

# FMM 신경망을 이용한 OSD 메뉴 검증기법

이진석, 백정민, 김호준  
한동대학교 전산전자공학부

e-mail : [jinseog2@chol.com](mailto:jinseog2@chol.com) , [deedman@hanmail.net](mailto:deedman@hanmail.net) , [hjkim@handong.edu](mailto:hjkim@handong.edu)

## An OSD Menu Verification Technique using a FMM Neural Network

Jin Seok Lee, Jung Min Paik, Ho Joon Kim

School of Computer Science and Electronic Engineering, Handong Global University

### 요 약

본 논문에서는 TV OSD(On Screen Display) 메뉴 자동검증 시스템에서 문자패턴의 실시간 인식을 위한 방법론을 고찰한다. 이는 일반적인 문자인식 문제와는 달리 시스템 환경에 대한 몇 가지 가정과 제약조건을 고려해야 한다. 예컨대 문제의 특성상 카메라 및 TV 제어 기기부의 동작과 연동하는 작업 스케줄링 기능과 실시간 분석기능 등의 요건은 시스템개발을 복잡하게 하는 반면, 주어진 OSD 메뉴 데이터로부터 검증과정은 미지 패턴에 대한 인식과정을 단순화하여 일종의 판정(decision) 문제로 고려될 수 있게 한다. 본 연구에서는 인식의 방법론으로서 수정된 구조의 FMM 신경망을 적용한다. 이는 하이퍼박스 기반의 패턴 분류기로서 간결하면서도 강력한 학습기능을 제공한다. 기존의 FMM 모델이 갖는 단점인 학습패턴에서 특징분포와 빈도를 고려하지 못한다는 점을 개선하여, 특징과 하이퍼박스간의 가중치 요소를 고려한 활성화 특성을 정의한다. 또한 실제 데이터를 사용한 실험결과를 통해 제안된 이론의 유용성을 고찰한다.

### 1. 서 론

TV 등의 디스플레이 장치에는 사용자가 직접 환경을 설정할 수 있도록 하는 OSD(On Screen Display) 메뉴가 있다. 디스플레이 제품의 개발 및 생산과정에서 OSD 메뉴문자의 오류 유무를 검사하는 검증 작업이 수행된다. 기존의 OSD 메뉴 검증작업은 작업자의 육안에 의한 판단과 수작업에 의해 이루어지고 있는데, 이는 반복작업에 의한 집중력 저하 및 판단착오에 의한 오류의 가능성을 내재한다. 또한 작업자가 다양한 국가의 언어에 대한 문자형태와 기호표현의 특성을 이해하여야 하고, 검증작업 자체에 따르는 부수적인 시간과 노력을 필요로 한다. 이에 따라 효율적인 OSD 메뉴 테스트를 위한 자동화의 필요성이 절실히 요구된다. 요구되는 자동화 시스템은 개발자가 작성한 OSD 메뉴 스펙 시트가 입력되고 문자 인식 프로그램이 카메라를 통해 찍은 OSD 메뉴의 사진을 순차적으로 확인하면서 OSD 메뉴의 오류를 판정하여 결과를 파일로 출력하는 것이다. 이러한 시스템을 통해

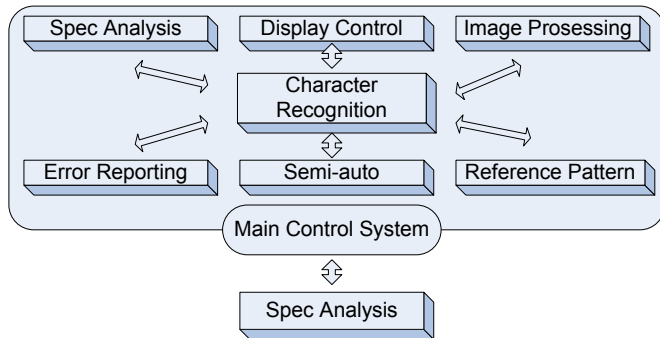
OSD 메뉴의 결함을 비롯한 여러 통계 자료를 자동으로 출력함으로써 작업의 효율성을 극대화 할 수 있다.

본 연구에서는 이러한 TV OSD 메뉴 자동검증 시스템에서 패턴 인식을 위한 방법론을 제시한다. 모듈구조를 갖는 시스템의 기능과 구조를 소개하고, 세부적으로 퍼지 최대 최소(FMM: Fuzzy Min-Max) 신경망을 기반으로 한 인식 모듈을 중점적으로 고찰한다.

학습에 사용되는 표준 패턴 데이터는 카메라를 통하여 획득한 다국적 언어의 문자패턴으로부터 생성되므로 특징의 왜곡과 노이즈를 포함할 수 있다. 또한 추출되는 특징의 수와 특징 종류별로 대상패턴에 대한 연관도 요소(relevance factor)는 인식시스템의 효율과 성능에 영향을 준다. 이에 본 연구에서는 학습된 신경망으로부터 특징유형별로 각각의 연관도 요소를 산출하는 방법론을 제안하고, 이로부터 효과적인 특징을 선별하는 이른바 특징 선정 기법을 제시한다. 이는 성능 저하를 최소화 하는 전제에서 시스템의 규모 및 인식속도를 개선할 수 있게 한다.

## 2. 배경 시스템

본 연구에서 기반으로 하는 OSD 자동검증 시스템은 [그림 1]과 같이 구성된다. 전체 시스템 동작은 초기화 과정에서 사용자가 작성한 특정한 파일형식의 기준문서를 불러오고, 작업스케줄러 생성 모듈에서는 주어진 검증작업을 진행하기 위한 순차적 작업을 정의 하고, 하드웨어 모듈에서는 작업스케줄러의 제어 신호에 따라 OSD 메뉴를 제어하기 위한 원격제어신호를 발생시킨다. 이어서 카메라에서 문서영상을 입력 받고, 문자영역 추출모듈에서 독립된 문자열과 단어 및 개별 문자가 추출된다. 표준패턴 구축모듈에서는 디스플레이 제품에서 사용되는 모든 정형화된 글자들을 영상으로 입력받아 데이터베이스로 저장하고, 최종적으로 검증 모듈은 문자영역 추출모듈에서 처리된 문서영상의 문자와 표준패턴의 문자를 비교하여 일치 여부를 판정한다. 모든 작업이 종료되면 검증 오류에 대한 보고서를 생성한다.



[그림 1] TV OSD 메뉴 자동검증 시스템의 구조

## 3. FMM 신경망 기반의 패턴 인식 모델

### 3.1 가중치를 갖는 FMM 신경망

FMM 신경망은 하이퍼박스 퍼지 집합으로 구성되는 패턴분류 모델이다. [1,2] 하이퍼박스란 모든 특징의 종류에 대하여 완전 클래스 멤버십을 가진 패턴들로 이루어진 n 차원 패턴 공간 영역이다. 이는 최소값과 최대값의 범위과 그 가장자리에서 퍼지 멤버십을 갖는 퍼지 구간(fuzzy interval)들로서 이루어진 하이퍼박스와, 그에 상응하는 멤버십 함수는 특징값의 집합과 패턴클래스 간의 사상을 지원한다. FMM 신경망은 주어진 학습패턴 집합에서 특징값의 범위만을 고려할 뿐 특징값의 발생 빈도를 학습과정에 반영하지 못한다. 본 연구에서 사용하는 FMM 신경망의 활성화 함수는 식 (1)과 같은 형태를 갖는다. 식에서 보인 바와 같이 특징값과 하이퍼박스 간에 가중치 요소를 부여함으로써 기존의 FMM 모델과는 달리 특징과 하이퍼박스와의 관계를 학습패턴이 발생한 빈도에 따라 가변적으로 고려할 수 있게 하여 특징의 상대적 중요도를 서로 다른 값으로 반영할 수 있게 한다.

$$b_j(A_h) = \frac{1}{\sum_{i=1}^n w_{ji}} \cdot \sum_{i=1}^n w_{ji} [\max(0, 1 - \max(0, \gamma_{jiv} \min(1, a_{hi} - v_{ji}))) + \max(0, 1 - \max(0, \gamma_{jju} \min(1, u_{ji} - a_{hi}))) - 1.0] \quad (1)$$

식에서  $a_h = (a_{h1}, a_{h2}, \dots, a_{hn})$ 는 h번째 입력 패턴으로 n개의 특징으로 이루어지며  $u_h = (u_{h1}, u_{h2}, \dots, u_{hn})$ 는  $b_j$ 의 최소점을,  $v_h = (v_{h1}, v_{h2}, \dots, v_{hn})$ 는  $b_j$ 의 최대점을 의미한다.  $w_{ji}$ 는 j번째 하이퍼박스와 i번째 특징사이의 연결 가중치를 의미하며  $\gamma$ 는 특징범위의 가장자리에서 퍼지 소속함수의 기울기를 결정하는 매개변수로 [0,1]사이의 값을 갖는다.

### 3.2 학습 알고리즘

FMM 신경망의 학습과정은 각 단계에서 하이퍼박스의 생성, 확장, 축소의 과정을 실행해 나가게 된다. 이러한 3 가지 과정에 대하여 가중치를 고려한 FMM 신경망에서는 하이퍼박스와 특징과의 관계가  $w_{ji}$ 로 각 특징에 가중치가 적용된다. 학습과정에서 빈도변수값이 최종적으로 유지되며 이로부터  $w_{ji}$ 값이 식 (2)에 의해 산출된다.

$$w_{ji} = \frac{\alpha f_{ji}}{R} \quad (2)$$

$$R = \max(s, v_{ji} - u_{ji}) \quad (\text{단, } s > 0)$$

식에서 보인 바와 같이  $w_{ji}$ 는 j번째 하이퍼박스에서 i번째 특징의 발생 빈도에 비례한 값으로 결정되며, 이는 특징의 구간크기에 반비례하여 재조정된다. 단, 특징의 범위가 단일 포인트로 나타나는 경우에 가중치가 지나치게 큰 값이 되는 것을 방지하기 위해 지정된 값 s의 범위로 대치하여 계산하여준다. s는 문제에서 주어지는 패턴 데이터의 형태에 따라 결정되는 파라미터로 0보다 큰, 0 근처의 값으로 정해준다.  $\alpha$ 는 학습률 상수인데 특징영역이 확장함에 따라 해당 특징에 대한 가중치가 얼마나 증가시킬 것인가를 결정하는 매개변수이다. 이와 같이 계산되는 가중치 개념은 좁은 특징 범위에 많은 빈도의 학습패턴이 주어질수록 그 특징은 해당 하이퍼박스에 상대적으로 높은 중요도를 가지는 특징이 된다는 점을 반영한다.

하이퍼박스 확장 방법은 기존에 생성된 하이퍼박스 중에서, 주어진 패턴에 가장 크게 반응하는 하이퍼박스를 선택하여 확장여부를 결정한다. 확장여부는 식 (3)의 조건에 따라 결정되는데 확장될 하이퍼박스와 의 최소 평균 거리를 파라미터  $\theta$ 로 제어한다. 식 (4)에서 n은 특징의 수이고 파라미터  $\theta$ 는 [0,1] 사이의 값을 가진다.

확장과정은 식 (4)과 같이 하이퍼박스의 최대점, 최소점을 재조정하고 특징의 빈도값을 수정한다.

$$n\theta \geq \sum_{i=1}^n (\max(v_{ji}, x_{hi}) - \min(u_{ji}, x_{hi})) \quad (3)$$

$$\begin{cases} f_{ji}^{new} &= f_{ji}^{old} + 1 \\ u_{ji}^{new} &= \min(u_{ji}^{old}, x_{hi}) \\ v_{ji}^{new} &= \max(v_{ji}^{old}, x_{hi}) \end{cases} \quad \forall i = 1, 2, \dots, n \quad (4)$$

다시 말해서 식 (3)의 조건을 만족하면 식 (4)을 통해 하이퍼박스의 최대점과 최소점을 재조정하는 과정으로 확장이 이루어지고 특징의 빈도변수  $f_{ji}$ 의 값을 1

씩 증가시키게 된다. 이렇게 하이퍼박스 학습 범위와 더불어, 발생빈도  $F_{ji}$  를 함께 학습함으로 이를 가중치로 반영하고 이후의 학습과정인 축소과정에서 나타나는 왜곡을 최소화 하는데 이용한다.

가중치를 갖는 FMM 모델의 핵심은 기존의 FMM 모델에 비해 다음과 같이 두 가지 장점을 기대할 수 있게 한다는 것이다.

- 학습패턴에 포함될 수 있는 노이즈나 비정상적인 데이터에 의한 영향을 줄일 수 있다. 데이터 집합내에서 상대적으로 빈도가 적은 패턴에 대해 하이퍼박스 영역의 확장을 점진적으로 이루어지게 하고, 가중치 값을 재조정하여 이러한 비정상 패턴에 민감하게 학습되는 현상을 보완한다.
- 두 번째로 특징에 대한 분석기능을 지원한다는 점이다. 가중치 값으로부터 각 특징과 클래스간의 관계를 해석해 낼 수 있으며, 이는 특징종류에 대한 유용성과 특징값에 대하여 하이퍼박스에 대한 상대적인 연관도를 서로 다른 값으로 판별해 낼 수 있게 한다.

4. 특징 분석 기법

앞절에서 제시한 FMM 신경망에서 가중치 요소는 특징범위와 하이퍼박스와의 연관도 요소를 반영한다. 이를 기반으로 각 특징유형과 주어진 패턴 클래스와의 상호 연관도 요소를 정의함으로써 해당 특징의 상대적 중요도를 분석할 수 있다. 이를 위하여 본 연구에서는 다음과 같이 두 가지 척도를 정의하였다. 식 (5)에 정의된  $RF1$  은 특징값  $X_i$ 와 패턴 클래스  $C_k$ 와의 연관도 요소이다. 여기서 상수  $N_B$ 와  $N_k$  는 각각 총 하이퍼박스의 수와 해당클래스에 속하는 하이퍼박스의 수를 의미한다. 따라서  $RF1$  이 양수의 값을 가지면 해당특징이 자극성(excitatory) 입력으로 작용하고 있음을 보이고 음수의 경우 억제성(inhibitory)으로 작용함을 반영한다.

$$RF1(x_i, C_k) = \left( \frac{1}{N_k} \sum_{B_j \in C_k} S(x_i, (u_{ji}, v_{ji})) \cdot w_{ij} - \frac{1}{(N_B - N_k)} \sum_{B_j \notin C_k} S(x_i, (u_{ji}, v_{ji})) \cdot w_{ij} \right) / \sum_{B_j \in C_k} w_{ij} \quad (5)$$

식에서 함수  $S$  는 일종의 유사도 척도(similarity measure)로서 주어진 두 개의 퍼지 구간 데이터에 대한 상호 유사도를 반영하며 이는 식 (6)와 같이 계산된다. 식에서  $Overlap$  은

$$S(x_i, (u_i, v_i)) = S((x_i^L, x_i^U), (u_i, v_i)) = \frac{Overlap((x_i^L, x_i^U), (u_i, v_i))}{Max(x_i^U - x_i^L, v_i - u_i)} \quad (6)$$

$$Overlap((x_i^L, x_i^U), (u_i, v_i)) =$$

$$\begin{cases} x_i^U - u_i & \text{if}(x_i^L \leq u_i \leq x_i^U \leq v_i) \\ v_i - u_i & \text{if}(x_i^L \leq u_i \leq v_i \leq x_i^U) \\ x_i^U - x_i^L & \text{if}(u_i \leq x_i^L \leq x_i^U \leq v_i) \\ v_i - x_i^L & \text{if}(u_i \leq x_i^L \leq v_i \leq x_i^U) \\ 0 & \text{Otherwise} \end{cases} \quad (7)$$

두 번째 척도  $RF2$  는 특징유형과 패턴클래스와의 연관도 요소로서 식 (8)와 같이  $RF1$  의 항으로 정의된다. 이는 특정 패턴을 분류하는 문제에서 해당 특징 유형의 상대적 중요도를 반영하는 요소로서 특징 선정기법에 활용될 수 있다.


$$RF2(X_i, C_k) = \frac{1}{L_i} \sum_{x_j \in X_i} RF1(x_j, C_k) \quad (8)$$

5. 실험 결과 및 고찰

OSD 검증모델은 수행은 크게 3 개의 단계로 구성된다. 우선 전처리 과정으로서 카메라로부터 획득한 영상으로부터 문자 영역과 개별 문자에 분할 작업이 이루어진다. 두 번째 단계는 분할된 각 문자 패턴에 대하여 특징벡터를 추출하는 과정이다. 본 연구에서는 문자의 윤곽선에 대한 8 방향 코드의 빈도를 분석한 메쉬벡터의 형태로 특징을 추출하였다. 이어서 인식단계가 수행되는데 인식 방법은 FMM 모델 기반의 신경망을 사용하여 구현하였다

실험은 [그림 2] 에 보인 바와 같이 총 159 개의 OSD 문자 패턴을 고려하였다. 학습데이터로서 110 개의 패턴 집합을 생성하고 15 개의 집합을 테스트 데이터로 사용하여 성능을 검증하였다.

학습데이터로서 실제 라틴계열 5 개국 언어의 문자를 포함하여 각 158 개의 OSD 문자로 이루어진 총 110 개의 패턴 집합을 사용하였다. [그림 2]는 학습에 사용된 패턴 집합의 예이다.



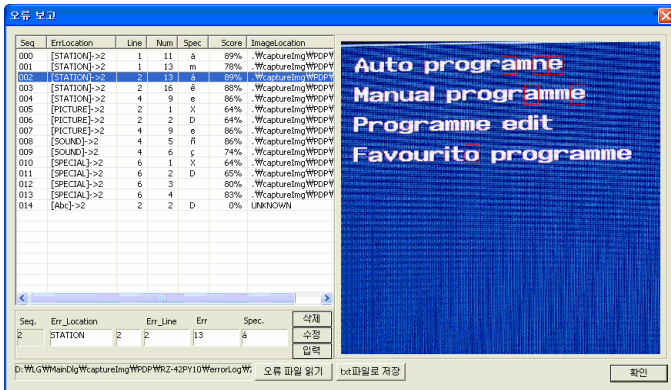
[그림 2] 학습 패턴의 예

특징추출은 정규화된 문자패턴에서 (4X4) 크기의 메쉬 형태로 영역을 구분하고 각 영역별로 8 방향 윤곽선 코드의 빈도를 추출하였다. 따라서 총 128 개의 성분으로 이루어진 특징벡터가 생성된다. [표 1]은 학습과정에서 생성된 하이퍼박스의 형태에 대한 예이다. 표에 보인 바와 같이 학습과정을 통하여 각 특징 범위의 상한과 하한값이 조정되며, 이를 통한 패턴 분류 과정은 앞 절에서 정의한 하이퍼박스 멤버쉽 함수의 값을 판정함으로써 이루어진다.

[표 1] 학습과정에 의해 생성된 하이퍼박스의 내용 예

| Pattern class | hyperbox | Feature type | Lower bound | Upper bound | weight |
|---------------|----------|--------------|-------------|-------------|--------|
| a             | b1       | f4           | 0.333       | 0.5         | 48     |
|               |          | f24          | 0           | 0.214       | 37.3   |
|               |          | f38          | 0.16        | 0.25        | 80     |
|               |          | f101         | 0.25        | 0.41        | 36     |
|               |          | f123         | 0.28        | 0.5         | 28     |
| b2            | b2       | f10          | 0           | 0.2         | 25     |
|               |          | f30          | 0.428       | 0.5         | 50     |
|               |          | f72          | 0.142       | 0.357       | 23.3   |
|               |          | f88          | 0.2         | 0.5         | 16.6   |
|               |          |              |             |             |        |

[그림 3]은 실제 구현된 시스템 출력 화면의 예이다. 그림에 보인 바와 같이 작업 스케줄러에 의해 설정된 해당 화면의 OSD 내용에 대하여 검증하고 그 결과에 대한 내용을 화면상에 표시함으로써 시스템 운영자로 하여금 직접 확인 할 수 있도록 한다.




[그림 3] 검증 결과에 대한 시스템 출력 화면의 예

[표 2]는 특징분석 실험 결과의 예이다. 표에 보인 바와 같이 학습된 FMM 신경망으로부터 각 특징유형과 이에 대한 상대적 중요도를 연관도 요소, RF2 로 측정할 수 있다. 이는 각 패턴 클래스별로 별도로 산출할 수 있으며 계산량을 줄이기 위하여 대상 패턴별로 상위값을 갖는 일정 개수의 특징을 선별할 수 있다. 표는 영문자 예제 패턴 158 개에 대하여 연관도 요소값을 산출하고 그 들 중 상위 8 개를 선별한 예이다.

| 대상패턴 | 특징 유형 | RF2   | 대상패턴 | 특징 유형 | RF2   |
|------|-------|-------|------|-------|-------|
| a    | f23   | 0.410 | b    | f103  | 0.333 |
|      | f97   | 0.409 |      | f115  | 0.319 |
|      | f80   | 0.350 |      | f77   | 0.299 |
|      | f20   | 0.321 |      | f49   | 0.284 |
|      | f59   | 0.190 |      | f35   | 0.179 |
|      | f67   | 0.156 |      | f119  | 0.109 |
|      | f120  | 0.154 |      | f24   | 0.105 |
|      | f15   | 0.114 |      | f40   | 0.098 |

[표 2] 특징 분석 실험 결과 예

[그림 4]은 특징 선정 기법의 유용성에 대한 실험결과로서 성능저하를 최소화 하는 전제에서 특징수 감축 효과를 보인다. 실험 결과 인식률 90%를 유지하는 수준에서 최대 39.0%까지 특징수를 줄일 수 있음을 보였다.



[그림 4] 특징수 감소에 따른 인식률

## 6. 결론

OSD 메뉴 검증의 자동화는 사람의 육안으로 이루어지는 TV 공정과정에서 반복작업의 어려움과 오류의 가능성을 개선한다는 점에서 매우 유용하다. 본 연구는 이러한 시스템에서 시스템의 구조와 패턴 인식을 위한 방법론 및 특징 분석 기법을 제한하였다. 가중치를 갖는 FMM 신경망 모델은 학습과정 및 분류과정에서 특징의 분포 및 빈도를 고려할 수 있게 한다. 이는 학습데이터로부터 특징값의 빈도에 따른 상대적 중요도를 적절하게 반영함으로써 노이즈나 비정상적 데이터에 의한 성능저하를 개선할 수 있게 한다. 또한 특징의 연관도 요소를 고려한 특징선정 기법은 인식기의 구조를 단순화 시키고 계산량을 줄일 수 있게 하여 시스템의 효율을 개선한다. 향후 연구로는 그래픽문자로 표현되는 국가의 언어에 적용할 수 있도록 확장하는 연구와 일반적인 범용문자 인식 기법과 결합하여 유용성을 일반화 하는 연구가 필요하다고 판단된다.

## 참고문헌

- [1] P. Simpson, "Fuzzy Min-Max Neural Networks-Part 1:Classification,"IEEE Transactions on Neural Networks, Vol.3, No.5,pp.776-786,1992.
- [2] B. Gabrys and A. Bargiela, "General Fuzzy Min-Max Neural Network for Clustering and Classification,"IEEE Transactions on Neural Networks, Vol.11, No.3, 2000.
- [3] Ho J. Kim, Tae W. Ryu, Thai T. Nguyen, Joon S. Lim, S. Gupta, "A Weighted Fuzzy Min-Max Neural Network for Pattern Classification and Feature Extraction," Lecture Notes in Computer Science, LNCS 3046, pp.791-798, 2004.
- [3] S. Mitra and Y. Hayashi,"Neuro-Fuzzy Rule Generation: Survey in Soft Computing Framework," IEEE Transactions on Neural Networks, Vol.11, No.3, pp.748-768, 2000.
- [4] Hung-Pin Chiu, Din-Chang Tseung, "Invariant Handwritten Chinese Character Recognition using Fuzzy Min-Max Neural Networks," Pattern Recognition Letters, Vol.18, pp.481-491, 1997.
- [5] Jayanta Basak, Rajat K. De, Sankar K. Pal,"Unsupervised Feature Selection using a Neuro-Fuzzy Approach," Pattern Recognition Letters, Vol.19, pp.997-1006, 1998.
- [6] Mahn M. Lee, Kuo H. Chen, I. F. Jiang, "A Neural network Classifier with Disjunctive Fuzzy Information," Neural Networks, Vol.11, No.1, pp.113-1125, 1998.
- [7] Jean M. Steppe, Kenneth W. Bauer, Jr. "Improved feature screening in feedforward neural networks," Neurocomputing , 13, pp.47-58, 1996