

# 양방향 RNN과 학술용어사전을 이용한 영문학술문서 교정 방법론

## Methodology of Automatic Editing for Academic Writing Using Bidirectional RNN and Academic Dictionary

노영훈(Younghoon Roh)\*, 장태우(Tai-Woo Chang)\*\*, 원종운(Jongwun Won)\*\*\*

### 초 록

자연어 처리 기술을 접목한 컴퓨터 보조 언어 학습 연구가 진행되고 있지만, 기존 영문교정은 일반적인 영어 문장을 기반으로 연구되어, 격식을 갖춘 문체와 전문적인 기술 용어를 사용하는 학술 영문의 경우 그 특성을 반영하지 못한 교정 결과를 제공한다. 또한 문장의 문법적 완성도 향상을 위한 다수의 기존 연구는 교정을 통한 문장 전달력 향상의 한계점이 존재한다. 따라서, 본 논문은 전문적인 기술 용어 사용을 기반으로 문장의 명확한 의미 전달을 목적으로 하는 학술 영문을 위한 자동 교정 방법론을 제안한다. 제안 방법론은 오타자 교정과 문장 전달력 개선 두 단계로 구성된다. 오타자 교정 단계는 입력된 오타자와 문맥에 적합한 교정 단어를 제공한다. 문장 전달력 개선 단계는 원문과 교정문의 쌍으로부터 학습할 수 있는 양방향 순환신경망 기계번역 사후교정 모델을 기반으로 문장의 전달력을 개선한다. 실제 교정 데이터를 이용한 실험을 수행하였으며, 정량적·정성적 분석을 통해 제안 방법론의 우수성을 검증하였다.

### ABSTRACT

Artificial intelligence-based natural language processing technology is playing an important role in helping users write English-language documents. For academic documents in particular, the English proofreading services should reflect the academic characteristics using formal style and technical terms. But the services usually does not because they are based on general English sentences. In addition, since existing studies are mainly for improving the grammatical completeness, there is a limit of fluency improvement. This study proposes an automatic academic English editing methodology to deliver the clear meaning of sentences based on the use of technical terms. The proposed methodology consists of two phases: misspell correction and fluency improvement. In the first phase, appropriate corrective words are provided according to the input typo and contexts. In the second phase,

---

This work was supported by the GRRC program of Gyeonggi province. [(GRRC KGU 2020-B01), Research on Intelligent Industrial Data Analytics].

\* First Author, Researcher, Intelligence & Manufacturing Research Center, Kyonggi University (yesrohyh@gmail.com)

\*\* Corresponding Author, Professor, Department of Industrial & Management Engineering / Intelligence & Manufacturing Research Center, Kyonggi University (keenbee@kgu.ac.kr)

\*\*\* Co-Author, Principal Researcher, Korean Railroad Research Institute (juwon@krri.ac.kr)

Received: 2022-04-05, Review completed: 2022-04-27, Accepted: 2022-05-06

the fluency of the sentence is improved based on the automatic post-editing model of the bidirectional recurrent neural network that can learn from the pair of the original sentence and the edited sentence. Experiments were performed with actual English editing data, and the superiority of the proposed methodology was verified.

**키워드** : 양방향 RNN, 자동사후교정, 영문교정, 학술용어사전  
Bidirectional RNN, Automatic Post Editing, English Editing, Academic Dictionary

## 1. 서 론

자연어처리(Natural Language Processing, NLP)는 자연어와 컴퓨터 사이의 다리 역할을 하며 관심이 증가하고 있다[41]. NLP를 통해 언어 데이터를 기반으로 인간의 소통 구조와 패턴을 분석할 수 있어서, 기계가 인간의 언어를 이해하고 처리 및 분석할 수 있도록 지원한다. NLP 기술은 강력한 모델을 개발하는 데 도움이 되는 데이터 기반 접근 방식에 의존하고 있다[8, 65, 68]. 최근 이미지 인식과 음성인식에서 높은 성능을 보인 인공지능 기반의 방법론이 컴퓨팅 능력의 발전과 축적된 빅데이터를 기반으로 NLP 분야에 접목되고 있다[8, 68]. 인공지능 기반 NLP 방법론은 전통 방식에서 새로운 데이터 기반 접근 방식으로 패러다임 변화를 가져왔다.

오타자 및 영문법 자동 교정은 작성된 영어 문장의 오류를 교정하는 작업으로서 NLP의 다양한 분야 중 활발히 연구되고 있는 분야이다[61]. 자동 영문교정은 영어 원어뿐만 아니라, 영어 학습자들도 작문 능력 향상을 위해 보조 도구로써 사용된다[40]. 자동 영문교정은 사용자가 입력한 문장을 구성하는 단어 또는 구를 기반으로 입력된 오류를 감지하고, 해당 오류를 교정하기 위한 교정 후보 단어 또는 구를 사용자에게 제안한다. 오늘날 자동 영문교정은

작문 관련 응용 프로그램에서 분리할 수 없는 구성요소이다.

다수의 영문교정 연구들은 기계번역으로부터 파생되어 연구되었다. 신경망 기반의 접근 방식은 최근 문법오류교정(Grammatical Error Correction, GEC)의 성능 향상을 주도하였으며, 전통적인 방법론보다 더 효과적임을 증명하였다[10, 29]. 그렇지만 GEC 학습을 위한 데이터가 상대적으로 제한적이어서[44], 최근 GEC 연구는 오류 유형 정보가 포함된 학습 데이터를 기반으로 데이터 희소성을 해결하려는 방법에 초점을 맞추고 있다[25, 30, 38, 69]. 데이터 희소성 해결 연구는 'Building Educational Applications' 워크숍에서 발표된 BEA-2019의 shared task를 기반으로 진행되고 있으며, BEA-2019 연구는 상대적으로 적은 학습 데이터를 기반으로 더 높은 성능을 보인다[7]. 또한, 신경망 기계번역을 기반으로 한 GEC 모델은 학습 데이터의 노이즈에 민감한 것으로 나타났다[31].

영문교정에 관한 기존 연구들은 일반 영문에 초점이 맞추어진 한계점을 지닌다. 기존 연구들은 '일반 영문'과 다른 '학술 영문'의 특성을 반영하지 못한다. 학술 영문은 일반 영문과 크게 세 가지의 차이점이 있다. 첫째, 학술 영문은 일반 영문보다 격식적인 문체와 기술적인 용어를 사용하며, 전문 지식을 포함하고 있다

[3, 58]. 두 번째, 학술 영문은 정확하고 명확한 문장의 의미를 전달하기 위해 복잡한 문장의 사용은 지양되며, 짧고 간결한 문장이 주로 사용된다[24, 59, 62]. 마지막으로, 학술 분야 및 학술 논문 목적에 따라 구조화된 작문 형식이 있다[48].

본 연구에서 다루는 추가적인 문제점은 기존 영문교정 연구가 문장의 전달력을 개선할 수 없다는 점이다. 문장 전달력 개선은 문법적 완성도뿐만 아니라 문장의 명확성과 자연스러움을 높인다는 점에서 단순 문법 교정과 차이점이 존재한다. <표 1>과 같이 문법 교정과 전달력 교정의 예시[18]를 보인다. 단순 문법 교정은 문장의 문법적 완성도를 높이지만, 부자연스러운 문장이다. 하지만 문장 전달력 교정은 문법 교정 이상으로 더 광범위하게 변경되었으며, 교정된 문장은 더 자연스럽고, 명확하게 문장의 의미를 전달한다. 학술 영문에서는 정확한 사실을 독자에게 제공해야 하므로, 문법적 완성도가 높아야 하며 명확한 의미를 내포하고 있는 문장을 작성하는 것이 요구된다.

<표 1> 문법 교정과 문장 전달력 교정 비교 예시(18)

Original	they just creat impression such well that people are drag to buy it.
Grammatical edit	They just create an impression so well that people are dragged to buy it.
Fluency edit	They just create such a good impression that people are compelled to buy it.

따라서 본 연구에서는 입력된 영어 문장 중 오타자가 존재하면 오타자를 인식하고 교정 단

어를 제공하며, 문장 전달력 개선을 통해 문장의 명확성을 높일 수 있는 학술용어사전과 딥러닝 기법을 사용하는 양방향 순환신경망 (Bidirectional Recurrent Neural Network, BRNN) 자동 사후교정(Automatic Post-Editing, APE) 모델 기반의 자동 학술 영문교정 방법론을 제안한다. 이 방법론은 사용자가 입력한 학술 영어 문장을 기반으로 오타자 및 문장 전달력 개선을 위한 교정 결과를 사용자에게 제공한다. 제공된 교정 결과는 입력된 문장의 문맥을 기반으로 최선의 문장 전달력 개선 사항을 사용자에게 제공한다. 사용자는 입력 문장의 길이와 무관하게 문장 전달력이 향상된 출력 문장을 얻을 수 있다. 교정 전문가로부터 수집된 실제 영문교정 데이터셋을 이용한 실험을 통해 제안 방법론의 성능이 비교 방법론 대비 우수함을 정량적, 정성적으로 확인하였다.

이하 논문은 다음과 같이 구성된다. 제2장에서 딥러닝 기반의 NLP 방법론과 영문교정에 관한 기존 연구와 오픈 데이터를 나열한다. 제3장에서 오타자 교정 및 문장 전달력 개선을 위한 방법론을 제안한다. 제4장에서 실제 원어민 에디터가 교정한 데이터를 활용한 실험 결과를 기반으로 제안 방법론의 유효성을 검증한다. 마지막으로 제5장에서 본 논문의 기여점과 향후 연구에 대해 제시한다.

## 2. 영문교정 관련 문헌 연구

### 2.1 딥러닝 기반의 NLP

본 절에서는 학술 영어 작문 shared task에서 활용된 딥러닝 기반 관련 연구 중 문장의 구성

단어가 순차적으로 입력되는 특성을 고려하기 위한 RNN 계열의 모델을 설명한다. 학술 영어 작문은 NLP 분야에서 상당한 주목을 받아 왔다[37, 64, 66].

RNN은 음성과 문장 등 순서를 가진 시계열 데이터에 적합한 모델이다. 그러나 현재 단계로부터 오래전에 입력된 정보를 잊어버릴 수 있는 장기의존성(long-term dependency) 문제가 발생하게 되고, 이를 해결하기 위해 입력 데이터를 장기간 저장할 수 있는 LSTM(Long Short-Term Memory)과 GRU(Gated Recurrent Unit) 등의 방법론이 개발되었다.

RNN에 cell-state를 추가한 LSTM 모델이 제안된 이후 꾸준히 연구되어, NLP 분야의 사용 방법론으로 자리 잡았다[4, 20, 21, 22]. LSTM은 기본적으로 RNN과 같은 구조이지만, 각 state에 gate를 추가함으로써 다음 단계에 전달할 정보를 선택하고, cell-state를 기반으로 결과를 업데이트한 후 다음 단계에 전달한다.

GRU 모델[11]은 LSTM과 달리 별도의 cell-state를 설정하지 않고 학습하므로, 필요한 매개변수의 수가 LSTM보다 적어 학습에 필요한 데이터의 양도 적으며 학습 속도가 빠르다. GRU는 LSTM의 input gate와 forget gate의 역할을 하는 update gate와 reset gate를 활용하여 학습 속도를 높일 수 있었다.

BRNN은 특정 시점에서의 출력값이 이전 시점과 이후 시점의 데이터를 모두 고려하여 학습을 진행하는 RNN의 확장 모델이다[54]. 기본 RNN에서 이전 시점 데이터의 영향을 많이 받는 단점을 해결하기 위해, BRNN은 순방향과 역방향으로 분리된 순환신경망을 기반으로 이전·이후 시점의 데이터를 모두 학습한다. 입

력값은 순방향과 역방향 두 hidden state로 입력되어, 순방향 RNN과 역방향 RNN의 두 출력값을 하나로 합쳐 하나의 값을 출력한다.

RNN 기반의 인코더-디코더 구조 모델은 음성인식[2] 분야뿐만 아니라, 기계번역[23] 분야에서 뛰어난 성능을 보인다. 인코더-디코더 구조는 입력 데이터를 압축하여 데이터를 함축하고 있는 컨텍스트 벡터로 표현하는 인코더와 이 정보를 입력받아 텍스트를 생성하는 디코더로 구성된다. 기본적인 RNN 인코더-디코더 모델[9]의 구조는 기계번역을 수행하기 위해 고안된 것이다. 인코더에 입력되는 변수의 길이와 디코더에서 출력되는 변수의 길이가 같아야 하는 단점을 가진다.

## 2.2 영문교정용 오픈 데이터

영문교정 인공지능 모델 학습을 위해 자주 사용되는 오픈 데이터는 두 가지 유형으로 나눌 수 있다. 첫 번째는 유형화된 오류 정보가 포함된 텍스트 데이터이다. 어노테이터가 오류 텍스트를 활용하여 오류를 구분한 데이터를 의미하며, NUCLE(National University of Singapore Corpus of Learner English), FCE(First Certificate in English)가 포함된다.

두 번째는 유형화된 오류 정보 없이 원본 텍스트와 교정 텍스트로 구성된 병렬 코퍼스 데이터이다. lang-8.com은 온라인 영어 학습자에 의해 수집된 Lang-8 Corpus of Learner English 데이터가 포함된다. Lang-8 버전 2에서는 버전 1보다 두 배 많은 데이터가 수집되었다. JFLEG(Johns Hopkins University Fluency-Extended Grammatical/Ungrammatical corpus)은 교정 시 문장 전달력 향상을 평가하기

위한 데이터를 공개하였다[47]. 이들 데이터를 비교하면 <표 2>와 같다.

<표 2> 영문교정 오픈 데이터 요약표

Open data	Number of sentences	Average number of characters in a sentence	error type information	Fluency information
NUCLE	59,000	115	O	X
FCE	34,000	74	O	X
Lang-8	1,900,000	56	X	O
JFLEG	1,500	94	X	O

## 2.3 문법오류교정(GEC)

2000년대의 GEC 모델은 대부분 Language Tool[46]과 ESL(English as a Second Language) Assistant[17] 등과 같이 파서를 사용하고, 언어 특성을 반영한 문법 규칙을 기반으로(Rule-based) 구성되었다. 여전히 규칙 기반 GEC 모델이 사용되지만, 데이터 기반 GEC 모델의 성능이 규칙 기반 GEC의 성능을 뛰어넘는 우수한 성능을 보인다.

한 언어를 다른 언어로 기계가 자동으로 번역하는 전통적인 통계적 기계번역(Statistical Machine Translation, SMT)은 베이스 정리를 활용한 noisy channel model에 기반을 두고 있다. 단어 또는 구를 다른 언어의 단어 또는 구에 매핑될 확률을 예측하는 모델이다. SMT 기반 GEC는 저품질의 영어를 고품질의 영어로 번역하는 기술이다. 병렬 코퍼스로부터 학습된 번역 모델은 다른 두 언어 문장의 단어 또는 구를 매핑하는 번역 프로세스와 동일하게 문법 오류와 교정된 문법 간의 관계를 학습할 수 있다[6].

다수의 연구에서 통계적 기계번역 모델을 GEC의 기초 프레임워크로 사용하고 있다.

다수의 신경망 기계번역(Neural Machine Translation, NMT) 기반 GEC는 인코더-디코더 프레임워크를 사용한다[29]. 인코더-디코더 프레임워크는 NMT를 위해 개발되었지만[8, 60], SMT와 인코더-디코더 프레임워크의 성능이 향상됨에 따라 같이 GEC에 적용된다[9]. NMT 기반 GEC는 SMT 기반 GEC보다 두 가지 장점이 있다. 첫 번째, NMT 기반 GEC의 인코더-디코더 프레임워크는 병렬 코퍼스로부터 입력 문장과 출력 문장의 관계를 매핑하여 학습한다. 두 번째, NMT 기반 GEC는 SMT 기반 GEC보다 비문법적 구문과 문장을 교정할 수 있는 효과적인 일반화 능력을 보유하고 있다[70]. 그러나 NMT 기반 GEC의 단점 중 하나는 블랙박스 모델이며, 학습 데이터의 품질에 따라 성능이 크게 좌우되는 것이다. 이로 인해 모델이 학습하지 못한 데이터가 입력되었을 때, 정확한 오류 원인 분석이 어렵다. 그런데도 NMT 기반 GEC는 현재 GEC 연구에서 가장 많이 연구되며, NMT와 SMT를 모두 사용한 연구도 다수 진행되고 있다[28].

## 2.4 기계번역 사후교정(APE)

초기 사후교정 방법론은 규칙 기반 사후교정 방식으로, 번역에서 자주 발생하는 오류 교정을 위해 교정 규칙을 번역문에 적용하였다[1, 33, 53]. 규칙 기반 사후교정 방법론은 교정 결과 품질 향상을 위해 SMT 기능을 추가한 하이브리드 사후교정 형태를 취했고[15, 36], 반복적인 오류 해결을 위해 통계적 접근 방식을 사용하였다[57]. 또한, 언어 형태학을 기반으로 사후

교정의 결과를 개선하려는 방법도 사용되었으며[42, 52], 사후교정 결과물에서 식별된 패턴 또는 문제 기반의 규칙 사후교정 연구도 진행되었다[14].

최근에는 인공지능영향을 적용한 사후교정 연구가 활발히 진행되고 있다[2, 9]. 인공지능영향 기반 사후교정은 소스 문장 대상의 인코더와 교정 문장을 디코딩하는 디코더로 구성된다. Multi-source Transformer 모델[28], BERT (Bidirectional Encoder Representations from Transformers)[12, 27, 39]를 이용한 모델이 우수한 성능을 보인다. 과거에는 규칙 및 통계 기반 기법 연구가 진행되었으나, 현재에는 인공지능영향 적용 연구가 주로 이루어지고 있다.

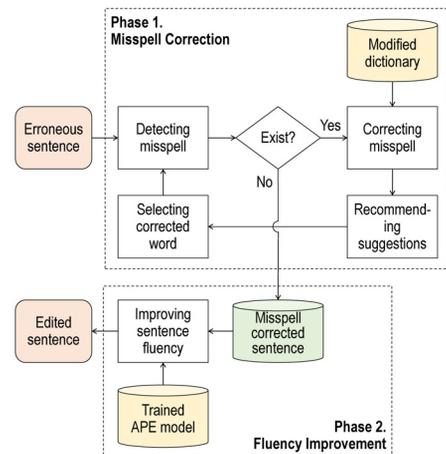
사후교정은 소스 문장과 번역문을 기반으로 사후교정 결과를 생성하기 위해 주로 연구되었지만, 1958년에 제안된[16], 소스 문장이 없는 번역문 기반의 단일 언어 사후교정 연구도 진행되었다. 단일 언어 사후교정의 핵심은 사후교정자가 소스 문장 없이 의미를 해석하고, 오류를 교정할 수 있는지 여부와 관련되어 있다. Krings[35]는 해당 의문점을 처음으로 연구하였으며, 소스 문장 없이 번역가가 제공한 문장의 수준이 향상된 것을 확인하였다. Koehn[34]도 소스 문장 없는 사후교정의 가능성에 대해 언급하였고, 문장의 정확성과 부정확성에 따라 연구가 진행되었다. 언어의 유창성과 의미의 적절성을 분리하는 평가를 기반으로 진행된 연구[26]도 존재한다.

하지만 다수의 연구는 단일 언어 사후교정의 성능은 사용된 병렬 코퍼스과 사후교정자에 따라 성능 차이가 발생하는 것을 발견하였다[34, 43, 55, 56]. 이러한 차이점의 원인은 소스 문장에 대한 사후교정자의 전문성과 연관되어 있다

[35]. 따라서 사후교정자가 소스 문장의 전문성을 갖고 있다면, 소스 문장 없이 사후교정 결과물을 생성할 수 있다.

### 3. 딥러닝을 활용한 자동 학술 영문교정 방법론

본 논문에서 제안하는 자동 학술 영문교정 방법론은 <그림 1>과 같이 2단계(Phases)로 구성된다. 첫 번째는 오타자를 교정하는 단계(Phase 1. Misspell correction)이고, 두 번째는 문장의 전달력을 개선하는 단계(Phase 2. Fluency improvement)이다. 오타자 교정 단계는 학술 용어사전을 기반으로 사용자가 입력한 문장의 구성 단어 중 존재하는 오타자를 감지하고, 감지된 오타자의 교정 단어를 사용자에게 제공한다. 문장 전달력 개선 단계에서는 교정 전 문장과 교정 후 문장의 쌍을 학습한 BRNN APE 모델을 바탕으로 입력된 문장의 전달력과 명확성이 개선된 교정문장을 사용자에게 제공한다.

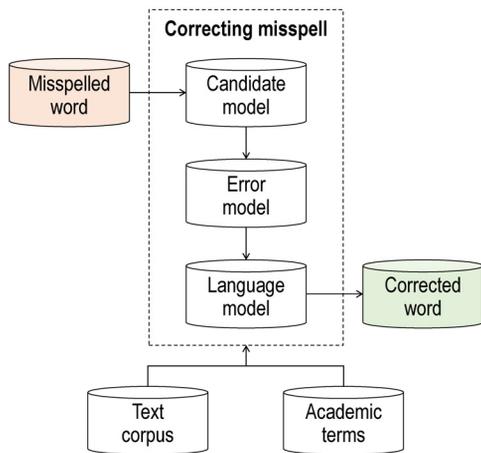


<그림 1> 자동 학술 영문교정 방법론

BRNN APE 모델을 기반으로 입력 문장의 길이와 무관한 길이의 교정문장을 출력할 수 있으며, 이에 따라 문장의 명확성과 전달력을 높일 수 있다.

### 3.1 학술용어사전 기반 오탈자 교정

본 논문에서는 noisy channel model을 기반으로 오탈자 교정을 실행한다. 입력된 오탈자  $e$ 를 기반으로 교정 후보 단어  $s$ 를 출력하기 위해  $P(e|s) \times P(s)$ 를 계산한다. 오탈자 교정을 위한 텍스트 처리 및 데이터 활용 과정은 <그림 2>와 같다.



<그림 2> 언어 모델 기반 오탈자 교정

학술용어사전을 기반으로 오탈자를 감지하고, 감지된 오탈자와 유사한 교정 후보(candidates)를 생성하는 Step 1, 생성된 교정 후보 중 문장의 문맥에 적합한 교정 단어를 선정하기 위해 에러 모델(error model)을 사용하는 Step 2, 선정된 교정 단어들 중 오탈자가 포함된 문장에 적합한 최종 교정 단어를 사용자에게

제공하기 위한 n-gram 언어 모델(language model)을 활용하는 Step 3의 과정을 거친다. 이를 통해, 일반적으로 사용되는 단어뿐만 아니라, 학술 영문에서 사용되는 전문적인 용어로부터 발생하는 오탈자를 정확히 인식하고 교정하여 사용자에게 교정 단어를 제공한다.

#### Step 1: Candidate model

입력된 오탈자를 감지하고 교정하기 위한 교정 후보 단어 선정이 필요하다. 본 논문에서는 교정 후보 단어 선정을 위해 Levenshtein Damerau 편집 거리를 활용한다[13]. 이 편집 거리는 문자의 추가, 삭제, 변경으로 인한 문자열의 차이를 측정하기 위한 지표로, 두 문자 간의 차이를 계산하여 차이가 적은 단어를 교정 후보로 선정한다.

본 논문에서는 학술용어를 단어 사전에 포함하기 위해 전문 원어민 에디터가 교정한 학술 영어 논문으로부터 329,374개의 학술용어를 단어 사전에 추가한다. 또한, 생물 분야 학술용어를 확보하기 위해 Cspell 단어 사전과 의학 전문 사이트인 KMLE[32] 사이트의 전문 용어를 수집한다.

#### Step 2: Error model

본 논문에서는  $P(e | s)$ 를 계산하기 위해 부분열 에러 모델을 활용한다. 따라서 부분집합은 일대일로 정렬되며, 부분집합을 비워 둘 수 있게 함으로써, 정렬은 하위 문자열의 삽입과 삭제를 모델링한다. Brill and Moore[5]에 제시된 바와 같이  $P(e|s)$ 을 식 (1)과 같이 도출한다.

$$P(e | s) \approx \max_{R, T, s.t. |T| = |R|} \prod_{i=1}^{|R|} P(T_i | R_i) \quad (1)$$

따라서 본 논문에서는  $3.7 \times 10^8$  개의 웹페이

지로부터 수집된 오탃자 데이터[63]를 기반으로, 에러 모델 학습을 위해 문자열을 길이가 최대 2인 부분열 집합을 제한하며,  $P(T_i|R_i)$ 의 최대우도법을 활용한다.

### Step 3: Language model

본 논문에서는  $P(s)$ 를 계산하기 위해 웹으로부터 수집한 데이터와 교정 데이터를 기반으로 학습된 n-gram 언어 모델을 활용한다. 명확한 문맥을 파악하기 위해 전/후 문맥을 활용한다. Brill and Moore[5]의 연구와 상반되게, 전문 교정가는 문서를 교정할 때 정확한 문장의 의미 전달을 위해 전/후 문장을 모두 교정하는 것을 확인하였다. 따라서 Step 2의 에러 모델 기반의  $P(e|s)$ 와 n-gram 언어 모델 기반  $P(s)$ 를 활용하여  $P(e|s) \times P(s)$ 가 가장 높은 교정 단어  $w$ 를 사용자에게 제공한다.

## 3.2 BRNN APE 기반 문장 전달력 개선

본 연구에서 제안하는 모델은 인코더와 디코더에 BRNN 기반의 APE 모델을 사용한다. BRNN APE 모델은 가변 길이로 입력된 원문  $X$ 를 고정 길이 벡터로 표현하는 인코더와 고정된 길이의 벡터를 기반으로 가변 길이로 출력된 교정문  $Y$ 를 출력하는 디코더로 구성된다. 따라서 입력된 원문 문장의 길이  $M$ 과 출력된 교정문 문장의 길이  $N$ 은 다를 수 있다. BRNN APE 모델은 입력 문장의 길이가 길면 성능이 저하되는 문제를 해결하였으며, 원문과 교정문의 쌍으로부터 문장 전달력 개선을 위한 문장간의 차이를 학습할 수 있도록 설계되었다. 또한, 입력 문장의 길이와 출력 문장의 길이가 같아야 하는 기존 방법론의 한계점을 개선한다.

BRNN APE의 인코더는 순방향 RNN과 역방향 RNN 두 가지로 구성된다. 순방향 RNN은 입력된 원문  $X$ 의 구성 단어  $(x_1, x_2, \dots, x_m)$ 의 정보를 순차적으로 전달하면서 비활성화 함수를 사용하는 RNN의 hidden state가 업데이트된다. 이와 유사하게, 역방향 RNN 인코더는 입력된 순서의 역순으로 hidden state를 업데이트한다. 즉,  $(x_m, x_{m-1}, \dots, x_1)$  순서로 계산이 진행된다. 문장이 끝나는  $x_m$ 까지 업데이트가 완료되면 hidden state는 입력 문장 전체에 대한 요약정보를 표현하는 컨텍스트 벡터  $C$ 를 계산한다.

디코더는 출력 문장  $Y$ 의  $t$ 번째 구성 단어  $y_t$ 를 생성하기 위해 학습된 또 다른 RNN 모델이며,  $t$ 번째 hidden state  $h_t$ 와 컨텍스트 벡터  $c_t$ 를 기반으로 계산된다. 디코더의  $t$ 번째 hidden state  $\eta_t$ 는 식 (2)와 (3)에 의해 계산되며,  $t$ 번째 컨텍스트 벡터  $c_t$ 는 식 (4)와 같이 계산된다.  $\alpha_{ti}$ 는  $h_i$ 의 가중치로서 식 (5)와 같이 계산할 수 있다.

$$P(y_t|y_1, \dots, y_{t-1}, X) = f(\eta_t, y_{t-1}, c_t) \quad (2)$$

$$\eta_t = f(\eta_{t-1}, y_{t-1}, c_t) \quad (3)$$

$$c_t = \sum_{i=1}^m \alpha_{ti} h_i \quad (4)$$

$$\alpha_{ti} = \exp(e_{ti}) / \sum_{j=1}^m \exp(e_{tj}) \quad (5)$$

식 (5)에서  $e_{ti}$ 는 식 (6)과 같이 계산 가능한 스칼라값이며, 직전 단계의 hidden state인  $\eta_{t-1}$ 와 인코더의  $i$ 번째 hidden state  $h_i$ 의 유사한 정도를 나타내는 값으로, Bahdanau et al.[2]에서 alignment model이라고 정의하고 있다.

$$e_{ti} = \alpha(\eta_{t-1}, h_i) \quad (6)$$

식 (5)는 계산된 유사도 점수  $e_{ti}$ 에 softmax 함수를 적용하여 모든 유사도의 합이 1이 되도록 하는 식이다. 따라서  $\eta_{t-1}$ 와  $h_i$ 의 유사도가 높으면 가중치  $\alpha_{ti}$ 가 높게 나타난다. 식 (4)에서  $t$ 번째 컨텍스트 벡터  $c_t$ 는 계산된 점수와 인코더의 각 hidden state의 가중합으로 계산된다. 따라서 인코더에 모든 hidden states에 대해 가중합이 계산되므로 입력값의 길이가 길면 성능이 저하되는 문제를 해결할 수 있다. 또한, 컨텍스트 벡터에 따라서 성능이 좌우되는 현상도 해결할 수 있다.

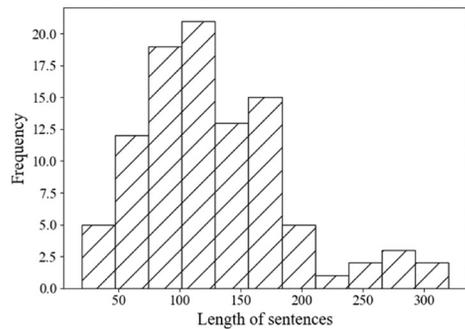
## 4. 실험

### 4.1 실험 데이터

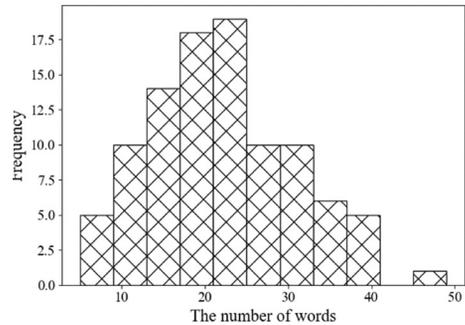
제안 방법론을 평가하기 위해 전문 에디터가 교정한 학술 영문교정 완료 데이터를 이용하여 실험하였다. 이 데이터는 학술 분야별 석·박사 학위를 보유한 전문 원어민 에디터가 오타자와 문장 전달력 개선을 위해 원문으로부터 직접 교정한 데이터이다. 학술 분야별로 발생하는 오타자 오류와 문장 전달력 개선 사항이 상이하므로, 정확한 성능 비교를 위해 다양한 학술 분야의 교정 문장 데이터셋을 활용하였다.

실험에 사용된 데이터는 <표 4>와 같이 6개 학술 분야의 총 303개 문장으로 구성된다. 교정 완료 문장 중 특수 문자 및 침자는 오타자 및 문장 전달력 개선과 무관하므로 제거하였고, 정확한 의미를 내포하고 있지 않은 구절 데이터도 제거하였다.

<그림 3>은 실험에 사용된 문장 길이를 나타낸 히스토그램이며, 사용된 문장의 평균 길이는 129이다. <그림 4>는 문장을 구성하는 단어의 수를 의미하며, 실험에 사용된 문장당 평균 단어 수는 22개이다.



<그림 3> 실험 사용 문장 길이 히스토그램



<그림 4> 문장 당 단어 수 히스토그램

<표 4> 실험 데이터 요약

Academic areas	Edited sentences
Arts & Humanities	53
Bioscience	50
Physical science	53
Psychology	50
Medical	49
Computer engineering	48
Sum	303

## 4.2 실험 환경

본 연구의 BRNN 인코더의 순방향 RNN과 역방향 RNN과 디코더는 각각 1,000개의 hidden state를 가지고 있다. 또한, Goodfellow et al.[19]의 방법론과 마찬가지로, 교정 결과 문장을 예측하기 위해 single maxout hidden layer를 포함한 multilayer network를 사용한다. 본 논문에서는 다차원 공간의 텍스트를 할당하기 위해 620차원의 벡터 공간으로 할당하였으며, maxout hidden layer의 크기는 500이다. 본 논문에서 활용한 alignment model의 hidden state 수 역시 1,000개이다. ‘Adadelta’[67]를 활용하여 미니 배치 통계적경사하강법(stochastic gradient descent, SGD)을 기반으로 학습되었다. ‘Adadelta’를 활용한 이유는 각 변수의 학습률이 자동으로 조정되기 때문이며, 각 SGD 업데이트 방향은 80개 문장의 미니 배치를 사용하여 계산된다.

교정 성능 평가지표는 GLEU(Generalized Language Evaluation Understanding)[45]를 사용하였다. GLEU는 BLEU(Bilingual evaluation understudy)[51] 기반의 지표로서, 정답문장(ground truth sentence)과 교정문장(edited sentence)을 n-gram으로 비교하여 겹치는 단어

수를 측정함으로써 순차적인 단어에 대해서 높은 점수를 부여하는 지표이며, 나타낼 수 있는 재현율과 정밀도의 최솟값이다.

BLEU와 같이, GLEU 지표는 결괏값이 클수록 정답과 유사하게 교정했다는 것을 의미하며, 적용 방법론의 성능이 우수함을 의미한다. 제안 방법론의 우수성을 증명하기 위해 단일 언어 사후교정의 성능을 NMT 방식의 APE 시스템인 비교 방법론[49, 50]의 성능과 비교하였다. 실험은 python 3.6과 <표 5>와 같은 사양의 학습용 PC로 수행하였다.

<표 5> 학습용 PC 사양 및 개발 소프트웨어

CPU	AMD Ryzen7 1700 8-Core 3.0GHz
GPU	GeForce GTX 1080 TI
Memory	16 GB
OS	Linux (Ubuntu 16.04. 6LTS)

## 4.3 실험 결과

### 4.3.1 정량적 비교 결과

본 연구에서 제안한 방법론의 GLEU 값은 <표 6>과 같이 여섯 가지 분야 중 다섯 가지에서 가장 우수한 성능을 보였다. 제안 방법론의

<표 6> 제안 방법론과 비교 방법론의 성능 비교

	Proposed method		Pal et al.[50]		Pal et al.[49]	
	GLEU(%)	time(s)	GLEU(%)	time(s)	GLEU(%)	time(s)
Arts & Humanities	<b>68.06</b>	2.34	61.54	<b>2.21</b>	59.45	2.45
Bioscience	<b>34.69</b>	2.89	33.58	<b>2.78</b>	31.45	2.80
Physical science	<b>56.29</b>	2.95	53.45	<b>2.78</b>	51.31	2.81
Psychology	<b>56.71</b>	<b>2.64</b>	54.55	2.88	55.79	2.95
Medical	42.94	<b>3.01</b>	<b>43.45</b>	3.14	39.40	3.12
Computer engineering	<b>54.64</b>	3.43	53.45	<b>3.21</b>	51.45	3.34

성능이 비교 방법론 대비 GLEU가 최대 8.6%p, 최소 0.9%p 높았다. GLEU 값이 클수록 성능이 우수하므로, 본 논문의 제안 방법론의 성능이 비교적 우수함을 알 수 있다.

또한, 원문이 입력되고 난 후, 교정문 도출까지 걸리는 시간을 측정할 결과, 여섯 가지 학술 분야 중 의학 및 물리학 두 가지 분야의 실험 데이터에서 가장 빠르게 교정 결과를 도출하였다. 하지만, 비교 방법론[50]의 교정 결과 도출 시간이 여섯 가지 분야 중 네 가지 분야에서 가장 빠른 것을 확인할 수 있었다. 또한, 교정 결과 도출 속도는 입력 문장 길이가 길수록 오래 걸리는 경향을 확인하였다.

4.3.2 정성적 비교 결과

<표 7>에 문법 오류가 포함된 문장을 제

안 방법론과 비교 방법론으로 교정한 결과물의 예를 비교하였다. 실제로 오류가 포함된 원 문장은 문장 전달력 개선의 여지가 있는 문장이다. 전문 용어 ‘기관지확장제 (bronchodilator)’가 포함된 입력 문장으로부터, 제안 방법론은 해당 전문 용어를 오타자로 감지하지 않았지만 두 비교 방법론은 해당 단어를 오타자로 감지하여 교정 결과를 제공하였다. 또한, ‘existed’를 ‘was observed’로 교정함으로써, 문장의 전달력이 개선된 것을 확인할 수 있었다. 두 번째 예에서도 관용구 표현이나 중복되는 동사의 변형 등을 교정한 결과를 확인할 수 있다.

교정 결과물로부터 문법 교정과 문장 전달력 개선을 기존 연구와 비교하여 정리하면 <표 8>과 같다.

<표 7> 제안 방법론과 비교 방법론의 정성적 결과 비교

	Example of edited result (1)	Example of edited result (2)
Original	Even after the inhaling of bronchodilator, significant difference in lung function between the never smokers and current smokers in our study existed.	For example when you read your school's book as a first time you will not understand any thing but when read it second time you understand it.
Proposed method	Even after the inhaling of <b>bronchodilator</b> , a significant difference in lung function between the non-smokers and current smokers in our study <b>was observed</b> .	<b>For example</b> , when you read your school's book <b>for the</b> first time, you will not understand anything, but when <b>you</b> read it <b>the</b> second time, you <b>know</b> it.
Pal et al.[50]	Even after the inhaling of <b>bronchodilators</b> , a significant difference in lung function between the never smokers and current smokers in our study <b>existed</b> .	<b>For example</b> , when you read your school's book <b>as a</b> first time you will not understand anything but when read it second time you <b>understand</b> it.
Pal et al.[49]	Even after the inhaling of <b>bronchodilator</b> , significant difference in lung function between the never smokers and current smokers in our study <b>existed</b> .	<b>For example</b> , when you read your school's book <b>for the</b> first time you will not understand anything but when <b>you</b> read it <b>a</b> second time you will <b>understand</b> it.

<표 8> 정성적 실험 결과 기반 교정 요인 비교

	Proposed method	Pal et al.[50]	Pal et al.[49]
GEC / Misspell correction	O	X	O
Fluency improvement	O	X	X

## 5. 결 론

최근 자연어와 컴퓨터 사이의 다리 역할을 하는 NLP 분야에서, 향상된 컴퓨터 계산 능력과 축적된 빅데이터를 기반으로 하는 인공지능 기반의 NLP 연구가 증가하고 있다. 이에 따라, 한 원문과 번역문 쌍의 학습 데이터를 기반으로 사람의 개입 없이 기계가 자동으로 번역하는 기계번역 연구가 활발하며, 실생활에서도 활용된다. 또한, 기계번역 연구를 기반으로 영문법 오류를 감지하고 교정하기 위한 GEC 관련 연구도 활발하게 진행 중이다.

본 연구는 학술 논문의 특성을 반영하지 못한, 일반적인 영어 문장을 대상으로 영문법 교정 연구에 초점이 맞추어진 기존 연구와 달리 기술 용어 사용과 명확한 의미 전달을 위한 자동 학술 영문교정 방법론을 제안하였다. 제안 방법론은 크게 두 단계로 구성된다. 첫 번째는 입력된 문장의 구성 단어 중 존재하는 오타자를 감지하고, 해당 문장의 문맥을 반영하여 교정 단어를 사용자에게 제공한다. 두 번째는 입력 문장의 길이가 길면 성능이 저하되는 문제를 해결한 BRNN APE 모델 기반의 문장 전달력 개선 단계로서 입력된 영어 문장의 전달력과 명확성을 개선한다.

제안 방법론의 성능을 평가하기 위해 실제 원어민 에디터가 교정한 실제 학술 영문교정 데이터셋을 이용하여 실험하였다. 단일 언어 사후교정 비교 방법론과 비교했을 때 우수한 성능을 확인하였다. 특히 단순 문법 교정을 넘어, 사용자가 입력한 문장의 명확성과 전달력을 개선할 수 있는 것을 정성적 결과를 통해 확인하였다. 본 연구의 방법론을 기반으로, 학술 연구자가 전문적인 기술 용어를 활용하여

학술 영어 논문 작성 시 마주하는 영어 작문의 어려움을 해결하고, 고품질의 학술 논문을 작성할 수 있을 것으로 기대한다.

추후 연구에서 고려되어야 할 두 가지 한계점도 존재한다. 첫째, 문장 단위로 교정이 진행되는 제안 방법론을 문단 단위의 교정 결과로 제공하기 위한 연구가 필요하다. 문장 단위보다 문단 단위의 교정 결과를 사용자에게 제공함으로써 학술 영문의 전체적인 품질 향상이 가능하다. 둘째, 교정 결과 도출 시간을 단축하기 위한 연구도 필요하며, 이를 통해 즉각적인 결과 확인과 적용이 가능해질 것이다.

---

## References

---

- [1] Allen, J. and Hogan, C., "Toward the development of a post editing module for raw machine translation output: A controlled language perspective," Third International Controlled Language Applications Workshop, pp. 62-71, 2000.
- [2] Bahdanau, D., Cho, K., and Bengio, Y., "Neural machine translation by jointly learning to align and translate," ArXiv: 1409.0473, 2014.
- [3] Bailey, S., Academic writing: A handbook for international students. Routledge, 2014.
- [4] Bayer, J., Wierstra, D., Togelius, J., and Schmidhuber, J., "Evolving memory cell structures for sequence learning," Inter-

- national Conference on Artificial Neural Networks, pp. 755-764, 2009.
- [5] Brill, E., and Moore, R. C., "An improved error model for noisy channel spelling correction," Proceedings of the 38th Annual Meeting of the Association for Computational Linguistics, pp. 286-293, 2000.
- [6] Brockett, C., Dolan, B., and Gamon, M., "Correcting ESL errors using phrasal SMT techniques," Proceedings of the 21st International Conference on Computational Linguistics and 44th Annual Meeting of the Association for Computational Linguistics, 2019.
- [7] Bryant, C., Felice, M., Andersen, Ø. E., and Briscoe, T., "The BEA-2019 shared task on grammatical error correction," Proceedings of the Fourteenth Workshop on Innovative Use of NLP for Building Educational Applications, pp. 52-75, 2019.
- [8] Cho, K., Van Merriënboer, B., Bahdanau, D., and Bengio, Y., "On the properties of neural machine translation: Encoder-decoder approaches," ArXiv:1409.1259, 2014.
- [9] Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., and Bengio, Y., "Learning phrase representations using RNN encoder-decoder for statistical machine translation," ArXiv:1406.1078, 2014.
- [10] Chollampatt, S. and Ng, H. T., "A multi-layer convolutional encoder-decoder neural network for grammatical error correction," Proceedings of the AAAI Conference on Artificial Intelligence, Vol. 32, No. 1, 2018.
- [11] Chung, J., Gulcehre, C., Cho, K., and Bengio, Y., "Empirical evaluation of gated recurrent neural networks on sequence modeling," ArXiv:1412.3555, 2014.
- [12] Correia, G. M. and Martins, A. F., "A simple and effective approach to automatic post-editing with transfer learning," ArXiv:1906.06253, 2019.
- [13] Damerau, F. J., "A technique for computer detection and correction of spelling errors," Communications of the ACM, Vol. 7, No. 3, pp. 171-176, 1964.
- [14] Dowling, M., Lynn, T., Graham, Y., and Judge, J., "English to Irish machine translation with automatic post-editing", Proceedings of the Conference: 2nd Celtic Language Technology Workshop, 2016.
- [15] Dugast, L., Senellart, J., and Koehn, P., "Statistical post-editing on systran's rule-based translation system," Proceedings of the Second Workshop on Statistical Machine Translation, pp. 220-223, 2007.
- [16] Edmundson, H. P. and Hays, D. G., "Research methodology for machine translation," Mech. Transl. Comput. Linguistics, Vol. 5, No. 1, pp. 8-15, 1958.
- [17] Gamon, M., Leacock, C., Brockett, C., Dolan, W. B., Gao, J., Belenko, D., and Klementiev, A., "Using statistical techniques and web search to correct ESL errors," Calico Journal, Vol. 26, No. 3, pp. 491-511, 2009.

- [18] Ge, T., Wei, F., and Zhou, M., “Fluency boost learning and inference for neural grammatical error correction,” Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics, 1. pp. 1055–1065, 2018.
- [19] Goodfellow, I., Warde-Farley, D., Mirza, M., Courville, A., and Bengio, Y., “Maxout networks,” Proceedings of the 30th International Conference on Machine Learning, pp. 1319–1327, 2013.
- [20] Graves, A., “Generating sequences with recurrent neural networks,” ArXiv:1308.0850, 2013.
- [21] Graves, A. and Schmidhuber, J., “Frame-wise phoneme classification with bidirectional LSTM and other neural network architectures,” Neural networks, Vol. 18, No. 5–6, pp. 602–610, 2005.
- [22] Graves, A., Fernandez, S., and Schmidhuber, J., “Multi-Dimensional Recurrent Neural Networks,” ArXiv:0705.2011, 2007.
- [23] Graves, A., Mohamed, A. R., and Hinton, G., “Speech recognition with deep recurrent neural networks,” 2013 IEEE International Conference on Acoustics, Speech and Signal Processing, pp. 6645–6649, 2013.
- [24] Greetham, B., How to write better essays. Macmillan International Higher Education, 2013.
- [25] Grundkiewicz, R., Junczys-Dowmunt, M., and Heafield, K., “Neural grammatical error correction systems with unsupervised pre-training on synthetic data,” Proceedings of the Fourteenth Workshop on Innovative Use of NLP for Building Educational Applications, pp. 252–263, 2019.
- [26] Hu, C., Resnik, P., Kronrod, Y., Eidelman, V., Buzek, O., and Bederson, B. B., “The value of monolingual crowdsourcing in a real-world translation scenario: Simulation using Haitian Creole emergency SMS messages,” Proceedings of the Sixth Workshop on Statistical Machine Translation, pp. 399–404, 2011.
- [27] Hwang, S. and Kim, D., “BERT-based Classification Model for Korean Documents,” Journal of Society for e-Business Studies, Vol. 25, No. 1, pp. 203–214, 2020.
- [28] Junczys-Dowmunt, M. and Grundkiewicz, R., “MS-UEdin submission to the WMT2018 APE shared task: Dual-source transformer for automatic post-editing,” ArXiv:1809.00188, 2018.
- [29] Junczys-Dowmunt, M., Grundkiewicz, R., Guha, S., and Heafield, K., “Approaching neural grammatical error correction as a low-resource machine translation task,” ArXiv:1804.05940, 2018.
- [30] Kasewa, S., Stenetorp, P., and Riedel, S., “Wronging a right: Generating better errors to improve grammatical error detection,” ArXiv:1810.00668, 2018.
- [31] Khayrallah, H. and Koehn, P., “On the impact of various types of noise on neural machine translation,” ArXiv:1805.12282,

- 2018.
- [32] KMLE., Retrieved from KMLE website: <http://www.kmle.co.kr/>, 2021.
- [33] Knight, K. and Chander, I., “Automated postediting of documents,” AAAI-94 Proceedings, pp. 779–784, 1994.
- [34] Koehn, P., “Enabling monolingual translators: Post-editing vs. options,” Human Language Technologies: The 2010 Annual Conference of the North American Chapter of the Association for Computational Linguistics, pp. 537–545, 2010.
- [35] Krings, H. P., *Repairing texts: Empirical investigations of machine translation post-editing processes*, Kent State University Press, 2001.
- [36] Lagarda, A. L., Alabau, V., Casacuberta, F., Silva, R., and Díaz-de-Liaño, E., “Statistical post-editing of a rule-based machine translation system,” Proceedings of Human Language Technologies: The 2009 Annual Conference of the North American Chapter of the Association for Computational Linguistics, Companion Volume: Short Papers, pp. 217–220, 2009.
- [37] Lee, J. and Webster, J. J., “A corpus of textual revisions in second language writing,” Proceedings of the 50th Annual Meeting of the Association for Computational Linguistics, Vol. 2, pp. 248–252, 2012.
- [38] Lichtarge, J., Alberti, C., Kumar, S., Shazeer, N., Parmar, N., and Tong, S., “Corpora generation for grammatical error correction,” ArXiv:1904.05780, 2019.
- [39] Lopes, A. V., Farajian, M. A., Correia, G. M., Trénous, J., and Martins, A. F., “Unbabel’s Submission to the WMT2019 APE Shared Task: BERT-based Encoder-Decoder for Automatic Post-Editing,” ArXiv:1905.13068, 2019.
- [40] Madi, N. and Al-Khalifa, H. S., “Grammatical error checking systems: A review of approaches and emerging directions,” 2018 Thirteenth International Conference on Digital Information Management (ICDIM), pp. 142–147. IEEE, 2018.
- [41] Manning, C. and Schütze, H., *Foundations of statistical natural language processing*, MIT Press, 1999.
- [42] Mareček, D., Rosa, R., Galuščáková, P., and Bojar, O., “Two-step translation with grammatical post-processing,” Proceedings of the Sixth Workshop on Statistical Machine Translation, pp. 426–432, 2011.
- [43] Mitchell, L., Roturier, J., and O’Brien, S., “Community-based post-editing of machine-translated content: monolingual vs. bilingual,” Proceedings of the MT Summit Conference 2013, European Association for Machine Translation, 2013.
- [44] Mizumoto, T., Hayashibe, Y., Komachi, M., Nagata, M., and Matsumoto, Y., “The effect of learner corpus size in grammatical error correction of ESL writings,” Proceedings of COLING 2012: Posters, pp. 863–872, 2012.
- [45] Mutton, A., Dras, M., Wan, S., and Dale, R., “GLEU: Automatic evaluation of sen-

- tence-level fluency,” Proceedings of the 45th Annual Meeting of the Association of Computational Linguistics, pp. 344-351, 2007.
- [46] Naber, D., A rule-based style and grammar checker, Universität Bielefeld, 2003.
- [47] Napoles, C., Sakaguchi, K., and Tetreault, J., “JFLEG: A Fluency Corpus and Benchmark for Grammatical Error Correction”, Proceedings of the 15th Conference of the European Chapter of the Association for Computational Linguistics: 2, 2017.
- [48] Northedge, A. and Chambers, E., “The Arts Good Study Guide,” 1997.
- [49] Pal, S., Naskar, S. K., Vela, M., & van Genabith, J., “A neural network based approach to automatic post-editing,” Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics, Vol. 2, pp. 281-286, 2016.
- [50] Pal, S., Naskar, S. K., Vela, M., Liu, Q., and van Genabith, J., “Neural automatic post-editing using prior alignment and re-ranking,” Proceedings of the 15th Conference of the European Chapter of the Association for Computational Linguistics, Vol. 2, pp. 349-355, 2017.
- [51] Papineni, K., Roukos, S., Ward, T., and Zhu, W. J., “BLEU: A method for automatic evaluation of machine translation,” Proceedings of the 40th annual meeting of the Association for Computational Linguistics, pp. 311-318, 2002.
- [52] Rosa, R., Mareček, D., and Dušek, O., “DEPFIIX: A system for automatic correction of Czech MT outputs,” Proceedings of the Seventh Workshop on Statistical Machine Translation, pp. 362-368, 2012.
- [53] Ryan, J. P., “The role of the translator in making an MT system work: Perspective of a developer,” Technology as Translation Strategy. American Translators Association Scholarly Monograph Series, Vol. 2, pp. 127-132, 1988.
- [54] Schuster, M. and Paliwal, K. K., “Bidirectional recurrent neural networks,” IEEE Transactions on Signal Processing, Vol. 45, No. 11, pp. 2673-2681, 1997.
- [55] Schwartz, L., “Monolingual post-editing by a domain expert is highly effective for translation triage,” Proceedings of the Third Workshop on Post-Editing Technology and Practice, pp. 34-44, 2014.
- [56] Schwartz, L., Anderson, T., Gwinnup, J., and Young, K., “Machine translation and monolingual postediting: The AFRL WMT-14 system,” Proceedings of the Ninth Workshop on Statistical Machine Translation, pp. 186-194, 2014.
- [57] Simard, M., Ueffing, N., Isabelle, P., and Kuhn, R., “Rule-based translation with statistical phrase-based post-editing,” Proceedings of the Second Workshop on Statistical Machine Translation, pp. 203-206, 2007.
- [58] Smith, P., How To Write an Assignment: Improving Your Research and Presentation Skills. How to Books, 1994.

- [59] Strong, S. I., “How to write law essays and exams,” Oxford University Press, 2018.
- [60] Sutskever, I., Vinyals, O., and Le, Q. V., “Sequence to sequence learning with neural networks,” ArXiv:1409.3215, 2014.
- [61] Wang, Y., Wang, Y., Liu, J., and Liu, Z., “A comprehensive survey of grammar error correction,” ArXiv:2005.06600, 2020.
- [62] Warburton, N., *The basics of essay writing*. Routledge, 2020.
- [63] Whitelaw, C., Hutchinson, B., Chung, G. Y., and Ellis, G., “Using the web for language independent spellchecking and autocorrection,” In *EMNLP*, pp. 890-899, 2009.
- [64] Wu, J. C., Chang, Y. C., Mitamura, T., and Chang, J. S., “Automatic collocation suggestion in academic writing,” *Proceedings of the ACL 2010 Conference Short Papers*, pp. 115-119, 2010.
- [65] Wu, S., Roberts, K., Datta, S., Du, J., Ji, Z., Si, Y., ... and Xu, H., “Deep learning in clinical natural language processing: a methodical review,” *Journal of the American Medical Informatics Association*, Vol. 27, No. 3, pp. 457-470, 2020.
- [66] Yimam, S. M., Venkatesh, G., Lee, J. S., and Biemann, C., “Automatic Compilation of Resources for Academic Writing and Evaluating with Informal Word Identification and Paraphrasing System,” *Proceedings of The 12th Language Resources and Evaluation Conference*, pp. 5896-5904, 2020.
- [67] Zeiler, M. D., “Adadelata: an adaptive learning rate method,” ArXiv:1212.5701, 2012.
- [68] Zhang, X., Zhao, J., and LeCun, Y., “Character-level convolutional networks for text classification,” ArXiv:1509.01626, 2015.
- [69] Zhao, W., Wang, L., Shen, K., Jia, R., and Liu, J., “Improving grammatical error correction via pre-training a copy-augmented architecture with unlabeled data,” ArXiv:1903.00138, 2019.
- [70] Zhao, Z. and Wang, H., “MaskGEC: Improving neural grammatical error correction via dynamic masking,” In *Proceedings of the AAAI Conference on Artificial Intelligence*, pp. 1226-1233, 2020.

## 저 자 소 개



노영훈

2018년

2020년

2020년~2021년

관심분야

(E-mail: yesrohyh@gmail.com)

경기대학교 산업경영공학과 (학사)

경기대학교 산업경영공학과 (석사)

쥬워드바이스 연구원

인공지능, 자연어처리, 기계번역



장태우

1995년

1997년

2004년

2002년~2007년

2007년~현재

2017년~현재

관심분야

(E-mail : keenbee@kgu.ac.kr)

서울대학교 산업공학과 (학사)

서울대학교 산업공학과 (석사)

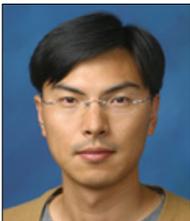
서울대학교 산업공학과 (박사)

한국전자통신연구원 연구원/선임연구원

경기대학교 산업경영공학과 교수

경기대학교 지능정보융합제조연구센터(GRRC) 센터장

스마트공장, 물류/SCM, 시스템분석



원중운

1996년

1998년

2004년

2005년~현재

관심분야

(E-mail: juwon@krri.ac.kr)

한국해양대학교 제어계측공학 (학사)

한국해양대학교 대학원 제어계측공학 (석사)

경북대학교 대학원 전자공학 (박사)

한국철도기술연구원 선임연구원/책임연구원

DA, SOA, IoT