

한국어 손글씨 인식을 위한 TrOCR 모델 미세조정

박시은, 안진현*

명지대학교

plscew@mju.ac.kr, *wlsqus3396@mju.ac.kr

A Study on Fine-Tuning TrOCR for Korean Handwritten Text Recognition

Sieun Park, Jin-hyun Ahn*

Myongji Univ.

요약

본 연구는 한국어 손글씨 문장 인식 성능 향상을 위해 Transformer 기반 OCR 모델인 TrOCR을 한국어 손글씨 데이터에 맞추어 파인튜닝하였다. 제안 모델은 Vision Encoder-Decoder 구조를 활용하여 손글씨 이미지로부터 문장 텍스트를 생성하며, 영어 중심 사전학습 모델을 한국어 손글씨 환경에 효과적으로 전이하는 것을 목표로 한다. 이를 위해 학습 안정성과 수렴을 고려한 2단계 학습 전략을 적용하였다. 1단계에서는 인코더를 고정하고 디코더를 중심으로 학습하여 한국어 문자 분포에 적응시켰으며, 2단계에서는 인코더의 후반부 레이어와 정규화 계층을 해제하여 미세조정을 수행하였다. 성능 평가는 Character Error Rate(CER)를 지표로 수행하였고, 실험 결과 CER는 1.27에서 0.14로 감소하여 한국어 손글씨 문장 인식 성능 향상을 확인하였다.

I. 서론

본 연구는 캡스톤 디자인 프로젝트 IVO의 기능 중 하나인 한국어 손글씨 인식 모듈을 구현하기 위해 수행되었다. IVO 프로젝트는 스마트워치 기반 제스처 입력과 OCR을 결합하여 발표·강의 상황에서 슬라이드 제어를 지원하고, 필기/판서 내용을 텍스트로 변환해 화면에 제공하는 발표·강의 보조 시스템이다.[1] 이러한 환경에서 손글씨 인식 성능은 시스템의 실사용성과 사용자 경험에 직접적인 영향을 주므로, 한국어 손글씨 문장 인식 성능 확보가 필요하다.

이를 위해 본 연구에서는 Transformer 기반 OCR 모델인 TrOCR을 기반 모델로 선택하고, 한국어 손글씨 데이터에 맞추어 파인튜닝하여 문장 단위 인식 성능을 개선하고자 한다.

II. 관련 연구

손글씨 인식은 이미지로부터 텍스트를 복원하는 문제로, 최근에는 입력 이미지를 특징으로 변환한 뒤 텍스트 시퀀스를 생성하는 인코더-디코더 기반 접근이 널리 사용된다. 이 방식은 글자 형태가 불규칙하거나 문장 길이가 긴 환경에서도 문맥 정보를 활용해 안정적으로 문자열을 생성할 수 있다.

최근 손글씨 텍스트 인식 분야에서는 Transformer 기반 인식이 활발히 연구되고 있다. ViTSTR은 ViT 인코더를 활용해 전역 문맥 특징을 추출하고 이를 기반으로 단어/문장 수준 텍스트를 예측하는 방식으로 성능을 얻는다.[2] PARSeq은 permuted autoregressive 학습을

통해 디코딩 순서 의존성을 완화하여 다양한 길이의 텍스트에 대해 강건한 성능을 보인다.[3] ABINet은 시각 인식 결과를 언어 모델로 반복 보정하여 철자 및 문맥 오류를 줄이는 방향으로 성능을 향상시킨다.[4] 다만 이러한 모델들은 사전학습 데이터 분포와 목표 도메인 간 차이가 클 경우 성능 저하가 발생할 수 있어, 실제 적용 환경에 맞춘 전이학습 및 파인튜닝 전략이 중요하다.

TrOCR은 Transformer 기반 end-to-end OCR 모델로서 사전학습 모델을 다양한 텍스트 인식 환경에 전이하는 전략을 제시하였다. 본 연구는 TrOCR의 전이학습 특성을 활용하여 한국어 손글씨 문장 인식 성능을 향상시키는 데 초점을 둔다.[5]

III. 실험

본 연구는 Transformer 기반 OCR 모델인 TrOCR을 사용하여 한국어 손글씨 문장 이미지를 텍스트로 변환하는 문제를 다룬다. 초기 가중치는 영어 손글씨에 대해 사전 학습된 microsoft/trocr-base-handwritten 체크포인트를 사용하였고, 이를 한국어 손글씨 데이터에 맞추어 단계적으로 파인튜닝하였다.

데이터는 AI Hub의 ‘한국어 손글씨 이미지’ 데이터셋을 기반으로 구성하였다. 파일명 기반 매칭을 통해 이미지-라벨 쌍을 구성한 뒤 학습/검증 세트로 분리하여 학습 및 평가에 활용하고 입력 이미지는 PIL을 통해 로드한 뒤 RGB로 변환하여 사용하였다.

한국어 손글씨 문장 인식 성능을 안정적으로 향상시키기 위해 총 2단계 파인튜닝 전략을 사용하였다. 이는 영어 중심으로 사전 학습된 TrOCR의 표현을 무리하게 한

번에 바꾸기보다, 단계적으로 한국어 데이터 분포에 적응시키는 방식이다.

Stage 1에서는 비전 인코더의 파라미터를 고정하고, 디코더를 중심으로 학습을 수행하였다. 이를 통해 사전학습 모델이 보유한 기본적인 손글씨 인식 표현은 유지하면서, 한국어 문장 생성에 필요한 문자 분포 및 디코딩 패턴을 우선적으로 적응시키는 것을 목표로 하였다.

Stage 2에서는 Stage 1 체크포인트를 초기값으로 사용하되, 인코더 전체를 학습하지 않고 마지막 2개 레이어와 LayerNorm 만 선택적으로 언프리징하여 추가 파인튜닝을 수행하였다. 또한 낮은 학습률($=1e-5$)을 적용해 과도한 파라미터 변화와 과적합을 방지하고, 한국어 손글씨의 시각적 분포에 부분적으로 적응하도록 유도하였다.

IV. 결과

성능 평가는 CER 을 사용하였다. CER 은 예측 문자열과 정답 문자열 사이의 편집거리를 기반으로 계산되며 치환(Substitution), 삭제(Deletion), 삽입(Insertion) 오류의 합을 정답 문장의 문자 수로 정규화한 값으로 정의된다.

$$CER = \frac{S + D + I}{N}$$

평가의 일관성을 위해 문자열은 유니코드 정규화(NFKC) 및 공백 정리를 수행한 후 CER 을 산출하였다. 동일한 검증 설정에서 사전학습 모델과 단계별 파인튜닝의 성능을 비교한 결과는 다음과 같다.

Model	Fine-tuning strategy	Generate CER
Baseline	Pretrained TrOCR	1.2765
Stage 1	Encoder frozen	0.2456
Stage 2	Partial unfreezing	0.1407

Stage 1 적용만으로도 CER 가 크게 감소하여 한국어 문자 분포 및 문장 생성 방식에 대한 적응 효과를 확인하였다. 이후 Stage 2에서 인코더의 일부 레이어를 선택적으로 unfreezing 하여 추가 학습을 수행한 결과 CER 가 0.1407 까지 추가로 감소하여, 한국어 손글씨의 시각적 분포에 대한 적응이 성능 향상에 기여했음을 확인하였다.

V. 결론

제안한 방법은 TrOCR 기반 Vision Encoder-Decoder를 한국어 손글씨 문장 데이터에 맞춰 파인튜닝하여 문장 인식 성능을 개선하였다.

학습 안정성과 도메인 적응을 위해 인코더 고정 기반 Stage 1과 인코더 부분 언프리징 기반 Stage 2로 구성된 2단계 파인튜닝 전략을 적용하였다. 검증 샘플 300개 기준 generate CER 은 baseline 1.2765에서 Stage 1 0.2456, Stage 2 0.1407로 감소하여 한국어 손글씨 문장 인식 성능 향상을 확인하였다.

향후에는 더 큰 규모의 데이터로 추가 검증을 수행하고, 다양한 필기체 및 촬영 조건에 대한 일반화 성능을 평가할 예정이다. 또한 언어모델 결합 기반 후처리(교정)를 적용하여 인식 오류를 줄이고, 영문과 한국어가 혼합된 문장에서도 안정적으로 인식할 수 있도록 성능을 향상시킬 계획이다.

ACKNOWLEDGMENT

본 과제(결과물)는 2025년도 교육부 및 경기도의 재원으로 경기 RISE 센터의 지원을 받아 수행된 지역혁신중심

대학지원체계(RISE)의 결과입니다.

(2025-RISE-09-A15)

This research was supported by the Regional Innovation System & Education RISE) program through the Gyeonggi RISE Center, funded by the Ministry of Education MOE) and the Gyeonggi-do, Republic of Korea.

(2025-RISE-09-A15)

참 고 문 헌

- [1] blueion0612, IVO (Smartwatch-Based Presentation & Lecture Assistance System), GitHub repository, <https://github.com/blueion0612/IVO>
- [2] Atienza, R., "Vision Transformer for Fast and Efficient Scene Text Recognition," arXiv:2105.08582, 2021.
- [3] Bautista, D., and Atienza, R., "Scene Text Recognition with Permuted Autoregressive Sequence Models," arXiv:2207.06966, 2022.
- [4] Fang, S., Xie, H., Wang, Y., Mao, Z., and Zhang, Y., "Read Like Humans: Autonomous, Bidirectional and Iterative Language Modeling for Scene Text Recognition," arXiv:2103.06495, 2021.
- [5] Li, M., et al., "TrOCR: Transformer-based Optical Character Recognition with Pre-trained Models" arXiv:2109.10282, 2021.