

# 발전기 웨지체결강도 평가용 학습모델 최적화 방법

## Optimization Method for Evaluating Generator Wedge Tightness using a Learning Model

손종덕<sup>†</sup>·엄예준<sup>\*</sup>  
Jongduk Son<sup>†</sup> and Yejun Eom<sup>\*</sup>

(Received January 13, 2025 ; Revised February 7, 2025 ; Accepted February 20, 2025)

**Key Words :** Generator Wedge(발전기 웨지), Tightness Evaluation(체결강도평가), Learning Model(학습모델)

### ABSTRACT

The stator wedges of large-scale generators must remain tight during operation to protect the windings from vibrations. This study aims to improve the traditional qualitative wedge evaluation method that relies on manual hitting and auditory assessment, by employing a portable device to acquire wedge tightness condition data. The Gaussian mixture model (GMM) algorithm was utilized to perform clustering based on wedge tightness conditions, followed by an evaluation of classification accuracy using the optimal clustering model. This research provides a comparative evaluation of classification performance by optimizing GMM clustering for data-driven quantitative assessment of wedge conditions.

### 기 호 설 명

- $a$  : 군집 간 응집도
- $b$  : 군집 간 분리도
- $\mu_k$  : 데이터의 평균
- $\sigma_k^2$  : 데이터 분포(공분산)

### 1. 서 론

발전기는 전자기 유도현상에 의해 전기를 생산하는 설비로 고정자(stator), 회전자(rotor) 등으로 구성되어있다. 대용량 발전기의 경우 고정자는 철심과 고정자 권선으로 구성되어 있으며 철심 구조 사이에 고정자 권선(winding)이 삽입되어 있다. 발전기 운전시

에 발생하는 진동으로부터 보호하기 위해 권선들은 웨지(wedge)로 고정되어 있다. 만약 웨지가 체결력이 약화된 상태에서 운전을 수행하게 되면 권선과 철심 사이의 마찰로 인해 고정자 권선 절연물이 마멸을 발생하여 절연과피 사고를 일으킬 수 있다<sup>(1)</sup>. 국내에서는 웨지상태를 진단하기 위해 회전자 인출한 상태에서 고정자 웨지를 사람이 수동으로 타격하고, 청음하여 정성적 평가를 수행하기 때문에 평가 결과에 대한 신뢰성 검증이 곤란한 상황이다<sup>(2)</sup>. 일부 발전소에서는 해외의 수동검사 측정 장비를 도입하였지만 진단 결과에 대한 신뢰도가 낮기 때문에 현장에서 활용이 곤란한 상황이다<sup>(3)</sup>.

최근 4차 산업 기술의 발전으로 지능형 디지털 솔루션을 기반으로 설비 상태를 평가하는 기술이 발전

<sup>†</sup> Corresponding Author ; Member, KEPCO Research Institute, Senior Researcher

E-mail : jongduk.son@kepco.co.kr

<sup>\*</sup> Member, KEPCO Research Institute, Researcher

<sup>‡</sup> Recommended by Editor Gilho Yoon

© The Korean Society for Noise and Vibration Engineering

하고 있다<sup>(4)</sup>. 국내 발전소도 인공지능을 기반으로 고장을 감시/진단하는 시스템을 도입하고 있다<sup>(5)</sup>. 이것은 데이터의 미세한 상태변화 정보를 인공지능 학습 모델을 통해 분석하고, 평가하기 때문에 사람보다 정확하게 진단할 수 있다. 또한, 수기문서로 관리되는 정비 점검결과를 디지털 이력관리를 통해 상태추적관리 및 정비계획 수립에 활용할 수 있는 장점이 있다.

이 연구에서는 기존의 정성적인 웨지 평가방법 개선을 위해 휴대용 타격/측정 장치를 활용하여 웨지 상태 데이터를 취득하고<sup>(6)</sup>, 가우시안 혼합 모델(GMM, Gaussian mixture model)을 기반으로 웨지 체결 상태에 따른 군집화를 수행하여, 최적의 군집모델평가를 통한 분류를 평가를 수행하였다. 이를 통해, 데이터 기반의 웨지상태 정량적 평가를 위한 알고리즘 최적화 방법을 제안하고자 한다.

## 2. 알고리즘

### 2.1 가우시안 혼합 모델

가우시안 혼합 모델(GMM)은 비지도 학습방법으로 전체 데이터를 몇 개의 가우시안 분포로 표현할 수 있다고 가정하고, 각각의 분포에 포함될 확률이 높은 데이터로 군집을 형성하는 방법이다. 예를 들어 Fig. 1과 같은 데이터가 있을 때, 3개의 가우시안 분포로 표현할 수 있으며, 각각의 데이터는 해당 분포에 속할 확률에 따라 군집을 형성하게 된다. GMM에서의 주요 파라미터는 각 가우시안 분포의 중심위치를 나타내는 평균( $\mu_k$ )과 데이터 분포의 모양과 크기를 나타내는 공분산( $\sigma_k^2$ ), 전체 데이터에서 해당 분포가 차지하는 비율을 나타내는 확률( $\pi_k$ )이 있다. GMM에서 임의의 데이터  $x$ 가 발생할 확률은 식 (1)과 같이 정의된다.

$$P(x) = \sum_{k=1}^K \pi_k \cdot N(x|\mu_k, \sigma_k^2) \tag{1}$$

여기서  $N(x|\mu_k, \sigma_k^2)$ 는 평균( $\mu_k$ ), 공분산( $\sigma_k^2$ )을 가지는  $k$ 번째 가우시안 분포를 의미하며, 식 (2)와 같이 표현할 수 있다. 이 수식을 통하여 GMM은 각 데이터들이 특정 가우시안 분포에 속할 확률을 계산하고, 이를 기반으로 군집화를 수행한다.

$$N(x|\mu_k, \sigma_k^2) = \frac{1}{\sqrt{2\pi\sigma_k^2}} \exp\left(-\frac{(x-\mu_k)^2}{2\sigma_k^2}\right) \tag{2}$$

그러나 GMM에는 몇 가지 제한점이 존재한다. 첫 번째는 군집 수를 사용자가 직접 설정해야 하는 한계가 있다. 군집 수는 데이터의 종류, 특성에 따라 분류 결과에 큰 영향을 미치며 부적절한 군집 수는 모델 성능을 저하시키기 때문에 적절한 군집 수를 선정해야 한다<sup>(7)</sup>. 두 번째로, GMM은 라벨링이 자동으로 이루어지지 않아 모델 성능 평가시 군집과 실제 라벨 간의 매핑을 사용자가 직접 수행해야 한다<sup>(8)</sup>. 따라서, 모델 성능 평가시에 군집의 정확한 매핑을 위한 보조적인 평가 기법이 필요하다.

### 2.2 실루엣 스코어

실루엣 스코어(silhouette score)는 데이터가 적절한 군집에 속했는지 평가하는 지표로서, 군집의 응집도와 분리도를 동시에 고려하여 평가할 수 있다<sup>(9)</sup>. 이는 데이터 간의 거리를 기반으로 군집링의 품질을 정량화하며, 군집화 성능을 직관적으로 평가할 수 있는 방법이다. 각 데이터 포인트  $i$ 의 실루엣 스코어는 식 (3)과 같이 정의한다.

$$\text{Silhouette score}(i) = \frac{b(i) - a(i)}{\max(a(i), b(i))} \tag{3}$$

여기서  $a(i)$ 는  $i$ 번째 데이터 포인트가 속한 군집 내의 평균 거리(응집도)이며,  $b(i)$ 는  $i$ 번째 데이터 포인트와 가장 가까운 다른 군집의 평균 거리(분리도)이다. Silhouette score( $i$ )의 값은 -1부터 1까지의 범위를 가지며, 결과값이 1에 가까울수록 군집화 품질이 우수함을 의미한다. 전체 데이터의 실루엣 스코어는 각각의 데이터 포인트의 실루엣 스코어 평균으로 계산을 수행하게 되며, 이를 통해 최적의 군집 수를 계산한다.

### 2.3 헝가리안 알고리즘

비지도학습 방법인 GMM을 사용한 군집화 방법은 군집 라벨이 임의로 지정되기 때문에, 실제 라벨

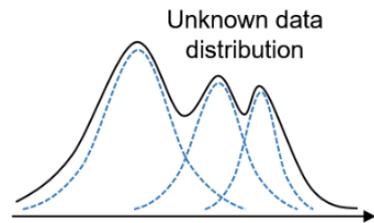


Fig. 1 Example of gaussian mixture model

(ground truth)과 군집 간의 직접적인 비교가 불가능하다. 이러한 문제를 해결하기 위해 헝가리안 알고리즘(Hungarian algorithm)을 활용하여 군집과 실제 라벨 간의 최적 매칭을 수행한다. 헝가리안 알고리즘은 최적화 문제에서 사용되는 방법론으로, 매칭 비용을 최소화하거나 최대화하는 매칭 결과를 계산하는데 효과적이다<sup>(10)</sup>.

GMM 군집화 결과와 실제 라벨 간의 관계는 혼동 행렬(confusion matrix)을 통해 표현되며, 혼동 행렬의 각 원소는 특정 군집과 실제 라벨 간에 공통으로 할당된 데이터 포인트 수를 나타낸다. 이 혼동 행렬을 기반으로, 헝가리안 알고리즘은 군집과 라벨 간의 최적 매칭 계산을 수행한다.

### 3. 데이터 취득 및 분석

#### 3.1 Test-bed 실험

이 연구에서는 Fig. 2와 같이 500 MW급 기력 발전기의 고정자 웨지 상태를 모사한 test-bed에서 데이터를 취득하였다. Test-bed는 실제 발전기와 동일한 구조로 설계되었으며, 웨지는 정상인 경우 강한 체결, 주의는 약간 느슨하게 체결, 불량인 경우 느슨하게 체결 총 3가지 상태로 구분하여 체결하였다. 또한, 시

험자가 슬롯별 웨지의 상태를 확인할 수 있도록 Fig. 3과 같이 정상(○), 주의(△), 불량(X)으로 표기하였다.

사용된 계측장비는 Fig. 4와 같이 사용자가 직접 타격하고 데이터를 저장할 수 있는 자체제작 휴대용 타격 장치를 사용하여 데이터를 취득하였다. 타격 장치에는 고감도 마이크로폰 센서가 부착되어있으며, 센서는 Table 1과 같이 45 mV/Pa 감도와 10 Hz ~ 20 kHz의 주파수 응답 범위를 가진다. 가속도계를 사용하지 않고 마이크로폰으로 선정한 이유는 웨지 체결 상태를 평가하는데 있어 충격음의 특성이 중요한 진단 요소이며, 비접촉 방식으로 발전기 속 수백개의 웨지 데이터를 손쉽게 취득하기 위함이다. 또한, 배경 소음으로 인한 노이즈를 방지하기 위해 지향성 마이크로폰으로 선정하여 원하는 타격음만을 추출하도록 설계하였다. 데이터 취득은 1개의 슬롯당 8개의 웨지 타격 지점을 포함하며, 총 3개의 슬롯으로 24개 지점을 타격하였다. 각 지점당 40회씩 타격을 수행하여 총 960개의 데이터를 확보하였으며, 신호의 정확성과 저주파 노이즈 제거 및 타격 임펄스 신호만 추출하기 위하여 1000 Hz 고주파 통과 필터를 적용하였다<sup>(11)</sup>. 또한, 타격시 음향신호의 미세한 변화를 측정하기 위하여 25 600 Hz 샘플링 주파수로 데이터 측정하였다.



Fig. 2 Test-bed

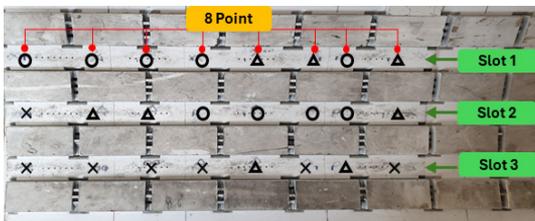


Fig. 3 Test-bed wedge

#### 3.2 신호 전처리 및 데이터 분석

웨지 체결강도에 대한 평가를 위해 작업자가 웨지를 타격하고, 청음하는 유사한 방법을 반영한 mel-scale

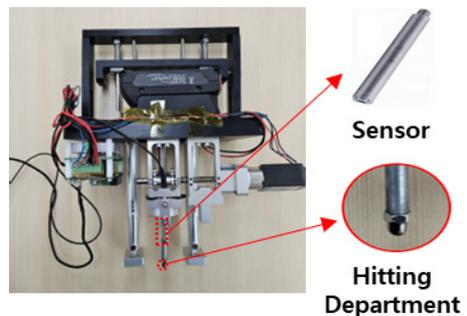


Fig. 4 Portable striking device

Table 1 Sensor specification

Sensor model	Sensitivity	Frequency response
130F21	45 mV/Pa	10 Hz ~ 20 kHz

변환을 적용하였다<sup>(12)</sup>. Mel-scale 변환은 인간의 청각 시스템이 주파수에 대해 비선형적으로 반응하는 특성을 반영한 방법으로, 주파수 축을 mel-scale로 변환함으로써 사람의 귀가 인식하는 주파수 대역을 기준으로 신호를 재구성할 수 있다. 높은 주파수 대역에서의 분해능을 상대적으로 낮추고 낮은 주파수 대역에서의 분해능을 높이는 방식으로, 인간의 청각 특성에 더욱 가까운 신호를 제공하여 신호의 중요한 특징을 부각시킬 수 있게 된다. 이는, 웨지 타격음과 같은 충격신호에서 유용한 정보를 추출할 수 있으며, 기존과 동일한 웨지 평가 방식을 유지하면서 상태를 정량적으로 평가 할 수 있게된다.

각 상태별 라벨을 기준으로 데이터셋을 구성하였으며, 시간 영역과 주파수 영역에서 각각 분석을 수행하였다. Fig. 5는 각 3가지 상태의 원신호(raw signal)를 나타내고, 시간 영역에서는 각 웨지 상태를 명확하게 구분하기 어려웠으며, 이는 웨지 상태별로 발

생하는 성분이 유사한 범위에 분포하기 때문에 판단된다. 주파수 영역에서는 고속 푸리에 변환(FFT, fast Fourier transform)적용 및 mel-scale 변환을 수행하여 데이터를 분석하였다. Fig. 6은 처리된 주파수 영역의 3가지 상태별 데이터를 나타낸다. 정상 상태에서는 5000 Hz ~ 6000 Hz, 주의 상태는 4000 Hz, 불량 상태는 2000 Hz ~ 3000 Hz의 대역에서의 에너지 분포를 확인하였으며, Fig. 7의 mel-scale 변환 결과에서도 동일한 에너지 분포를 가지는 것을 확인하였다. Mel-scale 변환 시 충격 신호의 연속적인 주파수 정보를 확보하기 위하여 75% 오버랩(overlap)을 적용하였으며, 입력 데이터는 128개의 mel 주파수 대역과 6개의 시간 프레임으로 구성된 형태의 행렬이다. 이는 각 프레임에서 mel 필터를 적용한 주파수의 특성과 시간 별 신호의 변화를 나타낸다. 분석결과를 바탕으로 웨지 체결 상태에 따라 발생하는 신호의 차이를 확인하였으며, 주파수 영역 데이터에서 웨지의

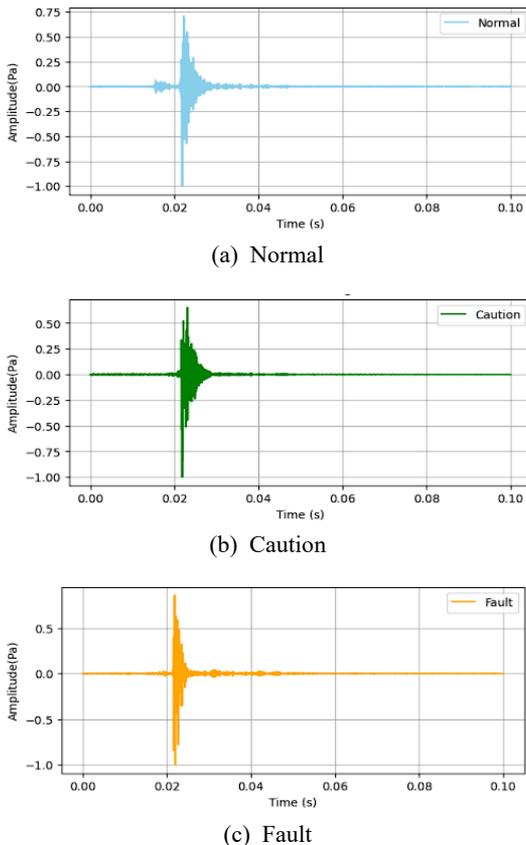


Fig. 5 Raw signal

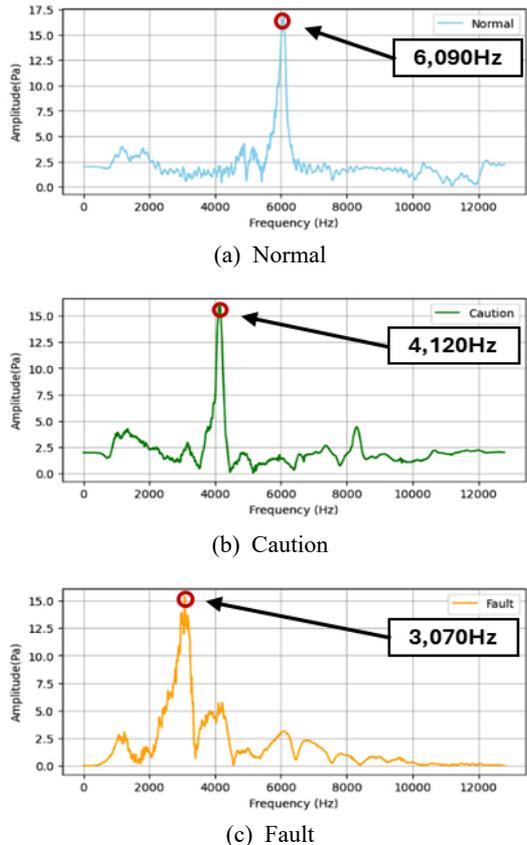


Fig. 6 Fast Fourier transform result

체결 상태를 구분할 수 있는 특징이 포함되어 있다는 것을 알 수 있다.

### 4. 최적 군집 결정 및 검증

#### 4.1 최적 군집 수 결정

앞서 2.2절에서 설명한 실루엣스코어링을 바탕으로 취득데이터에 적용하여 최적 군집 수를 결정하였다. Fig. 8은 2개에서 10개까지의 군집 수에 대한 실루엣스코어링 결과이다. 결과값이 가장 높게 나타난 군집 개수는 3개이며 실루엣 스코어는 0.66이다. 이는 각 상태별 데이터(정상, 주의, 불량) 분포와 일치하며 군집 수가 적절하게 설정되었음을 확인할 수 있다. 그러나, 발전소 현장 데이터에서는 최적 클러스터 개수가 다르게 나타날 수 있다. 실험 테스트 베드에서는 3

개의 상태(정상, 주의, 불량)로 웨지를 조립 체결하여 실험을 수행하였지만, 현장에서는 다양한 체결상태로 인해 더 많은 주의( $\Delta$ )상태의 데이터가 분포될 가능성이 있다. 이러한 경우, 각 클러스터의 데이터 분포 기반으로 상태를 세분화하여 정의하는 접근법을 통해 실험과 발전소 현장 데이터간의 차이를 줄이고, 웨지 상태 평가의 신뢰성을 향상시킬 수 있다.

#### 4.2 GMM 기반 군집화

실루엣 스코어링 결과를 바탕으로 최적 군집수를 정한 후 가우시안 혼합 모델 알고리즘으로 군집화를 수행하였다. FFT 및 mel-scale 변환을 통해 정상 주의, 불량 상태 간의 주파수 대역에서 에너지 분포차이를 확인 할 수 있지만, 대상 발전기 및 데이터 간 편차로 인해 임계값 설정만으로는 정확한 분류가 어려울 수 있기 때문에 데이터의 확률 분포를 기반으로 상태를 자동으로 군집화 할 수 있는 GMM을 활용하였다.

앞선 수해내용 결과를 바탕으로 군집화를 진행하였으며, 군집화 과정에서 주성분 분석(PCA, principal component analysis)을 수행하였다. PCA를 적용한 최종 입력 데이터는 6개의 시간 프레임을 기준으로 2개의 주요 성분(principal components)을 가지는 형태의 행렬이며, 이를 통해 데이터의 주요 정보를 유지하면서 분석 효율성을 향상시켰다. Fig. 9는 PCA를 적용한 후 GMM으로 군집화한 결과를 나타내며, 실루엣스코어링 결과를 바탕으로 3개 군집으로 군집화를 수행하였다. 분류 결과, 각 상태가 명확하게 분리되었으며 시각적으로 3개의 군집이 형성되어 있음을 확인하였다. 이는 정상, 주의, 불량 상태의 데이터가 각각 다

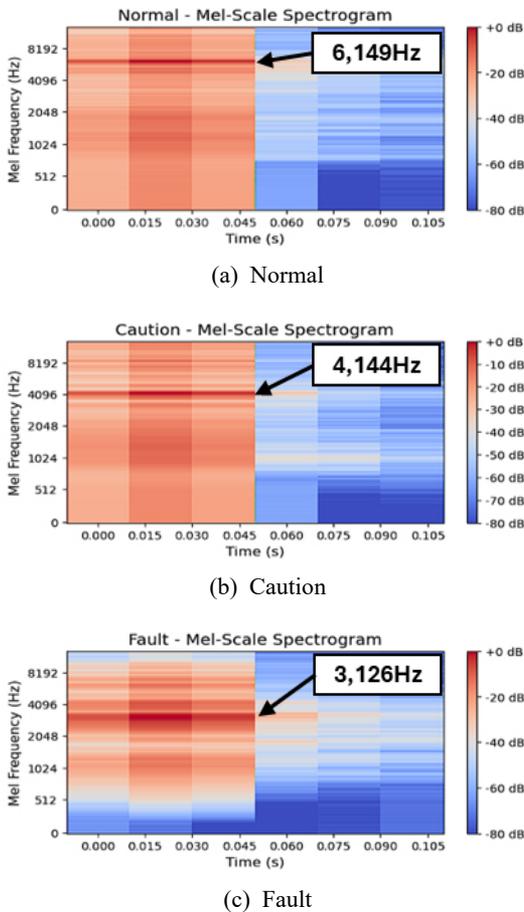


Fig. 7 Mel-scale transform

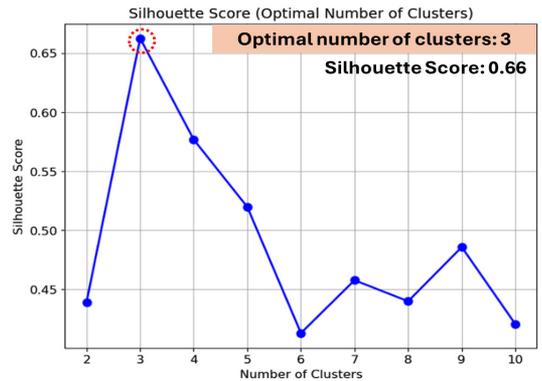


Fig. 8 Silhouette scoring result

른 가우시안 분포로 설명될 수 있음을 의미하며, 이를 바탕으로 분류결과 검증 및 성능평가를 수행하였다.

### 4.3 군집화 검증 및 평가

앞서 군집화한 결과를 검증하기 위해 헝가리안 알고리즘을 활용하여 군집을 실제 웨지상태 라벨과 매

핑하여 분류정확도를 평가하였다. GMM 모델 학습을 수행할 때, 학습 데이터와 테스트 데이터 각각 50%를 사용하여 검증 및 평가를 수행하였다. Fig. 10은 전체 과정의 흐름을 나타내는 플로우차트로, 데이터 취득, GMM 군집화, 실루엣 스코어 계산, 헝가리안 알고리즘을 통한 매핑 및 성능 평가의 과정을 시각적으로 표현하였다. Fig. 11은 3개의 군집화를 수행한 후 헝가리안 알고리즘으로 원본 라벨과 매핑하여 분류를 수행한 결과를 혼동 행렬로 나타낸 것이다.

정상, 주의, 불량 상태의 분류 정확도는 각각 100%, 100%, 98%로 도출되었다. 이를 통해 이 연구에서 수행한 군집화 방법이 웨지 체결 상태를 효과적으로 분류할 수 있음을 확인하였다. Table 2는 군집 수 2개에서 10개까지의 결과에 대한 분류 정확도를 평가한

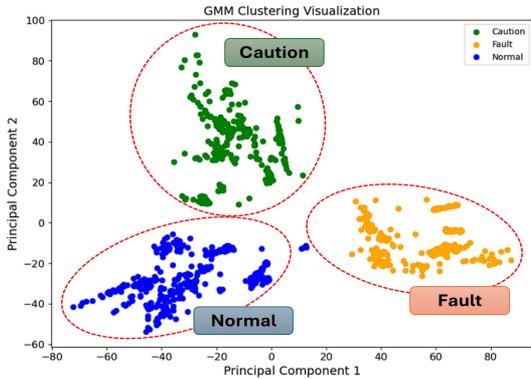


Fig. 9 GMM clustering result

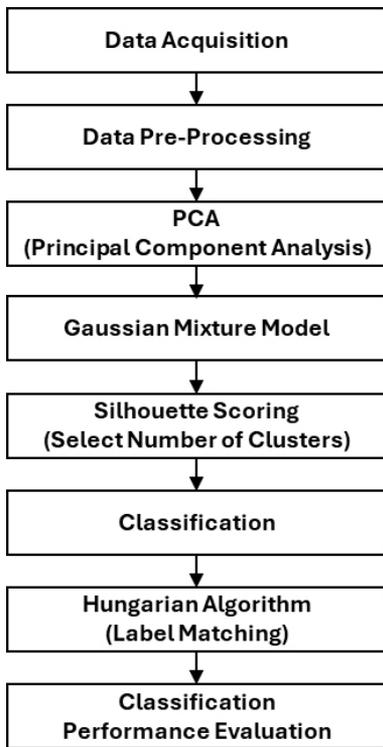


Fig. 10 Flow chart

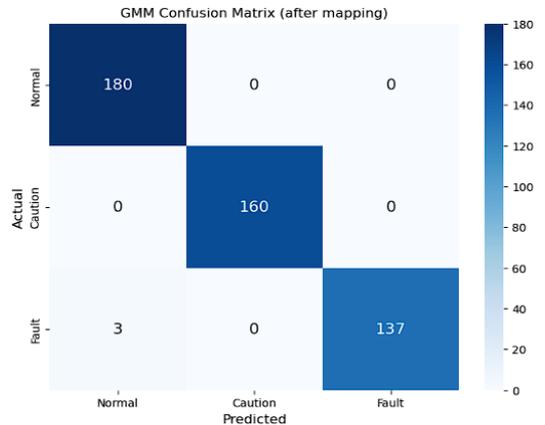


Fig. 11 Confusion matrix(cluster 3)

Table 2 Classification accuracy

Number of clusters	Silhouette score	Classification accuracy		
		Normal	Caution	Fault
2	0.44	100 %	100 %	0 %
3	0.66	100 %	100 %	98 %
4	0.58	68.89 %	88.75 %	100 %
5	0.52	68.33 %	53.12 %	100 %
6	0.41	56.11 %	63.12 %	100 %
7	0.46	55 %	63.12 %	59.29 %
8	0.44	46.67 %	61.25 %	59.29 %
9	0.49	46.67 %	37.5 %	59.29 %
10	0.42	37.22 %	41.88 %	59.29 %

표로, 각 군집 수 및 실루엣 스코어 점수에 따른 분류 정확도를 비교할 수 있도록 제시하였다.

이러한 방식으로 군집화과 라벨 매핑을 수행한 결과, 웨지 체결 상태를 높은 정확도로 판별 할 수 있음을 확인하였으며, 이 연구에서 제안한 최적화 방법이 실용적이고 유의미한 결과를 나타내었다.

### 5. 결 론

이 연구에서는 발전기 웨지의 체결 상태를 정량적으로 평가하기 위한 데이터 기반 학습모델 최적화 방법을 제안하였다. 이를 위해 휴대용 타격 장치를 활용하여 고정자 웨지의 정상, 주의, 불량 상태에 대한 데이터를 test-bed에서 취득하였으며, 가우시안 혼합 모델을 기반으로 군집화를 수행하고 최적 군집 수를 결정하였다. 실루엣 스코어링을 통해 군집의 적합성을 평가한 결과, 3개의 군집으로 군집화 할 때 가장 높은 정확도가 도출 되었다. 또한, 헝가리안 알고리즘을 이용한 라벨 매핑을 통해 정상, 주의 불량 상태의 분류 정확도를 평가한 결과 각각 100 %, 100 %, 98 %로 나타났으며 매우 높은 성능을 확인 할 수 있었다.

이 연구는 기존의 정성적 평가 방식에 비해 체계적이고 신뢰도 높은 웨지 상태 평가를 가능하게 하였으며, 이는 발전 설비의 유지보수 및 상태 모니터링에서 실질적인 기여를 할 수 있을 것으로 사료 된다. 앞으로 추가 연구에서는 다양한 상태의 데이터를 적용하여 모델의 범용성과 정확성을 더욱 향상시키고자 한다.

### 후 기

이 연구는 한국전력공사 전력연구원의 ‘가스터빈 발전기 회전자 인입상태 고정자 웨지 건전성 평가시스템 개발’ 연구과제의 지원으로 수행되었습니다.

### References

(1) Kong, T.-S., 2010, A Study on Insulation Property of VPI Type Generator Stator Winding through the Case Analysis of Insulation Breakdown, The Transactions P of the Korean Institute of Electrical Engineers, Vol. 59, No. 3, pp. 311~316.  
 (2) Xie, X., Li, C., Li, X. and Chen, W., 2022, A Stator Slot Wedge Loosening Offline Detection System

based on an Intelligent Maintenance Robot of a Large Hydro Generator, Machines, Vol. 10, No. 8, 655.  
 (3) Peng, X., Jia, Z., Gao, S., Guan, Z., Wang, L. and Wang, T., 2008, A New Method for Stator Slot Wedge Testing of Large Generators, IEEE Transactions on Dielectrics and Electrical Insulation, Vol. 15, No. 4, pp. 933~940.  
 (4) Kim, S., Noh, Y., Kang, Y., Park, S. and Ahn, B., 2021, Fault Classification Model based on Time Domain Feature Extraction of Vibration Data, Journal of the Computational Structural Engineering Institute of Korea, Vol. 34, No. 1, pp. 25~33.  
 (5) Lee, D.-Y., Park, S.-Y. and Lee, D.-H., 2023, Development of a New Prediction Alarm Algorithm Applicable to Pumped Storage Power Plant, Journal of Korean Society of Industrial and Systems Engineering, Vol. 46, No. 2, pp. 133~142.  
 (6) Electric Power Research Institute, 2020, Generator Stator Wedge Test Guide, EPRI, 3002018669, CA, United States.  
 (7) Lee, S.-W., 2009, Fast Search Algorithm for Determining the Optimal Number of Clusters using Cluster Validity Index, Journal of the Korea Contents Association, Vol. 9, No. 9, pp. 80~89.  
 (8) Xu, D. and Tian, Y., 2015, A Comprehensive Survey of Clustering Algorithms, Annals of Data Science, Vol. 2, No. 2, pp. 165~193.  
 (9) Lee, N. and Lee, D., 2024, Clustering Strategies for Learning Management System Chatbot Data: Based on Silhouette Scores, Proceedings of the Korea Computer Congress, pp. 897~899.  
 (10) Moon, S. T., 2022, Fair Hungarian Algorithm for Swarming Drone Flight Formation Transformation, Journal of KIISE, Vol. 49, No. 6, pp. 459~465.  
 (11) Oh, J., Son, J., Kim, H., Song, G. and Bae, Y., 2020, Signal Analysis Technique for Integrity Evaluation of Generator Stator Wedge, Transactions of the Korean Society for Noise and Vibration Engineering, Vol. 30, No. 5, pp. 441~447.  
 (12) Han, S.-W., Han, S.-H., You, S.-M., Song, D.-H. and Seo, C.-J., 2023, A Study on the Development of Deep Learning-based Deep Voice Detection System using Mel-spectrogram and MFCC, Transactions of the Korean Institute of Electrical Engineers, Vol. 72P, No. 3, pp. 186~192.