

고속, 고성능의 한국어 질의 응답 시스템

# 다이퀘스트닷컴

intelligent web dialogue

interface solutions

°김학수\*, 이근배\*\*, 서정연\*\*\*

\* ㈜다이퀘스트 연구소

\*\* 포항공대 컴퓨터공학과 자연어처리 연구실

\*\*\* 서강대학교 컴퓨터학과 자연어처리 연구실



## Contents

- ▼ Introduction
- ▼ Indexing method
  - System architecture
  - Answer-finding
  - Calculation of scores
- ▼ Searching method
- ▼ Experiments
- ▼ Demo
- ▼ Conclusion



## Introduction (3/3)

- Representative QA systems


	Strengths	Weaknesses
MURAX	Shallow linguistic analysis (POS tagger, finite-state recognizer)	Handcrafted patterns (Complex and fragile)
GuruQA	Fast response (Predictive annotation)	Use only local information
FALCON	High performance	Domain-specific knowledge like a semantic net.

1. 검색 속도가 IR 시스템에 비해서 상대적으로 많이 느리다.  
→ 색인 필요
2. Passage 내의 정답 주변 정보만을 이용한다.  
→ Second level 정보 이용 필요

diquest

자연어 처리, 분류, 및 질의 응답 에이전트 시장을 대표하는 연구 중심 벤처기업

## System architecture (1/2)




diquest

자연어 처리, 분류, 및 질의 응답 에이전트 시장을 대표하는 연구 중심 벤처기업



### System architecture (2/2)



diquest

자연어 처리 응용 분야의 실제 응용 예시들을 소개하는 연구동향 세미나 자료



### Answer-finding (1/2)

- 문맥 윈도우 설정

인터넷 포털 업체들의 새로운 전략

야후코리아(대표 염진섭 www.yahoo.co.kr)는 무료 이메일 서비스를 시작했다.

그 서비스를 사용하는 고객은 6메가의 무료 이메일 공간을 사용할 수 있다.



의미 사전



의미 규칙

diquest

자연어 처리 응용 분야의 실제 응용 예시들을 소개하는 연구동향 세미나 자료



## Answer-finding (2/2)

- 105개의 의미 분류

계층 1	계층 2				
animal	bird	fish	mammal	person	reptile
plant	grass	tree	flower		
location	address	building	city	continent	country
	state	town			
identification	code	e_mail	nationality	position	tel_num
	URL				
date	day	month	season	weekday	year
time	hour	minute	second		
quantity	age	distance	duration	length	money
	number	power	rate	size	speed
	temperature	volume	weight		

diquest

자연어 처리, 플루트 및 질의 응답 에이전트 시스템을 대표하는 연구중심 벤처기업



## Calculation of scores (1/3)

야후코리아(사장 염진섭 www.yahoo.co.kr)는 무료 이메일 서비스를 시작했다.  
 그 서비스를 사용하는 고객은 6메가의 무료 이메일 공간을 사용할 수 있다.

→ Distance, Term Frequency, TF\*IDF

- 거리 가중치 (distance feature 반영)

$$distw_{d,k}(a, w_j) = \frac{c}{\log(dist(i, j)) + c}$$

- 빈도수 (term frequency feature 반영)

$$LS_{d,k}^n(a, w_{pos(n)}) = distw_{d,k}(a, w_{pos(n)}) + (1 - distw_{d,k}(a, w_{pos(n)})) \times LS_{d,k}^{n-1}(a, w_{pos(n-1)}),$$

where  $LS_{d,k}^0(a, w_{pos(0)}) = 0$ .

diquest


자연어 처리, 플루트 및 질의 응답 에이전트 시스템을 대표하는 연구중심 벤처기업



## Calculation of scores (2/3)

### TF\*IDF

$$GS(pseudo\_d_w, w) = \begin{cases} \left(0.5 + 0.5 \frac{tf_w}{Max\_tf}\right) \frac{\log(N/n)}{\log(N)}, & \text{if } tf_w > 0 \\ 0, & \text{if } tf_w = 0 \end{cases}$$




diquest

자연어 처리, 불분명 한 질의 응답 매치먼트 시정점 (대표하는 연구자님 연락처)



## System architecture




diquest


자연어 처리, 불분명 한 질의 응답 매치먼트 시정점 (대표하는 연구자님 연락처)



### Searching method (1/2)



### Classification Rules



diquest

자연어 처리 솔루션 및 길의 응답 에이전트 기술을 대표하는 연구중심 벤처기업



### Searching method (2/2)

- 정답 후보 점수 계산: p-Norm 모델 (AND)

$$Sim(A, Q_{and}) = 1 - \sqrt[p]{\frac{q_1^p (1 - S(A, w_1))^p + q_2^p (1 - S(A, w_2))^p + \dots + q_i^p (1 - S(A, w_i))^p}{q_1^p + q_2^p + \dots + q_i^p}}$$

- IR, QA 유사도 결합

$$Sim(D, Q) = \frac{\alpha \cdot IRsim(D, Q) + \beta \cdot QAsim_d(A_{DMS}, Q)}{\alpha + \beta}$$

diquest

자연어 처리 솔루션 및 길의 응답 에이전트 기술을 대표하는 연구중심 벤처기업



## Experiments (1/2)

### 실험 데이터

- KorQATeC 1.0
  - 207,067 balanced documents (368,768 kilobytes)
- WEBTEC 1.0 (WEB TEst Collection)
  - 22,448 documents (43,953 kilobytes)
  - www.sogang.ac.kr (7,869 documents)
  - korea.internet.com (6,452 documents)

diquest

자신의 자리 이름과 및 강의 응답 메타인트 시그를 대표하는 연구용량 벤치마크



## Experiments (2/2)

### 질의 응답 정확률 실험

	Lee2000 (object)	Lee2000 (50-byte)	Kim2001 (object)	실험 시스템
MRAR	0.322	0.456	0.485	0.540
MRAR-1	0.322	0.456	0.539	0.600

### 질의 응답 및 색인 속도 실험

	Response time per query (seconds)	Indexing time per mega byte (seconds)
기본 IR 시스템	0.026	26.765
실험 시스템	0.048	30.542

diquest

자신의 자리 이름과 및 강의 응답 메타인트 시그를 대표하는 연구용량 벤치마크





# Conclusion

## AS - Is (기존의 검색 시스템)

- 기능 측면에서의 질의 응답 결과
  1. 해당되는 문서를 단순 나열함.
  2. 문서 속에서 정답 검색이 여전히 필요.
  3. 정보 검색 과정에 많은 시간 소요.
  4. 사용자의 문서 활용도가 매우 낮음.
- 정확도 측면에서의 질의 응답 결과
  1. 질문에서 키워드만을 추출.
  2. 키워드에 대한 체계적 검색 결과만 제시.
  3. 정확한 의도 분석이 불가능.

• 질문 : "김낙영 교수님의 전화번호는?"  
 1. 김낙영+교수+전화+번호  
 문서 내에서 단순히 발견되는 정도 측정.  
 "김낙영", "교수", "전화", "번호", "전화번호"  
 라는 단어가 들어간 불필요한 모든 문서들을  
 제시

## To - Be (질의 응답 시스템)

- 기능 측면에서의 질의 응답 결과
  1. 문서에서 정답을 직접 찾아서 제시.
  2. 정답 검색 과정 시간 단축.
  3. 사용자 문서 활용도 증가 → 인지도 향상.
  4. 웹 문서뿐 아니라 데이터베이스까지 검색.
  5. 특정 문서 직접 제시 가능.
- 정확도 측면에서의 질의 응답 결과
  1. 질문의 어휘 구조, 질문 의도까지 파악.
  2. 정확한 질의 분석 → 의미있는 부분만 검색.
  3. 검색 성능 최적화 가능.

• 질문 : "김낙영 교수님의 전화번호는?"  
 1. 전화번호에 관한 질문(김낙영 교수)  
 우선 전화번호에 관한 질문이라는 것이 파악  
 되고, 그 대상이 김낙영 교수라는 것을 인식  
 하여 정답 추출

diquesc

지능이 처리 솔루션 및 질의 응답 에이전트 시장을 대표하는 연구중심 벤처기업