

조건부 엔트로피의 최소화를 통하여 인식기의 집합을 결정하는 방법

강희중^o

한성대학교 컴퓨터공학과
hjkang^o@hansung.ac.kr

Determination of the Group of Classifiers by Minimizing the Conditional Entropy

Hee-Joong Kang^o

Department of Computer Engineering, Hansung University

요 약

패턴인식 문제를 다루는 연구에서 인식 성능을 향상시키고자 베이스 에러율의 상한인 조건부 엔트로피를 응용하는 시도가 있었다. 본 논문에서는 다수의 인식기로 구성된 다수 인식기 시스템이 우수한 성능을 보이도록 인식기의 집합을 결정하는 문제에서 이러한 조건부 엔트로피의 최소화를 통하여 시도한 방법과 다른 방법들을 간단하고 분명한 예제를 통하여 비교, 분석해 보았다. 다수 인식기의 결합 방법으로 대표적인 투표 기법과 조건부 독립 가정의 베이지안 기법을 사용하였으며, 조건부 엔트로피의 최소화를 통하여 인식기의 집합을 결정하는 방법에 대한 유용성을 확인할 수 있었다.

1. 서 론

어려운 패턴인식 문제를 다루는 연구에서 다수의 인식기가 병렬로 구성된 다수 인식기 시스템을 사용하여 인식 성능을 높여주는 연구가 수행되어 왔는데[1,2,3,4], 그 중에서 베이스 에러율의 상한인 조건부 엔트로피를 최소화하는 방식으로 다수의 인식기를 결합하는 연구 결과가 있었다[2]. 이러한 다수 인식기 시스템의 인식 성능은 결합 방법은 물론 선택되는 인식기에 따라 달라질 수 있기 때문에, 결합 방법에 대한 연구뿐만 아니라, 인식기를 선택하여 인식기의 집합을 만드는 방법에 대한 연구도 수행되어 왔던 것이다. 다수 인식기의 선택에 관한 연구, 즉, 어떻게 선택해야 하는가에 관한 문제와 얼마나 많이 선택해야 하는가에 관한 문제는 다수 인식기 시스템을 구축하는데 있어서 중요한 문제로 여겨져 왔다[3,4]. Woods 등은 다수 인식기의 집합을 결정하는데 있어서, 인식기의 선택 전략이 필요한 이유를 적은 수의 인식기들이 더 많은 수의 인식기들 보다 더 우수한 성능을 보인다는 점에서 설명하였다[5].

본 논문에서는, 다수의 인식기로 구성된 다수 인식기 시스템에서 우수한 성능을 보이도록 인식기의 집합이 어떻게 결정되어야 하는가에 관한 문제를 [6]에서 소개된 바와 같이 조건부 엔트로피의 최소화를 통하여 시도한 방법을 다른 방법들과 간단하면서도 분명한 예제를 통하여 비교, 분석해 보고자 한다. 여기에서는 [6]에서와 같이 다수 인식기의 선택 문제를 완화하기 위하여 선택되는 인식기의 개수는 미리 정해져 있다고 가정하지 않는다. 선택된 인식기의 집합은 대표적인 투표 기법과 조건부 독립 가정의 베이지안 기법을 사용하여 결합되었으며,

그 성능을 비교, 분석해 보았다.

2. 관련 연구

다수의 인식기를 선택하여 인식기의 집합을 만드는 관련 연구로는 초기에 선택하려는 인식기의 개수가 미리 지정되어 있다는 가정 하에서 시도된 연구로부터 정보이론에 기초하여 좀 더 유망한 인식기의 집합을 결정하려는 연구가 있었다[6]. 특히, [6]에서는 베이스 에러율의 상한인 조건부 엔트로피를 최소화하여 인식기를 선택하도록 하는 선택 기준이 제안되었다. Patridge와 Yates가 제안한 과생산 및 선택 (overproduction and choose) 방법론에 기초하여, 다수의 인식기를 먼저 만들고, 적절한 전략에 의하여 유망한 인식기를 선택하자는 연구 결과도 있다[4]. 이 경우에 인식기를 선택하는 기준으로서 인식기 간의 다양성(diversity) 기준을 정의하여 사용하였으며, 클러스터링 방법을 통하여 실험적으로 특정한 개수의 가급적 상호 보완적인 인식기들의 집합을 만들도록 시도하였다. 그렇지만, 이러한 방법들에 의해서 결정된 인식기의 집합이 반드시 우수한 성능을 보인다고 보장할 수 없었다. 따라서, 여전히 유망한 인식기의 집합을 결정하는 문제는 중요한 이슈로 남아 있다. 인식기 간의 다양성 기준으로는 Kuncheva 등이 제안한 Q statistic, Roli와 Giacinto가 제안한 CD (compound diversity), 강희중이 제안한 조건부 엔트로피의 최소화에 기반한 클래스-결정 상호정보 $U(L;E)$ 등이 있다[4,6]. 여기서, L 은 클래스를, E 는 인식기들의 결정을 나타낸다. 또한, Roli와 Giacinto는 인식기의 집합 간의 다양성을 결정하기 위하여 $diversity()$ 라는 기준을 정의하였다. 이들 다양성

기준에 대해서는 3.장에서 자세히 다루도록 한다.

3. 인식기 간의 다양성 기준

Kuncheva 등이 제안한 Q statistic은 아래 식과 같다. 먼저, 두 인식기 간의 다양성을 식 (1)과 같이 계산하며, 3개 이상의 인식기로 구성된 인식기의 집합에 대해서는 식 (2)와 같이 가능한 두 인식기의 쌍에 대한 Q statistic 값들의 합을 구하고, 그 합을 해당 인식기의 집합에 있는 가능한 인식기 쌍의 수로 나누는 평균 Q statistic 값을 사용하였다. 여기서 N^{11} 은 두 인식기 i, j 가 모두 제대로 맞춘 경우의 데이터 개수이며, N^{00} 은 두 인식기가 모두 틀린 경우의 수이다. 또한, N^{01} 과 N^{10} 은 두 인식기 중의 하나만 제대로 맞춘 경우의 수이다. 그리고, ${}_3C_2$ 는 3개에서 2개를 뽑는 경우의 수인 조합을 나타내는 것으로, 앞에 나온 아래 첨자가 인식기의 집합에 있는 인식기의 개수를 나타낸다. 따라서, 인식기의 개수가 달라지면, 이 아래 첨자의 값이 달라지게 된다.

$$Q_{i,j} = \frac{N^{11}N^{00} - N^{01}N^{10}}{N^{11}N^{00} + N^{01}N^{10}} \quad (1)$$

$$Q_{i,j,k} = \frac{\sum Q_{a,b}}{{}_3C_2} \quad (2)$$

그리고, Roli와 Giacinto가 제안한 CD (compound diversity) 기준은 두 인식기 E_i 와 E_j 에 대하여 식 (3)과 같이 정의되는데, 이들 인식기가 각각 속한 두 인식기의 집합인 A 와 B 에 대한 다양성 기준은 식 (4)와 같이 정의된다.

$$CD(E_i, E_j) = 1 - \text{prob}(E_i \text{ fails}, E_j \text{ fails}) \quad (3)$$

$$\text{diversity}(A, B) = \max_{E_i \in A, E_j \in B} CD(E_i, E_j) \quad (4)$$

끝으로, 강희중이 제안한 조건부 엔트로피의 최소화에 기반한 클래스-결정 상호정보 $U(L;E)$ 는 식 (5)에 정의된 베이스 에러율 P_e 의 상한인 조건부 엔트로피 $H(L|E)$ 로부터 유도되며, K 개의 인식기들에 대한 클래스-결정 상호정보를 계산한다고 가정할 때, 식 (6)과 같이 정의된다. 여기서 $H()$ 는 주어진 변수의 엔트로피를 의미한다.

$$P_e \leq \frac{1}{2}H(L|E) = \frac{1}{2}[H(L) - U(L;E)] \quad (5)$$

$$U(L;E_1, \dots, E_K) = \sum_e \sum_l P(e_1, \dots, e_K, l) \log \frac{P(e_1, \dots, e_K | l)}{P(e_1, \dots, e_K)} = H(L) + H(E_1, \dots, E_K) + \sum_e \sum_l P(e_1, \dots, e_K, l) \log P(e_1, \dots, e_K, l) \quad (6)$$

4. 인식기의 집합을 결정하는 예제와 비교, 분석

3.장에서 소개한 인식기 간의 다양성 기준을 기준으로 인식기를 선택하는 방법을 비교, 분석하기 위하여 5개의 가상 인식기 E_1, E_2, E_3, E_4, E_5 를 정의하고, 5개의 가상 클래스 A, B, C, D, E 를 정의한다. 또한, 가상의 인식기는 한 클래스만을 출력한다고 가정하고, 조건부 독립 가정의 베이지안 (CIAB) 결합 기법을 위하여 훈련 데이터와 테스트 데이터가 모두 동일하며, 5개의 데이터는 5개

의 가상 클래스로 이루어져 있다고 가정한다. 앞으로 소개될 예제에서는 다양한 인식 성능과 다양한 개수의 인식기로 구성된 인식기의 집합을 구성하고, 구성된 인식기의 집합에 대한 성능을 평가하기 위하여 대표적인 투표 기법과 조건부 독립 가정의 베이지안 (CIAB) 기법을 사용하였다.

먼저 EX-1 예제는 5개의 가상 인식기들이 표 1과 같이 20%의 인식율을 보이는 인식 결과를 지닌다고 가정한다. 다수 인식기 시스템을 위하여 고려되는 인식기의 집합은 1에서부터 최대 5개까지가 될 수 있다.

표 1 EX-1 예제의 20% 인식기 결과표

| 데이터 | 인식기 | | | | |
|-----|-------|-------|-------|-------|-------|
| | E_1 | E_2 | E_3 | E_4 | E_5 |
| A | A | B | C | D | E |
| B | A | B | C | D | E |
| C | A | B | C | D | E |
| D | A | B | C | D | E |
| E | A | B | C | D | E |

이러한 가정 하에서, 인식기의 개수를 늘려 가면서 각 인식기의 선택 기준을 적용했을 때 얻어지는 계산 값을 보면 표 2와 같다. $U(L;E)$ 값은 인식기의 개수에 상관없이 모두 0 (즉, $1/5 * \log(1/5) * 5 - \log(1/5) = 0$) 이었다. 그리고, Q statistic과 diversity()는 인식기가 1개 인 경우를 제외한 모든 경우에 대해서 각각 -1과 0.4 이었다. 인식기가 1개 인 경우에는 Q statistic과 diversity()을 계산할 수 없기 때문에 해당 사항이 없다는 '-' 기호를 나타내었다. 각 인식기의 집합에 대해 얻을 수 있는 가상의 최고 인식율 (pl)과 사용된 두 결합 기법에 대한 인식율을 보면 표 3과 같다.

표 2 EX-1 예제에서 인식기 개수의 변화에 따른 각 인식기 선택 기준의 계산 결과표

| 인식기의 수 | $U(L;E)$ | Q statistic | diversity() |
|--------|----------|-------------|-------------|
| 1 | 0 | - | - |
| 2 | 0 | -1 | 0.4 |
| 3 | 0 | -1 | 0.4 |
| 4 | 0 | -1 | 0.4 |
| 5 | 0 | -1 | 0.4 |

표 3 EX-1 예제에서 인식기 개수의 변화에 따른 가상의 인식율과 결합 기법의 인식 성능

| 인식기의 수 | pl | 투표 기법 | CIAB 기법 |
|--------|-----|---------|---------|
| 1 | 20 | 20 | 0,20 |
| 2 | 40 | 0,20,40 | 0,20 |
| 3 | 60 | 0 | 0,20 |
| 4 | 80 | 0 | 0,20 |
| 5 | 100 | 0 | 0,20 |

위 표 3에서 3개 이상으로 이루어진 인식기의 집합인 경우에 가상의 최고 인식율은 60%이고, 투표 기법으로 결합될 경우에 0%인 반면에, CIAB 기법으로 결합되도 잘해야 인식율이 20%가 됨을 알 수 있다. 그러나, 가상의 최고 인식율은 현실적 연기가 거의 불가능하다. 각 결합 기법에서 인식율이 여러 개로 표현된 경우는 1등으로 인식된 클래스가 해당 결합 기법에서 타이(tie)인 경우를 어떻게 처리하느냐에 따라서 인식 성능이 달라질 수 있음을 보인 것이다. 이 경우에 어느 개수로 인식기의 집합을 만드는 것이 인식 성능에 좋은 지는 결정할 수 없다.

다음에 EX-2 예제는 5개의 가상 인식기들이 표 4와 같이 40%의 인식율을 보이는 인식 결과를 지닌다고 가정한다. 이러한 가정 하에서, 인식기의 개수를 늘려 가면서 각 인식기의 선택 기준을 적용했을 때 얻어지는 계산 값을 보면 표 5와 같다. 인식기의 개수가 1인 경우에 $U(L;E)$ 값은 계산된 근사치로 0.5004 (즉, $-(4/5 * \log(4/5) + 1/5 * \log(1/5)) \approx 0.5004$) 이고, 인식기의 개수가 2개 인 경우에는 0.9503 (즉, $-(3/5 * \log(3/5) + 1/5 * \log(1/5) * 2) \approx 0.9503$) 이며, 3개 인 경우에는 1.3322 (즉, $-(2/5 * \log(2/5) + 1/5 * \log(1/5) * 3) \approx 1.3322$), 4개 이상인 경우에는 1.6094 (즉, $-(1/5 * \log(1/5) * 5) \approx 1.6094$) 이다. 그리고, Q statistic과 diversity()는 인식기가 1개 인 경우를 제외한 모든 경우에 대해서 각각 1/3과 0.6 이었다. 각 인식기의 집합에 대해 얻을 수 있는 가상의 최고 인식율과 두 결합 기법에 대한 인식율을 보면 표 6과 같다.

표 4 EX-2 예제의 40% 인식기 결과표

| 데이터 | 인식기 | | | | |
|-----|----------------|----------------|----------------|----------------|----------------|
| | E ₁ | E ₂ | E ₃ | E ₄ | E ₅ |
| A | A | B | C | D | A |
| B | B | B | C | D | E |
| C | A | C | C | D | E |
| D | A | B | D | D | E |
| E | A | B | C | E | E |

표 5 EX-2 예제에서 인식기 개수의 변화에 따른 각 인식기 선택 기준의 계산 결과표

| 인식기의 수 | U(L;E) | Q statistic | diversity() |
|--------|--------|-------------|-------------|
| 1 | 0.5004 | - | - |
| 2 | 0.9503 | 1/3 | 0.6 |
| 3 | 1.3322 | 1/3 | 0.6 |
| 4 | 1.6094 | 1/3 | 0.6 |
| 5 | 1.6094 | 1/3 | 0.6 |

표 6 EX-2 예제에서 인식기 개수의 변화에 따른 가상의 인식율과 결합 기법의 인식 성능

| 인식기의 수 | pl | 투표 기법 | CIAB 기법 |
|--------|-----|----------|--------------|
| 1 | 40 | 40 | 40 |
| 2 | 60 | 20,40,60 | 40,60,80,100 |
| 3 | 80 | 40 | 60,80,100 |
| 4 | 100 | 60 | 100 |
| 5 | 100 | 100 | 100 |

위 표 6에서 4개로 이루어진 인식기의 집합인 경우에 가상의 최고 인식율은 100%이고, 투표 기법으로 결합될 경우에 60%인 반면에, CIAB 기법으로 결합되면 인식율이 100%가 됨을 알 수 있다. 아울러, 표 5에서도 Q statistic과 diversity()는 인식기의 수에 변함이 없는 반면에, $U(L;E)$ 는 CIAB 기법이 100%가 되는 4개의 인식기의 집합이 될 때까지 증가함을 알 수 있다. 따라서, 이 경우에 결합 기법으로 CIAB 기법이 사용된다고 가정하면, 4개의 인식기의 집합으로 만드는 것이 인식 성능 측면에서 바람직하다고 볼 수 있다.

다음 EX-3 예제는 5개의 가상 인식기들이 표 7과 같이 60%의 인식율을 보이는 인식 결과를 지닌다고 가정한다. 이러한 가정 하에서, 인식기의 개수를 늘려 가면서 각 인식기의 선택 기준을 적용했을 때 얻어지는 계산 값을 보면 표 8과 같다. 인식기의 개수가 1인 경우에 $U(L;E)$ 값은 계산된 근사치로 0.9503 (즉, $-(3/5 * \log(3/5) + 1/5 * \log(1/5) * 2) \approx 0.9503$) 이고, 2개 인 경우에는 1.3322 (즉, $-(2/5 * \log(2/5) + 1/5 * \log(1/5) * 3) \approx 1.3322$) 이며, 3개 이상인 경우에는 1.6094 (즉, $-(1/5 * \log(1/5) * 5) \approx 1.6094$) 이다. 그리고, Q statistic과 diversity()는 인식기가 1개 인 경우를 제외한 모든 경우에 대해서 각각 1/3과 0.8 이었다. 역시 각 인식기의 집합에 대해 얻을 수 있는 가상의 최고 인식율과 두 결합 기법에 대한 인식율을 보면 표 9와 같다.

표 7 EX-3 예제의 60% 인식기 결과표

| 데이터 | 인식기 | | | | |
|-----|----------------|----------------|----------------|----------------|----------------|
| | E ₁ | E ₂ | E ₃ | E ₄ | E ₅ |
| A | A | B | C | A | A |
| B | B | B | C | D | B |
| C | C | C | C | D | E |
| D | A | D | D | D | E |
| E | A | B | E | E | E |

표 8 EX-3 예제에서 인식기 개수의 변화에 따른 각 인식기 선택 기준의 계산 결과표

| 인식기의 수 | U(L;E) | Q statistic | diversity() |
|--------|--------|-------------|-------------|
| 1 | 0.9503 | - | - |
| 2 | 1.3322 | 1/3 | 0.8 |
| 3 | 1.6094 | 1/3 | 0.8 |
| 4 | 1.6094 | 1/3 | 0.8 |
| 5 | 1.6094 | 1/3 | 0.8 |

표 9 EX-3 예제에서 인식기 개수의 변화에 따른 가상의 인식율과 결합 기법의 인식 성능

| 인식기의 수 | pl | 투표 기법 | CIAB 기법 |
|--------|-----|----------|-----------|
| 1 | 60 | 60 | 40,60 |
| 2 | 80 | 40,60,80 | 60,80,100 |
| 3 | 100 | 60 | 100 |
| 4 | 100 | 100 | 100 |
| 5 | 100 | 100 | 100 |

위 표 9에서 3개로 이루어진 인식기의 집합인 경우에 가상의 최고 인식율은 100%이고, 투표 기법으로 결합될 경우에 60%인 반면에, CIAB 기법으로 결합되면 인식율이 100%가 됨을 알 수 있다. 아울러, 표 8에서도 Q statistic과 diversity()는 인식기의 수에 변함이 없는 반면에, U(L;E)는 CIAB 기법이 100%가 되는 3개의 인식기의 집합이 될 때까지 증가함을 알 수 있다. 따라서, 이 경우에 결합 기법으로 CIAB 기법이 사용된다고 가정하면, 3개의 인식기의 집합으로 만드는 것이 인식 성능 측면에서 바람직하다고 볼 수 있다.

끝으로 EX-4 예제는 5개의 가상 인식기들이 표 10과 같이 80%의 인식율을 보이는 인식 결과를 지닌다고 가정한다. 이러한 가정 하에서, 인식기의 개수를 늘려 가면서 각 인식기의 선택 기준을 적용했을 때 얻어지는 계산 값을 보면 표 11과 같다. 인식기의 개수가 1인 경우에 U(L;E) 값은 계산된 근사치로 1.3322 (즉, $-(2/5 * \log(2/5) + 1/5 * \log(1/5) * 3) \approx 1.3322$) 이며, 2개 이상인 경우에는 1.6094 (즉, $-(1/5 * \log(1/5) * 5) \approx 1.6094$) 이다. 그리고, Q statistic과 diversity()는 인식기가 1개 인 경우를 제외한 모든 경우에 대해서 각각 -1과 1 이었다. 각 인식기의 집합에 대해 얻을 수 있는 가상의 최고 인식율과 두 결합 기법에 대한 인식율을 보면 표 12와 같다.

표 10 EX-4 예제의 80% 인식기 결과표

| 데이터 | 인식기 | | | | |
|-----|----------------|----------------|----------------|----------------|----------------|
| | E ₁ | E ₂ | E ₃ | E ₄ | E ₅ |
| A | A | B | C | D | A |
| B | B | B | C | D | E |
| C | C | C | C | D | E |
| D | D | B | D | D | E |
| E | A | B | C | E | E |

표 11 EX-4 예제에서 인식기 개수의 변화에 따른 각 인식기 선택 기준의 계산 결과표

| 인식기의 수 | U(L;E) | Q statistic | diversity() |
|--------|--------|-------------|-------------|
| 1 | 1.3322 | - | - |
| 2 | 1.6094 | -1 | 1 |
| 3 | 1.6094 | -1 | 1 |
| 4 | 1.6094 | -1 | 1 |
| 5 | 1.6094 | -1 | 1 |

표 12 EX-4 예제에서 인식기 개수의 변화에 따른 가상의 인식율과 결합 기법의 인식 성능

| 인식기의 수 | pl | 투표 기법 | CIAB 기법 |
|--------|-----|-----------|---------|
| 1 | 80 | 80 | 60,80 |
| 2 | 100 | 60,80,100 | 100 |
| 3 | 100 | 100 | 100 |
| 4 | 100 | 100 | 100 |
| 5 | 100 | 100 | 100 |

위 표 12에서 2개로 이루어진 인식기의 집합인 경우에 가상의 최고 인식율은 100%이고, 투표 기법으로 결합될 경우에 3가지의 인식 성능을 보인 반면에, CIAB 기법으로 결합되면 인식율이 100%가 됨을 알 수 있다. 아울러, 표 11에서도 Q statistic과 diversity()는 인식기의 수에 변함이 없는 반면에, U(L;E)는 CIAB 기법이 100%가 되는 2개의 인식기의 집합이 될 때까지 증가함을 알 수 있다. 따라서, 이 경우에 결합 기법으로 CIAB 기법이 사용된다고 가정하면, 2개의 인식기의 집합으로 만드는 것이 인식 성능 측면에서 바람직하다고 볼 수 있다.

비록 가상의 실험 환경이었지만, 위의 네 가지 예제를 통한 실험 결과로부터, 인식기의 결합 방법 측면에서 볼 때, 투표 기법 보다는 CIAB 기법이 더 적은 수의 인식기를 사용하여 100%의 인식율을 이룰 수 있음을 알 수 있었다. 또한, 인식기의 선택 측면에서 보면, 조건부 엔트로피의 최소화를 통한 클래스-결정 상호정보인 U(L;E) 값은 이러한 CIAB 기법과 비슷한 성향으로 인식기의 개수가 증가함에 따라 증가하다가 멈추면서, 상대적으로 다른 인식기 선택 기준 보다 다수 인식기 시스템에 포함

될 인식기의 개수를 결정하고, 인식기의 집합을 결정하는데 유용함을 알 수 있었다.

5. 결 론

본 논문에서는 다수 인식기 시스템을 위한 인식기의 집합을 결정하는 방법에 있어서, 인식기의 개수에 사전 제한을 두지 않고, 인식기의 선택 기준으로 사용되었던 조건부 엔트로피의 최소화를 통한 인식기 선택 방법을 기존의 Q statistic과 CD diversity()와 같은 다양성 기준을 사용하는 인식기 선택 방법과 간단하면서도 분명한 가상의 예제를 통하여 비교, 분석해 보았다. 그 결과, 조건부 엔트로피의 최소화를 통하여 인식기의 집합을 결정하는 방법이 유망한 인식 성능을 보이는 인식기의 개수를 결정하고, 인식기의 집합도 결정할 수 있음을 알 수 있었다. 또한, 이때에 결합 방법으로서 CIAB 결합 기법이 투표 기법 보다 더 유용함도 알 수 있었다. 그렇지만, 간단한 예제를 사용함으로써 클래스-결정 상호정보를 직접 계산할 수 있었으나, 실제 인식기의 데이터를 다룰 때에는 그러한 계산이 용이하지 않을 수 있기 때문에 이에 대비한 근사치를 활용하는 방법에 대한 고려가 필요할 수 있다고 본다.

참고문헌

- [1] Kittler, J., Hatef, M., Duin, R.P.W., and Matas, J., "On Combining Classifiers," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol.20, pp.226-239, 1998.
- [2] Kang, H.-J. and Lee, S.-W., "Combination of Multiple Classifiers by Minimizing the Upper Bound of Bayes Error Rate for Unconstrained Handwritten Numeral Recognition", *International Journal of Pattern Recognition and Artificial Intelligence*, vol.19, no.3, pp.395-413, 2005.
- [3] Ho, T. K., Chapter 7 Multiple Classifier Combination: Lessons and Next Steps, In H. Bunke and A. Kandel (Eds.), *Hybrid Methods in Pattern Recognition*, World Scientific, 2002.
- [4] Roli, F. and Giacinto, G., Chapter 8 Design of Multiple Classifier Systems, In H. Bunke and A. Kandel (Eds.), *Hybrid Methods in Pattern Recognition*, World Scientific, 2002.
- [5] Woods, K., Kegelmeyer Jr., W.P., and Bowyer, K., "Combination of Multiple Classifiers Using Local Accuracy Estimates," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol.19, pp.405-410, 1997.
- [6] 강희중, "인식기 간의 상호정보를 이용한 인식기 선택", *정보과학회논문지: 컴퓨팅의 실제 및 레터*, 제14권, 제3호, pp.326-330, 2008.