

인공지능과 시 읽기: 기계 해석과 인간 이해의 접점

김민서 (연세대학교)

Word Embedding

컴퓨터가 인간의 언어를 이해하고 사용하는 방식은 워드임베딩 기술에 근거한다. 워드임베딩이란 단어를 숫자 배열(vector)로 변환하는 방법으로, 컴퓨터가 인간의 언어를 해석하고 처리할 수 있도록 돋는 자연어 처리 기법 중 하나다. 이 기술은 한 단어의 의미를 개별적으로 규정하기보다는, 해당 단어가 다른 단어들과 맺는 관계를 기반으로 정의한다는 관점에 기반한다. 워드임베딩은 보통 단어를 고차원 공간에서 밀집된 (low-dimensional, dense) 벡터로 표현하며, 단어들 간의 관계(의미적 유사성 또는 문맥적 관련성)를 벡터 공간에서 상대적인 위치로 나타낸다. 이를 통해 단어뿐 아니라 문장, 문단, 또는 더 큰 규모의 텍스트도 벡터로 표현할 수 있다.

Cosine Similarity

두 표현이 얼마나 가까운지, 즉 의미상 얼마나 유사한지 확인하기 위해 코사인 유사도(cosine similarity)를 계산한다. 코사인 유사도(cosine similarity)는 두 벡터 간의 방향적 유사도를 측정하는 방법으로, 두 벡터가 이루는 각도의 코사인 값을 이용한다. 수학적으로 코사인 유사도는 두 벡터의 내적(inner product)을 각 벡터의 크기(norm)로 나눈 값으로 계산된다. 이 값은 -1에서 1 사이의 범위로 나타나며, 값이 1에 가까울수록 두 벡터가 유사한 방향을 가짐을 의미한다. 0에 가까울수록 무관하고, -1에 가까울수록 반대 방향을 갖는다. 텍스트 데이터를 벡터 공간 모델로 변환한 후, 각 벡터 간의 코사인 유사도를 계산함으로써 문서 간의 유사성을 정량적으로 평가할 수 있다.

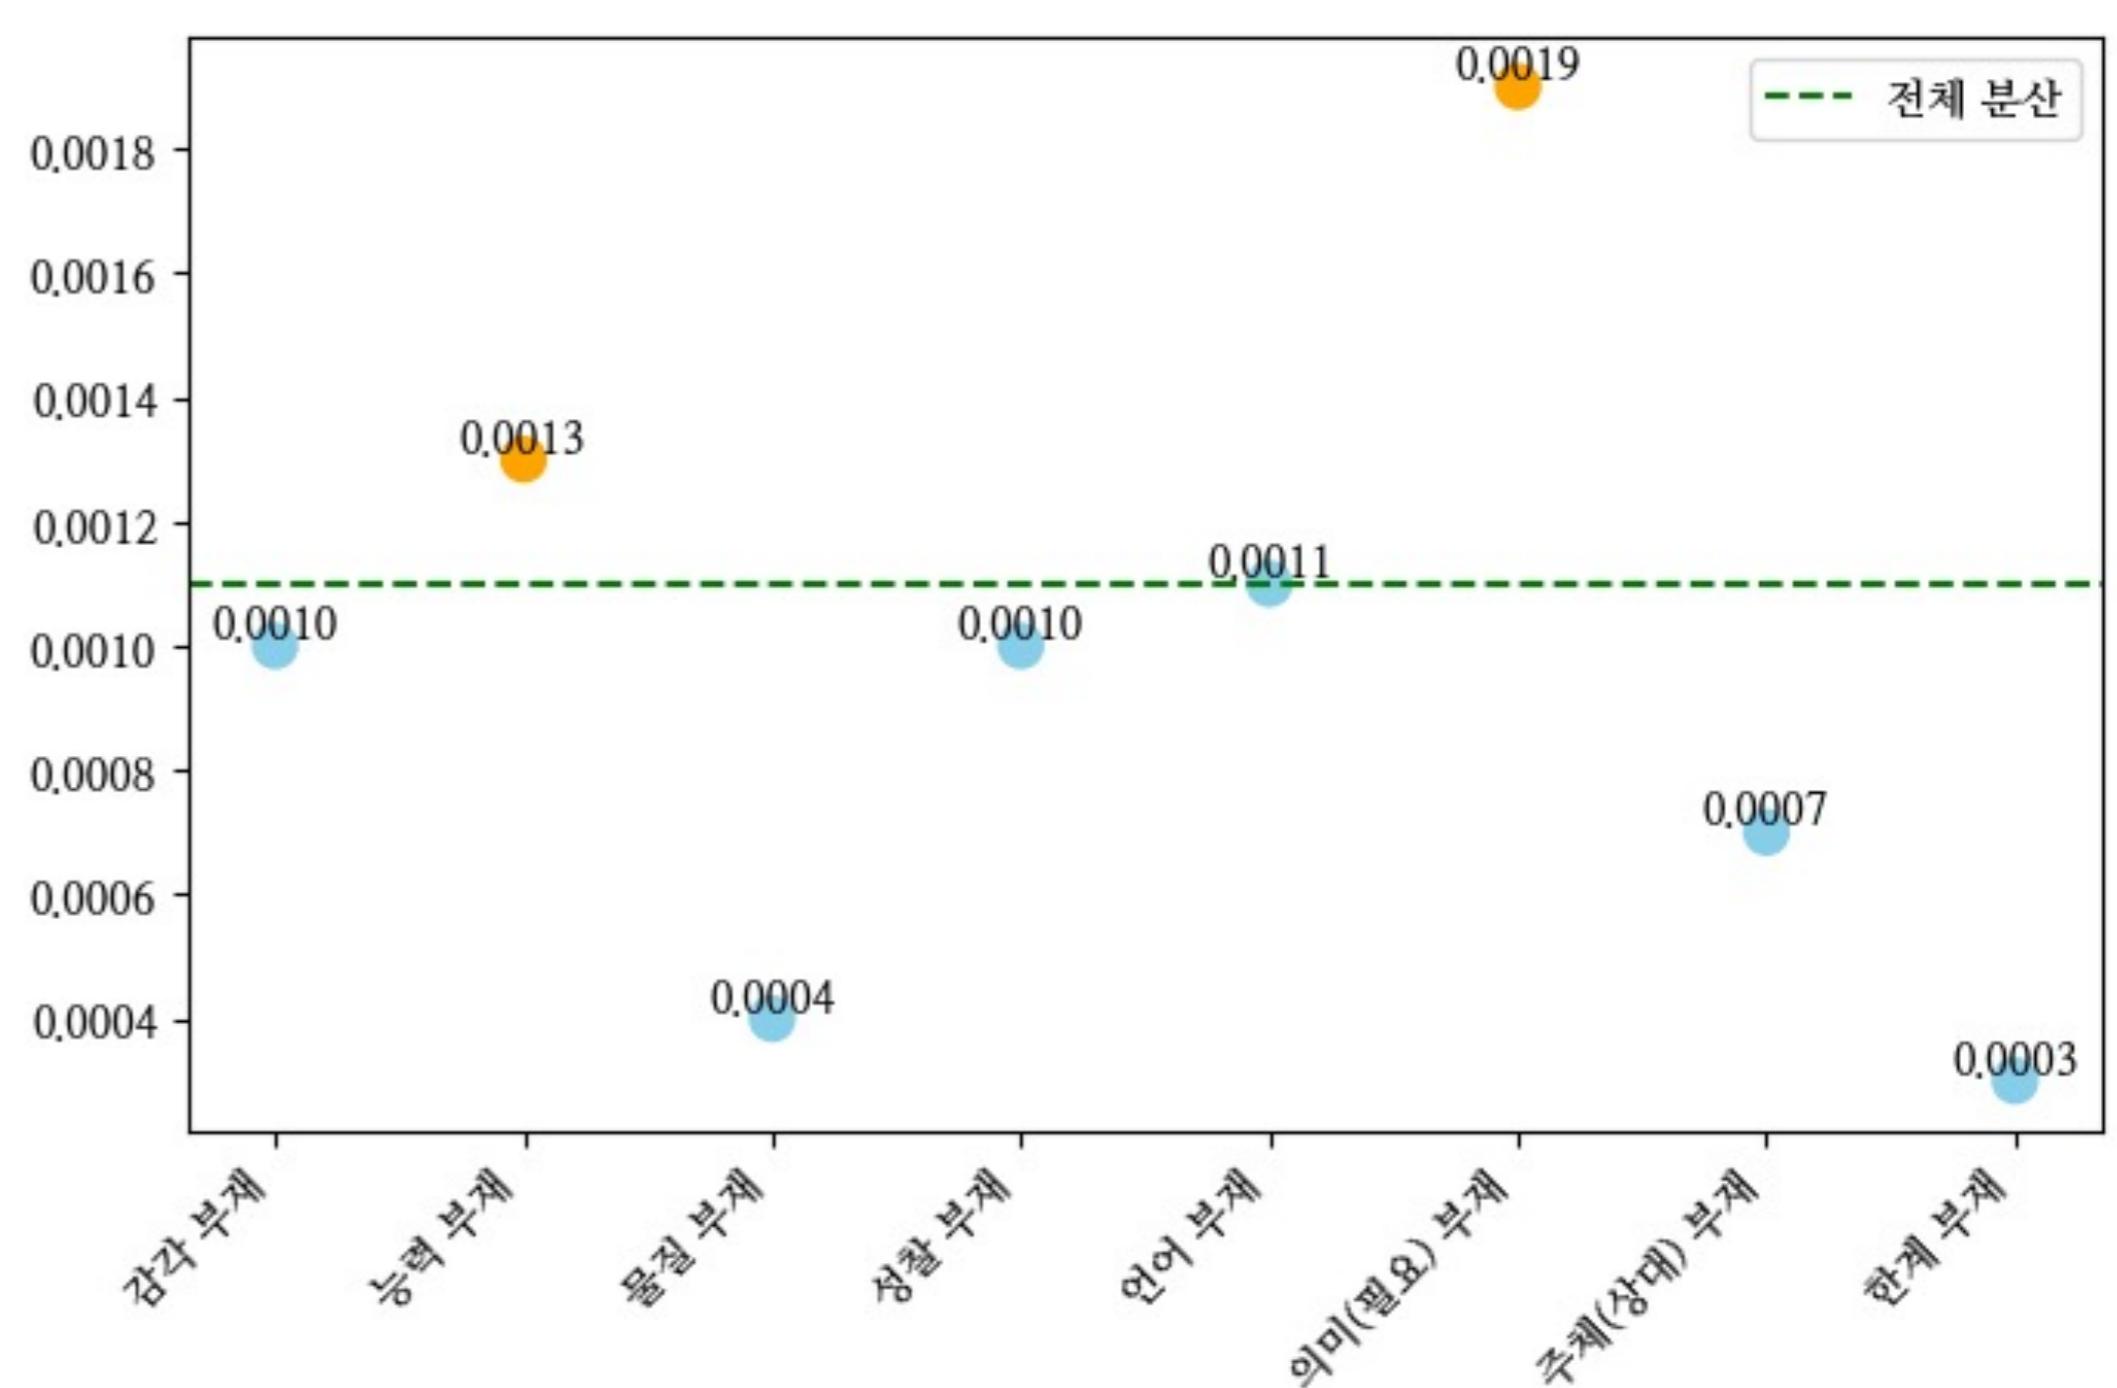
시적 의미를 계량화하거나 수치화할 수 있는가?
계량된 결과는 인간의 이해와 해석의 범주 안에서 의미를 얻을 수 있는가?



연구 과정 및 결과

- 형용사 '없다'의 어근 '없'이 등장하는 시 100편 선정
- 100편의 시에서 '없'다고 표현된 부재의 대상을 추출하고 유형화

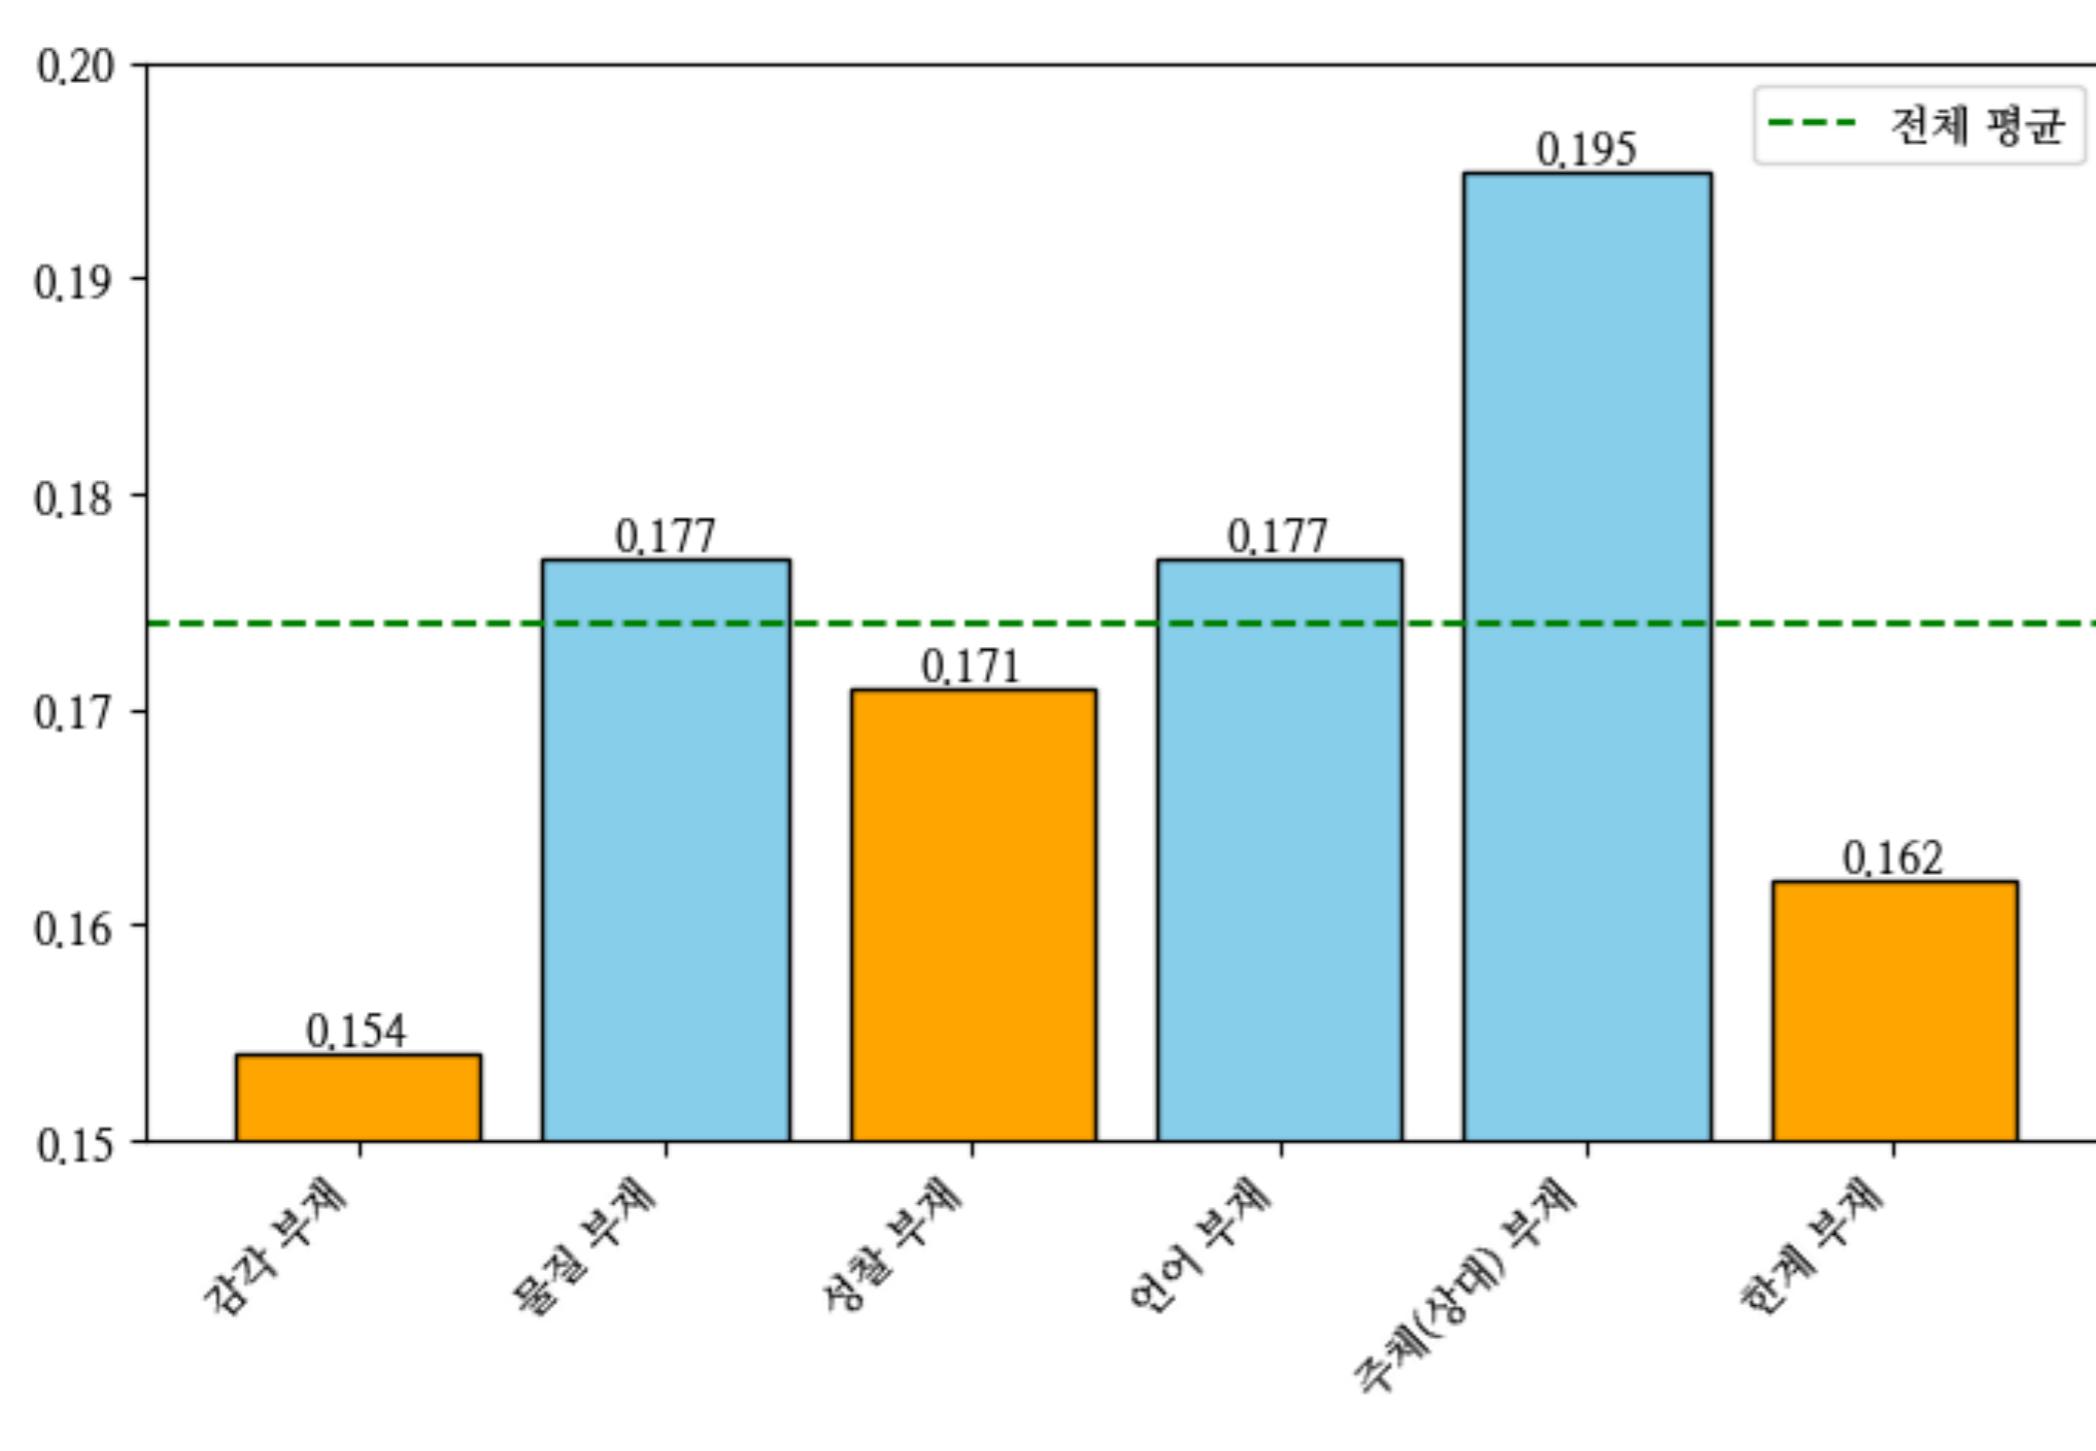
부재의 대상 및 구문	부재의 대상에 따른 유형 구분						
	감각	능력(기력)	물질	주체(상대)	성찰	언어	의미(필요)
스리	-할 수 (없다)	잔	너, 당신	찾다	어처구니(없다), 어이(없다)	의미	한(없이)
빛	-한 일 (없다)	돈	나	미련, 회한, 동요, 설움	높이, 폭, 규정, 표준	이유, 목적, 필요, 소용	수(없이)
	힘, 생기, 맥	지휘편	-한 사람	헤아리다	터무니(없다)	쓸데(없다), 보잘것(없다), 못(없다)	
	집, 은거할 곳, 바닥	정체	정신, 집중, 반성, 속련	말, 이름, 질문, 약속	성과, 효과, 값		
	냉방장치	적	중용, 중립	~할 리 (없다)			
	타구	그림자					
	에미						
작품 수	10	23	12	13	12	10	4



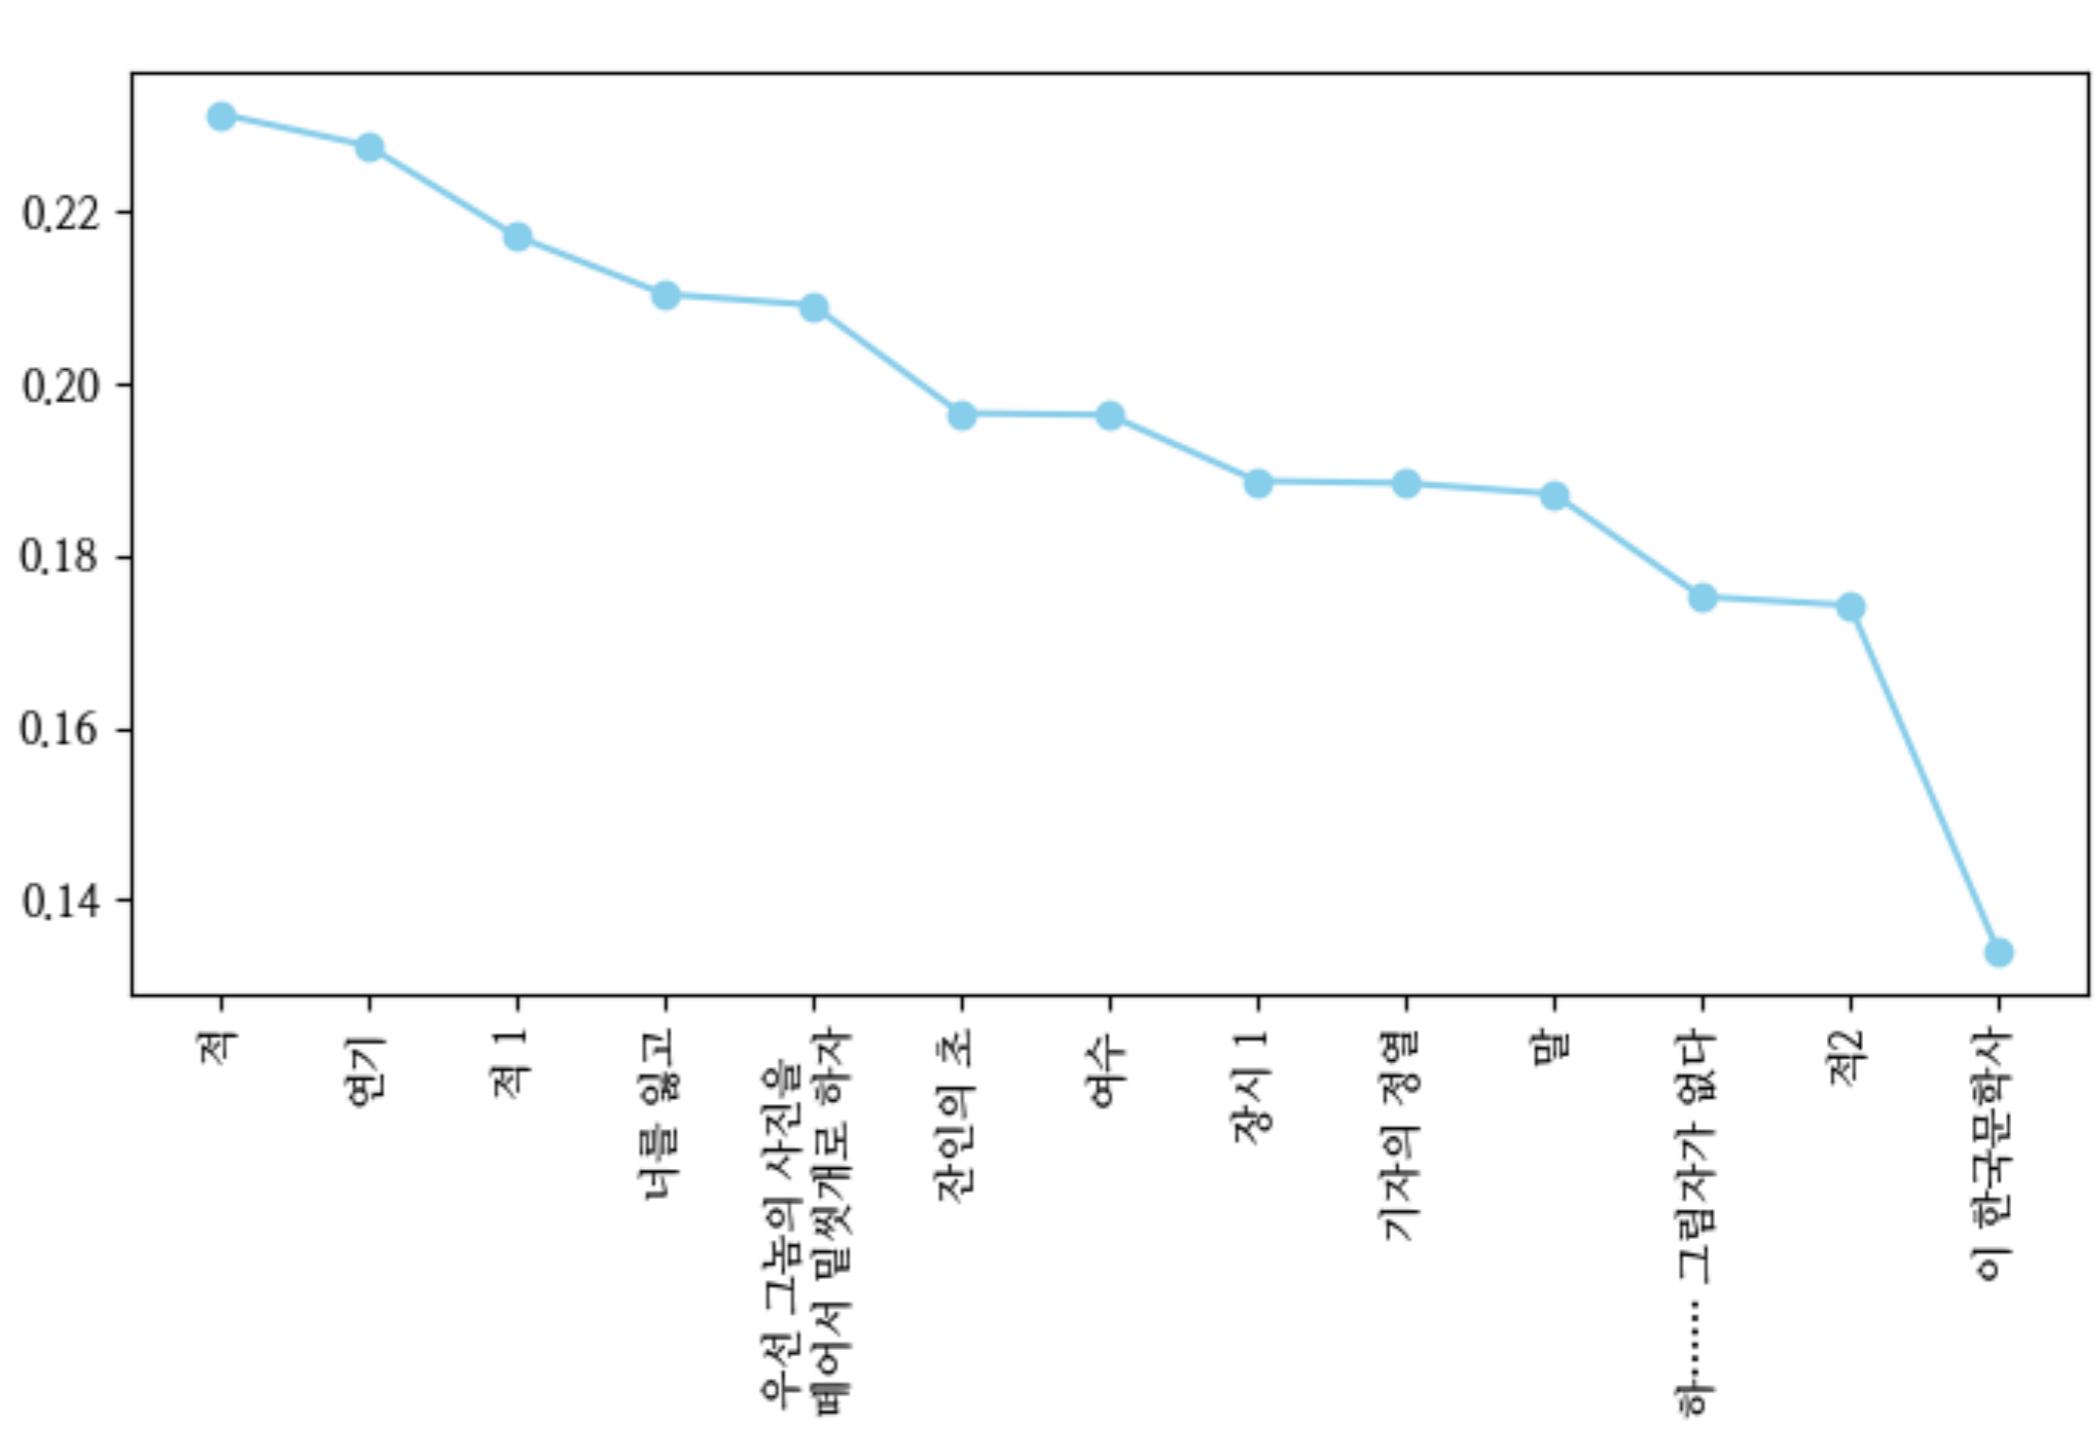
어학적 분류 기준

코사인 유사도 유형별 분산

- 100편의 시를 임베딩하여 벡터화하고 어근 '없'과의 코사인 유사도 측정
- 유형별 코사인 유사도의 분산을 분석하여 어학적 분류 기준과의 일치 여부 검토
- 가장 높은 평균 코사인 유사도를 가지는 유형 도출: 주체(상대) 부재



코사인 유사도 유형별 평균



주체(상대) 부재 유형의 작품별 코사인 유사도