

# 리프집합과 퍼지 모델을 이용한 인공위성의 이상 동작 검출 시스템

양승은\*

## Satellite Anomalous Behavior Detection System through Rough-Set and Fuzzy Model

Seung-Eun Yang\*

### 요 약

위성의 상태를 파악하기 위해 기존에는 OOL(Out-Of-Limit) 방식을 많이 사용하여 왔다. OOL은 특정 텔레메트리의 상위, 하위 문턱 값을 지정하여 해당 값을 벗어날 경우 문제가 발생한 것으로 인식 하는 방식이다. 이 방법은 파라미터의 특성을 파악하여 각각의 문턱 값을 정확히 설정해야 하는 전문 지식과 노력이 필요하고 텔레메트리 값이 문턱값 내에서 비정상적으로 변할 경우는 검출할 수 없다는 문제점이 있다. 이러한 문제를 극복하기 위해 본 논문에서는 위성이 정상 상태일 때 텔레메트리의 통계적 특징 중 러프 집합을 이용하여 중요한 것을 선택, 적용하여 퍼지 모델을 구축하고 이상 상태를 구분하는 시스템을 제안한다. 정상 상태의 데이터만 이용하여 모델을 구축하기 때문에 출력값을 비교 하여 사전에 정의되지 않은 비정상 상태의 구분이 가능 하며 다양한 통계 값을 이용하기 때문에 전문 지식 필요 없이 문턱값 내에서 비정상적으로 변하는 텔레메트리를 검출할 수 있다. 제안한 시스템의 동작 확인을 위해 실제 저궤도 관측위성의 배터리 온도 텔레메트리를 적용하여 시험을 수행 하였고 비정규적 운영 상태에 대한 검출이 성공적으로 이루어 졌다.

**Key Words** : artificial satellite, statistical feature, rough-set, fuzzy model, fault management

### ABSTRACT

Out-of-limit (OOL) alarm method that is threshold checking of telemetry value is widely used for the satellites fault diagnosis and health monitoring. However, it requires engineering knowledge and effort to define delicate threshold value and has limitations that anomalous behaviors within the defined limits can't be detected. In this paper, we propose a satellite anomalous behavior detection system through fuzzy model that is composed by important statistical feature selected by rough-set theory. Not pre-defined anomaly is detected because only normal state data is used for fuzzy model. Also, anomalous behavior within the threshold limit is detected by using statistic feature that can be collected without engineering knowledge. The proposed system successfully detected non-ordinary state for battery temperature telemetry.

## I. 서 론

인공위성의 이상 상태를 파악하기 위해 가장 많이 사용하는 방법 중 하나가 out-of-limits (OOL) 방식이다. OOL은 특정 텔레메트리 값에 대해 상위, 하위 문턱 값을 지정하여 텔레메트리가 지정된 문턱 값을 벗어날 경우 지상에 경고 메시지를 발생 시켜 문제를 확인하는 방식이다. 기존 방법의 성능 개선을 위해 위성의 운영 모드에 따라 문턱 값을 다르게 설정 하거나 이중 문턱 값을 지정하여 주의가 필요한 단

계와 긴급한 대응이 필요한 단계를 구분하여 알람을 발생시키는 등의 노력이 이루어 져 왔다. 그러나 결국 고정된 문턱 값에 의해 상태 파악이 이루어지므로 문턱 값 내에서 발생하는 값의 이상 변화는 감지할 수 없다. 또한 각각의 파라미터에 대해 알맞은 문턱 값을 설정하기 위해서는 해당 분야에 대한 전문적인 지식과 많은 파라미터에 대한 값 설정을 위한 노력이 필요하게 된다[1].

본 논문에서는 위에 제시된 문제를 극복하기 위해 위성 텔레메트리를 바로 활용하지 않고 평균, 표준편차 등 다양한

\* 한국항공우주연구원 위성기술연구단 위성비행소프트웨어팀 (seyang@kari.re.kr)  
접수일자 : 2017년 8월 25일, 최종게재확정일자 : 2017년 9월 18일

통계적 값을 오동작 검출을 위한 특징으로 활용하여 문턱 값 내에서 발생하는 이상 동작을 검출하는 방안을 제시한다. 특징 후보로 다양한 통계값들이 사용될 수 있는데 과적합(Overfitting)을 방지하고 성능 향상을 위해 러프 집합을 이용하여 중요한 것만을 선택, 적용하여 퍼지 모델을 구축하고 이상 상태를 구분한다. 러프 집합 이론은 Vinterbo에 의해 고안 된 것으로 여러 개의 임의의 집합이 주어졌을 때 각 집합들의 원소 중 최소한 하나 이상의 원소를 포함하는 집합(hitting set)을 기반으로 한다. 인식 과정에 필요한 특징은 해당 클래스를 결정하는데 필요한 고유한 속성을 가져야 하며 hitting set은 모든 집합에 대해 최소 한 개 이상의 원소를 포함 하므로 특징 선택을 위한 방법으로 사용할 수 있다[2].

시스템에 사용되는 통계 값 (평균, 표준편차, 최대 값, 최소 값 등)은 전문가의 지식 없이 데이터만 있으면 구할 수 있으므로 다양한 텔레메트리에 대해서도 쉽게 적용할 수 있는 장점이 있다. 또한 통계 값의 관찰을 통해 이상 상태를 구분하기 위한 규칙을 정의하고 인식을 개발해야 하는데 퍼지 로직의 경우 인간의 실수에 의한 규칙의 불안정성 및 불확정성에 대한 보상이 가능하기 때문에 해당 방법을 적용 하였다 [3]. 본 연구에서는 위성이 정상 동작할 경우의 데이터만 사용하여 퍼지 모델을 구축하기 때문에 모델의 출력 값을 비교하여 사전에 정의하지 않은 오류 상태에 대한 검출이 가능하다. 오동작 검출 성능을 높이기 위해 퍼지 모델의 최적화가 필요 하며 광범위 탐색 능력(exploration)과 선택적 집중 분석 (exploitation) 능력이 우수한 진화 알고리즘을 적용 하였다[4].

구현한 시스템의 성능을 평가하기 위해 실제 저궤도 관측 위성의 배터리 온도 정보를 사용하여 시험을 진행 하였다. 배터리는 위성에 사용되는 모든 전자 장비에 전력을 공급하는 중요한 장비이며 배터리 상태를 모니터링 할 수 있는 중요한 정보 중 하나가 온도 정보이다. 일반적인 운영 상태에 대한 1개월 동안의 데이터를 이용하여 모델을 구축, 최적화 하였고 요구조건을 벗어난 임무 수행 상태에 대한 데이터를 적용 하여 이를 성공적으로 구분하는 것을 확인 하였다.

본 논문은 다음과 같이 구성 하였다. II장에서는 러프 집합의 기본 개념에 대해 설명하고 이를 이용하여 여러 가지 특징 집합 중 중요한 특징을 선택하는 과정에 대해 다룬다. III장에서는 퍼지 규칙을 이용한 모델 구축 및 진화 알고리즘을 이용한 최적화 방안과 최적화 전, 후의 시험 결과를 비교 정리한다. 끝으로 IV장의 결론을 통해 본 논문을 마무리 하도록 한다.

## II. 러프 집합을 이용한 통계적 특징 선택

위성의 정상 동작 상태와 비정상 상태를 구분하기 위해 우선 특징 집합을 찾아야 한다. 본 논문에서는 위성 배터리

온도 텔레메트리 값의 변화를 관찰하여 여러 가지 통계적 값들을 특징 후보로 정리하고 러프 집합 이론을 통해 인식 과정에서 중요하게 사용 되는 특징을 검출 한다.

### 1. 위성 배터리 온도 텔레메트리의 통계적 특징

그림 1에 시간에 따른 위성 배터리의 온도 텔레메트리 변화를 도시 하였다. 해당 텔레메트리는 지상에 8초 주기로 전달되며 일정한 값을 유지하지 않고 특정 제어 값에 의해 주기적으로 변하는 것을 알 수 있다. 그림 2에는 온도 최소 구간의 변화 양상을 확인하기 위해 해당 구간을 확대하여 도시 하였는데 계속해서 일정한 값을 유지하지 않고 상승, 하강의 특성을 보인 후 최소값에 도달하고 다시 상승, 하강 변화를 거쳐 점차 상승 하는 것을 볼 수 있다. 해당 특성을 반영하여 통계적 특징 집합을 구하는 과정에서 최소값을 구할 경우 최소점의 값을 사용하되 특정 값 이하로 하강하는 시점부터 다시 동일 값에서 상승하는 구간 까지를 최소 구간으로 정의 하고 최대값에 대해서도 동일 개념을 적용 하였다.

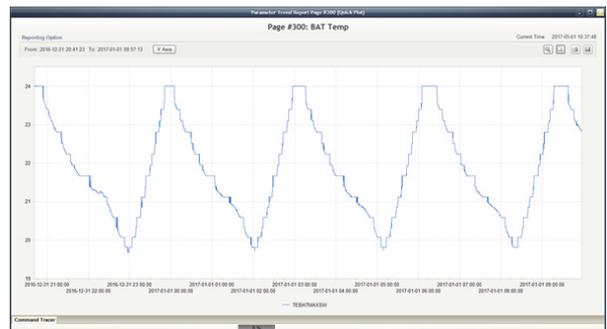


그림 1. 배터리 온도 텔레메트리

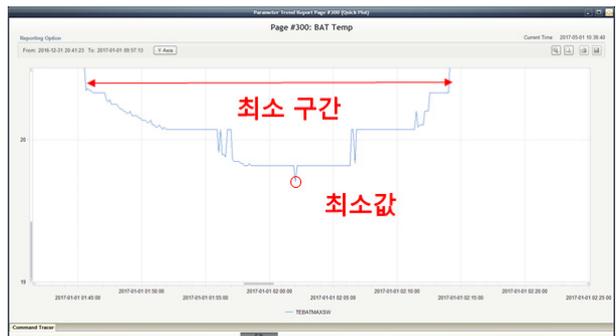


그림 2. 배터리 온도 최소 구간 변화 특성

배터리 온도 변화 특성을 관찰한 후 표 1과 같이 다양한 통계적 특징 들을 정의 하였다.

표 1. 비정상 동작 인식을 위한 특징 후보

구분	특징 후보
1	온도 최대값
2	온도 최대값 유지 시간 (최대 구간 시간)
3	온도 최소값
4	온도 최소값 유지 시간 (최소 구간 시간)

5	온도 증가 기울기
6	온도 감소 기울기
7	온도 최소값 대 최대값 차이
8	온도 최소값에서 최대값 까지 변하는 소요 시간
9	온도 최대값에서 최소값 까지 변하는 소요 시간

## 2. 러프 집합의 기본 개념 및 이를 이용한 중요 특징 선택

앞서 정리한 모든 특징을 이용하여 시스템을 구축 할 경우 복잡도가 증가하며, 또한 너무 많은 특징을 사용할 경우 학습에 사용한 데이터들에 대해서만 지나치게 적응 하여 학습에 사용되지 않은 다른 정상 데이터이나 일부 특성이 다른 경우 모두 비정상으로 인식 하는 과적합(overfitting) 문제가 발생할 수 있다[5]. 따라서 시스템의 성능을 높이기 위해 적절한 수의 특징을 사용해야 하며 본 논문에서는 러프 집합을 사용하여 중요한 특징을 검출 한다.

다양한 특징으로부터 중요한 특징을 선출하는 것은 특정 대상에 대한 클래스를 예측하는 과정으로 볼 수 있으며 클래스 분류 문제는 데이터 마이닝 작업으로 볼 수 있다. 데이터 마이닝을 위해 판단 트리, 로지스틱 회귀분석, 러프집합 이론 등 다양한 방법이 존재 하지만 다양한 데이터로부터 특징 규칙을 구축할 수 있고 특정 문제에 적용성이 뛰어난 러프 집합을 적용 하였다. 특히 러프 집합은 집합 이론을 기본을 기본으로 하기 때문에 많은 특징 중에서 일부를 선택하는 문제에 대해 우수한 성능을 보인다[2].

러프 집합은 r-approximate hitting set에 기반한 이론으로 hitting set이란 주어진 집합에 대해 각 집합들의 원소 중 동일한 원소를 최소한 하나 이상 포함하는 집합을 의미한다. Minimal Hitting Set(MHS)은 hitting set 중 최소 크기의 원소를 갖는 집합을 의미하며 집합  $L$ 과  $U$ 를 그림 3과 같이 정의 했을 때 그림 4의 예와 같이 MHS를 구할 수 있다. 그림 5에는 Absorption의 개념 및 예를 도시 하였는데 Absorption이란 주어진 집합에 대하여 동일한 원소를 포함하는 집합들을 제거한 것을 의미하며 absorption 이후 동일한 원소를 포함하는 집합은 존재하지 않는다. 또한 집합  $L$ 과 Absorption 후의 집합  $L^a$ 에 대한 MHS는 동일하다는 특성이 있기 때문에 Absorption을 먼저 구하면 보다 쉽게 MHS를 구할 수 있다.

$$L = \{S_i | i \in I \subseteq N, S_i \subset U\}$$

$$S \subset U, S \cap S_i \neq \emptyset, \forall i \in I$$

그림 3. 전제집합 U와 집합 S

$$U = \{a, b, c, d\}$$

$$L = \{\{a, b, c, d\}, \{a, b, d\}, \{a, b\}, \{c\}, \{d\}\}$$

Minimal Hitting Set(MHS):  $\{a, c, d\}, \{b, c, d\}$

그림 4. Minimal Hitting Set의 예

$$L^a = L - \{X \in L | \exists Y \in L \text{ st. } Y \subset X\}$$

$$L = \{\{a, b, c, d\}, \{a, b, d\}, \{a, b\}, \{c\}, \{d\}\}$$

$$L^a : \{a, b\}, \{c\}, \{d\} \quad , \quad MHS(L^a) = MHS(L)$$

그림 5. Absorption과 minimal hitting set

러프 집합을 이용한 특징 선택의 예를 표 2에 정리 하였다. A부터 J까지 총 10개의 특징 중 클래스 X를 결정하는데 사용될 수 있는 특징은 클래스 X에 대해 동일한 값을 유지하는 B와 I 뿐이며 이는 러프 집합에서의 MHS이 된다.

표 2. 특징 선택 과정의 예

Test Data	A(0), <b>B(0)</b> , C(2), D(3), E(2), F(3), G(1), H(0), <b>I(2)</b> , J(3) => X
	A(1), <b>B(0)</b> , C(3), D(2), E(1), F(1), G(4), H(3), <b>I(2)</b> , J(1) => X
	A(2), <b>B(0)</b> , C(2), D(1), E(1), F(2), G(1), H(0), <b>I(2)</b> , J(1) => X
Selected Features	B(0), I(2) => X

그러나 실제로는 예상하지 못한 다양한 경우가 존재하며 MHS이 존재하지 않는 경우도 있을 수 있다. 따라서 모든 집합에 대한 hitting set을 구하지 않고 전체 집합 중 최소한 r 개 이상의 집합에 대해 동일 원소를 포함하는 집합을 고려할 수 있는데 이를 r-approximate hitting set으로 정의 한다. 이때 특정 집합 X가 전체 집합을 얼마나 잘 대변 하는지를 나타내는 approximation measure  $\alpha(X)$ 는 그림 6과 같이 정의 되며  $w(S)$ 는 집합 S의 weight를 의미한다. 그림 7에 예를 정리 하였는데 각기 다른 weight를 갖는 집합들로 이루어진 집합 L에 대해 집합  $\{b, d\}$ 의 approximation measure는 0.786이 된다.

$$\alpha_w^L(X) = \frac{\sum_{S \in L} w(S) h_X^L(S)}{\sum_{S \in L} w(S)}, \quad h_X^L(S) = \begin{cases} 1, & \text{if } S \in L \text{ and } X \cap S \neq \emptyset \\ 0, & \text{otherwise} \end{cases}$$

그림 6. Approximation Measure

$$L = \{\{a, b, c, d\}^4, \{a, b, d\}^6, \{a, b\}^9, \{c\}^6, \{d\}^3\}$$

$$\alpha_w^L(\{b, d\}) = \frac{4+6+9+3}{4+6+9+6+3} = \frac{22}{28} \approx 0.786$$

그림 7. Approximation Measure의 예

러프집합 이론을 이용하여 다양한 특징 중 의미 있는 특징을 찾기 위해서는 여러 특징 조합에 대해 비교를 해 보아야 하는데 모든 조합을 모든 규칙에 적용하여 계산하기는 어렵기 때문에 진화 알고리즘을 사용하여 구하였다. 초기화 과정에서 주어진 특징을 이용하여 임의의 집합을 생성하고 변이(mutation)와 교차(crossover) 연산을 통해 새로운 값을 생성하여 보다 우수한 집합을 찾는 과정을 반복한다. 이때 선택된 집합이 얼마나 우수한지 알 수 있는 지표가 필요한데

그림 8과 같이 적합성 함수를 정의 하였다. 수식의 앞항을 통해 최종적으로 결정되는 집합의 원소가 적을수록 가중치를 주고 두 번째 항을 통해 hitting rate이 높을수록 가중치를 주게 된다.

$$F_w^L(S) = (1-l) \frac{|U|-|S|}{|U|} + \rho \min(r, \alpha_w^L(S))$$

그림 8. 러프 집합을 구하기 위한 적합성 함수

본 연구에서는 러프 집합을 고안한 저자가 개발한 프로그램 ROSETTA를 이용하여 특징 집합을 선택 하였으며 표 1의 특징 후보 중 “온도 최대값 유지 시간”과 “온도 최대값에서 최소값 까지 변하는 소요 시간” 두 가지가 최종 선택 되었다. 해당 특징에 대한 정상 상태 데이터는 그림 9와 같은 분포를 갖는다[6].

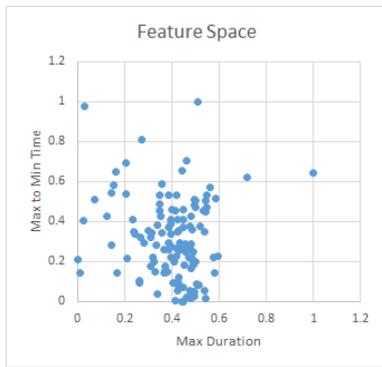


그림 9. 정상 상태에 대한 선택된 특징 분포

### III. 퍼지 규칙 기반의 이상동작 인식 시스템

#### 1. 퍼지 규칙 정의

위성의 정상 상태 데이터를 이용하여 퍼지 모델을 구축하기 위해 그림 10과 같이 4개의 삼각 함수를 이용하여 두 개의 입력과 하나의 출력에 대한 멤버 함수를 구성 하였다. 또한 그림 9의 데이터 분포 관찰을 통해 표 3과 같이 퍼지 규칙을 정리 하였다.

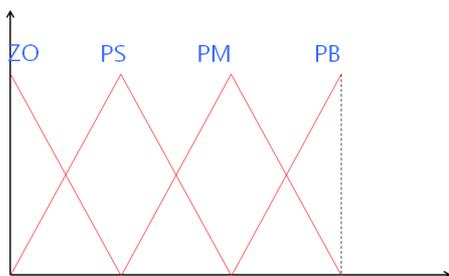


그림 10. 퍼지 멤버 함수

표 3. 위성의 정상 동작에 대한 퍼지 규칙

If A is ZO and B is ZO then Out is PS
If A is ZO and B is PS then Out is PS
If A is ZO and B is PM then Out is ZO
If A is ZO and B is PB then Out is ZO
If A is PS and B is ZO then Out is PB
If A is PS and B is PS then Out is PM
If A is PS and B is PM then Out is PS
If A is PS and B is PB then Out is ZO
If A is PM and B is ZO then Out is PB
If A is PM and B is PS then Out is PM
If A is PM and B is PM then Out is PS
If A is PM and B is PB then Out is ZO
If A is PB and B is ZO then Out is PM
If A is PB and B is PS then Out is PS
If A is PB and B is PM then Out is ZO
If A is PB and B is PB then Out is ZO

A: 온도 최대값 유지 시간, B: 온도 최대값에서 최소값 까지 변하는 소요 시간

퍼지 모델의 출력 값 계산을 위한 De-fuzzification 방식으로는 그림 11의 “Center of Sums” 방식을 적용 하였다[7]. 서로 다른 두 특징의 입력 값을 X1(n), X2(n)라고 할 때 각 규칙에 정의 된 멤버 함수 (ZO, PS, PM, PB)에 대응 되는 값이 있을 경우 fire 되었다고 한다. 그림 11에서 첫 번째의 예의 경우 아래와 같은 규칙을 따른다.

- IF x1 is PS and x2 is PM, then Output is PM

Input x1에 대해서는 PS이 fire 되고 Input x2에 대해서는 PM이 fire 되었으며 두 값 중 최소값이 Output PM에 대한 출력 값을 결정하게 된다. 모든 규칙에 대해 오른쪽 수식을 사용하면 해당 퍼지 모델에 대한 출력 값을 구할 수 있다. 퍼지 출력 값은 입력된 데이터가 구축된 모델에 얼마나 가까운지를 나타내는 지표가 되며 값이 클수록 해당 모델에 속하는 것을 나타낸다. 앞에서 구축한 모델의 경우 정상 상태의 데이터를 이용한 것이므로 정상 상태일 때의 데이터를 입력 할 경우 1에 가까운 값이 나오며 비정상 상태의 데이터를 입력 할 경우 0에 가까운 값이 나오게 된다.

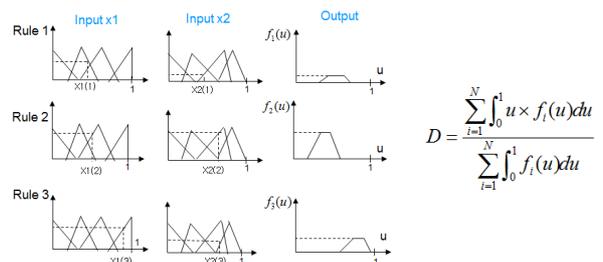


그림 11. Center of Sums De-fuzzification

구축한 퍼지 모델에 대하여 두 가지 경우에 대한 시험을 수행 하였다. 총 31개의 시험 데이터 중 앞의 28개는 일반적인 운영 상태일 때의 배터리 온도 정보를 사용 하였고 마지막 3가지는 요구조건을 벗어나는 임무를 수행 했을 때의 온도 정보를 사용 하였다. 그림 12에 해당 결과를 도시 하였는데 일반적인 경우 모두 0.4보다 큰 출력 값이 나타나며 과도한 임무를 수행한 마지막 세 가지의 경우 0.4보다 작은 출력 값이 나타나는 것을 확인할 수 있다. 따라서 구축한 퍼지 모델을 통해 정상 운영 상태와 그 외의 경우를 구분할 수 있음을 확인할 수 있다.

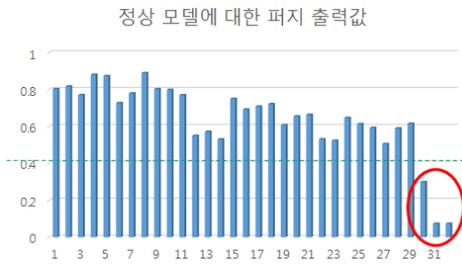


그림 12. 퍼지 모델에 대한 출력 값

본 시험은 약 1주일간의 데이터를 적용하여 수행 하였다. 그러나 위성의 전체 운영 기간을 고려했을 때 보다 다양한 형태의 데이터가 나타날 수 있으며 기존의 퍼지 모델로는 인식에 실패하는 경우도 발생할 수 있다. 따라서 보다 많은 데이터에 대해 주어진 퍼지 모델을 최적화 하여 신뢰성을 높일 필요가 있다. 이에 진화 알고리즘을 사용하여 최적화를 수행 하였으며 다음 장에서 자세히 다루도록 한다.

## 2. 진화 알고리즘을 사용한 최적화 수행

본 연구의 퍼지 모델에는 두 개의 입력과 하나의 출력에 대해 총 3개의 멤버 함수 집합이 사용 되었다. 이를 최적화하기 위해 각 멤버 함수 중 PS, PM의 경우 중심점 및 좌/우측 폭, ZO의 경우 우측의 폭 PB의 경우 좌측의 폭을 최적화의 대상으로 하였다. 하나의 퍼지 멤버 함수 집합에 대해 최적화해야 할 파라미터가 8개 존재 하고 총 3개의 멤버 함수 집합을 대상으로 하므로 총 24의 파라미터를 최적화해야 한다.

최적화를 위해서는 러프 집합에서도 사용 한 진화 알고리즘을 적용 하였다. 이때 적용한 진화 알고리즘의 각 파라미터는 표 4와 같다. 최적화의 목표는 정상 상태의 데이터를 입력 하였을 때 출력을 최대값으로 만드는 것이므로 퍼지 모델의 출력 값을 그대로 적합도 함수로 사용 하였다. 약 한달 간의 정상 운영 데이터를 이용하여 최적화를 수행 하였으며 두 가지 입력과 한 가지 출력에 대해 최적화 된 멤버 함수를 그림 13에 도시 하였다.

표 4. 진화 알고리즘에 사용 된 파라미터

파라미터 종류	파라미터 값
Maximum Number of Generation	1000
Population Size	300
Number of bits in a chromosome	150
Probability of Crossover	0.25
Probability of Mutation	0.02

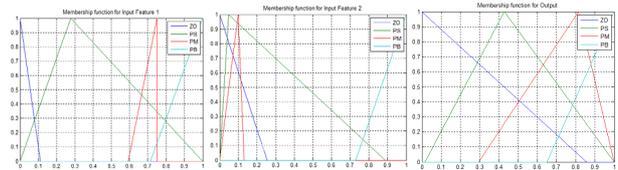


그림 13. 최적화를 통해 구한 멤버 함수

위에서 구한 멤버 함수를 이용하여 그림 12에 사용 된 동일한 데이터로 재시험을 수행 하였다. 이때 정확한 성능 확인을 위해 시험에 사용된 데이터는 최적화에 사용된 데이터와는 다른 것을 사용 하였다. 그림을 보면 모든 데이터에 대해 최적화 이후 출력 값이 최적화 이전 보다 커진 것을 확인할 수 있는데 이는 정상 상태의 입력 데이터에 대해 출력 값을 크게 하는 방향으로 적합도 함수를 설정하였기 때문이다. 그리고 정상 상태의 데이터에 대해서는 거의 유사한 값을 나타내고 과도한 임무 수행시의 데이터는 작은 값을 나타내고 있다. 따라서 최적화를 통해 정상 상태일 때와 그렇지 않을 때를 보다 분명히 구분할 수 있음을 확인할 수 있다.

최적화 전/후 의 결과 비교

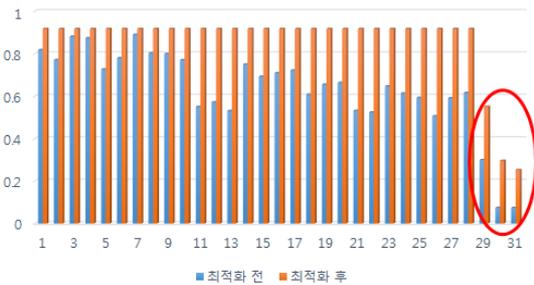


그림 14. 최적화 전, 후의 시험 결과 비교

## IV. 결론

본 논문에서는 기존의 위성 운영 시 문제 발생 확인을 위해 사용되어 온 OOL 방식의 한계점을 극복하기 위한 방안으로 러프 집합을 이용한 통계적 특징 선택 및 퍼지 모델을 이용한 이상 동작 인식 시스템을 소개 하였다. OOL 방식은 특정 텔레메트리 데이터에 대해 최대, 최소 문턱값을 설정하여 문제 여부를 판단하므로 해당 구간 내에서 비 정상적으로 나타나는 값의 변화를 탐지할 수 없다. 또한 모든 텔레메트

리에 대해 정확한 문턱 값을 설정하기 위해서는 전문적인 지식과 노력이 필요하게 된다.

본 논문에서 제안한 방안은 다양한 통계적 값을 사용하기 때문에 특정 문턱값 내에서 비 정상적으로 변화하는 구간을 검출할 수 있다. 또한 다양한 특증 후보 중 러프 집합을 이용하여 해당 데이터가 정상 상태임을 판단 할 수 있게 해 주는 중요 특징을 선택 하여 과적합 문제에 대비 하였다. 이후 선택된 특징 값의 관찰을 통해 퍼지 규칙을 설정하여 모델을 구축하고 진화 알고리즘을 통해 해당 모델을 최적화 하여 성능을 높이도록 하였다. 규칙 정의의 경우 데이터 특성 관찰을 통해 가능 하므로 전문적인 지식이 필요 없고 순수하게 데이터만을 가지고 동작을 하기 때문에 자동화가 가능 하며 사람의 노력 없이 쉽게 확장할 수 있는 장점이 있다. 제안한 방식의 성능을 확인하기 위해 위성 운영에 중요한 요소인 배터리 온도 텔레메트리를 사용 하였다. 실제 위성으로부터 약 한달 간의 데이터를 수집하여 특징 선택 및 모델 구축, 최적화에 사용 하였고 약 일주일간의 데이터를 시험에 사용 하였다. 최종 시험 결과 정상적인 운영 상태와 과도한 임무 수행에 대한 상태를 성공적으로 구분 하였다.

데이터의 특성에 따라 위성 운영 시 기존의 OOL 방법으로도 이상 상태를 판별할 수 있는 경우가 있고 지속적인 값의 변화 특성 확인 및 추가적인 분석 노력이 필요한 경우가 있다. 따라서 본 논문에서 제시한 방식은 기존의 OOL 방식에 추가적으로 적용함으로써 사람이 수행해야 할 일을 기계가 대체하여 보다 신속하고 안정적인 위성 운영을 가능하게 할 것으로 기대된다.

### 참 고 문 헌

[1] Jose Martinez Heras and Alessandro Donati, "Enhanced Telemetry Monitoring with Novelty Detection," AI Magazine, vol 35, No. 4, pp.37-46, 2004

[2] Staal Vinterbo and Aleksander Ohrn, "Minimal approximate hitting sets and rule templates," International Journal of Approximate Reasoning, vol 25, pp.123-143, 2000

[3] M. Arabzadeh Ghahazi, M. H. Fazel Zarandi, M. H. Harirchian and S. Rahimi Damirchi-Darasi, "Fuzzy rule based expert system for diagnosis of multiple sclerosis," IEEE Conference on Norbert Wiener in the 21st Century, September, 2014

[4] Roland S. Burns, "Advanced Control Engineering," Butterworth Heinemann, 2001

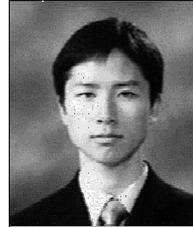
[5] Yi Liu and Yuan F. Zheng, "FS\_FSF: A novel feature selection method for support vector machine", Pattern Recognition, vol. 39, Issue 7, pp.1333-1345, 2006

[6] Aleksander Ohrn, "ROSETTA Technical Reference Manual," Department of Computer and Information Science, Norwegian University of Science and Technology, May, 2001

[7] Ponce-Cruz, Pedro, Ramirez-Figueroa and Fernando D, "Intelligent Control Systems with LabVIEW," Springer-Verlag London, pp.9-46 , 2010

### 저자

#### 양 승 은(Seung-Eun Yang)



- 2005년 2월 : 서강대학교 전자공학과 학사졸업
- 2007년 2월 : 한국과학기술원 전자전산학과 졸업
- 2007년~현재 : 한국항공우주연구원 선임연구원

<관심분야> : 위성운영, 고장형태영향분석