

한국어 형태소 분석

컴퓨터정보학부 심광섭

1. 형태론

◆ 형태소(Morpheme)

- 더 이상 분해될 수 없는 최소의 뜻 단위
분해하면 의미를 잃어버림.
- 이형태: 하나의 형태소가 환경에 따라 모습을 달리할 때 그것들을 그 형태소의 이형태라 함.
(예) 이/가 : 음운론적 환경으로 제약된 이형태
(예) 었/았/였 : 형태론적 환경으로 제약된 이형태

2001-7-25

1. 형태론

◆ 형태 자소론

- 두 형태소의 경계에서 발생하는 철자의 변형

(예) get+s = gets, go+s = goes, try+s = tries

(예) 막(block)+은 = 막은, 갈(grind)+은 = 간,
가(go)+은 = 간

◆ 형태 통사론

- 어떤 형태소 배열이 올바른 어절을 형성하는가?

(예) fragment-al, *employment-al

(예) 동작(action)+ 하+다, *정보(information)+하+다

2001-7-25

2. 형태소 분석

◆ 형태소 분석

- 표층 어절을 어휘층 형태소로 분해하는 작업

(예) “나는” →

나/대명사 + 는/조사

나/동사 + 는/어미

날/동사 + 는/어미

◆ 형태소 생성

- 어휘층 형태소들로부터 표층 어절을 생성하는 작업

(예) 분석/명사 + 하/동사화접미사 + 어/어미

→ “분석하여” / “분석해”

2001-7-25

2. 형태소 분석

◆ 형태소 분석의 요소

- 사전

- ◆ 표제어(형태소) + 형태소 정보(품사, 자질)

- 문법

- ◆ 형태 자소 규칙: 음운 현상을 표현
- ◆ 형태 통사 규칙: 형태소 결합의 합법성을 표현

- 분석 알고리즘

- ◆ 전처리: 한글 코드 변환, 한글 및 기호 분리
- ◆ 형태 자소 규칙 적용: 형태 분리, 원형 복원
- ◆ 사전 탐색: 형태소 정보 부여, 미등록 형태소 추정
- ◆ 어절의 형태소 분석 후보 생성: 형태소 정보 결합
- ◆ 형태 통사 규칙 적용: 비문법적인 형태소 결합 제거

2001-7-25

5



2. 형태소 분석

◆ 한국어 형태소 분석 과정

- 한글 코드 변환

- ◆ 형태소 변형을 처리하는 데는 조합형 한글 코드가 편리
- ◆ 완성형, 조합형의 상호 변환

- 한글 및 기호 분리

- ◆ 한글 문자열과 기타 문자열(영문자, 숫자, 기호 등)을 분리
(예) 클린턴(clinton)은 = 클린턴(+clinton+)+은

- 형태 분리

- ◆ 한글 문자열을 단순 분리
(예) 나는 = 나+는, 나+느+ㄴ, 나느+ㄴ

2001-7-25

6



2. 형태소 분석

◆ 한국어 형태소 분석 과정 (계속)

- 원형 복원 (형태자소규칙 적용)

(예) 나+는 → 나+는, 날+는
나+느+ㄴ → 나+느+ㄴ
나느+ㄴ → 나느+ㄴ

- 형태소 정보 부여 및 미등록 형태소 추정

나/동사|대명사
날/동사명사
느/비형태소
늘/동사|부사

나늘/비형태소
나느/비형태소
는/조사|어미
ㄴ/조사어미

2001-7-25

2. 형태소 분석

◆ 한국어 형태소 분석 과정 (계속)

- 형태소 분석 후보 생성

◆ 각 형태소 정보를 결합하여 분석 후보 생성

나/동사 + 는/조사	나/동사 + 는/어미
나/대명사 + 는/조사	나/대명사 + 는/어미
날/동사 + 는/조사	날/동사 + 는/어미
날/명사 + 는/조사	날/명사 + 는/어미
나/동사 + 늘/동사 + ㄴ/조사	나/동사 + 늘/동사 + ㄴ/어미
나/대명사 + 늘/동사 + ㄴ/조사	나/대명사 + 늘/동사 + ㄴ/어미

2001-7-25

2. 형태소 분석

- ◆ 한국어 형태소 분석 과정 (계속)
 - 비문법적인 형태소결합 제거 (형태통사규칙 적용)

동사+조사	나/동사 + 는/조사, 날/동사 + 는/조사, 늘/동사 + ㄴ/조사
대명사+어미	나/대명사 + 는/어미
동사+동사	나/동사 + 늘/동사
대명사+동사	나/대명사 + 늘/동사

나/동사 + 는/어미
나/대명사 + 는/조사
날/동사 + 는/어미

2001-7-25

9

2.1 형태소 분석 사전

- ◆ 형태 자소 규칙에 의해 어절로부터 분리된 문자열을 형태소로 인식하기 위해 사전 필요

- 사전 검색 이전 : 문자열 = 형태소 후보 (미확인상태)
- 사전 검색 성공 : 문자열 = 형태소
- 사전 검색 실패 : 문자열 ≠ 형태소 (완전한 사전인 경우)

❖ 완전한 사전: 미등록 형태소와 정보가 존재하지 않음

2001-7-25


10

2.1 형태소 분석 사전

◆ 미등록 형태소

- 미등록 형태소는 필연적으로 존재
 - ◆ 언어는 생성/발전/소멸하므로 완전한 사전을 만들 수 없음
- 미등록 형태소 문제
 - ◆ 올바른 어절에 대하여 분석 실패: 차이코프스키에게서
- 미등록 형태소 추정
 - ◆ 사전 검색 실패 문자열 = 미등록 형태소 ? / 비형태소 ?
차이코프스키에게서
차이코프스키에게서로서는을

2001-7-25



2.2 형태소 분석 문법


◆ 형태소 분석 문법

- 형태소 분석을 위한 규칙의 집합
 - ◆ 형태 자소 규칙
 - ◆ 형태 통사 규칙

◆ 형태소 분석 오류

- 미분석 : 문법의 적용 범위가 좁아 합법적인 해석이 누락
 - 과분석 : 문법의 적용 범위가 넓어 비합법적인 해석이 포함
 - 오분석 : 문법의 정확성 부족
- ❖ 모든 현상을 정확하게 표현하는 문법 필요

2001-7-25



3. 형태소 분석 방법

◆ 문자열 분리 방식 : 우좌분석

- 문자열의 우측부터 분리 (형식형태소 우선)

(예) 형태소분석하고
→ 형태소분석하+고
→ 형태소분석+하+고
→ 형태소+분석+하+고
→ 형태소+분석+하+고

- 한국어는 형식형태소가 매우 발달
- 문자열 좌측의 미등록 형태소 추정에 효과적

(예) 클린턴이

2001-7-25



3. 형태소 분석 방법

◆ 문자열 분리 방식 : 좌우분석

- 문자열의 좌측부터 분리 (실질형태소 우선)

(예) 형태소분석하고
→ 형태소+분석하고
→ 형태소+분석+하고
→ 형태소+분석+하+고
→ 형태소+분석+하+고

- 일반적인 문자열 판독과 동일한 방향

2001-7-25



3. 형태소 분석 방법

- ◆ 문자열 분리 방식 : 양방향분석
 - 우좌분석과 좌우분석을 동시에 수행
 - 문자열 중간의 미등록 형태소 추정에 효과적

(예) 한글프로그램개발

2001-7-25

15

3. 형태소 분석 방법

입력 어절

어절 유형 검사 모듈

코드 변환

형태소 분석 모듈

결과 출력

분석 후보생성

사전 검색

형태소 결합검증

2001-7-25

16

3.1 분석 후보 생성

◆ 불규칙 활용, 축약, 탈락 현상 등 형태론적

변형이 일어난 형태소의 원형을 복원

(예) 어절 "가는"의 분석 후보

- (1) 가는 (독립언 후보)
- (2) 가 + 는 (체언 + 조사 후보)
- (3) 가 + 는 (용언 + 어미 후보)
- (4) 갈 + 는 (ㄹ 탈락 후보)
- (5) 가느 + ㄴ (용언 + 어미 후보)
- (6) 가늘 + ㄴ (ㄹ 탈락 후보)
- (7) 가눌 + ㄴ (ㅎ 변형 후보)

2001-7-25

17

3.2 사전 검색

◆ 사전 검색을 통해 분석 후보 중 비형태소 제거

- (1) 가는 → 가는/비형태소
- (2) 가 + 는 → 가/NN + 는/JO
- (3) 가 + 는 → 가/VV + 는/EM
- (4) 갈 + 는 → 갈/VV + 는/EM
- (5) 가느 + ㄴ → 가느/비형태소 + ㄴ/EM
- (6) 가늘 + ㄴ → 가늘/AJ + ㄴ/EM
- (7) 가눌 + ㄴ → 가눌/비형태소 + ㄴ/EM

2001-7-25

18

3.3 형태소 결합 검증

- ◆ 형태 통사 규칙을 적용하여 두 형태소 간의 문법적 적합성 검사 (접속정보표 이용)
 - 어절의 시작과 끝으로 올 수 있는 형태소 지정이 필요
 - ◆ 시작 가능한 형태소 : 명사, 동사어간, 접두사, ...
 - ◆ 끝에 올 수 있는 형태소 : 명사, 접미사, 조사, 어말어미, 수사, ...
 - 형태 통사 규칙에 어긋나는 결합은 제거
(예) 감기는
 - ◆ 감기+는 : NN+JO, VV+EM (적합)
 - ◆ 감+기+는 : VV+EF+JO (적합)
 - ◆ 감+기는 : VV+EM (적합)
 - ◆ 가+ㅁ+기+는 : VV+EM+EM+JO (부적합)
 - EM+EM은 허용되지 않음

2001-7-25

19

3.4 기존 방법의 문제점

- ◆ 분석 후보 생성 후 부적격 후보 제거의 비효율성
 - 분석 후보 생성
 - 원형 복원 규칙을 적용하는 과정의 비효율성
 - 모든 어절에 대하여 여러 가지 조건의 적용 여부를 테스트해 보아야 함
 - (예) “가는” → 가는, 가+는, 갈+는, 가느+ㄴ, 가늘+ㄴ, 가늘+ㄴ
- 부적격 후보 제거
 - 부적격 후보의 제거를 위해 사전 검색 횟수가 증가
 - 사전 검색 횟수를 줄이는 것이 관건
 - 음절 정보를 이용한 사전 검색 횟수 감소 방안

2001-7-25

20

3.4 기존 방법의 문제점

◆ 코드 변환으로 인한 비효율성

- 어미에 포함된 'ㄴ/ㄹ/ㅁ/ㅂ'나 '아/어' 등은 어간과 결합하여 어간의 형태를 변형시키기 때문에 원형 복원 과정에서 자소별 조작이 필요
 - 완성형 코드로 주어진 어절을 조합형으로 변환
 - 형태소 분석이 완료된 후 다시 최초의 완성형 코드로 변환

완성형 조합형 형태소분석 조합형 완성형

- 입력 어절 중 위와 같은 이유로 자소별 조작을 해야 하는 경우는 일부에 지나지 않으나 어절 전체를 대상으로 일괄적인 코드 변환을 실시함.

(예) 아름다운 → 아름답 + 은

2001-7-25

21

4. 인접 조건 검사에 의한 분석

- ◆ 음절을 경계로 한 분석
- ◆ 음운 제약 조건
- ◆ 형태 제약 조건
- ◆ 품사 제약 조건
- ◆ 인접 조건 검사
- ◆ 형태소 분석 사전 구축
- ◆ 구현 사례

2001-7-25

22

4.1 음절을 경계로 한 분석

- ◆ 독립언 (하나의 단어가 하나의 어절을 이루는 유형)
한 번의 사전 탐색만으로 분석이 종료됨
- ◆ 체언 + 조사 유형
 - (1) 학교에서 → 학교/NN + 에서/JO
 - (2) 학생은 → 학생/NN + 은/JO
- ◆ 용언 + 어미 유형
 - (1) 예쁘니까 → 예쁘/AJ + 니까/EM
 - (2) 기다리다 → 기다리/VV + 다/EM
 - (3) 그립다고 → 그립/AJ + 다고/EM
 - (4) 믿다 → 믿/VV + 다/EM

위의 두 유형에 대해서는 두 번의 사전 탐색으로 분석이 종료됨

2001-7-25

23

4.1 음절을 경계로 한 분석

◆ 효율적인 분석

음절을 경계로 형태소 분석을 한다면 자소 단위의 연산이 불필요
→ 코드 변환 과정이 불필요
→ 형태소 분석을 사전 탐색에 의한 단어 인식 문제로 단순화

- (1) 학교에서 → 학교/NN + 에서/JO
- (2) 예쁘니까 → 예쁘/AJ + 니까/EM
- (3) 기다리다 → 기다리/VV + 다/EM

- 좌우 분석 또는 우좌 분석

2001-7-25

24

4.2 음운 제약 조건

◆ 음절을 경계로 한 분석의 문제 1

- (1) 먹는 → 먹/NN + 는/JO
- (2) 감는 → 감/NN + 는/JO

조사나 어미 중에는 선행하는 형태소에 대하여 음운론적 환경에 대한 제약을 가하는 것들이 있다.

조사 : 마지막 음절의 종성 자음 유무

어미 : 마지막 음절의 종성 자음 유무, 모음 유형 (양성/음성)

따라서 형태소 사전에 이러한 제약 조건을 나타낼 필요가 있다.

2001-7-25

25

4.2 음운 제약 조건

◆ 문제 1의 해결을 위한 사전 구조

(1) 음운 제약 조건의 표현

에서 : ([에서/JO])

는 : ([는/JO] @(+모음))

은 : ([은/JO] @(+자음))

아라 : ([아라/EM] @(+양성))

어라 : ([어라/EM] @(+음성))

이형태를 대표형으로 나타내고자 하는 경우

어라 : ([아라/EM] @(+음성))

2001-7-25

26

4.2 음운 제약 조건

◆ 문제 1의 해결을 위한 사전 구조

(2) 음운 정보의 표현

학교 : ([학교/NN] +모음)

마당 : ([마당/NN] +자음)

먹 : ([먹/VV] +음성 +자음)

보 : ([보/VV] +양성 +모음)

2001-7-25

27


4.2 음운 제약 조건

◆ 음운 제약 조건을 적용한 예

(1) 보아라

보 : ([보/VV] +양성 +모음)

아라 : ([아라/EM] @(+양성))




(2) 학교는 / 학교은

학교 : ([학교/NN] +모음)

는 : ([는/JO] @(+모음))

은 : ([은/JO] @(+자음))



2001-7-25

28

4.3 형태 제약 조건

◆ 음절을 경계로 한 분석의 문제 2

- (1) 그린다 → 그리/VV + ㄴ다/EM
- (2) 돌본다 → 돌보/VV + ㄴ다/EM

어미 중에는 선행하는 용언의 제일 마지막 음절과 결합하여 어간의 형태를 변형하는 것이 있다 → 원형 복원이 필요?

'돌본'을 용언으로 형태소 사전에 등재
'다'를 어미로 형태소 사전에 등재

둘 사이의 결합 관계를 잘 나타낼 수 있으면 음절을 경계로 한 분석 가능

2001-7-25

29

4.3 형태 제약 조건

◆ 문제 2의 해결을 위한 사전 구조 (확대된 사전)

- (1) 용언의 원형 : 가, 돌보, ...
- (2) 용언 + ㄴ 결합형 : 간, 돌본, ...
- (3) 용언 + ㄹ 결합형 : 갈, 돌볼, ...
- (4) 용언 + ㅁ 결합형 : 감, 돌봄, ...
- (5) 용언 + ㅂ 결합형 : 갑, 돌봄, ...
- (6) 용언 + ㅆ 결합형 : 갓, 돌봤, ...

2001-7-25

30

4.3 형태 제약 조건

◆ 형태 제약 조건의 표현 (확대된 형태소 사전)

게 : ([ㄹ/EM] @(+ㄹ))

다 : ([다/EM] @(+어간 | +ㅆ)) ([ㄴ/EM] @(+ㄴ))

세 : ([ㅁ/EM] @(+ㅁ))

니다 : ([ㅂ니다/EM] @(+ㅂ))

+어간, +ㄴ, +ㄹ, +ㅁ, +ㅂ, +ㅆ 등은 표제어의 왼쪽에 올 수 있는
문자열의 형태를 제약하는데 사용되는 기호

2001-7-25

81

4.3 형태 제약 조건

◆ 형태 정보의 표현 (확대된 형태소 사전)

돌보 : ([돌보/VV] +어간 +양성 +모음)

돌본 : ([돌보/VV] +ㄴ)

돌불 : ([돌보/VV] +ㄹ)

돌봄 : ([돌보/VV] +ㅁ)

돌봄 : ([돌보/VV] +ㅂ)

돌봤 : ([돌보/VV + 았/EP] +ㅆ)

2001-7-25

82


4.3 형태 제약 조건

◆ 형태 제약 조건을 적용한 예

(1) 돌봅니다

돌봄 : ([돌보/VV] +ㅂ)


니다 : ([ㅂ니다/EM] @(+ㅂ))



(2) 돌봄다

돌봄 : ([돌보/VV] +ㅂ)

다 : ([다/EM] @(+어간 | +ㅆ)) ([ㄴ다/EM] @(+ㄴ))



2001-7-25

83

4.3 형태 제약 조건

◆ 형태 제약 조건을 적용한 예 (다중 결과 생성)


(1) 갑니다

가 : ([가/VV] +어간 +양성 +모음)

갈 : ([갈/VV] +어간 +양성 +모음)

갑 : ([가/VV] +ㅂ) ([갈/VV] +ㅂ)

니다 : ([ㅂ니다/EM] @(+ㅂ))



2001-7-25

84

4.3 형태 제약 조건

- ◆ 형태 제약 조건을 이용한 아/어/으 문제 해결 예

보 : ([보/VV] +어간 +아 +양성 +모음)

봐 : ([보/VV] -아 +양성 +모음)

사 : ([사/VV] +어간 -아 +양성 +모음)

먹 : ([먹/VV] +어간 +아 +음성 +자음)

아도 : ([아도/EM] @(+아 +양성))

어도 : ([어도/EM] @(+아 +음성))

도 : ([아도/EM] @(-아 +양성)) ([어도/EM] @(-아 +음성))

고 : ([고/EM] @(+어간))

보아도, 봐도, 사도, 먹어도, 보고, 사고, 먹고, ... (분석 됨)

*봐아도, 사아도, 봐고, 먹도, ... (분석 안됨)

2001-7-25

35

4.3 형태 제약 조건

- ◆ 형태 제약 조건을 이용한 ㄷ/ㅌ/ㅅ 불규칙 문제 해결 예

듣 : ([듣/VV] +어간 +음성)

들 : ([듣/VV] +아 +음성)

돕 : ([돕/VV] +어간 +양성)

도 : ([돕/VV] +와 +양성)

굿 : ([굿/VV] +어간 +음성)

그 : ([굿/VV] +아 +음성)

듣고, 듣고, 굿고
들어도, 도와도, 그어도

...

아도 : ([아도/EM] @(+아 +양성))

어도 : ([어도/EM] @(+아 +음성))

도 : ([아도/EM] @(-아 +양성)) ([어도/EM] @(-아 +음성))

고 : ([고/EM] @(+어간))

와도 : ([아도/EM] @(+와 +양성))

워도 : ([어도/EM] @(+와 +음성))

2001-7-25

36

4.4 품사 제약 조건

- ◆ '는/도/만'과 같은 보조사는 체언뿐만 아니라 부사와도 사용됨.

학교/NN + 는/JO 빨리 /AD + 는 /JO

학교 /NN + 도 /JO 빨리 / AD + 도 /JO

학교 /NN + 만 /JO 빨리 / AD + 만 /JO

- ◆ 어미 중에는 동사나 형용사에서만 사용되는 것도 있음.

아름답/AJ + 거나/EM 들/VV + 거나/EM

아름답/AJ + 는군요/EM 들/VV + 는군요/EM

아름답/AJ + 군요/EM 들/VV + 군요/EM

2001-7-25

37

4.4 품사 제약 조건

- ◆ 품사 제약 조건 표현

에서 : ([에서/JO] @([NN NP NU NX]))

은 : ([은/JO] @([NN NP NU NX AD) @(+자음))

는 : ([는/JO] @([NN NP NU NX AD) @(+모음))

거나 : ([거나/EM] @([VV VX SV AJ AX SJ EP) @(+어간 | +ㅅ))

는군요 : ([는군요/EM] @([VV VX SV EP) @(+어간))

군요 : ([군요/EM] @([AJ AX SJ EP) @(+어간 | +ㅅ))

어미 '-거나'나 '-군요'는 '사-', '아름답-' 등과 같은 어간이나 'ㅆ'과 결합된 '샀-', '-았-', '-었-', '-웠-', '-웠-' 등의 뒤에 올 수 있다.

사거나, 아름답거나, 아름답군요, 샀거나, 아름다웠이거나, ...

2001-7-25

38

4.4 품사 제약 조건

◆ 품사 정보의 표현

하 : ([하/SV] #(NN) +어간 +양성 +모음)

했 : ([하/SV + 었/EP] #(NN) +ㅆ +음성)

시 : ([시/EP] #(VV VX SV AJ AX SJ) @(+모음 +어간) +어간)

셨 : ([시/EP + 었/EP] #(VV VX SV AJ AX SJ) @(+모음 +어간) +ㅆ +음성)

2001-7-25

39

4.4 품사 제약 조건

◆ 품사 제약 조건을 적용한 예

하 : ([하/SV] #(NN) +어간 +양성 +모음)

했 : ([하/SV + 었/EP] #(NN) +ㅆ +음성)

시 : ([시/EP] #(VV VX SV AJ AX SJ) @(+모음 +어간) +어간)

셨 : ([시/EP + 었/EP] #(VV VX SV AJ AX SJ) @(+모음 +어간) +ㅆ +음성)

다 : ([다/EM] @(+어간 | +ㅆ)) ([ㄴ다/EM] @(+ㄴ))

거나 : ([거나/EM] @(VV VX SV AJ AX SJ EP) @(+어간 | +ㅆ))

연구하다 : 연구/NN + 하/SV + 다/EM

연구했거나 : 연구 /NN + 하 /SV + 었/EP + 거나/EM


연구하시거나 : 연구 /NN + 하 /SV + 시/EP + 거나/EM

연구하셨거나 : 연구 /NN + 하 /SV + 시/EP + 었/EP + 거나/EM

2001-7-25

40

4.5 형태소 분석 사전 구축



2001-7-25

41

4.5 형태소 분석 사전 구축

- ◆ 음운/형태/품사 제약 조건을 간단하게 나타내기 위하여 다음과 같은 심볼을 사용함.

@용언, @동사, @형용사, @자음|체언, @모음|체언,
@ㅂ불|용언, @ㅂ불|동사, @ㅂ불|형용사, @아|용언,
@아|동사, @아|체언, ...

- ◆ 복합 조사/어미의 처리 방법

에서부터는 : ([에서/JO + 부터/JO + 는/JO] ...)
라고까지는 : ([라고/EM + 까지/JO + 는/JO] ...)


에서부터는 : ([에서부터는/JO] ...)
라고까지는 : ([라고까지는/EM] ...)

- ◆ 기타 다른 복합어의 처리 방법

2001-7-25

42

4.6 방법론 비교



2001-7-25

43

4.7 구현 사례

◆ MACH (Morphological Analyzer for Contemporary Hangul)

- C++로 구현
- 1.13GHz Pentium III급의 PC에서 1GB의 문서를 분석하는데 5분이 걸리며 이는 초당 약 45만 어절을 분석하는 것임.

N.B. 333MHz Pentium II급의 PC에서 1GB의 문서를 분석하는데 172분이 걸림.

N.B. 450MHz Pentium III급의 PC에서 명사 추출기를 수행시켰을 때
초당 4.3만 어절을 분석함.

2001-7-25

44

5. 품사태깅

◆ 형태론적 중의성

- 하나의 표층 어절이 두 개 이상의 형태소분석결과를 가지는 경우
(예) “나는”

나/대명사 + 는/조사
날/동사 + 는/어미
나/동사 + 는/어미

◆ 형태론적 중의성 해소

- 주어진 문맥 내에서는 단지 하나의 형태소 분석 결과만 가진다.
- 나는 오늘 병원에 가야 합니다.
 - 하늘을 나는 게 제 꿈입니다.
 - 싹이 나는 것을 보니 봄이 왔군요.

2001-7-25

45

6. 형태소 분석의 응용 분야

◆ 자연어 처리

- 구문 분석의 하위 모듈
- 단어 의미 중의성 해결
- 기계 번역(Machine Translation)

◆ 정보 처리

- 정보 검색
- 자동 요약

◆ 전처리 혹은 후처리

- 맞춤법(철자/띄어쓰기) 오류 검사 및 교정
- 문자 인식 또는 음성 인식의 후처리

◆ 언어 정보 획득

- 용례, 통계정보 추출

2001-7-25

46

7. 주요 한글 코드


- ◆ 상용 조합형 코드
- ◆ 완성형 KSC-5601
- ◆ 유니코드 한글

2001-7-25

47

7.1 상용 조합형 코드

- ◆ 한글의 한 음절을 2byte로 표현
 - 코드 당 2바이트, 첫바이트의 MSB = 1(한글), 0(아스키)
 - 5비트 초성, 5비트 중성, 5비트 종성



- ◆ 12,320 가능한 음절을 모두 표현
 - 완전한 현대 한글 음절 11,172자를 모두 표현
- ◆ 음절 구조 반영
 - 초성, 중성, 종성 정보를 코드로부터 직접 계산 가능
- ◆ 한국어 정보 처리(특히, 형태소분석)에 적합한 코드임

2001-7-25

48

7.2 완성형 코드 (KSC-5601)

- ◆ 한글의 한 음절을 2byte로 표현
 - 코드 당 2바이트, 첫바이트의 MSB = 1(한글 코드임을 나타냄)
- ◆ 한글은 자주 쓰이는 2,350자를 가나다 순으로 배치

가 = 0xB0A1	거 = 0xB0DC
각 = 0xB0A2	격 = 0xB0DD
간 = 0xB0A2	꺾 = 0xB0DE
갇 = 0xB0A3	건 = 0xB0DF
- ◆ 단점
 - 표현할 수 없는 글자가 많고, 한글 자모의 분리가 어려움

2001-7-25

49

7.3 유니코드 (Unicode)

- ◆ Unicode 2.0에서 추가된 한글 표현 방법
- ◆ 조합될 수 있는 현대 한글 모두를 가나다 순으로 정렬, 배치한 것
- ◆ 조합 가능한 글자의 수
 - 19(초성) x 21(중성) x 28(종성) = 11,172자
- ◆ 현대 한글을 모두 표현할 수 있으며 정렬에도 아무 문제가 없음
 - 고어 한글을 표현할 수 없음
- ◆ JAVA, Linux 등에서 지원

2001-7-25

50