

웨이브렛 특징과 순위 기반 인식을 이용한 한글 문서 영상 검색 시스템

A Hangul Document Image Retrieval System Using Rank-based Recognition

이득용, 김우연, 오일석

전북대학교 컴퓨터과학과

Duk-Ryong Lee(drlee@dahong.chonbuk.ac.kr), Woo-Youn Kim(wykim@dahong.chonbuk.ac.kr),
Il-Seok Oh(isoh@chonbuk.ac.kr)

요약

우리는 스캔된 한글 문서 영상에 대한 전문(full-text) 검색 시스템을 구축하였다. 이 시스템은 크게 전처리부, 인식부, 그리고 검색부로 구성되어 있다. 검색 알고리즘은 k순위까지의 인식 결과를 이용한다. 이 방법은 검색 성능이 인식 오류에 둔감할 뿐만 아니라, 재현률과 정확률을 사용자가 조절할 수 있는 장점을 갖는다. 객관적인 성능 평가를 위해 KISTI가 제공하는 정보과학회 논문지 영상을 실험에 사용하였다. 인식과 검색 성능을 통하여 시스템이 실용적임을 보였다.

■ 중심어 : | 문서영상 | 전문 검색 | 문자인식 | 재현률과 정확률 |

Abstract

We constructed a full-text retrieval system for the scanned Hangul document images. The system consists of three parts; preprocessing, recognition, and retrieval components. The retrieval algorithm uses recognition results up to k-ranks. The algorithm is not only insensitive to the recognition errors, but also has the advantage of user-controllable recall and precision. For the objective performance evaluation, we used the scanned images of the Journal of Korea Information Science Society provided by KISTI. The system was shown to be practical through the evaluation of recognition and retrieval rates.

■ Keyword : | Document Image | Full-Text Retrieval | OCR | Recall and Precision |

I. 서 론

1. 연구 배경

인류는 새로운 지식을 생산하여 이를 문자를 이용하여 문서라는 형태에 기록하여 후손에게 전달하는 지식 순환 과정을 가지고 있다. 이러한 과정을 통해 지식이 축적되고 인류 발전이 이루어진다.

최근 개인용 컴퓨터와 인터넷의 대중화로 인해 필기

위주의 문서 작성이 워드 프로세서를 사용하는 디지털 방식으로 전환되었다. 디지털 문서가 증가함에 따라 문서를 획득하는 방법 또한 급격히 디지털 방식으로 전환되고 있다[1]. 과거에는 도서관에 가서 자료를 복사하거나 대여하는 방법으로 정보를 얻었으나, 이제는 컴퓨터에서 디지털 도서관이나 e-book 서버 등에 접속하여 원하는 정보를 획득한다. 즉 아날로그 방식의 수고로움 없이, 편리하게 디지털 방식으로 원하는 정보를 획득하

는 새로운 문화가 생성되고 있다.

논문 [2]에서는 이러한 시대적 현상을 “시대적 디지털 격차(chronological digital divide)”라는 개념으로 설명하고 있다. 즉 디지털 방식에 익숙해짐에 따라 기존 종이 문서에 대한 접근 고리가 끊어져 지식의 시대적 절단이 발생할 수 있다는 진단이다. 이에 덧붙여 우리나라의 경우 1900년경 한문에서 한글로 언어 전환이 일어남에 따라 우리 조상의 기록물에 대한 접근 고리를 상실하였고, 이에 따라 민족정신 계승에 문제가 발생하고 급속히 서구화된 경험을 지적하고 있다.

예전의 아날로그 문서는 필기 또는 인쇄된 종이를 제본한 형태로 존재한다. 이러한 문서를 디지털 형태로 변환하기 위해서는 두 가지 작업을 수행하여야 한다. 첫 번째는 날장 단위로 스캔하여 영상 형태로 변환하는 것이고, 두 번째는 이 문서 영상을 검색이 가능한 형태로 가공하여 저장하는 것이다. 두 작업 모두 상당한 비용이 소요된다.

스캔 작업은 자동 급지 장치, 고속 스캐너, 비접촉 스캐닝 기술이 발달함에 따라 상대적으로 적은 비용으로 수행할 수 있다. 두 번째 작업을 위해서는 문서 영상 내의 문자들을 코드 형태로 변환해야 한다. 하지만 OCR (Optical Character Recognition) 기술의 한계로 인해 수작업 또는 OCR 이후 수작업 검증이라는 방법 중의 하나를 사용해야 하는데 두 가지 모두 사람이 필요하여 비용이 과다하다는 결론들이 있다. 예를 들어, 규장각 문서의 디지털 사업이 국가 주도로 수행되고 있는데 정서 필기된 한문 문서에서 한 문자 입력에 약 34원 정도로 산정하고 있다 [3].

우리 정부는 이러한 문제를 인식하여 국가 주도의 디지털 도서관 사업을 펼치고 있다. 한 예로서 [표 1]은 국립 중앙 도서관이 보유하고 있는 스캔된 문서에 대한 정보를 보여주고 있다. 표에 따르면 약 7천6백만 쪽에 달하는 스캔 문서를 보유하고 있지만 전체 소장 서적 약 4,736,460권과 비교하면 디지털 비율이 5%에도 미치지 못함을 알 수 있다. 현재 국가 기록보존소, 역사편찬위원회, 특허청과 같은 국가 기관, 대학, 언론 기관, 기업 등이 종이 문서를 스캔하여 디지털 변환 작업을 적극적으로 수행하고 있다.

표 1. 국립중앙도서관의 스캔 문서(tiff 포맷)

종류	발행연도	책 수	쪽 수	검색 방법
문화재 및 고서		68,896책	10,244,750면	서명, 저자, 색인, 목차
문화관광부 발행도서		630책	139,000면	서명, 저자, 색인, 목차
인문과학 분야박사 학위 논문	~1997	7,816권	1,475,273면	서명, 저자, 색인, 목차, 초록
신문	~1945	631종	1,064,482건	시문, 기사명, 날짜
단행자료	1945~1997	139,000책	43,000,000면	자료명, 저자, 발행자, 키워드, 목차
연속 간행물	~1950	3,036종	179,000건	연속간행물 명, 발행처명
학술 논문기사		1,400여종	280,000건	기사명, 기사저자명, 학술지명, 발행처명
기타 자료		55,599권	20,254,696건	
총		277,008권	76,637,201건	

이러한 적극적인 노력에도 불구하고 검색을 위한 가7공 작업이 문서 제목, 저자, 몇 개의 색인이, 목차, 요약까지만 수행되어 이용률이 낮은 실정이다. 이는 국내 디지털 도서관 사업이 비용 부담 때문에 스캐닝 작업에 치중하고 있기 때문이다. 제대로 된 검색은 문서 전체를 대상으로 하는 전문 검색(full-text retrieval)이 가능해야 한다. 전문 검색이 가능하면 아래와 같은 진보된 서비스를 제공할 수 있다.

- (1) 검색된 문서의 적합도(relevance)를 산정하고 이를 따라 문서 순위를 정하여 제공한다.
- (2) 고유 명사나 회귀어 질의어도 허용하는 개방형 어휘(open vocabulary) 검색을 제공한다.
- (3) 검색 목적에 따라 재현률(recall)과 정확률(precision)을 조절할 수 있다.

2. 문서 영상 처리 기술을 이용한 검색

최근 들어 방대한 양의 스캔된 문서의 이용률을 높이는 데 관심이 집중되고 있다. 하지만 OCR 소프트웨어의 낮은 인식률과 수작업 입력에 따른 인건비 부담 때문에 어려움에 직면해 있다. 이러한 어려움을 극복하는

하나의 대안은 실제 응용 영역에 적용할 수 있을 정도의 검색 성능을 갖는 문서 영상 검색 시스템을 문서 영상 처리 기술을 이용하여 개발하는 것이다.

문서 영상 처리 기술의 state-of-the-art를 살펴보면, 하나의 시스템으로 다양한 종류의 문서를 모두 처리한다는 목적은 달성할 수 없다. 하지만 문서들을 형태와 언어 등에 따라 구분하고, 각각에 대해 그에 최적인 알고리즘을 도입, 개발, 그리고 통합하면 충분히 합리적 수준의 검색 성능을 갖는 시스템을 개발할 수 있다 [4,5].



그림 1. 다양한 형태를 갖는 문서 영상

[그림 1]은 국내외 디지털 도서관에 접속하여 내려받은 문서 영상이다. [그림 1](a)는 1940년대의 신문 기사의 일부로서 국립 중앙 도서관에서 내려받았다[6]. [그림 1](b)는 규장각 사업으로 입력된 太祖實錄의 일부이다 [7]. [그림 1](c)는 IEEE의 디지털 도서관에서 내려받은 저널의 한 쪽이다[8]. [그림 1](d)는 KISTI(Korea

Institute of Science and Technology Information)에서 제공하는 정보과학회 논문지의 한 쪽이다[9]. [그림 1](c)와 (d)는 현대적인 문서의 대표적인 형태를 보이고 있다. 1800년대 이후 서구에서 발간된 문서와 1950년대 이후 우리나라에서 발간된 문서의 대부분이 이러한 형태를 취하고 있다.

이러한 문서 영상에 대해 전문 검색이 가능한 시스템을 만들기 위해서는 우선 문서의 구조 분석(layout analysis)이 이루어져야 한다. 이 과정에서 텍스트와 비텍스트의 구분, 줄 분할, 단어 분할, 그리고 문자 분할이 수행된다. 이후에는 질의어를 문서 속의 단어와 정합(matching)하여 검색을 수행한다. 이때 단어 단위로 정합할 수도 있고 문자 단위로 정합할 수도 있다. 영어의 경우 단어 단위가 유리하다[10]. 하지만 한글의 경우 명사에 조사가 붙는 경우가 많고 띠어쓰기가 일정하지 않기 때문에 문자 단위가 유리하다[11]. 또한 한글의 경우 영어에 비해 단어에서 문자 분할이 비교적 쉽다.

영어 문서에 대해서는 많은 연구 결과가 발표되었다. 많은 연구가 NSF가 주관하고 미국 6개 대학이 주도한 디지털 도서관 선도 사업의 일환으로 수행되었다[12]. Xerox PARC는 UC Berkeley와 함께 Environmental Digital Library 프로젝트를 수행하였다[13]. 저품질 인쇄 문서에 사용할 수 있는 HMM에 기반한 방법[14], 영어 알파벳 각각의 크기 차이를 이용한 모양 코드 기법[10], 가설과 검증을 사용한 기법[15], OCR과 N-gram을 결합한 기법[16] 등이 있다. 대표적인 실용적인 시스템은 미국 SRI사에서 개발한 SCRIBBLE 시스템이다[17]. 이 시스템은 단어의 모양 특성을 사용하여 정합함으로써 품질이 낮은 문서 영상에 대해 강건하게 작동한다.

한글 문서에 대한 연구는 국내 문서 영상 처리 분야와 정보검색 분야의 연구자들이 수행하였다. 꽈희규는 검색기의 전처리부를 위해 단어 단위로 분할하고 단어별로 언어, 폰트, 스타일 등의 속성을 알아내는 시스템을 개발하였다[18]. 양진호는 두 종류의 특징을 이용하여 거친 검색 후 세밀한 검색을 하는 두 단계 검색 알고리즘을 개발하여 속도 향상을 꾀하였다[11]. 한글 OCR 소프트웨어로 인식을 한 후, 인식 오류를 견디는 알고리

즘을 사용하는 시스템도 개발되었다[19, 20].

3. 논문 요약

우리는 한글 문서 영상에 대해 전문 검색이 가능한 전체 시스템을 구축하였다. 전체 시스템은 문서 영상 검색에 필요한 모든 문서 영상 처리 모듈을 포함하고 있음을 의미한다. 우리 시스템은 크게 전처리부(preprocessing module), 인식부(recognition module), 그리고 검색부(retrieval module)로 구성된다.

상용 OCR 소프트웨어는 분할한 문자 각각에 대해 가장 잘 정합된 부류 하나만 출력한다. 이러한 1 순위 인식 결과를 사용하는 방법은 검색 성능에 한계를 가질 수밖에 없고, OCR 소프트웨어에 전적으로 의존한다는 문제를 안고 있다. 이러한 문제점을 극복하기 위해, 우리는 k 순위까지 사용하는 순위 기반 인식 방법을 제안한다. 이 방법은 인식 오류에 덜 민감한 장점을 가질 뿐만 아니라, 재현률과 정확률을 사용자가 조절할 수 있는 기능을 가능하게 해 준다.

실용성을 검증하기 위해, KISTI에서 서비스하고 있는 정보과학회 논문지 영상을 실험에 사용하였다. 이 데이터베이스는 1970년대에 출간된 저품질 문서부터 1990년대 출간된 고품질 문서까지를 포함하고 있어 성능 평가 기준으로 사용하기에 적합하다. 인식과 검색 실험을 통하여 시스템이 실용적으로 활용 가능함을 입증하였다.

II장에서는 시스템 구조와 특성을 개략적으로 소개한다. III장은 전처리부, IV장은 인식부, 그리고 V장은 검색부에 대해 그들이 사용하는 알고리즘에 대해 자세히 설명한다. VI장에서는 실험 결과를 제시하고 실제 응용 분야에서의 활용에 대해 토론한다. 마지막으로 VII장에서 결론을 기술한다.

II. 시스템 개요

1. 시스템 구조

우리 시스템은 크게 시스템 구축 측면과 사용자 운영 측면으로 나누어져 있다. 시스템 구축에서는 입력된 문

서 영상을 검색 가능한 형태로 변환하여 저장하는 역할을 수행하며 전처리부와 인식부로 나눌 수 있다. 사용자 운영에서는 사용자의 질의를 받아, 정합 과정으로 얻은 검색 결과를 사용자에게 보여준다. 전체적인 시스템 구조를 [그림 2]가 보여준다.

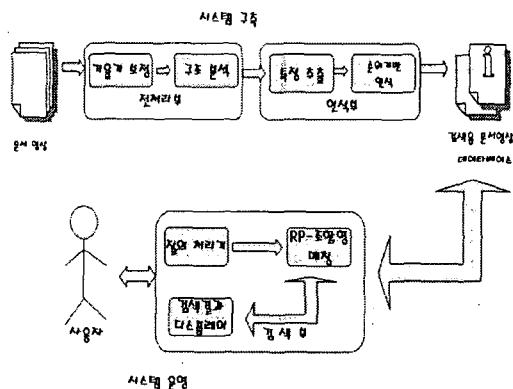


그림 2. 시스템 구조도

문자를 인식하기 위해서는 인식 대상이 되는 문자를 찾는 과정이 선행되어야 한다. 시스템의 전처리부는 문서 영상을 받아 기울기 교정, 텍스트와 비텍스트 영역 구분, 줄 분할, 단어 분할, 문자 분할을 수행한다. 인식부에서는 문자 단위로 특징을 추출하고, 이를 모델 문자와 정합하여 가장 잘 정합된 k개 부류로 분류하여 얻은 순위 기반 인식 결과를 검색용 데이터베이스에 저장한다.

검색부에서는 사용자가 입력한 질의어를 받아 검색을 시도하여 그 결과를 사용자에게 제시한다. 이때 재현률과 정확률을 조절할 수 있는 RP-조절형(recall and precision-controllable) 정합을 사용한다. 자세한 내용은 III~V장에서 다룬다.

2. 시스템 특성과 처리 가능한 문서 범위

우리 시스템은 다음과 같은 여러 장점을 가지고 있다.

- ① 전체 시스템으로 구현되어 있다. 전체 시스템을 구축하는 것은 개별 모듈을 개발하는 노력의 합보다 더 많은 노력과 시간을 필요로 한다. 현재 국내에서

전체 시스템을 개발하고, 실제적인 문서 영상 집합에 대해 객관적이고 엄밀한 성능 평가를 통해 실용성을 입증한 연구는 찾아볼 수 없다.

- ② 일반적으로 재현률과 정확률은 tradeoff 관계에 있는데, 우리 시스템에서는 사용자가 검색 목적에 따라 이들을 조절할 수 있다. 예를 들어, 놓치면 안 되는 중요한 단어를 검색 할 때에는 높은 재현률 모드로 설정하여 검색한 후 사후 검증 절차를 밟으면 된다.
- ③ 문자 인식 방법에 기반을 두고 있으나, k 순위까지의 인식 결과를 사용함으로써 인식 오류에 대한 강인함을 지니고 있다. 이 장인성으로 인해 높은 검색 성능을 유지할 수 있다.

문서 영상 처리 시스템의 성능은 문서의 형태와 영상의 품질에 큰 영향을 받는다. 예를 들어, 상용 한글 OCR 소프트웨어의 경우 품질에 따라 인식률이 50%~99%의 큰 편차를 보인다[20]. 따라서 제시한 시스템이 처리할 수 있는 문서의 범위를 가급적 구체적으로 제시할 필요가 있다. 우리 시스템은 다음과 같다.

- ① 언어 : 한글 인쇄체만 가능하다.
- ② 문서 형태 : [그림 1](d)과 같은 잘 포맷된 인쇄 문서를 다룬다. 다단 편집도 허용하며, 그림과 표를 포함한 문서도 처리할 수 있다. 원본 문서에 심한 얼룩이 있는 경우 그 부분을 그림으로 판단하는데, 그 이외의 부분에 있는 텍스트는 처리 가능하다.
- ③ 스캔 품질 : 300dpi 이상의 문서에 대해서는 실용적인 검색 성능을 제공한다. 스캐닝 과정에서 발생하는 문서 기울기는 자동으로 교정한다. 스캐닝 과정에서 심한 비선형 기하학적 왜곡이 발생하는 경우 처리가 어렵다.

III. 전처리

1. 기울기 보정

기울기 추정은 이현주 등이 제안한 방법을 사용하였는데[21]. 우선 수평 방향으로 화소 접합을 한다. 이를 위

해 수평 방향으로 흰 런(white run)을 구한 후, 임계값보다 짧은 런을 검은 화소로 채운다. 이렇게 하면 문서를 구성하는 대부분의 줄이 하나의 연결 요소를 형성하게 된다. 이 연결 요소에서 수직 방향으로 가장 낮은 곳에 있는 화소를 바닥 화소로 추출한다. 이들 바닥 화소는 선형 모양을 이루게 되는데, 이들을 직선으로 근사한다. 이렇게 얻은 직선들의 기울기 평균을 구하여, 이를 문서의 기울기로 한다.

이제는 추정한 기울기 각도 θ 에 따라 영상을 반대 방향으로 회전시켜 기울기를 교정한다. 각도를 θ 라 하고 $0 \leq \theta \leq \pi/4$ 라 하면, x 방향으로 $1/\tan(\theta)$ 화소마다 y 방향으로 한 화소 위로 밀려 있음을 의미한다. 따라서 $1/\tan(\theta)$ 화소마다 y 방향으로 한 화소를 아래로 내리면 된다. 만일 $-\pi/4 \leq \theta < 0$ 이면 반대로 한 화소를 위로 옮기면 된다. 같은 과정을 x와 y의 역할을 바꾸어 수행하면 기울기 교정이 끝난다.

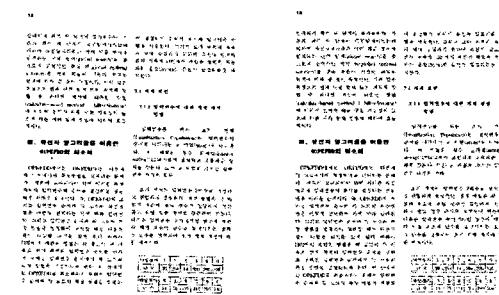


그림 3. 기울기 보정

2. 텍스트 영역 추출과 문자단위 분할

효과적인 검색 성능을 위해 아래 세 가지 기능을 염두에 두고, 새로운 알고리즘을 개발하였다.

- ① 다단 편집된 문서도 처리한다.
- ② 그림과 표를 텍스트와 구별한다.
- ③ 그림과 표 속에 들어있는 문자도 찾아낸다.

중에 가장 왼쪽 것을 첫 번째 사각형으로 하여 위의 과정을 반복한다. [그림 4](d)는 이 과정으로 분할된 결과를 보여준다.

[그림 5]는 또 다른 문자 단위 분할 결과를 보여 준다. 이 그림에서는 표 속의 문자들도 텍스트 영역으로 추출해 냈음을 확인할 수 있다.

그림 3 매체별 QoS 특성 및 가장 채널별로 펑에서 보장되는 CLR

매체의 종류	QoS 특성		CLR
	최저	TERmax	
비면접형	최저화장	비설시간	10 ⁻⁶
인체	텍스트	*	10 ⁻¹¹
현속성	입증비디오	설시간	10 ⁻⁸
매체	음성	*	3.34*10 ⁻⁴

●전송망은 ATM망으로서, AAI기종엔서는 인천 오류 회복 작업도 수행되지 않는다. 또한 응용에 포함된 각

그림 5. 표 안에 있는 텍스트의 분할

IV. 인식

앞 장에서 분할된 문자 영상 각각에 대해 특징을 추출한다. 이 특징 벡터를 모델 문자의 특징 벡터와 정합하여 정합 점수가 가장 높은 k 개 부류로 분류하고, 이 결과를 검색부가 사용할 수 있는 형태로 검색용 데이터베이스에 저장한다.

1. 특징 추출

분할된 문자는 [그림 6]과 같이 문서 작성에 사용한 폰트 크기, 스캔 해상도, 그리고 문자 부류에 따라 크기 변화가 크다. 때문에 특징 추출 이전에 크기 정규화 과정을 거쳐야 한다. 우리는 $m \times n$ 크기의 문자 영상 $P_{m \times n}$ 을 32×32 크기로 정규화한다. 문자 영상에 32×32 격자 메쉬를 써운 후, 이 메쉬에 속하는 사각형 각각에 대하여 그에 겹치는 P 영상의 화소들 값을 겹치는 비율에 따라 합산하여 그 사각형의 값을 구한다. 격자 메쉬

를 구성하는 모든 사각형에 대해 이 과정을 수행한 후 그들의 값이 [0..255] 사이에 분포하도록 정규화한다. 이렇게 함으로써 크기 정규화 과정에서 정보 손실을 적게 할 수 있다. [그림 6]은 정규화한 문자 영상을 보여 준다.

문자 인식을 위해서는 미리 특징을 추출해야 한다. 문자 인식에 사용할 수 있는 특징 추출 방법은 상당히 많이 발표되어 있다. 우리는 문자 인식과 단어 검색 응용에서 좋은 성능이 보고되어 있는 웨이브렛 특징을 사용한다[22, 23].

크기 정규화된 32×32 문자 영상에 Haar 커널을 적용하여 2단계 분해를 수행하였다. [그림 7]은 두 단계 분해를 실제 예제 영상으로 보여준다. O8은 저주파 영역으로서 원 영상이 압축된 정보를 갖는다. 이 영역을 2×2 의 16개 블록으로 나누고 각 블록에서 임계값 이상의 화소 수를 세어 그 값을 특징으로 취한다. 따라서 O8영역에서 총 16개의 특징값이 얻어지며, 각 특징은 [0..4] 사이의 값을 갖는다.

나머지 영역은 고주파 영역으로서, H, V, D로 표시되는데 각각은 수평 에지, 수직 에지, 대각선 에지 정보를 갖는다. H8영역을 2×2 의 16개 블록으로 나누고 각 블록에서 음수를 갖는 화소 개수와 양수를 갖는 화소 개수를 세어 각각을 특징으로 취한다.



(a) 정규화 이전

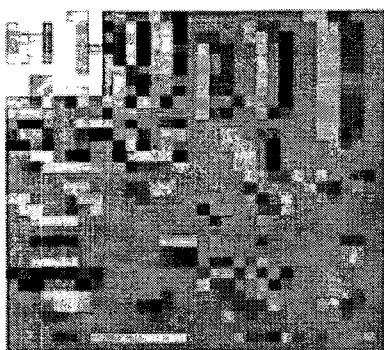


(b) 정규화 이후

그림 6. 다양한 크기의 문자 영상과 정규화 영상

O_8	H_8	H_{16}
V_8	D_8	
V_{16}	D_{16}	

(a) 분해 과정



(b) 분해된 문자 영상

그림 7. 32*32 영상의 두 단계 웨이블렛 분해

따라서 이 영역에서 총 32개의 특징이 추출되며, 각 특징은 [0..4] 사이의 값을 갖는다. V8과 D8에 대해서도 같은 과정을 거쳐 각각 32개의 특징을 추출한다. H16, V16, D16영역들은 4*4 크기의 블록으로 나누며, 특징 값은 같은 방법으로 계산한다. 따라서 이를 영역 각각에서 32개의 특징이 추출되며, 하나의 특징은 [0..16] 사이의 값을 갖는다.

이렇게 하여 총 208개의 특징을 추출하며, 이들은 208-차원의 특징 벡터로 표현된다.

2. 순위 기반 인식

기존 OCR 소프트웨어는 분할된 문자 각각에 대해 모델 문자와 정합을 시도하여 정합 점수가 가장 높은 부류 하나만 출력한다. 이렇게 1 순위만 사용하면, 저품질 문서에서 매우 낮은 인식률 때문에 실용적인 검색 성능을 얻을 수 없다. 또한 상용 한글 OCR 소프트웨어의 경우 인식률이 문서 종류와 품질에 따라 큰 편차를 보이며, 이러한 편차가 검색 성능에 직접적인 영향을 미친다

는 문제를 안고 있다.

우리는 이러한 문제점을 극복하기 위해, K 순위까지 출력하는 순위 기반 인식(rank-based recognition)을 한다. 이 방법은 인식 오류에 덜 민감한 장점을 가질 뿐만 아니라, 재현률과 정확률을 사용자가 조절할 수 있는 기능을 제공해 준다.

한글 2350자를 대상으로 모델 문자를 구축하였다. 모델 문자 영상은 한글 워드프로세서가 제공하는 명조체를 사용하여 만들었으며, 이를 영상으로부터 특징 벡터를 추출하여 모델 문자를 표현한다.

인식은 유클리디언 거리 분류기(Euclidean distance classifier)로 수행한다. 신경망 방법은 인식 순위를 정하는데 어려움이 있어 채택하지 않았다. 인식할 문자가 입력되면 특징 벡터를 추출하고, 이를 2350개의 모델 문자와 유클리디언 거리를 계산하고 가장 가까운 K개의 부류를 인식 결과로 출력한다.

3. 검색용 문서 데이터베이스 구축

인식 후에는 각각의 문자를 K개의 부류와 함께 검색용 데이터베이스에 저장한다. 또한 문서 영상에서 위치를 표시하기 위해 두 점의 좌표를 같이 저장한다. 따라서 문자 당 $2K+8$ bytes가 필요하다. 어떤 문서 영상 한 쪽에 1000개의 문자가 있고 $K=100$ 이라면, 약 200 Kbytes가 필요하다. KISTI 문서에서 한 쪽 영상이 보통 50 Kbytes이므로 총 250 Kbytes의 메모리가 필요하다.

III장의 전처리와 IV장의 인식은 시스템 구축 과정에서 오프라인으로 사전에 수행하므로 사용자의 검색 속도에 영향을 미치지 않는다.

V. 검색

검색용 데이터베이스가 이미 준비되어 있으므로, 검색 단계에서는 문자열 정합(string matching)만 필요하다. 문자열 정합 알고리즘의 속도가 검색 반응 시간에 직접적인 영향을 미치므로 빠른 알고리즘 설계가 매우 중요하다.

1. RP~조절형 정합

사용자는 K 순위까지 저장된 인식 결과 중에서 몇 순위까지 사용할지를 입력한다. 사용자가 설정한 순위를 k라 하면, $k \leq K$ 이다. k가 크면 정합 조건이 느슨해지므로 재현률이 높고 정확률이 낮은 특성을 갖고, 반대로 k가 작으면 재현률이 낮고 정확률이 높은 특성을 보인다. 우리는 이러한 기능을 RP-조절형(recall and precision-controllable) 검색이라 부른다.

O(1)에 탐색이 가능하다.

한 문서 영상이 n 개의 문자를 가지고 있고 질의어가 m 개의 문자를 갖는다 하자. 보통 n은 수천~수만 정도이고 m은 2~12정도가 된다. 질의어를 문서 영상에서 찾는 문제는 문자열 정합 문제이다. 우리는 계산 복잡도가 m과 무관하게 O(n)을 갖는 KMP 알고리즘을 사용하였다[24]. 따라서 영상 한 쪽을 검색하는데 필요한 계산 복잡도는 O(nk)이고, 불린 변수를 사용하면 O(n)이 된다.

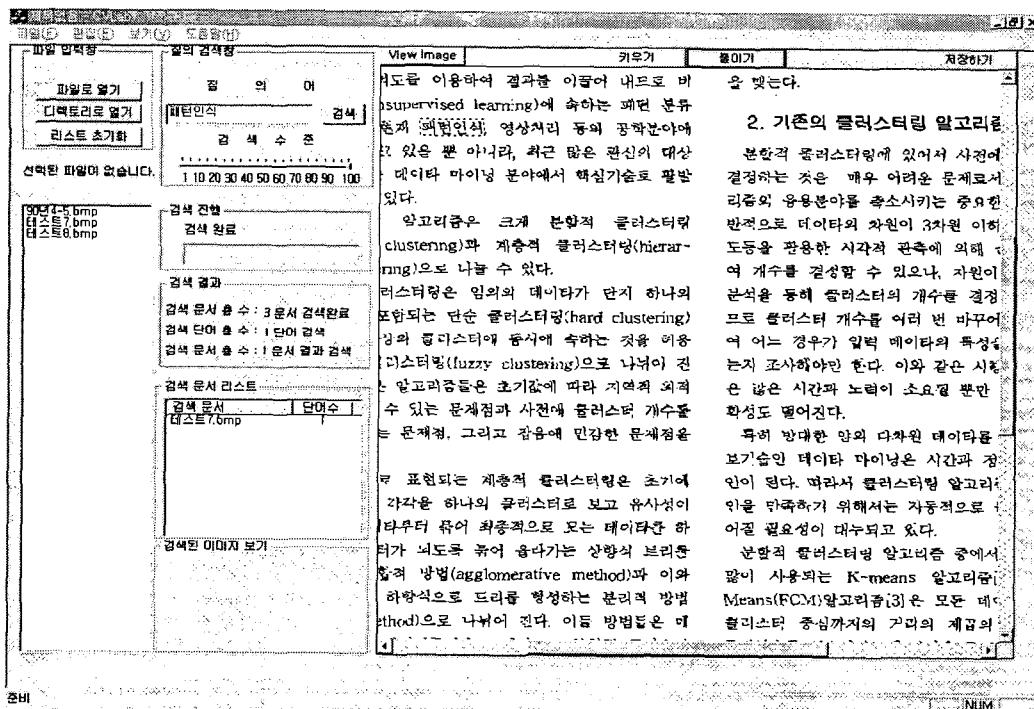


그림 8. 시스템 화면과 검색 결과

이와 더불어 사용자는 질의어를 입력한다. 질의어를 구성하는 문자를 q 라 하고 문서 내에서 현재 정합 대상이 되는 문자를 t 라 하자. t 의 k 순위 이내에 q 가 존재하면 정합이 성공했다고 한다. q 가 k 개 요소를 갖는 리스트 안에 있는지를 판단해야하므로 문자 정합을 위한 계산 복잡도는 $O(k)$ 이다. 메모리를 더 사용할 수 있다면, 주어진 k 에 대하여 2350개의 문자 각각에 불린 변수를 할당하여 리스트에 속하는 부류에 대해 참으로 설정하면

2. 검색 인터페이

[그림 8]은 우리 시스템의 구조와 작동을 보여준다. 화면은 크게 세 부분으로 나뉘어 진다. 맨 왼쪽은 문서 파일 관리 창이다. 문서를 파일 단위와 폴더 단위로 입력할 수 있도록 하였다. 가운데 창에는 질의어를 입력하는 부분과 RP-조절 막대를 두어 사용자가 k 값을 1부터 100사이에서 조절할 수 있게 하였다. 또한 가운데 아래 부분에는 검색된 문서들의 이름을 리스트 박스에 출

력하여 사용자가 선택할 수 있게 하였다. 오른쪽에는 검색된 영상을 보여주며, 확대 축소 기능을 갖고 있다. 검색된 단어에 상자를 씌워 사용자가 쉽게 확인할 수 있도록 했다. 이 그림에서는 질의어가 “페턴 인식”이고 문서 왼쪽 위 부분에서 하나의 단어를 찾아 표시하고 있다.

VI. 실험 결과와 토의

1. 실험 방법

객관적인 성능 평가를 위해서는 공인된 기관에서 제작한 문서 영상 데이터베이스를 사용해야 한다. 우리는 KISTI에서 내려받기 서비스하고 있는 정보과학회 논문지 영상을 실험에 사용하였다. 이 데이터베이스는 1974~1998년도에 정보과학회에서 출간한 논문지에서 1749개 논문을 스캔하여 tiff 형태로 저장한 것이다. 스캐닝은 300dpi로 수행되었다.

객관적인 성능 평가와 시스템의 활용 가이드라인을 설정하기 위해, 문서를 세 종류로 나누었다. 대략 1970년대에 출간된 저품질 문서, 1980년대에 출간된 중품질 문서, 그리고 1990년대에 출간된 고품질 문서로 나누어 실험하였다. [그림 9]는 각각에 대한 예제 영상을 보여준다. 저품질인 경우 획의 끊어짐이 심함을 볼 수 있다. 순위 기반 인식률과 검색 성능을 측정하기 위해 각 범주에 속하는 영상을 10장씩 임의로 선택하였다. 이를 영상에 대해 k에 따른 인식률과 검색률을 측정하여 표와 그래프로 제시한다.

電機에 의해 人力되는 信號의 解析은 受信號
議譯 인터페이스를 통하여 만들어지는 計數값을
가지고 判斷 處理한다. 이 과정은 그림 2의 계
동도에 표시된 바와 같이 크게 네부분으로 分類
되며 이의 동작은 각각 다음과 같다.

(i) 待機가 성一 人力信號를 感知하는 部分으로

(a) 저품질 (1979년 출간)

그러나 연구가 진행됨에 따라 이 방법에는 한계가 노출되었다. 그 후 Georgetown 대학이 개발한 시스템은 핵 물리학에 관한 텍스트를 소련어에서 영어로 번역하는데 사용되고 있다. 이 시스템의 최근 version인 SYSTRAN은 현재

(b) 중품질 (1985년 출간)

사용자 인터페이스뿐만 아니라 얼굴에 관한 여러 가지 다른 분야에서 요구되고 있다. 예를 들어 인식은 신분 증명, 보안 시스템, 인사 자료에 수 있으며, 치안 분야에서는 범인을 색출하기 위해 각 부분의 그림이나 사진을 보여 주면서 유사

(c) 고품질 (1997년 출간)

그림 9. KISTI의 정보과학회 논문지 영상

표 3. 10 순위까지의 인식률

(단위: %)

K	고품질	중품질	저품질
1	54.1	45.6	34.9
2	70.8	62.5	47.1
3	76.3	70.3	54.6
4	82.2	75.1	60.3
5	85.3	78.1	63.6
6	85.8	80.0	66.3
7	86.0	82.2	68.3
8	88.0	83.5	70.0
9	88.7	84.7	71.6
10	89.0	85.3	73.5

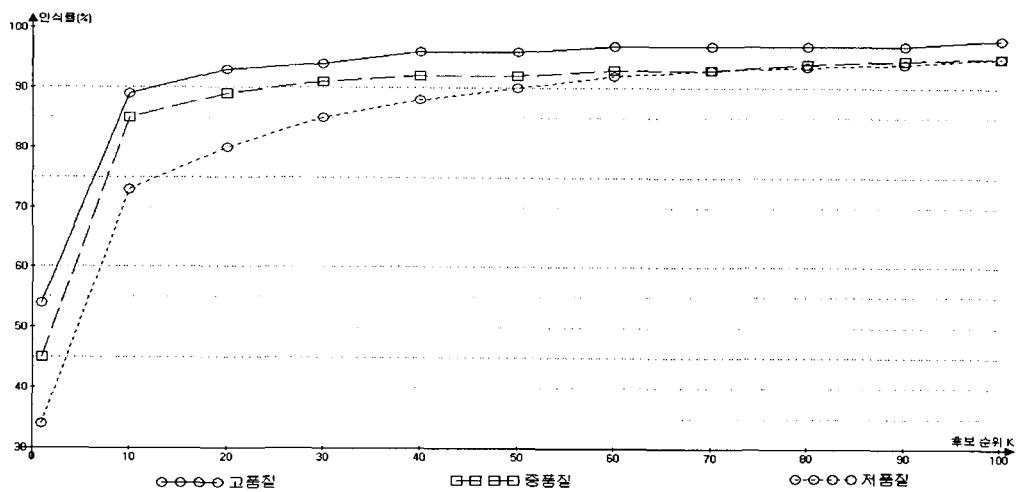


그림 10. 100 순위까지의 인식률 추이

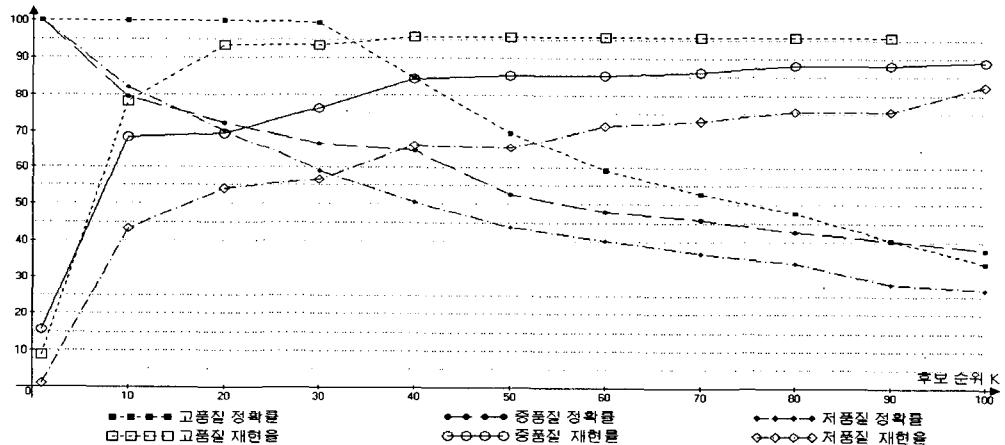


그림 11. 100 순위까지의 검색 성능 추이

표 4. 10 순위까지의 검색 성능

(단위: %)

K	고품질		중품질		저품질	
	재현률	정확률	재현률	정확률	재현률	정확률
1	8.7	100	15.7	100	1.4	100
2	37.0	100	32.4	100	10.8	100
3	43.5	100	37.3	100	16.2	100
4	43.5	100	43.1	100	23.0	94.4
5	52.2	100	49.0	98.0	25.7	95.0
6	52.2	100	49.0	98.0	27.0	90.1
7	52.2	100	53.9	96.5	29.7	91.7
8	68.1	100	61.8	92.6	32.4	80.0
9	76.1	100	65.7	89.3	36.5	80.0
10	78.3	100	68.6	79.5	43.2	82.1

2. 실험 결과

실험 결과는 아래와 같이 세 가지로 나누어 제시한다.

① 글자 분할 성공률

III장의 글자 분할 모듈의, 분할 성공률을 [표 2]가 보여준다. 한글에 대해서만 측정한 결과이다. III장의 [그림 4](d)와 [그림 5]를 보면 다른 문자에 속하는 획이 서로 붙은 경우 분할 오류가 많다. 저품질과 중품질 문서의 경우 획의 끊어짐이 많아 오류율이 높다.

표 2. 글자 분할 성공률

(단위: %)

고품질	중품질	저품질
97.9	95.8	91.8

② 순위 기반 인식률

[표 3]은 K를 1부터 10까지 증가시키며 측정한 인식률을 보여준다. [그림 10]은 K를 5에서 시작하여 5씩 증가시키며 100까지의 인식률을 추이를 보여준다. 인식률은 분할이, 성공적으로 된 글자 영상에 국한하여 측정하였다.

고품질 문서의 경우 10 순위 인식률이 87%이고, 50 순위에서 97%, 그리고 100순위에서 98% 이다. 저품질은 각각 73%, 92%, 95%로 고품질에 비해 현저히 떨어짐을 알 수 있다.

③ 검색 성능

[표 4]는 k를 1부터 10까지 증가시키며 측정한 재현률과 정확률이다. [그림 11]은 k를 5에서 시작하여 5씩 증가시키며 100까지의 재현률과 정확률의 변동 추이를 보여준다. 재현률과 정확률은 분할을 실패한 단어들도 감안한 것으로, 사용자 측면에서 측정한 자료이다.

고품질의 경우 30 순위까지는 정확률 100%를 유지하며 재현률이 꾸준히 증가한다. 30순위에서 정확률 100%, 재현률 93%로서 높은 검색 성능을 보였다. 40순위에서 재현률 96%를 얻었으며, 이후에는 재현률 개선 없이 정확률만 떨어지는 현상을 보였다. 저품질의 경우 재현률 80%를 얻기 위해서는 100순위까지 허용해야하며, 이때 정확률은 30%에 머물렀다. 10순위에서 정확률은 82%에 달하였는데, 이때 재현률은 43%이었다.

3. 활용에 대한 토론

우리 시스템은 전체 시스템으로 구성되어 있으므로 실제 응용 분야에 곧바로 투입할 수 있는 강점을 가진다. 활용에 대한 가이드라인을 몇 가지 관점에서 제시한다.

① 성능 범위

KISTI에서 제공하는 실제 문서 영상에 대한 실험 결과로 실용성을 입증하였다. 이들 영상은 1990년 중반에 스캐닝하였으며, 그 이후 스캐닝 기술이 발달하여 잡음과 해상도 등의 품질 면에서 그때보다 뛰어나고 저장 장치 기술의 발전으로 훨씬 고품질의 스캐닝이 가능해졌다. 따라서 앞에서 제시한 [그림 9]의 문서 품질과 성능 평가 결과를 감안하면, 다른 기관의 문서 영상에 대해서도 실용적인 성능이 가능함을 예측할 수 있다.

② 문서 범위

우리 시스템이 처리할 수 있는 범위는 [그림 1](d)와 같은 잘 포맷된 문서 영상이다. 개략적으로 말하면, 서구에서는 1800년대 이후에 인쇄된 서적, 우리나라에서는 1950년 이후 인쇄된 서적들이 이러한 범주에 속한다 할 수 있다. 이러한 문서를 보유하고 있는 기관은 크게 보아 정부 부서(특허청, 정부기록보존소, 역사편찬위원회 등의 소장 서적), 대학교(석박사 논문, 보고서, 행정 문서 등), 학회(발간 논문지와 학회지 등), 기업 등이 있다. 따라서 우리 시스템을 적용할 수 있는 대상은 매우 방대하다 할 수 있다. 우리 시스템에서 원본 문서 영상 집합만 대처해주면 다른 기관의 문서에 대해서도 곧바로 적용 가능하다.

③ 색인과 비색인 활용

현재 구축된 시스템은 색인 기능이 없다. 따라서 어떠한 질의어라도 허용하는 개방형 어휘(open vocabulary) 모드로 작동한다. 응용에 따라 이러한 활용이 가능한 응용 분야가 있는가 하면, 속도 제약 때문에 미리 색인해 놓아야 하는 응용 분야도 있다. 우리 시스템에 색인기를 추가하는 것이 향후 연구 과제 중의 하나이다.

④ 적합도 순위화

우리 시스템은 전문 검색이 가능하므로 검색 결과를

적합도(relevance) 산정에 활용할 수 있다. 가장 간단한 방법은 어떤 논문에 대해 전문 검색을 한 후, 찾은 단어수에 비례하도록 적합도를 부여하는 것이다. 좀 더 진보된 방법으로서, 우선 “요약”, “서론”, “결론” 등의 질의 어로 논문의 의미적인 구조를 알아낸 후 단어가 어느 부분에 포함되었는지를 고려하여 적합도를 산정하는 기법을 고려할 수 있다.

VII. 결 론

예전 아날로그 문서와 현재 디지털 문서에 대한 접근 방식의 차이로 인해 발생할 문제점을 지적하고, 이를 해결하는데 일조할 수 있는 한글 문서 영상 검색 시스템을 제시하였다. 이 시스템은 한글 특성에 따라 설계되었으며, 전체 시스템으로 구현하여 유용성을 높였다. 공인된 기관의 문서 영상 데이터베이스에 대한 체계적인 실험 결과를 바탕으로 실제 응용 영역에서 사용할 수 있음을 보였다.

가장 중요한 향후 연구는 개별 모듈의 성능을 개선하여 전체 시스템의 검색 성능을 향상시키는 것이다. 현재, 보다 높은 인식률을 얻기 위해 특징 추출과 특징 선택에 대한 연구가 진행 중이다. 목표는 문서 품질에 따라 인식 오류를 30~50% 줄이는 것이고, 이 목표가 성공적으로 달성되면 검색 오류도 자연히 크게 줄어들 것이다. 또 다른 향후 연구는 색인기를 개발하여 추가하는 것이다.

참 고 문 헌

- [1] 김태수, 최석두, 유양근, 정준민 역, 디지털 도서관, 사이텍미디어, 2000.
- [2] 오일석, 김수형, 유태웅, 곽희규, “문서 영상 처리 기술과 디지털 도서관”, 정보과학회 학회지, 제20권 제8호, pp.24~34, 2002.
- [3] M.S. Kim, M.D. Jang, and J.H. Kim, “Digitalization system of historical

documents using recognition and rejection method,” Proceedings of the 2nd KAIST-Tsinghua Joint Workshop on Pattern Recognition, KAIST at Daejeon, pp.57~63, 2003.

- [4] D. Doermann, “The indexing and retrieval of document images: A survey,” Computer Vision and Image Understanding, Vol.70, No.3, pp.287~298, 1998.
- [5] M. Mitra and B.B. Chaudhuri, “Information retrieval from documents: a . survey,” Information Retrieval, pp.141~163, 2000.
- [6] <http://www.nl.go.kr>
- [7] <http://kyujanggak.snu.ac.kr>
- [8] <http://ieeexplore.ieee.org/Xplore/DynWel.jsp>
- [9] <http://www.kisti.re.kr>
- [10] A.L. Spitz, “Shape-based word recognition,” International Journal on Document Analysis and Recognition, Vol.1, No.4, pp.178~190, 1999.
- [11] 양진호, 두 단계 검색 방법을 이용한 인쇄 한글 단어의 고속 검색, 전북대학교 석사학위 논문, 2002.
- [12] IEEE Computers, Special issue on Digital Library Initiative, Vol.29, No.5, 1996.
- [13] G.E. Kopec, “Document image decoding in the Berkeley digital library,” Proceedings of ICIP, pp.769~772, 1996.
- [14] S. S. Kuo and O.E. Agazzi, “Keyword spotting in poorly printed documents using pseudo 2-D hidden Markov models,” IEEE Trans. on Pattern Analysis and Machine Intelligence, Vol.16, No.8, pp.842~848, 1994.
- [15] J. Zhu, T. Hong, and J.J. Hull, “Image-based keyword recognition in Oriental language document images,” Pattern Recognition, Vol.30, No.8, pp.1293~1300, 1997.

- [16] C.L. Tan, et al., "Imaged document text retrieval without OCR," IEEE Trans. on Pattern Analysis and Machine Intelligence, Vol.24, No.6, pp.838~844, 2002.
- [17] "SCRIBBLE: SRI's keyword spotting system, "<http://www.erg.sri.com/projects/scribble>
- [18] 곽희규, 문서 영상의 단어 단위 분할 및 단어 영상의 속성 추출에 관한 연구, 전북대학교 박사학위논문, 2001.
- [19] 이준호, 이충식, 한선희, 김진형, "문자 인식에 의해 구축된 한글 문서 데이터베이스에 대한 정보 검색", 한국정보처리학회 논문지, 제6권, 제4호, pp.833~840, 1999.
- [20] 안재철, OCR 소프트웨어를 이용한 한글 문서 검색 시스템, 전북대학교 석사학위 논문, 2002.
- [21] 이현주, 최영우, "화소 접합을 이용한 문서영상 기울기 측정", 9회 영상처리 및 이해에 관한 워크숍, 경주, pp.125~129, 1997.
- [22] Y.Y. Tang et al., Wavelet Theory and Its Application to Pattern Recognition, World Scientific, 2000.
- [23] 김혜금, 양진호, 이진선, 오일석, "웨이브렛을 이용한 영상 기반 인쇄 한글 단어 검색", 정보과학회 논문지(SA), Vol.28, No.2, pp.91~103, 2001.
- [24] E. Horowitz, S. Sahni, and D. Mehta, Fundamentals of Data Structures in C++, Computer Science Press, New York, 1995.

김 우연(Woo-Yen Kim)

준회원



- 2004년 : 전북대학교 컴퓨터공학과 학사
- 2004년 2월~현재 : 전북대학교 컴퓨터정보학과 석사과정
- <관심분야> : 문서영상 처리, 패턴인식

오 일석(Il-Seok Oh)

정회원



- 1984년 : 서울대학교 컴퓨터공학과 학사
- 1992년 : KAIST 전산학과 박사
- 1992년 9월~현재 : 전북대학교 전자정보공학부 교수
- <관심분야> : 문서영상 처리, 패턴인식, 유전알고리즘의 패턴인식 응용

저자 소개

이 득용(Duk-Ryoung Lee)

준회원



- 2004년 8월 : 전북대학교 전자정보공학부 학사
- 2004년 9월~현재 : 전북대학교 컴퓨터정보학과 석사과정
- <관심분야> : 문서영상 처리, 패턴인식