

## 구조적 유사성을 이용한 UMLS 의미망 군집 방법

지영신\*, 전혜경\*, 정현만\*, 이정현\*\*  
인하대학교 공과대학 전자계산공학과\*, 컴퓨터공학부\*\*

### UMLS Semantic Network Automatic Clustering Method using Structural Similarity

Youngshin Ji\*, Hyekyoung Jeon\*, Heonman Jeong\*, Junghyun Lee\*\*

{Dept.\*, School\*\*} of Computer Science & Engineering

Inha University

E-mail : \*{ys\_ji, jhk0214, hmjung}@nlsun.inha.ac.kr, \*\*jhlee@inha.ac.kr

#### Abstract

Because UMLS semantic network is bulky and complex, user hard to understand and has shortcoming that can not express all semantic network on screen.

To solve this problem, rules to dismember semantic network efficiently are introduction, but there is shortcoming that this should classifies manually applying rule whenever UMLS semantic network is modified.

Suggest automatic clustering method of UMLS semantic network that use genetic algorithm to solve this problem.

Proposed method uses Linked semantic relationship between each semantic type and semantic network does clustering by structurally similar semantic type linkages.

To estimate the performance of suggested method, we compared it with result of clustering method by rule.

#### I. 서론

UMLS(Unified Medical Language System)는 서로 다른 의학전문용어 사전들간의 차이점에 의해서 야기되는 문제를 극복할 수 있도록 해주지만, 약 190 만개의 개념(concept)명과 73 만개의 개념이 포함된 메타시소스의 방대한 크기와 복잡성은 사용자의 이해를 어렵게 할수도 있다. 그래서 UMLS는 사용자의 이해를 돋기위해 방대한 지식을 다이어그램의 형태로 제공하는 의미망을 제공하고 있지만 이것 또한 크기가 크고 이해하기 어렵다[1]. 또한, 서로 복잡하게 연결된 의미유형들을 하나의 컴퓨터 화면에 표현하는 것이 불가능하다는 문제점이 대두되고 있다. 최근 이런 문제점을 해결

하기 위해 의미망을 구조적으로 유사한 군집들로 분할하기 위한 여러 가지 규칙들이 소개되고 있다.

본 논문에서는 의미유형과 군집들 사이의 구조적 유사성과 결합적 학도의 계산 방법을 정의하였다. 또한, 유전자 알고리즘의 전역적 탐색 기법을 이용하여 의미망을 구조적으로 자동 분할하는 방법을 소개하고 기준의 규칙에 의한 분류결과와 비교 평가한다.

#### II. Unified Medical Language System 의 의미망

##### 2.1 정의 및 범위

UMLS는 미국 NLM(National Library of Medicine)에서 장기과제로 개발하고 있는 통합용어시스템이다. 향후 의료분야에 컴퓨터를 이용한 지능적인 자료처리를 위해서는 컴퓨터가 이해할 수 있는 형태의 의학용어모델을 활용하는 핵심기술에 대한 연구가 필요하다. 이에 맞추어 광범위하게 생명과학분야의 전문 검색 시스템을 개발하고 지원하기 위한 연구들이 세계각국에서 진행되고 있다. 그 중 미국국립의학도서관이 운영하는 UMLS가 가장 활발히 진행되고 있는 연구분야 중 하나이다.

의미망은 UMLS의 일부분으로 지식요소의 하나이며, 의미망의 목적은 UMLS 메타시소스에서 표현된 모든 개념들에 대한 일관성 있는 범주화와 유용한 관계집합을 제공하는데 있다. 2003AA edition의 의미망은 135 개의 의미유형과 55 개의 의미관계가 정의되었다.

## 2.2 구조 및 관계정의

각각의 메타시소스 용어의 개념은 적어도 하나 이상의 의미유형(semantic type)이 할당된다. 즉, 계층 구조로 이루어진 의미망의 노드인 특수한 의미유형이 개념으로 할당되는 것이다.

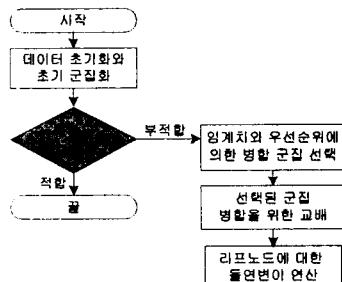
의미망은 Entity 와 Event 의 두개의 의미유형을 루트로 갖고 있으며, 각각의 의미유형은 isa 관계로 계층을 결정짓고 계층관계 이외에도 54 개의 의미관계(semantic relationship)로 의미유형 사이의 관계를 정의한다. 의미유형 사이의 isa 관계는 의미관계들의 상속을 의미한다. 즉, 자식 의미유형은 부모 의미유형의 모든 의미관계 정의를 상속받으며, 상속받는 의미관계 이외에도 의미유형들은 새로운 의미관계를 정의하기도 한다. UMLS 는 의미관계의 상속에 영향을 미치는 두개의 특별한 모델링 특징을 제공한다. 첫번째는 정의는 되지만 계승되지 않는 관계로 이를 DNI 라고하며, 두번째는 계승된 관계를 무효로 하는 blocking 을 말한다.

## III. 의미망의 자동 분할 방법

### 3.1 시스템의 구조

본 논문에서는 의미유형들의 초기 군집을 구성하고 적합도 평가에 의해 각 군집이 상위 군집과 통합될 수 있는지를 평가하여 선택된 군집들을 통합한다.

시스템의 구성은 초기군집으로부터 선택, 교배, 돌연변이 등의 연산들을 사용하는 진화 과정을 통해 다음 세대의 군집을 생성하는 유전자 알고리즘과 유사한 흐름으로 진행되며, 시스템 구성도는 그림 1과 같다.



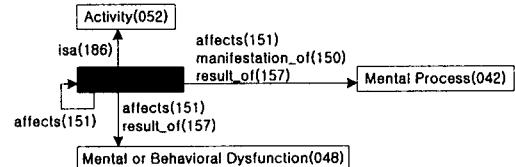
[그림 1] 군집화 시스템의 구성도

### 3.2 데이터 초기화와 초기 클러스터링

의미유형과 의미관계에 십진수 세자리 숫자의 고유번호를 할당하여 이를 데이터베이스화 한다.

그림 2 는 의미망의 일부를 보여준다. Activity, Behavior, Mental Process, Mental or Behavioral

Dysfunction 이 의미유형이고, affects, manifestation\_of, result\_of 가 의미관계로 화살표를 이용하여 방향을 표현하고 있다. 이를 각각에 052, 053, 042, 048, 151, 150, 157 와 같은 세자리 숫자의 고유번호를 부여한다.



[그림 2] UMLS 의미망의 일부분

부여된 고유번호로 각 의미유형의 정보와 의미관계들을 표현한다. 예를들면, result\_of 관계로 의미유형 Mental Process 에 연결되어 있는 의미관계는 151042 로 각각의 고유번호를 나열하여 표현한다. 또한 해당 의미유형의 의미망에서의 위치를 나타내는 TID, 하위 의미유형의 개수, 상위 의미유형 그리고, DNI 관계를 포함하는지의 여부를 포함한다. 그림 2 와 같은 Behavior 의미유형은 {053|B1, 1|2|186052|N|150048|151042|151048|151053|157042|157048}로 표현한다.

데이터베이스 구성 후, isa 관계에 있는 의미유형들 중 동일한 의미관계를 가지는 의미유형들을 하나로 군집화하여 초기 군집을 구성한다.

### 3.3 적합도 함수

본 논문에서는 유사한 두개의 군집을 발견하여 병합하는 과정을 반복적으로 수행한다. 이 때 우수한 두 개의 군집을 찾아내기 위해 식(1)과 같은 UMLS 의미망에 적합한 적합도 측정방법을 고안했다. 적합도는 군집<sub>i</sub> 와 군집<sub>j</sub>의 유사도와 결합적합도에 의해 계산된다.

$$Fit_{ij} = \frac{UFit_{ij}}{Sim_{ij}} \quad \text{식(1)}$$

$UFit_{ij}$ : 군집<sub>i</sub> 와 군집<sub>j</sub>의 결합적합도

$Sim_{ij}$ : 군집<sub>i</sub> 와 군집<sub>j</sub>의 유사도

#### 3.3.1 결합적합도

여러 의미유형들이 하나의 군집을 이루면 그 군집에서의 루트노드가 해당 군집을 대표하는 의미유형이 되므로, 결합적합도를 계산하여 두 군집이 병합되었을 때 병합된 군집의 루트노드가 해당 군집을 얼마나 잘 대표할 수 있는지를 평가한다. 두 군집의 결합적합도 계산 방법은 식(2)와 같다.

$$UFI_{ij} = \frac{UC_{Oij}}{EC_{Oij} + EC_{Oij}}$$

2

$$UC_{Oa} = \frac{\sum_{a=1}^{n_i} \frac{M(R_i, I_a)}{\max(|R_i|, |I_a|) - M(R_i, I_a) + 1}}{n_i + n_j}$$

$$EC_{Oa} = \frac{\sum_{a=1}^{n_i} \frac{M(R_i, I_a)}{\max(|R_i|, |I_a|) - M(R_i, I_a) + 1}}{n_i}$$

$n_i$  : 군집  $i$ 에 속하는 의미유형의 개수

$R_i$  : 군집  $i$ 의 루트 의미유형

$M(R_i, I_a)$  : 의미유형  $R_i$ 와 의미유형  $I_a$  사이에 일치하는 의미관계의 개수

$\max(|R_i|, |I_a|)$  :  $R_i$ 와  $I_a$  중 의미관계 개수 중 큰 숫자

군집  $i$ 는 군집  $j$ 의 루트 의미유형의 부모 의미유형이 속한 군집으로 한다. 즉, 부모군집과 자식군집의 적합도를 계산하여 병합여부를 결정하는 것이다.

각 군집의 결합적합도를 나타내는  $EC_{Oa}$  와  $EC_{Oj}$  의 평균에 비해 두 군집을 병합했을 때의 결합적합도를 나타내는  $UFI_{ij}$  가 크다면 두 군집의 결합적합도는 높은 것이다.

### 3.3.2 군집간의 유사도

본 논문에서는 군집내의 모든 의미유형들이 공통적으로 가지고 있는 공통 의미관계와 그 외의 비공통 의미관계들을 분류하여 유사도를 계산함으로써 계산량을 줄이고자 한다.

먼저, 두 군집에서 공통 의미관계를 추출하여 그림 3과 같은 비교 테이블을 구성한다. 2 행은 군집  $i$ 의 의미유형이 정의하고 있는 것이면 1, 아니면 0이라고 표기하고, 3 행은 같은 방법으로 군집  $j$ 에 대하여 나타내고 있다

군집 $i$ 의 공통 의미관계 : 150048 151042 151048 151053
군집 $j$ 의 공통 의미관계 : 150048 151042 157042 157048
의미관계 150048 151042 151048 151053 157042 157048
군집 $i$ 1 1 1 1 0 0
군집 $j$ 1 1 0 0 1 1

(111100) XOR (110011) = 001111

[그림 3] 공통 의미관계 유사도 계산

이 테이블의 2 행과 3 행을 행단위로 추출하여 XOR 연산을 수행하면 두 군집의 모든 의미유형이 공통적으로 가지고 있는 의미관계의 개수와 그렇지 않은 것의 개수를 구할 수 있다. XOR 연산의 결과를 사용하여 식(3)과 같이 유사도를 계산한다.

$$SimA = \frac{(n_i^2 \times D_i) + (n_j^2 \times D_j)}{2}$$

식(3)

$n_i$  : 군집  $i$ 의 의미유형 개수

$D_i$  : XOR 연산 결과 1의 개수

군집내의 비공통 의미관계를 사용한 유사도 계산을 하기 위해 그림 4와 같은 별도의 테이블을 구성한다.

군집 $i$ 의 비공통 의미관계 : 150048 151042 151048 151053 157042
군집 $j$ 의 비공통 의미관계 : 150048 151042 157042 157048
의미관계 150048 151042 151048 151053 157042 157048
군집 $i$ 3 2 1 4 6 0
군집 $j$ 4 1 0 0 3 1

[그림 4] 비공통 의미관계 유사도 계산

2 행은 군집  $i$ 에서 나타난 해당 의미관계의 빈도수이고, 3 행은 군집  $j$ 에서 나타난 의미관계의 빈도수이다. 이 테이블을 이용한 유사도 계산법은 식(4)와 같다.

$$SimB = \frac{\sum_{a=1}^{row} (w_i \times T_{2a-1})^2 + \sum_{a=1}^{row} (T_{2a-1} \times w_j)^2}{2}$$

$$w_i = \frac{|n_i|}{|n_j|}, \quad w_j = \frac{|n_j|}{|n_i|}$$

$n_i$  : 군집  $i$ 의 의미유형의 개수

row: 행의 수

$T_{2a-1}$  : 테이블의 2 행 a 열의 빈도수

위의 식(3)과 식(4)의 결과로 식(5)과 같이 두 군집간의 유사도를 계산한다.

$$Sim = \sqrt{SimA + SimB}$$

식(5)

### 3.4 선택, 교배와 돌연변이

선택단계에서는 적합도 값이 크고 의미관계의 개수가 적은 군집에 상대적으로 많은 병합 기회를 부여한다.

교배단계에서 먼저  $SimA$  계산 과정에서 만들어진 테이블을 이용하여 군집  $i$ 와 군집  $j$ 에 모두 있는 공통 의미관계를 군집  $i$ 의 새로운 공통 의미관계로 생성한다. 군집  $i$ 의 의미유형의 비공통 의미관계에 기존 군집  $i$ 의 공통 의미관계에서 탈락한 의미관계들을 추가하고 군집  $j$ 의 의미유형의 비공통 의미관계에 기존 군집  $j$ 의 공통 의미관계에서 탈락한 의미관계들을 추가한다. 교배단계의 마지막으로 군집  $i$ 의 의미유형에 추가하고 군집  $j$ 를 삭제한다.

돌연변이단계에서는 리프노드인 의미유형이 DNI 선언이 되었을 경우 DNI 선언 정의를 삭제하여 군집의 효율성을 높인다.

## IV. 실험 및 평가

본 논문에서는 [2]에서 제공하는 2003AA edition의 의미망 데이터를 사용하여 실험하였다. 초기 군집 단계에서는 82 개의 군집이 형성되었다. 각 군집에 포함된 의미유형의 개수는 표 1 와 같다. 첫번째 행은 군집내 의미유형의 개수이고, 두번째 행은 해당 군집의 개수이다.

[표 1] 초기 군집의 결과

	1	2	3	4	6	8	14
	62	9	5	3	1	1	1

각 군집과 그 상위 그룹을 병합후보들이라고 한다. 각 병합후보들에 대해 결합적합도, 유사도, 적합도를 구하여 모든 병합후보들의 유사도가 임계값을 초과하면 분류과정을 마친다.

열번의 적합도 판정 과정을 거쳐 최종 요약된 의미망을 구성하였으며, 선택 단계에서 선택된 병합후보의 개수는 각각 17, 13, 13, 9, 5, 3, 1, 1, 0 개이다.

교배 연산은 선택 단계에서 선택된 후보군집을 대상으로 수행되었으며 앞에서 언급한 대로 하위 군집을 상위 군집에 합병하고 하위 군집을 삭제하였다.

돌연변이 연산은 10 개의 의미유형에서 발생했고, DNI 선언을 별도 처리한 결과 모두 상위 그룹과 통합되었다.

최종 분할은 23 개의 군집으로 분할되었으며 결과는 표 2 와 같다. 첫번째 행은 군집내 의미유형의 개수이고, 두번째 행은 해당 군집의 개수이다.

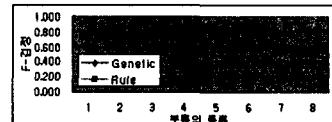
[표 2] 23 개의 군집

	1	2	3	4	5	6	7	8	9	15	16	21
	4	3	3	2	2	1	3	1	1	1	1	1

본 논문의 평가는 전문가들과 비전문가들이 규칙에 의해 수작업으로 분류한 결과와 비교하여 재현율, 정확율, F-검정을 계산하여 평가하였다. 본 논문에서의 결과를 Genetic 이라고하고, [3]의 결과를 Rule 이라고하며, 비교 결과는 표 3 과 그림 5 에서 보이고 있다.

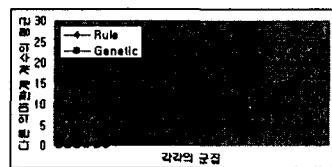
[표 3] 평가결과 (재현율/정확율/F-검정)

0.966 / 0.683 / 0.800	0.928 / 0.634 / 0.753
0.897 / 0.667 / 0.765	0.892 / 0.641 / 0.745
0.931 / 0.771 / 0.844	0.892 / 0.714 / 0.793
0.897 / 0.839 / 0.867	0.821 / 0.741 / 0.778
0.862 / 0.833 / 0.847	0.821 / 0.766 / 0.792
0.724 / 0.955 / 0.824	0.714 / 0.909 / 0.799
0.448 / 0.929 / 0.605	0.428 / 0.857 / 0.570
0.379 / 0.917 / 0.537	0.357 / 0.833 / 0.499



[그림 5] Genetic 과 Rule 의 비교

의미망의 분할은 군집을 대표하는 루트와 하위노드와의 구조적 유사성이 중요하므로 각 군집의 루트와 하위노드와의 의미관계를 비교하여 일치하지 않는 의미관계 개수의 평균을 구하여 비교하였으며, 그 비교 결과는 그림 6 과 같다.



[그림 6] 루트노드와 하위노드의 구조적 차이

루트와 하위노드와의 일치하지 않는 의미관계 개수 평균의 총합은 Genetic 은 166.967, Rule 은 167.339 이고 군집의 개수로 평균화한 값은 각각 5.757, 5.967 로 Genetic 방식이 군집의 루트와 하위노드 간의 유사성이 더 높음을 알 수 있다.

## V. 결론

본 논문에서는 UMLS 의미망을 자동 군집화 방법을 제안하였다. 유사도와 적합도를 이용한 적합도함수를 제안하고 유전자 알고리즘을 이용하여 분류의 효율성을 향상시켰다. 향후 과제로는 의미망의 내부구조외에 메타시스템소스에서의 개념들과 의미유형과의 관련성을 함께 고려한다면 좋은 결과를 기대할 수 있을 것이다.

## 참고 문헌

- [1] James Geller, Yehoshua Perl, Michael Halper, Zone Chen, and Hyanying Gu. "Evaluation and Application of a Semantic Network Partition," IEEE Transaction on Information Technology Biomedicine Vol. 6, no. 2, 109-115, June 2002.
- [2] NLM, UMLS Knowledge Source Server, URL: <http://umlsks.nlm.nih.gov/>.
- [3] Zong Chen, Yehoshua Perl, Michael Halper, James Geller, and Hyanying Gu "Partitioning the UMLS Semantic Network" IEEE Transaction on Information Technology Biomedicine Vol. 6, no. 2, 102-108, June 2002.