

# 고유어와 한자어의 비교 음소배열제약

서울대학교 언어학과 박사과정  
박나영 (arimnet@naver.com)

한국어학회 제 68차 전국학술대회  
2015년 2월 27일(금) 서강대학교

# 고유어 vs. 한자어

▶ 어원의 차이 → 경쟁 관계 → 하위 어휘 목록 형성

- ✓ 음운, 형태, 의미의 차이
- ✓ 공시적인 문법지식으로 실재

▶ 고유어와 한자어의 음운론적 차이

- 한자어: 구성음절의 음소분포 차이 (송기중 1992, 권인한 1997, 신지영 2009, 안소진 2009)
  - 초성: 경음 및 ‘ㄱ’의 제한
  - 중성: 고유어에 비해 이중모음(특히, ‘ㄱ, 나’)이 많이 쓰임
  - 종성: ‘ㄷ, ㅂ, ㅈ’과 경음, 격음, 자음군 제한
- 한자어: 일부 음운 규칙이 적용되지 않는다.
  - /o/ > /u/ (채서영 1999)      고유어: 하루      한자어: 삼촌
  - 모음축약 (이주희 2005)      고유어: 아이~애      한자어: X

# 본 연구의 목적

## ➤ 기존연구

- 한자어 대상
- 구성 음절 구조 또는 개별 음운 규칙 분석

## ➤ 본 연구

고유어와 한자어를 **구별**할 수 있는 음운론적 제약 탐색

1. '비교 음소배열제약' 개념 도입
2. 제약 탐색 및 선정: 통계 & 기계학습 방법
3. 결과: 제약 및 제약의 강도
4. 검토: 개별 단어가 각 어휘 부류에 속할 확률 점검

# 비교 음소배열제약 (comparative phonotactics)

- ▶ 음소배열제약: 음소의 결합을 선호하거나 규제하는 문법 지식
- ▶ 비교 음소배열제약(Hayes, in press)
  - 어휘 부류들 사이의 선호도를 결정하는 제약
    - Y([A] 선호): 음운론적 형태인 Y는 어휘 부류 [A]를 선호한다.
  - Y를 포함한 단어가 '경쟁 어휘 부류 [B]'에 속하는 것을 저지
  - **가중치(weight): 제약의 강도**

# 비교 음소배열제약 적용 (1)

➤ ‘뀡 [k'wΛ□]’에 대한 비교 음소배열제약

- 어두 경음 [k']    한자어 회피    고유어 선호 → 한자어 후보 위배
- 이중 모음 [wΛ]    한자어 선호    고유어 회피 → 고유어 후보 위배

단어	후보	# [k'] (고유어 선호)	[wΛ] (한자어 선호)
		가중치: 10	가중치: 7
뀡 [k'wΛ□]	고유어		1
	한자어	1	

# 비교 음소배열제약 적용 (2)

- ▶ 조화값(Harmony) : 각 후보가 위배하는 제약의 가중치를 더한 벌점
  - 해당 단어가 해당 어휘 부류에 **부적합**한 정도를 나타낸다.

단어	후보	# [k'] (고유어 선호)	[wʌ] (한자어 선호)	조화값
		가중치: 10	가중치: 7	
굉 [k'wʌ□]	고유어		1	7
	한자어	1		10

- ▶ 조화값(부적합도) 비교
  - 고유어인 ‘굉’ 조화값 **7** vs. 한자어인 ‘굉’ 조화값 **10**
  - **고유어에 가까움**

# 개별 단어가 특정 어휘 부류에 속할 확률

▶ 전체 조화값(부적합도)에 대한

특정 어휘 부류 조화값(부적합도)의 비율로 계산

- $e$ ( $\approx 2.718$ )를 밑으로 삼고 조화값을 음의 지수로 취한다.  $\rightarrow e^{-H}$

확률(어휘 부류 A) =

$$\frac{\exp(-\text{후보 } A \text{의 조화값})}{\exp(-\text{후보 } A \text{의 조화값}) + \exp(-\text{후보 } B \text{의 조화값})}$$

- '핑'이 고유어일 확률 =  $\frac{\exp(-7)}{\exp(-7) + \exp(-10)} = 0.952$

# 고유어와 한자어의 비교 음소배열제약

단어	후보 <sup>1</sup>	# [k'] (고유어 선호)	[wΛ] (한자어 선호)	3 조화값	예측 확률
	2	가중치: 10	가중치: 7		
굉 [k'wΛ□]	고유어		1	7	0.952
	한자어		1	10	0.048

## 1. 어휘 부류를 선호하는 제약

- 1단계: 각 어휘 목록에서 회피되는 제약 탐색
- 2단계: 두 어휘 부류를 구별하는 제약 선정

## 2. 가중치 학습

- 각 제약이 개별 단어의 실제(입력) 어휘 부류를 최대한 예측할 수 있도록 가중치를 배운다

## 3. 개별 단어의 어휘 부류를 예측

- 새로운 단어의 어휘 부류를 예측할 수 있다.

# 어휘 목록

- ✦ 어휘 목록=고유어(5,542 단어) + 한자어(29,869 단어)
  - 빈도 5 이상인 일반명사(강범모·김흥규 2009); 단일어와 복합어 포함
  - 표준국어대사전 (<http://www.korean.go.kr>) 참조
    - 고유어와 한자어의 판별 기준: 한자음과 1:1 대응 여부
    - 표준국어대사전 발음형 기준
- ✓ 추후 형태론적 정보
  - 불규칙적인 발음형
  - 수의적인 발음형 등이 추가적으로 고려되어야 한다.
- 어말 자음은 모음으로 시작하는 조사와 결합할 때, 실현될 수 있는 바, 음운론적으로 가정되는 기저형을 입력형으로 채택하였다.

# 제약 탐색

- 고유어와 한자어 각각에서 회피되는 연쇄를 자동적으로 학습 (박나영 2014)
    - 기계학습 방법: 최대 엔트로피 음소배열제약(Hayes and Wilson 2008)
      - 표면형으로부터 음소 연쇄의 출현 확률을 계산
      - 유의미하게 빈도가 낮은 음소 연쇄를 제약으로 포착
      - 자질 결합을 회피하는 유효성 제약  
예: \*#[+긴장음], \*[+성절][+성절]
    - 소프트웨어: UCLA 음소배열학습자(UCLA phonotactic learner)
      - 입력형: 어휘 목록 + 자질 목록 → 출력형: 제약 + 가중치
      - 각각 100개씩 학습 → 5회 반복 학습 중 3회 이상 학습된 제약
  - 결과: 156 제약
- 한자어 회피 제약 91개 + 고유어 회피 제약 82개 - 공통제약 17개



# 제약의 가중치 학습

- 선호하는 어휘 부류를 제약에 명시  
 한자어에서 회피(학습) → 고유어 선호 제약  
 고유어에서 회피(학습) → 한자어 선호 제약
- ✓ 제약을 위반하지 않는 단어가 없도록,  
 한자어 **기본** 선호 제약, 고유어 **기본** 선호 제약을 더하였다.
- MaxEnt Tool(소프트웨어) 이용: 각 제약에 가중치 할당

단어	후보	입력 부류	# [k'] (고유어 선호)	[w <sub>Λ</sub> ] (한자어 선호)
			가중치	가중치
뀡[k'w <sub>Λ</sub> □]	고유어	1		1
	한자어	0	1	

- ‘뀡’과 같은 단어가 고유어로서 제약을 위반하는 빈도 → 가중치 반영  
 한자어로서 제약을 위반하는 빈도

# 결과

- 고유어 선호 제약 (42개) > 한자어 선호 제약 (23개)
  - 대체로 고유어 선호 제약이 두 어휘 부류 판별에 기여
- 본 모델은 기본적으로 한자어를 선호한다.
  - 한자어 기본 선호 제약: 1.936
  - 고유어 기본 선호 제약: 0
  - 입력단어의 구성 비율: 한자어 어휘 목록 > 고유어 어휘 목록  
← 기본 선호 정도는 입력단어의 구성 비율에 따라 달라진다.
- 한국어 화자가 새로운 단어의 어휘 부류를 응답
  - 새로운 단어가 아무런 음소배열제약을 위배하지 않을 때  
- 응답 확률: 한자어 부류 > 고유어 부류
  - 새로운 단어가 음소배열제약으로 포착될 때,  
-한자어에서 회피되는 연쇄 多 고유어에서 회피되는 연쇄 少

# 고유어 선호 제약 (1)

- 기존연구: 초성, 중성, 종성 → 어두, 어중, 어말 제약
  - 한자어에서 회피되는 연쇄를 단어 내 위치를 포함하여 포착

어중, 어말: 고유어 선호 제약 (해석)	가중치	고유어 예
가. [t][자음]	7.240	깃털 [kit <sup>h</sup> ʌ]
나. [t <sup>h</sup> , s, c]#	5.943	옷 [os]
다. [t <sup>h</sup> , c <sup>h</sup> , p <sup>h</sup> , k <sup>h</sup> ] #	5.764	앞 [ap <sup>h</sup> ]
라. [□m]#	4.877	뱀 [p□m]
마. [up, op]#	4.714	굽 [kup]
바. [자음][자음]#	4.654	흙 [h□lk]

어두: 고유어 선호 제약 (해석)	가중치	고유어 예
사. #[n, m][ʌ]	5.858	너머 [nʌmʌ]
아. #[k', p', s', t']	5.068	또래 [t'이□]

# 고유어 선호 제약 (2)

## ➤ [자음] + [e, ʌ]

- ‘세, 제, 체’를 제외한 [자음]+[e] 연쇄 선호; [격음]+[ʌ]; ‘터, 테’에 대한 선호

고유어 선호 제약 (해석)	가중치	고유어 예
가. [자음][n, m, l][e, ʌ]	5.467	들머리 [t□lmaʌi]
나. [p, p', t, t', tʰ, k, k'][e]	4.540	떼 [t'e]
다. [tʰ][e]	3.503	테두리 [tʰetuli]
라. [kʰ, pʰ, tʰ][ʌ]	2.824	터[tʰʌ]

## ➤ [자음] , [모음] 연쇄 제약 – 음소 결합을 포착

- ‘ㄹ’에 이어지는 설정 경음화 → 음소배열제약<마>

고유어 선호 제약 (해석)	가중치	고유어 예
마. [l, p, t, k][t, s, c]	5.697	길잡이 [kilcapi]
바. [m, □][kʰ]	4.677	넙쿨 [nʌ□kʰul]
사. [i, e, ʌ][i]#	3.249	어이 [ʌi]
자. [i, ʌ][후설모음]	3.093	거울 [ʌul]

# 고유어 선호 제약 (3)

## ➤ [자음]+[모음]+[자음] 제약

고유어 선호 제약 (해석)	가중치	고유어 예
가. [t, t', tʰ][i, i, e, ʌ][m, n, l]	4.812	무덤 [mutʌm]
나. [p, p', pʰ][i, ʌ][k, □]	3.998	범벅 [pʌmpʌk]
다. [tʰ, kʰ][u][n, □]	3.851	귀통이 [kwitʰu□i]
라. [t, t', tʰ][ɨ][l]	3.410	들 [t□l]

- 세부적인 환경을 명세하여 한자어에 잘 나타나지 않는 음절을 포착
    - 털, 덤, 덥, 톨, 듭 [가]
    - 벅, 병 [나]
    - 통 [다]
- 들, 뜰, 툐 [가, 라]

# 한자어 선호 제약 (1)

- ▶ 어말 제약: [ɛk]# (가장 높은 가중치 제약)

한자어 선호 제약 (해석)	가중치	한자어 예
가. [ɛk]#	4.255	여객 [jʌk □ k]
나. [p, p <sup>h</sup> , k, k <sup>h</sup> ][ʌ, a]#	1.771	검거 [kʌm kʌ]
다. [p', t', k'] [u, ʌ, o]#	1.155	각도 [kakt'o]

- ▶ 자음과 모음의 결합 제약

cf. 기존연구: 한자어 고빈도 음절 정보만으로 다 포착하기 어려움

한자어 선호 제약 (해석)	가중치	한자어 예
마. [c <sup>h</sup> i]	3.395	측정 [c <sup>h</sup> □ kc'ʌ □]
바. [c'i]	2.520	녹즙 [nokc' □ p]
사. [c <sup>h</sup> ][e]	2.281	체육 [c <sup>h</sup> ejuk]
아. [s', c'][e]	2.181	법제 [pʌp c'e]
자. [k <sup>h</sup> , h][u]	2.169	후각 [hukak]

# 한자어 선호 제약 (2)

- ▶ [자음]과 [활음]의 결합 제약

한자어 선호 제약 (해석)	가중치	한자어 예
가. [□] [w, ɰ, j]	4.095	강연 [ka□jʌn]
나. [p, k] [ju]	3.195	규정 [kjuɕʌ□]
다. [hj]	3.114	휴가 [hjuka]
라. [t, s, c] [wʌ, wa]	2.960	좌석 [cwasʌk]
마. [p, m, k, h, □] [ɰ]	2.505	심의 [simɰi]

- ▶ 이중모음 제약: j계 이중 모음인 경우(사, 아, 자), 선·후행 모음에 상관없이 한자어에서 더 선호될 수 있다.

한자어 선호 제약 (해석)	가중치	한자어 예
바. [wʌ]	3.243	월급 [wʌlk□p]
사. [ɛ, a][j, ɰ]	2.742	가열 [kajʌ]
아. [u][j, ɰ, w]	2.200	수요 [sujo]
자. [i, u, e, ʌ, o][j, ɰ, i, a]	1.153	제약 [ejak]

# 한자어 선호 제약 (3)

➤ 그 밖의 제약

한자어 선호 제약 (해석)	가중치	한자어 예
가. [a][ε, ʌ, o, a], [ʌε]	2.591	가액
나. #[i]	2.443	응답
다. [p, t, k][p <sup>h</sup> , t <sup>h</sup> , k <sup>h</sup> ]	0.999	목표

# 결과 정리

## ➤ 고유어 선호 제약(한자어 회피 연쇄)

- 기존연구 확인: 한자어 초성, 종성 제한 → 어두, 어말 제약으로 포착
- 구성 음절에 대한 양적 분석과 대응
  - 기존연구: 한자어에서 회피되는 결합(양적연구)
  - 본 연구: 고유어 선호 제약
    - '세, 제, 체'를 제외한 [자음]+[e, ʌ]연쇄 선호,
    - [모음] 연쇄 선호
  - 세부적인 환경을 명세하여, 한자어에 잘 나타나지 않은 음절을 포착

## ➤ 한자어 선호 제약(고유어 회피 연쇄)

- 가장 변별적인 제약: [ɛk]#
- 이중 모음에 대한 제약
- [자음]과 [모음]의 결합: [츠, 즈, 세, 제, 체 후]

# 장점

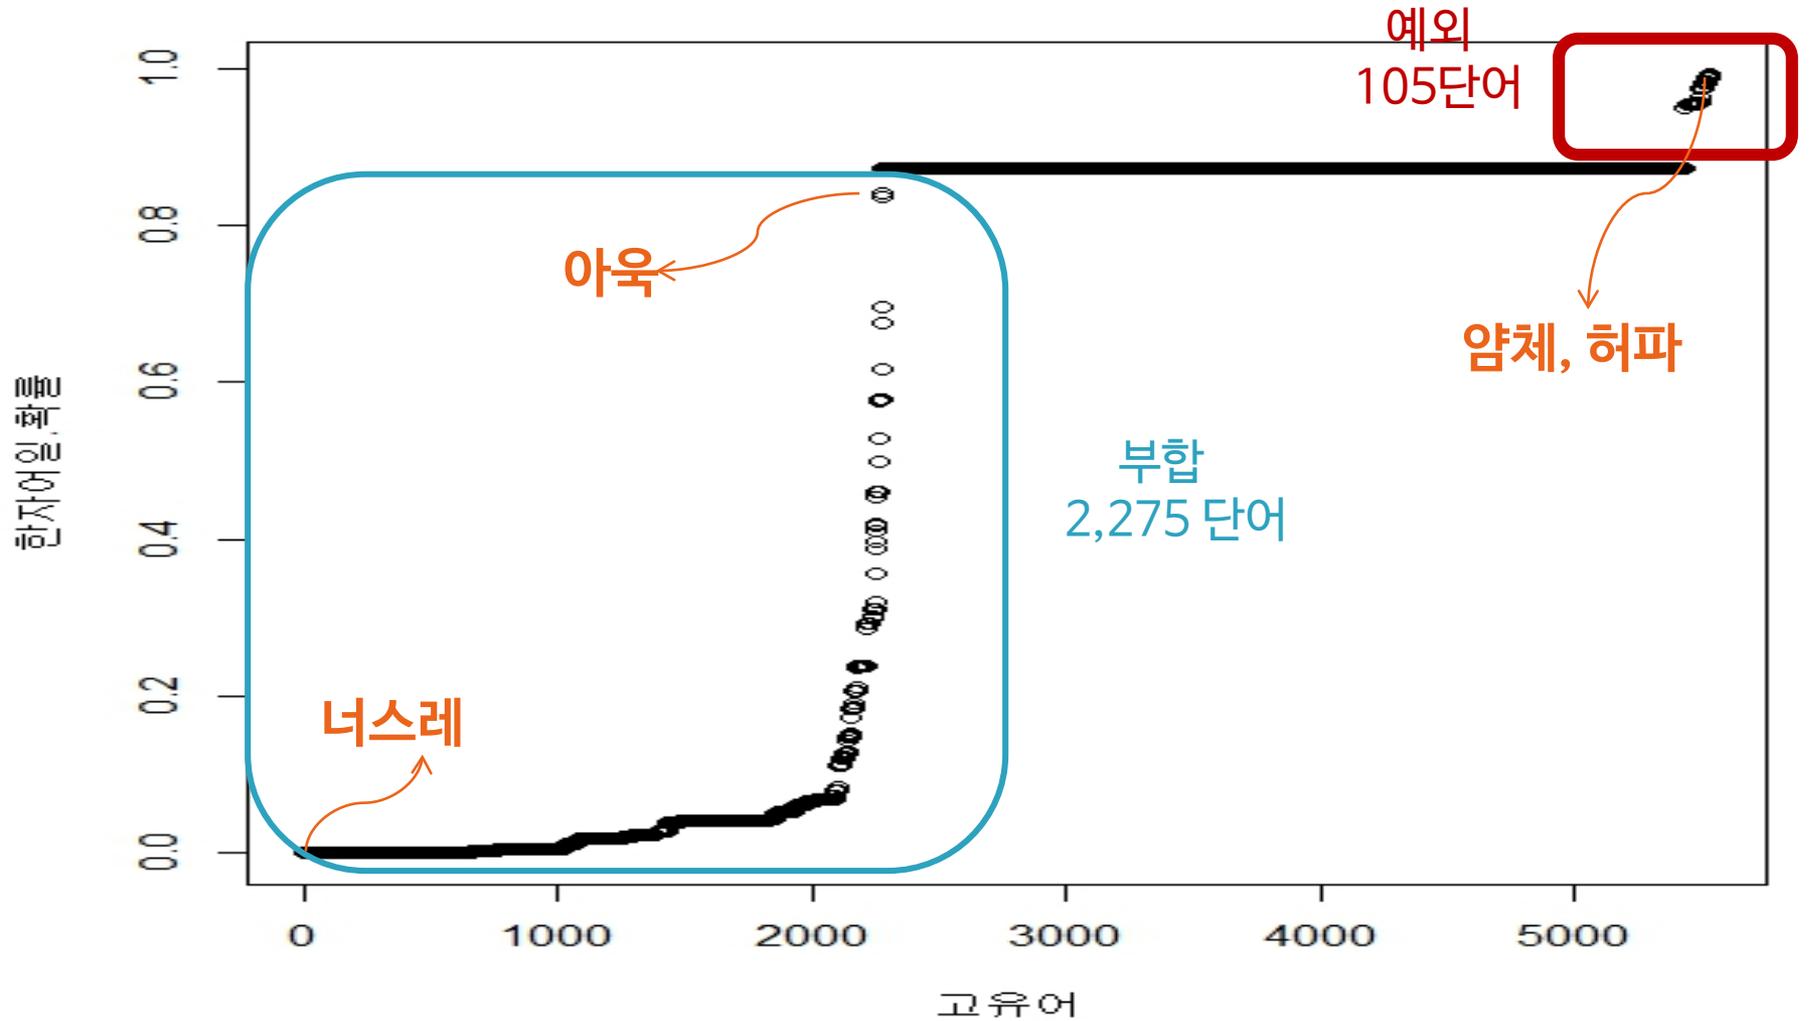
1. 낮은 빈도로 출현하는 연쇄를 제약으로 포착      예: 게 [憩, 揭]

2. 한 단어에 두 어휘 부류의 속성이 혼재하는 경우에도  
그 단어의 어휘부류를 예측할 수 있다.

■ ‘휴게’      입력형: 한자어      출력형: 고유어에 다소 가까움

단어	후보	[ke] (고유어 선호)	[hj] (한자어 선호)	조화값
		4.54	3.114	
휴게[hjuke]	고유어		1	3.114
	한자어	1		<b>4.54</b>

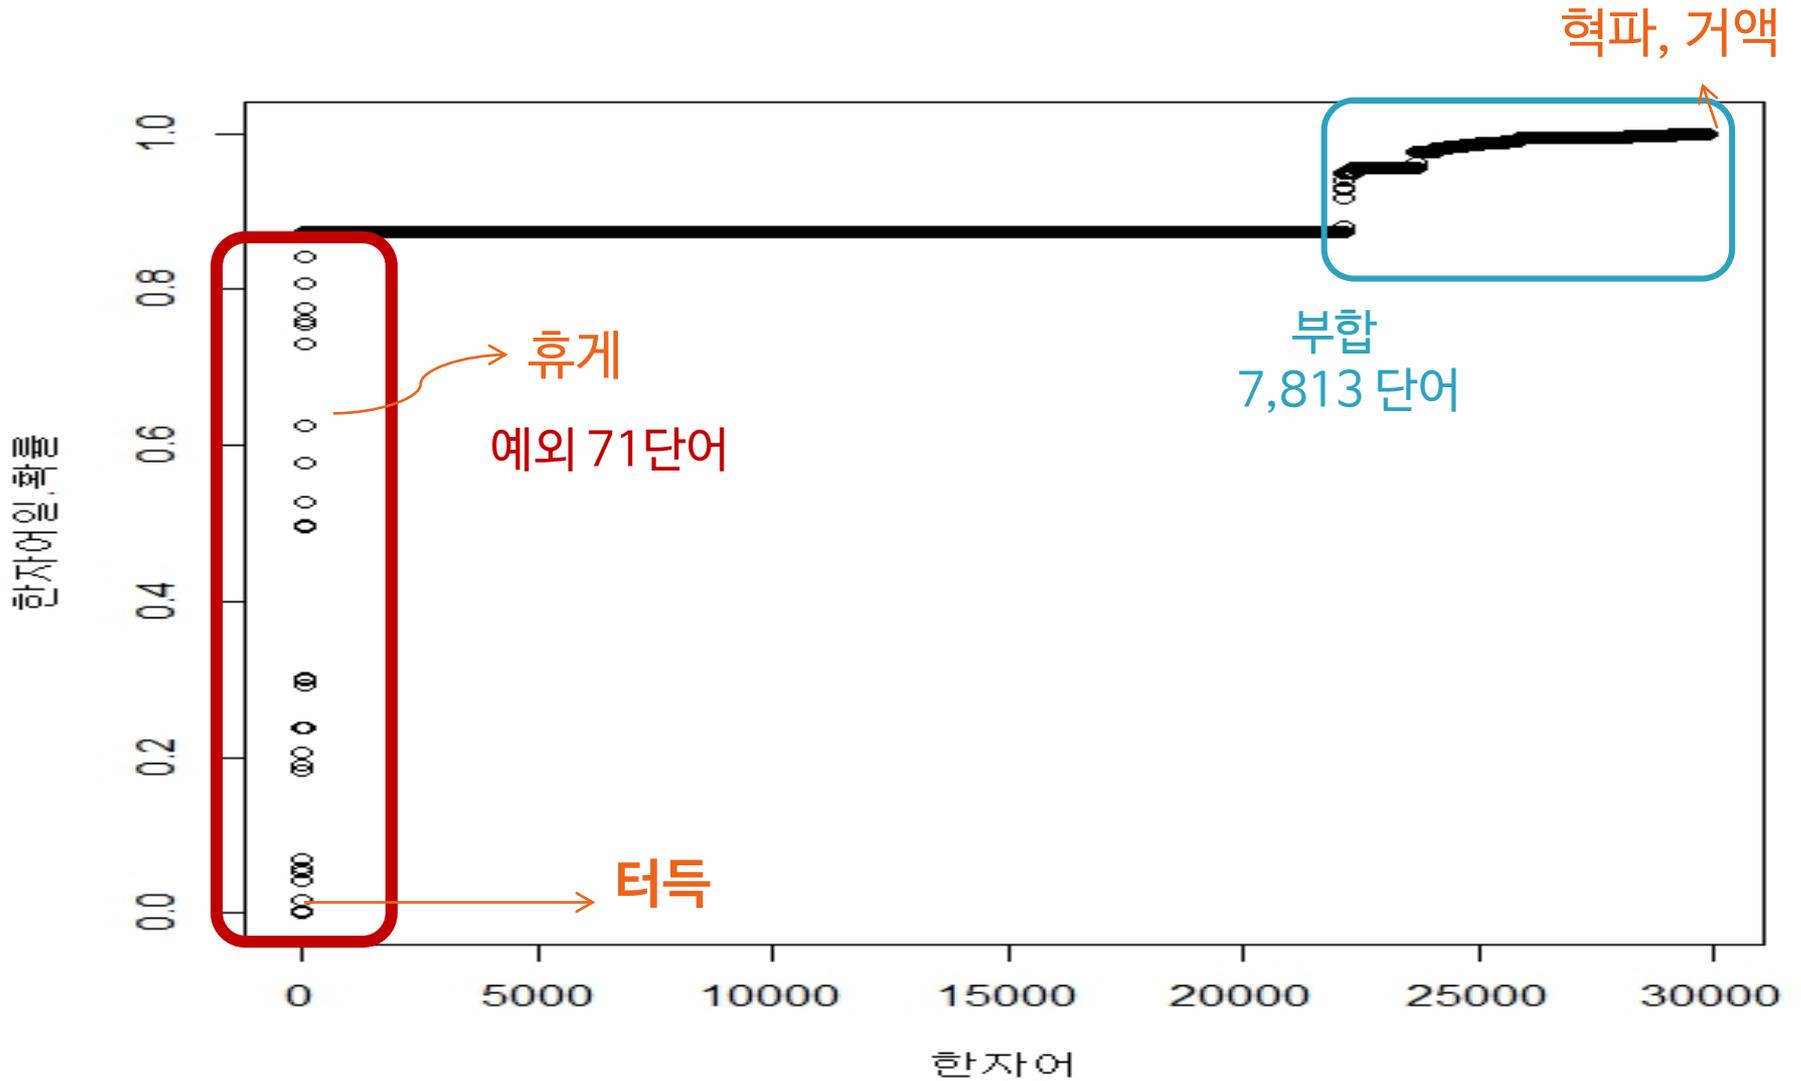
# 개별 단어에 대한 예측 확률 -고유어-



# 개별 단어에 대한 예측 확률 -고유어-

- ▶ 한자어 기본 선호 제약 1.936
  - 음소배열제약을 위배하지 않는 단어 (고유어: 3155 단어, 한자어: 22045 단어)  
한자어일 확률: **0.874** 기준
  
- ▶ 한자어일 확률: 고유어
  - 한자어일 확률이 기준(0.874)보다 낮은 고유어
    - $P < 0.2$  (2168 단어)  
**너스레** (0), 고삐 (0.023), 뱀 (0.05), 또아리 (0.121), 키다리 (0.173)
    - $P \geq 0.2$  (107 단어)  
겨울 (0.239), 오빠 (0.3), 이엉 (0.578), 애꾸 (0.576), **아욱** (0.618)
  
  - 한자어일 확률이 **기준(0.874)보다 높은** 고유어 (105 단어)  
**흉내** (0.994), 응석 (0.988), **얇체** (0.985), **허파** (0.976), 비아냥 (0.956)

# 개별 단어에 대한 예측 확률 -한자어-



➤ 한자어일 확률: 한자어

- 한자어일 확률이 기준(0.874)보다 높은 한자어 (7741단어)

- **혁파**(1), 좌석(0.993), 억제(0.984), 소아(0.956), 여왕(0.881)

- 한자어일 확률이 **기준(0.874)보다 낮은** 고유어 (71단어)

- **터득**(0.03), 쌍(0.042), 틈입(0.053), 별게(0.069), 잡음(0.207), 합헌(0.292), 우울(0.301), 이양(0.578), **휴게**(0.625), 파업(0.776)

✚ 실제 화자를 대상으로 그 인식을 점검할 필요가 있다.

✚ 보다 많은 단어들을 포착하기 위해

고빈도 음절, 형태론적 제약 등을 포함할 필요 있음

# 남은 문제

➤ 한자어 에서 회피되는 제약(고유어 선호 제약)

- 공명음에 이어지는 경음 제약

예: [-자음] [-지속, +긴장] [-후설, +성절]  
[모음][p', t', k', c'] [i, e, ε]

가중치: 5.702

해당 고유어: 새끼

- 하나의 운율 단위로 정의되지 않는 [자음] + [모음] + [모음],  
[모음] + [모음] + [자음] 제약

예: [+공명, -양순] [+고설, +후설, +성절] [-원순, +성절]  
[n][ɪ, u][i, ɪ, e, ʌ, ε, a]

가중치: 5.030

해당 고유어 '누이'

- ✓ 실재하는 제약인가?

➤ 개별 단어의 사용빈도(token frequency) 고려

➤ 한자어는 고유어와 다른 형태론적 구조와 입력형을 가정해야 하는가?

➤ 단일어 vs. 복합어: 음소배열제약? 형태론적 제약?

## 참고문헌

- 강범모·김흥규. 2009. 「한국어 사용 빈도」 한국문화사.
- 강용순. 1998. “한국어 어휘부 구조.” 「음성·음운·형태론연구」(한국음운론학회) 4, 55-67.
- 권인한. 1997. “현대국어 한자어의 음운론적 고찰.” 「국어학」(국어학회) 29, 243-260.
- 김창섭. 2001. “한자어 형성과 고유어 문법의 제약.” 「국어학」(국어학회) 37, 177-195.
- 김한샘. 2005. 「2005년 신어」 국립국어원.
- 박나영. 2014. “한국어 명사의 음소배열제약에 대한 기계학습.” 「음성·음운·형태론연구」(한국음운론학회), 20(3), 297-322.
- 박선우·홍성훈·변군혁. 2013. “한국어의 어휘계층과 음운론적 복잡성.” 「음성·음운·형태론연구」(한국음운론학회) 19(2), 225-274.
- 송기중. 1992. “현대국어 한자어의 구조.” 「한국어문」(한국정신문화연구원) 1, 1-85.
- 신지영. 2009. “한국 한자음의 빈도 관련 정보 및 음절 구조 제약.” 「말소리와 음성과학」(한국음성학회) 1(2), 129-140.
- 안소진. 2009. “한자어 구성 음절의 특징에 대하여.” 「형태론」(형태론학회) 11(1), 43-59.
- 안소진. 2011. 「심리어휘부에 기반한 한자어 연구」 서울대학교 국어국문학과 박사학위논문.
- 안소진. 2014. “한자어 형태론의 제 문제와 어휘부.” 「한국어학」(한국어학회), 62, 373-394.
- 이운영. 2002. 「표준국어대사전 연구분석」 국립국어연구원.
- 이주희. 2005. “최적성 이론과 음운론적 어휘부 연구.” 「돈암어문학」(돈암어문학회), 383-413.

# 참고문헌

- Capodieci, Frank, Bruce Hayes and Colin Wilson. 2008. UCLA Phonotactic learner. <http://www.linguistics.ucla.edu/people/hayes/Phonotactics/>
- Chomsky, Noam and Morris Halle. 1965. Some controversial questions in phonological theory. *Journal of Linguistics* 1, 97-138.
- Frisch, Stefan, Janet Pierrehumbert and Michael Broe. 2004. Similarity avoidance and the OCP. *Natural Language and Linguistic Theory* 22(1), 179-228.
- Friedman, Jerome, Trevor Hastie, Noah Simon, Rob Tibshirani. 2014. glmnet: Lasso and elastic-net regularized generalized linear models. R package version 1.9-8. <http://cran.r-project.org/web/packages/glmnet/>.
- Gelman, Andrew, Yu-Sung Su, Masanao Yajima, Jennifer Hill, Maria Grazia Pittau, Jouni Kerman, Tian Zheng, Vicent Dorie. arm: Data Analysis Using Regression and Multilevel/Hierarchical Models. R package version 1.7-07. <http://cran.r-project.org/web/packages/arm/>
- Goldwater, Sharon and Mark Johnson. 2003. Learning OT constraint rankings using a Maximum Entropy Model. Proceedings of the Workshop on Variation within Optimality Theory, Stockholm University, 2003.
- Hayes, Bruce. in press. [Comparative phonotactics](#). Proceedings of the 50th meeting of the Chicago Linguistic Society. April 10, 2014. [http://www.linguistics.ucla.edu/people/hayes/Papers/HayesComparativePhonotacticsCLS50\\_2014.pdf](http://www.linguistics.ucla.edu/people/hayes/Papers/HayesComparativePhonotacticsCLS50_2014.pdf)
- Hayes, Bruce and Colin Wilson. 2008. A Maximum Entropy Model of phonotactics and phonotactic learning. *Linguistic Inquiry* 39(3), 379-440.
- Hayes, Bruce, Colin Wilson, Ben George. 2009. MaxEnt Grammar Tool. <http://www.linguistics.ucla.edu/people/hayes/MaxentGrammarTool>.
- Hayes, Bruce and Kie Zuraw. 2013. Class 10 More on Ratings vs. Probability, Lecture handouts. Linguistic 251 Variation in Phonology. UCLA. [http://www.linguistics.ucla.edu/people/zuraw/251\\_2013/AllLecturesLing251HayesZuraw.zip](http://www.linguistics.ucla.edu/people/zuraw/251_2013/AllLecturesLing251HayesZuraw.zip)
- Itô, Junko and Armin Mester. 1995. The core-periphery structure of the lexicon and constraints on reranking. In Jill N. Beckman, Laura Walsh-icky and Suzanne Urbanczyk (eds.). University of Massachusetts Occasional Papers in Linguistics 18, Papers in Optimality Theory, 181-209. Amherst, MA: GLSA.
- R Core Team. 2014. R: A language and environment for statistical computing. Version 3.1.1. R Foundation for Statistical Computing, Vienna, Austria. [www.R-project.org](http://www.R-project.org).
- Zheng, Vicent Dorie. arm: Data Analysis Using Regression and Multilevel/Hierarchical Models. R package version 1.7-07.

감사합니다.