

좋은 검색서비스를 만들기 위한 기계학습의 활용사례

김상범

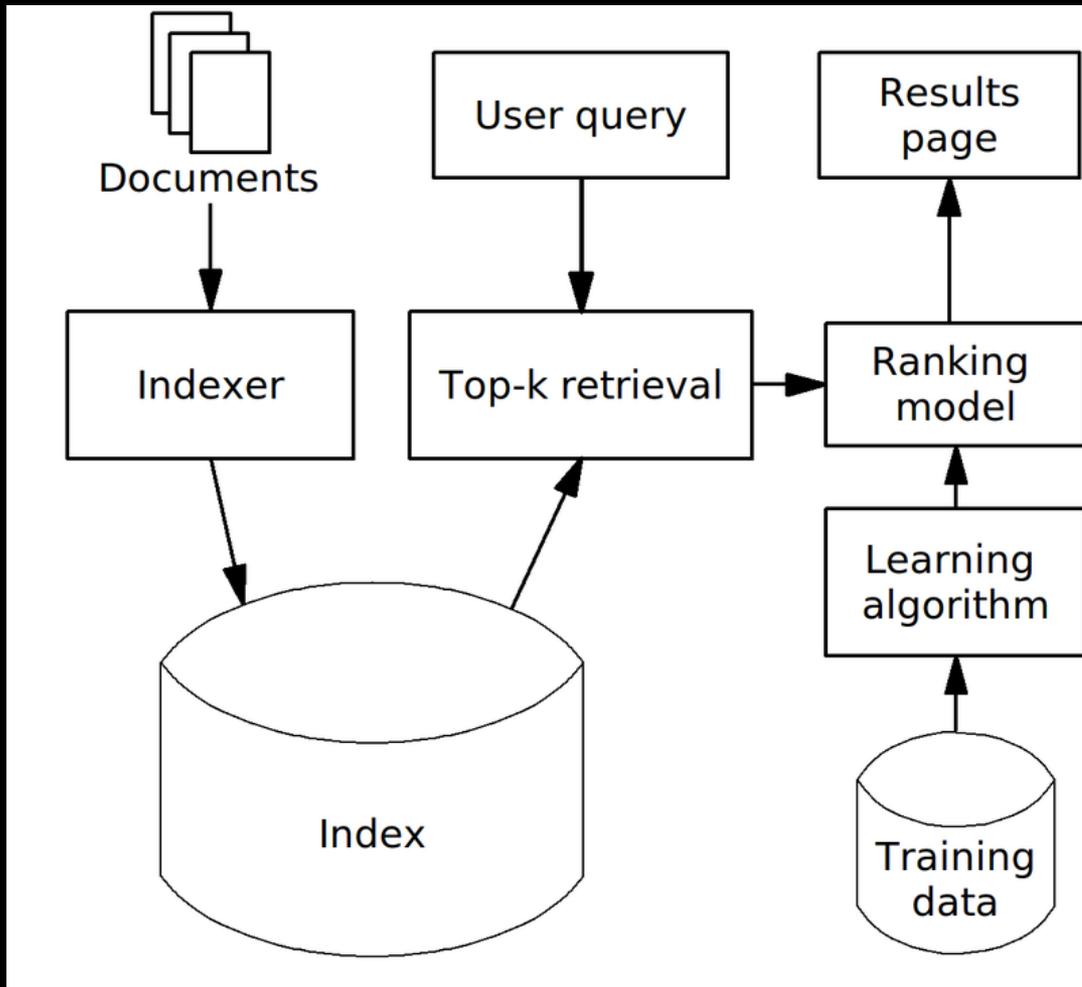
2016. 6.

NAVER

Contents

1. 네이버 ?
2. 검색서비스 ?
3. 기계학습 활용사례
 - Ranking
 - Sequence Labeling
 - Text/Query Mining
 - Vision-Text Collaboration
 - Recommendation

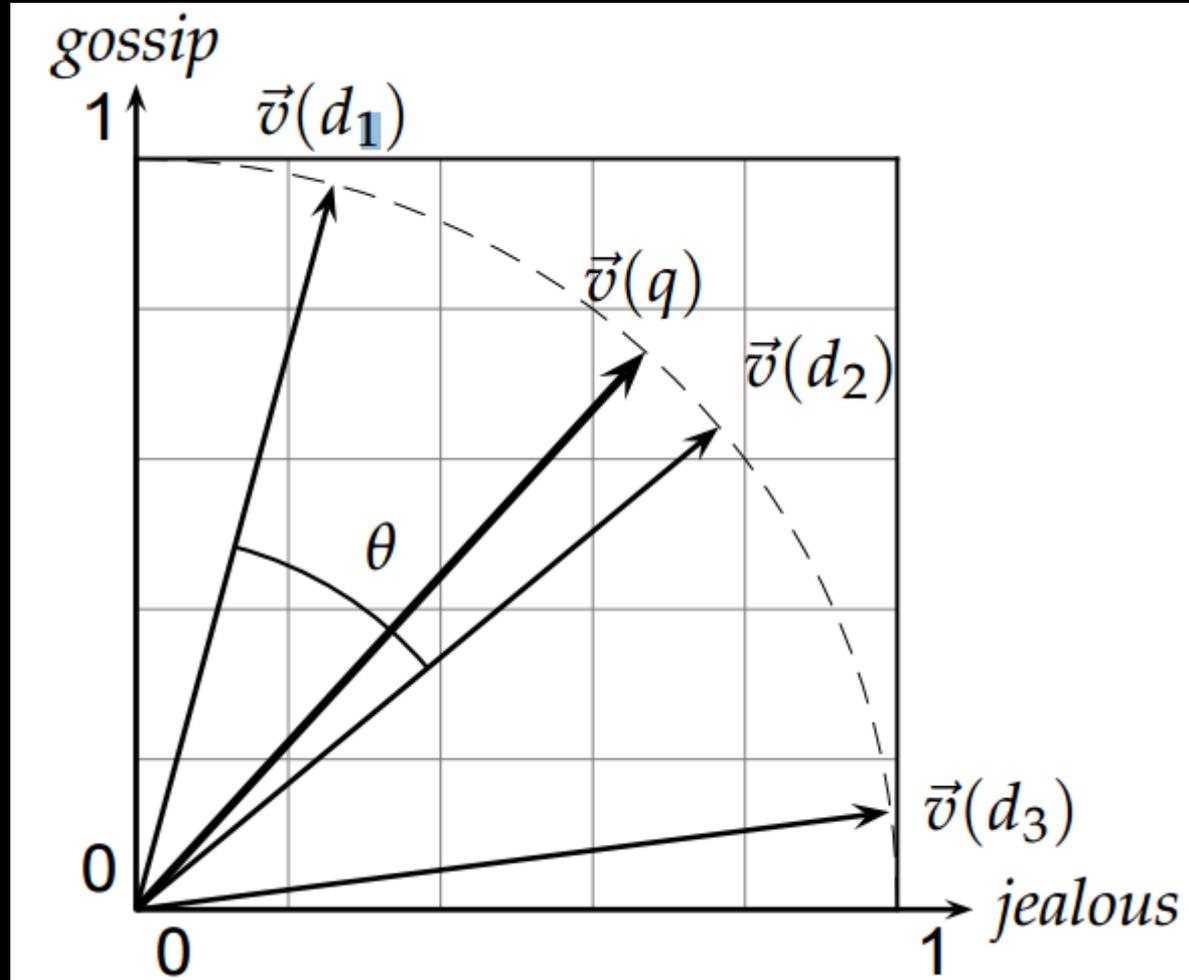
검색서비스?



Coverage
Efficiency
Effectiveness
Policy

Ranking : Old Approaches

- Vector Space Model



Ranking : Old Approaches

- Probabilistic Ranking Model

$$P(\text{rel} | d, q) \propto_q \frac{P(\text{rel} | d, q)}{P(\overline{\text{rel}} | d, q)} \quad (2.1)$$

$$= \frac{P(d | \text{rel}, q) P(\text{rel} | q)}{P(d | \overline{\text{rel}}, q) P(\overline{\text{rel}} | q)} \quad (2.2)$$

$$\propto_q \frac{P(d | \text{rel}, q)}{P(d | \overline{\text{rel}}, q)} \quad (2.3)$$

$$\approx \prod_{i \in V} \frac{P(TF_i = tf_i | \text{rel}, q)}{P(TF_i = tf_i | \overline{\text{rel}}, q)} \quad (2.4)$$

$$\begin{aligned} w_i^{\text{BM25}}(tf) &= \frac{tf'}{k_1 + tf'} w_i^{\text{RSJ}} \\ &= \frac{tf}{k_1 \left((1 - b) + b \frac{dl}{avdl} \right) + tf} w_i^{\text{RSJ}} \end{aligned}$$

Ranking : Old Approaches

- Language Model based IR

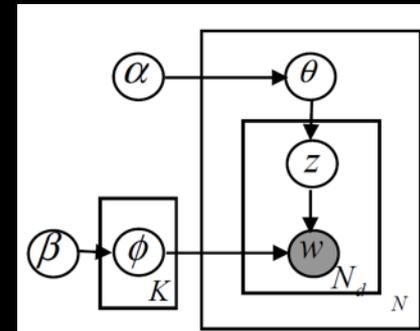
$$P(d|q) \propto P(d) \prod_{t \in q} ((1 - \lambda)P(t|M_c) + \lambda P(t|M_d))$$

- ✓ Simple smoothing

$$\hat{P}(t|d) = \frac{tf_{t,d} + \alpha \hat{P}(t|M_c)}{L_d + \alpha}$$

- ✓ LDA

$$P(w | D) = \lambda \left(\frac{N_d}{N_d + \mu} P'(w | D) + \left(1 - \frac{N_d}{N_d + \mu}\right) P'(w | coll) \right) + (1 - \lambda) \left(\sum_{t=1}^K \frac{n_{-i,j}^{(w_i)} + \beta_{w_i}}{\sum_{v=1}^V (n_{-i,j}^{(v)} + \beta_v)} \times \frac{n_{-i,j}^{(d_i)} + \alpha_{z_i}}{\sum_{t=1}^T (n_{-i,t}^{(d_i)} + \alpha_t)} \right) \quad (9)$$



Ranking : 실제상황

- 단어의 빈도만 갖고 랭킹을 하기에는 signal이 너무 많음
 - 질의와 매치된 단어의 폰트가 어떠한가?
 - 많은 사람들이 보았거나 링크를 걸었는가?
 - 다른 사람이 어떤 단어로 링크를 걸었는가?
 - 문서를 작성한 사람이 과거에 스팸작성자로 경고조치 됐었는가?
 - 언제 만들어진 문서인가?
 - 몇 명이 조회한 문서인가?
 - 문서의 제목과 본문의 관련성은 높은가?
- 상당수의 질의들에 대해서는 자동평가집합구축이 가능
 - 클릭수?
 - 위치를 고려한 클릭수?
 - 체류시간?

Feature가 많아지고
Evaluation Set확보가 비교적 쉬워짐
→ 기계학습 기반 랭킹을 안 할 수 없음

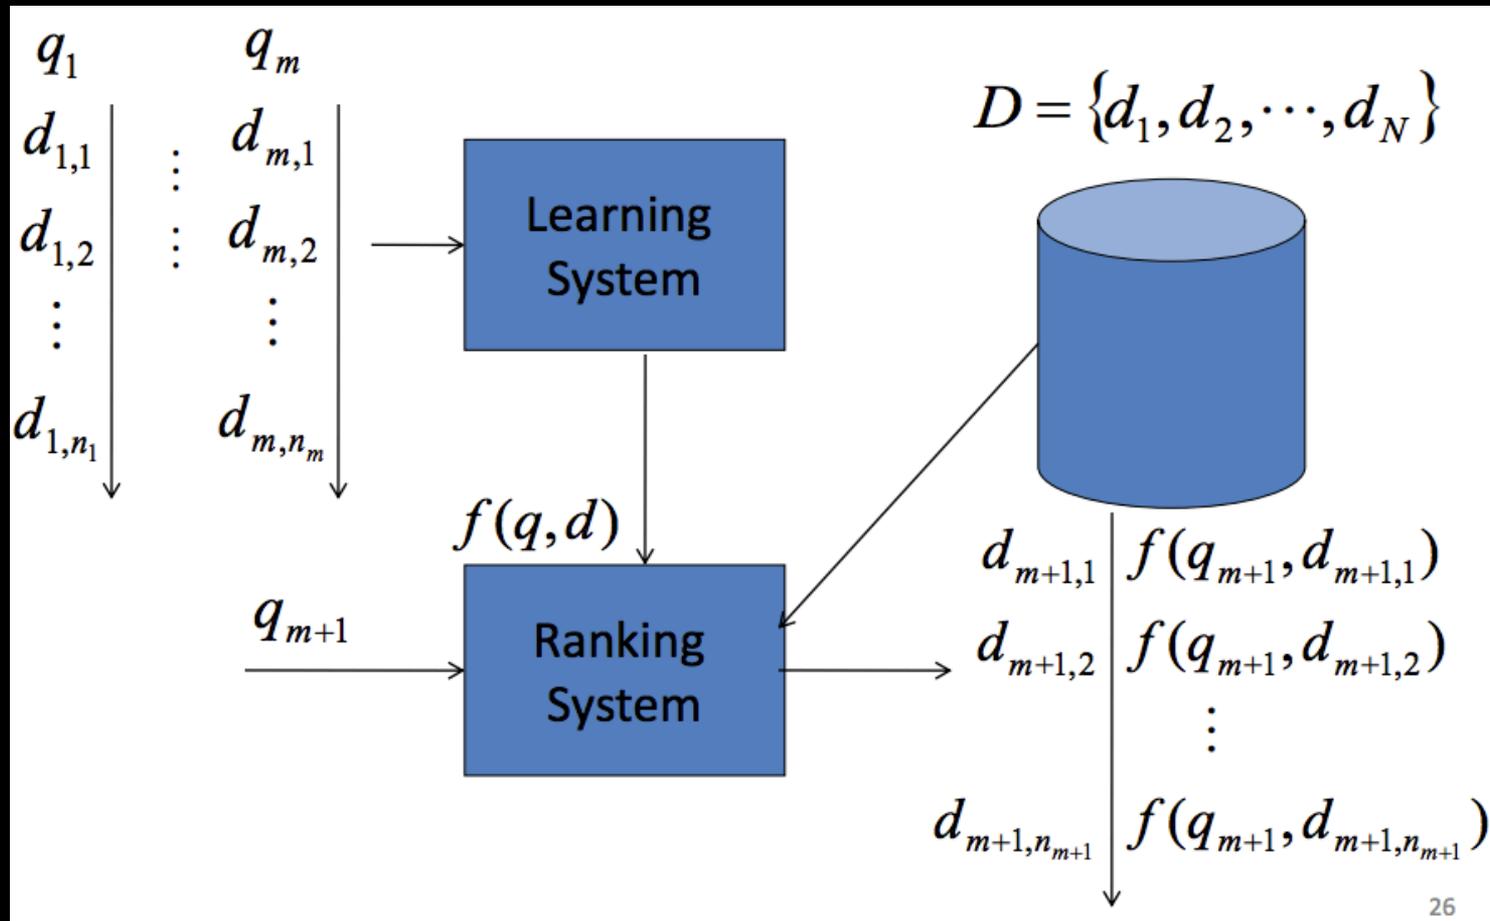
Ranking : Learning-to-Rank Overview

- 검색의 핵심은 **체계적으로** 줄세우기

q_1	= “한국 경제 전망”
$d_{1,1}$	= [0.66 , 2 , 0.08, 1 , 3, 1, 0, 4.2, 25, 0.43]
$d_{1,2}$	질의 단어 중 제목에 나타난 단어의 비율
\vdots	제목에 출현한 질의 단어의 총 합
\vdots	질의 단어별 “본문출현빈도/본문길이”의 합
d_{1,n_1}	질의 단어 중 본문에 나타난 단어의 비율
	질의의 단어수
	전문정보를 찾는 질의인가?
	질의에 연예인 이름이 포함되어 있나?
	문서가 포함된 사이트의 Site Authority
	문서의 나이(Age)
	문서의 품질(Quality)

Ranking : Learning-to-Rank Overview

- 검색의 핵심은 **체계적으로** 줄세우기



Ranking : Learning-to-Rank Overview

- Training Data
 - Query : Document(URL) : Feature-Value-List : Grade
- Feature List
 - Matching Feature
 - ✓ Sum of $tf*idf$, Match term Ratio, etc
 - Document-specific Feature
 - ✓ Visit Count, Quality, Create Time, etc
 - Query-specific Feature
 - ✓ Length of query, HasPersonName, etc
- Grade
 - Perfect / Excellent / Good / Fair / Bad

Ranking : Learning-to-Rank Overview

- Evaluation Measure : nDCG

4 documents: d_1, d_2, d_3, d_4

i	Ground Truth		Ranking Function ₁		Ranking Function ₂			
	Document Order	r_i	Document Order	r_i	Document Order	r_i		
1	d4	2	d3	2	d3	2		
2	d3	2	d4	2	d2	1		
3	d2	1	d2	1	d4	2		
4	d1	0	d1	0	d1	0		
		NDCG _{GT} =1.00			NDCG _{RF1} =1.00			NDCG _{RF2} =0.9203

$$DCG_{GT} = 2 + \left(\frac{2}{\log_2 2} + \frac{1}{\log_2 3} + \frac{0}{\log_2 4} \right) = 4.6309$$

$$DCG_{RF1} = 2 + \left(\frac{2}{\log_2 2} + \frac{1}{\log_2 3} + \frac{0}{\log_2 4} \right) = 4.6309$$

$$DCG_{RF2} = 2 + \left(\frac{1}{\log_2 2} + \frac{2}{\log_2 3} + \frac{0}{\log_2 4} \right) = 4.2619$$

$$MaxDCG = DCG_{GT} = 4.6309$$

Ranking SVM

- Problem Definition

- Input space: X
- Ranking function $f : X \rightarrow R$
- Ranking: $x_i \succ x_j \Leftrightarrow f(x_i; w) > f(x_j; w)$
- Linear ranking function: $f(x; w) = \langle w, x \rangle$
 $\langle w, x_i - x_j \rangle > 0 \Leftrightarrow f(x_i; w) > f(x_j; w)$
- Transforming to pairwise classification:

$$(x_i - x_j, z), z = \begin{cases} +1 & x_i \succ x_j \\ -1 & x_j \succ x_i \end{cases}$$

Ranking SVM

- Solution

$$\min_{w, \xi} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \xi_i$$

$$z_i \langle w, x_i^{(1)} - x_i^{(2)} \rangle \geq 1 - \xi_i \quad i = 1, \dots, l$$

$$\xi_i \geq 0$$



$$\min_w \sum_{i=1}^l \left[1 - z_i \langle w, x_i^{(1)} - x_i^{(2)} \rangle \right]_+ + \lambda \|w\|^2$$

$$[s]_+ = \max(0, s) \quad \lambda = \frac{1}{2C}$$

Ranking SVM

- Problems

- Error 에도 그 중요도가 있는데 반영을 못한다
(검색랭킹 specific한 평가척도를 직접 최적화하지는 못함)

Ranks: 3, 2, 1

ranking 1: 2 3 2 1 1 1 1

ranking 2: 3 2 1 2 1 1 1

ranking 2 should be better than ranking 1

Ranking SVM views them as the same

- Query별 labeled 문서수에 따라 bias가 생길 수 있다

q1: 3 2 2 1 1 1 1

q2: 3 3 2 2 2 1 1 1 1

number of pairs for q1 : $2*(2-2) + 4*(3-1) + 8*(2-1) = 14$

number of pairs for q2: $6*(3-2) + 10*(3-1) + 15*(2-1) = 31$

개선된 RankSVM이나 Listwise 접근법 등 다양한 연구가 진행됨

Ranking만 잘하면 되나?

N 인공지능 × 🔍

통합검색 | 뉴스 | 이미지 | 어학사전 | ...

연관 인공지능의 장단점, 명견만리, 인공지능 토론, 인공지능 장점, 인공지능의 미래, 알파고, 인공지능 영화

지식백과

인공지능
artificial intelligence, 人工智能

인간의 학습능력과 추론능력, 지각능력, 자연언어의 이해능력 등을 컴퓨터 프로그램으로 실현한 기술. 인간의 지능으로 할 수 있는 사고, 학습, 자기계발 등을 컴퓨터가 할 수 있도록 하는 방법을 연구하는 컴퓨터공학 및 정보기술의 한 분야로서, 컴퓨터...
두산백과

어린이백과 1 | 학생백과 3

지식백과 더보기 >

인공지능 - Wikipedia

인공지능의 또다른 정의는 인공적인 장치들이 가지는 지능이다. 대부분 정의들이 인간처럼 사고하는 시스템, ...
웹문서 <https://ko.m.wikipedia.org/wiki/...>

인공지능 - 사이언스타임즈

"인공지능" Tag 모든 글 "제조업이 4차혁명 최적의 공간" 김상현 한국오라클 CTO 기조강연 누가 '4차 산업혁명'...
웹문서 <http://www.sciencetimes.co.kr/?...>

Q 인공지능에 대해서!!
인공지능이 미래에 가져올 긍정과부정에는 뭐가있을까요??

A -매우 접근하기 어려운 재난 현장이나, 데이터 분석등을 인공지능이 더욱 쉽고 간편하게 수행할수있다. -인...
지식iN 7일 전 ♡ 2

인류를 결국 멸망시킬 5개의 인공지능 회사들

앞으로 5년 후부터는 실질적으로 인간의 지능에 근접한 기계들을 만나게 될 것이며, 어느 순간이 되면 로봇은 ...
웹문서 2014.04.12. | <http://www.earlyadopter.co.kr/9359>

인공지능(AI)에 대한 오해와 진실

알파고와 이세돌 9단의 바둑 경기 모습 (출처: 한국기원 홈페이지) 지난 3월 구글의 ...
블로그 2016.04.29. | 현대자동차 영현대 ... SmartEditor (3.0) ♡

더보기 >

책

인공지능과 딥러닝 (인공지능이 ...

저자 마쓰오 유타카
출판사 동아엠앤비
출간일 2015.12.10.
★★★★☆ 7.83

책소개 ▾ | 리뷰 26 ▾ | 도서 | e북

인공지능 1 (현대적 접근방식)

저자 스튜어트 러셀, 피터 노빅
출판사 제이펍
출간일 2016.01.29.
★★★★★ 10.0

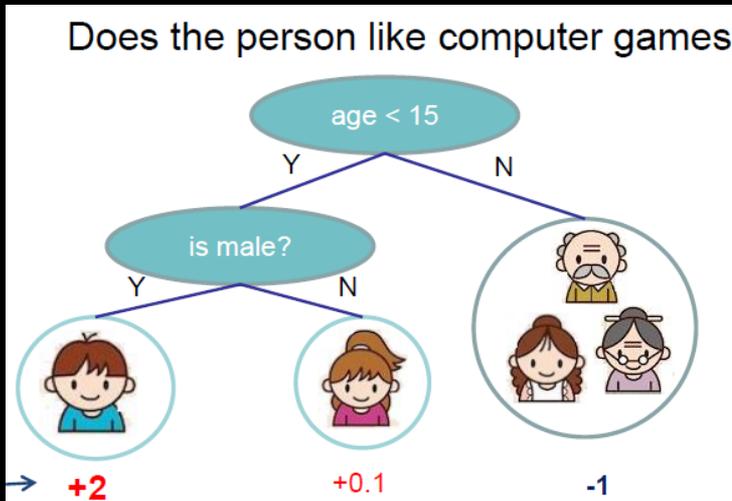
책소개 ▾ | 리뷰 1 ▾ | 도서

책 더보기 >

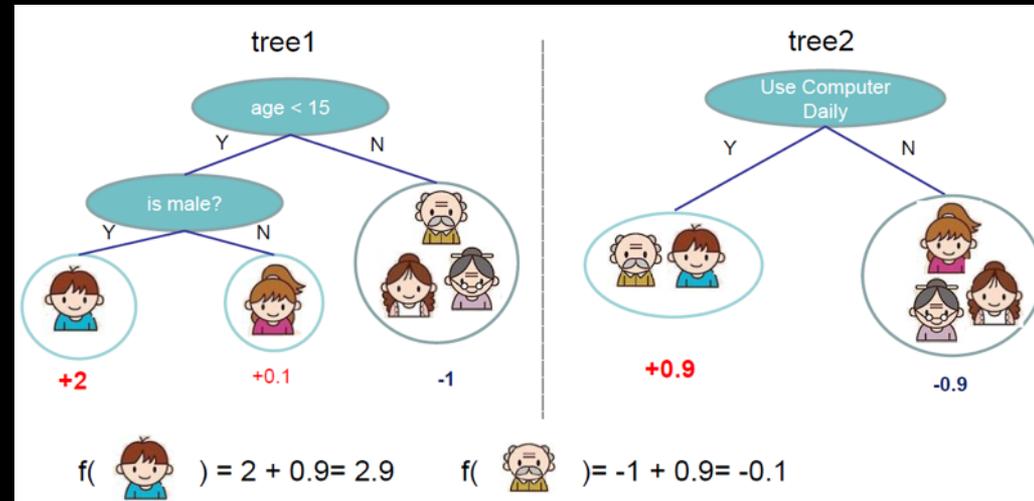
Ranking만 잘 하면 될까?
무조건 5개까지 보여주면 될까?

Ranking and Regression : GBRT

- Regression Tree



- Regression Tree Ensemble



- Model: assuming we have K trees

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i), \quad f_k \in \mathcal{F}$$

- Objective

$$Obj = \sum_{i=1}^n l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k)$$

Training loss

Complexity of the Trees

SVM, NN, LR같이
 학습방법이 잘 연구되어온
 Numerical vector/matrix기반
 classifier가 아니라서...
 학습방법 자체가 큰 연구토픽

Ranking and Regression : GBRT

- GBRT (Gradient Boosted Regression Tree)

$$\begin{aligned}\hat{y}_i^{(0)} &= 0 \\ \hat{y}_i^{(1)} &= f_1(x_i) = \hat{y}_i^{(0)} + f_1(x_i) \\ \hat{y}_i^{(2)} &= f_1(x_i) + f_2(x_i) = \hat{y}_i^{(1)} + f_2(x_i) \\ &\dots \\ \hat{y}_i^{(t)} &= \sum_{k=1}^t f_k(x_i) = \hat{y}_i^{(t-1)} + f_t(x_i) \leftarrow \text{New function}\end{aligned}$$

Model at training round t

Keep functions added in previous round

$$\begin{aligned}Obj^{(t)} &= \sum_{i=1}^n l(y_i, \hat{y}_i^{(t)}) + \sum_{i=1}^t \Omega(f_i) \\ &= \sum_{i=1}^n l(y_i, \hat{y}_i^{(t-1)} + f_t(x_i)) + \Omega(f_t) + constant\end{aligned}$$

Goal: find f_t to minimize this

$$\begin{aligned}&= \sum_{i=1}^n \left(y_i - (\hat{y}_i^{(t-1)} + f_t(x_i)) \right)^2 + \Omega(f_t) + const \\ &= \sum_{i=1}^n \left[2(\hat{y}_i^{(t-1)} - y_i) f_t(x_i) + f_t(x_i)^2 \right] + \Omega(f_t) + const\end{aligned}$$

Ranking and Regression : GBRT

- GBRT (Gradient Boosted Regression Tree)

$\hat{y}_i^{(0)} = 0$
 $\hat{y}_i^{(1)}$
 $\hat{y}_i^{(2)}$
 $\hat{y}_i^{(t)}$

Model at training round t

Loss function

Objective function

Goal: find f_t to minimize this

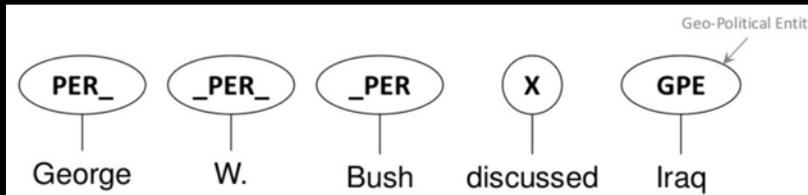
$$Obj^{(t)} = \sum_{i=1}^n (y_i - (\hat{y}_i^{(t-1)} + f_t(x_i)))^2 + \Omega(f_t) + const$$
$$= \sum_{i=1}^n [2(\hat{y}_i^{(t-1)} - y_i)f_t(x_i) + f_t(x_i)^2] + \Omega(f_t) + const$$


Sequence Labeling : 일반적인 적용분야

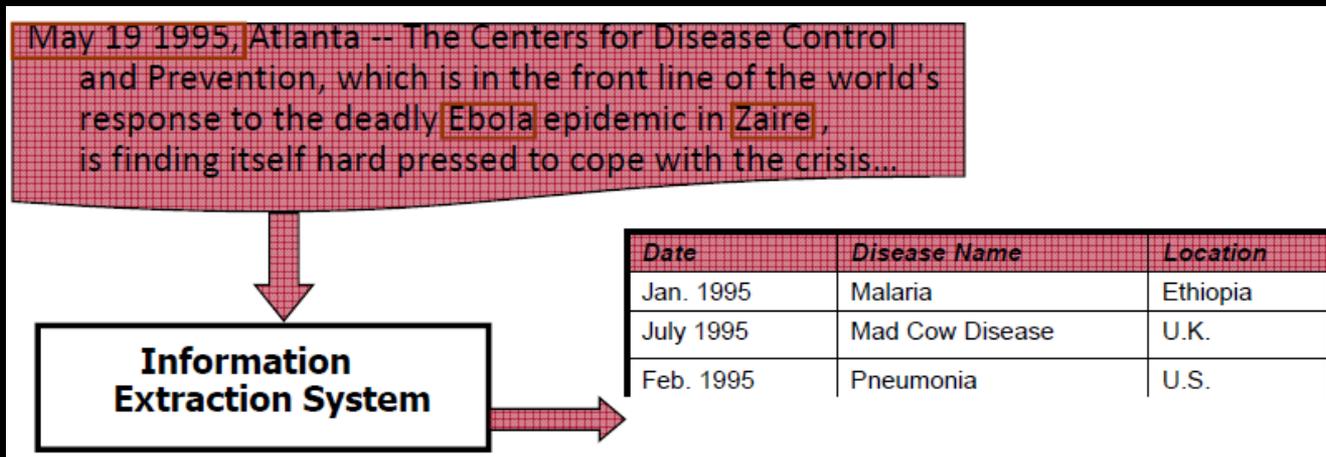
- Word Segmentation

검	색	시	스	템	용		단	어	분	할	기
B	I	B	I	I	B	O	B	I	B	I	B

- Named Entity Tagging



- Information Extraction



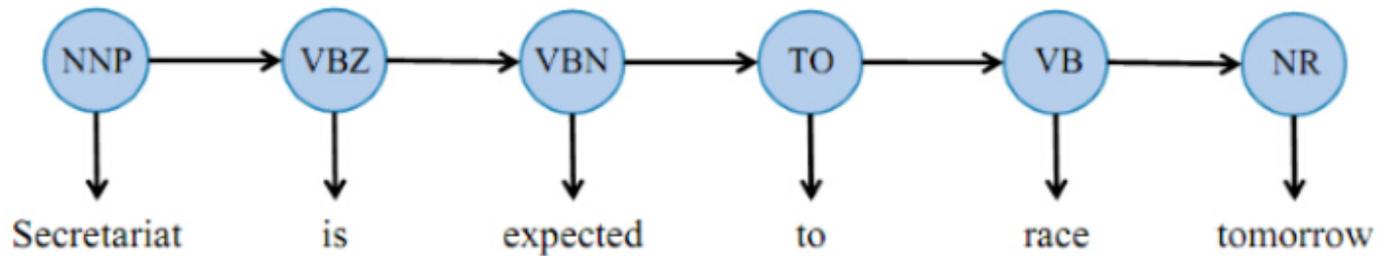
Sequence Labeling : 실제 적용사례

- 자동번역기를 위한 분석기
- 즉답제공을 위한 관계추출

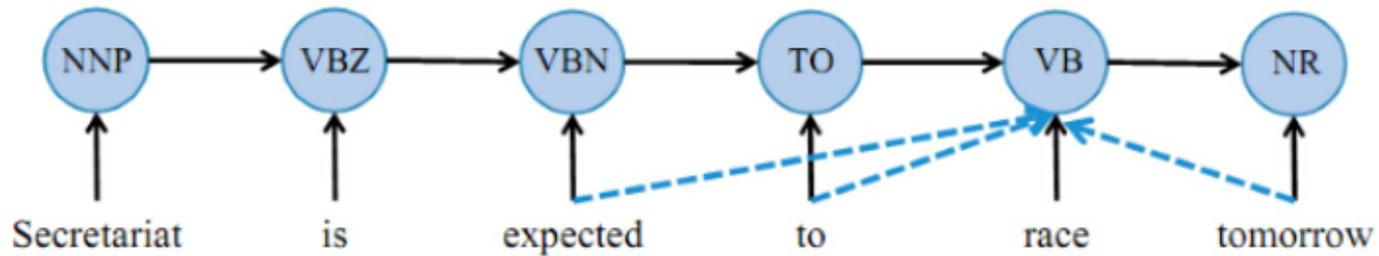


Sequence Labeling : HMM / MEMM / CRF

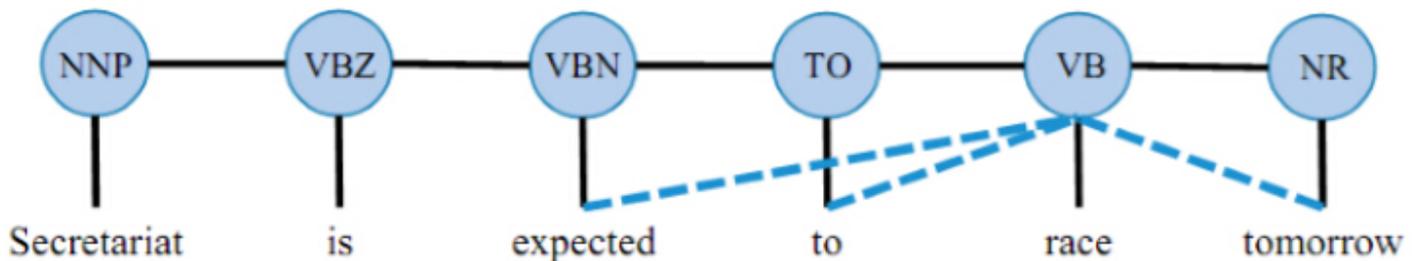
HMM



MEMM



CRF

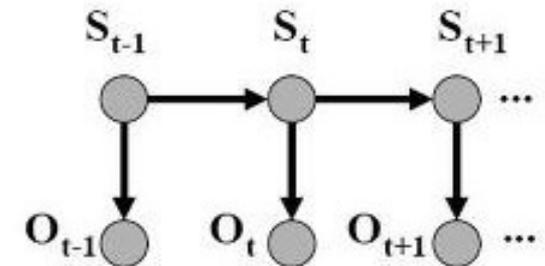


Sequence Labeling : HMM / MEMM / CRF

$$\vec{s} = s_1, s_2, \dots, s_n \quad \vec{o} = o_1, o_2, \dots, o_n$$

HMM

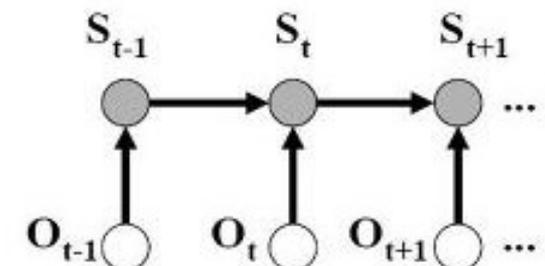
$$P(\vec{s}, \vec{o}) \propto \prod_{t=1}^{|\vec{o}|} P(s_t | s_{t-1}) P(o_t | s_t)$$



MEMM

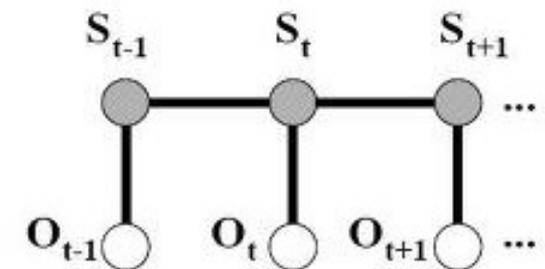
$$P(\vec{s} | \vec{o}) \propto \prod_{t=1}^{|\vec{o}|} P(s_t | s_{t-1}, o_t)$$

$$\propto \prod_{t=1}^{|\vec{o}|} \frac{1}{Z_{s_{t-1}, o_t}} \exp \left(\sum_j \lambda_j f_j(s_t, s_{t-1}) + \sum_k \mu_k g_k(s_t, x_t) \right)$$



CRF

$$P(\vec{s} | \vec{o}) \propto \frac{1}{Z_{\vec{o}}} \prod_{t=1}^{|\vec{o}|} \exp \left(\sum_j \lambda_j f_j(s_t, s_{t-1}) + \sum_k \mu_k g_k(s_t, x_t) \right)$$



Sequence Labeling : LSTM

- 새로운 강자 LSTM

Table 2: Comparison of tagging performance on POS, chunking and NER tasks for various models.

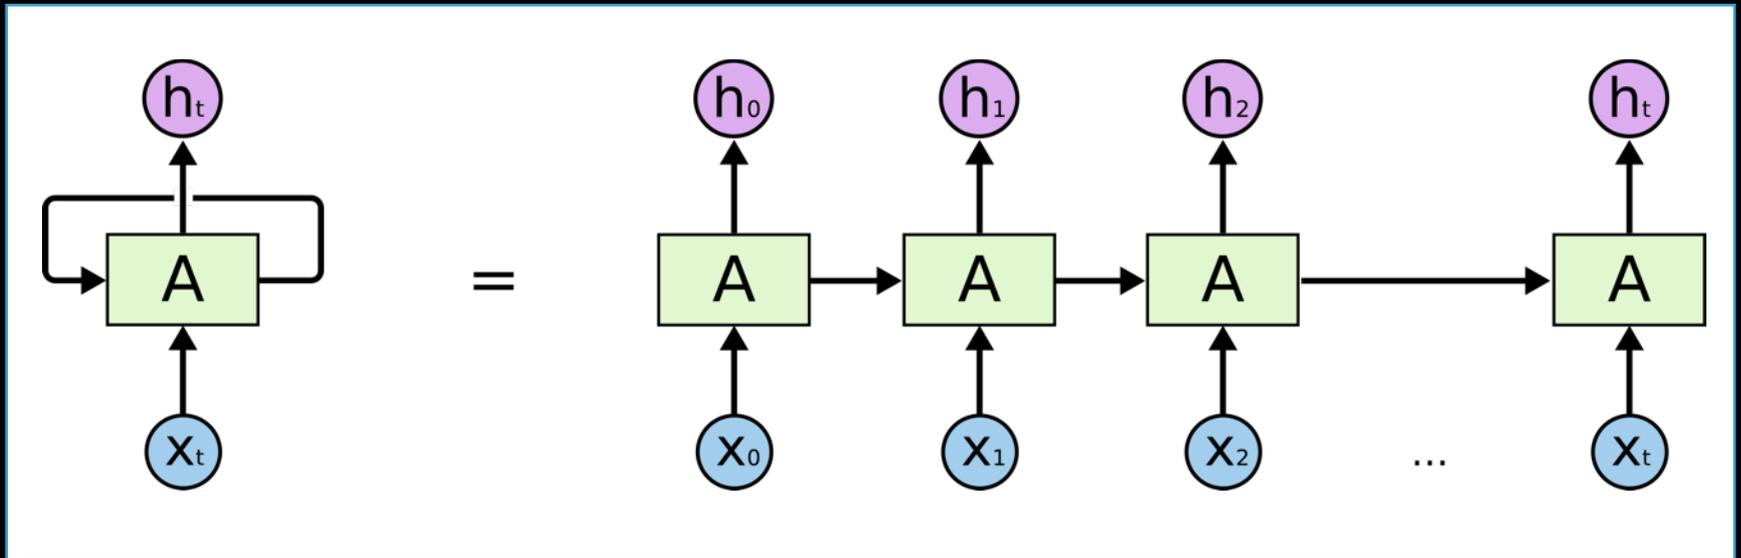
		POS	CoNLL2000	CoNLL2003
Random	Conv-CRF (Collobert et al., 2011)	96.37	90.33	81.47
	LSTM	97.10	92.88	79.82
	BI-LSTM	97.30	93.64	81.11
	CRF	97.30	93.69	83.02
	LSTM-CRF	97.45	93.80	84.10
	BI-LSTM-CRF	97.43	94.13	84.26
Senna	Conv-CRF (Collobert et al., 2011)	97.29	94.32	88.67 (89.59)
	LSTM	97.29	92.99	83.74
	BI-LSTM	97.40	93.92	85.17
	CRF	97.45	93.83	86.13
	LSTM-CRF	97.54	94.27	88.36
	BI-LSTM-CRF	97.55	94.46	88.83 (90.10)

Table 3: Tagging performance on POS, chunking and NER tasks with only word features.

		POS	CoNLL2000	CoNLL2003
Senna	LSTM	94.63 (-2.66)	90.11 (-2.88)	75.31 (-8.43)
	BI-LSTM	96.04 (-1.36)	93.80 (-0.12)	83.52 (-1.65)
	CRF	94.23 (-3.22)	85.34 (-8.49)	77.41 (-8.72)
	LSTM-CRF	95.62 (-1.92)	93.13 (-1.14)	81.45 (-6.91)
	BI-LSTM-CRF	96.11 (-1.44)	94.40 (-0.06)	84.74 (-4.09)

Sequence Labeling : LSTM

- Motivation : RNN의 원거리 의존관계 문제

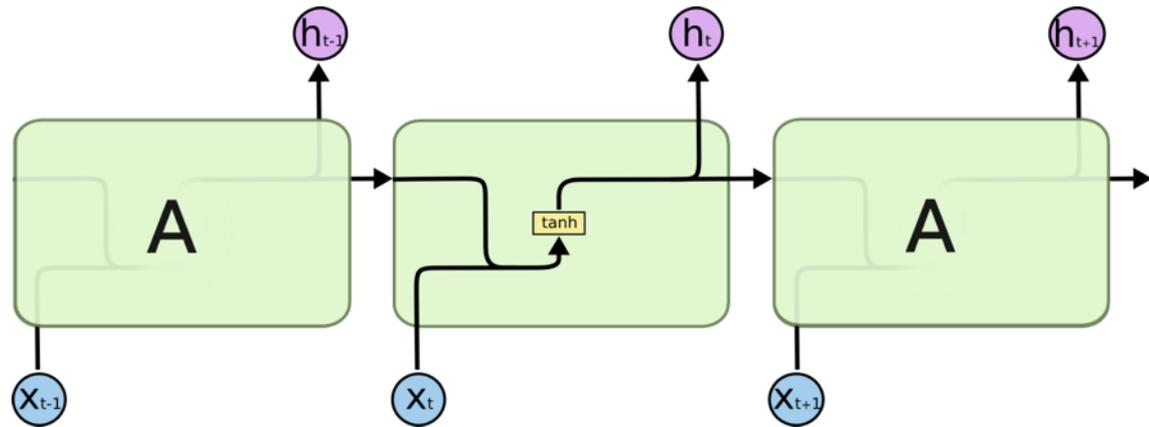


- 이전상태를 기억하면서 현재 입력을 바탕으로 결과를 내놓는다는 점에서 많은 진보를 가져다 줌
- “the clouds are in the _____”
- “I grew up in France where my mother still lives. So I speak fluent _____” → 원거리 의존관계 문제 (long-term dependency)

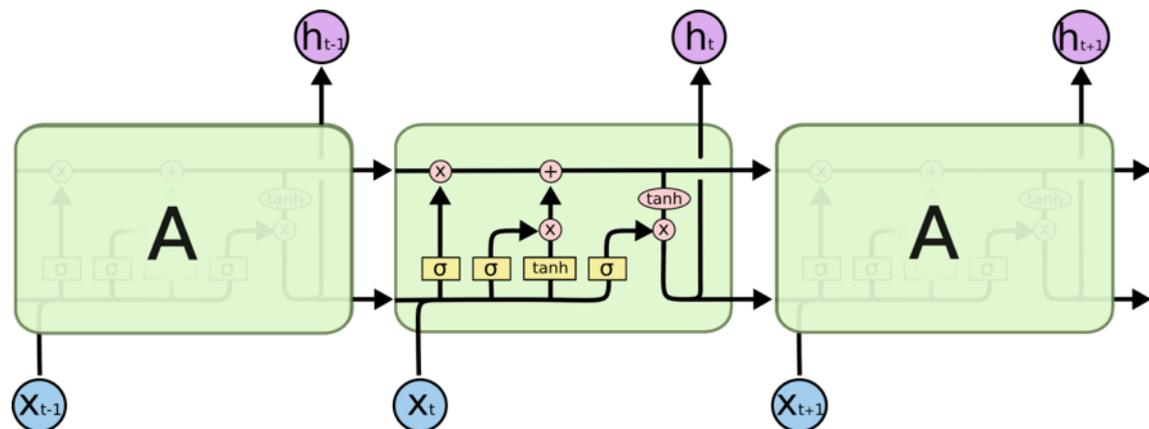
Sequence Labeling : LSTM

- RNN vs LSTM

RNN

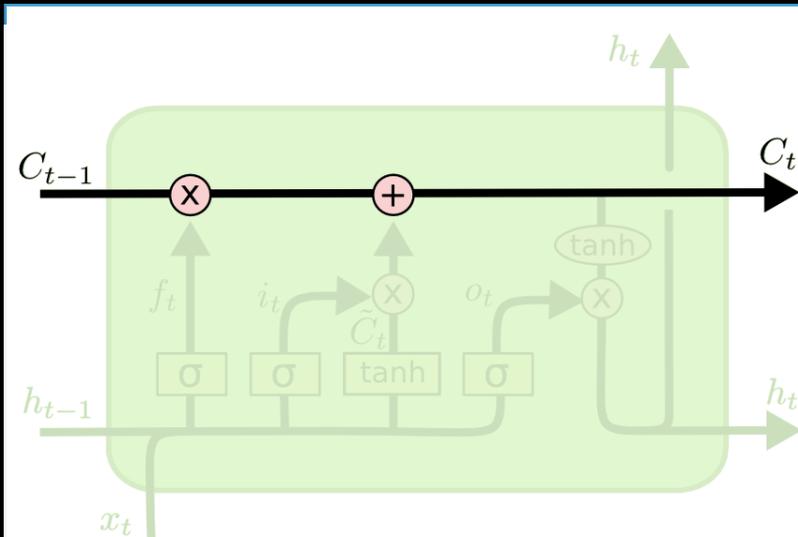


LSTM



Sequence Labeling : LSTM

- Cell state 의 도입



기존의 RNN에 없던 C는
이전 히스토리 중 의미있는 정보들을 갖고 있는 벡터.

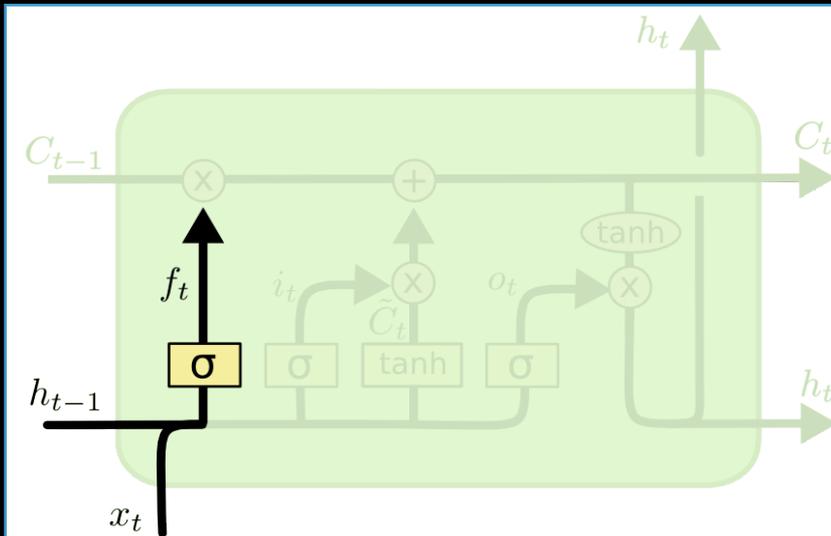
예를 들어 문장을 계속 읽어나가면서 다음 단어를 예측하는 LSTM이라면,
가장 최근에 나타난 주어의 성별정보를 C의 k번째 원소에 저장
(He, She 등을 적절히 생성해내려고)

<http://colah.github.io/posts/2015-08-Understanding-LSTMs/>

- 이전셀상태에 뭔가 곱해지고 더해져서 최종 셀상태가 됨
- 곱해질때는 이전셀상태 각 원소의 유지여부가 결정되고, 더해질 때는 셀 걸러진 이전셀상태에 뭔가 새로운 것(정보)이 추가되는 것
- 출력(h)은 계산된 이번셀상태에 따라 결정됨

Sequence Labeling : LSTM

- Forget gate 를 통한 이전셀상태 억제장치 준비



$$f_t = \sigma (W_f \cdot [h_{t-1}, x_t] + b_f)$$

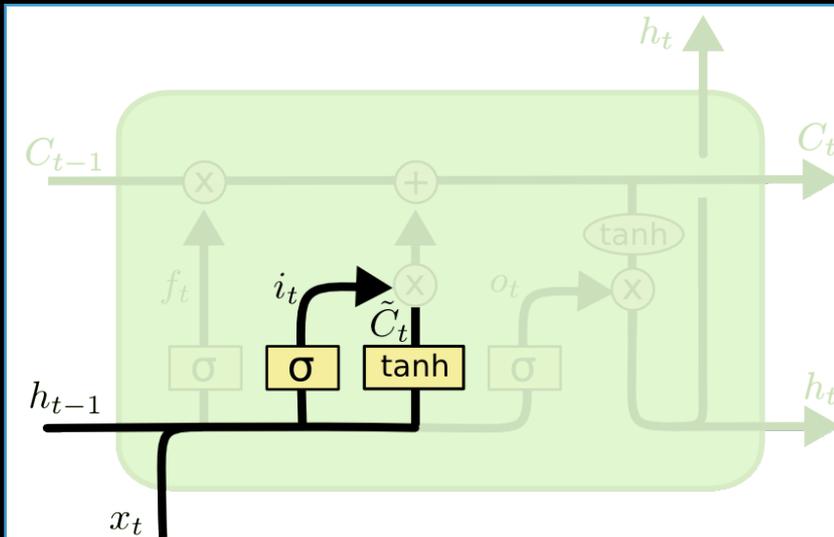
<http://colah.github.io/posts/2015-08-Understanding-LSTMs/>

- 이전출력(h)과 현재입력(x)을 받아 f를 계산해서 이전셀상태에 곱함
- f에 따라 이전 셀상태벡터의 어떤 값은 리셋되고 어떤 값은 살아남음

이전출력+현재입력을 보아 “새로운 주어”라는 판단이 들면 f의 k번째 원소는 0

Sequence Labeling : LSTM

- Input gate 를 통한 이번입력의 반영정도 준비



$$i_t = \sigma (W_i \cdot [h_{t-1}, x_t] + b_i)$$
$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C)$$

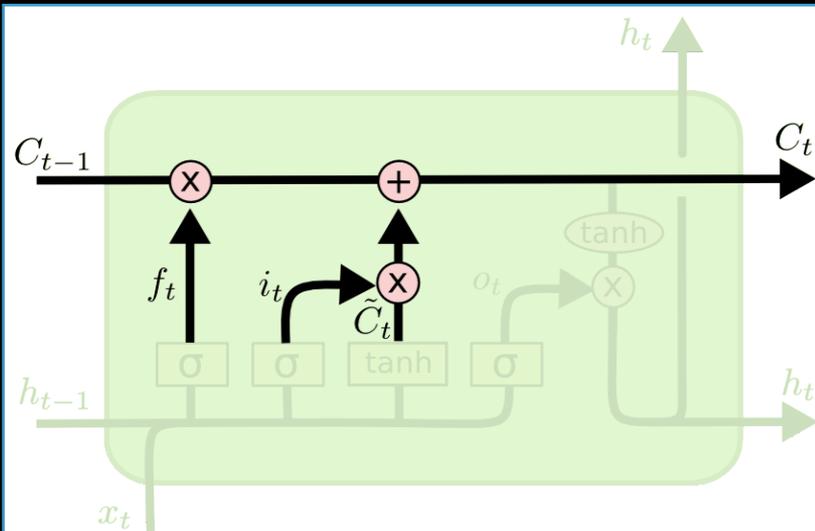
<http://colah.github.io/posts/2015-08-Understanding-LSTMs/>

- 이전출력(h)과 현재입력(x)으로 i 를 계산함
- 이전출력(h)과 현재입력(x)으로 이번입력에 기반한 셀상태를 계산함

이전출력+현재입력을 보아 “새로운 주어”라는 판단이 들면
 i 는 1이고 셀상태의 k 번째 원소는 새로운 성별값

Sequence Labeling : LSTM

- 최종셀상태 G의 계산



$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t$$

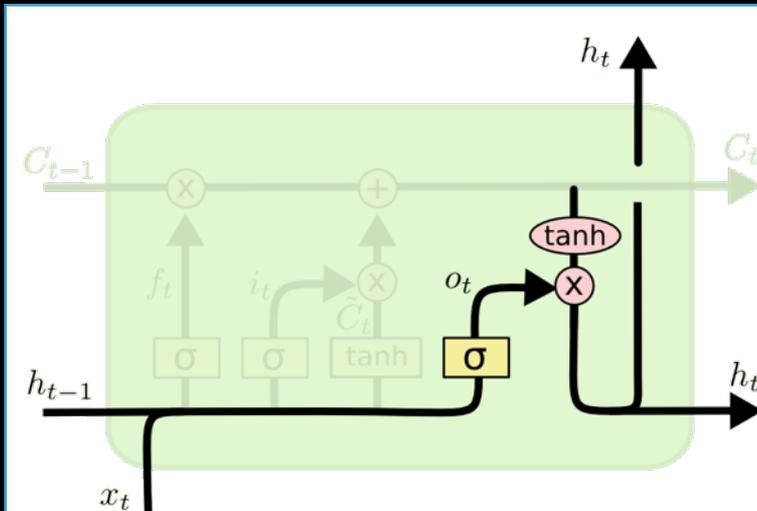
<http://colah.github.io/posts/2015-08-Understanding-LSTMs/>

- f로 이전셀상태의 유지정도를 결정
- i로 단순 셀상태값이 최종 셀상태값에 끼치는 영향력을 결정

앞에서 구한 f와 i 및 셀상태를 사용하여 최종셀상태를 업데이트 (최근에 본 주어의 성별)

Sequence Labeling : LSTM

- 최종출력(h)계산을 위한 셀상태와 output gate 의 활용



$$o_t = \sigma (W_o [h_{t-1}, x_t] + b_o)$$

$$h_t = o_t * \tanh (C_t)$$

<http://colah.github.io/posts/2015-08-Understanding-LSTMs/>

- 최종출력(h)은 최종셀상태(C)의 일부

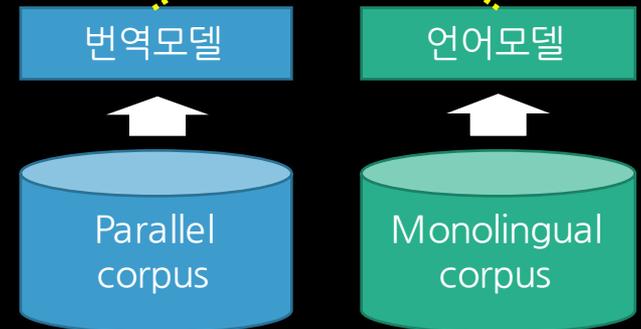
다음 단어가 무엇인지를 예측하기 위해서는,
최종셀상태 정보 중 방금 바뀐 최근 주어의 성별정보는 필요 없고
대신 동사의 단/복수 형 결정을 위해 주어의 “수”정보가 필요하므로
C의 k번째 정보는 내보내지 않는 대신 k+1번째 정보만 내보낼 수 있다.

Text/Query Mining

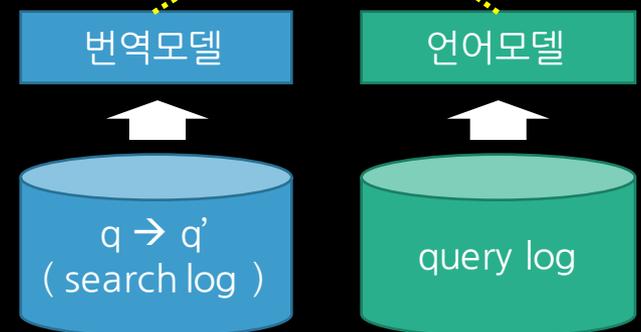
- Query Suggestion & Reformulation



$$e_{best} = \operatorname{argmax}_e P(f|e)P(e)$$



$$q'_{best} = \operatorname{argmax}_{q'} P(q|q')P(q')$$



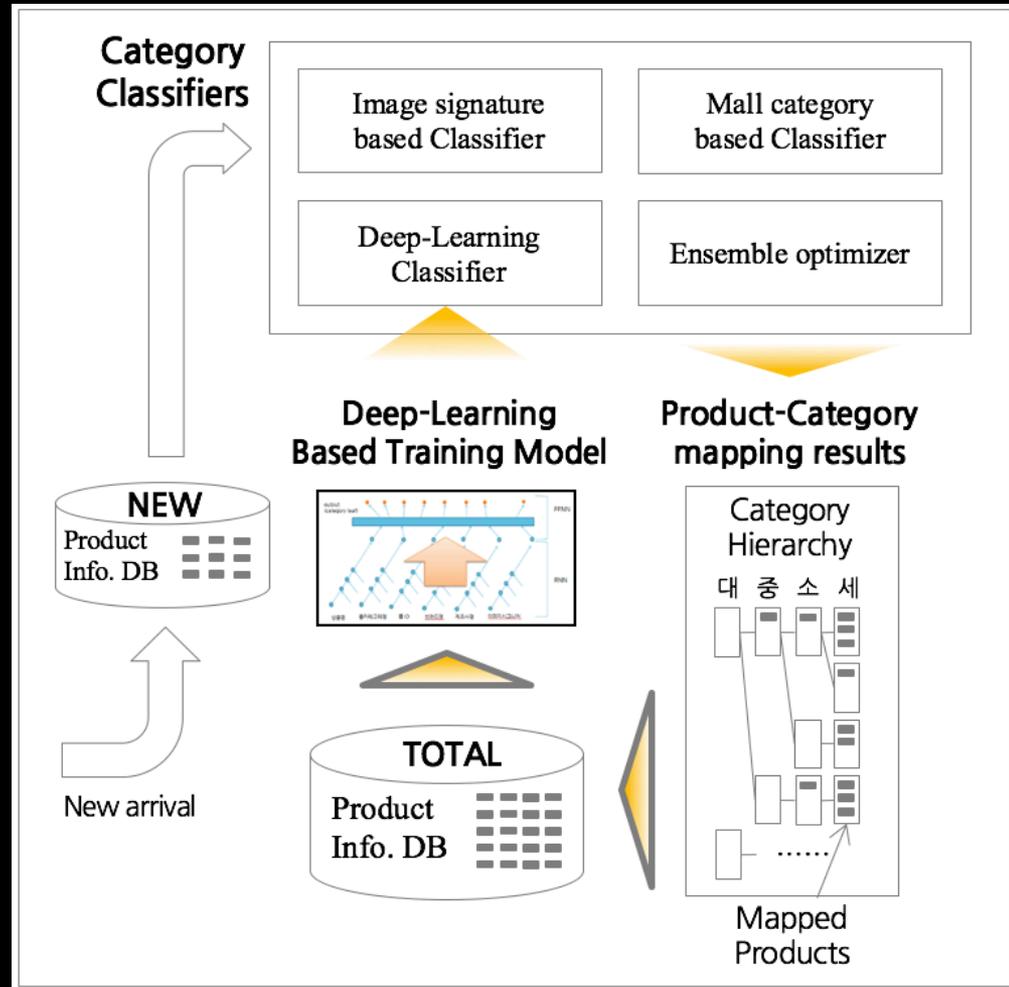
Text/Query Mining

- Product Categorization

4억여개의 상품
4천여개의 카테고리

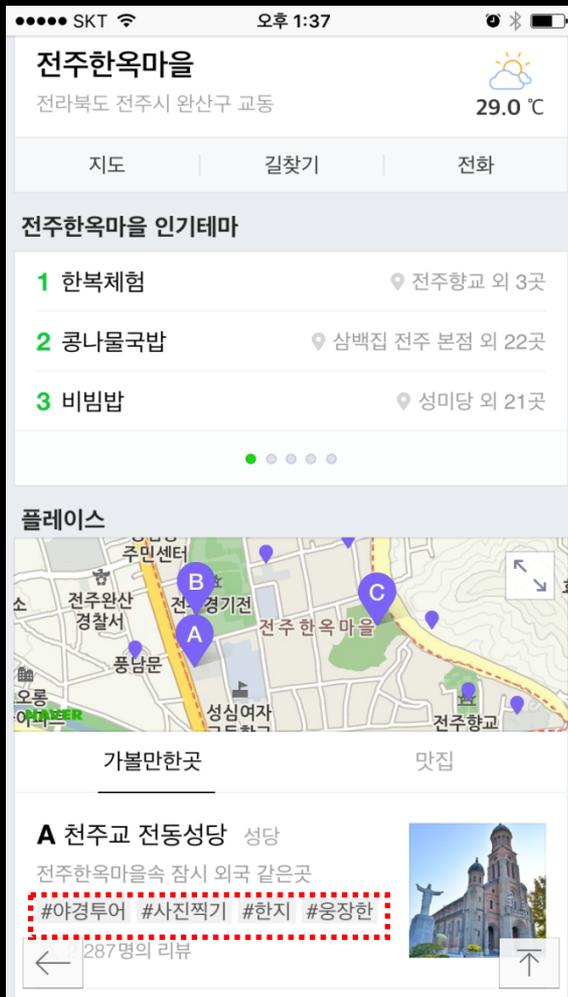
예)
스포츠/레저 > 수영 > 비치웨어 > 커플비치웨어
디지털/가전 > 음향가전 > 홈시어터 > 조합형홈시어터

카테고리 등록정보 신뢰도도 낮고
더 나은 쇼핑서비스를 위해
카테고리를 개편하기도 하고...



Text/Query Mining

- Place Analysis



S1: 아이들과 당일치기로 전주를 다녀왔어요
S2: 아이들 교육에도 최적의 장소
S3: 비오는날 운치있는 전주여행
S4: 운치있고 여유로운 곳이었어요
S5: 야간에 산책하면서 다니는 재미
S6: 날씨 즐기며 천천히 걸어다니는 것도



S1: **아이들과** 당일치기로 전주를 다녀왔어요
S2: **아이들** 교육에도 최적의 장소
S3: 비오는날 **운치있는** 전주여행
S4: **운치있고** 여유로운 곳이었어요
S5: 야간에 **산책**하면서 다니는 재미
S6: 날씨 즐기며 천천히 **걸어다니는** 것도

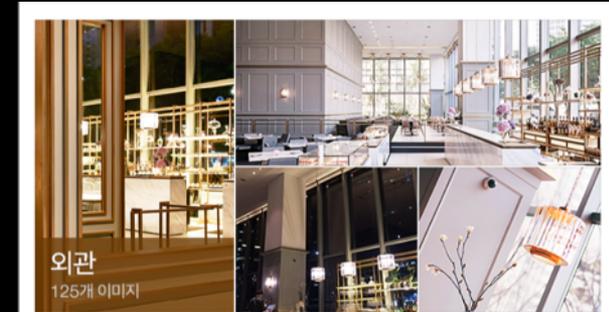
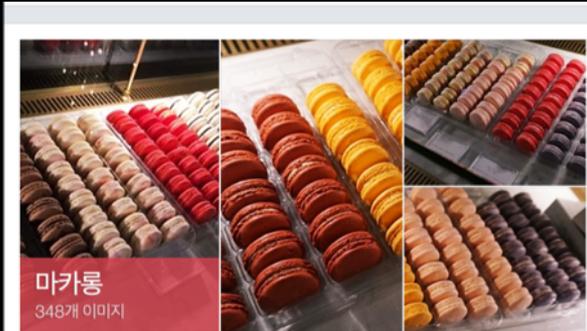
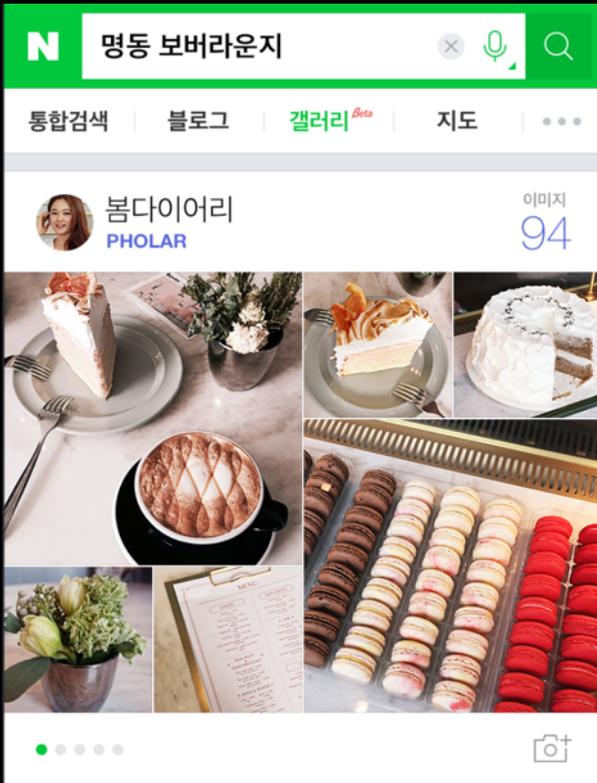
Vision-Text Integration

• 스타 타임라인



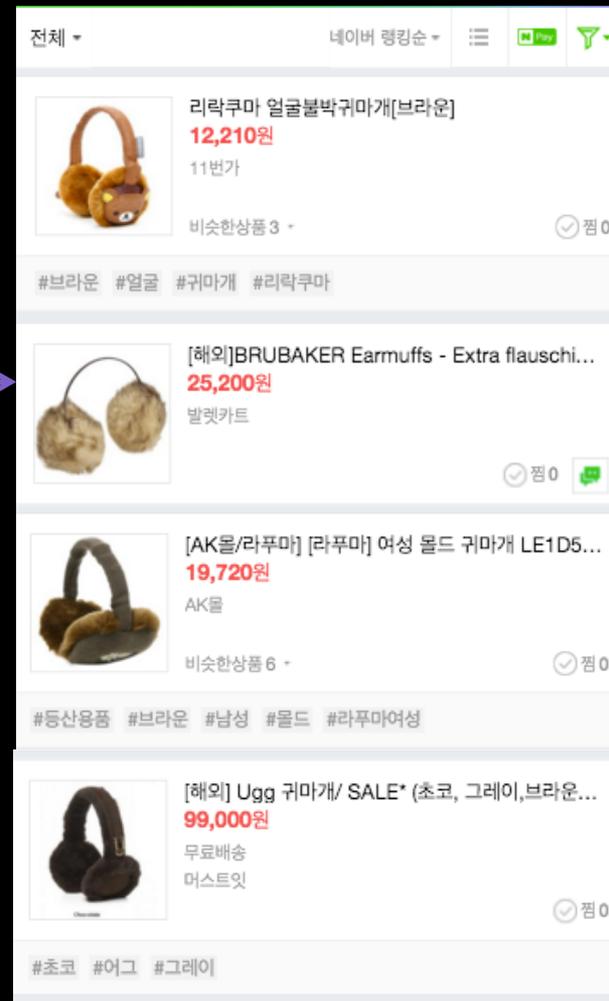
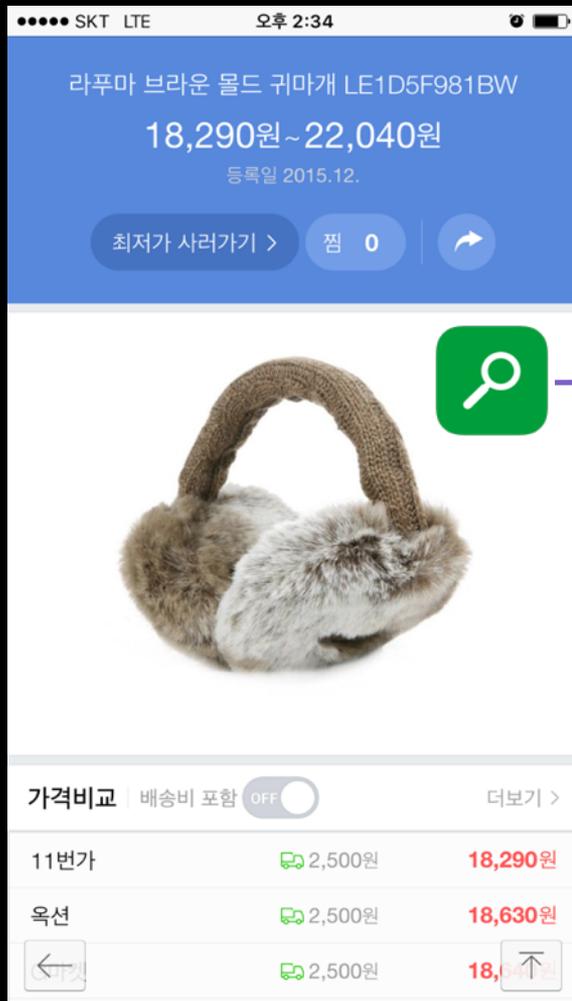
Vision-Text Integration

• 음식점 포토요약



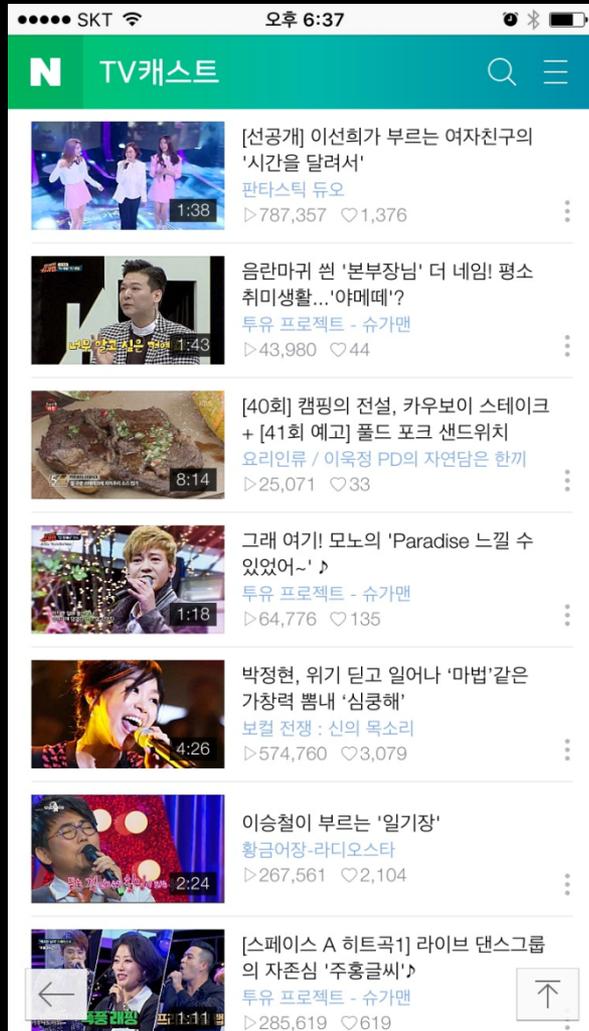
Vision-Text Integration

- 스타일 서치



Recommendation

- 어떻게 하면 네이버에서 더 오래 즐거운 시간을 보내실까?



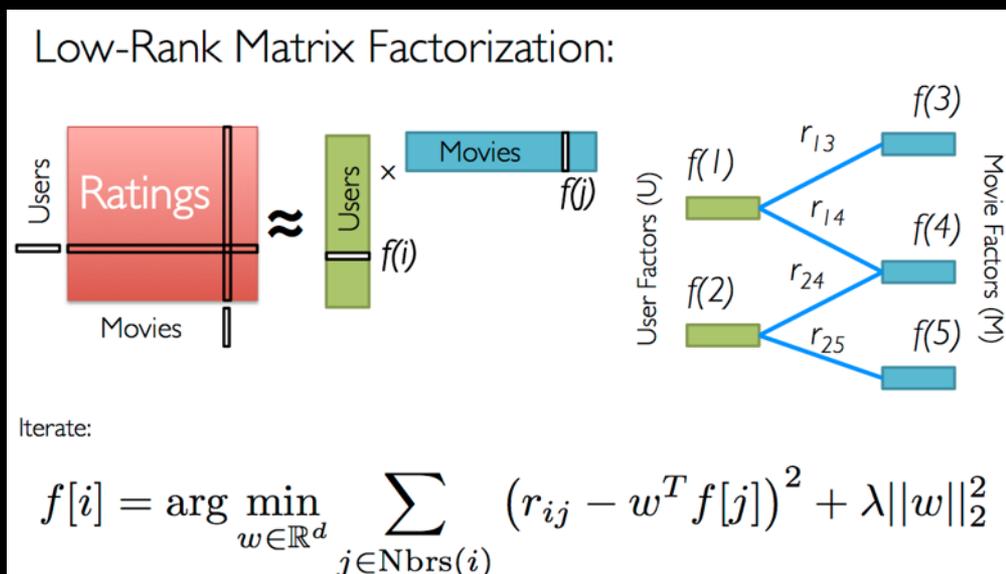
“투유프로젝트-슈가맨”이라는 방송의 클립을 보고 난 사용자에게 어떤 동영상을 추천해주면 좋을까?

“슈가맨같은 동영상”

“의외의 다른 동영상”

Recommendation

- Collaborative Filtering + Diversity



<https://databricks-training.s3.amazonaws.com/movie-recommendation-with-mllib.html>

DIVERSIFY(k): Given query q , a set of documents R_q , a probability distribution of categories for the query $P(c|q)$, the quality values of the documents $V(d|q, c)$, $\forall d \in \mathcal{D}$ and an integer k . Find a set of documents $S \subseteq R_q$ with $|S| = k$ that maximizes

$$P(S|q) = \sum_c P(c|q) \left(1 - \prod_{d \in S} (1 - V(d|q, c)) \right) \quad (5) \quad \rightarrow \text{Novelty factor}$$

감사합니다