

EMD 기반 집합 간 거리 얼굴 검증에서 가중치 전략의 성능 분석

이상훈

한국전자통신연구원

sanghoon@etri.re.kr

Performance Analysis of Weighting Strategies for EMD-based Set-to-Set Distance Face Verification

Sanghoon Lee

Electronics and Telecommunications Research Institute

요약

본 논문은 EMD(Earth Mover's Distance) 기반의 집합 간 거리 얼굴 검증에서 다양한 가중치 전략의 성능을 분석한다. EMD는 한 분포를 다른 분포로 변환하는 데 필요한 최소 노력을 측정하는 유망한 방법으로, 여러 얼굴 이미지나 프레임에서 추출된 특징 집합을 비교하는 시나리오에 적합하다. 본 연구에서는 다양한 가중치 전략의 성능을 IJB-C 데이터셋을 통해 평가하였다. 실험 결과, 목격 단위 가중치 전략이 모든 FMR 수준에서 가장 낮은 FNMR을 기록하며 우수한 성능을 보였다. 결론적으로, 복잡도와 단순성 간의 균형을 맞추는 것이 최적의 성능을 달성하는 데 중요함을 확인하였다.




그림 1. 집합 간 거리 기반 얼굴 검증

I. 서론

얼굴 검증은 생체 인식 시스템에서 중요한 작업으로, 두 개의 얼굴 특징 집합이 동일한 신원에 속하는지를 검증하는 것을 목표로 한다. 전통적인 접근 방식은 보통 특징 집합당 하나의 특징 벡터를 사용하지만, 최근의 발전 [1]은, 그림 1과 같이, 동일한 사람의 다른 뷰 또는 프레임에서 추출된 여러 특징의 집합 간 비교의 효과를 보여주었다.

Earth Mover's Distance (EMD)는 집합 간 거리 비교를 위한 유망한 방법으로, 한 분포를 다른 분포로 변환하는 데 필요한 최소 노력을 측정한다. 본 논문에서는 EMD의 구별력을 향상시키기 위해 집합 내 특징에 다양한 가중치 전략을 적용하는 것이 최종 거리 계산과 얼굴 검증의 정확성에 어떤 영향을 주는지 분석한다.

II. 본론

본 논문에서는 EMD 기반 얼굴 검증 작업에 적용할 주요 가중치 전략에 대해 살펴본다. 이러한 가중치 전략은 DeepFace-EMD [2]의 가중치 전략에서 영감을 받았으며, 본 연구의 환경에 맞게 일부 수정하여 반영했다. 또한, 집합 내 모든 특징에 대한 가중치들의 합은 1로 정규화된다.

1) **균일(Uniform) 가중치**: 집합 내 모든 특징에 동일한 가중치를 부여한다. EMD의 표준 접근 방식이며, 비교를 위한 기준으로 사용된다.

2) **목격 단위(Per Sighting, PS) 가중치**: 목격 단위로 특징에 가중치를 부여하는 방식으로 집합 내의 구조적 정보를 반영한다. 각 목격에서 추

출된 특징의 수에 따라 가중치가 결정되며, 동일한 목격에서 추출된 특징들은 동일한 가중치를 가진다.

3) **평균 풀링 상관(Average Pooling Correlation, APC) 가중치**: 한 집합 내의 각 특징은 다른 집합 내 모든 특징들의 평균적인 상관에 따라 가중치가 부여된다. 각 특징이 다른 특징 집합에 기여하는 정도를 반영하며, 평균 풀링된 특징과 내적 후 램프(Ramp) 함수를 적용하여 계산된다.

4) **조합 상관(Combination Correlation, CC) 가중치**: 두 집합의 모든 원소 조합에 대한 내적을 고려하여 가중치를 부여한다. 각 특징은 다른 집합 내의 모든 특징들과 내적 후 램프 함수를 적용받으며, 이후 평균을 적용하여 가중치가 계산된다. APC와 비교하여, 모든 특징 간의 관계를 고려함으로써 보다 정밀한 비교를 가능하게 한다.

각 가중치 전략의 복잡도는 Uniform, PS, APC 및 CC 순으로 $O(1)$, $O(S)$, $O(MN)$ 및 $O(MN^2)$ 으로 나타낼 수 있다. 여기서 S는 목격의 수, N과 M은 두 집합의 특징 수이다.

III. 실험 환경

1) **데이터셋**: 다양한 가중치 전략의 영향을 평가하기 위해 IJB-C [3] 데이터셋의 Test 1(1:1 검증)을 사용한다. Test 1은 각 신원에 대하여 다수의 템플릿(=특징 집합)으로 구성되어 있으며, 다양한 얼굴 표정과 자세에서 추출된 풍부한 특징 집합을 제공한다. 검증에 사용되는 하나의 매치(Match)는 등록(Enrollment) 및 검증(Verification) 템플릿 쌍(Pair)으로 구성된다. Test 1은 15,658,489 개의 매치로 구성되며, 이 중 동일한 신원의 템플릿들로 구성되는 진정(Genuine) 매치는 총 19,557개로 전체의 약 0.12%이며, 대다수는 위조(Impostor) 매치가 차지한다. Test 1의 등록 및 검증 템플릿에 대한 분포는 다음과 같다.

유형	신원 수	템플릿 수	신원 당 템플릿 수	템플릿 당 이미지 수
등록	3,531	3,531	1.0	3.3577
검증	3,531	19,593	5.5489	23.3511

2) **특징 추출 방법**: 실험을 위하여 Test 1 내의 진정 및 위조 매치를 각각 5,000개 씩 무작위로 선정하였다. 또한 얼굴 영역 추출에는 IJB-C 데이터 셋의 메타데이터를 사용하였으며, 특징 추출에는 Arcface [4]를 이용하였다.

3) **평가 지표**: 가중치 전략의 성능을 다음 지표를 사용하여 평가한다.

- **FNMR@FMR(False Non-Match Rate@False Match Rate)**: FNMR과 FMR은 모두 잘못 분류되는 비율을 나타내며, 각각 진정 및 위조 매치가 대상이다. FNMR@FMR은 특정 FMR 수준에서의 FNMR 값을 의미한다. 이 지표를 통해 보안성(낮은 FMR에서 위조 매치 식별 성능)과 편리성(낮은 FNMR에서의 진정 매치 식별 성능)을 어떻게 균형있게 처리하는지 파악할 수 있다.

- **수신자 조작 특성(Receiver Operating Characteristic, ROC)**: 수신자 조작 특성 곡선은 다양한 임계값에서의 민감도와 위양성 비율 간의 관계를 시각적으로 나타낸다. ROC를 이용한 분류 성능 지표에는 AUC(Area Under the Curve)를 이용하였으며, 값이 1에 가까울수록 성능이 뛰어난 것을 의미한다.

IV. 실험 결과

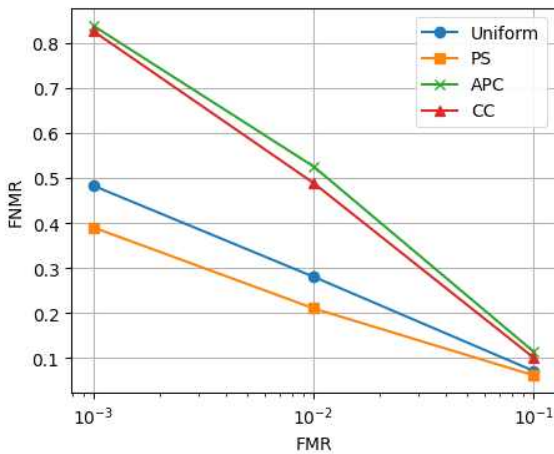


그림 2. 가중치 전략에 따른 FNMR@FMR

1) **FNMR@FMR**: 그림 2는 다양한 FMR 수준에서 각 가중치 전략의 FNMR 값을 나타낸다. PS 가중치 전략은 모든 FMR 수준에서 가장 낮은 FNMR을 기록하였으며, Uniform, CC 및 APC 순서로 높은 FNMR 값을 확인할 수 있다.

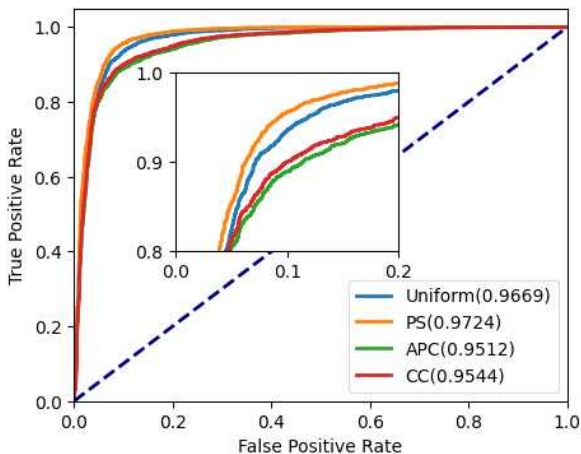


그림 3. 가중치 전략에 따른 ROC 곡선과 AUC 값

2) **ROC**: 그림 3은 각 전략 별 ROC 곡선 및 이에 상응하는 AUC 값을 나타낸다. PS 가중치 전략은 AUC 값이 가장 높아 전체적으로 가장 뛰어난 성능을 보여 다양한 상황에서 얼굴 검증에 매우 효과적임을 나타내었다. Uniform 전략 또한 비교적 높은 AUC 값으로 안정적인 성능을 보였다.

V. 결론

본 논문에서는 EMD 기반 집합 간 거리 얼굴 검증의 성능에 미치는 다양한 가중치 전략의 영향을 조사했다. 실험 결과, PS 전략이 EMD의 성능을 가장 크게 향상할 수 있음을 확인했다. 실험에서 각 전략의 복잡도는 Uniform, PS, APC 그리고 CC 순으로 증가한다. 복잡도가 증가하면 더 많은 정보를 고려하게 되므로 더 나은 성능을 기대할 수 있다. 하지만 본 논문을 위한 실험 결과에서는 복잡도가 항상 성능 향상으로 이어지지 않았다.

APC와 CC는 복잡한 상호작용을 고려하지만 그만큼 노이즈에도 민감할 수 있다. 이러한 결과로 제한된 상황에서 높은 성능을 발휘하지 못한 것으로 예상된다. 반면, PS와 Uniform은 상대적으로 단순하고 노이즈의 영향을 덜 받을 수 있기 때문에, 다양한 상황에서 더 안정적인 성능을 보일 수 있었던 것으로 해석된다. 특히 PS 전략은 동일한 목적 내의 특징 벡터에 적절한 가중치를 부여함으로써 신뢰할 수 있는 매칭 결과를 제공하였다. 수행한 실험들의 결과는, 단순한 전략이 오히려 다양한 상황에서 강력한 성능을 발휘할 수 있음을 시사한다. 또한 PS 전략은 집합 내 구조적인 정보를 효율적으로 반영하여 모든 평가 지표에서 안정적이고 가장 높은 성능을 달성하였다. 결론적으로, 최선의 성능을 얻기 위해서는, 주어진 데이터 특성과 문제의 요구사항에 따라 복잡도와 단순성 간의 균형을 맞추는 것이 중요함을 알 수 있었다.

ACKNOWLEDGMENT

This work was supported by Institute of Information & communications Technology Planning & Evaluation (IITP) grant funded by the Korea government (MSIT) [RS-2024-00395401, Development of VFX creation and combination using generative AI].

참고 문헌

- [1] Cevikalp, Hakan, and Bill Triggs. "Face recognition based on image sets." 2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. IEEE, 2010.
- [2] Phan, Hai, and Anh Nguyen. "DeepFace-EMD: Re-ranking using patch-wise earth mover's distance improves out-of-distribution face identification." Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2022.
- [3] Maze, Brianna, et al. "Tarpa janus benchmark-c: Face dataset and protocol." 2018 international conference on biometrics (ICB). IEEE, 2018.
- [4] Deng, Jiankang, et al. "Arcface: Additive angular margin loss for deep face recognition." Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2019.