

## 반감독학습에서 중심이동 선형판별분석

신용준<sup>o</sup> 박정희

충남대학교 컴퓨터공학과

yjsin@cnu.ac.kr, cheonghee@cnu.ac.kr

## Centroid Shift Linear Discriminant Analysis for semi-supervised learning

Yong Joon Sin<sup>o</sup> Cheong Hee Park

Department of Computer Engineering Chungnam National University

## 1. 서론

데이터마이닝분야에서는 일반적으로 이미지나 텍스트 등의 높은 차원의 데이터를 이용할 경우 발생하는 차원의 저주(the curse of dimensionality) 문제를 해결하고 성능을 높이기 위해 차원 감소(dimension reduction)방법을 통해 데이터를 가공하게 된다. 이러한 기법들은 입력 데이터의 의미 있는 정보는 남기고 중복되는 정보나 의미 없는 정보들을 제거하는 기능을 수행한다. 일반적으로 데이터는 많지만 데이터의 클래스정보는 얻기 힘들고 처리 비용이 높은 반면 클래스정보가 없는 데이터(unlabeled data)는 얻기 쉽기 때문에, 클래스정보가 있는 데이터(labeled data)에 추가적으로 클래스정보가 없는 unlabeled data를 이용하여 학습하는 방법이 연구되고 있다. 이것을 반감독학습(semi-supervised learning)이라고 한다.[1] 차원감소방법도 데이터의 클래스정보 사용 여부에 따라 구분을 할 수 있고 labeled data와 unlabeled data를 모두 사용하는 반감독차원감소(semi-supervised dimensionality reduction)가 있다. 기존에 제안된 반감독차원감소 방법에는 감독차원감소방법에 무감독차원감소방법을 결합한 형태인 SSLDA(Semi-Supervised LDA)[2]와 NSSLDA(New Semi-Supervised LDA)[3]가 있다. 여기에서 SSLDA는 LDA[4]와 LPP[5]의 결합이고 NSSLDA는 LDA와 UDP[6]의 결합이다. 이 논문에서는 감독차원감소방법인 LDA에 unlabeled data를 이용하여 클래스 분류 성능을 향상시킨 중심이동 선형판별분석(Centroid Shift LDA)을 제안한다.

## 2. 중심이동 선형판별분석

임의의 규칙에 의해 클래스 정보가 결정된 unlabeled data를 LDA에 그대로 사용하게 되면 unlabeled data의 클래스 정보가 100% 정확하지 않을 경우 차원감소의 성능을 나쁘게 하는 원인이 된다. 이러한 특징 때문에 본 논문에서는 unlabeled data를 직접 사용하지 않고 클래스 중심값과 전체 데이터의 중심값의 조정에 활용함으로써 부정확한 unlabeled data의 사용으로 발생하는 나쁜 영향을 줄이고 더욱 많은 데이터를 활용할 수 있도록 하여 클래스 분류 성능을 향상시킨다. 먼저 LDA의 목표함수는 다음과 같다.

$$W_{LDA} = \arg \max_{W \in R^{d \times m}} \frac{|W^T S_b W|}{|W^T (S_w + \lambda_1 I) W|} \quad (1)$$

이고, 여기에서  $S_b$ 는 클래스간 분산 행렬(between-class scatter matrix),  $S_w$ 는 labeled data의 클래스 내 분산 행렬(within-class scatter matrix)를 의미한다.  $\lambda_1$ 은 정규화 파라미터(regularization parameter)이다. 제안한 방법에서 사용될 unlabeled data는 다음과 같은 방법으로 선택한다. 먼저, 각 labeled data의 클래스 중심으로 unlabeled data를 분류한다. 다음으로, 각 클래스 별로 labeled data의 k-인접이웃에 포함되는 unlabeled data를 선택하는 것이다. 이러한 규칙에 의하여 클래스 정보가 결정된 unlabeled data를 중심계산에 사용한 LDA방법을 CSLDA(Centroid Shift Linear Discriminant Analysis)라 하고 목표함수는 다음과 같다.

$$W_{CSLDA} = \arg \max_{W \in R^{d \times m}} \frac{|W^T S_b^{CS} W|}{|W^T (S_w + \lambda_1 I) W|} \quad (2)$$

위의 식에서  $S_b^{CS}$ 는

$$S_b^{CS} = \sum_{i=1}^r n_i^{CS} (cm_i^{CS} - tm^{CS})(cm_i^{CS} - tm^{CS})^T$$

이다.  $n_i^{CS}$ 는 unlabeled data를 포함한  $i_{th}$  클래스의 데이터 수, labeled data와 위에서 설명한 규칙에 의해 선택된 unlabeled data를 이용하여 계산한 클래스  $i$ 의 평균을  $cm_i^{CS}$ 라 하고, 전체 데이터의 평균을  $tm^{CS}$ 이라고 나타내었다.

### 3. 성능 평가 및 결론

실험에 사용된 텍스트 데이터는 20Newsgroups과 reviews이고 특징은 다음과 같다. reviews는 데이터 수가 많은 클래스 3개와 frequency가 높은 속성으로 재구성하였다.

데이터	클래스 수	데이터 수	속성수
20Newsgroups	20	18941	26214
reviews	3	4069	20015

표 1. 실험 텍스트 데이터 설명

각 데이터는 트레이닝 데이터를 클래스당 100개, 테스트 데이터를 클래스당 100개 두고 트레이닝 데이터에서 labeled, unlabeled 나누었고 labeled data수를 변경하면서 1-nn 분류기를 이용해 정확도를 측정하였고 각 실험은 5번씩 반복하여 평균정확도를 계산하였다. 다음 실험결과에서 T는 테스트 데이터를 의미하고 U는 unlabeled 데이터를 의미한다.

labeled 데이터수	LDA		NSSLDA		CSLDA	
	T	U	T	U	T	U
5	41.42	42.16	48.26	50.96	49.52	48.35
10	50.22	51.04	56.6	57.7	59.14	56.40
20	58.15	58.45	62.13	63.7	63.76	61.95
40	63.27	62.92	66.24	68.19	67.08	68.08

표 2. 20NG의 평균 정확도

labeled 데이터수	LDA		NSSLDA		CSLDA	
	T	U	T	U	T	U
5	78.47	78.74	72.2	71.23	77.27	79.23
10	81.67	83.48	78.87	79.78	83.67	85.93
20	88.6	90.83	89.4	91.42	90.67	91.83
40	93.07	95.56	92.67	93.22	92.33	94

표 3. reviews의 평균 정확도

위의 결과로 볼 때 CSLDA는 기존의 반감독형

LDA 보다 좋은 클래스 분류 성능을 보인다는 것을 알 수 있다. 이 논문에서 제안한 CSLDA에서는 필요한 매개변수가 식(2)의  $\lambda_1$ , unlabeled data를 선택하기 위한  $k$ 가 있다. 여기서  $\lambda_1$ 은 LDA에서도 사용하는 매개변수이고 추가적으로 사용된  $k$ 는 기존의 반감독차원감소방법인 SSLDA나 NSSLDA에 사용되는 매개변수에 비해 그 범위가 매우 작기 때문에 상대적으로 결정하기 쉽다는 장점이 있다. 이 논문에서는 labeled data가 적고 얻기 힘든 점을 보완하기 위해 labeled data보다 많고 수집 비용이 적게 드는 unlabeled data를 이용하는 새로운 선형판별분석방법인 CSLDA를 제안하였다. 이 방법은 기존의 unlabeled data를 이용하는 SSLDA와 다르게 임의의 규칙을 통해 사용할 unlabeled data를 선택함으로써 계산비용을 줄이고 이를 중심값 이동에 적용하여 클래스 분류성능을 향상시키는 결과를 얻었다.

### 참고문헌

- [1] M. Belkin, P. Niyogi. Semi-Supervised Learning on Riemannian Manifolds. Machine Learning, 56:209-239, 2004.
- [2] Y. Song, F. Nie, C. Zhang and S. Xiang. A unified framework for semi-supervised dimensionality reduction. Pattern Recognition, 44:2789-2799, 2008.
- [3] G. Lim, C. Park. Semi-supervised Dimension Reduction Using Graph-based Discriminant Analysis. IEEE International Conference on Computer and Information Technology, 2009
- [4] R. Duda, P. Hart, and D. Stork, Pattern Classification, Wiley-interscience, New York, 2001.
- [5] X. He, P. Niyogi. Locality preserving projections. Advances in Neural Information Processing Systems, 585-591, 2003.
- [6] J. Yang, D. Zhang, J. Yang and B. Niu. Globally Maximizing, Locally Minimizing : Unsupervised Discriminant Projection with Applications to Face and Palm Biometrics. IEEE transactions Pattern Analysis and Machine Intelligence, 29(4):650-664, 2007.