

# A Classification Method of Delirium Patients Using Local Covering-Based Rule Acquisition Approach with Rough Lower Approximation

Chang Sik Son<sup>†</sup> · Won Seok Kang<sup>††</sup> · Jong Ha Lee<sup>†††</sup> · Kyoung Ja Moon<sup>††††</sup>

## ABSTRACT

Delirium is among the most common mental disorders encountered in patients with a temporary cognitive impairment such as consciousness disorder, attention disorder, and poor speech, particularly among those who are older. Delirium is distressing for patients and families, can interfere with the management of symptoms such as pain, and is associated with increased elderly mortality. The purpose of this paper is to generate useful clinical knowledge that can be used to distinguish the outcomes of patients with delirium in long-term care facilities. For this purpose, we extracted the clinical classification knowledge associated with delirium using a local covering rule acquisition approach with the rough lower approximation region. The clinical applicability of the proposed method was verified using data collected from a prospective cohort study. From the results of this study, we found six useful clinical pieces of evidence that the duration of delirium could more than 12 days. Also, we confirmed eight factors such as BMI, Charlson Comorbidity Index, hospitalization path, nutrition deficiency, infection, sleep disturbance, bed scores, and diaper use are important in distinguishing the outcomes of delirium patients. The classification performance of the proposed method was verified by comparison with three benchmarking models, ANN, SVM with RBF kernel, and Random Forest, using a statistical five-fold cross-validation method. The proposed method showed an improved average performance of 0.6% and 2.7% in both accuracy and AUC criteria when compared with the SVM model with the highest classification performance of the three models respectively.

Keywords : Delirium, Geriatric Syndrome, Rough Set Approximation, LEM2, Classification Rule

## 러프 하한 근사를 갖는 로컬 커버링 기반 규칙 획득 기법을 이용한 섬망 환자의 분류 방법

손 창 식<sup>†</sup> · 강 원 석<sup>††</sup> · 이 종 하<sup>†††</sup> · 문 경 자<sup>††††</sup>

## 요 약

섬망은 의식 장애, 주의력 장애 및 언어력 장애와 같은 일시적인 인지 장애가 있는 환자, 특히 노인에서 나타나는 가장 흔한 정신 장애 중 하나이다. 섬망은 환자와 가족에게 고통을 주고, 통증과 같은 증상의 관리를 방해할 수 있으며 노인 사망률 증가와 관련이 있다. 본 논문의 목적은 장기 요양 시설에서 섬망 환자를 구별하는데 사용될 수 있는 유용한 임상적 지식을 생성하는데 있다. 이러한 목적을 위해, 러프 하한 근사 영역을 갖는 로컬 커버링 규칙 기법을 활용하여 섬망과 관련된 임상적 분류 지식을 추출하였다. 제안된 방법의 임상적 적용 가능성은 전향적 코호트 연구로부터 수집된 데이터를 활용하여 확인하였다. 연구 결과, 섬망 기간이 12일 이상 지속될 수 있는 6가지 유용한 임상적 증거를 발견하였고, 체질량 지수, 동반질환 지수, 입원경로, 영양결핍, 감염, 수면박탈, 욕창, 기저귀 사용과 같은 8가지 인자들이 섬망 결과를 구별하는 데 중요한 요인이라는 것을 확인하였다. 제안된 방법의 분류 성능은 통계적 5-겹 교차검정 방법을 사용하여 3가지 벤치마킹 모델, 즉 ANN, RBF 커널 함수를 활용한 SVM, 랜덤 포레스트와 비교하여 검증하였다. 제안된 방법은 3가지 모델 중 가장 높은 성능을 제공한 SVM 모델과 비교했을 때 정확도와 AUC 기준에서 평균 0.6%와 2.7% 개선된 성능을 보였다.

키워드 : 섬망, 노인성 증후군, 러프 집합 근사화, LEM2, 분류 규칙

## 1. 서 론

섬망(delirium)은 다양한 원인에 의해서 갑자기 발생한 의

식 장애, 주의력 저하, 언어력 저하 등의 인지기능 전반의 장애와 정신병력 증상을 유발하는 대표적인 노인 증후군(geriatric syndrome) 중 하나이다[1]. 과거에는 급성 혼돈상태(acute confusional state), 급성 뇌증후군(acute brain syndrome), 급성 뇌부전(acute brain failure), 중환자실 증후군(intensive care unit syndrome) 등의 여러 가지 용어가 혼용되어 사용되었다[2, 3]. 그러나 DSM-IV(diagnostic and statistical manual of mental disorders)[4]에서 인지기능 장애를 섬망, 치매(dementia), 기억장애(memory complaints) 및 기타 기억장애로 구분한 이후로부터 섬망으로 통일되어 사용되고 있다[5]. 섬망은 주의력, 집중력, 언어력 저하 이외에도 혼

※ 이 논문은 2019년도 산업통상자원부 및 산업기술평가관리원(KEIT) 연구비 지원에 의해 수행되었습니다(10077260, 10063553).

※ 이 논문은 2019년도 한국정보처리학회 추계학술발표대회에서 '로컬 커버링 규칙 획득기법을 활용한 섬망 환자의 분류'의 제목으로 발표된 논문을 확장한 것이다.

† 정 회 원 : 대구경북과학기술원 지능형로봇연구부 선임연구원

†† 정 회 원 : 대구경북과학기술원 지능형로봇연구부 책임연구원

††† 비 회 원 : 계명대학교 의과대학 의용공학과 부교수

†††† 비 회 원 : 계명대학교 간호학과 조교수

Manuscript Received : December 20, 2019

Accepted : January 29, 2020

\* Corresponding Author : Chang Sik Son(changsikson@dgist.ac.kr)

돈, 환각, 망상이나 정신운동성 초조와 공격적 행동 등을 나타낸다[6].

종합병원 입원환자에서 섬망의 유병률(prevalence rate)은 환자의 연령, 질환의 중증도에 따라 다른 것으로 알려져 있지만, 대개 65세 이상 노인 환자에서 발생률이 높으며, 특히 화상 환자의 20%, 암 환자의 20%, 응급실에 내원한 환자의 25%, 중환자실 환자의 30%, 수술 후 환자의 7~52%, 각종 질환의 말기 환자에서 80%로 차이를 보인다[7-9]. 특히 요양원 또는 요양 시설에서 섬망의 유병률이 더욱더 높게 나타나는 것으로 보고되고 있는데, 이는 섬망의 고위험군인 노인이 주로 거주하고 치매의 유병률이 높기 때문이다[10].

섬망의 초기 진단은 환자의 보호자 또는 가족으로부터 병력 청취를 통해 섬망 증상의 발생 시점과 증상의 변화 등을 확인하고, 그 외에 환자의 주위 환경 변화, 동반된 질환 여부 및 약물 복용력 등을 파악한다. 환자의 인지 기능은 간이 정신 상태 검사(mini-mental status examination, MMSE)와 착란 평가 방법(confusion assessment method, CAM)을 활용한 신체검사를 통해 평가된다. 그리고 섬망에 기여하는 인자들을 확인하거나 다른 유사 질환들을 구별하기 위한 방법으로 혈액검사를 병행하고, 신경학적 이상이나 외상이 있는 것으로 의심되는 경우 컴퓨터단층촬영(computerized tomography, CT)과 자기공명영상진단(magnetic resonance imaging, MRI)을 이용한 뇌 영상 검사가 시행된다[11].

기존의 선행된 섬망 관련 연구결과를 살펴보면, 대부분 중환자실 환자에서 섬망과 관련된 위험인자를 선별하는데 로지스틱 회귀분석(logistic regression, LR) 모형을 활용한 분석 연구가 주를 이루고 있다[12, 13]. 그러나 로지스틱 회귀분석 모형은 섬망과 관련된 독립적인 위험인자를 손쉽게 찾을 수 있는 선형 분석 기법이지만, 다양한 위험인자들 간에 상호작용을 찾고 유용한 인자들을 효과적으로 선별할 수 없는 어려움이 있다. 이러한 제약점을 개선하기 위한 방안으로 Lee와 Bae[14]은 C5.0, CART, LR 및 베이저안 신뢰망(bayesian belief network, BBN)와 같은 다양한 기계학습(machine learning) 기법을 섬망 데이터에 적용한 비교 연구를 수행하였고, 섬망과 관련된 위험인자와 이들 인자들 간에 복합 작용을 해석하는데 BBN 모형이 가장 적절함을 제시하였다. 최근에는 중환자실 환자와 심장 수술(cardiac surgery) 환자에서 섬망을 식별할 수 있는 예측 모형을 개발하는데 랜덤 포레스트(random forest, RF), 인공 신경망(artificial neural network, ANN), 서포트 벡터 머신(support vector machine, SVM) 등을 활용하고 있다. 이들 연구는 다양한 임상과학에서 섬망 치료를 위한 원인을 찾거나 외과적 수술 후 섬망의 발생을 사전에 효과적으로 구별할 수 있는 기계학습 방법을 찾는데 궁극적인 목적을 두고 있다. 이들 연구결과에 따르면, RF[15, 16]는 일반적인 섬망 데이터를 예측할 때 가장 좋은 모형으로 평가하였고, SVM[17]과 ANN[18]은 중환자실 환자 또는 심장 수술 환자에서 섬망의 발생을 예측하는데 가장 적합한 평가 모형으로 제시하고 있다. 그러나 섬망 연구뿐만

아니라 여러 임상응용연구에서 가장 중요한 점은 분석 모형의 성능 이외에, 추론된 결과를 설명하거나 해석할 수 있는 의학적 근거(evidence)를 제시할 수 있어야 한다.

본 논문의 목적은 섬망의 진단과 예측적 근거를 제시할 수 있는 임상 의사결정지원시스템(clinical decision-making support system)을 개발하기 위한 선행연구로서, 요양원이나 요양 시설에 입원한 노인 환자의 특성(나이, 성별, 동반 질환 지수, 입원 경로 등)과 16가지 위험인자들(뇌 손상 과거력, 수면 박탈, 욕창, 약물 사용 등)을 활용하여 섬망 환자를 사전에 구별할 수 있는 임상적 지식을 생성하는 데 있다. 이를 위해 본 연구에서는 러프 집합(rough set)의 근사화(approximations) 개념과 로컬 커버링 규칙 획득(local covering-based rule acquisition) 기법을 활용한 응용 방법을 소개하고, 선행 연구에서 활용된 몇 가지 기계학습 기법들과 성능을 비교한다. 본 논문의 구성은 다음과 같다. 2장에서는 러프 집합의 2가지 근사화 개념과 이를 활용한 로컬 커버링 기반 규칙 획득 기법에 관해서 설명한다. 3장에서는 본 연구에서 활용된 섬망 데이터의 특성과 실험 결과에 관해서 설명하고, 4장에서 결론을 맺는다.

## 2. 로컬 커버링 기반 규칙 획득 기법

특정 분야의 전문가가 주어진 문제를 해결하는 데 도움이 되는 정보를 찾고, 지식을 습득하는 과정은 오랜 시간 수많은 시행착오를 겪으면서 얻은 경험이 있어야만 가능하다. 지식 획득(knowledge acquisition)은 다양한 종류의 데이터들로부터 유용한 규칙들을 자동으로 생성하는 중요한 단계이다. 지식 획득의 목적은 데이터로부터 추출된 규칙들을 이용하여 이전에 볼 수 없었던 새로운 사건에 대해서 가능한 한 정확하게 의사결정을 내릴 수 있는 추론 모델을 구성하는 데 있다.

본 연구에서는 여러 지식 획득 방법 중에서 LERS (learning from examples using rough sets) 시스템[19]에 포함된 2가지 규칙 생성 방법들 가운데 러프 집합의 2가지 근사화 개념[20], 즉 하한(lower) 또는 상한 근사(upper approximations) 개념을 활용한 LEM2 알고리즘[21]을 이용한 응용 방법을 소개한다.

일반적으로 러프집합에서 의사결정표(decision table, DT)  $DT=(U, C, D, V, f)$ 은 4개의 튜플(tuple)로 구성된다.  $U$ 는 샘플 (혹은 사례)들의 전체집합(universe of discourse),  $C$ 는  $a \in C$ 에 대해서  $f: U \rightarrow V_a$ 로 사상되는 입력 (혹은 조건) 속성의 집합(set)을 나타낸다.  $V_a$ 는 임의의 속성  $a$ 의 값들로 구성된 집합을 의미한다. 그리고  $D$ 는  $d \in D$ 에 대해서  $f: U \rightarrow V_d$ 로 사상되는 출력 (즉 의사결정) 속성의 집합을 나타낸다. DT에서 임의의 속성 부분집합(subset)  $P \subseteq C$ 에 대한 동치관계(equivalence relation)  $IND(P)$ 는 다음과 같이 정의된다.

$$IND(P) = \{(x, y) \in U^2 \mid a(x) = a(y), \forall a \in P\} \quad (1)$$

$x$ 와  $y$ 는 전체집합  $U$ 에서  $x$ 와  $y$ 번째 샘플을 의미하고,  $a(x)$ 와  $a(y)$ 는 임의의 속성  $a$ 에서  $x$ 와  $y$ 번째 샘플의 값을 나타낸다. 그러므로 속성 부분집합  $P$  상에서 동치관계  $IND(P)$ 는 이진 관계(binary relation)로 표현할 수 있다.

동치관계  $IND(P)$  상에서 샘플들의 분할(partition)은  $U/IND(P)$ 로 표기하고 Equation (2)과 같이 정의된다.

$$U/IND(P) = \otimes \{ U/IND(a) | a \in P \} \quad (2)$$

where,  $A \otimes B = \{ X \cap Y | X \in A, Y \in B, X \cap Y \neq \emptyset \}$

만약 두 샘플  $x$ 와  $y$ 의 관계  $xPy$ 가 동치관계를 만족한다면, 두 샘플은 속성 부분집합  $P$  상에서 구별할 수 없으며, 식별불가능(indiscernibility)하다고 정의할 수 있다. 이때 속성 부분집합  $P$ 의 동치류(equivalence class)  $[x]_P$ 는 Equation (3)과 같이 정의된다.

$$[x]_P = \{ y | (x, y) \in IND(P), \forall a \in P \} \quad (3)$$

러프 집합에서 2가지 근사화 개념인 하한과 상한에 관한 간략한 설명을 위해 Table 1의 샘플 데이터를 고려하자. 위의 정의에 따라, 전체집합  $U$ 는 7개의 샘플, 입력 속성  $C$ 는 4개의 변수, 출력 속성  $D$ 는 1개의 변수로 구성된다. 이때 입력과 출력 속성에 관한 값들의 집합  $V$ 는 다음과 같이 정의된다:  $V_T = \{\text{very high, high, normal}\}$ ,  $V_H = V_W = V_N = V_F = \{\text{yes, no}\}$ . Table 1에서 T, H, W, 그리고 F는 Temperature, Headache, Weakness, Flu를 의미한다. 만약 입력 속성의 부분집합  $P$ 가  $\{H, W\}$ 로 정의된다면, 샘플 1과 4, 샘플 3과 6, 그리고 샘플 5와 7은 식별불가능하고, Equation (2)에 의해서 샘플들을 다음과 같이 분할할 수 있고, Equation (3)에 의해서 4개의 동치류  $[1]_P = [4]_P$ ,  $[2]_P$ ,  $[5]_P = [7]_P$ ,  $[3]_P = [6]_P$ 을 추출할 수 있다.

Table 1. Sample Data

No.	T	H	W	N	F
1	very high	yes	yes	no	yes
2	high	yes	no	yes	yes
3	normal	no	no	no	no
4	normal	yes	yes	yes	yes
5	high	no	yes	no	yes
6	high	no	no	no	no
7	normal	no	yes	no	no

$$U/IND(P) = U/IND(H) \otimes U/IND(W)$$

$$= \{ \{1, 2, 4\}, \{3, 5, 6, 7\} \} \otimes \{ \{1, 4, 5, 7\}, \{2, 3, 6\} \}$$

$$= \{ \{1, 4\}, \{2\}, \{5, 7\}, \{3, 6\} \}$$

러프집합에서 하한과 상한 근사는 입력과 출력 속성 간에 동치류의 포함관계(inclusion relation)를 이용하여 쉽게 유도 가능하다. Equation (4)와 (5)는 하한과 상한 근사의 정의를 나타낸다.

$$\underline{PD}(x) = \{ x \in U | [x]_P \subseteq [x]_D \} \quad (4)$$

$$\overline{PD}(x) = \{ x \in U | [x]_P \cap [x]_D \neq \emptyset \} \quad (5)$$

Equation (4)의 하한 근사는 속성 부분집합  $P$  상에서 각 샘플의 동치류  $[x]$ 가 해당 출력 값 (즉 클래스)의 동치류에 완전히 포함되는 경우를, Equation (5)의 상한 근사는 해당 출력 값의 동치류에 일부분 포함되는 경우를 나타낸다. 다시 말해서, 하한 근사는 전체 샘플 데이터에서 정확히 분류되는 샘플들을, 상한 근사는 정확히 분류되거나 잘못 분류될 수 있는 샘플들을 포함한다. 그러므로 러프집합의 불확실한 영역, 즉 경계영역(boundary region)은 Equation (6)과 같이 정의되고, Fig. 1과 같이 도식화할 수 있다. 보다 자세한 내용은 참고문헌[22, 23]을 참고하기 바란다.

$$BND_P = \bigcup_x \overline{PD}(x) - \bigcup_x \underline{PD}(x) \quad (6)$$




Fig. 1. Rough Set Approximations

Table 2는 섬망 환자를 구별할 수 있는 임상적 지식을 유도하기 위한 LEM2 알고리즘[21,24]의 의사 코드(pseudo code)를 보여준다.

라인 7에서  $t$ 는 하나의 속성-값 쌍 (예, Table 1에서 (T, very high)),  $[t]$ 는  $t$ 의 동치류 (Equation (3) 참조), 그리고  $T(G)$ 는 상한 근사에 포함된 속성-값 쌍의 집합을 의미한다. 라인 10에서 13은  $T(G)$ 에 포함된 속성-값 쌍들 가운데에 가장 좋은 우선순위를 가진 한 개의 속성-값 쌍  $t$ 를 선택하는 과정을 나타내고, 해당 조건을 만족하는 속성-값 쌍  $t$ 가 더 이상 존재하지 않을 때까지 그 과정을 반복 한다 (라인 8에서 18). 라인 19에서 23은 선택된 속성-값 쌍 중에서 제거하더라도 결과에 영향을 끼치지 않는 불필요한 속성-값 쌍  $t$ 를 순차적으로 제거하고, 후보 규칙(candidate rule)을 구성하는 과정을 나타낸다. 라인 25에서 27은 생성된 후보 규칙들 가운데에 불필요한 규칙을 제거하는 후처리 과정을 설명한다. 본 연구에서는 더욱 적은 수의 샘플을 활용하여 섬망 환자를 구별할 수 있는 임상적 규칙을 생성하기 위해, 전체 샘플 데이터에서 하한 근사영역에 포함된 샘플들을 LEM2 알고리즘의 입력으로 사용하였다.

### 3. 실험 결과

본 실험의 목적은 섬망 환자를 사전에 구별할 수 있는 유용한

Table 2. LEM2 Algorithm

<b>Input:</b> $B$ // Samples in lower or upper approximation
<b>Output:</b> $R$ // a rule-set (or rules)
1 begin
2 $G = B$
3 $R = \emptyset$
4 while $G \neq \emptyset$
5 begin
6 $T = \emptyset$
7 $\mathcal{T}(G) = \{t \mid d \cap G \neq \emptyset\}$ // 식 (5)
8 while $T = \emptyset$ or $[\mathcal{T}] \not\subseteq B$
9 begin
10 select a pair $t \in \mathcal{T}(G)$ such that $ d \cap G $ is
11 maximum: if a tie occurs, select a pair $t \in \mathcal{T}(G)$
12 with the smallest cardinality of $d$ ; if another
13 tie occurs, select first pair;
14 $T = T \cup \{t\}$
15 $G = d \cap G$
16 $\mathcal{T}(G) = \{t \mid d \cap G \neq \emptyset\}$
17 $\mathcal{T}(G) = \mathcal{T}(G) - T$
18 end while
19 for each $t \in T$ do
20 if $ T - \{t\}  \subseteq B$ then $T = T - \{t\}$
21 end for
22 $R = R \cup \{T\}$
23 $G = B - \cup_{T \in R} [T]$
24 end while
25 for each $T \in R$ do
26 if $\cup_{S \in R - \{T\}} [S] = B$ then $R = R - \{T\}$
27 end for
28 end

임상적 지식을 찾고, 객관적인 성능지표를 제공하는데 있다. 이를 위해 120개와 100개의 병상을 보유한 대구와 경북지역에 위치한 2곳의 장기 요양 시설(long-term care facilities)에 입원한 노인 환자를 대상으로, 2016년 10월부터 2017년 3월까지 6개월 동안 전향적 코호트 연구(prospective cohort study)를 통해 수집된 데이터를 활용하였다[1]. 초기에 코호트 연구의 참가자(n=321)는 섬망 혹은 치매가 없는 환자, 치매가 있는 환자, 섬망이 있는 환자, 그리고 치매로 발병된 섬망 환자로 분류하였다. 이들 환자 중 입원 후 12시간 이내에 장기 요양 시설에서 이송되거나 같은 기간 내에 사망한 환자 또는 코호트 연구에 참여를 거부한 노인 환자 148명을 제외한 173명을 최종 연구 대상으로 선정하였다.

본 연구에서는 섬망 환자를 구별할 수 있는 임상적 분류 근거를 마련하기 위해, 코호트 연구에 참여한 네 그룹의 참여자들을 비 섬망군(no delirium)과 섬망군(delirium)으로 재분류하였다. 여기서 비섬망군은 섬망 증상이 없거나 치매가 있는 환자, 섬망군은 섬망 증상이 있거나 치매로 발병된 섬망 환자로 구분하였다.

3.1 데이터 특성

Table 3은 전향적 코호트 연구로부터 수집된 데이터를 비 섬망군과 섬망군으로 재분류하였을 때 연구 참여자의 특성을

보여준다. 평균 나이는 76.9세인 것으로 조사되었고, 이때 비 섬망군과 섬망군의 평균 나이는 각각 72.7세와 81.4세였고, 섬망군은 비 섬망군에 비해 평균 8.7세 많은 것으로 나타났다. 성별에서는 전체 173명의 환자들 중 128명(74%)이 여성으로 조사되었고, 섬망군의 경우 여성의 비율이 78.3%를 차지하였다. 체질량지수(body mass index, BMI)에서는 섬망군이 비 섬망군에 비해 평균 1.3kg/m<sup>2</sup>가 낮은 것으로 조사되었다. 동반질환 지수(CCI)의 경우 비 섬망군에 비해 섬망군에서 평균 3.5점, 총 복용약의 수(total number of medications)에서도 평균 0.8배 높은 것으로 나타났다. 흡연(smoke)은 비 섬망군이 섬망군에 비해 다소 높은 비율을 보였고, 반면에 음주(alcohol)는 섬망군에서 다소 높은 비율을 보였지만 큰 차이는 나타나지 않았다. 인지기능 손상(cognitive impairment)은 전체 환자들 중 47.4%가 해당 병력을 가지고 있었고, 비 섬망군은 35.6%, 섬망군은 60.2%를 차지하였고, 섬망군에서 높은 비율을 보였다. 또한 입원 경로(admission path)에서는 전체 환자들 중 46.2%가 병원으로부터 이송된 것으로 조사되었고, 그다음으로 집, 다른 요양원 순을 보였고, 섬망군에서도 이와 유사한 특성을 보였다.

Table 3. Data Characteristics

Variable	No Delirium (N=90)	Delirium (N=83)	Total (N=173)
Age (years)	72.7±12.1	81.4±8.5	76.9±11.4
Female	63(70.0)	65(78.3)	128(74.0)
Body mass index (kg/m <sup>2</sup> )	21.4±3.4	20.1±3.8	20.8±3.6
CCI*	3.1±3.1	6.6±2.9	4.8±3.5
Number of medications	6.8±3.2	7.6±3.3	7.2±3.2
Smoke (yes)	18(20.0)	11(13.3)	29(16.8)
Alcohol (yes)	8(8.9)	10(12.0)	18(10.4)
Cognitive impairment <sup>†</sup>	32(35.6)	50(60.2)	82(47.4)
Admission path			
Home	34(37.8)	21(25.3)	55(31.8)
Hospital	33(36.7)	47(56.6)	80(46.2)
Other facility	22(24.4)	15(18.1)	37(21.4)
Other	1(1.1)	-	1(0.6)

\* CCI, Charlson Comorbidity Index

<sup>†</sup>Assessed by physician at time of admission

Table 4는 섬망과 관련된 16가지 임상적 위험인자를 보여준다.

임상적 위험요인들 중 뇌 손상 과거력(history of brain disease), 탈수증상(dehydration), 감염(infection), 환자의 움직임 등의 위험을 줄이기 위한 억제대(restraint)의 사용과 부동 유지(immobility)는 섬망군과 비 섬망군에서 큰 차이를 보이지 않았고, 영양결핍(nutritional deficiency), 수분 전해질 불균형(fluid imbalance), 수술(surgery) 여부, 수면박탈(sleep disturbance), 욕창(bed sores), 섬망 발병 시 약

Table 4. Clinical Risk Factors Associated with Delirium

Variable	No Delirium (N=90)	Delirium (N=83)	Total (N=173)
History of brain disease	8(8.9)	8(9.6)	16(9.2)
Nutrition deficiency	11(12.2)	39(47.0)	50(28.9)
Fluid imbalance	1(1.1)	7(8.4)	8(4.6)
Dehydration	3(3.3)	3(3.6)	6(3.5)
Surgery	3(3.3)	7(8.4)	10(5.8)
Infection	11(12.2)	11(13.3)	22(12.7)
Sleep disturbance	11(12.2)	30(36.1)	41(23.7)
Restraint	1(1.1)	1(1.2)	2(1.2)
Immobility	3(3.3)	3(3.6)	6(3.5)
Fall	49(54.4)	26(31.3)	75(43.4)
Bed scores	9(10.0)	25(30.1)	34(19.7)
Delirium medication*	3(3.3)	15(18.1)	18(10.4)
Foley catheter	4(4.4)	10(12.0)	14(8.1)
Nasogastric feeding	4(4.4)	11(13.3)	15(8.7)
Diaper use	23(25.6)	50(60.2)	73(42.2)
Pain score	3.2±1.2	2.9±1.3	3.0±1.3

\* Assessed by physician at time of admission

물사용(delirium medication), 인공도뇨(foley catheter), 위관영양(nasogastric feeding) 처치, 기저귀 사용(diaper use)은 섬망군에서 높은 비중을 차지하였다. 반면에 낙상(fall)은 비 섬망군에서 발생이 빈번한 것으로 조사되었고, 통증 점수(pain score) 또한 비 섬망군이 평균 0.3점 높은 것으로 나타났다.

### 3.2 섬망 분류 규칙

일반적으로 정량적인 값 혹은 정량 및 정성적인 값이 혼합된 이질적인 데이터(heterogeneous data)로부터 규칙을 생성하기 위해서는 수치로 구성된 변수(혹은 특징)를 이산화된 값으로 변환하는 범주화 과정(discretization process)이 선행되어야 한다. 본 연구에서는 여러 범주화 알고리즘 중에서 출력변수의 클래스를 판별하는데 관련성이 낮은 입력변수들을 제거할 수 있는 기능을 포함한 MDLP(minimum description length principle) 알고리즘[25]을 활용하였고, Table 3과 Table 4에서 5가지 정량적인 변수들 (즉 나이, 체질량지수, CCI, 총 복용약 수, 통증 점수)을 범주화하는데 적용하였다. 범주화 결과, 총 복용약 수의 경우 비 섬망군으로부터 섬망군을 식별하는데 적절한 분할 기준을 찾을 수 없었고, 나이, 체질량지수, CCI 및 통증 점수의 기준은 다음과 같았다: 가) 나이, 67.5와 92.5; 나) 체질량지수, 19.26; 다) CCI, 4.5; 라) 통증 점수, 2.5. 이들 기준을 활용하여 정량적인 값으로 표현된 변수들을 정성적인 값으로 범주화하였다. 또한 섬망 환자의 분류를 위한 임상적 규칙을 생성하기 위해서 전체 샘플 데이터 중에서 하한 근사영역에 포함된 169건(비 섬망

군 88건과 섬망군 81건)의 샘플들을 활용하였다. 그 결과 50개의 임상적 분류규칙을 생성할 수 있었고, 이들 규칙을 활용하여 전체 173건의 샘플 데이터를 분류하였을 때 분류 성능은 98.8%이었다. 이때 섬망군을 나타내는 민감도(sensitivity) 값은 97.6%, 비 섬망군을 나타내는 특이도(specificity) 값은 100%를 보여주었고, ROC(receiver operating characteristic) 상에서 AUC (area under the ROC curve) 값은 98.8% 수준이었다.

아래의 규칙은 섬망군으로 구별된 환자들로부터 추출된 상위 6개의 임상적 분류기준을 나타내고, 이들 규칙의 신뢰도는 모두 1.0 (즉 100%)을 보였다.

- R1) 체질량지수가 19.26 이하이고 기저귀를 사용하고 영양결핍 병력을 가진 환자 9.83%에서 섬망 발생 (평균 섬망의 발생 기간 13.5일)
- R2) 인공도뇨 처치를 시행하지 않은 환자들 중 욕창 병력이 있고 수면박탈이 있는 환자 6.36%에서 섬망 발생 (평균 섬망의 발생 기간 13.1일)
- R3) 낙상, 감염 병력 및 위관영양 처치를 받지 않은 환자들 중 체질량지수가 19.26 이하이고, 입원 경로가 병원인 환자 6.36%에서 섬망 발생 (평균 섬망의 발생 기간 12.6일)
- R4) 기저귀를 사용하지 않은 환자 중 CCI가 4.5 이상이고, 수면박탈이 있는 환자 5.78%에서 섬망 발생 (평균 섬망의 발생 기간 14일)
- R5) 비흡연자이면서 영양결핍 병력이 없었던 환자 중 CCI가 4.5 이상이고, 수면박탈이 있는 환자 5.78%에서 섬망 발생 (평균 섬망의 발생 기간 14일)
- R6) 기저귀를 사용하고 감염 병력을 가진 환자 5.2%에서 섬망 발생 (평균 섬망의 발생 기간 13.5일)

### 3.3 섬망 분류 규칙에 대한 통계적 교차검정

비록 본 논문에서 사용된 섬망 데이터가 장기 요양 시설에 입원한 노인환자를 대상으로 6개월 추적관찰을 통해 수집되었다 할지라도, 소규모의 샘플 수를 포함한다. 일반적으로 소규모 데이터로부터 분류 혹은 예측모형의 객관적인 성능을 추정하기 위한 수단으로 통계적 K-겹 교차검정(cross validation)을 시행한다.

본 실험에서는 제안된 방법의 객관적인 성능지표를 제공하기 위해서, 5-겹 교차 검정 실험을 실시하였다. 교차 검정 실험은 전체 173건의 샘플 데이터를 5개의 하위그룹으로 분할한 뒤, 4개의 하위그룹에 포함된 샘플 데이터는 섬망 환자를 분류하기 위한 규칙(즉 분류기)을 구성하는데 사용하였고, 나머지 1개의 하위그룹의 샘플 데이터는 섬망 분류 규칙의 예측 성능을 검증하기 위한 실험용으로 활용하였다. 제안된 방법의 분류 성능은 5번의 교차 검정 실험 동안에 측정된 정확도, 민감도, 특이도 및 AUC 척도에 대한 평균값을 각각 계산하였다. 또한 제안된 방법의 성능은 3가지 분류 모형 (즉 ANN, SVM with

Table 5. Classification Performance

Method	Avg. ACC* (%)	Avg. SENS* (%)	Avg. SPEC* (%)	Avg. AUC (%)	Avg. number of rules
Proposed	71.7	74.4	71.6	73.8	39
ANN <sup>a</sup>	67.6	59.0	75.6	67.6	-
SVM with RBF <sup>b</sup>	71.1	62.7	78.9	71.1	-
RF <sup>c</sup>	70.5	65.1	75.6	70.5	-

\* ACC, accuracy; SENS, sensitivity; SPEC, specificity

<sup>a</sup> ANN, batch size=100; number of hidden layers=1; number of hidden nodes=13; learning rate=0.3; momentum=0.2; epochs=500

<sup>b</sup> SVM, batch size=100; C=1.0; epsilon=1.0E-12; RBF kernel with gamma=0.01; tolerance parameter=0.001

<sup>c</sup> RF, size of each bag, as a percentage of the train set size (100); batch size=100, number of iterations=100

RBF kernel, RF)과 비교하였다. 모든 실험은 Windows 10 운영 체제 환경 (Intel(R) Core(TM) i7-6700 CPU @ 3.40GHz, 64GB RAM)에서 수행하였고, 제안된 방법은 Python 3.7과 IntelliJ IDEA 2019.2.4. (Ultimate Edition) 개발도구를 활용하여 구현하였다. 그리고 3가지 분류 모형은 Weka 3.8.3[26] 환경에서 실험하였다.

Table 5는 5-겹 교차 검증 실험 후 계산된 제안된 방법과 3가지 분류 모형에 대한 평균 성능 결과를 보여준다. 실험 결과, 3가지 벤치마킹 방법 중에서 SVM 모형이 가장 좋은 분류 성능을 보였고, 그다음으로 RF와 ANN 순으로 나타났다. SVM 모형과 성능 비교에서 제안된 방법은 분류 정확성에서 평균 0.6% 개선된 성능을 보였다. 그리고 민감도에서 SVM에 비해 평균 11.7% 개선된 성능을 보였지만, 특이도에서 평균 7.3% 낮은 성능 수준을 보였다. 그러나 이들 2가지 성능 평가 척도를 모두 고려한 AUC에서 제안된 방법은 SVM 보다 평균 2.7% 향상된 성능을 제공하였다.

#### 4. 결 론

본 연구에서는 러프집합 이론의 하한 근사와 로컬 커버링 규칙 획득 방법을 이용하여 섬망 환자를 보다 손쉽게 구별할 수 있는 임상적 지식을 생성할 수 있는 방법을 제안하였다. 제안된 방법의 임상적 응용 가능성을 제시하기 위해, 대구와 경북지역에 위치한 2곳의 장기 요양 시설에 입원한 노인 환자를 대상으로 6개월 동안 전향적 코호트 연구를 통해 수집된 9가지 기본 특성과 16가지 섬망 위험인자들로 구성된 데이터를 연구에 활용하였다.

연구 결과, 노인 환자의 기본 특성 중에서 체질량지수, 동반 질환 지수, 입원경로, 그리고 16가지 섬망 위험인자 중 영양결핍, 감염, 수면박탈, 욕창, 기저귀 착용 유무는 섬망 환자를 사전에 구별하는데 활용될 수 있는 중요한 요인이라는 점을 확인할 수 있었고, 이로부터 평균 섬망 기간이 12일 이상 유지될 수 있는 6가지 유용한 임상적 판단 기준을 획득할 수 있었다.

제안된 방법의 객관적인 성능수준을 제시하기 위해 기존의 섬망 연구에서 가장 좋은 예측 성능을 보였던 ANN, SVM, RF와 통계적 5-겹 교차 검증 실험을 실시하였다. 제안된 방법은 가장 우수한 성능을 보였던 SVM 모형보다 정확도와

AUC 평가 기준에서 각각 평균 0.6%와 2.7% 개선된 성능을 보였다. 그러나 비 섬망군의 식별 정도를 나타내는 특이도에서 다른 3가지 벤치마킹 방법보다 낮은 분류 성능을 보였다.

향후 연구에는 특이도 성능의 저하 원인을 개선시킬 수 있는 방법과 다양한 지식 획득기법들과의 비교 연구를 수행할 계획이다. 그리고 현재 전체 173건의 데이터로부터 추출된 50개의 섬망 분류규칙의 임상적 효과성을 검증하기 위한 중재연구(interventional study)를 준비 중에 있으며, 6가지 섬망 분류기준에 대한 임상적 근거를 확인할 계획이다.

#### References

- [1] K. J. Moon and H. O. Park, "Outcomes of Patients with Delirium in Long-term Care Facilities," *Journal of Gerontological Nursing*, Vol.44, No.9, pp.41-50, 2018.
- [2] Z. J. Lipowski, "Delirium (Acute Confusional States)," *Journal of the American Medical Association (JAMA)*, Vol.258, No.13, pp.1789-1792, 1987.
- [3] T. M. Brown and M. F. Boyle, "Delirium," *British Medical Journal (BMJ)*, Vol.325, No.7365, pp.644-647, 2002.
- [4] C. C. Bell, "DSM-IV: Diagnostic and Statistical Manual of Mental Disorders," *Journal of the American Medical Association (JAMA)*, Vol.272, No.10, pp.828-829, 1994.
- [5] B. D. Ku and J. H. Hong, "Clinical Approach to the Patients with Delirium in the Neurocritical Care," *Journal of Neurocritical Care*, Vol.3, No.2, pp.27-37, 2010.
- [6] J. S. Park, J. J. Kim, S. J. Park, S. M. Kim, and J. Y. Park, "Clinical Course According to Antipsychotics Prescription Pattern in Delirium," *Korean Journal of Psychosomatic Medicine*, Vol.25, No.2, pp.120-128, 2017.
- [7] J. R. Fann, "The Epidemiology of Delirium: A Review of Studies and Methodological Issues," *Seminars in Clinical Neuropsychiatry*, Vol.5, No.2, pp.64-74, 2000.
- [8] S. K. Inouye, "Delirium in Older Persons," *The New England Journal of Medicine*, Vol.354, No.11, pp.1157-1165, 2006.
- [9] J. I. Salluh, M. Soares, J. M. Teles, D. Ceraso, N. Raimondi, V. S. Nava, P. Blasquez, S. Ugarte, C. Ibanez-Guzman, J. V. Centeno, M. Laca, G. Grecco, E. Jimenez, S. Arias-Rivera,

- C. Duenas, M. G. Rocha, and The DECCA(Delirium Epidemiology in Critical Care) Study Group, "Delirium Epidemiology in Critical Care (DECCA): an International Study," *Critical Care*, Vol.14, No.6, pp.R210, 2010.
- [10] G. Bucht, Y. Gustafson, and O. Sandberg, "Epidemiology of Delirium," *Dementia and Geriatric Cognitive Disorders*, Vol.10, No.5, pp.315-318, 1999.
- [11] C. O. Kim, "Delirium," *The Korean Journal of Medicine*, Vol.79, No.s2, pp.536-540, 2010.
- [12] M. Dubois, Y. Strobik, N. Bergeron, M. Dumont, and S. Dial, "Delirium in an Intensive Care Unit: a Study of Risk Factors," *Intensive Care Medicine*, Vol.27, No.8, pp.1297-1304, 2001.
- [13] E. Arend and M. Christensen, "Delirium in the Intensive Care Unit: a Review," *Nursing in Critical Care*, Vol.14, No.3, pp.145-154, 2009.
- [14] J. Y. Lee and J. Y. Bae, "The Effect Investigation of the Delirium by Bayesian Network and Radial Graph," *The Koran Data and Information Science Society*, Vol.22, No.5, pp.911-919, 2011.
- [15] A. Davoudi, A. Ebadi, P. Rashidi, T. O. Baslanti, A. Bihorac, and A. C. Bursian, "Delirium Prediction using Machine Learning Models on Preoperative Electronic Health Records Data," in *Proceedings of IEEE International Symposium on Bioinformatics and Bioengineering (BIBE)*, Washington, DC, USA, 2017, pp.568-573.
- [16] J. P. Corradi, S. Thompson, J. F. Mather, C. M. Waszynski, and R. S. Dicks, "Prediction of Incident Delirium using a Random Forest Classifier," *Journal of Medical Systems*, Vol.42, No.12, pp.261, 2018.
- [17] J. Y. Oh, D. R. Cho, J. S. Park, S. H. Na, J. I. Kim, J. S. Heo, C. S. Shin, J. J. Kim, J. Y. Park, and B. R. Lee, "Prediction and Early Detection of Delirium in the Intensive Care Unit by using Heart Rate Variability and Machine Learning," *Physiological Measurement*, Vol.39, No.3, 035004, 2018.
- [18] H. N. Mufti, G. M. Hirsch, S. R. Abidi, and S. S. R. Abidi, "Exploiting Machine Learning Algorithms and Methods for the Prediction of Agitated Delirium after Cardiac Surgery: Models Development and Validation Study," *JMIR Medical Informatics (JMI)*, Vol.7, No.4, e14993, 2019.
- [19] J. W. Grzymala-Busse, "A New Version of the Rule Induction System LERS," *Fundamenta Informaticae*, Vol.31, No.1, pp.27-39, 1997.
- [20] Z. Pawlak, "Rough Sets," *International Journal of Computer and Information Sciences*, Vol.11, No.5, pp.341-356, 1982.
- [21] J. W. Grzymala-Busse, "Rough Set Strategies to Data with Missing Attribute Values," In: L. T. Young, S. Ohsuga, C. J. Liau, X. Hu (eds) *Foundations and Novel Approaches in Data Mining. Studies in Computational Intelligence*, Vol.9, Springer, 2015.
- [22] Z. Pawlak and A. Skowron, "Rudiments of Rough Sets," *Information Sciences*, Vol.177, No.1, pp.3-27, 2007.
- [23] Z. Pawlak and A. Skowron, "Rough Sets and Boolean Reasoning," *Information Sciences*, Vol.177, No.1, pp.41-73, 2007.
- [24] J. W. Grzymala-Busse, "Rule Induction from Rough Approximations," In: J. Kacprzyk, W. Pedrycz (eds) *Springer Handbook of Computational Intelligence*, Springer, Berlin, Heidelberg, 2015.
- [25] U. M. Fayyad and K. B. Irani, "Multi-interval Discretization of Continuous-valued Attributes for Classification Learning," In: *IJCAI*, pp.1022-1029, 1993.
- [26] E. Frank, M. A. Hall, and I. H. Witten, *The Weka Workbench. Online Appendix for "Data Mining: Practical Machine Learning Tools and Techniques," Morgan Kaufmann, Fourth Edition*, 2016.

### 손 창 식



<https://orcid.org/0000-0001-5682-1770>

e-mail : changsikson@dgist.ac.kr

2000년 대구가톨릭대학교

컴퓨터정보통신공학부(학사)

2002년 대구가톨릭대학교 전자통계학과

전자계산학과(석사)

2006년 대구가톨릭대학교 컴퓨터정보통신공학부(박사)

2007년 ~ 2009년 영남대학교 전기공학과 지능시스템연구소

박사후연구원

2009년 ~ 2014년 계명대학교 의과대학 의료정보학교실/

생체정보기술개발사업단 연구교수

2014년 ~ 현 재 대구경북과학기술원 지능형로봇연구부

선임연구원

관심분야 : 지식획득, 지식학습, 기계지능

### 강 원 석



<https://orcid.org/0000-0002-1034-454X>

e-mail : wskang@dgist.ac.kr

1998년 영남대학교 컴퓨터공학과(학사)

2000년 영남대학교 컴퓨터공학과(석사)

2000년~2004년 한국과학기술원 연구원

2005년~현 재 대구경북과학기술원

지능형로봇연구부 책임연구원

관심분야 : 데이터마이닝, 기계학습, 지능시스템



### 이 종 하

<https://orcid.org/0000-0002-5756-1621>  
e-mail : segeberg@kmu.ac.kr  
2000년 인하대학교 전자공학과(학사)  
2006년 New York University,  
Electrical Engineering(석사)  
2011년 Temple University, Electrical  
Engineering(박사)

2012년 삼성전자 종합기술원 Future IT Lab 전문연구원  
2013년 ~ 현재 계명대학교 의과대학 의용공학과 부교수  
관심분야 : Artificial Intelligence, Computer Aided  
Diagnosis



### 문 경 자

<https://orcid.org/0000-0002-3475-739X>  
e-mail : kjmoon2150@kmu.ac.kr  
2000년 University of Newcastle  
Nursing(학사)  
2007년 University of Newcastle  
Nursing(석사)

2012년 가톨릭대학교 간호학(박사)  
2014년 ~ 현재 계명대학교 간호학과 조교수  
관심분야 : Delirium, Prevention & Intervention, Simulation  
Education