 그 차이가 줄어들지만 클래스 #1과 #7에서는 여전히 5~10%의 성능 차이를 보인다. 이는 R-LDA에서는 학습 데이터 개수가 차원에 비해 상당히 적은 클래스의 S_W 추정치는 과대적합되는데 반해서, S-LDA에서는 평탄도 규제를 통해 과대적합되는 정도가 상당히 완화되기 때문이다. 그림 6은 R-LDA와 S-LDA에 의해 추출된 한 분별 벡터를 나타내는데 S-LDA에 의해 추출된 분별 벡터가 상대적으로 매우 평탄함을 알 수 있다. R-LDA의 분별 벡터가 나타내는 굴곡 정도(ruggedness)는 테스트 데이터에 대한 일반화 성능을 낮게 만들 가능성이 높다.

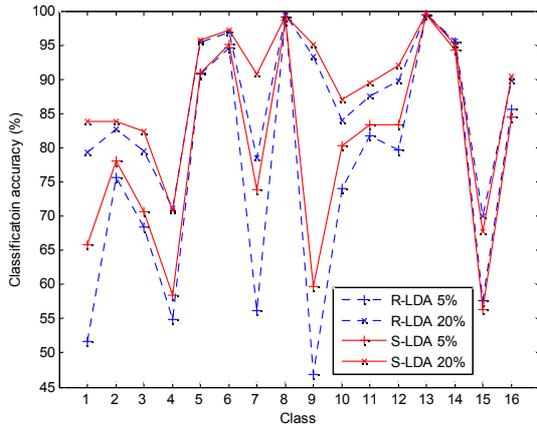


그림 5. 클래스별 R-LDA와 S-LDA의 분류 성능 (학습 데이터 크기 비율이 5%, 20%).

Fig. 5. Classification accuracies of R-LDA and S-LDA for each class (when the training data set size are 5% and 20%).

DS-LDA의 특징 추출 성능을 분석하기 위한 실험을 위해 그림 2의 이웃 구조를 채택하였다. 이웃 픽셀의 정규화된 스펙트럴 데이터를 일렬로 붙여서 $5 \times 188 = 940$ 차원의 데이터를 사용하였다. 그림 7은 규칙화 계수에 따른 R-LDA, S-LDA, DS-LDA의 성능을 나타낸다. DS-LDA의 성능은 규칙화 계수 β 에 대해 $[10^{-8}, 10^{-1}]$ 범위 내에서는 거의 동일한 성능을 보였다. 실험 결과로부터 아래 관찰을 확인할 수 있었다.

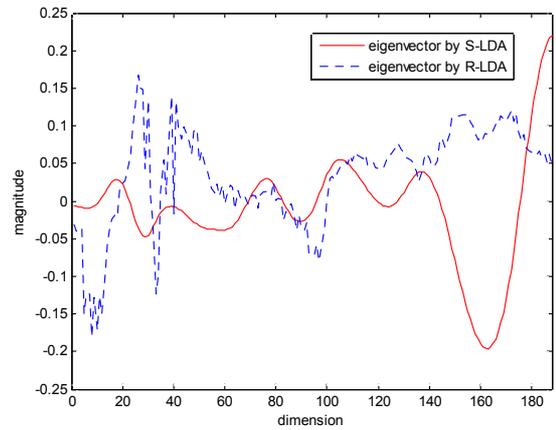
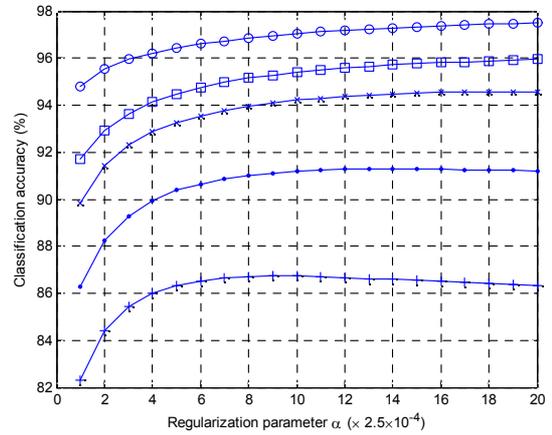
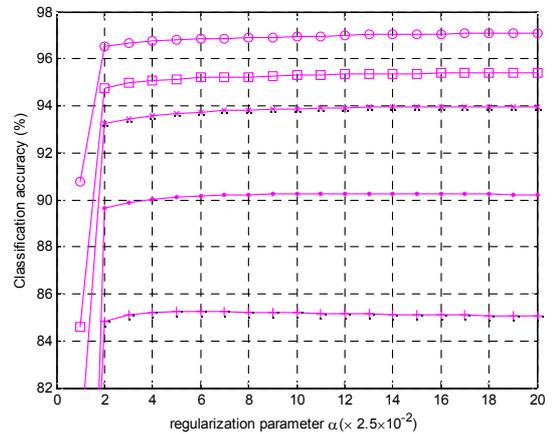


그림 6. R-LDA와 S-LDA의 분별 벡터 (학습 데이터 크기 비율이 5%).

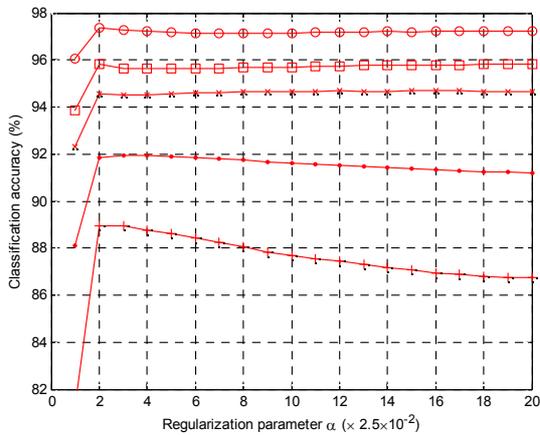
Fig. 6. Discriminant vectors of R-LDA and S-LDA (when the training data set size is 5%).



(a)



(b)



(c)

그림 7. 이웃 픽셀을 이용한 실험에서의 분류 성능. (a) R-LDA, (b) S-LDA, (c) DS-LDA.

Fig. 7. Curves of classification accuracy in the experiments using neighboring pixels. (a) R-LDA, (b) S-LDA, (c) DS-LDA.

- 그림 4의 성능과 비교해보면, R-LDA는 단순히 주위 픽셀의 스펙트럴 정보만을 추가하는 것만으로도 학습 데이터 비율에 따른 큰 차이 없이 약 6% 이상 성능이 향상되었다. S-LDA는 학습 데이터 비율이 낮은 경우에는 2% 정도의, 비율이 높은 경우에는 5% 정도의 성능이 향상되는데 그쳤다.
- 싱글(single) 픽셀만을 이용한 실험 결과와는 다르게, 흥미롭게도 R-LDA가 S-LDA보다 높은 성능을 보였다. 학습 데이터 개수가 적은 경우(학습 데이터의 비율이 5%)에도 오히려 R-LDA가 2% 정도 높은 분류 성능을 보였다. 데이터의 차원이 5배나 커졌기 때문에 그림 4의 경우에서 나타난 S-LDA와 R-LDA의 성능 차이가 커질 것으로 예상하였으나 오히려 반대의 결과가 나타났다. 이는 추가된 정보가 전혀 연관성이 없는 데이터가 아닌, 이웃 픽셀들의 스펙트럴 정보로서 충분히 상관도가 높은 정보이기 때문으로 추정된다.
- DS-LDA는 S-LDA뿐만 아니라 성능이 향상된 R-LDA보다 높은 성능을 보였다. 특히 학습 데이터의 비율이 5%인 경우에는 분류 성능이 R-LDA보다 약 2% 정도로 높았다. 이는 싱글 픽셀 분류 실험에서와 마찬가지로, 이웃 픽셀 정보를 이용하는 분류에서도, 내재된 상관도(이웃 픽셀들 간의 공간적 상관도)를 활용하여 분류 벡터를 규제하는 것이 데이터가 부족할 때 매우 효과적이고 유용한 선택임을 의미한다. 그림 8과 같이 학습 데이터 집합의 크기가 점차 증가할수록 그 성능 차이는 감소하는 경향을 보인다. DS-LDA의 클래스별 분류 성능의 특성은 싱글 픽셀 분류에서와 동일한 경향을 보였다.

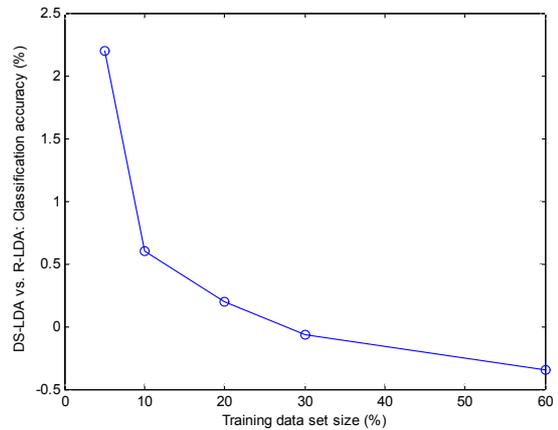


그림 8. 학습 데이터 집합의 크기에 따른 DS-LDA와 R-LDA의 성능 차이 추이.

Fig. 8. Performance difference between DS-LDA and R-LDA with respect to the training data set size.

6. 결론

본 논문에서는 하이퍼스펙트럴 영상 분류에서의 평탄도에 기반한 LDA 규칙화 기법의 성능을 실험적으로 분석하였으며, 보다 효과적인 특징 추출을 위하여 이웃 픽셀 정보를 사용하고 하이퍼스펙트럴 영상의 공간적 차원의 평탄도를 추가적으로 활용하는 이중 평탄도 LDA 규칙화 기법을 제시하였다. 대표적인 하이퍼스펙트럴 영상 데이터인 AVIRIS 92AV3C 데이터를 사용한 실험을 통해서, 평탄도 규칙화 LDA가 전반적으로 학습 데이터의 개수가 적을 때 기존 규칙화 LDA보다 효과적인 분류 성능을 보이며, 특히 데이터의 개수가 적은 클래스의 분류에서 확연히 높은 분류 성능을 보임을 확인하였다. 또한, 제한한 이중 평탄도 규칙화 LDA가 스펙트럴 차원뿐만 아니라 공간적 차원의 상관도를 함께 활용하여 특징 추출을 수행함으로써 다른 규칙화 LDA 방법보다 개선된 일반화 성능을 보였다.

참고 문헌

- [1] P. Martinsen, P. Schaarse, and M. Andrews, "A versatile near-infrared imaging spectrometer," *J. of Near-Infrared Spectrosc.*, vol. 7, no. 1, pp. 17-25, 1999.
- [2] G. Shaw and D. Manolakis, "Signal processing for hyperspectral image exploitation," *IEEE Signal Processing Magazine*, vol. 19, no. 1, pp. 12-16, 2002.
- [3] Z. Du, M. K. Jeong, and S. G. Kong, "Band selection of hyperspectral images for automatic detection of poultry skin tumors," *IEEE Trans. Automation Science and Engineering*, vol. 4, no. 3, pp. 332-339, 2007.
- [4] G. F. Houghes, "On the mean accuracy of statistical pattern recognition," *IEEE Trans. Inform.*

- Theory*, vol. 14, no. 1, pp. 55-63, 1968.
- [5] K. Fukunga, *Introduction to Statistical Pattern Recognition*, Academic Press, New York, 1991.
- [6] J. H. Friedman, "Regularized discriminant analysis," *J. of the American Statistical Association*, vol. 84, no. 405, pp. 165-175, 1989.
- [7] J. Lu, K. N. Plataniotis, and A. N. Venetsanopoulos, "Regularization studies of linear discriminant analysis in small sample size scenarios with application to face recognition," *Pattern Recognition Letters*, vol. 26, no. 2, pp. 181-191, 2005.
- [8] D.-Q. Dai and P. C. Yuen, "Face recognition by regularized discriminant analysis," *IEEE Trans. on SMC-PART B*, vol. 37, no. 4, pp. 1080-1085, 2007.
- [9] T. Hastie, A. Buja, and R. Tibshirani, "Penalized discriminant analysis", *The Annals of Statistics*, vol. 23, no. 1, pp. 73-102, 1995.
- [10] D. Cai, X. He, Y. Hu, J. Han, and T. Husang, "Learning a spatially smooth subspace for face recognition", *Proc. of IEEE Conf. on Computer Vision and Pattern Recognition*, pp. 1-7, 2007.
- [11] B. Yu, I. Michael Ostland, P. Gong, and R. Pu, "Penalized discriminant analysis of in situ hyperspectral data for species recognition," *IEEE Trans. on Geoscience and Remote Sensing*, vol. 37, no. 5, pp. 2569-2577, 1999.
- [12] R. A. Fisher, "The use of multiple measures in taxonomic problems," *Ann. Eugenics*, vol. 7, pp. 179-188, 1936.
- [13] P. N. Belhumeur, J. P. Hespanha, and D. J. Kriegman, "Eigenface vs. Fisherface: Recognition using class specific linear projection," *IEEE Trans. Pattern Analysis Machine Intelligence*, vol. 19, pp. 711-720, 1997.
- [14] H. Yu and J. Yang, "A direct LDA algorithm for high-dimensional data with application to face recognition," *Pattern Recognition*, vol. 34, pp. 2067-2070, 2001.
- [15] L. Chen, H. Liao, M. Ko, J. Lin, and G. Yu, "A new LDA-based face recognition system which can solve the small size problem," *Pattern Recognition*, vol. 33, no. 10, pp. 1713-1726, 2000.
- [16] D. Landgrebe, "On information extraction principles for hyperspectral data: a white paper," Tech. Rep., School Elec. Comput. Eng., Purdue Univ., West Lafayette, IN, 1997.

저 자 소 개



박래정

1991년 : 서울대학교 전기공학과 공학사
 1993년 : 한국과학기술원 전기및전자공학과 석사
 1997년 : 한국과학기술원 전기및전자공학과 박사
 1997년~1999년 : LG 종합기술원 선임연구원

2000년~현재 : 강릉대학교 전자공학과 부교수.

관심분야 : 기계학습, 데이터마이닝, M2M 지능, 센서 네트워크.