Natural Language Processing

자연어 처리: 전처리 & 토큰화

강사 양석환

자연어 처리를 위한 전 처리 과정

자연어 처리를 위한 전처리 과정

- 자연어 처리에서 가장 중요한 것은 “전처리 과정”이다
  - 외부로 드러나지 않는 과정이다 보니 상대적으로 주목도가 낮음
  - 다루고자 하는 언어, 문제에 따라 전처리 과정이 다름
  - 기술의 내용이 기반이 되어야 하지만 경험의 누적이 더욱 중요한 분야

일반적인 전처리 과정

- 언어, 문제에 따라 다른 전처리 과정을 거치지만 일반적으로 다음과 같음

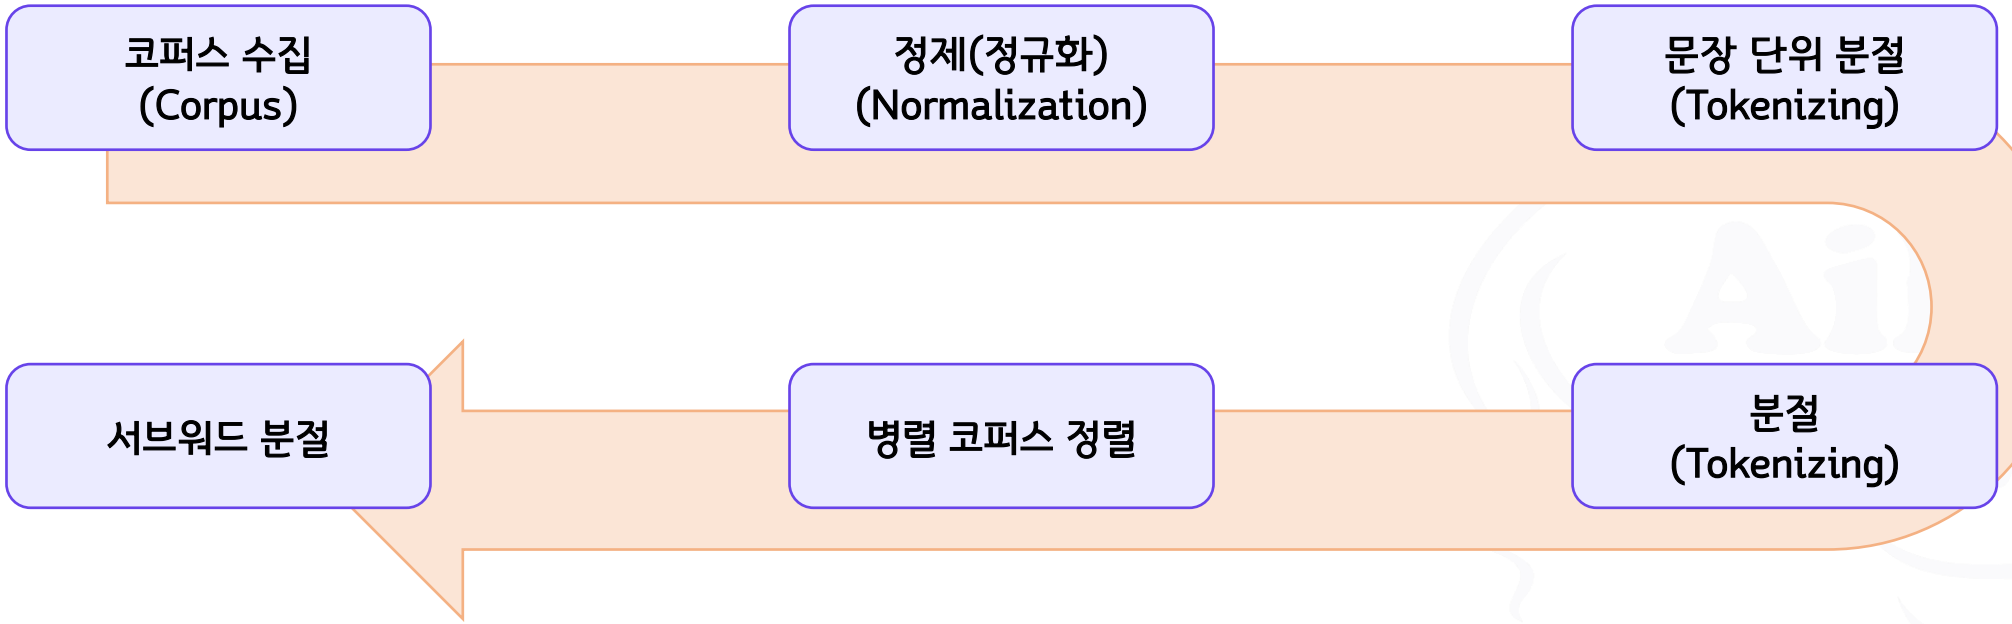

코퍼스 (Corpus, 말뭉치)

- 여러 단어로 이루어진 문장을 가리킴
- 자연어 처리를 위하여 머신러닝/딥러닝을 수행하려면 훈련데이터가 필요하며, 다수의 문장으로 구성된 코퍼스가 훈련데이터로 사용됨
- 코퍼스가 많고 오류가 없을 수록 자연어 처리 모델은 더욱 정교해지고 정확도가 높아짐

코퍼스 (Corpus, 말뭉치)

- **코퍼스의 분류**
  - **구성 언어에 따른 분류**
    - 단일 언어 코퍼스(Monolingual Corpus)
    - 이중 언어 코퍼스(Bilingual Corpus)
    - 다중 언어 코퍼스(Multilingual Corpus)
  - **구성 방법에 따른 분류**
    - 병렬 코퍼스(Parallel Corpus) : 각 언어가 서로 쌍으로 구성되는 코퍼스
      - 예:

영문	한글
I love to go to school.	나는 학교에 가는 것을 좋아한다.
I am a doctor.	나는 의사이다.

코퍼스 (Corpus, 말뭉치)

- **코퍼스 수집**
  - **공개 데이터 사용하기**
    - 감성 분석 등의 텍스트 분류 데이터, 기계번역을 위한 언어 쌍 데이터 등 각종 대회 또는 논문을 위한 데이터가 주류
    - 데이터의 분량과 내용의 분야가 한정적
  - **유료 데이터 구매하기**
    - 비용 문제

코퍼스 (Corpus, 말뭉치)

- **웹 크롤링**
  - 다양한 웹 사이트에서 크롤링 가능 → 다양한 분야의 데이터 획득 가능
  - 특정 분야에 대한 자연어 처리가 아니라면 최대한 많은, 다양한 분야의 데이터가 필수
  - 무분별한 웹 크롤링은 법적 문제 유발 가능, 웹 서버에 불필요한 트래픽 가중

    → 적절한 사이트에서, 올바른 방법으로, 상업적인 목적이 아닌 경우로..

    와 같이 제한된 크롤링 권장

코퍼스 (Corpus, 말뭉치)

- 단일 언어 코퍼스 수집
  - 가장 손쉽게 구할 수 있는 코퍼스
  - 올바른 도메인의 코퍼스 수집 필요
  - 사용 가능한 형태로 가공하는 과정 필요
  - 위키피디아 등의 사이트에서 덤프 데이터를 제공하기도 함
  - 적법한 인터넷 사이트 등에서 다운로드 가능
  - 머신러닝 경진대회 플랫폼 사이트 “캐글” 등에서 쉽게 다운로드 가능

코퍼스 (Corpus, 말뭉치)

- **도메인 별 단일 언어 코퍼스 수집 사례**

문체	도메인	수집처	정제 난이도
대화체	일반	채팅 로그	높음
대화체	일반	블로그	높음
문어체	시사	뉴스 기사	낮음
문어체	과학, 교양, 역사 등	위키피디아	중간
문어체	과학, 교양, 역사, 서브 컬쳐 등	나무위키	중간
대화체	일반 (각 분야별 게시판 존재)	클리앙	중간
문어체	일반, 시사 등	PGR21	중간
대화체	일반	드라마, 영화 자막	낮음

코퍼스 (Corpus, 말뭉치)

- **다중 언어 코퍼스 수집**
  - **다중 언어 코퍼스는 기계번역을 목적으로 하는 경우가 많음**
  - **단일 언어 코퍼스에 비하여 수집하기 어려움**
  - **자막 데이터 등은 저작권이 있는 경우가 많으므로 저작권 정보 확인 필수**
  - **자막 등은 번역 품질 문제가 큰 영향을 미치므로 주의 요함**
  - **자막 등은 대화형 언어이며, 언어 별 특징에 따른 문제도 고려 요함**
    - 예: 영어 자막에서 대명사로서 지칭할 때, “아빠” → “you”, “친구 명“ → ”you”

정제 (Normalization, 정규화)

- 텍스트를 사용하기 위한 필수 과정
- 원하는 업무, 문제, 응용 분야에 따라 필요한 정제의 수준, 깊이 상이
  - 예시
    - 음성 인식을 위한 언어 모델: 괄호, 기호, 특수문자 등 포함 금지
    - 개인정보, 민감한 정보: 제거 또는 변조해서 모델링

정제 (Normalization, 정규화)

- 전각 문자 제거
  - 중국어, 일본어 문서는 대부분 전각 문자로 표기됨
  - 한국어 문서의 일부는 전각 문자로 표기된 기호, 숫자 등을 사용함
  - 데이터 처리는 반각 문자를 기준으로 하므로 전각 문자를 반각 문자로 변형하는 작업이 요구됨

정제 (Normalization, 정규화)

- 대소문자 통일
  - 일부 영어 코퍼스에서는 약자 등에서 대소문자 표현이 통일되지 않음
    - 예: New York City 약자 → NYC, nyc, N.Y.C., N.Y.C 등
  - 데이터를 하나의 형태로 통일하여 희소성을 줄이는 효과 기대
    - 희소 표현에 의한 메모리 사용량 감소 가능
  - 딥러닝 모델이 확산되면서 중요도가 떨어짐

정제 (Normalization, 정규화)

- 정규 표현식을 사용한 정제
  - 다량의 코퍼스는 특수문자, 기호 등의 노이즈가 많음(특히 크롤링의 경우)
  - 웹 사이트의 성격에 따라 일정한 패턴을 가지는 경우도 많음
  - 정규 표현식의 사용 방법의 예
    - [ ] 사용: [2345cde] → “2 or 3 or 4 or 5 or c or d or e”의 의미
    - - 사용: [2-5c-e] → “2 or 3 or 4 or 5 or c or d or e”의 의미
    - [^] 사용: [^2-5c-e] “ → 2~5, c~e를 제외한 한 글자”의 의미 (Not의 의미)
    - ( ) 사용: (x)(yz) → 그룹 1:x, 그룹 2: yz (그룹을 구성할 수 있음)

정제 (Normalization, 정규화)

- **지정 문자 사용**

지정 문자	설명	예제
^	이 패턴으로 시작해야 함	^abc : abc로 시작해야 함 (abcde, abc123 등)
$	이 패턴으로 종료되어야 함	xyz$: xyz로 종료되어야 함 (123xyz, strxyz 등)
[문자들]	문자들 중의 하나여야 함 가능한 문자들의 집합을 정의함	[Pp]ython : “Python” 또는 “python”
[^문자들]	[문자들]의 반대 피해야 할 문자들의 집합을 정의함	[^aeiou] : 소문자 모음(母音)이 아닌 문자들
|	두 패턴 중 하나여야 함 (OR 기능)	a|b : a 또는 b 여야 함
?	앞 패턴이 없거나 하나여야 함 (Optional 패턴을 정의할 때 사용)	\d? : 숫자가 하나 있거나 없어야 함
+	앞 패턴이 하나 이상이어야 함	\d+ : 숫자가 하나 이상이어야 함
*	앞 패턴이 0개 이상이어야 함	\d* : 숫자가 없거나 하나 이상이어야 함

정제 (Normalization, 정규화)

- **지정 문자 사용**

지정 문자	설명	예제
패턴{n}	앞 패턴이 n번 반복해서 나타나는 경우	\d{3} : 숫자가 3개 있어야 함
패턴{n,m}	앞 패턴이 최소 n번, 최대 m번 반복해서 나타나는 경우 (n 또는 m은 생략가능)	\d{3,5} : 숫자가 3개, 4개, 또는 5개 있어야 함
\d	숫자 ([0-9]와 같음)	\d\d\d : 0~9 범위의 숫자가 3개 (123, 000 등)
\D	숫자를 제외한 모든 문자([^0-9]와 같음)	
\s	공백 문자(white space) ([\t\n\r\f]와 같음)	\s\s : 공백문자 2개 (\r\n, \t\t 등)
\S	공백 문자를 제외한 모든 문자	
\w	alphanumeric(알파벳+숫자) + '_' 포함 ([A-Za-z0-9]와 같음)	\w\w\w : 문자가 3개 (xyz, ABC 등)
\W	non-alphanumeric 문자 및 '_' 제외 ([^A-Za-z0-9]와 같음)	
.	뉴 라인(\n)을 제외한 모든 문자	.{3} : 문자가 3개 (F15, 0x0 등)

정제 (Normalization, 정규화)

- **그룹 사용**
  - **정규 표현식에서 괄호는 그룹을 의미**
  - **예**
    - **전화번호 패턴**
      - \d{3}-\d{4}-\d{4} : 010-1234-5678 → 일반적인 사용
      - (\d{3})-(\d{4}-\d{4}) : 010-1234-5678

        → 지역번호 3자리는 group(1), 나머지 번호는 group(2)로 묶어서 파라미터로 가지고 올 수 있음

        → 전체 번호를 가져올 때는 group(0)으로 사용

정제 (Normalization, 정규화)

- **정규 표현식 적용 예제**

  - 자연어 문제를 풀고자 한다.
  - 문서의 마지막 줄에 전화번호 등의 개인 정보가 포함된 문서를 데이터 셋으로 사용하려고 한다.
  - 이때, 해당 개인 정보를 제외하고 사용해야 한다.

  Hello Seokhwan, I would like to introduce regular expression in this section.

  ~~~

  Thank you!

  Sincerely,

  Seokhwan: +82-10-1234-5678
  ~~~

정제 (Normalization, 정규화)

- **정제 작업**
  - **마지막 줄에 전화번호가 있다 → 삭제 → 마지막 줄에 전화번호가 없는 경우는?? → X**
  - **다양한 상황을 고려하여야 한다**

- 이름이 전화번호 앞에 나올 수도 있다.
- 이름 뒤에 콜론(:) 이 나올 수도 있다.
- 콜론 앞/뒤로는 탭 또는 공백이 다수 존재할 수도 있다.
- 전화번호는 국가번호를 포함할 수도 있다.
- 국가번호는 최대 3자리이다.
- 국가번호의 앞에는 '+'가 붙을 수도 있다.
- 전화번호 사이에 '-'가 들어갈 수도 있다.
- 전화번호는 빈칸 없이 표현된다.

- 전화번호 맨 앞과 지역번호(또는 010)의 다음에는 괄호가 들어갈 수도 있다.
- 괄호는 한쪽만 나올 수도 있다.
- 지역번호 자리의 맨 처음에 나오는 0은 빠질 수도 있다.

  (즉 2자리가 될 수도 있다.)
- 지역번호 다음의 번호 그룹은 3자리 또는 4자리의 숫자이다.
- 마지막은 항상 4자리 숫자이다.
- 기타 등등...

정제 (Normalization, 정규화)

- **정제 작업 결과**
  - ([\w]+\s*:? \s*)?\(?\+?([0-9]{1,3})?\-?[0-9]{2,3}(\)|\-)?[0-9]{3,4}\-?[0-9]{4}

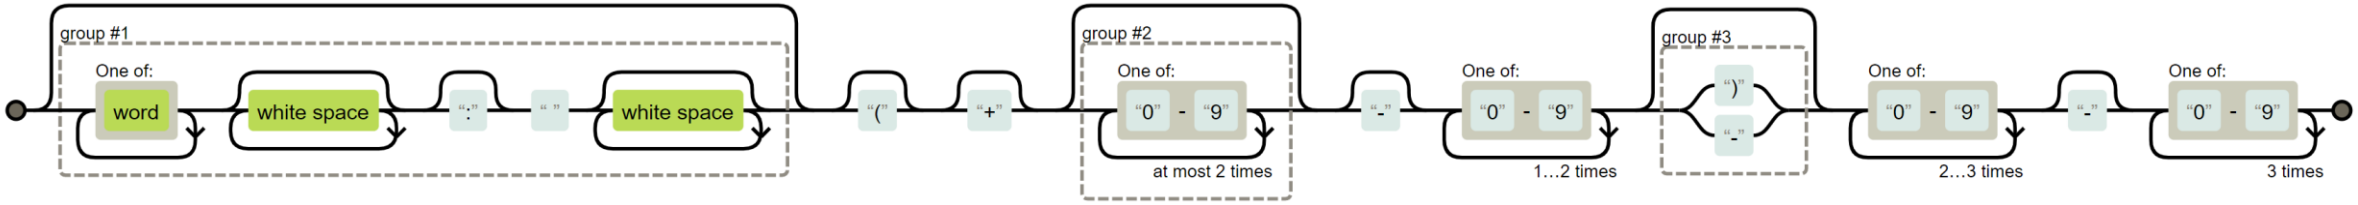

https://regexper.com/ 에서 디스플레이하기

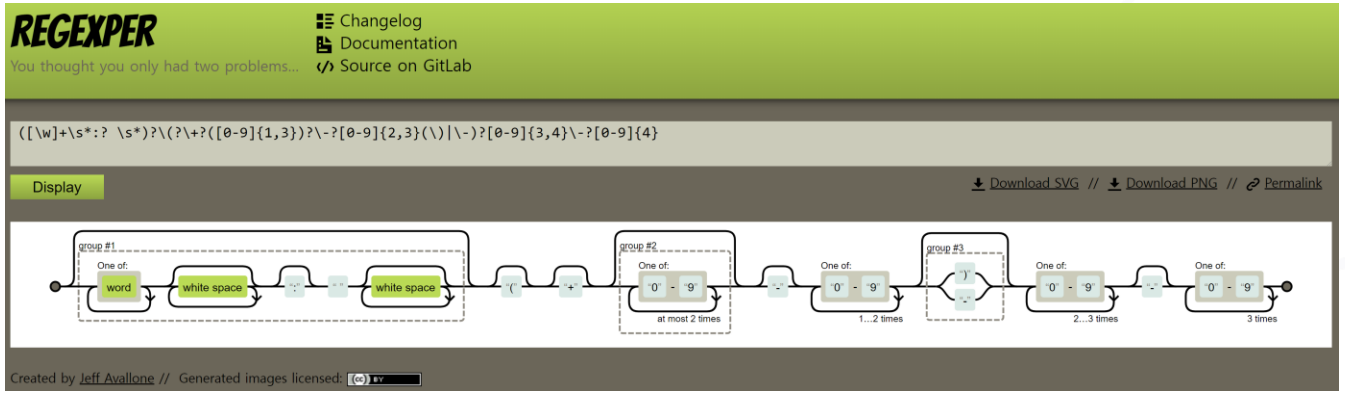

분절

- 자연어 처리에 사용되는 데이터
  - 입력단위: 기본적으로 문장 단위
    - 한 줄에 한 문장 요구
    - 여러 문장이 한 줄에 있거나, 한 문장이 여러 줄에 걸쳐 있는 경우

      → 문장 단위 분절이 요구됨

분절

- 문장 단위 분절의 기준
  - 마침표(.)를 기준으로 잡으면 → U.S와 같은 약자, 3.14와 같은 소수점 등의 문제 발생
  - 적절한 알고리즘 또는 모델이 필요함

    → 직접 구현하기 어려우므로 잘 알려진 자연어 처리 툴킷, 패키지 등의 활용 권장

분절

- 단어 단위 분절: 토크나이징(형태소 분석)
  - 풀고자 하는 문제에 따라 형태소 분석 또는 단순 분절을 통한 정규화 수행
  - 가장 기본적인 기준은 띄어쓰기
    - 비슷한 문화권인 한국, 중국, 일본의 경우
      - 한국: 근대 이후 띄어쓰기 도입. 아직 제대로 사용하지 못하는 사람 많음
      - 중국: 띄어쓰기 사용하지 않음. 문자단위로 처리해도 그다지 차이가 없음
      - 일본: 띄어쓰기 사용하지 않음. 적절한 언어모델 구성을 위해 띄어쓰기가 요구되고 있음
    - 영어의 경우
      - 띄어쓰기가 필수. 대부분의 경우 규칙이 잘 지켜짐

분절

- NLTK (Natural Language Toolkit)
  - 자연어 처리 기능을 제공하는 파이썬 라이브러리
  - 텍스트로부터 단어 개수, 출현 빈도, 어휘 다양도 같은 통계적인 정보를 쉽게 얻을 수 있음
  - 손쉽게 이용할 수 있도록 모듈 형식으로 기능을 제공함

  - 전처리 모듈: 분류 토큰화(tokenization), 스테밍(stemming) 등
  - 분석 모듈: 구문분석(parsing), 클러스터링, 감정 분석(sentiment analysis), 태깅(tagging) 등
  - 추론 모듈: 시맨틱 추론(semantic reasoning) 등
  - 각 모듈은 최소 2개 이상의 알고리즘을 제공하여 사용자가 원하는 알고리즘을 선택할 수 있도록 지원

(예) 분류 알고리즘의 경우 SVMs, 나이브 베이즈, 로지스틱 회귀와 결정 트리를 제공 중.
이들 중 하나를 선택해 분류 알고리즘을 적용할 수 있음

분절

- 문서화가 잘 되어 있음
- 포럼이 활성화 되어 있어 개발 지원을 받을 수 있음
- 많은 레퍼런스를 포함함
- 속도가 다소 느림

- 원래 한국어를 지원하지 않았기때문에 국내 연구자들이 KoNLTK와 같은 모듈을 개발하여 사용하였음
- 최근 한국어도 지원 언어에 포함됨.

- 각 언어별 주요 자연어 처리 지원 패키지

언어	패키지명	개발언어	특징
한국어	Mecab	C++	일본어 Mecab을 Wrapping함. 속도가 가장 빠르지만 설치가 까다로움 정상적으로 설치를 성공한 경우, KoNLPy에서 호출하여 사용 가능
한국어	KoNLPy	Python Wrapping(복합)	Pip를 통해 설치 가능. 사용이 쉬움. 일부 모듈의 경우 속도가 느림
일본어	Mecab	C++	속도 빠름
중국어	Stanford Parser	Java	미국 스탠포드에서 개발
중국어	PKU Parser	Java	북경대에서 개발. 스탠포드 파서와 성능 차이가 거의 없음
중국어	Jieba	Python	가장 최근에 개발됨. 파이썬으로 개발되어 시스템 구성에 용이함

병렬 코퍼스 정렬

- **병렬 코퍼스**
  - **동일한 내용을 가진 복수 언어 말뭉치(코퍼스)**
    - 예: 한국어 원문과 영어 번역문을 문장 단위로 대응시켜 DB를 구축한 것
  - **데이터 자체가 복수 언어를 대상으로 만들기 때문에 언어의 대조 연구나 기계번역, 대역 사전구축, 언어 교육(작문 교육, 회화 교육) 등에 유용하게 사용됨**

병렬 코퍼스 정렬

- **병렬 코퍼스 정렬**
  - **대부분의 병렬 코퍼스들은 “여러 문장” 단위로 정렬**
    - 예: 영자 신문에서 크롤링한 영문기사와 한글기사의 매핑

      → 문서 간의 매핑

      → 문장 사이의 정렬은 이루어지지 않음

      → 각 문장을 정렬하고 동일한 내용의 문장끼리 매핑해 주어야 함

      → 불필요한 내용 정리, 문장 간 정렬 재정비 등의 작업이 요구됨

병렬 코퍼스 정렬

- **병렬 코퍼스 제작 프로세스**

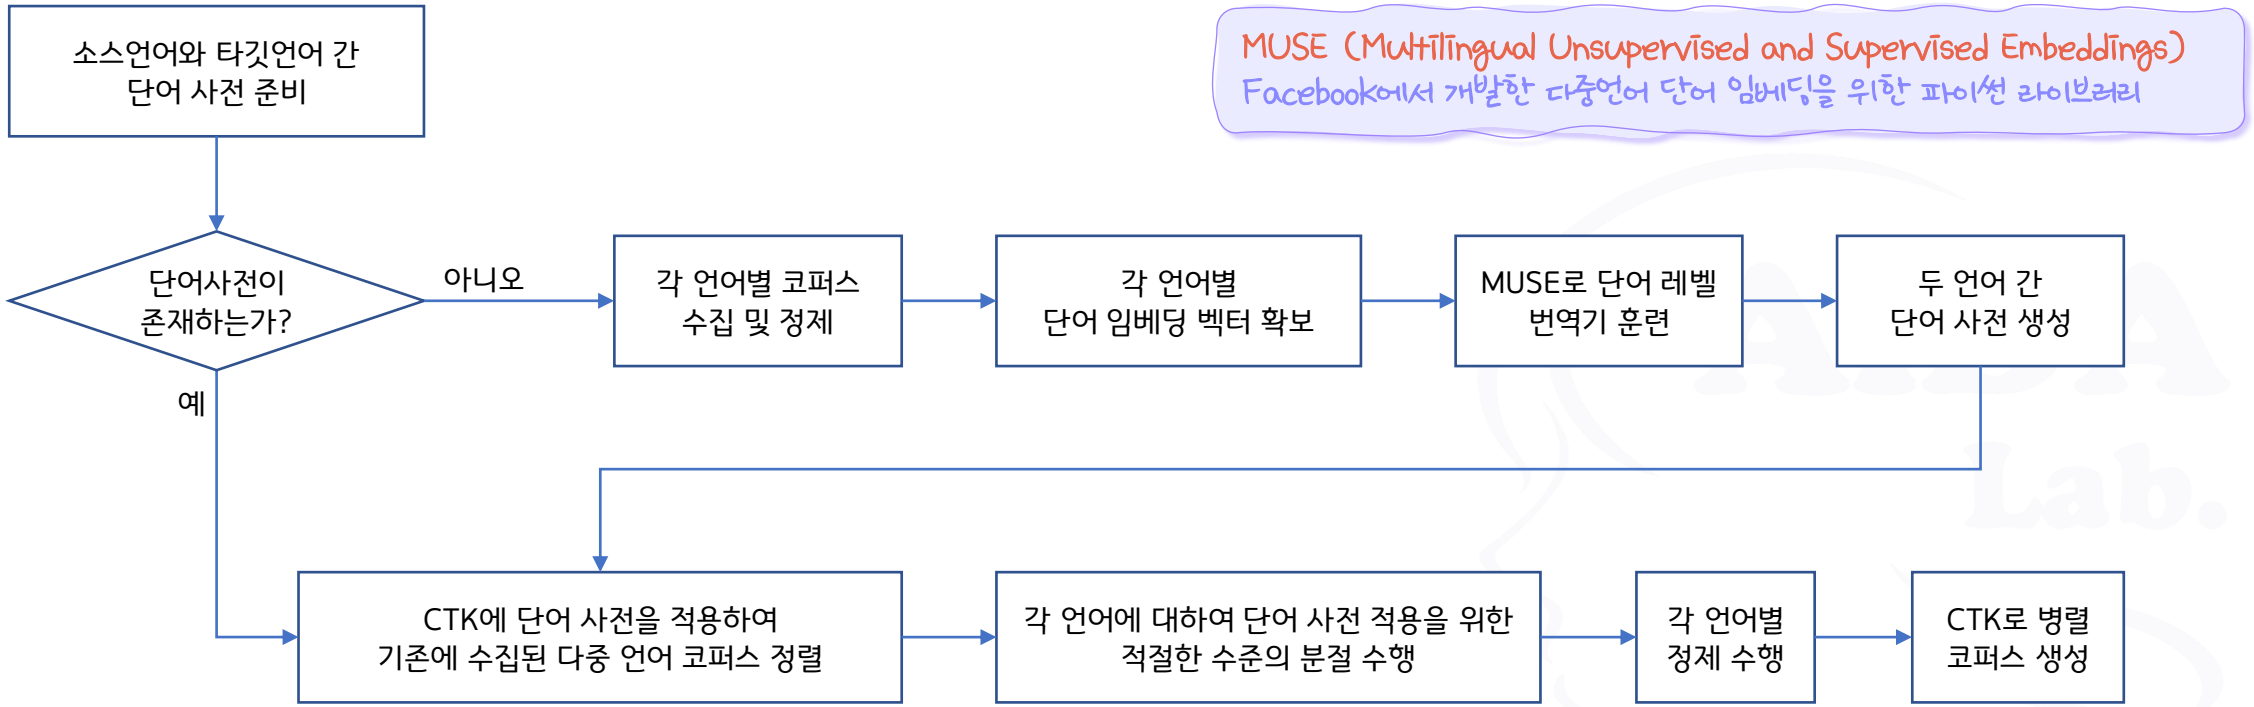

MUSE (Multilingual Unsupervised and Supervised Embeddings)
Facebook에서 개발한 다중언어 단어 임베딩을 위한 파이썬 라이브러리

CTK (Champollion Toolkit)
가능한 한 많은 언어 쌍에 대하여 즉시 사용할 수 있는 병렬 텍스트 문장 정렬도구를 제공하는 오픈소스 툴 킷

병렬 코퍼스 정렬

- **사전 생성**
  - **단어 사전 구축에는 많은 비용이 요구됨**
    - **기 구축된 사전 활용 또는 MUSE를 이용한 단어 사전 자동 생성(구축) 활용**
      - **MUSE: 병렬 코퍼스가 없는 상황에서 사전 구축을 위한 방법, 코드 제공**
        - 각 단일 언어 코퍼스를 통해 구축한 언어별 단어 임베딩 벡터에 대해 다른 언어의 임베딩 벡터와 매핑을 통하여 단어간 번역 수행
        - 비지도 학습을 적용한 모델
  - **구축된 사전은 CTK의 입력으로 사용됨**

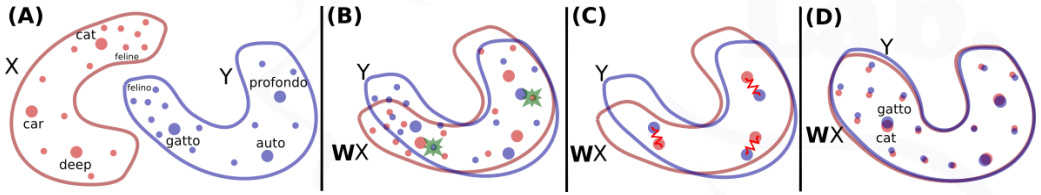

https://github.com/facebookresearch/MUSE/blob/main/outline_all.png

병렬 코퍼스 정렬

- MUSE를 통한 비지도 학습의 결과인 단어사전의 예

stories <> 이야기	dark <> 어두운
stories <> 소설	dark <> 어둠
contact <> 연락	dark <> 짙
contact <> 연락처	song <> 노래
contact <> 접촉	song <> 곡
green <> 녹색	song <> 음악
green <> 초록색	salt <> 소금
green <> 빨간색	

- 비지도 학습이지만 꽤 정확한 단어간 번역을 확인할 수 있음
- <>을 구분 문자로 사용

병렬 코퍼스 정렬

- **CTK를 활용한 정렬**
  - **CTK (Champollion Toolkit)**
    - **구축된 단어사전을 이용하여 여러 라인으로 구성된 언어별 문서에 대해 문장 정렬 수행**
    - **정렬 결과 예시**

omitted <=> 1	타깃언어의 1, 2, 3번째 문장: 짝을 찾지 못해서 버려짐
omitted <=> 2	
omitted <=> 3	
1 <=> 4	소스언어의 1, 2, 3번째 문장: 타깃 언어의 4, 5, 6번째 문장과 매핑
2 <=> 5	
3 <=> 6	
4,5 <=> 7	소스언어의 4, 5번째 문장: 타깃 언어의 7번 문장과 매핑
6 <=> 8	소스언어의 6, 7, 8번째 문장: 타깃 언어의 8, 9, 10번째 문장과 매핑
7 <=> 9	
8 <=> 10	
9 <=> omitted	소스언어의 9번 문장: 짝을 찾지 못해서 버려짐

- 일대일, 일대다, 다대일 매핑 가능
- 버려지는 경우도 가능

서브워드 분절

- **서브워드 분절 기법**
  - **“단어는 의미를 가진 더 작은 서브워드들의 조합으로 이루어진다”는 가정 하에 적용되는 알고리즘**
  - **BPE(Byte Pair Encoding) 알고리즘을 기반으로 함**
  - **현재 시점에서 필수 전처리 방법으로 꼽힘**

영어와 한국어의 서브워드 분절 사례

언어	단어	조합
영어	concentrate	con(=together) + centr(=center) + ate(=make)
한국어	집중(集中)	集(모을 집) + 中(가운데 중)

서브워드 분절

- **서브워드 분절 효과**
  - **적절하게 분절하면 어휘 수 감소 및 희소성의 효과적 감소 가능**
  - **Unknown 토큰에 대한 효율적인 대처 가능**
    - 자연어 처리에서는 문장을 입력 받을 때 단어들의 시퀀스로 받아들임
    - Unknown이 발생하면 언어모델의 확률이 크게 하락하고 적절한 문장 생성이 어려워짐

Tokenizing

Tokenizing(형태소 분석) 개요

- 자연어: 우리가 일상 생활에서 사용하는 언어
- 기본적으로 컴퓨터는 자연어를 이해하지 못한다
- 컴퓨터에게 자연어를 이해하게 하려면?
  - 여러 방법이 연구되어 왔으나 가장 일반적인 방법은?
    - 토크나이징과 임베딩 기반으로 컴퓨터가 이해할 수 있도록 데이터화
    - 텍스트 유사도를 이용하여 문맥 분류

Tokenizing(형태소 분석) 개요

- **Tokenizing이란?**
  - 주어진 문장에서 토큰 단위로 정보를 나누는 작업
  - 문장 형태의 데이터를 처리하기 위해 제일 처음 수행해야 하는 기본적인 작업
  - 주로 텍스트 전처리 과정에서 사용됨
  - 토큰: 일정한 의미가 있는 가장 작은 정보 단위
- **Tokenizing 과정**
  - 어떤 문장을 일정한 의미가 있는 가장 작은 단어로 나눈다
  - 나눠진 단어들을 이용해 의미를 분석한다 (이때 가장 기본이 되는 단어가 토큰이다)

토큰화(Tokenizing)의 방식

- 토큰화(Tokenizing)의 기본적인 방식
  - 단어 단위 토큰화 : 단어(어절) 단위로 토큰화
  - 문자 단위 토큰화 : 문자 단위로 토큰화
  - 서브 워드 단위 토큰화 : 서브 워드 단위로 토큰화

토큰화(Tokenizing)의 방식

- 단어 단위 토큰화
  - 가장 쉬운 방법은 공백으로 분리(별도의 토크나이저가 없어도 무방)
    - 단점: 어휘 집합의 크기가 매우 커질 수 있음
      - “갔었어”, “갔었는데요”는 서로 다른 토큰이 됨
      - 표현이 살짝만 바뀌어도 관련된 모든 경우의 수가 어휘 집합에 포함되어야 함

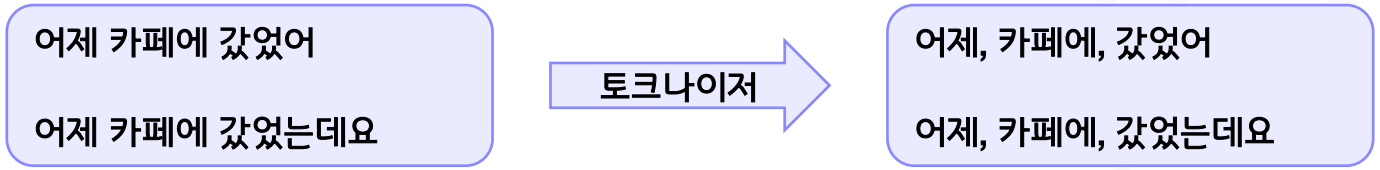

토큰화(Tokenizing)의 방식

- 사전 학습된 토크나이저를 사용한다면
  - 어휘 집합의 비대화를 다소 완화 가능 (완전히 해결하기는 어려움)

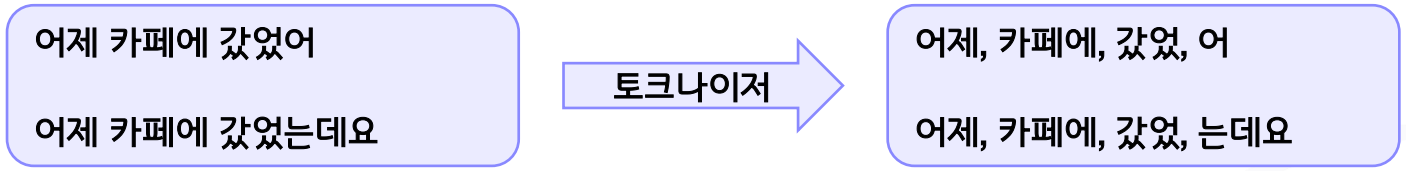

  - 하나의 언어로 모델을 구축할 때, 어휘 집합의 크기는 10만개를 가뿐히 넘어감
  - 어휘 집합의 크기가 커질 수록 모델의 학습은 어려워짐

토큰화(Tokenizing)의 방식

- 문자 단위 토큰화
  - 한글의 경우 표현 가능한 글자는 11,172개
    - 알파벳, 숫자, 기호를 모두 고려해도 어휘 집합의 크기는 15,000개 정도
  - 해당 언어의 모든 문자를 어휘 집합에 포함 → 미등록 토큰 문제 없음
  - 단점
    - 각 토큰은 의미 있는 단위가 될 수 없음

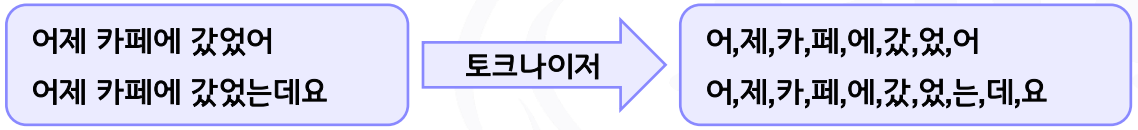

    - 어미에 따른 변화, 조사의 사용 등 한글의 특징이 모두 사라짐
    - 분석 결과인 토큰 시퀀스의 길이가 단어 단위 토큰화의 결과보다 상대적으로 길어짐
    - 언어 모델에 입력할 토큰 시퀀스가 길면 모델의 학습이 어려워지고 결과적으로 성능하락

토큰화(Tokenizing)의 방식

- 서브 워드 단위 토큰화
  - 단어 단위 토큰화와 문자 단위 토큰화의 중간 형태
  - 두 토큰화 방식의 장점만 적용
    - 어휘 집합의 크기가 지나치게 커지지 않음
    - 미등록 토큰 문제 회피 가능
    - 분석 결과의 토큰 시퀀스가 너무 길어지지 않음
  - 대표적인 서브워드 단위 토큰화 기법: 바이트 페어 인코딩(BPE)

BPE (Byte Pair Encoding)

- **BPE (Byte Pair Encoding)**
  - **1994년 제안된 정보 압축 알고리즘**
  - **데이터에서 가장 많이 등장한 문자열을 병합하여 데이터를 압축하는 기법**
  - **데이터에 등장한 글자를 초기 사전으로 구성하여 연속된 두 글자를 한 글자로 병합하는 방식 적용**
  - **최근에는 자연어 처리 모델에 널리 쓰이는 토큰화 기법**
    - 대표적인 활용 모델: GPT 모델

BPE (Byte Pair Encoding)

- **BPE 알고리즘의 적용 예**
  - **초기 사전: (a, b, c, d) → 4개, 문자열: aaabdaaabac → 11자**
    - aaabdaaabac → aa를 Z로 병합 → ZabdZabac
    - ZabdZabac → ab를 Y로 병합 → ZYdZYac
    - ZYdZYac → ZY를 X로 병합 → XdXac
  - **BPE 수행 이후**
    - 사전: (a, b, c, d, Z, Y, X) → 7개
    - 결과 문자열: XdXac → 5자

BPE기반 토큰화 기법
- 사전 크기의 증가를 억제하면서도 정보를 효율적으로 압축할 수 있는 알고리즘
- BPE 어휘 집합은 고빈도 바이그램 쌍을 병합하는 방식으로 구축함

BPE (Byte Pair Encoding)

- **BPE 알고리즘의 특징**
  - 분석 대상 언어에 대한 지식이 필요하지 않음
  - 말뭉치(코퍼스)에서 자주 나타나는 문자열(서브 워드)을 토큰으로 분석
  - 자연어 처리에서 BPE가 처음 적용된 분야는 기계번역 분야

- **BPE 활용 토큰화 절차**
  1. 어휘 집합 구축: 자주 등장하는 문자열 병합 후 어휘집합 추가 반복
  2. 토큰화: 문장의 각 어절에서 어휘 집합에 있는 서브 워드를 어절에서 분리

BPE (Byte Pair Encoding)

- **BPE 어휘 집합 구축하기**

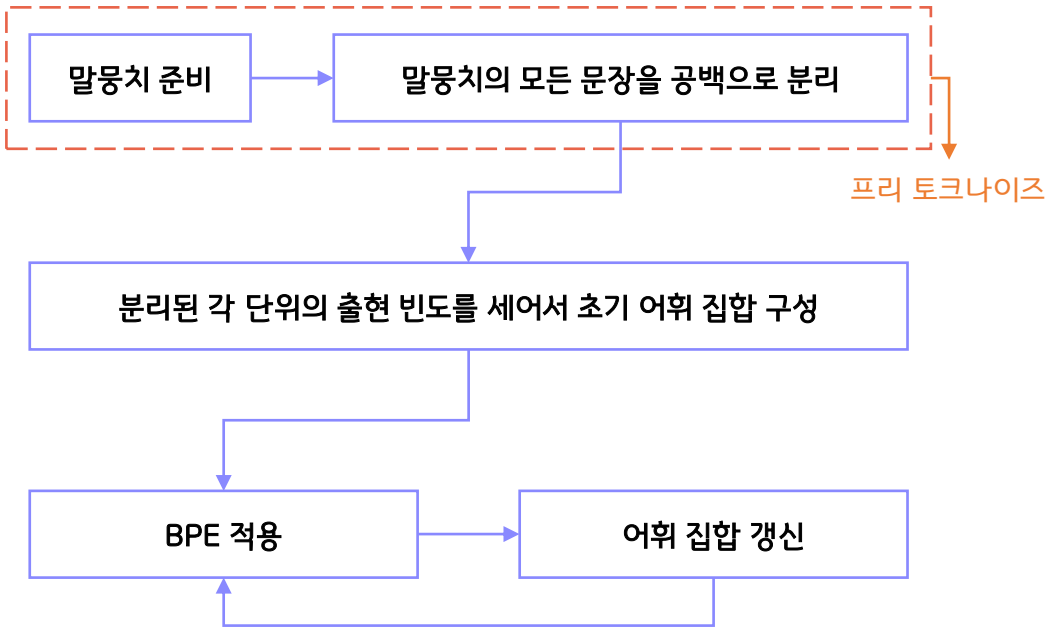

어휘 집합이 사용자가 정한 크기가 될 때까지 반복

초기 어휘 집합

b, g, h, n, p, s, u

프리 토크나이즈 결과

토큰	빈도
hug	10
pug	5
pun	12
bun	4
hugs	5

초기 어휘 집합으로 다시 작성한 빈도표

토큰	빈도
h, u, g	10
p, u, g	5
p, u, n	12
b, u, n	4
h, u, g, s	5

바이그램 쌍으로 나열

토큰	빈도
h, u	10
u, g	10
p, u	5
u, g	5
p, u	12
u, n	12
b, u	4
u, n	4
h, u	5
u, g	5
g, s	5

같은 바이그램 쌍 합치기

토큰	빈도
b, u	4
g, s	5
h, u	15
p, u	17
u, g	20
u, n	16

u, g 병합

토큰	빈도
h, ug	10
p, ug	5
p, u, n	12
b, u, n	4
h, ug, s	5

바이그램 쌍 빈도로 나열

토큰	빈도
b, u	4
h, ug	15
p, u	12
p, ug	5
u, n	16
ug, s	5

u, n 병합

토큰	빈도
h, ug	10
p, ug	5
p, un	12
b, un	4
h, ug, s	5

바이그램 쌍 빈도로 나열

토큰	빈도
b, un	4
h, ug	15
p, ug	5
p, un	12
ug, s	5

BPE 어휘 집합 구축 결과

b, g, h, n, p, s, u, ug, un, hug

BPE (Byte Pair Encoding)

- **BPE 토큰화**
  - **어휘 집합과 병합 우선순위를 기준으로 토큰화 수행**
    - **병합 우선순위**

토큰	빈도
b, u	4
g, s	5
h, u	15
p, u	17
u, g	20
u, n	16

토큰	빈도
b, u	4
h, ug	15
p, u	12
p, ug	5
u, n	16
ug, s	5

토큰	빈도
b, un	4
h, ug	15
p, ug	5
p, un	12
ug, s	5

병합 우선순위

u, g	1순위
u, n	2순위
h, ug	3순위

BPE (Byte Pair Encoding)

- **BPE 토큰화 예시**
  - 토큰화 대상
  - 프리 토크나이즈
  - BPE 토큰화 시작

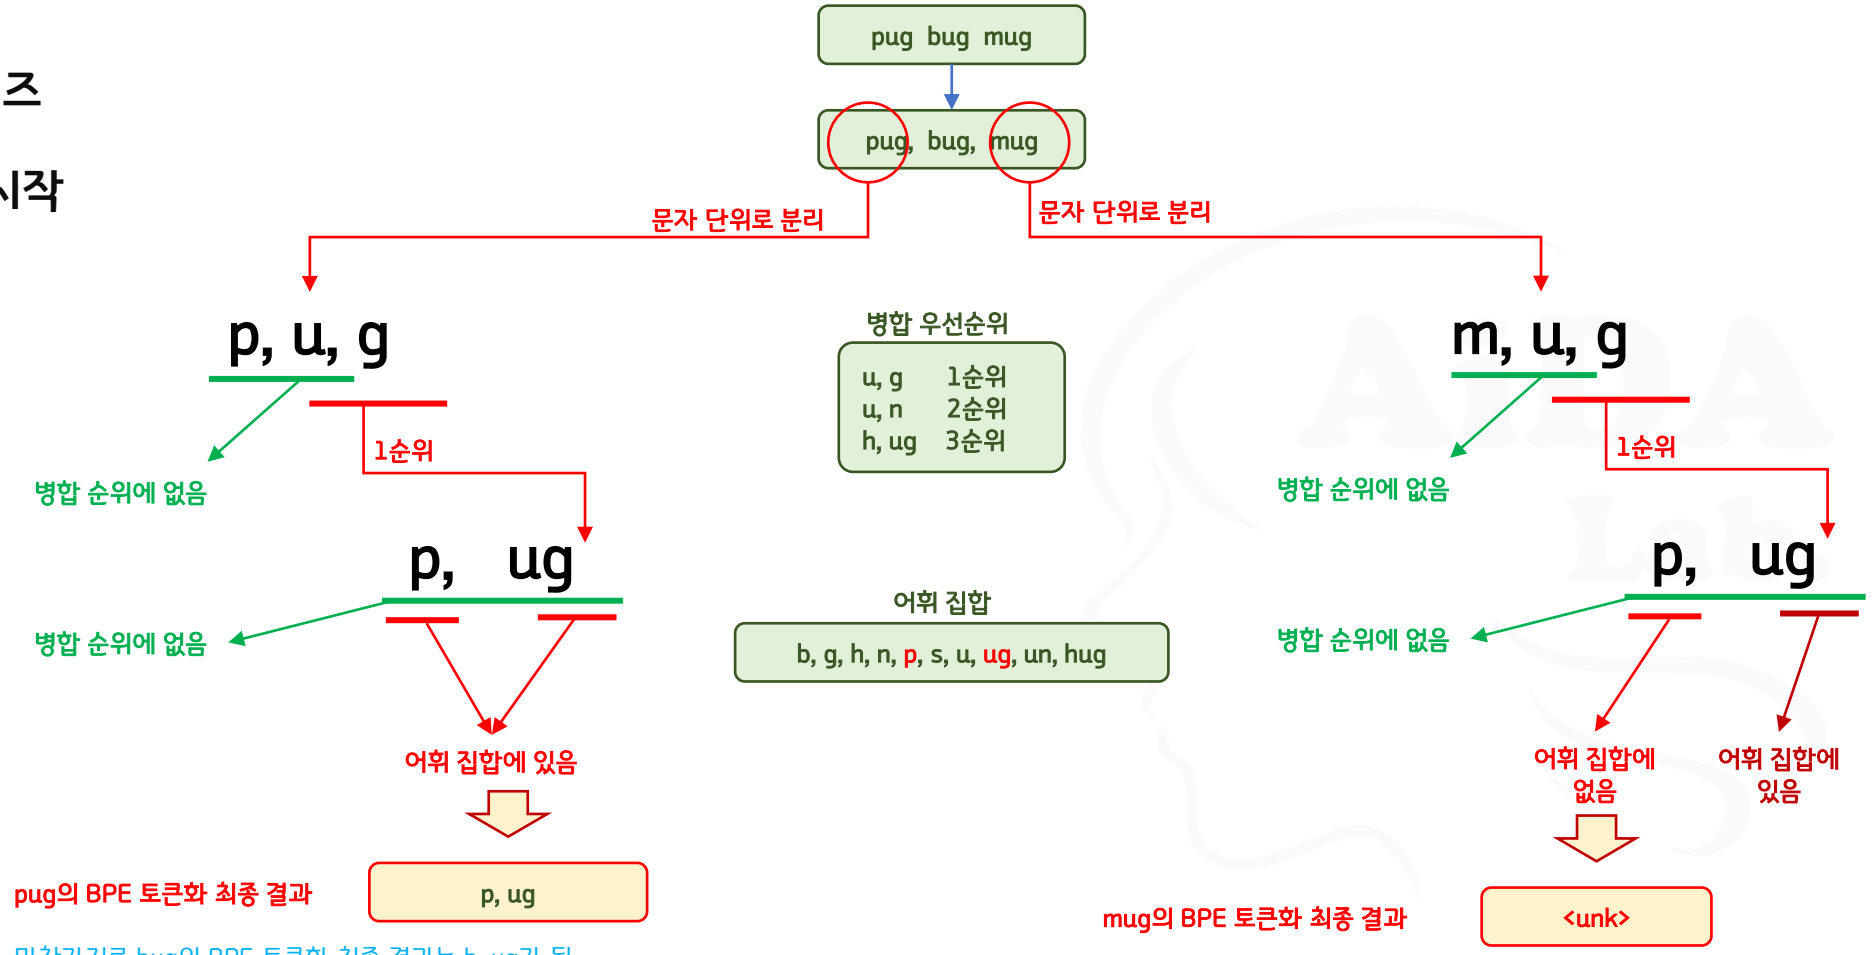

마찬가지로 bug의 BPE 토큰화 최종 결과는 b, ug가 됨

<unk> : Unknown Token

한국어 토크나이징(형태소 분석)

- 한국어 Tokenizing을 구현하려면?
  - 한국어 문법에 대한 깊은 이해가 필수!!!
  - 비전공자는 어떻게 해야 하나?
    - 한국어 Tokenizing을 지원하는 파이썬 라이브러리를 사용한다.
    - 대표적인 한국어 자연어 처리 지원 라이브러리: KoNLPy (코엔엘파이)

한국어 토크나이징(형태소 분석)

- “토큰 단위를 어떻게 정의하느냐”가 자연어 처리 성능에 큰 영향
- 한국어 분석에서 사용하는 토큰의 단위는 “형태소”
  - 형태소란?
    - 언어학에서 사용되는 용어
    - 일정한 의미가 있는 가장 작은 말의 단위 (의미상 더 이상 쪼개지지 않는 단어)
  - 형태소를 토큰 단위로 사용한다면?
    - 단어와 품사 정보를 같이 활용할 수 있다 → 효과적 처리가 가능함

한국어 토크나이징(형태소 분석)

- 문장을 어떻게 형태소 단위로 분리(Tokenizing)할 수 있는가?
  - 영어의 경우는 Tokenizing이 쉽다
    - 단어의 변화가 크지 않다
    - 띄어쓰기로 단어를 구분한다
    - 따라서, 공백을 기준으로 토크나이징을 수행해도 문제가 없다
  - 한글의 경우는 Tokenizing이 어렵다
    - 한국어는 명사와 조사를 띄어 쓰지 않는다 → 공백을 기준으로 토크나이징 수행 불가능
    - 용언에 따라 여러 가지 어미가 붙는다 → 일정한 기준을 찾기 어렵다
    - 따라서 복잡한 특성을 고려하여 문장에서 형태소를 분석할 수 있는 “형태소 분석기“ 가 필수
    - 다양한 문법적 특징을 반영하고 언어적 속성의 구조를 파악할 수 있어야 함

한국어 토크나이징(형태소 분석)

- **한국어 Tokenizing의 어려움의 예**
  - **아버지가 방에 들어가신다**
  - **아버지 가방에 들어가신다**

  } 컴퓨터는 이런 것을 구분하지 못함

- **형태소 분석기를 사용해서 분석한 결과**
  - **아버지가 방에 들어가신다.**

  → [(‘아버지’, ‘명사‘), (‘가’, ‘조사‘), (‘방’, ‘명사‘), (‘에’, ‘조사‘), (‘들어가신다’, ‘동사(서술어)’), (‘.’, ‘마침표(기능적인 기호)’)]

한국어 토크나이징(형태소 분석)

- **한국어의 9품사**

품사	설명
명사	주로 물건이나 사람, 동식물을 가리킬 때 쓰는 품사 [강아지, 철수, 챗봇, ...]
대명사	사람이나 사물의 이름을 대신해서 쓰는 품사 [너, 우리, 무엇, 그것, ...]
수사	숫자나 순서를 나타내는 품사 [하나, 둘, 1, 2, 첫째, 둘째, ...]
동사	동작이나 작용을 나타내는 품사 [먹었다, 보았다, 간다, ...]
형용사	사물의 성질이나 상태를 나타내는 품사 [아름답다, 맵다, 희다, ...]
관형사	체언(명사, 대명사, 수사) 앞에서 체언을 수식하는 품사 [이, 그, 저, 새, 헌, 옛, ...]
부사	동사, 형용사, 동사구, 문장 전체를 수식하는 역할을 맡은 품사 [정말, 벌써, 매우, ...]
조사	명사, 부사 따위에 붙어 문법 관계를 맺어주는 품사 [~이, ~가, ~에서, ...]
감탄사	감탄이나 놀람, 느낌, 응답 등을 나타내는 품사 [꺄, 와, 아하, 헉, ...]

한국어 토크나이징(형태소 분석)

- 형태소 분석기
  - 복잡한 한국어 문법때문에 형태소 분석기의 개발은 매우 어렵다
  - KoNLPy 등의 라이브러리 사용은 필수
    - KoNLPy 내부에서 다양한 형태소 분석기를 통합하여 라이브러리 형태로 제공
    - 다소 튜닝이 필요하지만 기본적인 성능이 뛰어난 편 → 실무에서도 많이 사용 중
  - KoNLPy가 제공하는 대표적인 형태소 분석기
    - Kkma (꼬꼬마, 서울대에서 개발, GPL2 라이센스), Komoran (코모란, Shineware에서 자바로 개발, Apache 2.0 라이센스), Okt (트위터에서 개발, Apache 2.0 라이센스)
    - 통합제공하기 때문에 세 종류 모두 사용법이 거의 동일함

한국어 토크나이징(형태소 분석)

- **KoNLPy의 형태소 분석기 비교**

형태소 분석기	장점	단점
Kkma	• 분석 품질이 좋음 • 지원하는 품사 태그가 가장 많음	• 분석 속도가 느림 • 사용자 사전으로 추가한 복합 명사에 대하여 불완전하게 동작함
Komoran	• 자소가 분리된 문장이나 오탈자에 강함 • 사용자 사전 관리 용이	• 적당한 분석 품질과 분석 속도
Okt	• 매우 빠른 분석 속도 • 정규화 기능 지원	• 사용자 사전 관리가 어려움 • 용언 분석에 일관성이 부족함

한국어 토크나이징(형태소 분석)

- 사용자 사전 구축
  - 챗봇의 데이터 입력단은 인터넷 구어체와 관련이 많음

    → 일반적으로 딱딱한 구어체, 문어체 등을 사용하지 않음
  - 새롭게 생겨나는 단어나 문장은 형태소 분석기가 인식하지 못하는 경우 많음
    - 기존의 많은 문장을 이용하여 형태소 분석기 모델이 개발되었으므로 새로운 형태의 단어, 문장은 학습 데이터에 포함되어 있지 않음 → 인식률 저하의 원인
  - 문제의 해결을 위해 대부분의 형태소 분석기는 사용자 사전을 추가할 수 있도록 구성됨