

# 딥러닝 자동 분류 모델을 위한 공황장애 소셜미디어 코퍼스 구축 및 분석\*

## Building and Analyzing Panic Disorder Social Media Corpus for Automatic Deep Learning Classification Model

이수빈 (Soobin Lee)\*\* , 김성덕 (Seongdeok Kim)\*\*\*  
이주희 (Juhee Lee)\*\*\*\* , 고영수 (Youngsoo Ko)\*\*\*\*\*  
송민 (Min Song)\*\*\*\*\*

### 초 록

본 연구는 공황장애에 말뭉치 구축과 분석을 통해 공황장애의 특성을 살펴보고 공황장애 경향 문헌을 분류할 수 있는 딥러닝 자동 분류 모델을 만들고자 하였다. 이를 위해 소셜미디어에서 수집한 공황장애 관련 문헌 5,884개를 정신 질환 진단 매뉴얼 기준으로 직접 주석 처리하여 공황장애 경향 문헌과 비 경향 문헌으로 분류하였다. 이 중 공황장애 경향 문헌에 나타난 어휘적 특성 및 어휘의 관계성을 분석하기 위해 TF-IDF값을 산출하고 단어 동시출현 분석을 실시하였다. 공황장애의 특성 및 증상 간의 관련성을 분석하기 위해 증상 빈도수와 주석 처리된 증상 번호 간의 동시출현 빈도수를 산출하였다. 또한, 구축한 말뭉치를 활용하여 딥러닝 자동 분류 모델 학습 및 성능 평가를 하였다. 이를 위하여 최신 딥러닝 언어 모델 BERT 중 세 가지 모델을 활용하였고 이 중 KcBERT가 가장 우수한 성능을 보였다. 본 연구는 공황장애 관련 증상을 겪는 사람들의 조기 진단 및 치료를 돕고 소셜미디어 말뭉치를 활용한 정신 질환 연구의 영역을 확장하고자 시도한 점에서 의의가 있다.

### ABSTRACT

This study is to create a deep learning based classification model to examine the characteristics of panic disorder and to classify the panic disorder tendency literature by the panic disorder corpus constructed for the present study. For this purpose, 5,884 documents of the panic disorder corpus collected from social media were directly annotated based on the mental disease diagnosis manual and were classified into panic disorder-prone and non-panic-disorder documents. Then, TF-IDF scores were calculated and word co-occurrence analysis was performed to analyze the lexical characteristics of the corpus. In addition, the co-occurrence between the symptom frequency measurement and the annotated symptom was calculated to analyze the characteristics of panic disorder symptoms and the relationship between symptoms. We also conducted the performance evaluation for a deep learning based classification model. Three pre-trained models, BERT multi-lingual, KoBERT, and KcBERT, were adopted for classification model, and KcBERT showed the best performance among them. This study demonstrated that it can help early diagnosis and treatment of people suffering from related symptoms by examining the characteristics of panic disorder and expand the field of mental illness research to social media.

키워드: 공황장애, 소셜미디어, TF-IDF, 단어 동시출현, 딥러닝  
panic disorder, social media, TF-IDF, word co-occurrence, deep-learning

- 
- \* 본 연구는 정부의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(NRF-2018S1A3A2075114).
  - \*\* 연세대학교 문헌정보학과 박사과정(bini122@yonsei.ac.kr) (제1저자)
  - \*\*\* 연세대학교 문헌정보학과 석사과정(ystetjdejr@yonsei.ac.kr) (공동저자)
  - \*\*\*\* 연세대학교 문헌정보학과 석사과정(juhee5795@yonsei.ac.kr) (공동저자)
  - \*\*\*\*\* 연세대학교 문헌정보학과 석사과정(kosue@yonsei.ac.kr) (공동저자)
  - \*\*\*\*\* 연세대학교 문헌정보학과 교수(min.song@yonsei.ac.kr) (교신저자)

- 논문접수일자: 2021년 5월 17일 ■ 최초심사일자: 2021년 6월 3일 ■ 게재확정일자: 2021년 6월 15일
- 정보관리학회지, 38(2), 153-172, 2021. <http://dx.doi.org/10.3743/KOSIM.2021.38.2.153>

© Copyright © 2021 Korean Society for Information Management  
This is an Open Access article distributed under the terms of the Creative Commons Attribution-NonCommercial-NoDerivatives 4.0 (<https://creativecommons.org/licenses/by-nc-nd/4.0/>) which permits use, distribution and reproduction in any medium, provided that the article is properly cited, the use is non-commercial and no modifications or adaptations are made.

## 1. 서론

급변하는 현대사회에서 스트레스는 양적으로 증가하며 현대인의 고질적인 문제로 자리 잡았다. 현대인의 스트레스는 우울증을 비롯한 불안 장애, 수면 장애 등 다양한 형태의 정신 질환으로 나타난다. 단적인 예로 경쟁적이고 여유가 없으며 자연과 동떨어져 사는 현대의 생활방식이 우울증의 원인이라는 연구 결과가 있다(서울아산병원, 2014; 신용우, 2021). 이러한 정신 질환은 과거에는 낯설게 바라보는 시선이 만연했지만 현대에 들어서 환자가 증가함에 따라 건강한 사회를 위한 이슈로 부상하고 있다. 또한, 정신 질환이 신체 질환과 같은 엄연한 질병으로 받아들여지면서 건강을 위해 치료가 필요하다는 의식이 점차 확대되고 있다. 이와 더불어 국가적 차원에서 ‘행복한 삶, 건강한 사회를 위한 정신건강 종합대책(2016.2.25.)’이 발표되었으며 정신보건법 개정안들이 국회를 통과하는 등 더 나은 정신건강을 위한 다방면의 정책적 변화가 이루어지고 있다. 또한 정신 질환을 앓고 있는 환자와 가족들이 건강회복을 위해 심리치료와 약물치료를 적극 활용하고 있는 모습은 자연스러운 사회의 일면이 되었다.

공황장애는 예상하지 못한 상황에서 갑작스럽게 나타나는 불안 증세로 호흡곤란, 심계항진 등의 증상을 동반하며(박수현, 2017; American Psychiatric Association, 2013) 인구 100명 중 최대 5명이 겪고 있는 일반적인 질환이다(Roy-Byrne, Craske, & Stein, 2006). 한국에서는 유명인들이 겪고 있다고 고백한 이후 부각되기 시작하였고 건강보험심사평가원(신서희, 2017)에 따

르면 공황장애는 최근까지도 증가하는 추이를 보이며 많은 관심을 받고 있다. 공황장애가 나타나는 원인은 유전적 요인과 인지적 요인으로 나눌 수 있으며 생물학적 원인이나 외부 스트레스가 원인이 될 수 있다(서울아산병원, 2014).

공황장애는 여러 가지 요인으로 발병될 수 있지만 대부분 환자는 약물 및 인지행동 치료 등 적절한 치료 후에 호전하는 모습을 보인다(서울대학교병원, 2010). 이는 다시 말해 조기 진단 및 치료가 환자의 신체적, 정신적 고통을 빠르게 경감시킬 수 있고, 환자 가족들이 겪는 어려움 해결에도 도움이 될 수 있음을 의미한다. 대부분의 환자들은 공황장애 증상을 처음 겪을 때 호흡곤란이나 심장관련 증상 등을 경험한다. 하지만 이런 증상들을 공황장애 증상이라 판단하지 못하고 심장 관련 병원이나 호흡 관련 병원을 찾게 된다. 때문에 많은 환자들이 자신의 공황장애 발병 여부를 발견하지 못한 채 치료 시점을 놓치고 있다. 공황장애 진단을 받지 못하고 이후에도 여러번 발작증상이 나타나 병원을 돌아다니다가 진단을 받는 상황이 빈번한 것이다. 이러한 공황장애의 특성 때문에 공황장애에 대한 정확한 특성 파악은 조기 진단과 치료를 돕기 위한 중요한 의미를 지닌다.

기존의 정신 질환 관련 연구들은 실제 환자를 대상으로 임상 양상 및 관련 치료의 영향 등을 조사하였다. 이러한 연구들은 정신 질환 환자의 양상과 동향 파악에는 효과적이다. 하지만, 아직 진단을 받지 않은 잠재적인 환자들에 대한 연구들은 아직 부족하다. 소셜미디어는 익명성, 비대면성이 보장되고 형식 없이 자유롭게 표현이 가능하기 때문에 사람들이 자신이

겪는 증상, 궁금증, 경과에 대한 의견들을 쉽게 표현하고 있다. 때문에 이를 바탕으로 잠재적인 환자들에 대한 연구가 가능하다.

소셜미디어 ‘네이버 지식iN’은 자유로운 소셜미디어의 특징에 부합하면서도 타 소셜미디어들과 다르게 이용자가 궁금한 내용을 질문하면 다른 이용자가 이를 대답해주는 특징이 있다. 최근에는 각 분야의 전문가들이 대답을 해주는 제도를 도입해 대답에 대한 신뢰도를 더욱 높였다(유정욱, 2019). 이를 토대로 본 연구에서는 공황장애 관련 ‘네이버 지식iN’ 말뭉치를 수집 및 분석하였다.

본 연구는 ‘네이버 지식 iN’을 활용하여 공황장애와 관련된 말뭉치를 구축하고 그 말뭉치에 나타난 공황장애의 특성을 찾고자 한다. 또한, 공황장애 경향 여부를 주석처리한 훈련 데이터를 만들고 이를 딤러닝 모델에 학습시켜 공황장애 경향 문헌을 자동 분류하는 모델을 만들고자 한다. 이를 통해 대다수 환자들의 공황장애의 진단 및 치료에 도움을 줄 수 있고 이는 한국 사회의 정신건강 증진에도 긍정적인 영향을 줄 수 있다는 점에서 연구 의의를 지닌다.

본 연구의 연구질문은 다음과 같다.

- 연구질문 1: 소셜미디어 텍스트에서 정신 질환 매뉴얼의 공황장애 증상을 발견하고 공황장애 말뭉치를 구축할 수 있는가?
- 연구질문 2: 공황장애 경향 문헌에서 나타난 어휘의 특성 및 어휘 간 관계는 어떠한가?
- 연구질문 3: 공황장애 경향 문헌에서 나타난 공황장애 증상의 특성 및 증상 간 관계는 어떠한가?

- 연구질문 4: 딤러닝 모델을 통해 소셜미디어 텍스트로부터 공황장애 경향 문헌을 자동으로 분류할 수 있는가?

## 2. 선행연구

### 2.1 소셜미디어를 활용한 정신 질환 분석

일상생활에서 의사소통의 공간으로 많은 부분을 차지하고 있는 소셜미디어의 특징에 기인하여 소셜미디어 말뭉치를 활용한 연구들이 이루어지고 있다. 특히 정신 질환 연구의 경우에는 정신 질환에 대한 사회의 부정적인 편견과 차별(백혜진, 조혜진, 김정현, 2017)을 의식하지 않고 소셜미디어 공간에서 자유롭게 환자가 자신의 질환이나 증상을 이야기할 수 있다는 점에서 소셜미디어 말뭉치를 활용한 정신 질환 연구의 중요성이 부각된다.

소셜미디어를 활용한 정신 질환 연구 흐름 중 하나는 수집한 소셜미디어 텍스트 자체의 분석에 중점을 두어 의미 있는 내용 분석을 하는 연구들이다. 레딧(Reddit)에서 수집한 데이터를 LDA 토픽 모델링과 사회연결망 분석을 통해 섭식 장애를 분석한 연구(Moessner et al., 2018)와 중국 소셜미디어인 Weibo에서 TextMind라는 텍스트 분석 시스템을 활용하여 의미적인 내용 분석을 통해 우울증을 분석한 연구(Yu et al., 2021)가 그 예시이다. 소셜미디어 데이터를 활용하여 딤러닝 기반의 예측 모델을 제안해 정신 질환을 예측하거나 탐지하는 연구도 활발하게 이루어지고 있다. 관련하

여 딥러닝 기반의 정신 질환 예측 모델을 제안한 연구로 딥러닝 프레임워크를 통해 정신 질환의 일종인 자살을 예측하는 모델을 제안한 연구(Benton, Mitchell, & Hovy, 2017)와 딥러닝 기반의 이진 분류를 통한 정신 질환을 예측하는 모델을 제안한 연구(Sekulić & Strube, 2020)를 볼 수 있다.

소셜미디어 말뭉치에 관한 여러 연구를 살펴 보았을 때 과거와 달리 현재 소셜미디어 내 대화가 일상생활의 많은 부분을 차지하고 있음을 파악하였다. 또한 소셜미디어 데이터를 분석할 수 있는 딥러닝 기법 등의 기술 발전이 이루어진 이유로 소셜미디어를 활용한 정신 질환 연구가 다양하게 이루어지고 있다. 본 연구는 공황장애를 주제로 소셜미디어 말뭉치를 구축하고 분석하는 연구를 진행하고자 한다.

## 2.2 말뭉치 활용한 딥러닝 모델

자연어처리 분야에서 딥러닝 모델은 인간의 언어를 기계가 가장 잘 이해할 수 있도록 도와주는 AI 시대의 혁신적인 기술(Medrouk & Pappa, 2017)로 꼽힌다. 딥러닝 모델 성능 개선에는 말뭉치 품질이 중요한 문제로 파악(박찬준 외, 2021) 되는데, 적합한 양질 말뭉치를 확보해야 활용하고자 하는 자연어처리 연구에 실질적인 도움이 될 수 있기 때문이다. 말뭉치 구축과 관련된 딥러닝 모델 연구들의 예시로는 한국 전통문화 말뭉치를 구축한 다음 Bi-LSTM, CNN, CRF로 학습 모델을 만들어 한국어 개체명 인식 시스템의 성능을 향상한 연구(김경민 외, 2018), 트위터에서 데이터를 수집하여 자살의 원인이 되는 정신적 스트레스 정도를 주석

처리하여 말뭉치를 구축한 후 딥러닝 모델인 CNN과 RNN을 활용하여 자동 분류한 연구(Du et al., 2018), 최신 딥러닝 언어 모델을 활용하여 트위터에서 수집한 데이터로 구축한 말뭉치에서 증오 발언을 감지한 연구(Mozafari, Farahbakhsh, & Crespi, 2019)가 있다.

선행연구에서 살펴본 바와 같이 말뭉치를 구축하여 딥러닝 모델을 적용하면 다양한 연구 분야에서 각 연구 주제를 깊이 있게 탐색하고 감지할 수 있는 원동력이 되게 해준다. 본 연구에서도 공황장애 말뭉치를 구축하고 딥러닝 모델을 활용하여 공황장애의 특성을 더욱 깊이 있게 알아보하고자 한다.

## 2.3 언어 모델 BERT

BERT(Bidirectional Encoder Representations from Transformers)는 트랜스포머(Vaswani et al., 2017)를 기반으로 설계된 언어 모델이다(Devlin et al., 2018). 트랜스포머는 기존의 인코더-디코더 구조를 어텐션(Attention)으로만 구현한 모델로 BERT는 트랜스포머 인코더를 여럿 연결하여 심층 학습이 가능하고 양방향 학습으로 문맥 파악에 효과적이다. BERT는 이러한 장점으로 다양한 자연어처리 영역에서 우수한 성능을 달성하였다.

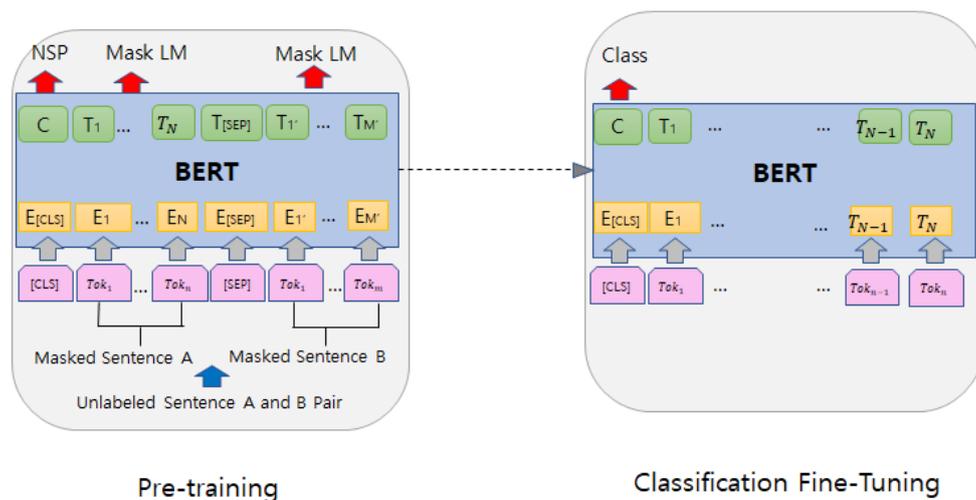
BERT를 중심으로 한 최신 딥러닝 기반 언어 모델 분야에서는 대규모의 텍스트로 사전훈련(pre-training)한 뒤 소규모의 훈련데이터로 해당 모델을 파인튜닝(fine-tuning)하는 기법이 각광받고 있다. 특히, BERT의 사전훈련 기법은 주석처리가 되어있지 않은 대규모 텍스트를 적용하여 우수한 단어 표현(word representation)

을 획득할 수 있는 장점이 있다. 이에 따라 파인 튜닝 단계에서 별도의 모델 구조를 추가하지 않더라도 적은 학습데이터로 높은 수준의 성능을 달성할 수 있다. BERT의 사전학습 및 파인 튜닝의 원리와 절차는 <그림 1>에서 제시된 바와 같다.

<그림 1>에 따르면, BERT는 사전학습 단계에서 연속된 두 문장을 입력데이터로 받아 다음의 두 가지 학습기법으로 훈련한다. 먼저 Masked Language Modeling 학습기법은 주어진 문장으로부터 일부 단어를 마스크 토큰으로 대체한 후 모델이 해당 단어를 올바르게 예측하도록 모델 가중치를 업데이트하는 기법이다. 이와 같은 양방향 학습은, 이전에 사용된 좌측에서 우측 방향으로만 다음 단어를 예측하였던 단방향 학습에 비해 풍부한 문맥 정보를 학습할 수 있다는 강점을 지닌다. 다음으로 Next Sentence Prediction 학습기법은 논리적으로 연결되는 문장 쌍과 임의로 추출한 문장 쌍을 구성한 후 모델이 특정 문장 쌍에 대해 논리적으로 연결

관계에 놓인 것인지 올바르게 판단하도록 가중치를 업데이트하는 방법이다. 이를 통해 언어 모델은 단어의 선후 관계를 넘어 문장 차원에서의 정보를 학습한다.

이처럼 BERT는 사전학습 과정에서 대규모 텍스트로부터 단어 표현을 학습하며, 이후 파인튜닝 과정에서 얼마나 높은 품질의 단어 표현이 획득하는지가 결정된다. 이러한 맥락에서 언어 모델을 다양한 데이터로 사전학습하는 것이 최근 중요한 연구영역으로 주목받고 있다. 이에 대한 사례로 구글은 영문 위키피디아로 사전학습한 기본 모델을 제시하는 한편, 약 100개 이상의 언어로 이루어진 위키피디아를 활용한 BERT multilingual 모델을 제공하고 있다(Devlin, 2019). 이 외 한국어에 최적화된 단어 표현을 획득하기 위해 국내에서도 한글 데이터만을 사용하여 BERT를 사전훈련한 다양한 유형의 모델들이 제안된 바 있다. 대표적으로 SKTBrain에서 공개한 KoBERT는 한글 위키피디아를 기반으로 학습한 모델(Jeon, 2021)이



<그림 1> BERT 모델

며, 한국전자통신연구원에서 출시한 KorBERT는 한글 백과사전과 뉴스 기사를 사용한 모델이다(한국전자통신연구원, 2019). 다른 사례로 KcBERT는 구어체나 정제되지 않은 텍스트로부터 높은 성능을 얻기 위해 네이버 뉴스의 댓글과 대댓글로부터 추출한 약 1억 1천 만개 이상의 문장을 사전학습에 적용한 모델이다(Lee, 2020).

향 문헌 여부를 주석 처리하였다. 이러한 주석 작업을 교차로 3차례에 수행하여 공황장애 말뭉치를 구축하였다. 말뭉치 구축 이후 공황장애 경향 문헌으로 분류된 문헌집단에 대해 어휘 및 증상 분석을 수행하였다. 뿐만 아니라, 구축한 말뭉치를 학습데이터로 활용하여 공황장애 경향 문헌 자동 분류 모델을 학습하고 성능 평가를 수행하였다. 아래에서 각 연구 단계에 대해 상술하도록 하겠다.

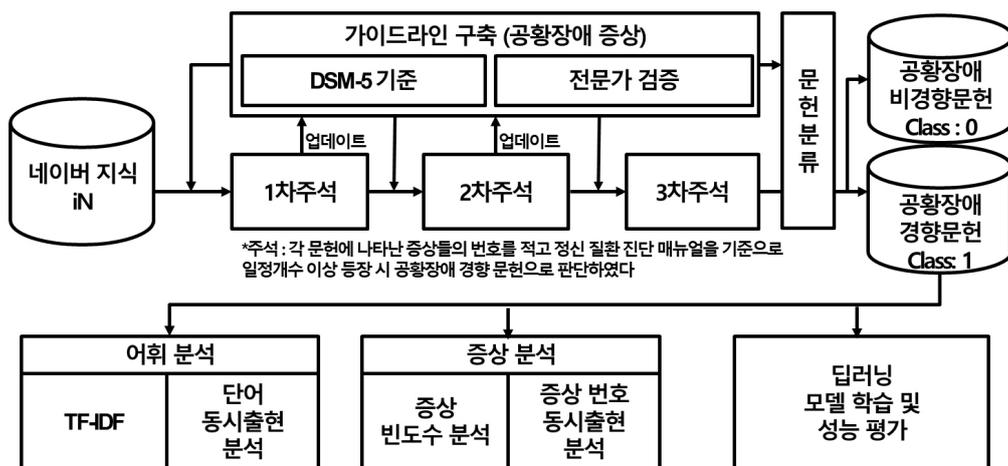
### 3. 연구 방법

본 연구의 진행 절차는 <그림 2>에서 제시한 바와 같다. 먼저 네이버 지식iN에서 공황장애 관련 문헌들을 수집하고 전처리를 수행하였다. 전처리 작업 이후, 수집한 데이터에 대해 DSM-5 기준에 의거하여 주석작업을 수행하였다. 주석 작업은 크게 두 가지 사안에 대해 진행되었다. 먼저, 각 문헌에 등장하는 공황장애 증상의 번호와 개수를 주석하고, 다음으로 각 문헌에 등장하는 증상 개수의 기준에 따라 공황장애 경

#### 3.1 데이터 수집 및 전처리

본 연구에서는 네이버 지식iN에서 “공황장애”와 “공황발작”을 질의어로 사용하여 2017년 1월부터 2019년 12월까지 이용자 질문 문헌을 수집하였다. 중복문헌을 제거한 전체 문헌의 총수는 약 44,123건이며, 임의추출 과정을 거쳐 5,884건의 문헌을 최종 선정하였다.

다음으로 앞서 선정한 문헌 집단에 대해 전처리 작업을 수행하였다. 온라인 소셜미디어



<그림 2> 연구 절차

텍스트는 철자나 띄어쓰기 등의 문법적 오류가 빈번히 발생하며, 이러한 점은 이후 연구 과정에 부정적인 영향을 미칠 수 있다. 이를 고려하여 본 연구에서는 온라인 소셜미디어 데이터에 특화된 딤러닝 기반 자동 띄어쓰기 라이브러리 PyKoSpacing(Jeon, 2018)을 활용하여 띄어쓰기를 교정하였다. 또한, 한국어 문장 자동 분리 기인 Korean Sentence Splitter(Ko, 2021)를 사용하여 문장 간 경계를 보다 엄격한 기준으로 분절하였다. 한편, 후술할 어휘 분석에서는 텍스트마이닝 통합 프레임워크인 treform(Song, 2021)을 사용하였다. treform에서 제공하는 파이프라인에 따라 각 문헌에 대해 문장 분리, 형태소 분석, 품사 필터링, 불용어 제거 등의 과정을 거쳤다.

### 3.2 말뭉치 구축

전처리 작업 이후 총 3명의 대학원생이 DSM-5 공황장애 증상 기준을 토대로 주석작업을 수행

하였다. 구체적으로, 대학원생 3명이 전체 문헌 집단에 대해 세 차례에 걸쳐 교차 검증하는 방식으로 수행하였고, 그 과정에서 공황장애 주석 가이드라인을 작성하였다. 해당 가이드라인은 논란의 여지가 있는 문헌들에 대한 세부적인 근거와 합의 내용을 중심으로 서술되었으며, 정신 의학과 전문의로부터 주기적인 자문을 받아 높은 신뢰성을 확보하도록 하였다. DSM-5 증상 기준은 <표 1>과 같다.

본 연구에서 구축한 말뭉치에는 두 가지 유형의 주석작업이 수행되었다. 먼저 <표 1> DSM-5 증상 기준에 근거하여 각 문헌에 나타난 공황장애 증상에 해당하는 증상번호를 기재하였다. 이후 해당 문헌에서 확인되는 증상의 수가 4개 이상이면 공황장애 경향 문헌, 그렇지 않으면 비 공황장애 경향 문헌으로 분류하였다.

실제 주석작업 예시는 <표 2>를 통해 확인할 수 있다. <표 2>에서 첫 번째 문헌의 경우 “가슴이 답답하고”, “어지러움이 있고”라는 내용은 각각 DSM-5 증상번호 6번과 8번에 해당하

<표 1> DSM-5 증상 기준

DSM-5 증상 기준	
1	심계항진. 가슴 두근거림 또는 심장 박동 수의 증가
2	발한
3	몸이 떨리거나 후들거림
4	숨이 가쁘거나 답답한 느낌
5	질식할 것 같은 느낌
6	흉통 또는 가슴 불편감
7	메스꺼움 또는 복부 불편감
8	어지럽거나 불안정하거나 멍한 느낌이 들거나 쓰러질 것 같음
9	춥거나 화끈거리는 느낌
10	감각 이상(감각이 둔해지거나 따끔거리는 느낌)
11	비현실감(현실이 아닌 것 같은 느낌) 혹은 이인증(나에게서 분리된 느낌)
12	스스로 통제할 수 없거나 미칠 것 같은 두려움
13	죽을 것 같은 공포

〈표 2〉 주식 예시

문헌	증상 번호	문헌 분류
요즘 들어서 사람이 많은 곳에서나 사람이 밀집되어있는 곳에 있게 될 시에 가슴이 답답하고 어지러움이 있고 불안한 거 같은 증상이 있는데 왜 이러는 걸까요.	6번, 8번	비 공황장애 경향 문헌
부모님이 싸우실 때마다 몸이 너무 긴장합니다. 손발이 떨리고, 땀이 나면서 호흡이 불편하고 명치가 답답한 느낌을 받습니다. 공황장애같은 건가요?	2번, 3번, 4번, 6번	공황장애 경향 문헌

며, 증상의 수가 4개 미만이므로 비 공황장애 경향 문헌으로 분류하였다. 두 번째 문헌의 경우 “손발이 떨리고”, “땀이 나면서”, “호흡이 불편하고”, “명치가 답답한 느낌을 받습니다.”라는 내용에 대해 각각 증상번호 3번, 2번, 4번, 6번에 해당한다고 주석하였고, 기재된 증상의 수가 4개 이상이므로 공황장애 경향 문헌으로 구분하였다.

### 3.3 어휘 분석

#### 3.3.1 TF-IDF

TF-IDF 가중치는 특정 문헌 내 출현빈도가 높으면서 전체 문헌집단 내 출현빈도가 낮은 단어가 더 중요하다는 가정에 기초하여 단어빈도를 역문헌빈도에 의해 정규화한 값이다(Salton & McGill, 1983). 이러한 가정 아래 TF-IDF 값이 높은 단어는 특정 문헌의 핵심 메시지를 담고 있을 확률이 높아 핵심 단어로 간주할 수 있다(송민, 2017; 김현지 외, 2019).

본 연구에서는 공황장애 경향 문헌 집단으로부터 핵심 단어를 추출하여 공황장애를 겪는 이용자의 어휘적 특성을 분석하고자 한다. 그러나 앞서 언급한 TF-IDF 가중치는 개별 문헌 범위에서 각 단어가 갖는 중요성을 측정하는

지표라는 한계를 지닌다. 이를 고려하여 본 연구에서는 문헌 집단 범위에서 단어가 지닌 중요성을 측정하는 변형 TF-IDF 가중치를 사용하여 키워드를 추출하고자 한다. TF-IDF 변형 식에는 *TFIDF*와 *NTFIDF*(Normalized *TFIDF*) 두 가지 공식이 존재한다(이성직, 김한준, 2009). 먼저 *TFIDF*는 기존 TF-IDF 공식에서 특정 문헌에서의 단어 출현빈도 TF를 전체 문헌 집단에서의 단어 출현빈도 CF로 변경하고, 문헌 집단 내 모든 단어들의 CF 값 중 최대값으로 나누어 정규화한다. 역문헌빈도 IDF는 기존 TF-IDF 공식과 동일하게 사용한다. *NTFIDF*는 *TFIDF*에서 정규화된 CF 값에 로그를 취하고 1을 더하여 정규화한 후 IDF 값을 곱한 값이다.

본 연구는 공황장애 경향 문헌 집단에 대해 전술한 *TFIDF*와 *NTFIDF* 값을 각각 적용하여 가중치별 상위 15개 단어를 분석하였다.

#### 3.3.2 단어 동시출현 분석

단어 동시출현 분석은 일정한 단위 내에서 동시에 출현하는 단어들은 주제적으로 연관성이 있을 것이라는 전제에 기초한다. 이러한 분석은 단어들이 어떠한 맥락에서 사용되었는지 맥락 정보를 반영하므로, 기존의 단순 단어빈도 분석에서 발견할 수 없는 새로운 내용을 발견할 수

있다.

본 연구에서는 공황장애 경향 문헌들에 대해 문헌 단위로 함께 출현하는 단어 쌍의 빈도를 계산하고, 이후 전체 단어 쌍에 대해 출현빈도수를 기준으로 내림차순으로 정렬하여 상위 30개 단어 쌍에 대한 분석을 수행하였다. 보다 의미 있는 분석을 위해 “공황”, “장애”, “증상”은 분석 대상 단어 군에서 제외하였다. 또한, 단어들이 동시에 출현하는 관계 정보를 토대로 단어 동시출현 네트워크 시각화를 수행하였다. 네트워크에서 노드(node)는 단어이며, 엣지(edge)는 단어 간 동시출현 빈도를 나타낸다.

### 3.4 증상 분석

#### 3.4.1 증상 빈도수 분석

본 연구진들이 구축한 말뭉치에는 특정 문헌이 공황장애 경향에 해당하는지 여부와 함께 해당 문헌에 등장하는 증상들의 번호가 주석되어 있다. 이에 공황장애 경향 문헌 집단을 대상으로 각 증상번호가 출현한 전체 빈도수를 계산하였다. 그리고 결과를 내림차순으로 정렬한 뒤 상위 증상을 중심으로 분석을 수행하였다.

#### 3.4.2 증상 동시출현 분석

앞선 단어 동시출현 분석의 기본 전제와 마찬가지로, 하나의 문헌에서 동시에 출현하는 증상들은 주제적으로 관련이 있을 것이라고 볼 수 있다. 이를 고려할 때, 증상 동시출현 분석은 개별 증상의 단순 빈도수에서 확인할 수 없었던 증상들 간의 관계적 특성을 파악하는데 효과적이다.

이에 본 연구에서는 하나의 문헌에서 동시에

등장하는 증상번호 쌍의 빈도를 계산하였다. 이후 전체 출현빈도를 내림차순으로 정렬하여 상위 10개 증상번호 쌍에 대해 분석하고자 하였다. 이를 통해 증상들 가운데 관련성이 높은 증상 간의 관계적 특성을 살펴볼 수 있다.

### 3.5 모델 학습 및 성능 평가

본 연구에서 구축한 말뭉치는 딥러닝 모델 학습을 위한 훈련데이터로 사용할 수 있도록 주석되어 있다. 이에 본 연구는 해당 말뭉치를 활용하여 실제 공황장애 경향 문서 자동 분류 모델을 학습하고 이를 제안하고자 하였다. 이를 위해 사전학습된 다양한 BERT 모델들을 주석한 말뭉치로 파인튜닝하고, 이들 간 성능 평가를 수행하였다. 파인튜닝에 사용한 BERT 언어 모델은 BERT-multilingual, KoBERT, KcBERT 세 가지이다. 최종 학습된 모델은 분류 모델(classification model)로서 주어진 공황장애 관련 질문 문헌으로부터 해당 문헌이 공황장애 경향성이 의심되는지를 이진 분류할 수 있다.

모델 실험을 위해 전체 데이터를 세 유형으로 분류하였다. 먼저 훈련데이터는 실제 모델을 학습시키기 위한 목적으로 사용되며, 검증데이터는 모델 선정을 위해 학습 과정에서 모델의 성능을 지속적으로 확인하는 용도로 활용된다. 마지막으로 평가데이터는 학습 완료되어 최종 선정된 모델의 성능을 평가하기 위해 사용된다. 본 연구에서는 전체 5,884건에 대해 훈련/검증/평가데이터를 70%/15%/15% 비율로 분할하였다. 하이퍼 파라미터 설정은 원논문(Devlin et al., 2018)의 기준을 준용하였다.

성능 평가 기준으로는 정확도(accuracy) 지표를 사용하였다. 정확도는 전체 테스트데이터 가운데 해당 모델이 올바른 정답을 예측한 비율로 계산한다. 또한, 더욱 상세한 성능 평가를 위해 정확률(Precision), 재현율(Recall), F1 척도를 활용하였다. 정확률은 양성 클래스에 속하였다고 판단한 표본 가운데 실제로도 양성 클래스에 속하는 표본의 비율로 계산하며, 재현율은 실제 양성 클래스에 속한 표본 중 실제로도 양성 클래스에 속하였다고 판단한 표본의 비율로 측정한다. F1 척도는 일반적으로 반비례 관계에 놓여 있는 정확률과 재현율 지수를 종합적으로 반영하기 위해 두 지수에 조화평균을 적용한 값이다. 본 연구에서는 세 가지 언어 모델에 대해 F1 척도 값을 비교하고, 이후 F1 척도 값이 가장 높은 언어 모델의 정확률과 재현율을 상세히 살펴보았다.

## 4. 연구 결과

### 4.1 어휘 분석 결과

#### 4.1.1 TF-IDF

공황장애 경향 문헌에서 등장한 단어의 전체 개수는 229,717개이며 중복 값을 제외한 단어 개수는 9,940개이다. 본 연구는 핵심 단어를 확인하기 위해 변형된 TF-IDF값을 계산하였고 그 결과는 <표 3>과 같다. *TFIDF*와 *NTFIDF*의 두가지 방법으로 도출한 상위 5개 단어는 각각 ‘검사(0.4862)’, ‘약(0.4567)’, ‘느낌(0.3953)’, ‘불안(0.3801)’, ‘심장(0.3647)’과 ‘검사(0.7423)’, ‘약(0.7047)’, ‘느낌(0.5763)’, ‘호흡(0.5594)’, ‘불안(0.5401)’으로 나타났다. 상위 5개 단어 중 4개 단어가 같아서 결과는 거의 비슷하다고 볼 수 있다.

먼저 ‘검사’ 단어가 핵심 단어로 나타났는데

<표 3> TF-IDF값

순위	단어	<i>TFIDF</i>	단어	<i>NTFIDF</i>
1	검사	0.4862	검사	0.7423
2	약	0.4567	약	0.7047
3	느낌	0.3953	느낌	0.5763
4	불안	0.3801	호흡	0.5594
5	심장	0.3647	불안	0.5401
6	병원	0.3593	병원	0.5270
7	호흡	0.3514	스트레스	0.5205
8	증상	0.3466	몸	0.5065
9	스트레스	0.3260	정신	0.4897
10	몸	0.3232	머리	0.4648
11	숨	0.3225	가슴	0.4563
12	정신	0.3083	심장	0.4521
13	가슴	0.3044	잠	0.4323
14	잠	0.2962	치료	0.4049
15	머리	0.2936	숨	0.4038

이 단어가 포함된 문헌들을 살펴보면 사람들은 공황장애를 판정받기 전 다양한 검사를 받았고 원인을 찾지 못하고 있었다는 것을 알 수 있다. 주요 문헌은 다음과 같다. “매우 놀라 병원을 가서 심부전 폐검사 피검사 등 다 해봤지만 아무 이상이 없었습니다.”, “신체적인 검사는 다 했는데 이상이 없다고 합니다.” 이를 통해 공황장애는 판별하기 어려우며 공황장애 진단을 받기까지 많은 시간이 걸리는 것을 알 수 있다. 단어 ‘약’ 과 관련된 주요 문헌은 다음과 같다. “신경정신과에서 약을 1년 넘게 먹었습니다. 근데 저는 약을 이제 끊고 싶는데...”, “근데 약을 먹으면 일상생활에 영향도 끼치고 사람이 완전 바보가 된 기분입니다.” 이를 통해 공황장애를 겪는 사람들이 장기간 약을 먹고 있고 약을 끊고 싶어 문의하는 글이 많음을 알 수 있다. 단어 ‘느낌’ 은 대부분의 증상이 명확하게 드러나지 않고 느낌상으로 추측되기 때문에 나타난 것으로 보인다. 주요 문헌은 다음과 같다. “...아무 일도 없었는데 무슨 일이 닥칠 것 같다는 느낌이 너무 심하게 들었고...”, “...공기가 폐까지 전달되지 않는 느낌이구요...”, “...가슴이 뜨거워지는 느낌도 있고 토할거 같고 그래요...” ‘호흡’, ‘불안’, ‘심장’ 단어는 공황장애 증상과 관련된 단어들이다. 이를 통해 호흡과 심장 관련 증상이 주요 증상임을 알 수 있는데 이 두 증상은 공황장애 환자의 임상 특성 연구에서도 가장 견디기 힘든 증상인 것으로 나타났다(고은정 외, 2000).

TF-IDF 결과로 공황장애 경향 문헌에서 나타난 핵심 단어들을 살펴볼 수 있었으며 공황장애의 특성과 주요 증상 등을 파악할 수 있었다. 또한, 공황장애 증상을 느낀 사람들이 주로

어떠한 질문을 소셜미디어에 올리며 궁금해하는지를 살펴 볼 수 있었다.

#### 4.1.2 단어 동시출현 분석 결과

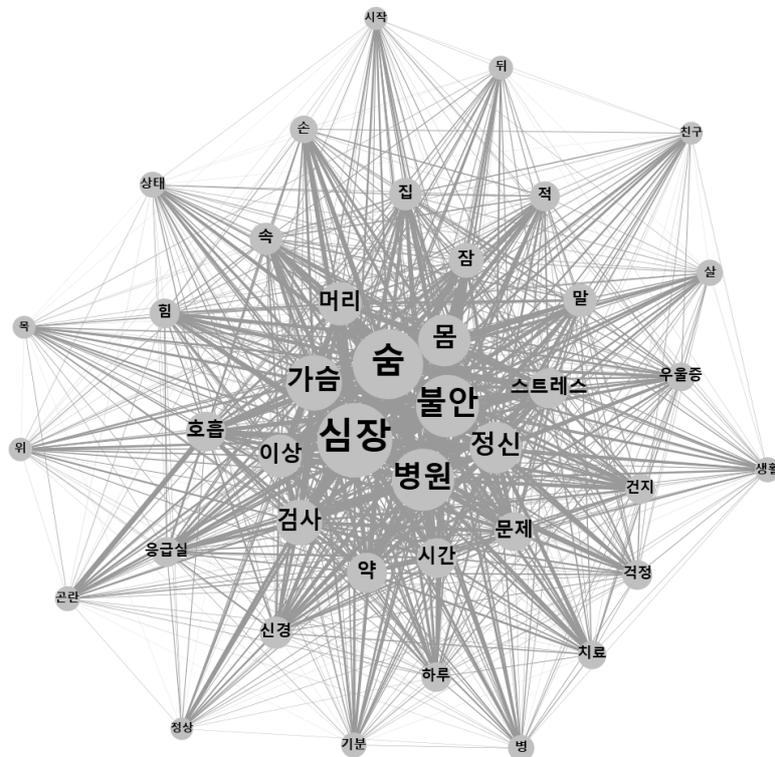
단어 사이의 관련성을 파악하기 위해 공황장애 경향 문헌에서 함께 등장하는 두 개의 단어 쌍의 출현 빈도수를 구하는 단어 동시출현 분석을 진행하였다. 단어 동시출현 분석 결과는 <표 4>와 같고 이를 시각화 한 결과는 <그림 3>과 같다.

분석 결과 ‘숨’과 ‘심장’, ‘숨’과 ‘가슴’, ‘불안’과 ‘심장’, ‘숨’과 ‘불안’, ‘심장’과 ‘가슴’이 상위에 등장하였다. TF-IDF 결과와 마찬가지로 호흡과 심장 관련 증상이 높은 비중을 차지하고 있음을 파악할 수 있다. 또한, ‘숨’, ‘심장’, ‘가슴’ 등 신체적 불편함을 나타내는 단어와 ‘스트레스’, ‘불안’, ‘정신’ 등 정신적 불편함을 나타내는 단어가 함께 공존하는 것으로 볼 때 공황장애가 신체적 정신적 불편을 함께 겪는 복잡한 병임을 알 수 있다. 증상과 상관없는 단어인 ‘병원’과 ‘약’이 단어 동시출현으로 등장한 이유는 공황장애 의심으로 병원에 가서 약 처방을 받고 나서도 증상이 호전되기까지는 시간이 걸려 이에 대해 문의하는 것으로 파악된다.

추가적으로 단어 동시출현의 네트워크 분석을 진행하였다. 분석 결과 전체 단어 개수를 나타내는 노드는 348개, 동시출현 빈도수를 나타내는 엣지는 4,107개이다. 시각화에서 모든 단어를 보여줄 수 없기 때문에 노드의 Degree 범위를 50으로 제한하였고 그 결과 노드 41개, 엣지 797개로 시각화를 진행하였다. 네트워크 밀도는 0.972이다.

〈표 4〉 단어 동시출현

단어 1	단어 2	동시출현 빈도수 (상위 1-15)	단어 1	단어 2	동시출현 빈도수 (상위 16-30)
숨	심장	292	숨	정신	140
숨	가슴	261	숨	머리	140
불안	심장	248	정신	심장	140
숨	불안	215	병원	가슴	131
심장	가슴	204	불안	몸	130
병원	심장	187	호흡	심장	128
숨	몸	177	심장	이상	128
숨	병원	173	숨	스트레스	127
몸	심장	166	몸	병원	126
불안	가슴	161	불안	정신	120
검사	심장	157	검사	이상	115
정신	병원	154	심장	문제	112
불안	병원	151	숨	호흡	111
검사	병원	150	병원	약	109
머리	심장	144	호흡	곤란	108



〈그림 3〉 단어 동시출현 네트워크 시각화

## 4.2 증상 분석 결과

### 4.2.1 증상 빈도수 분석 결과

본 연구에서는 공황장애 말뭉치 5,844문헌을 직접 주석 처리하여 공황장애 경향 문헌 여부를 분류했고 여기에 나타난 공황장애 증상의 특성을 알아보기 위해 증상 빈도수를 분석하였다. 분석 결과는 <표 5>와 같다.

먼저 숨이 가쁘거나 답답한 느낌이 가장 높은 순으로 나타났고 그 다음으로 심계항진, 가슴 두근거림 또는 심장 박동 수가 증가하는 증상이 높은 빈도수로 나타났다. 어지럽거나 불안정하고 멍한 느낌이 드는 증상과 흉통, 복부 불편감도 높은 빈도수를 기록했다. 그 다음으로는 발한과 감각 이상, 죽을 것 같은 공포감, 몸의 떨림, 질식할 것 같은 느낌, 춥거나 화끈거리는 느낌, 비현실감, 스스로 통제할 수 없거나 미칠 것 같은 두려움 순으로 빈도수가 높게 나타났다. 상위 빈도의 증상은 단어 동시출현 분석 결과와 유사하다. 심장 관련 증상과 호흡 관련 증상, 어지럽거나 불안정한 느낌과 흉통 또는 가슴 불편감이 높은 빈도수를 차지하고 있는데 이 4개의 증상이 전체 빈도수의 50% 이상을 차지하고 있어 공황장애를 겪고 있는 사람들이 가장 많이 겪는 주요 증상임을 알 수 있다.

나 불안정한 느낌과 흉통 또는 가슴 불편감이 높은 빈도수를 차지하고 있는데 이 4개의 증상이 전체 빈도수의 50% 이상을 차지하고 있어 공황장애를 겪고 있는 사람들이 가장 많이 겪는 주요 증상임을 알 수 있다.

### 4.2.2 증상 번호 동시출현 분석 결과

공황장애 경향 문헌에 나타난 증상들 사이의 관계성을 살펴보기 위해 증상 번호 간 동시출현 빈도수를 살펴본 결과는 <표 6>과 같다.

가장 빈번하게 함께 등장한 증상 번호는 4번(숨이 가쁘거나 답답한 느낌), 8번(어지럽거나 불안정하거나 멍한 느낌이 들거나 쓰러질 것 같음)으로 나타났다. 공황장애를 호소하는 사람들이 호흡 곤란과 더불어 어지러움, 쓰러질 것 같은 느낌을 가장 많이 경험하고 있음을 파악할 수 있다.

그 다음으로 1번(심계항진, 가슴 두근거림 또는 심장 박동 수의 증가)과 4번(숨이 가쁘거나 답답한 느낌)이 함께 나타났다. 단어 동시출현

<표 5> 주석 증상 빈도수

순위	증상 번호	설명	빈도수
1	4번	숨이 가쁘거나 답답한 느낌	1,778
2	1번	심계항진, 가슴 두근거림 또는 심장 박동 수의 증가	1,519
3	8번	어지럽거나 불안정하거나 멍한 느낌이 들거나 쓰러질 것 같음	1,497
4	6번	흉통 또는 가슴 불편감	1,263
5	7번	메스꺼움 또는 복부 불편감	960
6	2번	발한	837
7	10번	감각 이상(감각이 둔해지거나 따끔거리는 느낌)	750
8	13번	죽을 것 같은 공포	749
9	3번	몸이 떨리거나 후들거림	737
10	5번	질식할 것 같은 느낌	613
11	9번	춥거나 화끈거리는 느낌	572
12	11번	비현실감(현실이 아닌 것 같은 느낌), 이인증(나에게서 분리된 느낌)	244
13	12번	스스로 통제할 수 없거나 미칠 것 같은 두려움	201

〈표 6〉 증상 번호 동시출현 분석

순위	증상번호 및 주요증상 1	증상번호 및 주요증상 2	동시출현 빈도수
1	4번(호흡곤란)	8번(어지러움)	996
2	1번(심장이상)	4번(호흡곤란)	980
3	4번(호흡곤란)	6번(가슴답답)	877
4	1번(심장이상)	8번(어지러움)	827
5	1번(심장이상)	6번(가슴답답)	677
6	6번(가슴답답)	8번(어지러움)	668
7	4번(호흡곤란)	7번(메스꺼움)	638
8	7번(메스꺼움)	8번(어지러움)	633
9	2번(발한)	8번(어지러움)	515
10	2번(발한)	4번(호흡곤란)	511

분석에서도 알 수 있듯이 심장 관련 증상과 호흡 관련 증상이 함께 많이 발생하고 있음을 알 수 있다.

세 번째로 많이 함께 등장한 증상 번호는 4번(숨이 가쁘거나 답답한 느낌)과 6번(흉통 또는 가슴 불편감)으로 나타났다. 호흡 곤란 증상과 더불어 흉통과 같은 가슴 불편 증상이 많이 나타나는 것으로 파악할 수 있다.

이현주 외(2019)가 진행한 한국 공황장애 환자의 신체적 증상 연구에 따르면 순환기 증상(빈맥, 가슴통증)이 63.9%, 호흡기 증상이 55.4%, 어지러움 증상이 28.7%로 가장 많이 나타난다고 하였는데 본 연구에서도 심장, 호흡, 가슴통증, 어지러움이 공황장애의 주요증상으로 나타나 이 4가지 증상이 주요 증상임을 확인하였다. 따라서, 사람들에게 이 증상들이 함께 나타날 때 주의 깊게 확인할 필요가 있다.

### 4.3 모델 학습 및 성능 평가 결과

본 연구에서는 공황장애 경향 문헌을 분류 예측하기 위해 1차로 판별된 말뭉치 데이터를 딥러

닝으로 학습시켜 모델을 만들었다. 모델의 성능을 판별하기 위해 3가지의 BERT 기반 딥러닝 기술(BERT-multilingual, KoBERT, KcBERT)을 사용하여 적용한 결과는 〈표 7〉과 같다. 최종 성능은 검증데이터 기준 가장 높은 성능으로 확인된 모델을 실제 테스트 데이터에 적용한 값으로 하였다.

〈표 7〉 BERT 정확도 비교

모델	정확도
BERT-multilingual	0.7913
KoBERT	0.7875
KcBERT	<b>0.8464</b>

〈표 7〉에 따르면, 세 가지 BERT 모델의 정확도는 약 0.78부터 0.85 사이에 분포하였고 KcBERT, BERT-multilingual, KoBERT 순으로 높았다. 특히, KcBERT의 정확도가 가장 높아 이 모델이 나머지 모델에 비해 우수한 성능을 보이는 것으로 파악된다. 이는 13가지의 증상 중 4개 이상일 때 공황장애로 판별하는 까다로운 기준에도 높은 정확도를 보여 향후 공황장애 경향

문헌과 비 경향 문헌을 예측하는 모델로 사용 가능할 것으로 보인다. 이때 사용된 하이퍼 파라미터는 배치 사이즈 16, 학습률  $3e-5$ , 에포크 9이며, 나머지는 기존 논문(Devlin et al., 2018)의 기본값과 동일하게 적용하였다.

〈표 8〉 F1-Measure 결과

모델	F1-measure
BERT Multilingual	0.7523
KoBERT	0.7345
KcBERT	<b>0.7775</b>

〈표 8〉에서 나타난 F1 비교분석 결과 앞서 살펴본 정확도 분석과 유사한 패턴이 발견되었다. F1 값은 0.73에서 0.78 사이에 분포되어 있으며, KcBERT, BERT-multilingual, KoBERT 순으로 높았다. 정확도 비교와 마찬가지로, KcBERT가 가장 높은 F1 값을 보였다. 다만, 이전과는 다르게 KcBERT의 F1 성능과 나머지 모델의 F1 성능 간의 차이가 상대적으로 완화된 경향을 확인하였다.

정확도 및 F1 비교분석 결과 KcBERT가 가장 높은 성능을 지닌 것으로 관찰되었다. 이는 해당 모델의 사전학습 데이터가 네이버 뉴스 댓글 및 대댓글이어서 네이버 지식iN 텍스트와 유사한 어휘 특성을 가졌기 때문으로 추정된다. KoBERT는 어휘와 구문이 비교적 정확한 위키 피디아 데이터로 사전학습하였고, 데이터의 양도 KcBERT에 비해 상당히 적기 때문에 소셜 미디어 말뭉치를 최적화되는데 한계를 보이는 것으로 파악된다. 또한, BERT-multilingual은 대규모의 데이터를 사전학습하였지만 100개 이상의 서로 다른 언어로 구성되어 있어 한국어

에 특화된 KcBERT 및 KoBERT에 비해 낮은 성능을 보인 것으로 분석된다.

〈표 9〉 KcBERT 실험 결과

클래스	정확률	재현율	F1
공황장애 비(非) 경향 문헌	0.78	0.66	0.72
공황장애 경향 문헌	0.79	0.89	0.84

본 연구는 가장 좋은 성능을 보인 KcBERT가 공황장애 경향 문헌을 분류하는 모델로 사용 가능성을 확인하였다. 모델 활용을 위해 추가로 더 자세한 분석을 수행하였다. 〈표 9〉는 공황장애 비 경향 문헌과 공황장애 경향 문헌에 대한 KcBERT 모델의 성능 분석 결과이다. 공황장애 비 경향 문헌에 대해 약 0.78 정확률, 0.66 재현율을 보이며 0.72의 F1 값을 보인다. 그리고 공황장애 경향 문헌에 대해서는 약 0.79 정확률, 0.89 재현율을 보이며 0.84의 F1 값을 보인다. 이는 정확률에서 유사한 성능을 보였지만 재현율에서 상당한 차이가 발생해 F1 성능 차이가 생긴 것으로 파악할 수 있다.

## 5. 결론

본 연구는 말뭉치 구축과 분석을 통해 공황장애의 특성을 살펴보고 딥러닝 기반 자동 분류 모델을 구축하기 위한 토대를 마련하였다. 이를 위해 소셜미디어에서 수집한 공황장애 관련 문헌을 직접 주석 처리하였다. 정신 질환 진단 매뉴얼인 DSM-5에 나타나 있는 공황장애 증상 기준에 따라 객관성을 확보하여 주석 처리하였고 13가지의 증상 기준을 3차례 교차 검증함으

로써 말뭉치 주석의 정확성을 높였다. 또한, 전문가의 자문을 받은 가이드라인으로 주석의 신뢰도를 높였다. 이렇게 구축된 공황장애 말뭉치는 공황장애의 특성을 파악하고 소셜미디어 텍스트에서 공황장애 경향 문헌을 분류하는 연구의 기반이 되었다는 점에서 의의가 있다.

공황장애 경향 문헌에 대한 TF-IDF 값 산출과 동시출현 단어 분석을 실시하여 공황장애를 겪는 사람들이 사용하는 주요 단어의 특성을 파악하였다. 이후 진행된 공황장애 증상 빈도수 측정으로 공황장애 주요 증상 및 증상 간의 관련성도 확인하였다. 분석 결과, 심장, 호흡, 가슴통증, 어지러움 관련 증상이 공황장애의 주요증상으로 나타났다.

직접 주석처리한 말뭉치를 훈련데이터로 활용하여 딥러닝 기반 자동 분류 모델 학습 및 성능 평가를 하였다. 최신 딥러닝 언어 모델 BERT를 활용하여 공황장애 경향 문헌을 분류하고 탐지할 수 있는 모델을 제안하였다. 성능 평가 결과 BERT Multilingual, KoBERT, KcBERT 세 가

지 모델 중 KcBERT가 정확도 0.84, F1 값 0.77로 가장 우수한 성능을 보였다. 이러한 성능은 본 연구의 대상 데이터가 한국어라는 점을 고려할 때 비교적 우수한 성능으로 평가된다.

본 연구는 국내에서 처음으로 공황장애 관련 말뭉치 구축 및 딥러닝 기반 자동 분류 모델 만드는 연구를 하였다. 이를 통해 주요한 공황장애 증상(심장, 호흡, 가슴통증, 어지러움)을 겪는 사람들이 공황장애를 의심해 볼 수 있는 토대를 마련하고 공황장애의 조기 진단 및 치료를 독려할 수 있다는데 의의가 있다.

그렇지만 학습한 모델을 새로운 데이터에 적용하는 단계까지는 진행하지 않았다는 한계점이 있다. 후속 연구를 통해 공황장애를 자동으로 탐지하고 및 예측하는 모델을 구축한다면 사람들에게 직접적인 도움을 줄 수 있을 것으로 보인다. 또한, 소셜미디어 텍스트를 활용한 다양한 정신 질환 연구로 범위를 확장 시킬 수 있는 토대를 마련하였다는 점에서 시사점이 있다.

## 참 고 문 헌

- 고은정, 최영희, 박기환, 이정흠 (2000). 공황장애의 임상적 특성. *생물치료정신의학*, 6(2), 188-198.
- 김경민, 김규경, 조재춘, 임희석 (2018). 한국 전통문화 말뭉치구축 및 Bi-LSTM-CNN-CRF를 활용한 전통문화 개체명 인식 모델 개발. *한국융합학회논문지*, 9(12), 47-52.
- 김현지, 박서정, 송채민, 송민 (2019). 조현병과 정신분열병에 대한 뉴스 프레임 분석을 통해 본 사회적 인식의 변화. *한국문헌정보학회지*, 53(4), 285-307.  
<http://dx.doi.org/10.4275/KSLIS.2019.53.4.285>
- 박수현 (2017). 공황장애에 대한 근거기반치료. *Korean Journal of Clinical Psychology*, 36(4), 458-469.  
<https://doi.org/10.15842/kjcp.2017.36.4.002>

- 박찬준, 박기남, 문현석, 어수경, 임희석 (2021). 인공지능망 기계번역에서 말뭉치 간의 균형을 고려한 성능 향상 연구. 한국융합학회논문지, 12(5), 23-29.  
<http://doi.org/10.15207/JKCS.2021.12.5.023>
- 백혜진, 조혜진, 김정현 (2017). 정신 질환의 낙인과 귀인에 대한 언론 보도 분석. 한국언론학보, 61(4), 7-43. <https://doi.org/10.20879/kjics.2017.61.4.001>
- 서울대학교병원 (2010). N의학정보 공황장애, 출처:  
<http://www.snuh.org/health/nMedInfo/nView.do?category=DIS&medid=AA000344>
- 서울아산병원 (2014). 질환백과 공황장애. 서울아산병원, 출처:  
<http://www.amc.seoul.kr/asan/healthinfo/disease/diseaseDetail.do?contentId=31583>
- 송민 (2017). 텍스트 마이닝. 서울: 청람.
- 신서희 (2017). 최근 5년간공황장애 환자의 진료경향 분석. 건강보험심사평가원.
- 신용욱 (2021). 현대인의 우울증과 스트레스 관리. 서울아산병원, 출처:  
<http://psy.amc.seoul.kr/asan/depts/psy/K/bbsDetail.do?menuId=862&contentId=213922>
- 유정옥 (2019). 텍스트마이닝을 이용한 청소년의 성고민 분석. 보건정보통계학회지, 44(2), 181-188.  
<https://doi.org/10.21032/jhis.2019.44.2.181>
- 이성직, 김한준 (2009). TF-IDF 의 변형을 이용한 전자뉴스에서의 키워드 추출 기법. 한국전자거래학회지, 14(4), 59-73.
- 이현주, 김민숙, 김세주, 박선철, 양중철, 이경욱, 이상혁, 이승재, 임세원, 채정호, 한상우, 홍진표, 서호준 (2019). 한국인에게 나타나는 공황장애의 신체적 증상 및 유발 요인의 특징. Journal of Korean Neuropsychiatric Association, 58(4), 339-345. <https://doi.org/10.4306/jknpa.2019.58.4.339>
- 한국전자통신연구원 (2019). KorBERT. 출처: [https://aiopen.etri.re.kr/service\\_dataset.php](https://aiopen.etri.re.kr/service_dataset.php)
- American Psychiatric Association. (2013). Diagnostic and Statistical Manual of Mental Disorders (5th ed.). Washington, DC: Author.
- Benton, A., Mitchell, M., & Hovy, D. (2017). Multi-task Learning for Mental Health using Social Media Text. arXiv preprint arXiv:1712.03538.
- Devlin, J., Chang, M. W., Lee, K., & Toutanova, K. (2018). Bert: Pre-training of deep bidirectional transformers for language understanding. arXiv preprint arXiv:1810.04805.
- Devlin, J. (2021). Bert multilingual. Available:  
<https://github.com/google-research/bert/blob/master/multilingual.md>
- Du, J., Zhang, Y., Luo, J., Jia, Y., Wei, Q., Tao, C., & Xu, H. (2018). Extracting psychiatric stressors for suicide from social media using deep learning. BMC medical informatics and decision making, 18(2), 77-87. <https://doi.org/10.1186/s12911-018-0632-8>
- Jeon, Heewon. (2018). KoSpacing: Automatic Korean word spacing. Available:

- <https://github.com/haven-jeon/PyKoSpacing>
- Jeon, Heewon. (2021). KoBERT. Available: <https://github.com/SKTBrain/KoBERT>
- Ko, Hyunwoong. (2021). Korean Sentence Splitter. Available:  
<https://github.com/hyunwoongko/kss>
- Lee, Junbum. (2021). KcBERT: Korean Comments BERT. Available:  
<https://github.com/Beomi/KcBERT>
- Medrouk, L. & Pappa, A. (2017). Deep learning model for sentiment analysis in multi-lingual corpus. In International Conference on Neural Information Processing (pp. 205-212). Springer, Cham. [https://doi.org/10.1007/978-3-319-70087-8\\_22](https://doi.org/10.1007/978-3-319-70087-8_22)
- Moessner, M., Feldhege, J., Wolf, M., & Bauer, S. (2018). Analyzing big data in social media: Text and network analyses of an eating disorder forum. *International Journal of Eating Disorders*, 51(7), 656-667. <https://doi.org/10.1002/eat.22878>
- Mozafari, M., Farahbakhsh, R., & Crespi, N. (2019). A BERT-based transfer learning approach for hate speech detection in online social media. In International Conference on Complex Networks and Their Applications (pp. 928-940). Springer, Cham. [https://doi.org/10.1007/978-3-030-36687-2\\_77](https://doi.org/10.1007/978-3-030-36687-2_77)
- Roy-Byrne, P. P., Craske, M. G., & Stein, M. B. (2006). Panic disorder. *The Lancet*, 368(9540), 1023-1032. [https://doi.org/10.1016/S0140-6736\(06\)69418-X](https://doi.org/10.1016/S0140-6736(06)69418-X)
- Salton, G. & M. J. McGill. (1983). Introduction to modern information retrieval.
- Sekulić, I. & Strube, M. (2020). Adapting deep learning methods for mental health prediction on social media. arXiv preprint arXiv:2003.07634.
- Song, Min. (2021, June 6). treform. Available: <https://github.com/MinSong2/treform>
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L., & Polosukhin, I. (2017). Attention is all you need. arXiv preprint arXiv:1706.03762.
- Yu, L., Jiang, W., Ren, Z., Xu, S., Zhang, L., & Hu, X. (2021). Detecting changes in attitudes toward depression on Chinese social media: A text analysis. *Journal of affective disorders*, 280, 354-363. <https://doi.org/10.1016/j.jad.2020.11.040>

• 국문 참고문헌에 대한 영문 표기  
(English translation of references written in Korean)

- ETRI (2019). KorBERT. Available: [https://aiopen.etri.re.kr/service\\_dataset.php](https://aiopen.etri.re.kr/service_dataset.php)
- Kim, Gyeong-Min, Kim, Kue-kyeng, Jo, Jae-choon, & Lim, Heui-Seok (2018). Constructing for

- Korean traditional culture corpus and development of named entity recognition model using Bi-LSTM-CNN-CRFs. *Journal of the Korea Convergence Society*, 9(12), 47-52.
- Kim, Hyun-Ji, Park, Seo-Jeong, Song, Chae-Min, & Song, Min (2019). Text mining driven content analysis of social perception on schizophrenia before and after the revision of the terminology. *Journal of the Korean Society for Library and Information Science*, 53(4), 285-307.
- Ko, Eun-Jung, Choi, Young-Hee, Park, Gi-Hwan, & Lee, Jung-Heum (2000). Clinical characteristics of panic disorder. *Journal of the Korean Society of Biological Therapies in Psychiatry*, 6(2), 188-198.
- Lee, Hyun-Joo, Gim, Min-Sook, Kim, Se-Joo, Park, Seon-Cheol, Yang, Jong-Chul, Lee, Kyoung-Uk, Lee, Sang-Hyuk, Lee, Seung-Jae, Lim, Se-Won, Chae, Jeong-Ho, Han, Sang-Woo, Hong, Jin-Pyo, & Seo, Ho-Jun (2019). The bodily panic symptoms and predisposing stressors in Korean patients with panic disorder. *Korean Neuropsychiatric Association*, 58(4), 339-345. <https://doi.org/10.4306/jknpa.2019.58.4.339>
- Lee, Sungjick & Kim, Han-joon (2009). Keyword extraction from news corpus using modified TF-IDF. *The Journal of Society for e-Business Studies*, 14(4), 59-73.
- Paek, Hye-Jin, Cho, Hye-Jin, & Kim, Jung-Hyun (2017). Content analysis of news coverage on stigma and attribution regarding mental illness. *Korean Journal of Journalism & Communication Studies*, 61(4), 7-43. <https://doi.org/10.20879/kjcs.2017.61.4.001>
- Park, Chan-Jun, Park, Ki-Nam, Moon, Hyeon-Seok, Eo, Su-Gyeong, & Lim, Heui-Seok (2021). A study on performance improvement considering the balance between corpus in neural machine translation. *Journal of the Korea Convergence Society*, 12(5), 23-29.
- Park, Soo-Hyun (2017). Evidence-based treatment of panic disorder. *Korean Journal of Clinical Psychology*, 36(4), 458-469. <https://doi.org/10.15842/kjcp.2017.36.4.002>
- Seoul Asan Hospital (2014). Disease encyclopedia panic disorder. Available: <http://www.amc.seoul.kr/asan/healthinfo/disease/diseaseDetail.do?contentId=31583>
- Seoul National University Hospital (2010). N medical information panic disorder. Available: <http://www.snuh.org/health/nMedInfo/nView.do?category=DIS&medid=AA000344>
- Shin, Seo-Hee (2017). Panic disorder patients in the last 5 years Treatment trend analysis. Health Insurance Review & Assessment Service.
- Shin, Yong-Wook (2014). Seoul Asan Hospital. Available: <http://psy.amc.seoul.kr/asan/depts/psy/K/bbsDetail.do?menuId=862&contentId=213922>
- Song, Min (2017). *Textmining*. Seoul: Chungnam.

- Yu, J. (2019). Text mining for identifying topics in internet Q&A about adolescents' sexual concerns. *Journal of Health Informatics and Statistics*, 44(2), 181-188.  
<https://doi.org/10.21032/jhis.2019.44.2.181>