

# 텍스트 마이닝을 이용한 KEI 연구동향 분석

6th Bigdata Research Team Seminar : Progress Report

2017. 05. 24

빅데이터연구팀 김도연

# 목차

- I. 연구 개요
- II. 선행연구
- III. 연구 내용
- IV. 연구 추진방법
- V. 기대효과

## 연구 개요

## 선행 연구

## 연구 내용

## 연구 추진방법

## 기대효과

## 연구 개요

- **과제명** : 텍스트 마이닝을 이용한 KEI 연구동향 분석

- **참여 연구진** :

성명	소속	주요업무	참여율(%)
강성원	빅데이터연구팀	텍스트 마이닝 분석 플랫폼 개발 및 분석	60
김도연	빅데이터연구팀	문헌 분석, 데이터 수집 및 분석	40

- **연구 기간** : 2017.1.1 ~ 2017.12.31

## 자문의견 반영 내용

연구 개요

선행 연구

연구 내용

연구 추진방법

기대효과

위원	제안내용	반영내용
이명진 (KEI 부연구위원)	한글 전처리 문제 (조사 등)	<ul style="list-style-type: none"> <li>• 한글 전처리 R package를 활용해서 해결 가능함.</li> <li>- 형태소분석기 실행(KoNLP 등)</li> <li>- Low TF-IDF 값 제거</li> <li>- 불용어 처리 (특정 단어 삭제, 특수문자 제거, 소문자로 변경 등)</li> <li>- Word Lengths는 2글자 이상</li> <li>- 동의어 처리</li> </ul>
	한글 라이브러리 문제	<ul style="list-style-type: none"> <li>• 토픽클러스터링(LDA)기법을 활용한 토픽별 사전을 구축할 예정임.</li> <li>- 토픽별 전문가 의견을 반영하여 사전 구축</li> </ul>
우석진 (명지대학교 교수)	환경정책 수혜자 DB 분석을 통해 정책적 시사점 도출 필요	<ul style="list-style-type: none"> <li>• 온라인 뉴스기사와 뉴스댓글 데이터를 통해 환경정책 수혜자 오피니언 마이닝 분석 실시할 예정임.</li> <li>- 향후, 환경부에서 제공하는 페이스북, 트위터, 블로그, 유튜브 등을 통해 정책수혜자 오피니언 마이닝 분석 실시할 계획임.</li> </ul>

## 연구 개요

## 선행 연구

## 연구 내용

## 연구 추진방법

## 기대효과

## 연구 배경 및 목적

- KEI 연구동향이 국민적 관심에 반응하고 있는 지 여부에 대한 회의 존재
    - 개별 연구자의 시간적 제약 및 개인적 연구 성향에 의해서 연구수요 정보 파악 범위가 제한
    - 파악된 정보에 부여되는 우선순위가 개별 연구자의 선호에 영향을 받으므로 최신 정보 및 시의성 있는 연구수요 반영에 제약이 존재
  - 최근 트렌드 분석에 활발하게 사용되는 텍스트 마이닝을 통해 KEI 연구동향과 민간의 환경연구 수요 간의 관계 파악 가능
    - 텍스트 마이닝은 실시간으로 생산되는 다량의 비정형데이터 속에서 의미 있는 패턴을 발견하여 트렌드를 파악하는데 주로 활용
    - 대용량 텍스트 자료 분석이 가능하므로 KEI 연구동향과 민간의 연구수요 동향을 시기별로 트렌드를 각각 추출하여 비교 분석 가능
- ▼
- ▶ 본 연구는 텍스트 마이닝을 이용한 24년(1993~2016) KEI 연구동향 분석을 시도하여 시간적 추이 및 민간 연구수요와의 조응여부를 탐구
    - KEI 연구문헌 및 온라인 뉴스기사와 뉴스댓글 분석을 병행하여 환경관련 연구공급 동향 및 연구수요 동향을 파악
    - 텍스트 마이닝 기법을 이용하여 연구수요를 파악하는 방법의 예를 제공하여 기존의 개별 연구자의 직관에 의존하는 방식을 보완하는 방법을 제공

## 선행 연구

구분	연구목적	연구방법	주요 연구내용	
<b>주요 선행 연구</b>	<b>1</b>	- 과제명: 텍스트 마이닝 기법을 활용한 한국의 경제연구 동향 분석 - 연구자(년도): 송민 외(2013) - 연구목적: 텍스트 마이닝 기법 활용 외국 학술지 한국 경제분야 트렌드 분석	- 키워드 분석 - 네트워크 분석 - 토픽모델링 분석	- 외국 학술지의 한국경제 연구에 대한 연구 동향 및 지적 구조 파악
	<b>2</b>	- 과제명: 소셜 빅데이터를 활용한 국민 통일인식 동향 분석 - 연구자(년도): 송태민 (2015) - 연구목적: 2014년 '통일대박론' 대두 이후 통일인식 변화를 소셜빅데이터 이용 분석	- 키워드 분석 - 연관성 분석	- 소셜 미디어 통일관련 연관어 분석 - 통일관련 연관어와 통일인식간의 관계 분석
	<b>3</b>	- 과제명: 항공산업 미래유망분야 선정을 위한 텍스트 마이닝 기반의 트렌드 분석 - 연구자(년도): 신경식 외(2015) - 연구목적: 텍스트마이닝 트렌드 분석 활용 항공산업 미래유망분야 발굴	- 토픽 모델링 분석	- 텍스트 마이닝 기법을 적용한 항공산업 관련 논문 트렌드 분석 - 토픽 모델링 분석 활용 항공산업 미래유망부분 추출
	<b>4</b>	- 과제명: 빅데이터를 활용한 환경분야 정책수요 분석 - 연구자(년도): 이미숙 외(2014) - 연구목적: 매체별(뉴스, 블로그, 트위터) 환경정책수요 분석	- 감성 분석 - 연관성 분석 - 네트워크 분석	- 세부 환경분야별 소셜빅데이터 분석 - 전체문서 및 환경문서의 행복도 비교 분석
<b>본 연구</b>	- 기존의 연구는 단일 매체의 추세 파악에 집중하여 분석결과 활용이 미진 - 환경분야 문헌 텍스트 마이닝 연구는 초기 단계	- 분석 대상이 단일 매체에 국한되어 전체적인 동향 파악에 한계가 있음	- 환경분야 연구 문헌 텍스트 마이닝 기법을 적용하는 선도적 연구가 필요 - 다양한 매체의 동향을 비교 분석하여 연구 동향의 시사점을 파악하는 연구가 필요	

연구 개요

선행 연구

연구 내용

연구 추진방법

기대효과

연구 개요

선행 연구

연구 내용

연구 추진방법

기대효과

## 주요 연구 내용

### ■ KEI 연구동향 파악

- 텍스트 마이닝 기법을 활용한 연구동향 분석
  - KEI가 설립된 1993년부터 2016년까지의 KEI DB에서 제공하는 연구보고서(제목, 목차, 요약, 날짜, 연구자명) 데이터를 분석에 활용
  - 24년 간(1993-2016) 연구보고서 1,697건

### ■ 매체별 환경분야 이슈 비교 분석

- 연구공급 동향과 연구수요 동향 비교 분석
  - 연구공급 동향 파악: 2007년부터 2016년까지의 KEI DB에서 제공하는 연구보고서 데이터 분석
  - 연구수요 동향 파악: 2012년부터 2016년까지의 언론매체에서 제공하는 뉴스 기사 및 댓글 데이터 분석
- 매체별 추출한 키워드를 시계열로 파악하고 두 시계열을 비교 분석


연구 개요

선행 연구

연구 내용

연구 추진방법

기대효과



# Text Mining Process List

연구 개요

선행 연구


연구 내용

연구 추진방법

기대효과

Plan 2017	Process	File Name	Description	Input	Output	Note	
상반기	3월 상순	Pre-processing(1)	topic_clustering.R	<ul style="list-style-type: none"> <li>- 형태소분석기 실행(KoNLP 등)</li> <li>- Low TF-IDF 값 제거</li> <li>- 불용어처리 등 전처리 과정 (특정 단어 삭제, 특수문자 제거, 소문자로 변경 등)</li> <li>- Word Lengths는 2글자 이상</li> <li>- 동의어 처리</li> </ul>	kei.csv	DocumentTermMatrix	<ul style="list-style-type: none"> <li>- 자문익전(이명진 박사님) : 한글 처리 문제(조사 등) → 다양한 한글 전처리 방법을 통해 해결 가능함.</li> </ul>
	3월 하순	LDA Modeling	topic_clustering.R	<ul style="list-style-type: none"> <li>- LDA기반 토픽 모델링</li> <li>- 토픽별 핵심 단어 출력</li> <li>- 문서별 토픽번호 및 확률값 출력</li> <li>- 단어별 토픽번호 및 확률값 출력</li> </ul>	Document TermMatrix	term_topic.csv doc_Prob_df.csv doc_prob_df_max.csv id_topic.csv lda_tm.csv	<ul style="list-style-type: none"> <li>- 입력값 : SEED = 2017, K = 5</li> </ul>
	4월	LDavis	topic_clustering.R	<ul style="list-style-type: none"> <li>- 토픽모델링</li> <li>- 2차원 시각화 및 주요 키워드 확률분포 목록 시각화</li> </ul>	lda_tm.csv	HTML 등 웹파일	<ul style="list-style-type: none"> <li>- apache-tomcat-8.5.12 사용</li> <li>- 산출물 서버업로드 필요</li> </ul>
	5월 상순	LDA Result Analysis		<ul style="list-style-type: none"> <li>- 토픽별 키워드 분석</li> <li>- 토픽별 연구보고서 동향 분석</li> </ul>	id_topic.csv	id_topic_Analysis.xlsx	-1993-2016년 연구보고서 동향 분석
	5월 하순	Association Analysis(1)	Association_Analysis.R	<ul style="list-style-type: none"> <li>- 지지도, 신뢰도가 0.01 이상 출력</li> <li>- 3가지측도(지지도, 신뢰도, 항상도) 분석</li> </ul>	1993_2002.txt 2003_2007.txt 2008_1012.txt 2013_2016.txt	Association.xlsx	<ul style="list-style-type: none"> <li>- 연구보고서 제목 데이터 활용</li> <li>- 초록으로 분석시 메트릭스가 너무 커짐</li> <li>- 4개 시기별 동향 분석</li> </ul>
		Network Analysis(1)	Association_Analysis.R	<ul style="list-style-type: none"> <li>- 원의 크기 : 언급량이 많을수록 크기가 큼</li> <li>- 원의 색깔 : 매개중심성이 높을수록 색깔이 진함</li> </ul>		93-02.png 03-07.png 08-12.png 13-16.png	
6월 상순	Data Collection	Naver_news.java	- Web crawling		Naver_news.csv	<ul style="list-style-type: none"> <li>- 2012~2016년 네이버에서 제공하는 환경뉴스 데이터 수집</li> <li>- Java-Joup 사용</li> </ul>	
하반기	6월 하순	Pre-processing(2)		상동			
	7월 상순	LDA Modeling(2)					
	7월 상순	LDavis(2)					
	7월 하순	Keyword Analysis(2)					
	8월	Trend Comparative Analysis					
	9월	시사점 도출 및 정책제언					
	10월	향후 계획 수립					

# Text Mining Process List



Plan 2017	Process	File Name	Description	Input	Output	Note
3월 상순	Pre-processing(1)	topic_clustering.R	<ul style="list-style-type: none"> <li>- 형태소분석기 실행(KoNLP 등)</li> <li>- Low TF-IDF 값 제거</li> <li>- 불용어처리 등 전처리 과정 (특정 단어 삭제, 특수문자 제거, 소문자로 변경 등)</li> <li>- Word Lengths는 2글자 이상</li> <li>- 동의어 처리</li> </ul>	kei.csv	DocumentTermMatrix	<ul style="list-style-type: none"> <li>- 자문의견(이명진 박사님) : 한글 처리 문제(조사 등) → 다양한 한글 전처리 방법을 통해 해결 가능함.</li> </ul>
3월 하순	LDA Modeling	topic_clustering.R	<ul style="list-style-type: none"> <li>- LDA기반 토픽 모델링</li> <li>- 토픽별 핵심 단어 출력</li> <li>- 문서별 토픽번호 및 확률값 출력</li> <li>- 단어별 토픽번호 및 확률값 출력</li> </ul>	Document TermMatrix	term_topic.csv doc_Prob_df.csv doc_prob_df_max.csv id_topic.csv lda_tm.csv	<ul style="list-style-type: none"> <li>- 입력값 : SEED = 2017, K = 5</li> </ul>
4월	LDAvis	topic_clustering.R	<ul style="list-style-type: none"> <li>- 토픽모델링</li> <li>- 2차원 시각화 및 주요 키워드 확률분포 목록 시각화</li> </ul>	lda_tm.csv	HTML 등 웹파일	<ul style="list-style-type: none"> <li>- apache-tomcat-8.5.12 사용</li> <li>- 산출물 서버업로드 필요</li> </ul>

연구 개요

선행 연구

연구 내용

연구 추진방법

기대효과

# Pre-processing(1)

연구 개요

선행 연구

연구 내용

연구 추진방법

기대효과

## 1. Pre-processing with R

```
#형태소 분석기 실행
system("tctstart")

#Corpus 생성
corp<-VCorpus(VectorSource(parsedData$res$content))
#특수문자 제거
corp <- tm_map(corp, removePunctuation)
#소문자로 변경
corp <- tm_map(corp, tolower)
#특정 단어 삭제
corp <- tm_map(corp, removewords,
               c("전략", "연구", "평가", "마련", "조사", "관리", "보다", "분석", "구축"))
#TXT 문서 형식으로 변환
corp <- tm_map(corp, PlainTextDocument)
#Document Term Matrix 생성 (단어 Length는 2로 세팅)
dtm<-DocumentTermMatrix(corp, control=list(removeNumbers=FALSE, wordLengths=c(2,Inf)))
#한글자 단어 제외하기
#colnames(dtm) = trimws(colnames(dtm))
#dtm = dtm[,nchar(colnames(dtm)) > 1]

#sparse Terms 삭제
dtm <- removeSparseTerms(dtm, as.numeric(0.997))
#Remove low tf-idf col and row
term_tfidf <- apply(dtm$V$row_sums(dtm)[dtm$J, dtm$J, mean]) * log2(noccs(dtm)/col_sums(dtm > 0))
new_dtm <- dtm[,term_tfidf >= 0]
new_dtm <- new_dtm[row_sums(new_dtm)>0,]
```

+

연구자의 판단 -> 불용어 처리!

## 2. Pre-processing data: id\_topic.csv 생성

A	B	C	D	E	F	G	H	I	J	K
row	id	doc_topic	pContent	maxProb	Title	author	class	year	month	day
1	a1		5 환경 개선 마스터플랜 수립 지원 국내 사후 설	0.840	환경분야 공적개발원조(O조공장	수시연구2016	06		30	
2	a2		4 추진 국내 탄소 감축 정책 해외 탄소 감축 정책	0.450	제주 탄소제로실 추진전략이영국	수시연구2016	06		24	
3	a3		4 국내외 기술 사회 경제 시나리오 사회 경제 시	0.340	지탄소 기후변화 적응 사후제여라	수시연구2016	05		31	
4	a4		3 화학 사고 피해액 추정 제안 화학 사고 인적 상	0.805	화학사고의 경제적 손실 최소화책	수시연구2016	04		30	
5	a5		3 나노 폐기물 나노 물질 나노 폐기물 세계 나노	0.586	나노폐기물의 안전처리를 조지혜	수시연구2016	04		30	
6	a6		2 2015년 충남 서북 부 지역 가을 대응 2015년	0.760	가을 단계에 따른 적용형 김호정	수시연구2016	03		31	
7	a7		2 국내외 기술 국내 기술 국내 산지 정책 동향	0.352	국내 농산업 GIS기반 통합 이주재	수시연구2016	03		31	
8	a8		3 국내외 기술 최종 최종 단계 추진 토의 건강	0.542	기후변화에 따른 건강영향신용승	수시연구2016	02		28	
9	a9		2 제네바 텍스트 중재 제네바 텍스트 제네바 텍	0.502	Post-2020 신기후체제 협상이승준	수시연구2015	12		31	
10	a10		4 서울 인터넷 혁명 핵심 기술 부상 올 환경 사	0.404	서울인터넷(IoT)를 활용한 한혜진	연구	2016	10	31	
11	a11		4 나다 차별 중국 전략 아시아 인프라 투자 온	0.998	중국의 일대일로(一帶一路)추진방	연구	2016	10	31	
12	a12		2 도시 기후 회복력 도시 기후 회복력 도시 기후	0.810	도시의 기후 회복력 확보를김동현	연구	2016	10	31	
13	a13		2 국내 지역 사회 환경 보건 문제 진단 국내 지	0.458	지역기반 환경보건정책 지신용승,배	연구	2016	10	31	
14	a14		2 파리 협정 핵심 파리 협정 파리 협정 적응 손	0.910	신기후체제의 기후변화 적이승준	수시연구2016	09		30	
15	a15		4 차별친환경 차 보급 정책 동향 국내 정책 동	0.898	대기환경비용을 고려한 친환경적	수시연구2016	09		30	
16	a16		1 경우 차 실 도로 대기 오염 물질 초과 배출 원	0.821	실제로에서 경우차의 대기감량	수시연구2016	09		22	
17	a17		5 접근 국내 정보 관련 부지 시사점 건설 기	0.703	토양정보 관련 부지의 최적비용하	수시연구2016	08		31	
18	a18		2 과업 과업 실행 생물 다양 정책 여건 중간 점	0.896	제3차 국가생물다양성전략이현우	수시연구2016	08		30	
19	a19		4 지속 가능 발전 87년 환경 관 세계 위원회 발	0.733	국가 지속가능성 평가 등김종호	수시연구2016	07		30	
20	a20		2 국의 지지도 공인 동향 유네스코 아시아 태	0.772	유네스코 세계지질공원 이주재	수시연구2016	11		22	
21	a21		2 시스템 네트워크 언어미래 환경 정책 아	0.526	시스템과 네트워크 이론을이승준	기초연구2016	11		06	
22	a22		5 국가 지역 미래 성장 동력 미래 성장 동력 미	0.479	국가 및 지역 미래성장동력방성일	연구	2016	10	31	
23	a23		5 국가 지역 미래 성장 동력 미래 성장 동력 미	0.479	지중환경을 위한 제도 개 황상일	연구	2016	10	31	
24	a24		3 정책 정부 패러다임 주민수 응성 정책 주민수	0.699	정부3.0 기반 지시기피시김태현	연구	2016	10	31	
25	a25		3 차별국내외의 재해 폐기물 제도 비교 국내 수	0.596	공감정보를 활용한 재해폐조지혜,김	연구	2016	10	31	
26	a26		3 국내 폐기를 활용 활용 산업 국내 폐기를 발생	0.540	자원순환사회 전환 추진을이소라,신	연구	2016	10	31	
27	a27		3 전기 전자 제품 활용 정책 활용 국내 일본 국	0.844	폐자원유용분류를 통한 전 이희선	연구	2016	10	31	
28	a28		4 물 환경 인프라 사회 투자 수익 물 환경 인	0.605	사회적 투자수익률(SROI)이유재,강	연구	2016	10	31	
29	a29		2 자연 자본 여건 전망 자연 자본 특성 국내 자	0.393	생태계서비스 기반의 지역이현우	연구	2016	10	31	
30	a30		2 크리티컬 존 국내외 정책 동향 국외 크리티	0.527	근지표환경 일계영역(Critical)현용정	기초연구2016	12		06	
31	a31		5 국내 외 환경 재난 사후 대응 정책 국내 환경	0.359	드론을 이용한 환경재난 시승용우	기초연구2016	12		06	
32	a32		4 건물 지속 가능 고밀 건물 환경 주다 영향 측정	0.648	건물부문의 환경부하 평가승지윤	기초연구2016	12		06	
33	a33		3 고밀 기후 변화 노동자 대 영향 노동자 위험	0.712	미래 고온환경 변화와 직결김동현	기초연구2016	12		06	

# LDavis (Topic 1)

연구 개요

선행 연구



연구 내용

연구 추진방법

기대효과

Selected Topic: 1 Previous Topic Next Topic Clear Topic

Slide to adjust relevance metric:<sup>(2)</sup>  
λ = 0.05 0.0 0.2 0.4 0.6 0.8 1.0



1. saliency(term w) = frequency(w) \* [sum\_i p(t | w) \* log(p(t | w)/p(t))] for topics t; see Chuang et. al (2012)  
2. relevance(term w | topic t) = λ \* p(w | t) + (1 - λ) \* p(w | t)p(w); see Sievert & Shirley (2014)



# LDAvis (Topic 2)

연구 개요

선행 연구



연구 내용

연구 추진방법

기대효과

Selected Topic: 2    Previous Topic    Next Topic    Clear Topic

Slide to adjust relevance metric:<sup>(2)</sup>   $\lambda = 0.05$



1. saliency(term w) = frequency(w) \* [sum\_t p(t | w) \* log(p(t | w)/p(t)) for topics t; see Chuang et. al (2012)  
 2. relevance(term w | topic t) =  $\lambda * p(w | t) + (1 - \lambda) * p(w | t)/p(w)$ ; see Sievert & Shirley (2014)

- Term
- 폐기물
- 소음
- 화학
- 처리
- 폐수
- 하수
- 수거
- 유해
- 막다
- 소각
- 쓰레기
- 악취
- 부담금
- 처리장
- 유해성

“폐기물”

# LDAvis (Topic 3)

연구 개요

선행 연구



연구 내용

연구 추진방법

기대효과

Selected Topic: 3 Previous Topic Next Topic Clear Topic

Slide to adjust relevance metric:<sup>(2)</sup>  
λ = 0.04 0.0 0.2 0.4 0.6 0.8 1.0



1. saliency(term w) = frequency(w) \* [sum\_i p(t | w) \* log(p(t | w)/p(t))] for topics t; see Chuang et. al (2012)  
2. relevance(term w | topic t) = λ \* p(w | t) + (1 - λ) \* p(w | t)p(w); see Sievert & Shirley (2014)

- Term
- 협력
- 포럼
- 북한
- 상하수도
- 남북
- 동북아
- 교류
- 지속
- 베트남
- 시민
- 남북한
- 이니셔티브
- 거버넌스
- 필리핀
- 아시아

“대의 협력”

# LDAvis (Topic 4)

연구 개요


선행 연구

연구 내용


연구 추진방법

기대효과

Selected Topic: 4 Previous Topic Next Topic Clear Topic



Slide to adjust relevance metric:<sup>(2)</sup>  
λ = 0.05 0.0 0.2 0.4 0.6 0.8 1.0



1. saliency(term w) = frequency(w) \* [sum\_t p(t | w) \* log(p(t | w)/p(t))] for topics t; see Chuang et. al (2012)  
2. relevance(term w | topic t) = λ \* p(w | t) + (1 - λ) \* p(w | t)/p(w); see Sievert & Shirley (2014)

- Term
- 지하수
  - 환경영향평가
  - 하천
  - 습지
  - 정화
  - 지형
  - 수변
  - 상수원
  - 부지
  - 서식지
  - 한강
  - 수생
  - 도양
  - 녹지
  - 새만금

“물환경”  
+  
“환경영향평가”

# LDAvis (Topic 5)

연구 개요


선행 연구

연구 내용


연구 추진방법

기대효과

Selected Topic: 5 Previous Topic Next Topic Clear Topic



Slide to adjust relevance metric:<sup>(2)</sup>  
 $\lambda = 0.05$       0.0   0.2   0.4   0.6   0.8   1.0



1.  $sallency(term\ w) = frequency(w) * [\sum_{t=1}^T p(t|w) * \log(p(t|w)/p(t))]$  for topics  $t$ ; see Chuang et. al (2012)  
 2.  $relevance(term\ w\ l\ topic\ t) = \lambda * p(w|t) + (1 - \lambda) * p(w|l)/p(w)$ ; see Sievert & Shirley (2014)

- Term
- 기후
  - 변화
  - 가뭄
  - 재난
  - 폭염
  - 해수면
  - 기온
  - 침수
  - 사망
  - 자연재해
  - 오존
  - 홍수
  - 태풍
  - 강수량
  - 온도

“기후변화”

# LDAvis (Topic 전체)

연구 개요

선행 연구

연구 내용


연구 추진방법

기대효과



No.	Topic 1	Topic 2	Topic 3	Topic 4	Topic 5
Title	에너지 자원	폐기물	대외협력	물 환경, 환경영향평가	기후변화
1	온실가스	폐기물	협력	지하수	기후
2	에너지	소음	포럼	환경영향평가	변화
3	전력	화학	북한	하천	가뭄
4	연료	처리	상하수도	습지	재난
5	가스	폐수	남북	정화	폭염
6	청정	하수	동북아	지형	해수면
7	탄소	수거	교류	수변	기온
8	풍력	유해	지속	상수원	침수
9	세제	막다	베트남	부지	사망
10	탄소세	소각	시민	서식지	자연재해
11	이산화탄소	쓰레기	남북한	한강	오존
12	천연가스	약취	이니셔티브	수생	홍수
13	경유	부담금	거버넌스	토양	태풍
14	공기	처리장	필리핀	녹지	강수량
15	신재생에너지	유해성	아시아	새만금	온도
...					

# Text Mining Process List



Plan 2017	Process	File Name	Description	Input	Output	Note
5월 상순	LDA Result Analysis		<ul style="list-style-type: none"> <li>- 토픽별 키워드 분석</li> <li>- 토픽별 연구보고서 동향 분석</li> </ul>	id_topic.csv	id_topic_Analysis.xlsx	-1993-2016년 연구보고서 연도별 동향 분석
5월 하순	Association Analysis(1)	Association_Analysis.R	<ul style="list-style-type: none"> <li>- 지지도, 신뢰도가 0.01 이상 값 출력</li> <li>- 3가지측도(지지도, 신뢰도, 향상도) 분석</li> </ul>	1993_2002.txt 2003_2007.txt	Association.xlsx	<ul style="list-style-type: none"> <li>- 연구보고서 제목 데이터 활용</li> <li>- 초록으로 분석시 매트릭스가 너무 커짐</li> <li>- 4개 시기별 동향 분석</li> </ul>
	Network Analysis(1)	Association_Analysis.R	<ul style="list-style-type: none"> <li>- 원의 크기 : 언급량이 많을수록 크기가 큼</li> <li>- 원의 색깔 : 매개중심성이 높을수록 색깔이 진함</li> </ul>	2008_1012.txt 2013_2016.txt	93-02.png 03-07.png 08-12.png 13-16.png	

연구 개요

선행 연구

연구 내용

연구 추진방법

기대효과

## 토픽별 KEI 연구보고서 동향 분석

연구 개요


선행 연구

연구 내용

연구 추진방법

기대효과

토픽별 KEI 연구보고서 동향



- 1993~ 2002년도: 전반적으로 토픽별 연구추세가 비슷함.
- 2003~ 2007년도: 기후변화 관련 연구가 활발하게 진행  
물 환경/환경영향평가, 에너지자원 관련 연구는 감소하는 추세를 보임.
- 2008~ 2012년도: 폐기물, 물 환경/환경영향평가 연구가 급증함.
- 2013~ 2016년도: 폐기물 관련 연구가 활발하게 진행  
2015년을 기점으로 연구의 양이 적어짐.

Doc Topic	Title	1993~ 2002	2003~ 2007	2008~ 2012	2013~ 2016	총합
1	에너지자원	57	37	51	38	183
2	폐기물	13	48	109	140	310
3	대외협력	35	74	70	79	258
4	물 환경, 환경영향평가	88	72	86	88	334
5	기후변화	78	120	113	83	394
NA(영문, 한문)		5	27	11	0	43
총합		276	378	440	428	1,522









연구 개요


선행 연구

연구 내용

연구 추진방법

기대효과

## Text Mining Process List



Plan 2017	Process	File Name	Description	Input	Output	Note
6월 상순	Data Collection	Naver_news.java	- Web crawling		Naver_news.csv	<ul style="list-style-type: none"> <li>- 2012~2016년 네이버에서 제공하는 환경뉴스 데이터 수집</li> <li>- Java-joup 사용</li> </ul>

# Data Collection\_NaverNews

연구 개요

## • 데이터수집범위에 대한 고민...

1. NAVER 뉴스 > 사회 > 환경 관련 기사 전체 수집 or 환경사전 구축 > 환경 키워드 검색 > 키워드 관련 기사 수집
2. 2012년 ~ 2016년 (5개년) 데이터 수집 ?

선행 연구



연구 내용

**사회** | **환경**

사건사고 | 교육 | 노동 | 언론 | **환경** | 인권/복지 | 식품/의료 | 지역 | 인물 | 사회 일반 | 속보

명예의 전당

**국립수목원, 희귀식물 77% 보전... 국제기준 초과 달성**  
(포천=연합뉴스) 김도연 기자 = 산림청 국립수목원이 국내 희귀식물의 77.2%를 보전함으로써 국제기구의 권고 기준을 조기예 초 ... [연합뉴스](#), 2017-05-23 14:53

**대전충남 '봄가슴 심각'... 여름에도 비 적을듯**  
(대전=연합뉴스) 김소연 기자 = 심각한 불 가들이 이어지고 있는 대전·충남지역에 여름에도 땀날보다 적은 비가 내릴 것으로 예보 ... [연합뉴스](#), 2017-05-23 14:47

**\*폭염 막아라\* 건물 온도 낮추는 '쿨루프' 조성 구슬담**  
(부산=연합뉴스) 김재홍 기자 = 부산시가 지난해 시범 추진한 '쿨루프' 조성 사업을 올해 크게 확대해 폭염에 ... [연합뉴스](#), 2017-05-23 14:35

**산림청, 헬기 이용한 산림병해충 항공 방제 나서**  
- 5~7월 소나무재선충병 증가는 매개충 활동 시기 고려 - 경남과 제주, 경기 등 전국 41개 시군 구 7236ha 방제 [대 ... [이데일리](#), 2017-05-23 14:25

**<날짜이야기>5월24일 수요일(음력 4월29일)**  
전국이 흐리고 비가 오다가 아침에 서쪽 지역부터 그치기 시작해 오후에 대부분 그쳤다. 아침 최저기온은 12도에서 18도, 낮 ... [문화일보](#), 2017-05-23 14:21

연구 추진방법

NAVER **미세먼지**

통합검색 | 이미지 | **뉴스** | 어학사전

정렬 - 기간 - 영역 - 유형 - 언론사 - 기자명 - 옵션유지 [개괄] [키워드] | 상세 검색 -

연관검색어 (K) **환경kps 날씨 황사 일본 미세먼지 사이트 오늘날씨 미세먼지 마스크** |  |  |  |

오늘 미세먼지 농도 중국 미세먼지 에어코리아 서울 미세먼지 서울날씨 |

뉴스 1-10 / 274,987건

관련도순  최신순  오래된순

**미세먼지 공포에 집에서 운동... 실내운동용품 매출 급증**  
연말뉴스 | 시간전 | 네이버뉴스 |

**미세먼지와 황사를 피해 집에서 운동하는 사람들이 늘어나는 것으로 나타났다.** 일반적으로 실내운동 관련 제품들은 날씨가 추운 1~2월에 판매가 집중되지만 **미세먼지**의 영향으로 4~5월 매출이 한겨울 수준에 달하고...

▶ **미세먼지 기습에 실내 운동용품 매**... BBS NEWS | 26분 전

▶ **미세먼지 공포에 실내운동용품 붐터**... 중소기업신문 | 22분 전

**서울시내 미세먼지 가장 심한 장소로는 '공화대로'**  
뉴스 | 시간전 | 네이버뉴스 |

▶ 서울시내 간선도로중 **미세먼지**가 가장 많은 곳은 '공화대로'로 밝혀졌다. 서울시가 24일 공개한 '서울시 도로별 대기오염측정소 **미세먼지**, 초미세먼지 및 황사 농도' 자료에 따르면 지난해 1년동안 서울시 도로별...

▶ **서울시내 간선도로 중 '공화대로' 미**... 일요서울 | 25분 전

기대효과

연구 개요


선행 연구

연구 내용

연구 추진방법

기대효과

## Text Mining Process List



Plan 2017	Process	File Name	Description	Input	Output	Note
6월 하순	Pre-processing(2)		상동			
7월 상순	LDA Modeling(2)					
7월 상순	LDavis(2)					
7월 하순	Keyword Analysis(2)					

연구 개요


선행 연구

연구 내용

연구 추진방법

기대효과

## Text Mining Process List



Plan 2017	Process	File Name	Description	Input	Output	Note
8월	Trend Comparative Analysis					
9월	시사점 도출 및 정책제언					
10월	향후 계획 수립		<ul style="list-style-type: none"> <li>뉴스기사 댓글, 환경부 관련 페이스북, 트위터, 블로그, 유튜브 등을 통해 정책 수혜자 오피니언 마이닝 분석 실시</li> </ul>			

연구 개요

선행 연구

연구 내용

연구 추진방법

기대효과

## 학술적 기대효과

- 장기간에 걸친 KEI 연구 동향을 정리하여 추후 환경연구 기획에 필요한 정보를 원내외 연구진에게 제공
- 환경분야 텍스트 마이닝 분석기반 플랫폼 개발의 기초 구성
  - 환경관련 키워드 빈도 분석, 연관성 분석, 토픽 클러스터링 등 다양한 텍스트 마이닝 분석 기법 집적 가능
  - 추후 이들 기법을 자동으로 처리하는 플랫폼을 구축하는 기초로 활용 가능
- 환경 키워드 라이브러리 구축 사전 작업
  - 본 연구에서 구축하는 환경 키워드 사전 베타 버전은 향후 환경 키워드 사전으로 발전시켜 다양한 텍스트 마이닝 분석의 인프라로 활용 가능

연구 개요

선행 연구

연구 내용

연구 추진방법

기대효과

## 후속 연구

- 매체별 환경문제 인식 성향 분석을 소셜미디어, 전통미디어, 전문사이트(학술논문), 공공기관 발간문건 등으로 확대하여 연구동향과 사회적 인식간의 관계파악 범위를 확대
- KEI 제공 발간물 데이터 시각화 서비스를 구축하여 사용자의 이용 편이 증진
  - 대량의 KEI 발간물 데이터에 대한 정보를 사용자가 효율적으로 파악할 수 있도록 정보 전달력을 제고
- 환경연구 트렌드 분석을 활용하여 미래 환경연구 수요 예측에 반영
  - 기존의 정량적 전망을 활용한 미래 환경문제 예측을 반영하는 연구수요 예측과 매체 분석을 통해 수요자 선호를 반영하는 연구수요 예측을 병행

연구 개요

선행 연구

연구 내용

연구 추진방법

기대효과

## 정책 개발

- 환경정책 수요자의 선호를 정책개발에 활용하여 “환경서비스 품질수준 제고<sup>1)</sup>” 도모 가능
    - 매체별 환경분야 연구동향과 사회적 요구를 비교분석한 결과를 근거로 수요자의 선호를 파악하여 정책 개발 기초 자료로 활용
- 1) 국정과제 95. 생활환경 취약지역 개선 및 환경질 개선의 과제개요

**Thank you.**

## 초 록

본 연구는 환경정책·평가연구원(이하 KEI) 연구동향을 파악하고 환경연구에 대한 사회적 연구 수요와의 조응 여부를 탐구하였다. 1993년 이래 KEI는 다양한 환경 연구를 진행하고 있지만, 연구동향이 국민적 관심에 반응하고 있는 지 여부에 대한 회의가 존재한다. 이유는 일반적으로 개별 연구자는 연구주제 선정 시 시간적 제약 및 개인적 연구 성향에 의해서 연구수요 정보 파악 범위가 제한되기 때문이다. 또한 파악된 정보에 부여되는 우선순위가 개별 연구자의 선호에 영향을 받으므로 최신 정보 및 시의성 있는 연구 수요 반영에 제약이 존재하게 된다. 따라서 연구주제 선정 시 기존의 개별 연구자의 직관에 의존하는 방식을 보완할 필요가 있다. 이에 본 연구에서는 KEI에서 발행되는 연구보고서와 환경관련 뉴스 기사를 수집한 후 토픽 클러스터링, 연관어 분석, 키워드 네트워크 분석 등 다양한 텍스트 마이닝 기법을 이용하여 장기간의 KEI 연구동향과 사회적 연구수요 동향을 시기별로 각각 추출하여 비교분석하였다. 분석결과는 다음과 같다. ~ (향후 내용 추가). 분석 결과를 근거로 환경정책 수요자의 선호를 파악하여 추후 환경연구 기획에 필요한 정보를 원내의 연구진에게 제공하고자 한다.

# | 차례 |

## 1. 서론

- 가. 연구배경 및 목적
- 나. 연구내용 및 범위
- 다. 연구방법
- 라. 본문의 구성

## 2. 텍스트 마이닝의 정의와 활용

- 가. 텍스트 마이닝 기법의 개념
- 나. 텍스트 마이닝을 활용한 연구동향 분석 사례
  - 1) 사례1
  - 2) 사례2
  - 3) 사례3

## 3. 텍스트 마이닝 기반 연구동향 분석 방법론

- 가. 텍스트 마이닝 분석 기법
  - 1) LDA 분석
  - 2) 연관어 분석
  - 3) 네트워크 분석
- 나. 연구동향분석을 위한 텍스트 마이닝 적용 가능성
- 다. 연구 분석 절차
  - 1) 환경연구 동향 분석 : KEI 연구보고서 데이터(1993~2016)
  - 2) 환경뉴스 동향 분석 : NAVER 환경뉴스 데이터(2012~2016)
  - 3) 매체별 환경 분야 동향 비교 분석 : 연도별 분석(2012~2016)

## 4. KEI 연구동향 분석 결과(3-5일 작성)

- 가. 분석 데이터 개요
- 나. LDA기반 토픽 클러스터링 분석 결과
  - 1) 토픽별 KEI 연구 동향 (1993년~2016년)
  - 2) 토픽별 키워드 분석 결과

가) 에너지 자원

나) 폐기물

다) 대외협력

라) 물 환경, 환경영향평가

마) 기후변화

다. 키워드 연관성 분석 및 네트워크 분석 결과

1) 시기별 분석 결과

가) 1993년~2002년

나) 2003년~2007년

다) 2008년~2012년

라) 2013년~2016년

## 5. 환경뉴스 동향 분석 결과(6-7월)

가. 분석 데이터 개요

나. LDA기반 토픽 클러스터링 분석 결과

1) 토픽별 환경뉴스 동향 (2012년~2016년)

2) 토픽별 키워드 분석 결과

가) 토픽1

나) 토픽2

다) 토픽3

라) 토픽4

마) 토픽5

## 6. 매체별 환경 분야 동향 비교 분석 결과(8-9월)

가. 연도별 분석 결과

1) 2012년

2) 2013년

3) 2014년

4) 2015년

5) 2016년

## 7. 결론 및 제언(10월)