

이동통신 기기용 온/오프라인 통합형 임베디드 필기체 문자 인식 엔진

OSS 지원사업 워크숍
2010. 5 .19

중앙대학교 컴퓨터공학부
휴먼인터페이스 연구실

순서

- 서론
 - 배경, 개요
- 개발 내용
 - 단계별 개발 내용
 - 1차년도 개발 내용
 - 2차년도 개발 계획 및 방법
- 활동 내용
 - 커뮤니티 운영/관리, 기술 정보 활동
- 요약

배경

- 모바일 기기의 소형 경량화 및 대중화
 - 다양한 서비스에 대한 정보 입력이 필수적
 - 숫자키 패드에 의한 정보 입력의 불편함
 - 카메라, 터치패드 등의 다양한 입력기기 탑재
 - 다양한 환경에 대응하는 통합 문자 인식기 필요
-
- 실용적인 한글 문자 인식 공개 S/W 없음
 - 한글 문자 인식을 위한 데이터의 절대 부족

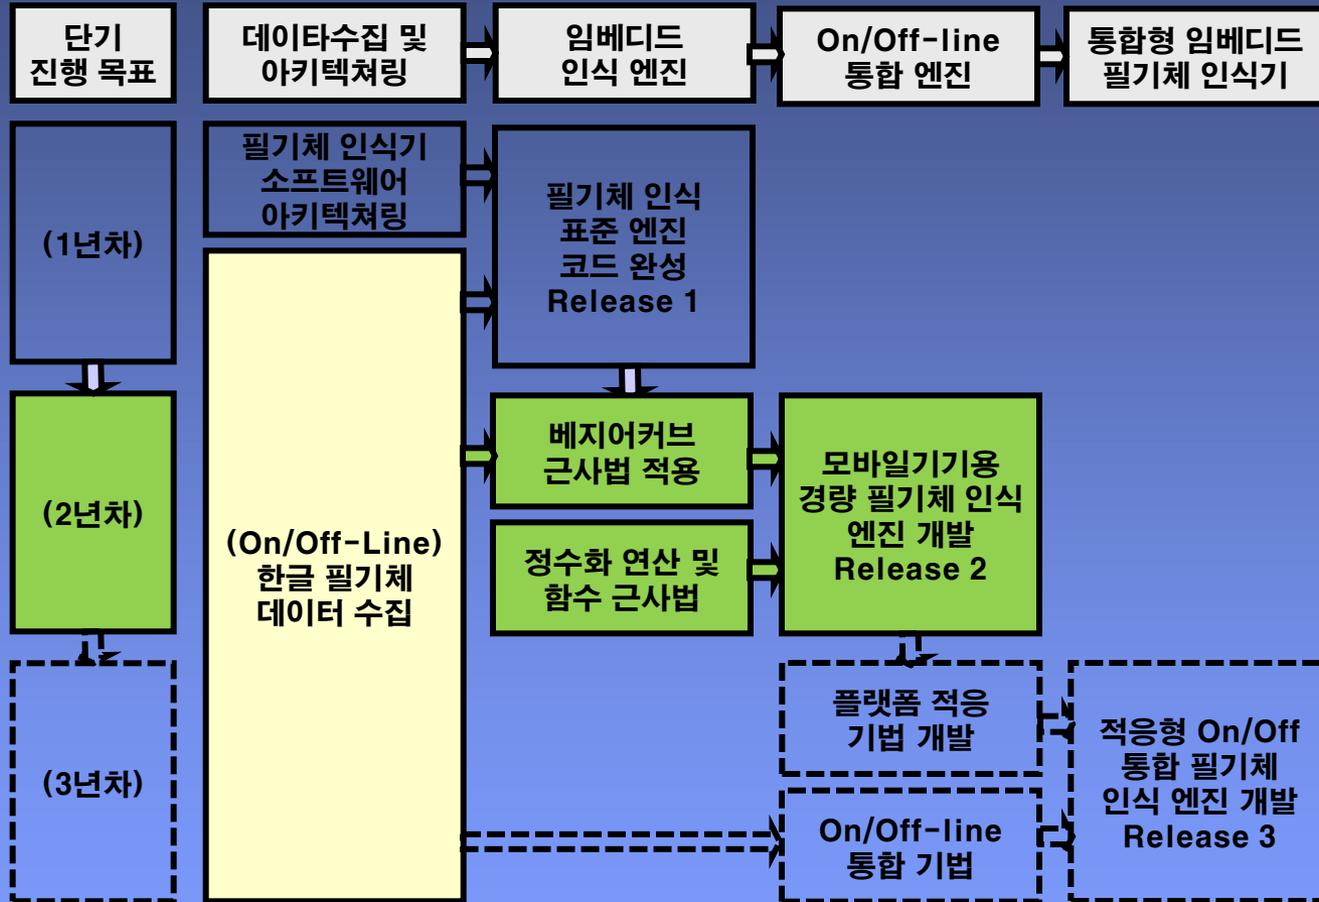
개요

- **모바일 기기용 한글 문자 인식 S/W 개발**
- **개발용 필기체 한글 데이터 확보**

- **통합형 인식 엔진**
 - 온라인/오프라인의 통합 인식
 - 인쇄체/필기체의 통합 인식
 - 다중 언어/문자의 통합 인식

- **임베디드 모듈화**
 - 모바일 기기에 대응하도록 소형 경량화
 - 다양한 플랫폼에 대응하여 이식성 강화
 - 플랫폼 리소스변화에 대응하는 적응성 강화

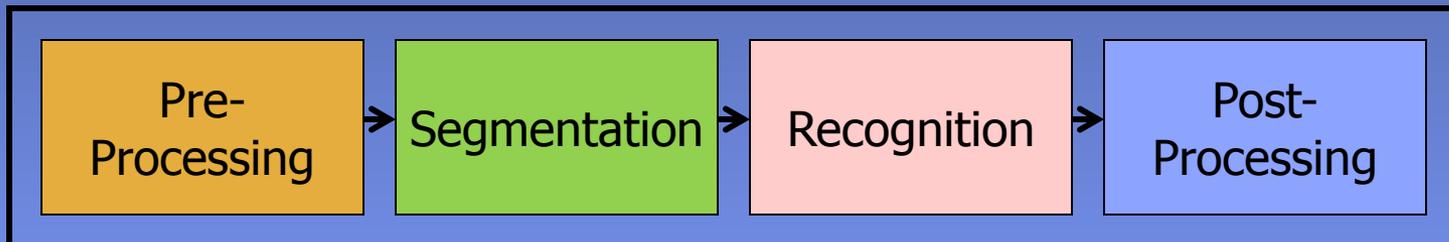
단계별 개발 내용



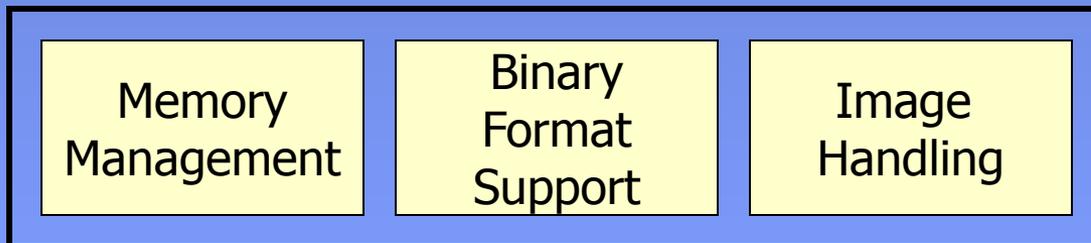
Setup

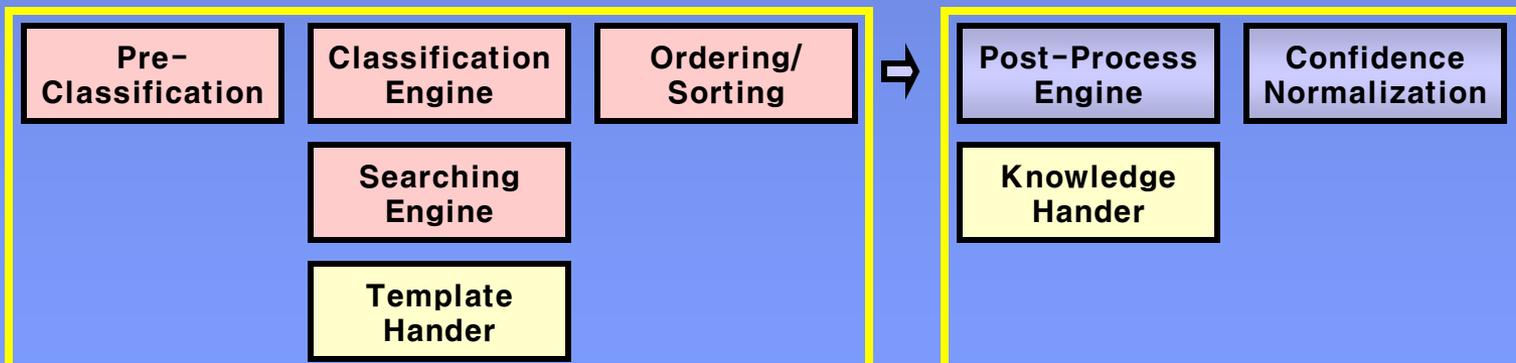
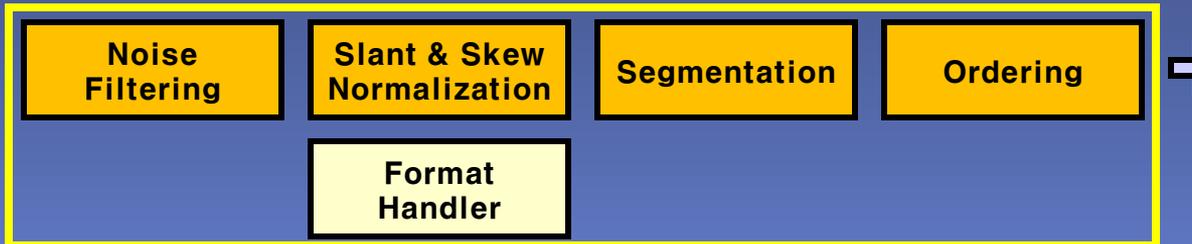


Recog Engine Core



Support





- 전체 수집 데이터

분류명	영어	숫자	특수문자	한글	총계
온라인	212,355	32,206	6,222	188,459	439,242
오프라인	37,981	7,675	16,029	1,400,042	1,461,727

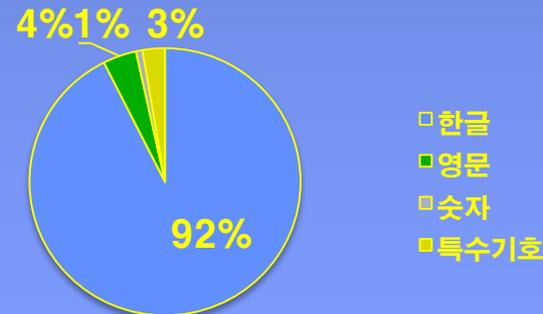
- 온라인 데이터 수집

구분	영어	숫자	특수문자	한글	총계
Kaist	43,529	3,114	282	90,009	136,934
연세대	0	788	4,133	98,450	103,371
UJI	1,966	397	0	0	2,363
Unipen	166,860	27,907	1807	0	196,574

오프라인 데이터 수집

세트번호	부수	수집 문자수	정제 문자수	제거율
SET 1	132	310,200	220,475	28.92%
SET 2	131	333,002	274,494	17.56%
SET 3	77	195,734	192,211	1.79%
SET 4	65	165,230	157,227	4.84%
SET 5	96	244,032	198,948	18.47%
SET 6	71	180,482	179,634	0.46%
SET 7	100	254,200	238,738	6.08%

문자 종류별 비율



오프라인 문자 수집-수집틀

- 한글 2350자, 영문자(대소), 숫자, 특수 문자
- 문자별 품질의 균질성 위해 무작위 배열
- 6가지 서로 다른 문자 배열 순서
- 자료제공자의 기초 자료 포함
- 자동화 인식표 삽입

한글 문자 데이터 수집을 위한 틀(v1.1)
02-071 2006.08.10 (E형)

재pose
blank

중앙대학교 휴먼인더페이스 연구실

•원자 정보 (다음을 정확히 기재하여 주세요.)

성	별	남	여
나이	이	26	
직	업	대학생	
최종 학력			
성명	이	시용석	
연락처		010-6354-3415	

< 수집된 데이터는 상업 목적이 아닌 연구를 자료로 활용될 것임 >

• 주의사항

1. 용이름 구기거나 인입하지 마세요.
2. 상당 비표로써 오염물을 묻히지 마세요.
3. 깨끗한 상태를 유지해 주세요.
4. 문자 수집 시 수정력을 이용하세요.
5. 굵은 펜을 이용하여 주세요.

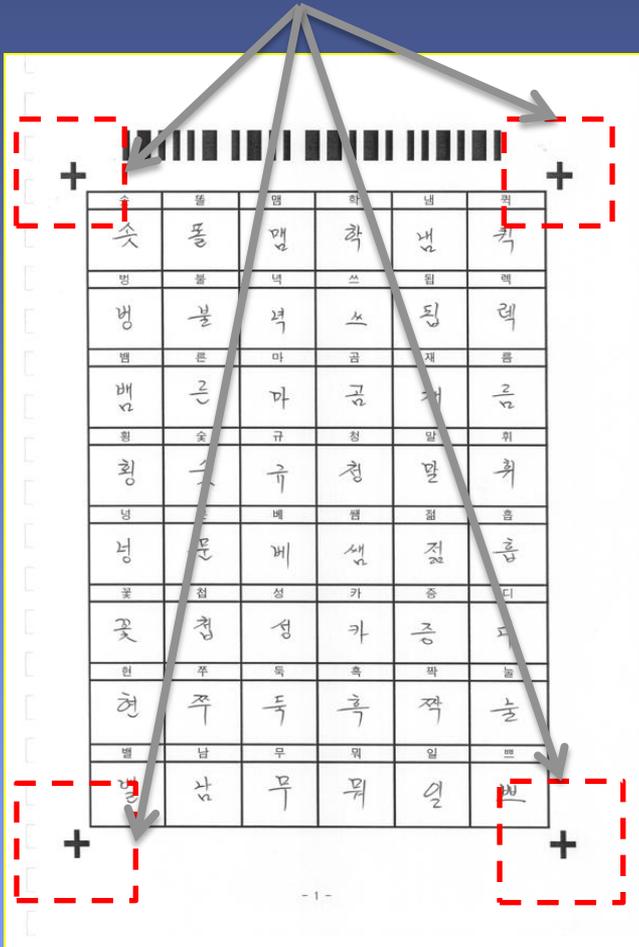


키	각	냉	릭	성	경
양	뜻	환	경	방	캠
증	능	황	존	강	레
복	화	균	외	른	티
부	마	글	태	은	티
원	관	적	난	찬	중
뎡	광	씩	난	찬	중
재	캠	외	택	상	날
튀	양	은	탕	공	건
극	한	반	낫	한	곡

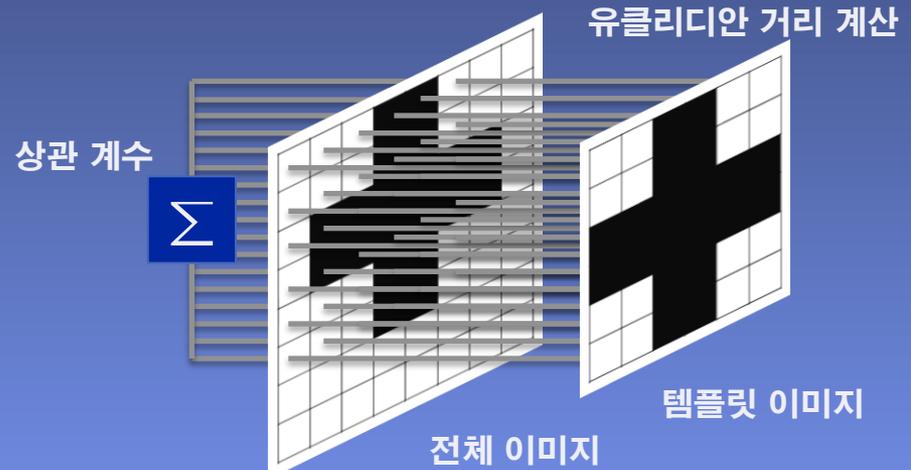
-2-

오프라인 문자 수집 - 문자 분리

십자 마커 탐색 영역



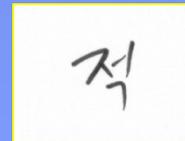
1. 십자 마커 영역 탐색 영역 계산
2. 상관 계수 계산을 통한 십자 마커 탐색



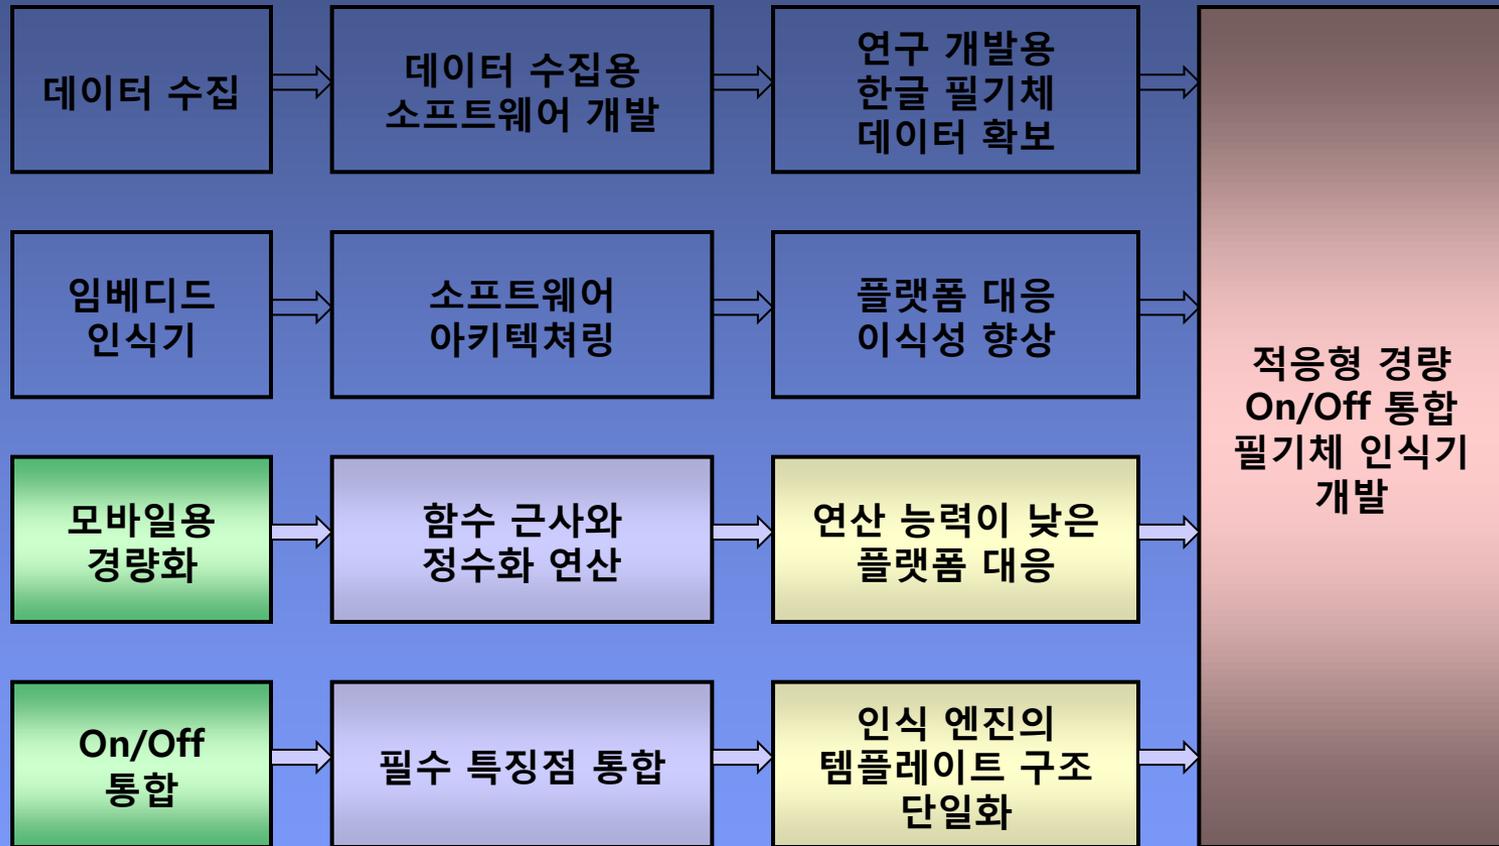
3. 바코드 판독



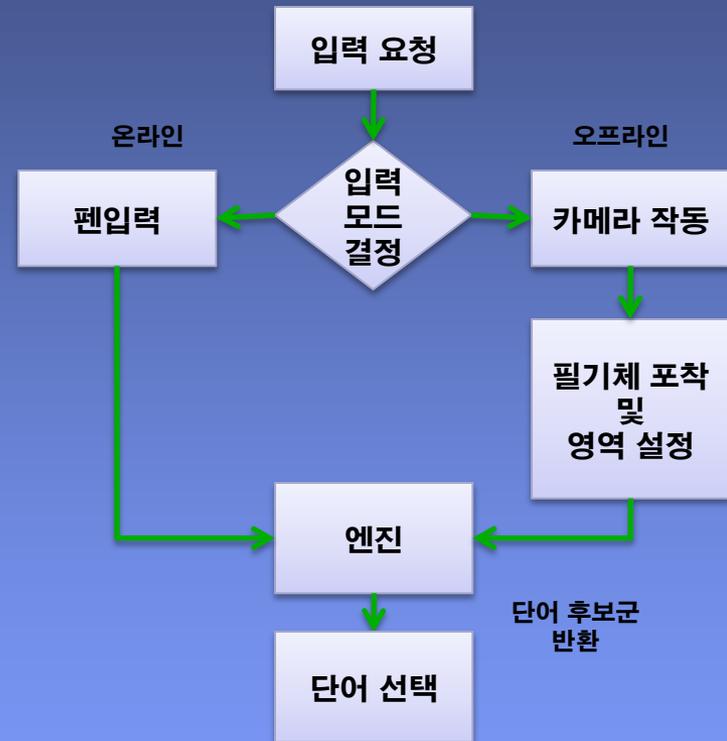
4. 문자 추출



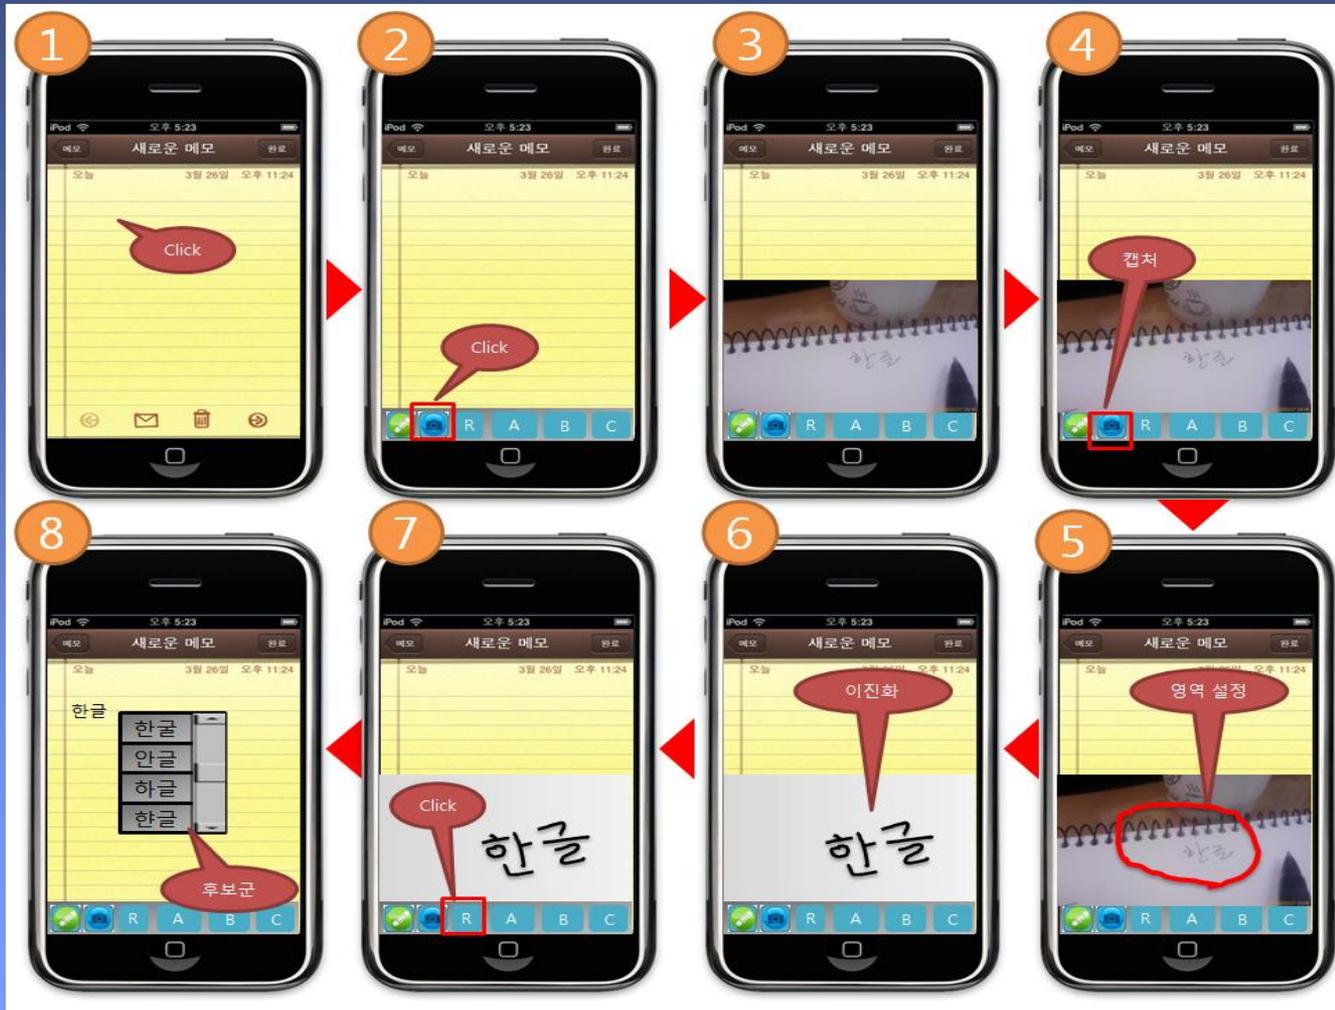
내용과 목표 - 2차년도



사용자 인터페이스 - 통합 인터페이스



사용자 인터페이스 - 오프라인 모드




프로그래밍 환경 구축

- 개발 환경 조성
 - 개발 디렉터리 구조 설계
 - 소스 컨트롤, Makefile 등 빌딩 관련 구조 개발
 - 하위 모듈별 개발 담당자 배정 및 확정
- 임베디드 프로그래밍
 - 이식성향상을 위한 변수형, 선언자 를 규정
 - 함수의 리턴형 통일 및 에러 코드 발생 규칙 설정
 - 코드의 통일성 유지를 위한 코딩 규칙 제정

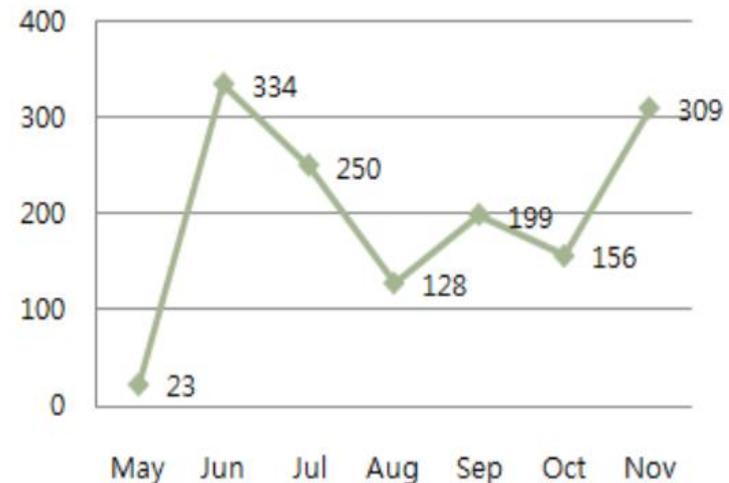
커뮤니티 운영

- <https://sourceforge.net/projects/ucr-project/>
- <http://kldp.net/projects/ucr/wiki/>

순위



전체 페이지 수



기술 정보 활동

- 저작권 관리

- 저작권 위원회 저작권 관련 전문가 자문 (3회)
- 공개 소프트웨어 저작권 관련 학술대회 참여

- 과제 홍보 및 협력

- 디오텍(주)와 문자인식 관련 기술 멘토 및 협력
- 국제 학술 논문
- CJKPR 10 논문 발표 (2010년 11월 4-6일, 일본 후쿠오카)

- 교육 기회 제공

- 패턴인식, 소프트웨어공학 관련 프로젝트
- 컴퓨터 공학과 졸업 프로젝트로 참여 확대

개발 계획

과제내용	추진 일정												참여인력 (M/M)
	1	2	3	4	5	6	7	8	9	10	11	12	
베지어 곡선 특징점 추출													0.3
연산 효율 개선 방안 연구													0.3
사용자 인터페이스 개선													0.3
인쇄체 인식 확장 모듈													0.3
한글 필기체 데이터 수집													0.2
주요 Milestone 완성점에서의 수행결과	<ul style="list-style-type: none"> 온/오프라인 통합 표준 특징점 추출 알고리즘 개발 보고서 						<ul style="list-style-type: none"> 연산 효율 개선 따른 성능 평가 보고서 온/오프라인 통합 필기체 인식 엔진 코드 (release 2) 						1.4

- **모바일용 통합형 필기체 문자 인식 엔진 개발**
 - 모바일 기기용 경량 필기체 인식 엔진 개발
 - 모바일 기기용 사용자 인터페이스 개발
- **한글 필기체 데이터의 지속적 수집**
 - 오프라인: 200세트 수집, 1000세트 수집 완료(200만 자)
 - 온라인: 기존의 공개 데이터 수집, 규격 통합 재생산 (50만 자)
- **커뮤니티 운영 및 기술 정보 활동**
 - 개발 소스 코드, 관련 문서 배포 → 커뮤니티 활성화 기대
 - 관련 기술의 홍보, 저작권 관련 기술 내용 확보