

전력 품질 데이터 기반 제조설비 운영 상태 분류에 관한 연구

이민정, 허태욱*

과학기술연합대학원대학교, *한국전자통신연구원

mjlee00@ust.ac.kr, *htw398@etri.re.kr

A Study on Operating State Classification of Manufacturing Equipment Based on Power Quality Data

Minjeong Lee, Tae-Wook Heo*

University of Science and Technology (UST),

*Electronics and Telecommunications Research Institute (ETRI)

요약

본 논문은 전력 품질 파라미터 6종(역률, 유효전력, 전류 불평형률, 누적 전력량 차이, 설비 전력정격, 정격 전압)을 활용한 전력 시계열 데이터 기반 LSTM 모델로 제조설비의 Loading, Unloading, Stop 상태를 자동 분류하는 방법을 제안한다. 실험 결과, 모델의 정확도 98.21%, 운영 상태 분류의 평균 F1-Score 0.9766을 달성하였다. 기존 설비별 개별 모델 사용 시 평균 정확도 95.66%에 비해 2.55% 높은 성능을 보인다. 이를 통해 다양한 설비를 단일 모델로 통합 학습했음에도 경쟁력 있는 성능을 확보함으로써 실제 제조 현장에서의 확장성과 적용 가능성을 입증하였다.

I. 서론

최근 탄소중립 정책이 강화되면서 제품 단위의 탄소 배출량을 정량적으로 산정할 필요성이 증가하고 있다. 특히 유럽연합의 탄소국경조정제도과 디지털 제품 여권과 같은 규제는 수출입 및 공급망 전반에서 탄소 정보의 투명한 공개를 요구한다. 이에 따라 제조 기업은 제품의 탄소발자국을 체계적으로 산정해야 하는 상황에 직면하고 있다. 탄소발자국은 원자재 채굴부터 제조, 운송, 사용, 폐기까지 생애주기 전 과정에서 발생하는 온실가스 배출량을 의미하며, 이 중 제조 단계에서의 배출량 산정은 생산 공정의 에너지 사용량과 직결된다.

제조 단계에서 세부 공정 또는 부품 단위의 탄소 배출량을 추정하기 위해서는 설비별 에너지 소비 패턴을 파악하고, 설비의 운영 상태에 따른 전력 사용 특성을 분석할 필요가 있다. 동일한 설비라도 가공이 실제로 수행되는 구간>Loading), 작업 전환 또는 감속 구간>Unloading), 정지 구간>Stop) 등 운영 상태에 따라 전력 사용량과 신호 특성이 달라질 수 있다. Park et al. [1]은 설비의 운영 상태 분류를 위해 전력 신호의 시계열 정보를 활용하고 순환 신경망 모델을 적용하여 설비의 운전 상태를 분류하는 방법을 제안하였다. 그러나 해당 접근은 개별 설비의 데이터 특성에 최적화된 모델로 설계되어, 설비가 추가되거나 운영 환경이 변화할 경우, 추가

설비에 대한 데이터 확보와 모델 재학습이 요구되는 한계가 있다. 따라서 본 논문은 설비별 데이터 분포의 차이를 고려하여, 서로 다른 설비에서도 일괄적으로 적용이 가능한 통합 운영 상태 분류 방법을 제안한다.

II. 본론

본 논문은 Park et al. [1]의 전력 시계열 기반 운영 상태 분류 접근을 참고하되, 설비별 데이터 분포 차이를 반영하여 다수 설비를 단일 모델로 분류할 수 있도록 실험을 확장하였다.

본 장에서는 제조설비의 운영 상태를 Loading, Unloading, Stop의 세 가지 클래스로 분류하는 방법을 기술한다. 그림 1은 제안하는 분류 시스템의 전체 구조를 나타낸다. 먼저 전처리 과정에서는 설비 간의 전력 데이터 범위 및 분포 차이를 완화하기 위해 Z-score 정규화를 적용하고, 운영 상태와 연관성이 높은 전력 품질 파라미터를 입력 변수로 선정한다. 선정된 시계열 데이터에 슬라이딩 윈도우(Sliding Window) 기법을 적용하여 일정 길이의 입력 시퀀스를 구성하고, 이를 Long Short-Term Memory(LSTM) 모델의 입력으로 사용한다. 마지막으로 LSTM이 학습한 시간적 의존성을 기반으로 완전 연결층과 Softmax 활성화 함수를 통해 각 구간의 운영 상태를 분류한다.

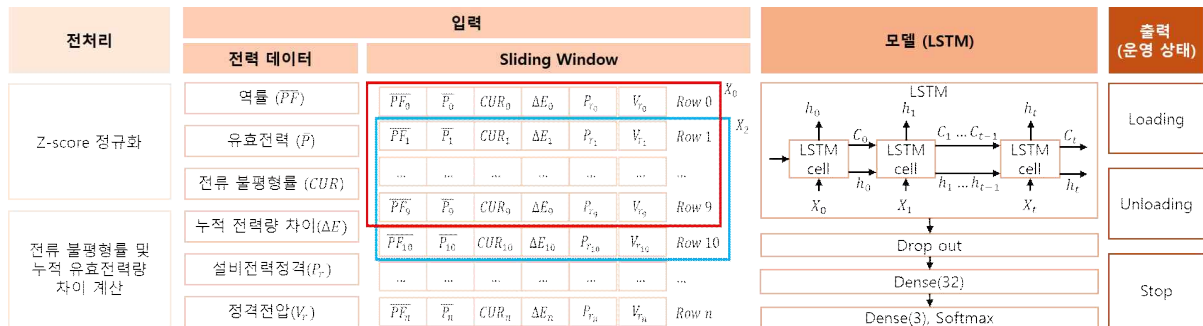


그림 1. 전력 품질 기반 제조설비 운영 상태 분류 시스템의 전체 구조

2.1 전력 설비 에너지 데이터셋

본 논문에서는 제조설비의 운영 상태를 분류하기 위해 AI 허브에서 제공하는 전력 설비 에너지 패턴 및 고장 분석 센서¹⁾ 데이터셋을 활용한다. 원본 데이터셋은 공작기계, 공기압축기, 보일러 등 다양한 설비 유형을 포함하며, 본 연구에서는 운영 상태 클래스(Load, Unload, Stop)의 분포가 상대적으로 균형을 이루는 6종의 설비(file number: 29, 246, 272, 324, 335, 533)를 선정하였다. 선정된 6종 설비의 총 데이터 개수는 227,055개이며, 각 클래스의 평균 비율은 Load 35.9%, Unload 29.75%, Stop 34.53%로 구성된다.

2.2 전력 설비의 운영 상태 특징 추출

입력 파라미터는 Park et al. [1]를 참고하여 역률 평균(\overline{PF}), 유효전력 평균(\overline{P}), 전류 불평형률(CUR), 누적 전력량 차이(ΔE)를 선정하였으며, 설비 간의 정격 및 운전 조건 차이를 반영하기 위해 설비 전력정격(P_r)과 정격 전압(V_r)을 추가 입력으로 포함하였다. 설비 전력정격 및 정격 전압은 시간에 무관한 설비의 고유한 특성이므로, 각 윈도우의 모든 시간 스텝에 동일한 값으로 반복 입력되어 최종 입력 차원을 (10, 6)으로 구성하였다.

전처리 과정에서 첫 번째로, 선정된 6종 설비의 데이터를 통합하여 각 파라미터별로 전체 학습 데이터를 기준으로 평균(μ)과 표준편차(σ)를 계산하여 Z-score($z = (x - \mu)/\sigma$)로 정규화하였다[2]. Z-Score를 사용한 이유는 전력 계측 데이터가 현장 환경(부하 변동, 센서 잡음, 통신 지연 등)으로 인해 순간적인 스파이크나 결측치가 발생할 수 있어 이상치에 상대적으로 덜 민감하고 분포 중심으로 범위를 정규화하기 때문이다. 이때 검증 및 테스트 데이터에는 학습 데이터에서 도출된 동일한 μ 와 σ 를 적용하여 데이터 누수를 방지하였다.

두 번째로, 시계열 특성을 반영하기 위해 정규화된 데이터에 슬라이딩 윈도우 기법을 사용하여 일정 길이의 연속 구간을 하나의 입력 시퀀스로 구성하였다. 데이터셋은 1분 간격으로 측정되므로, 슬라이딩 윈도우 길이를 10으로 설정하여 각 샘플이 10분 구간의 정보를 포함하도록 하였다. 윈도우는 1분 간격(stride=1)으로 이동하여 연속된 샘플을 생성한다. 각 입력 시퀀스의 정답 라벨은 윈도우의 마지막 시점에 해당하는 상태로 부여하였으며, 이는 윈도우가 포함하는 과거의 관측값을 활용하여 현재 시점의 운영 상태를 추정하도록 하는 설정으로, 실시간 적용 관점을 고려한다.

2.3 LSTM 모델

본 연구는 제조설비의 운영 상태를 Load, Unload, Stop으로 분류하기 위해 LSTM 모델을 활용한다. 제조설비의 운영 상태는 순간적으로 변화하지 않고 일정 기간의 전력 패턴 추이로 나타나므로, 앞서 구성된 10분 단위 시계열 데이터를 모델의 입력으로 사용한다. LSTM 레이어는 시계열 데이터의 장기 의존성을 학습하여 과거 시간 스텝의 정보를 효과적으로 활용함으로써 각 시간 구간에서의 운영 상태 변화를 포착한다[3].

모델 구조는 64개 유닛의 LSTM 레이어 이후 Dropout을 배치하여 과적합을 방지하며, 두 개의 완전 연결 레이어를 통해 특징을 축소한 뒤 최종적으로 Softmax 활성화 함수로 3가지 운영 상태의 확률을 출력한다. 학습 과정에서 조기 종료를 적용하여 검증 손실이 더 이상 개선되지 않을 때 학습을 중단함으로써 일반화 성능을 확보하였다.

1) 본 연구에 활용된 데이터셋은 과학기술정보통신부의 재원으로 한국지능정보사회진흥원의 지원을 받아 구축되었으며, aihub.or.kr에서 다운로드가 가능하다.

표 1. LSTM 모델의 운영 상태별 분류 성능

운영상태	정확도	정밀도	재현율	F1-Score
Loading		0.9847	0.9990	0.9918
Unloading	98.21%	0.9913	0.9854	0.9832
Stop		0.9609	0.9488	0.9548

III. 결과

LSTM 모델을 기반으로 설비 6종의 데이터를 통합하여 학습한 결과, 전체 운영 상태 분류 정확도는 98.21%를 기록하였다(표 1). 운영 상태 3종에 대한 정밀도(Precision), 재현율(Recall), F1-Score 평균은 각각 0.9790, 0.9744, 0.9766으로, 세 지표가 유사한 수준을 보여 특정 클래스에 편향되지 않고 균형 있게 학습되었음을 확인할 수 있다.

한편 참고 논문[1]에서는 설비별로 서로 다른 모델 구조와 하이퍼파라미터를 적용하였으며, 개별 설비 기준 정확도는 92.53%에서 99.95% 범위(평균 95.66%)의 성능을 보고하였다. 이를 고려할 때, 제안 방법은 개별 설비 최상위 성능과 비교하면 다소 낮을 수 있으나, 서로 다른 6종 설비의 데이터를 단일 모델로 통합하여 학습했음에도 불구하고 평균 정확도 대비 높은 성능을 달성했다는 점과 실용적인 관점에서 충분히 우수한 분류 성능을 보인다고 평가할 수 있다.

IV. 결론

본 논문에서는 AI 허브 전력 설비 에너지 패턴 및 고장 분석 센서 데이터셋을 활용하여 서로 다른 6종 제조설비의 운영 상태를 단일 LSTM 기반 모델로 통합 분류하는 방법을 제안하였으며, Z-score 정규화와 슬라이딩 윈도우 전처리를 통해 설비 간 데이터 분포 차이를 완화하고 전력 품질 및 설비 정격 정보를 통합한 입력 특성을 구성함으로써 전체 정확도 98.21%, 평균 Precision 0.9790, Recall 0.9744, F1-Score 0.9766의 균형 잡힌 성능을 달성하였다. 또한 설비별로 서로 다른 모델과 하이퍼파라미터를 사용한 기존 연구의 평균 정확도 95.66%와 비교했을 때, 서로 다른 설비 6종을 하나의 모델로 통합 학습했음에도 경쟁력 있는 성능을 유지함을 확인하였다. 이를 통해 디지털 트윈이나 공정별 탄소 원단위로 결합하여, 본 연구에서 분류한 Load/Unload/Stop 운영 상태 정보를 부품 또는 제품 단위의 탄소 배출량 산정에 활용할 수 있다.

ACKNOWLEDGMENT

본 연구는 2025년도 정부(산업통상자원부)의 재원으로 한국산업기술진흥원(KIAT)의 지원을 받아 수행된 연구임(RS-2025-04752996).

참 고 문 헌

- [1] Park, Y., et al., "순환신경망 기반 전력 데이터 분석을 활용한 제조설비 운영 상태 예측 사례 연구," Journal of the Korean Society for Precision Engineering, 2023.
- [2] Kim, Y.S., et al., "Investigating the impact of data normalization methods on predictive modeling," Sustainable Cities and Society, Vol. 105, pp. 105789, 2025.
- [3] Hochreiter, S., and Schmidhuber, J., "Long Short-Term Memory," Neural Computation, Vol. 9, No. 8, pp. 1735-1780, 1997.