

장르 분류 성능 향상을 위한 거리함수 학습의 활용

장달원 신사임 이종설 장세진 임태범

전자부품연구원

dalwon@keti.re.kr

Applying distance metric learning for improvement of genre classification

Jang, Dalwon Shin, Saim Lee, JongSeol Jang, Sei-jin Lim, Tae-Beom

Korea Electronics Technology Institute

요약

음악 장르 분류 분야에서는 다양한 특징을 모아서 사용하는 방법과 support vector machine (SVM) 분류기가 주로 사용되고 있다. 이 논문에서는 거리 함수 학습을 음악 장르 분류에 적용하여 성능 향상을 꾀한다. 여러 거리 함수 학습 방법 중 하나의 방법을 선택하고, 일반적으로 많이 사용되는 특징 셋을 활용하여 다양한 특징 셋에 대해서 적용하였을 때, 실제 성능 향상이 있는지를 알아본다. 세 종류의 특징 셋을 사용하여 실험한 결과 두 가지 특징이 같이 있는 특징 셋에 대해서만 성능 향상이 있었으며, SVM보다 높은 성능을 보이지 못 했다.

1. 서론

디지털 음악의 사용이 늘어나면서 대용량의 음악 데이터베이스에 저장된 정보들을 효율적으로 관리하고, 검색하는 기술에 대한 수요가 생겨왔다. 그리하여 음악 정보 검색과 관련된 다양한 연구가 있어왔으며, 그 중 하나로 음악 장르 분류 분야가 있다[1-7]. 음악 장르 분류는 입력 음악에 대해서 그것을 분석하고, 미리 정해진 여러 개의 장르 중 하나의 장르를 입력에 대한 것으로 출력해 주는 기술이다. 음악의 장르는 음악 정보의 관리에 꼭 필요한 정보로 자동적인 분류가 가능하다면 판매처, 방송국 등 대용량의 음악 데이터베이스를 보유하는 업체 뿐만 아니라 개인에게도 많은 도움이 될 것이다. 음악장르 분류는 2000년대 이후로 많이 연구되었으며 특징(feature)들을 추출하는 과정과 분류기를 이용해서 결과를 얻는 과정으로 구성된다[1-7]. 현재는 Mel-Frequency Cepstral Coefficients (MFCC)를 비롯한 여러 가지 특징들을 추출하고, 이를 합쳐서 하나의 특징 셋을 만들어서 사용하고 있다. 여러 가지 분류기 중 support vector machine (SVM)이 일반적으로 좋은 성능을 보이고 있다.

이 논문에서는 거리 함수 학습 방법이 음악 장르 분류 시스템의 성능 향상에 도움을 줄 수 있는지에 대해서 알아본다. 거리 함수 학습 방법은 2000년대 중반 이후 다양한 방법들이 개발되었다 [8-11], 다양한 분류 분야에 적용되었다. 이 논문에서는 그 중 maximally collapsing metric learning (MCML) 방법을 사용하였다 [11]. 거리 함수 학습 방법을 사용할 경우, 분류기는 k-nearest neighbor (k-NN) 분류기를 사용하게 된다. MCML을 일반적으로 많이 사용되는 음악장르 분류 테스트 데이터와 세 종류의 특징셋을 사용하는 음악 장르 분류 시스템에 적용하였을 때 성능의 변화를 알아보고, 현재 많이 사용되는 SVM 분류기와의 성능을 비교한다.

2. MCML 방법 [11]

일반적으로 거리 함수 학습 방법은 N 차원의 벡터에 대해서 $N \times N$ 크기의 어떤 positive semi-definite (PSD) 행렬 A 를 파라미터로 정의하고, 파라미터 행렬 A 를 이용해서 다음과 같은 거리를 정의한다.

$$d_A(\vec{x}_i, \vec{x}_j) = (\vec{x}_i - \vec{x}_j)^T A (\vec{x}_i - \vec{x}_j)$$

여기에서 \vec{x}_i 와 \vec{x}_j 는 N 차원의 어떤 벡터를 나타낸다. 파라미터가 어떤 값으로 결정되느냐에 따라서 거리 함수가 결정되고, 그 파라미터는 학습을 통해서 결정된다.

MCML의 기본 원리는 하나의 클래스에 속한 모든 특징 벡터들은 하나의 점에 모여 있고, 다른 클래스에 속한 특징 벡터끼리는 무한히 면 위치에 있다는 이상적은 상황을 가정하는 것이다 [11]. 이런 가정 하에 각각의 훈련 데이터마다 정의되는 조건부 확률 분포는 이상적인 상황에 최대한 가깝게 되도록 학습한다. 어떤 벡터 \vec{x}_i 에 대한 조건부 확률을 아래와 같이 \vec{x}_i 와 다른 벡터와의 거리를 기준으로 정해진다.

$$p^A(j|i) = \frac{1}{Z_i} e^{-d_A(\vec{x}_i, \vec{x}_j)} = \frac{e^{-d_A(\vec{x}_i, \vec{x}_j)}}{\sum_{k \neq i} e^{-d_A(\vec{x}_i, \vec{x}_k)}}$$

위와 같이 정의된 조건부 확률 분포가 이상적인 확률분포와 가깝게 만들기 위해서 두 확률 분포 사이의 KL divergence를 최소화시키는 방법을 사용한다. 훈련 데이터에 속하는 각각의 벡터 \vec{x}_i 에 대해서 계산된 확률 분포와 이상 확률 분포와의 KL divergence를 구하고 이를 전체에 대해서 더한 합을 최소화하는 행렬 A 를 구한다. 행렬 A 를 구하는 자세한 방법은 [11]에서 찾아볼 수 있다.

3. 실험

실험에서는 GTZAN 데이터 셋을 사용하였는데[1], 이 데이터는 10가지 장르에 대해서 각각 100곡씩 데이터를 가지고 있다. 우리는 이 데이터 셋에 대한 분류 정확도를 10 fold cross-validation을 이용해서 계산하였다. 따라서, 900곡을 훈련 데이터로 사용하고, 100곡을 테스트 데이터로 사용하였으며 훈련 데이터와 테스트 데이터를 바꿔가면서 10번의 과정을 거치고, 전체 평균을 구한다.

세 가지 특징 셋을 구성하였다: 특징 셋 1) MFCC의 평균(13차원), 특징 셋 2) MFCC의 평균과 분산(26차원), 특징 셋 3) MFCC, Octave-band spectral contrast (OSC) [3] 의 평균과 분산(58차원). 이 특징들을 오랜 연구를 통해서 음악 장르 분류 분야에서 검증된 특징이며, 논문으로 발표된 다양한 시스템에서 많이 사용되기에 [4-7] 이것들로 결정하였다. 각 프레임마다, 각각 13차원의 MFCC와 16차원의 OSC 특징이 추출되는데, 이 특징들은 여러 프레임간의 평균, 분산을 구한 것이다. 사용한 세 가지 특징 셋 자체가 높은 성능을 보장할 수 없지만, 다양한 시스템에서 많이 사용되는 특징들이기 때문에, 일반적인 경우에 MCML이 성능 향상에 영향을 미치는지에 대해 알아보기 적합할 것으로 생각된다.

MCML을 이용해서 거리 함수를 결정할 때, 행렬 A 의 초기값을 정하고, 여러 번의 반복 과정을 거치게 되는데, 우리는 이 실험에서 초기값을 identity 행렬로 정하고, 경우에 따라서 100번~200번의 반복과정을 거치게 하였다. 실험에서는 linear 커널을 사용하는 SVM 분류기와 유클리디안 거리를 사용하는 일반적인 k-NN 분류기를 비교대상으로 삼는다.

아래의 표 1에 다양한 경우의 분류 정확도를 기술하였다. 세 가지 특징 셋에 대해서 특징 셋 3에 대해서만 1~2% 정도 성능이 향상됨을 확인할 수 있었다. 하지만 기존의 k-NN 분류기에 비해서는 성능이 향상되었지만, SVM보다는 낮은 성능을 보였다. 그리고, 특징 셋 1, 2에 대해서는 오히려 성능이 떨어졌다.

분류기	분류 정확도		
	특징 셋 1	특징 셋 2	특징 셋 3
k-NN ($k=3$)	45.6	34.9	26.6
k-NN ($k=5$)	43.4	33.4	25
SVM	46.9	32.8	22.9
MCML + k-NN ($k=3$)	50.7	35.7	24.6
MCML + k-NN ($k=5$)	47.6	36.2	23.4

표 1. 다양한 경우의 분류 정확도

4. 결론

현재 음악 장르 분류 분야에 많이 사용되는 k-NN 분류기의 성능을 향상해 보기 위해서 거리 함수 학습 방법을 적용하고, 이것이 일반적인 상황에서 성능 향상을 이끌 수 있는지 알아보기 위해서 일반적인 특징 셋 3가지를 정하고 이에 대해서 성능을 알아보았다. MFCC만을 사용한 단순한 특징 셋일 경우에는 학습과정이 오히려 성능을 떨어뜨리는 결과를 보였으나, 두 가지 특징이 섞인 특징 셋을 사용하니, 성능이 좋아지는 모습을 보였다. 본 논문에 제시된 결과만으로는, 우리 실

험에서 사용한 MCML 방법이 음악 장르 분류에 도움을 주는지에 대한 명쾌한 해답을 얻을 수 없었다. 더욱 복잡한 형태의 실제적인 특징 셋에 대해서 어떤 결과를 보이는지 알아봐야 할 것이다.

5. 감사의 글

이 논문은 2013년도 정부(지식경제부)의 재원으로 산업원천기반 구축개발사업의 지원을 받아 수행된 연구임(No. 10037244).

6. 참고문헌

- [1] G. Tzanetakis and P. Cook, "Musical genre classification of audio signals," IEEE Trans. Speech Audio Process., vol. 10, no. 5, pp. 293-302, 2002.
- [2] T. Li , M. Ogihara, and Q. Li, "A comparative study on content-based music genre classification" Proc. ACM Con! on Research and Development in Information Retrieval, pp. 282-289, 2003
- [3] D. N. Jiang, L. Lu, H. J. Zhang, J. H. Tao, and L. H. Cai, "Music type classification by spectral contrast feature," Proc. ICME 02, vol. 1, pp. 113-116, 2002.
- [4] C-H. Lee, J-L. Shih, K-M. Yu, and J-M Su, "Automatic music genre classification using modulation spectral contrast feature," Proc. ICME 07, 2007
- [5] D. Jang, M. Jin, and C. D. Yoo, "MUSIC GENRE CLASSIFICATION USING NOVEL FEATURES AND A WEIGHTED VOTING METHOD," in Proc. ICME 08, June 23 2008-April 26 2008.
- [6] S.-C. Lim, J.-S. Lee, S.-j. Jang, S.-P. Lee, and M. Y. Kim, "Music-Genre Classification System based on Spectro-Temporal Features and Feature Selection," IEEE Trans on Consumer Electronics, Vol. 58, No. 4m Nov. 2012.
- [7] S.-C. Lim, S.-J. Jang, S.-P. Lee, and M. Y. Kim, "Music genre/mood classification using a feature-based modulation spectrum," in Proc. IEEE Int. Conf. Mobile IT Convergence, 2011, pp. 133-136.
- [8] E. P. Xing, A. Y. Ng, M. I. Jordan, and S. Russell, "Distance metric learning, with application to clustering with side-information," Adv. Neural Inf. Process. Syst. vol. 14, pp. 521 - 528, 2002.
- [9] A. Bar-Hillel, T. Hertz, N. Shental, and D. Weinshall, "Learning a Mahalanobis metric from equivalence constraints," J. Mach. Learning Res., vol. 6, pp. 937 - 965, 2005.
- [10] J. Goldberger, S. Rowewis, G. Hinton, and R. Salakhutdinov, "Neighborhood components analysis," Adv. Neural Inf. Process. Syst., vol. 17, pp. 513 - 520, 2005.
- [11] A. Globerson and S. Rowewis, "Metric learning by collapsing classes," Adv. Neural Inf. Process. Syst., vol. 18, pp. 451 - 458, 2006.