

문자 인식을 이용한 한글 문서 검색

안재철*, 오일석**

전북대학교 컴퓨터과학과

*jcan@cs.chonbuk.ac.kr, **isoh@moak.chonbuk.ac.kr

Hangul Document Retrieval Using Character Recognition

Jae-Cheol Ahn, Il-Seok Oh

Department of Computer Science, Chonbuk National University

요 약

이 논문은 OCR(Optical Character Reader)로 인식된 한글 문서에서의 오인식 경향을 분석하고, 이를 이용한 한글 단어 검색 방법을 제안한다. OCR로 인식된 많은 양의 한글 문서를 기반으로 자모별 인식 빈도수를 계산하고 이를 바탕으로 초성, 중성, 종성별 인식 혼동 행렬(confusion matrix)을 구성하였다. 또한 인식 정보를 적절히 이용하기 Bayes 정리를 이용하였다. 질의어에 대한 오인식 단어의 검색 방법을 제시하고 혼동 행렬과 이 검색 방법을 바탕으로 OCR 기반 단어 검색 시스템을 구축하였다.

1. 서 론

급속히 발전하는 정보화 시대에 있어 유용한 정보를 빠르고 정확하게 접근하는 방법은 개인이나 단체 또는 기업의 성과를 좌우할 정도로 중요하다. 유용한 정보를 손쉽게 접근할 수 있는 방법으로 현재 디지털 라이브러리 등과 같은 정보검색 시스템의 구축은 정보화 사회에 있어 그 필요성이 날마다 부각되고 있다. 하지만 기존의 방대한 양의 인쇄 문서들을 전자 문서들로 변환하여 데이터 베이스화 하는 작업은 시스템 구축의 가장 큰 걸림돌이 되고 있을 뿐만 아니라, 비싼 전문 노동력과 많은 비용을 필요로 한다[1]. OCR(Optical Character Reader)은 이러한 문제를 해결하기 위한 기술로 인쇄 문서들을 전자 문서로 자동 전환하여 수작업을 통한 입력 방법보다 시간과 노동력에 대한 비용을 횡천 줄일 수 있다. 하지만 이 기술 또한 오인식을 수반하며, 오인식을 수반하는 문서에서의 정보 검색은 검색 성능의 저하를 유발시키는 가장 큰 요인이 된다. 따라서 문서 인식과 결부된 효과적인 오인식 단어의 검색 방법은 OCR를 이용하는 많은 부분에 있어 그 연구의 필요성이 중요하다 할 수 있다.

현재 문서 내의 질의어 검색에 관한 연구로는 영상 기반과 OCR 기반 방법이 제안되고 있다. 영상 기반 방법으로는 영문 문서의 각 문자 영상을 모양 특징(shape feature)으로 인코딩 한 후 스트링 매칭을 시도하는 방법[2]과 영문 문서에 대해 모양 코드를 정의 한 후 문서 영상에서 단어를 검색하는 방법이 있다[3]. 한글에 대해서도 웨이블렛(wavelet)의 특징을 이용하는 방법과 단어 영상에서의 프로파일의 특징을 추출하여 검색에 응용하려는 시도가 있었다[4, 5].

OCR 기술과 결부된 오인식 단어의 검색 방법으로는 OCR로 인식된 영문 문서 내에서 오인식 빈도의 정보로 구성된 혼동 행렬과 문자의 삽입, 삭제, 결합, 분해의 정보를 지닌 확장 혼동 행렬을 이용한 오인식 단어의 검색 방법이 이미 제안되었다[6]. Marukawa[7]등은 일본어에 대해 혼동 행렬을 이용한 질의어 확장 검색 방법과 인식 과정에 있어 모호성을 가지는 문자에 대해 다중 후보 문자를 출력하여 검색하는 방법을 제안하고 있다. 한글 문서에 대해서는 오인식 문자를 포함하는 문서에서의 형태소 단위 색인법과 2-gram 기반 색인법 그리고 혼동 행렬을 이용한 단어의 검색에 대한 연구가 있었다[8, 9].

본 논문은 인쇄 한글 문서에서 단어 검색을 위해 혼동 행렬을 구성하고, 이에 기반한 검색 방법에 대해 제안한다. 또한 디지털 라이브러리 등에 응용 할 수 있는 계기를 마련하고자, 논문의 구성 요소별 단어 출현 빈도수를 세어 이를 기반으로 문서의 적합성을 측정할 수 있는 시스템을 구축하였다.

이 논문의 2장에서는 OCR 소프트웨어가 발생하는 오인식 오류의 유형에 대해 설명하고, 한글과 영문의 오류 유형을 비교하였다. 3장에서는 한글 OCR 소프트웨어를 이용하여 오인식을 범하는 자모별 초성, 중성, 종성에 대한 혼동 행렬의 구성 방안과 문자 인식 시스템의 혼동 확률(Confusion probability)을 구하기 위해 사용된 Bayes 정리를 설명한다. 4장에서는 혼동 행렬을 이용한 오인식 단어 검색 방법에 대해서 기술하고, 3장에서 구성된 혼동 행렬을 이용하여 단어 검색 성능을 5장에서 측정한다. 6장에서는 결론 및 향후 연구를 기술한다.

2. OCR 소프트웨어의 오인식 오류의 유형

일반적으로 OCR를 사용하여 얻은 인식 자료를 분석해 보면 다음과 같은 오류들을 찾아 볼 수 있다.

1) 대치 오류(Substitution error) : 원문 영상의 문자가 다른 문자로 인식됨

2) 실종 오류(Missing error) : 원문 영상의 문자가 삭제됨

3) 추가 오류(Insertion error) : 원문 영상에 없는 문자가 추가됨

4) 조합 오류(Combination error) : 두 개 이상의 문자가 결합됨

5) 분해 오류(Decomposition error) : 원문 영상의 문자가 분해됨

인식 자료의 분석에 의하면 한글의 경우 대치 오류가 대부분이며, 영상 품질이 낮을수록 실종 오류나 분해 오류 또는 주가 오류가 많아 발생하였다. 한글은 문자들의 조합 오류가 거의 발생하지 않으며, 영문과 다르게 문자의 조합으로 인해 간혹 발생하였다. 이와 같은 이유로 본 논문에서는 한글 문자의 실종, 추가, 조합, 분해 오류에 대한 정보를 사용하지 못하고, 가장 많이 발생하는 대치 오류만을 고려하여 시스템을 구성하고 실험을 하였다.

3. 자모 단위의 혼동 행렬

이 장에서는 한글 OCR 소프트웨어를 이용하여 오인식을 범하는 자모별 초성, 중성, 종성에 대한 인식 혼동 행렬의 구성 방안과 이 혼동 행렬을 적절히 이용하기 위해 사용된 Bayes 정리에 대해 설명한다. 혼동 행렬을 구성하기 위해 현재 인식률 면에서 좋은 평가를 받고 있는 아르미 5.0 전문가용을 이용하였다[10]. 인식 대상 문서로는 정보과학회 1996-1997년에 출판된 논문지 영상 535건을 KORDIC 원문 서비스(<http://society.kordic.re.kr>)에서 받아 사용하였다. 혼련 테

이터의 개별 문자 인식률은 92.56%이다.

오인식 문자를 검색하기 위한 가장 좋은 방법은 사용 빈도수가 큰 한글 2350 자에 대한 혼동 행렬을 구성하는 것이다. 하지만, 이 행렬은 구성을 위해 많은 양의 훈련 데이터가 필요하고, 훈련 데이터가 적으면 적용수록 회소 행렬이 된다는 문제점을 지니고 있다. 또한 훈련되지 않은 오인식 문자에 대해서는 검색을 하지 못하는 단점을 가지고 있다. 이러한 문제점을 해결하기 위해 본 논문에서는 그림 2와 같은 자모별 초성, 중성, 종성간에 영향이 없다고 가정하고 이를 각각을 독립적으로 처리한다. 그럼 1(a) 원문 영상에 대한 사실 자료(ground truth data)를 그림 1(b)가 보여주고 있으며, 이를 OCR 인식한 결과 인식 자료(recognition data)를 그림 1(c)가 보여준다.

3.1 자모 단위 혼동 행렬의 구성 방안

이 절에서는 혼동 행렬의 구성 방안에 대해서 설명한다. 이 행렬은 인식 시 초성, 중성, 종성간에 영향이 없다고 가정하고 이를 각각을 독립적으로 처리한다. 그럼 1(a) 원문 영상에 대한 사실 자료(ground truth data)를 그림 1(b)가 보여주고 있으며, 이를 OCR 인식한 결과 인식 자료(recognition data)를 그림 1(c)가 보여준다.

요약 본 논문에서는 기존의 분산 드롭백선 처리 시스템에서 발생되는 교차 상태 험시의 문제점을 지적하고, 교차 상태 문제를 근본적으로 해결하기 위해 본산 사이트 담당자 기반으로 하는 새로운 행렬 계이 기법을 제시하였다. 이와 같은 행렬 계이 기법의 문제점과 해결 방안을 기술하였고, 본산 교차 상태 험시 방식을 이용하여 자료를 사용하는 드롭백선 사이트에 순차성을 보장하였다. 또한 시뮬레이션을 통해 기존의 2-단계 로깅 기법과 새로운 방통 계이 기법의 성능을 비교하였다.

(a) 원문 영상

* VOL-B-23NC6-4.TXT *

요약 본 논문에서는 기존의 분산 드롭백선 처리 시스템에서 발생되는 교차 상태 험시의 문제점을 지적하고, 교차 상태 문제를 근본적으로 해결하기 위해 본산 사이트 담당자 기반으로 하는 새로운 행렬 계이 기법을 제시하였다. 이와 같은 행렬 계이 기법의 문제점과 해결 방안을 기술하였고, 본산 교차 상태 험시 방식을 이용하여 자료를 사용하는 드롭백선 사이트에 순차성을 보장하였다. 또한 시뮬레이션을 통해 기존의 2-단계 로깅 기법과 새로운 방통 계이 기법의 성능을 비교하였다.

(b) 사실자료(ground truth data)

* VOL-B-23NC6-4.TXT *

요약 본 논문에서는 기존의 분산 드롭백선 처리 시스템에서 발생되는 교차 상태 험시의 문제점을 지적하고, 교차 상태 문제를 근본적으로 해결하기 위해 본산 사이트 담당자 기반으로 하는 새로운 행렬 계이 기법을 제시하였다. 이와 같은 행렬 계이 기법의 문제점과 해결 방안을 기술하였고, 본산 교차 상태 험시 방식을 이용하여 자료를 사용하는 드롭백선 사이트에 순차성을 보장하였다. 또한 시뮬레이션을 통해 기존의 2-단계 로깅 기법과 새로운 방통 계이 기법의 성능을 비교하였다.

(c) 인식자료(recognition data)

그림 1. 예제 문서 영상과 인식자료.

ㄱ	ㄴ	ㄷ	ㄹ	ㅁ	ㅂ	ㅅ	ㅇ	ㅈ	ㅊ	ㅋ	ㅌ	ㅎ
ㄱ	ㄴ	ㄷ	ㄹ	ㅁ	ㅂ	ㅅ	ㅇ	ㅈ	ㅊ	ㅋ	ㅌ	ㅎ
7	20	19	0	53	4	5	0	15	3	10	94	3
80	52	0	0	1	1	0	0	1	2	0	0	0
15	6704	7	1	21	4	1	0	1	4	10	2	0
37	2	7711627	10	37	4	7	0	4	1	16	26	11
0	0	0	1	65	3	21	1	2	0	0	0	0
112	2	17	8	3	1166	6	10	0	4	24	50	0
20	0	12	00	33	67	5922	61	0	0	21	4	0
24	2	56	108	114	99	14,849	9	5	0	10	12	2
4	1	8	0	3	6	3	83	0	2	1	0	0
177	6	43	2	1	8	2	4	10,889	57	14	22	0
4	2	0	1	1	0	0	2	0	5	290	0	0
106	6	25	85	103	175	1299	25	1	44	6,38700	33	0
93	2	0	8	0	67	4	16	16	7	0	10,402	121
3	0	0	0	0	1	0	0	0	0	0	1	92
11	1	1	0	0	7	2	3	0	18	5	3	3025
27	2	1	6	0	35	1	6	0	0	1	2	0
1	0	8	73	4	27	1	4	0	2	2	1	7
65	6	2	3	11	46	0	89	0	2	8	2	3
57	5	4	15	24	206	21	15	2	4	5	26	39

그림 2. 초성 인식 혼동 행렬

이 사실 자료와 인식 자료를 한자씩 비교하여 한글 초성, 중성, 종성에 대한 인식 혼동 행렬을 구성하였다. 이중 초성에 대한 인식 혼동 행렬을 그림 2가 보여주고 있다. 그림 2의 첫 번째 행(column)은 사실 자료의 자음이고, 첫 번째 열(row)은 인식 자료의 자음이다. 'ㄱ'의 경우 총 18243번 발생하여 그중 17717개를 정인식 하여 97.12%의 정인식률(substitution error)를 범한 자음을 의외로 'ㅍ'이었다. 그 이유는 충성 'ㄱ'과 '-'에 많은 영향을 받은 것으로 추정할 수 있다. 가장 많은

오인식이 발생한 경우는 'o'이 'ㅁ'으로 대체된 경우이며, 반대로 'ㅁ'이 'o'으로 대체된 경우는 적은 편이었다. 이외에도 'ㅎ'이 'ㅊ'으로 'ㄷ'이 'ㅍ'으로 오인식 된 경우와 'ㄱ'이 'ㄹ'로 오인식 된 경우도 많이 찾아볼 수 있었다. 가장 오인식률이 높은 자음은 'ㄱ'으로, 정인식 보다 오인식이 더 많이 발생한 경우이다.

3.2 Bayes 정리를 이용한 문자 인식 시스템의 혼동 확률

이 절에서는 실제 문자 인식 시스템의 혼동 확률(Confusion Probability)을 구하기 위해 Bayes 정리를 이용하였다. 문자 인식 시스템에서 입력된 사실 자료의 자모를 A 라 하고, 사실 자료에 대한 인식 자료의 자모를 B 라 하면, 인식 자료의 자모 B 가 사실 자료의 자모 A 될 확률은 Bayes의 정리에 의해 $P(A|B)$ 와 같이 표현 할 수 있으며, 자모 순서에 따라 표 1과 같이 다시 표현 할 수 있다. 가령 A_i 는 그림 2의 자음 중 사실 자료의 i 번째 자음을 B_i 는 인식 자료의 j 번째 자음이라 하면, 인식 자료의 B_j 번째 자음이 사실 자료의 A_i 번째 자음이 될 확률 $P(A_i|B_j)$ 는 표 1의 식 1과 같이 표현 할 수 있다. 실제 $P(B_j|A_i)$ 와 $P(A_i)$ 을 계산하기 위해 그림 2와 같이 구성된 자모 단위의 초성, 중성, 종성 인식 혼동 행렬을 이용하였다. 그림 3은 그림 2와 같은 자모 단위의 인식 혼동 행렬과 식 1을 이용해 구성한 행렬의 구조를 보인다.

표 1. Bayes 정리의 해석

$P(A_i|B_j) : B_j$ 라고 인식한 것이 A_i 일 확률.

$P(B_j|A_i) : A_i$ 를 B_j 라고 인식하는 확률.

$P(A_i) : A_i$ 의 출현 빈도율.

$P(B_j) : P(B_j|A_i) \times P(A_i) + P(B_j|A_i^c) \times P(A_i^c).$

$P(B_j|A_i^c) : A_i$ 를 B_j 로 오인식하는 확률.

$P(A_i^c) : 1 - P(A_i).$

$$P(A_i|B_j) = \frac{P(B_j|A_i) \cdot P(A_i)}{P(B_j)} \quad \text{식(1)}$$

B_j = 인식자료의 j 번째 자모

A_i	B_1	B_2	B_3	\dots	B_n
A_1	$P(A_1 B_1)$	$P(A_1 B_2)$	$P(A_1 B_3)$	\dots	$P(A_1 B_n)$
A_2	$P(A_2 B_1)$	$P(A_2 B_2)$	$P(A_2 B_3)$	\dots	$P(A_2 B_n)$
A_3	$P(A_3 B_1)$	$P(A_3 B_2)$	$P(A_3 B_3)$	\dots	$P(A_3 B_n)$
\vdots	\vdots	\vdots	\vdots	\dots	\vdots
A_n	$P(A_n B_1)$	$P(A_n B_2)$	$P(A_n B_3)$	\dots	$P(A_n B_n)$

그림 3. Bayes 정리를 이용한 혼동 행렬의 구성

4. 검색 방법

본 논문의 검색 알고리즘은 3.2절에서 구축해 놓은 혼동 행렬을 사용한다. 혼동 행렬은 OCR이 범하는 오류의 형태와 빈도수를 제공하기 때문에 이에 기초하여 알고리즘을 설계하는 것은 타당성을 갖는다. 혼동 행렬의 구성과 계산한 알고리즘은 문자간의 의존성보다 자료간의 의존성을 중시하여 설계하였다. 검색 대상은 OCR이 범하는 오류 종 카운터를 중심으로 한다. 식 3과 4는 매칭 알고리즘을 설명한다.

표 2. 자모별 혼동 행렬에 대한 매칭 점수 계산

$$Q = \langle q_1, q_2, \dots, q_k \rangle = \langle (a_1, b_1, c_1), (a_2, b_2, c_2), \dots, (a_k, b_k, c_k) \rangle$$

$$T = \langle t_1, t_2, \dots, t_k \rangle = \langle (x_1, y_1, z_1), (x_2, y_2, z_2), \dots, (x_k, y_k, z_k) \rangle \quad \text{식(3)}$$

$$\text{Score}(Q, T) = \frac{\prod_{i=1}^k (\text{초}[ai][xi] \times \text{중}[bi][yi] \times \text{종}[ci][zi])}{\prod_{i=1}^k (\text{초}[ai][ai] \times \text{중}[bi][bi] \times \text{종}[ci][ci])} \quad \text{식(4)}$$

검색은 사용자가 제시한 질의어와 오인식 문자를 포함한 문서에서의 단어 검색을 수행한다. 질의어 단어를 Q , 목적 단어를 T 라 하면 식 3과 같이 표시할 수 있다. 여기서 q_i 와 t_i 는 한 문자를 나타내고

a_i, b_i, c_i 는 q_i 의 초성, 중성, 종성을 x_i, y_i, z_i 는 t_i 의 초성, 중성, 종성을 나타낸다. 매칭 값은 질의어의 신뢰도에 대한 오인식 단어의 신뢰도를 상대적인 비율로 식 4와 같이 표현하였다. 단어 검색을 위해 사용자가 입력한 매칭 값보다 검색된 단어의 매칭 값이 큰 경우 이를 적합한 단어로 간주하고 검색하게 된다.

논문 [9]에서는 검색된 단어의 매칭 값을 구하기 위해 식 4에서 사용한 Π 와 \times 대신에 Σ 와 $+$ 연산을 사용하였다. 논문 [9]의 연산 방식은 질의어와 형태적으로 유사한 단어 이외에도 매칭 값이 유사한 단어들까지도 검색하게 되는 문제점이 있어 단어 검색 시 정확률을 떨어뜨리는 요인으로 적용하고 있다. 하지만 식 4는 글의 연산을 사용하여 질의어와 검색된 단어 사이의 자모가 하나라도 혼동 행렬의 0인 값을 참조하면, 검색 단어의 매칭 값이 0이 되어 검색 시 제외가 된다. 즉, 이것은 형태적으로 유사한 단어 외에 매칭 값이 유사한 단어들을 제외시켜 정확률을 유지하게 한다.

5. 검색 성능 측정

본 논문은 단어 검색 실험을 위해 KORDIC에서 1996년도 정보과학회 논문지 6편을 다운 받아 이를 아로마로 인식 후 테스트 문서로 사용하였다. 단어 검색을 위한 매칭 값은 7부터 0.4까지 0.2씩 줄여가면서 그 성능을 확인해 보았다. 질의어로 10개의 단어를 입으로 신청하여 오인식 문자를 포함한 문서에서의 검색을 수행한 후 그림 4와 같은 검색 성능을 얻었다. 그림 4에서도 알 수 있듯이 정확률의 순서이 거의 없이 재현율이 계속 증가함을 보이고 있다.

$$\text{재현율} = (\text{검색된 적합 단어의 수}) / (\text{적합 단어의 총 수})$$

$$\text{정확율} = (\text{검색된 적합 단어의 수}) / (\text{검색된 단어의 총 수})$$

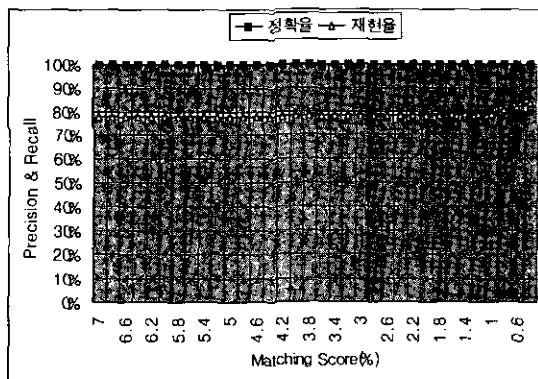


그림 4. 테스트 문서에 따른 검색 성능

표 2. 매칭 값이 100%와 0.4%일 경우의 검색 성능

	완전 매칭 (매칭 값=100 %)	매칭 값=0.4 %
정확율	100	99.94
재현율	76.55	83.98

표 2는 매칭 값이 100일 때와 0.4일 때의 재현율과 정확율을 보여 준다. 표 2에서 알 수 있듯이 검색 단어를 완전 매칭하여 검색하는 방법보다 혼동 행렬을 구성하여 검색하는 방법이 더 효과적임을 증명하고 있으며, 실현 결과 혼동 행렬과 Bayes 정리를 이용하여 완전매칭보다 약 8%의 재현율을 높였다.

6. 검색 시스템의 구현

그림 5는 실제 이 실험에 사용된 단어 검색 시스템으로, 질의어로 “트랜잭션”과 매칭 값으로 0.4를 주어 검색한 결과이다. 출력은 검색된 단어들을 보여주고 있으며, 오인식 단어에 대해서 표시를 해주고 있다. 우측은 검색된 문서의 번호, 부류, 정확율과 재현율을 보여주고 있다. 또한 문서를 구성하는 부류별 검색 단어의 수를 보여 준다. 이의 정보는 Elsevier ScienceDirect 등과 같은 디지털 라이브러리의 구축 시 검색된 문서의 적합성을 판단하기 위해 아주 중요한 정보로 사용될 수 있다.

부류	검색 단어	정확율		재현율	
		정확율	재현율	정확율	재현율
VOL_D	서울	0.01	0.01(0.01)	1.0000	1.0000
VOL_D	서울	0.07	0.05(0.05)	1.0000	0.7143
VOL_D	서울	0.07	0.03(0.03)	1.0000	0.0000
VOL_E	제작	0.02	0.02(0.02)	1.0000	1.0000
VOL_E	제작	0.13	0.13(0.13)	0.9333	0.9333
VOL_E	제작	0.25	0.25(0.25)	0.8667	0.8667
VOL_E	제작	0.25	0.25(0.25)	0.8000	0.8000
VOL_E	제작	0.17	0.14(0.14)	1.0000	0.8235
VOL_F	제작	0.01	0.01(0.01)	1.0000	1.0000
VOL_F	제작	0.02	0.02(0.02)	1.0000	1.0000
VOL_F	제작	0.14	0.14(0.14)	1.0000	1.0000
VOL_F	제작	0.22	0.21(0.21)	1.0000	0.8545
VOL_A	제작	0.11	0.09(0.09)	1.0000	0.5655
VOL_A	제작	0.03	0.01(0.01)	1.0000	0.3333
VOL_B	제작	0.01	0.01(0.01)	1.0000	1.0000
VOL_B	제작	0.05	0.05(0.05)	1.0000	1.0000
VOL_B	제작	0.05	0.05(0.05)	1.0000	1.0000

그림 5. OCR 기반 단어 검색 시스템

7. 결론

본 논문은 OCR 기반 인쇄 한글 문서에서 단어 검색을 위해 인식 혼동 행렬을 구성하고, 이의 정보를 적절히 사용하기 위해 Bayes 정리를 이용하였다. 이에 기반한 단어 검색 방법에 대해 제안했고, 실제 디지털 라이브러리 등에 활용 할 수 있는 계기를 마련하고자, 논문의 구성 요소별 단어의 출현 빈도수를 세고, 이를 기반으로 문서의 적합성을 측정할 수 있는 시스템을 구축하였다.

참고 문헌

- [1] 김태수, 유양근, 정준민, 최석주, 디지털 도서관, 사이텍미디어, 2000.
- [2] Y. Tanaka and H. Torii, "Transmedia machine and its keyword search over image texts," *Proc. RIAO*, pp. 248-258, 1988.
- [3] A. Lawrence Spitz, "Shape-based word recognition," *International Journal on Document Analysis and Recognition*, pp. 178-190, 1999.
- [4] 김혜금, 최윤근, 오일석, "웨이블렛 다중-규모 공간에서 한글단어의 매칭 성능 분석," 한국정보과학회 춘계 학술발표논문집, 제26권, 제1호, pp. 558-560, 1999.
- [5] 전영범, 오일석, "대용량 인쇄 한글 문서 검색을 위한 영상 기반 단어 매칭 방법," 한국정보과학회 추계 학술발표논문집, 제27권, 제2호, pp. 461-463, 2000.
- [6] M. Ohta, A. Takasu, and J. Adachi, "Retrieval Methods for English-Text with Misrecognized OCR Characters," *Proceedings of 4th International Conference on Document Analysis and Recognition*, Vol. 2, pp. 950-955, 1997.
- [7] K. Marukawa, T. Hu, H. Fujisawa, and Y. Shima, "Document retrieval tolerating character recognition errors-evaluation and application," *Pattern Recognition*, Vol. 30, No. 8, pp. 1361-1371, 1997.
- [8] 이준호, 이충식, 한선화, 김진형, "문자 인식에 의해 구축된 한글 문서 데이터베이스에 대한 정보 검색," 한국정보처리학회논문지, 제6권, 제4호, pp. 833-840, 1999.
- [9] 안재철, 오일석, "한글 OCR 소프트웨어의 오류 분석과 단어 검색 예의 응용," 제4회 문자인식 워크샵 발표 논문집, pp. 77-89, 2000.
- [10] 함산 컴퓨터, 아르미 5.0 사용 설명서, 함산 컴퓨터(주), 2000.