

OSD 메뉴 자동검증을 위한 작업스케줄링 및 패턴 인식 기법

이진석⁰, 김호준

한동대학교 전산전자공학부

jinseog2@chol.com, hjkim@handong.edu

Job Scheduling and Pattern Recognition for Auto OSD Verification System

Jin Seok Lee⁰, Jung Min Paik, Ho Joon Kim

School of Computer Science and Electronic Engineering, Handong Global University

요약

본 연구는 디스플레이 제품의 OSD(On Screen Display) 메뉴의 문자 오류 검사 과정을 자동화 하는 방법과 FMM신경망을 이용한 실시간 문자인식 방법을 제안한다. 이는 일반적인 문자인식 문제와는 달리 시스템 환경에 대한 몇 가지 가정과 제약조건을 고려해야 한다. 예컨대 문제의 특성상 카메라 및 TV제어 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 디스플레이 제품의 OSD 메뉴와 같이 특수한 구조를 갖는 문서영상에 대한 논리적인 구조분석을 통해서 연속적인 문서영상을 발생시켜서 검증과정을 자동화하는 작업스케줄링 방법을 제안하고 인식의 방법론으로서 수정된 구조의 FMM신경망을 적용한다. 또한 실제 데이터를 사용한 실험결과를 통해 시스템의 유용성을 고찰한다.

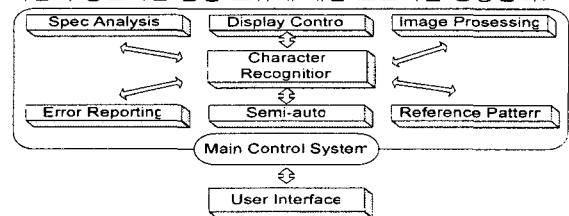
1. 서 론

디스플레이 제품의 개발 및 생산과정에서 OSD 메뉴문자의 오류 유무를 검사하는 검증 작업이 수행된다. 이는 현재 수작업으로 행해지고 있는데 반복작업으로 인한 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. 따라서 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. 본 연구에서는 이러한 OSD 메뉴 검증자동화를 위한 작업 스케줄링 기법과 패턴 인식을 위한 방법론을 제시한다. 모듈구조를 갖는 시스템의 기능과 구조를 소개하고, 세부적으로 작업스케줄러모듈과 퍼지 최대 최소(FMM: Fuzzy Min-Max) 신경망을 기반으로 한 인식 모듈을 충점적으로 고찰한다.

2. 전체 시스템 구성

OSD자동검증 시스템은 [그림 1]과 같이 구성된다. 전체 시스템 동작은 초기화 과정에서 사용자가 작성한 특정한 파일형식의 기준문서를 불러오고, 작업스케줄러 생성모듈에서는 주어진 검증작업을 진행하기 위한 순차적인 그리고 각각의 2계층의 문자열 우측에 각각의 2계층에

작업을 정의하고, 하드웨어 모듈에서는 작업스케줄러의 제어신호에 따라 OSD 메뉴를 제어하기 위한 원격제어신호를 발생시킨다. 이어서 카메라에서 문서영상을 입력 받아 개별 문자가 추출된다. 표준패턴 구축모듈에서는 디스플레이 제품에서 사용되는 모든 정형화된 글자들을 영상으로 입력받아 데이터베이스로 저장하고, 최종적으로 문자 인식 모듈은 문자영역 추출모듈에서 추출된 문자와 표준패턴의 문자를 비교하여 일치 여부를 판정한다. 모든 작업이 종료되면 검증 오류에 대한 보고서를 생성한다.



[그림 1] OSD 메뉴 자동검증 시스템의 구조

3. 검증 자동화를 위한 작업스케줄러 모듈

검증용 기준문서로부터 정보를 획득하는 방법으로 기준문서에 계층을 구분할 수 있는 별도의 형식정의명령을 추가할 필요가 있다. [표 1]은 실제 간단한 형식정의명령을 추가한 예를 보이고 있다. 예에서 #MENU라는 명령을 사용하고 있는데, #MENU 바로 아래에 있는 문자열은 1계층의 문자열이고, 1계층 바로 아래에 있는 문자열부터 시작해서 #MENU까지의 문자열은 2계층의 문자열이다. ‘s’는 학습 데이터의 형태에 따라 결정되는 값으로 0 근처

종속하는 3계층 문자열이 위치한다.

| | |
|----------------|--------------|
| #MENU | |
| STATION | |
| Auto programme | System |
| | Storage from |
| #MENU | |

[표 1] 형식 정의 언어가 추가된 기준문서의 예

이처럼 검증용 기준문서를 규칙적인 구조로 구성하고 형식정의명령을 추가하면 계층적인 트리구조, 이른바 스펙트리(spec. tree)로 쉽게 변환이 가능하다. 작업스케줄러는 이러한 스펙트리에서 생성되는데, 스펙트리를 추적(traversal)하면서 모든 노드들에 대하여 순차적으로 빠짐 없이 작업을 생성해 나간다. 이 과정에서 커서를 이전 메뉴위치에서 현재의 위치로 이동시키기 위한 원격제어신호 정보가 연결된다. 이 정보는 자동검증의 모든 진행과정에서 마치 동기신호와 같은 역할을 한다. 작업스케줄러는 자동검증을 구축하기 위한 핵심적인 요소로써 다음의 5가지 정보를 갖는다.

- OSD 메뉴를 제어하는 키 정보.
- 현재 커서가 위치한 메뉴의 문자열.
- 현재 메뉴의 바로 하위 계층에 있는 모든 메뉴의 문자열: 검증 모듈에게 검증을 위한 문자열을 제공.
- 검증하고 있는 메뉴의 계층에 대한 정보: 오류보고 모듈에 오류 보고 작성시 필요한 정보를 제공.
- 현재 메뉴의 하위 계층에 메뉴 문자열 존재 유무에 대한 정보: 검증과정을 건너뛰기 위한 상태정보 제공.

4. FMM 신경망 기반의 패턴 인식 모듈

4.1. 가중치를 갖는 FMM 신경망

FMM신경망은 하이퍼박스 퍼지 집합으로 구성되는 패턴분류 모델이다.[1,2] FMM신경망은 주어진 학습패턴집합에서 특징값의 범위만을 고려할 뿐 특징값의 발생빈도를 학습과정에 반영하지 못한다. 본 연구에서 사용하는 FMM 신경망의 활성화 함수는 식 (1)과 같은 형태를 갖는다. 식에서 보인 바와 같이 가중치를 부가하여 특징값과 하이퍼박스 간에 관계를 학습패턴이 발생한 빈도에 따라 가변적으로 고려할 수 있게 한다.[3]

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

식에서 $a_h = (a_{h1}, a_{h2}, \dots, a_{hn})$ 는 h 번재 입력 패턴으로 n 개의 특징으로 이루어지며 $u_h = (u_{h1}, u_{h2}, \dots, u_{hn})$ 는 b 의 최소점을, $v_h = (v_{h1}, v_{h2}, \dots, v_{hn})$ 는 b 의 최대점을 의미한다. w_{ji} 는 j 번째 하이퍼박스와 i 번째 특징사이의 연결 가중치를 의미하며 γ 는 특징범위의 가장자리에서 퍼지 소속함수의 기울기를 결정하는 매개변수로 [0,1] 사이의 값을 갖는다. w_{ji} 는 학습과정에서 특징의 범위와 특징의 발생빈도수로부터 계산되어 식 (2)에 의해 산출된다.

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

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

특정 패턴을 분류하는 문제에서 해당 특징 유형의 상대적 중

의 값으로 정해준다. α 는 학습률 상수인데 특정영역이 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 확장여부는 식 (3)의 조건에 따라 결정되는데 확장될 하이퍼박스와의 최소 평균 거리를 θ 로 제어한다. 식 (4)에서 n 은 특징의 수이고 θ 는 [0,1] 사이의 값을 가진다. 확장과정은 식 (4)과 같이 하이퍼박스의 최대점, 최소점을 재조정하고 특징의 빈도값을 수정한다.

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

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

이렇게 하이퍼박스 학습 범위와 더불어, 발생빈도 F_j 를 함께 학습함으로 이를 가중치로 반영하고 이후의 학습과정인 축소과정에서 나타나는 왜곡을 최소화 하는데 이용한다.

4.2. 특징 분석 기법

앞 절에서 제시한 특징과 하이퍼박스의 연결 가중치를 기반으로 각 특징유형과 주어진 패턴 클래스와의 상호 연관도 요소를 정의하여 해당 특징의 상대적 중요도를 분석할 수 있다. 이를 위하여 다음과 같이 두 가지 척도를 정의하였다. 식 (5)에 정의된 RF1은 특징값 X 와 패턴 클래스 C_k 와의 연관도 요소이다. 여기서 상수 N_B 와 N_k 는 각각 총 하이퍼박스의 수과 해당클래스에 속하는 하이퍼박스의 수를 의미한다. 따라서 RF1이 양수의 값을 가지면 해당특징이 자극성(excitatory) 입력으로 작용하고 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 Overlap은

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

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

두 번째 척도 RF2는 특징유형과 패턴클래스와의 연관도 요소로서 식 (8)와 같이 RF1의 항으로 정의된다. 이는

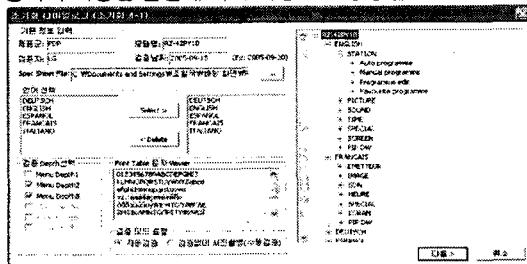
| 패턴 | 특징 | RF2 | 패턴 | 특징 | RF2 |
|----|-----|-------|----|------|-------|
| A | f23 | 0.410 | b | f103 | 0.333 |
| | f97 | 0.409 | | f115 | 0.319 |

요도를 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

[그림 3]은 구현된 시스템에서 작업스케줄러 생성을 위한 설정화면을 보여준다. 작업스케줄러는 검증용 기준문서를 분석하여 각종 정보들을 띄우고, 스펙 트리를 만들고 자동검증을 위해 검증대상 언어와 계층(depth), 수동/자동 검증모드 등 사용자가 지정한 옵션에 따라 다양하게 생성될 수 있다.



[그림 3] 작업스케줄러 생성을 위한 초기화면

실험은 총 158개의 OSD 문자 패턴을 고려하였다. 학습데이터로서 110개의 패턴 집합을 생성하고 15개의 집합을 테스트 데이터로 사용하여 성능을 검증하였다. 실제 라틴 계열 5개국 언어의 문자를 포함하여 각 158개의 OSD 문자로 이루어진 총 110개의 패턴 집합을 학습데이터로 사용하였다. [그림 4]는 학습에 사용된 패턴 집합의 예이다.



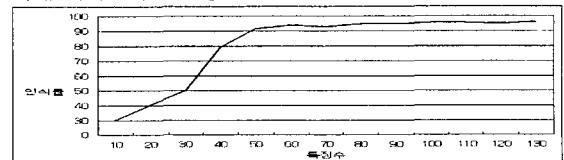
[그림 4] 학습 패턴의 예

본 연구에서는 분할된 각 문자 패턴에 대하여 특징벡터를 추출하는 방법으로 문자의 윤곽선에 대한 8방향 코드의 빈도를 분석한 메쉬벡터의 형태를 사용하였고 인식 방법은 FMM모델 기반의 신경망을 사용하여 구현하였다. 정규화된 문자패턴에서 (4X4) 크기의 메쉬 형태로 영역을 구분하고 각 영역별로 8방향 윤곽선 코드의 빈도를 추출하여 총 128개의 성분으로 이루어진 특징벡터가 생성된다. [표 2]는 특징분석 실험 결과의 예이다. 표에 보인 바와 같이 학습된 FMM 신경망으로부터 각 특징유형과 이에 대한 상대적 중요도를 연관도 요소, RF2로 측정할 수 있다. 이는 각 패턴 클래스별로 별도로 산출할 수 있으며 계산량을 줄이기 위하여 대상 패턴 별로 상위값을 갖는 일정 개수의 특징을 선별할 수 있다. 표는 영문자 예제 패턴 158개에 대하여 연관도 요소값을 산출하고 그들 중 상위 6개를 선별한 예이다.

| | | | |
|-----|-------|------|-------|
| f80 | 0.350 | f77 | 0.299 |
| f20 | 0.321 | f49 | 0.284 |
| f59 | 0.190 | f35 | 0.179 |
| f67 | 0.156 | f119 | 0.109 |

[표 2] 특징 분석 실험 결과 예

[그림 4]은 특징 선정 기법의 유용성에 대한 실험결과로서 성능저하를 최소화 하는 전제에서 특징수 강축 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. 결 론

본 연구에서는 라틴 계열 5개 국어 문자 집합을 적용한 실제 OSD 메뉴를 대상으로 자동 검증 시스템을 구현하고 특징 분석 기법을 적용하였다. 가중치를 갖는 FMM 신경망 모델은 학습과정 및 분류과정에서 특징의 분포 및 빈도를 고려할 수 있게 한다. 이는 학습데이터로부터 특징 값의 빈도에 따른 상대적 중요도를 적절하게 반영함으로써 노이즈나 비정상적 데이터에 의한 성능저하를 개선 할 수 있게 한다. 또한 특징의 연관도 요소를 고려한 특징선정 기법은 인식기의 구조를 단순화시키고 계산량을 줄일 수 있게 하여 시스템의 효율을 개선한다. 결과적으로 시스템의 실시간 응답특성이 우수한 실용 가능한 시스템을 구축할 수 있었다. 향후 연구로는 그래픽문자로 표현되는 국가의 언어에 적용할 수 있도록 확장하는 연구와 일반적인 범용문자 인식 기법과 결합하여 유용성을 일반화하는 연구가 필요하다고 판단된다.

참고문헌

- P. Simpson, "Fuzzy Min-Max Neural Networks—Part 1:Classification," IEEE Transactions on Neural Networks, Vol.3, No.5, pp.776–786, 1992.
- 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.
- 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.
- 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.