

CNN을 이용한 3상 유도전동기 ITSC 진단의 효율적인 1차원 전류 신호 구성 및 Encoding방법

Efficient One-dimensional Current Configuration and Encoding Method for ITSC Diagnosis of 3-Phase Induction Motor using CNN

고 영 진^{*★}

Yeong-Jin Goh^{*★}

Abstract

This paper proposes an efficient fault diagnosis method for ITSC(Inter-Turn Short Circuit) in three-phase induction motors using CNN. By utilizing only the D-axis component of the D-Q synchronous coordinate system, it compares SWM(Slide Window Method) and GAF(Gramian Angular Field) methods for image encoding. Results show GAF achieving ~74% accuracy, while SWM achieves ~65%, indicating GAF's superiority by 9%. Learning time (~14.74s) remains consistent, particularly with epochs ≤ 100 , showcasing faster learning.

요 약

본 논문에서는 CNN을 이용한 3상 유도모터 ITSC(Inter-Turn Short Circuit) 고장진단에 있어서, 전류 데이터를 이용한 고장 진단 및 효율적인 이미지 encoding 방법을 제안하도록 한다. 진동, 소음센서를 이용한 방법과 달리 전류를 이용하는 방법은 데이터의 손실이 낮을 수 있다는 장점은 있지만, 3상 신호로 인해 CNN의 채널 수 증가의 부담이있다. 이에 D-Q 동기좌표계의 D축 성분만의 데이터를 활용하여 채널 부담을 줄이고, 효율적인 입력 이미지 구성 방법을 알아보고자 SWM(Slide Window Method)과 GAF(Gramian Angular Field)방식을 비교하도록 하였다. 데이터는 무부하부터 전부하까지 전체 변화를 고려하였으며, 그 결과, GAF방식은 약 74%, SWM방식은 약 65%로, GAF방식이 약 9%의 높은 정확도를 보임을 알 수 있었다. 또한, 학습된 속도에 있어서 약 14.74[s]로 전체 학습 시간대비 차이가 없었으며, 100 epoch 이하에서는 빠른 속도로 학습이 가능함을 알 수 있었다.

Key words : Induction Motor, ITSC, CNN, GAF, SWM

1. 서론

산업현장에서 두루 활용되는 모터 고장 중 ITSC(Inter

Turn Short Circuit)의 검출은 노이즈 및 손실과 같은 범주에 속하여 비슷한 특징을 나타냄에 따라 하나의 데이터 추출 센서에 의존하기에는 부족함이 있어 딥러닝

* Dept. of Electrical Engineering, Tongmyong University

★ Corresponding author

E-mail : zerojjin@tu.ac.kr, Tel : +82-51-629-1314

※ Acknowledgment This research was supported by the Tongmyong University of Research Grants 2022B008

Manuscript received Jun. 9, 2024; revised Jun. 20, 2024; accepted Jun. 22, 2024.

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

기반 진단이 불가피하다.

이에 최근 몇 년 동안 일부 학자들은 결합 진단을 위한 다중 센서 데이터 융합(진동+소음)을 통한 CNN의 진단 효율을 높이기 위해 연구되고 있다.

[1]은 1D 및 2D 컨볼루션 채널을 포함하는 다중 규모 학습 신경망을 제안하였으며, [2]에서는 다차원의 깊이(depth) 특징을 추출하기 위해 1D-CNN과 2D-CNN 병렬 다채널 구조의 사용이 제안되었다. [3]에서는 진동 신호와 음향 신호에서 특징을 추출하고, 1D-CNN 기반 네트워크를 사용하여 보다 정확한 진단 방법을 제안하였다. [4]에서는 두 개의 센서 데이터의 특징을 융합하기 위해 다중 2계층 SAE(Sparse Autoencoder) 신경망으로 변환하였다.

그러나 CNN은 1차원 신호 데이터 처리에 적합하며 다차원 데이터 처리에는 한계를 가지고 있다[5].

[6]의 논문에서는 진동 신호를 기반으로 1차원 신호를 2차원 신호로 바꿔주는 방법으로 프레임 길이와 샘플링 데이터 포인트 수의 관계로 신호 슬라이드 윈도우 방식을 제안하였다. 그러나, 프레임의 크기가 클수록 입력 레이어가 커지므로 신경망 처리에서 계산이 길어질 수 있다. 반면, 작은 프레임을 가질 경우 현재 신호의 적절한 특성을 나타내지 못하고 낮은 분류정확도를 생성할 수 있다. 이를 해결하고자 [7]과 [8]의 논문에서는 진동 및 소음 신호를 신호 슬라이드 윈도우 방식을 기반으로 GAF(Gramian Angular Field)를 제안하였다. 이는 1차원의 시계열 신호와 Gramian 행렬 사이의 시간적 상관관계를 보존하는 극좌표 기반 행렬로 나타내도록 하여 절대적인 시간적 관계를 유지하도록 하였으나, 채널수가 늘어나며, 불규칙적인 패턴구조로 컨볼루션 레이어에 다수의 필터적용과 처리시간이 늘어날 수 있다.

채널 수가 늘어남에 따라 처리 과정의 부담을 줄이기 위해 시계열 데이터를 PCA(Principle Component Analysis)를 적용하여 채널 수를 축소하여 GAF에 적용하도록 하였다[9]. 그러나, PCA처리과정에서 원데이터의 정보손실의 문제가 발생 될 수 있으며, 샘플링 수 또한 줄어드는 문제를 가지고 있다.

이처럼, SWM방식을 대체할 GAF방식으로 CNN의 성능을 개선할 수 있으나, 진동 신호에 의한 채널수 증가 및 패턴의 불규칙성, 정보손실의 문제가 대두되고 있다.

또한, 진동 및 소음은 실제 환경에 적용에 있어서 불규칙성이 심하게 나타날 수 있음에 따라 지도학습된 데이터와 상이할 수 있는 문제를 가지고 있다.

그러나, 3상 전류 신호를 이용한 CNN방식은 채널 수

의 증가에 문제가 있지만, 일정한 주파수 내에서 신호의 변동이 발생됨에 따라 일정한 규칙성을 가지고 있으며, 진동 및 소음방식에 비해 주변 환경에 영향도 적은 편이다.

이에 데이터의 정보손실 없이 3상 신호를 1상 시계열로 변환될 경우, 채널 수의 부담을 줄일 수 있으며, 이는 환경적 영향을 최소화할 수 있기 때문에 MCSA(Motor Current Signal Analysis)방법을 채택할 필요가 있다 [10].

한편, 종래의 연구들은 유도전동기의 속도 조절이 성능에 좋지 않기 때문에 많이 이뤄지지 않으므로 주로 활용되는 특정 속도에서 연구가 이뤄지고 있다.

그러나, 유도전동기를 공급하는 측면에서는 전체 속도 및 부하 상태에 맞춰진 범용적인 학습데이터를 공급할 필요가 있다.

이러함에 따라, 앞선 연구들에 대한 전체 부하에 따른 성능 비교가 필요하다.

이에 본 논문에서는 MCSA를 이용하여 3상의 입력신호를 간소화하는 방법을 제안하고, 효율적인 encoding 방법을 제안하고자 한다.

이를 수행하는 조건으로는 특정 부하 상태가 아닌 정상상태와 ITSC 상태에서의 무부하부터 전부하까지 전체 부하 변동의 빅데이터를 기반으로 encoding기법에 따른 CNN의 성능 비교를 하고자 한다.

II. 본론

1. 전류데이터의 1차원 시계열 구성방법

3상 유도전동기를 통한 측정된 전류는 3상의 형태로 3개의 시계열을 가지고 있다. 만약 3개의 시계열을 사용하여 CNN에 적용할 경우, 채널 수의 증가의 문제가 발생된다.

3상을 2상으로 변환하는 D-Q변환을 이용할 경우, 2개의 상으로 추출 가능하며, 이 중, 주요성분 0의 성분을 가지는 q축 성분을 제외한 d축 성분만을 이용하면 1개의 시계열로 구성이 가능하다.

D-Q변환은 유도전동기의 순시 토크를 제어하기 위해서 3상 전류가 고정자 권선에 흐를 때 자속 성분의 전류와 토크 성분의 전류가 얼마가 되는지 알기 위해 하는 방법으로 A, B, C상 전류를 90도 위상을 갖는 2개의 D-Q축 성분으로 변환하는 방법을 이용하고 있다. 3상 유도전동기의 경우 전압이나 전류, 자속을 D-Q 좌표 변환하는 근본적인 이유는 기구적으로 고정자 권선이 120

도 간격으로 배치되어 있어 해석이 용이하기 때문이다.

D축은 3상 유도전동기의 자속이 발생하는 축이며, 통상적으로 고정자 A상에서 발생하는 자속의 방향을 나타낸다. Q축의 경우 D축과 직각을 이루는 축으로 반시계 방향으로 회전시 D축에 앞서서 위치하게 되며 벡터 제어에서 토오크를 발생하는 전류 축을 의미한다.

또한 회전기에서 발생되지 않는 n축인 중성축이 존재하고 있으며 운동에너지의 역할을 하는 유도전동기에는 발생되지 않는다.

이처럼, D-Q 변환은 정지 좌표계(Stationary Reference Frame)와 회전 좌표계(Rotating Reference Frame)으로 구분된다.

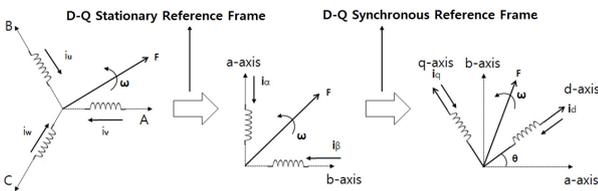


Fig. 1. Schematics explaining the D-Q transformation process.

그림 1. D-Q 변환의 과정

그림 1은 D-Q변환의 정지좌표계와 동기 좌표계의 변환하는 과정을 나타내고 있다.

이때, 3상 좌표계에서 A상이 발생시키는 자속의 방향과 일치하게 α 축과 직교하는 β 축을 2상 좌표계로 변환한 것을 D-Q 정지좌표계라고 한다.

회전 각속도를 고려할 경우, 두 개의 주파수로 회전하는 정지좌표계에서는 직류값으로 표현되며 그 크기는 교류값의 최대값으로 표현 가능하다.

그러한 결과, D축에는 방향만으로 크기가 나타나게 되어 자속의 성분이 D축으로 옮겨지게 된다. 이 때 Q축은 항상 0의 값이 출력하게 된다.

2. 입력데이터의 encoding 방법

가. SWM(Slide Window Method)

일반적으로 진단에 활용되는 진동 및 소음, 전류 신호 원 등은 시간 흐름에 따른 1차원임에 따라 이를 CNN에 적용하여 활용하기 위해 이미지로 변환하는 방법으로 신호 슬라이드 윈도우 방식을 이용하고 있다. 이 방식은 식 (1)을 이용하여 시간변화에 따른 2차원 이미지로 변경을 하고 있다. 다음 그림 2는 이 방법의 기본적인 프로세스를 설명하고 있다.

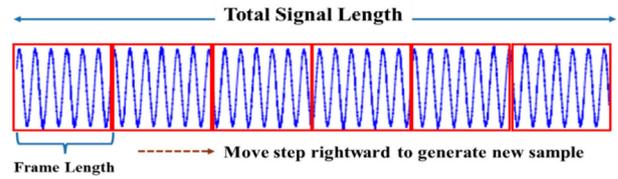


Fig. 2. Data segmentation for converting time-series data into an image.

그림 2. 시간변이 데이터에 대한 이미지 변환을 위한 데이터분할

$$n = \left\lfloor \frac{\zeta - \tau}{\varepsilon} \right\rfloor + 1 \quad (1)$$

τ 는 프레임 길이를 나타내며, 모든 샘플데이터 포인트 수가 τ 임을 의미하고 있다. n 은 총 샘플 수를 나타내며, 단계 크기는 ε 으로 표시되며 더 많은 훈련 및 테스트 샘플을 취할 수 있도록 τ 보다 작게 설정된다. 신호의 총 길이를 ζ 는 신호의 총 길이를 나타낸다.

여기서 프레임의 크기가 클수록 입력 레이어가 커지므로 신경망 처리에서 계산이 길어질 수 있다. 반면, 작은 프레임을 가질 경우 현재 신호의 적절한 특성을 나타내지 못하고 낮은 분류정확도를 생성할 수 있다.

이에, 실험과 수집된 데이터의 크기에 따라 크기를 적절히 정의해줘야 하는 문제가 있다.

나. GAF

GAF(Gramian Angular Field)는 각 시점 간의 시간적 상관관계를 극좌표 기반으로 표현하는 알고리즘이며. 시계열 데이터를 극좌표 기반 행렬 형태의 이미지로 변경하는 것은 시간 상관관계를 보존할 수 있다는 장점이 있다. 일반적으로 GAF 알고리즘을 적용하기 전에 시계열 데이터의 값을 극좌표 값으로 변환할 때 치역을 통일하기 위해서 $[-1, 1]$ 혹은 $[0, 1]$ 구간으로 정규화시킨다. 이때, 정규화된 신호를 \tilde{x}_i 라고 하고 시간 인덱스를 t_i , 반지름을 r_i 로 표현한다면 식 (2)처럼 극좌표로 변환할 수 있다.

$$\begin{cases} \phi_i = \arccos(\tilde{x}_i), & -1 \leq \tilde{x}_i \leq 1, \text{ and } \tilde{x}_i \in \tilde{X} \\ r_i = \frac{t_i}{N}, & t_i \in N \end{cases} \quad (2)$$

여기서 N 은 극좌표계의 범위에 따른 정규화 상수이며, GAF는 각도의 합과 차에 따라 두 가지 방식으로 나뉜다. GASF는 i 와 j 의 시간 쌍으로 이뤄진 극좌표계 시계열 데이터의 각도 합으로 나타내며, 다음 식 (3)과 같다.

$$GASF = \begin{bmatrix} \cos(\phi_1 + \phi_1) & \dots & \cos(\phi_1 + \phi_n) \\ \cos(\phi_2 + \phi_1) & \dots & \cos(\phi_2 + \phi_n) \\ \vdots & \ddots & \vdots \\ \cos(\phi_n + \phi_1) & \dots & \cos(\phi_n + \phi_n) \end{bmatrix} \quad (3)$$

GADF(Gramian angular difference field)는 GASF와 반대로 극좌표계의 각도 차로 다음 식(4)와 같다.

$$GADF = \begin{bmatrix} \sin(\phi_1 + \phi_1) & \dots & \sin(\phi_1 + \phi_n) \\ \sin(\phi_2 + \phi_1) & \dots & \sin(\phi_2 + \phi_n) \\ \vdots & \ddots & \vdots \\ \sin(\phi_n + \phi_1) & \dots & \sin(\phi_n + \phi_n) \end{bmatrix} \quad (4)$$

GAF는 왼쪽 상단에서 오른쪽 하단으로 이동함에 따라 시간이 증가하기 때문에 시간 종속성을 보존한다. 주대 각선은 원시 데이터의 값과 각도 정보를 포함하기 때문에 이를 이용하여 원시 데이터를 복구할 수 있다.

3. 실험환경 및 구성

가. D-Q 정지좌표계의 D축성분 추출

본 실험을 진행하기 위해 측정된 3상 전류데이터를 D-Q 정지좌표계를 통한 D-Q 동기좌표계로 변환한 뒤, d축의 전류성분만을 이용하여 전류를 측정하도록 하였다.

그림 3(a)는 정상상태의 실제 3상 유도전동기(3상, 1HP, 4극) 전류와 (b)는 D-Q변환에 의한 정지좌표계 I_α , I_β 및 동기좌표계의 I_d 를 나타내고 있다.

본 논문에서는 3상의 신호를 1차원 시계열로 추출한 D-Q 동기좌표계의 I_d 값을 이용하여 이미지로 encoding하도록 하였다. 한편, 정상상태와 고장상태를 비교하기 위해 고장상태는 고정자의 미세한 턴 단락을 시료로 사용하였다.

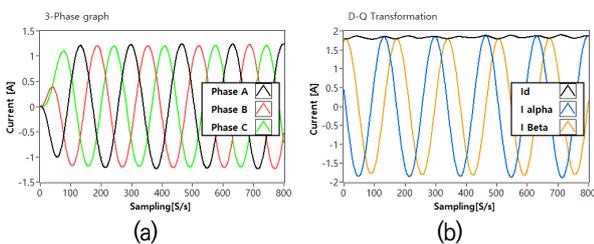


Fig. 3. D-Q transformation results for a three-phase current source: (a) input three-phase current; (b) transformation result of D-Q stationary and synchronous reference frame.

그림 3. 3상 전류원의 D-Q변환 결과: (a) 입력 3상 전류, (b) D-Q 정지 및 동기좌표계의 변환 결과

나. 입력데이터의 encoding

(1) 구성방법

본 실험은 SWM 방식과 GAF방식에 대하여 전체 부하

상태를 학습하고, encoding에 따른 CNN진단의 성능 유용성을 검증함에 있기 때문에 SWM방식과 GAF방식으로 입력데이터를 encoding하도록 하였다.

encoding에 앞서 필터에 의한 데이터 변형 값을 가지는 초기값을 1,000sample을 제외하고 9,000sample을 이용하여 구성하도록 하였다.

이를 이미지로 encoding하기 위해 30*30 size로 정규화 하여 주도록 하였으며, 1분간 측정된 데이터에서 총 10개의 이미지를 추출하도록 하였다.

(2) SWM encoding

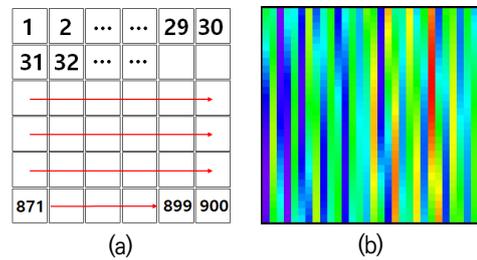


Fig. 4. Slide window method (SWM) used for image configuration: (a) SWM configuration and (b) SWM with the applied spectrogram.

그림 4. SWM의 이미지 구성방법: (a) SWM구성 (b) 스펙트로그램을 적용한 SWM

9,000 sample에 대하여 30*30 size로 SWM으로 구성하기 위해 다음 그림 4와 같이 구성하도록 하였다.

(3) GAF

GAF구성에 있어서 GASF를 이용하여 실험하도록 하였다. 이미지 구성방법에 있어서 900 sample에 대하여 SWM과 동일한 30*30size로 구성하도록 하였으며 식 (3)을 통해 구현하도록 하였다. 또한, 구성된 1개의 encoding 이미지를 SWM과 동일하게 스펙트로그램으로 나타내었다.

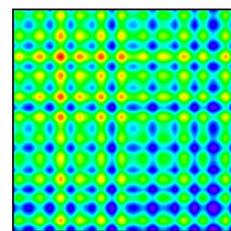


Fig. 5. GASF spectrogram. 그림 5. 스펙트로그램이 적용된 GASF

그림 5는 실제 유도전동기의 정상상태에 대한 GASF를 나타낸다.

다. CNN 구성

더욱 많아진 데이터양과 처리의 정확도를 위해 CNN 모델의 layer를 깊게 할수록 성능이 떨어지게 된다. 이는 gradient vanishing/exploding 문제 때문에 학습이 잘 이뤄지지 않기 때문이다. resNET은 skip connection을 이용한 residual learning을 통해 layer가 깊어짐에 따른 gradient vanishing 문제를 해결할 수 있다. 이 중 resNET-50은 50개의 계층으로 구성된 컨벌루션 신경망을 의미하며, 신경망 모델중 Training speed, inference speed 등 뛰어난 성능을 가진 것으로 알려져 있다. 이에 본 논문에서는 resNET50을 파이썬으로 구현하여 실험에 활용하였다.

학습 및 훈련데이터의 비율은 8:2로 구성하였으며, 학습데이터 내에서 학습데이터와 validation data는 7:3으로 구성하였다. CNN의 구성 방법은 표 1과 같다.

여기서 batch size는 하나의 소그룹에 속하는 데이터 수를 의미하며, 소그룹으로 나누는 이유는 트레이닝 데이터를 전체로 신경망에 넣으면 비효율적인 리소스 사용으로 학습시간이 오래 걸리기 때문이다. Step per Epoch는 Weight와 Bias를 1회 업데이트하는 것을 1Step이라 하며 총 137step으로 설정해 주었다. 학습 횟수 epoch는 200회를 실시하도록 하였다.

Table 1. Setup for convolutional neural network configuration.

표 1. CNN 구성을 위한 설정

	SWM	GAF
Total data - steady state	6,347	6,365
Total data - inter-turn short circuit	6,253	6,252
Total learning data	12,600	12,617
Validation data	3,780	3,785
Training data (excluding 20 % for testing)	8,820	8,831
Train batch size	64	64
Train step per epoch	137	137
Validation batch size	64	64
Validation steps per epoch	59	59
Epoch	200	

표 1에서 알 수 있듯이, SWM과 GAF의 성능비교를 위해 전체적인 CNN의 성능을 동일시 구성하도록 하였다.

4. 실험 결과

다음 그림 6은 실험환경 및 구성에 따른 SWM방식과

GAF방식에서 ITSC와 정상상태의 Train하에서 정확도를 나타내고 있다.

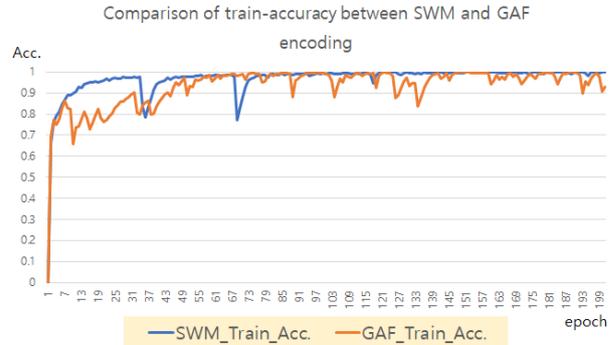


Fig. 6. Comparison of train accuracy between SWM and GAF encoding.

그림 6. SWM과 GAF의 학습 정확도 비교

Train accuracy는 실험 환경에서 구성된 70:30의 비율 중, 30% 데이터인 학습에 관여한 데이터를 기반으로 측정된 결과이다. 그림에서 알 수 있듯이 두 방식은 60 epoch에서 100%에 해당하는 정확도를 보이고 있다.

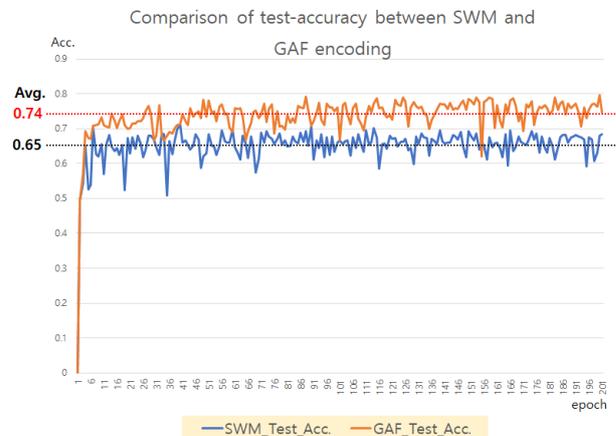


Fig. 7. Comparison of test accuracy between SWM and GAF encoding.

그림 7. SWM과 GAF의 훈련 정확도 비교

그림 7은 학습에 관여하지 않는 20%의 데이터를 기반으로 측정된 전체 부하 상태에서의 정확도를 보이고 있다.

일반적으로 1D CNN을 이용한 방법은 95%~97%의 정확도 성능을 보인다. 이것은 전부하 속도 상태에서의 연구 결과만을 나타낸다. 산업용 진단기에 올바른 진단장치를 개발하기 위해서는 무부하부터 전부하까지의 속도환경에서 진단 결과가 필요하다. 이에 본 연구에서

는 무부하에서부터 전부하까지의 전체 속도 데이터를 고려하였다. 그러함에 따라 일반적인 방법인 SWM방식은 평균 약 65%의 정확도를 가지며, GAF방식은 평균 약 74%의 정확도로 GAF가 9% 우수한 성능을 보였다.

그림 8은 SWM과 GAF방식이 학습 속도에 미치는 영향을 알아보기 위한 그래프이다.

두 방식의 전체 학습 시간은 SWM 약 45.49시간, GAF는 약 44.67시간이며, 평균 학습 속도는 SWM 818.95[s], GAF 804.21[s]로 나타났다. 이 결과, GAF가 14.74[s]로 전체 학습시간 대비 큰 차이없는 속도를 보임을 알 수 있으며, 약 50epoch부터 100epoch 사이에서 GAF 방식이 빠른 속도를 보임을 알 수 있다.

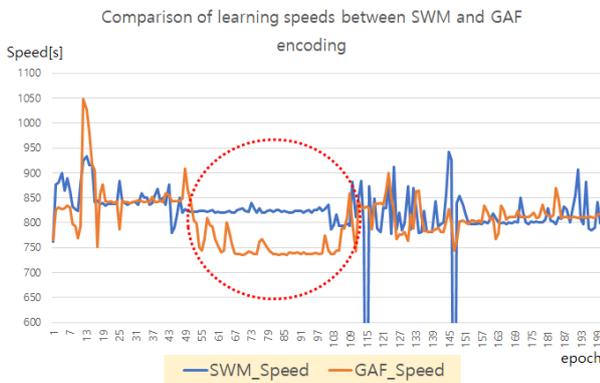


Fig. 8. Comparison of learning speeds between SWM and GAF encoding.

그림 8. SWM과 GAF의 학습 속도 비교

50epoch 이하에서는 CNN의 구조 내에서 sigmoid 함수의 미분특성으로 인해 결합하게 되면서 학습이 느려지는 현상이 있으나, 50 epoch 이상에서부터 안정화를 찾는 것을 알 수 있다.

그러나, 100epoch 이상에서는 데이터의 오버피팅현상으로 다시 학습 속도가 올라감을 유추할 수 있다.

즉, 그림 7과 그림 8을 토대로 보았을 때, GAF방식을 이용하여 과다한 학습량보다도 100epoch 이하로 학습하는 것이 정확도 및 시간 절약에도 우수함을 알 수 있다.

III. 결론

본 논문에서는 MCSA를 이용하여 CNN의 ITSC진단 하는데 있어서 입력 이미지 구성을 위한 전류신호원의 합성 및 효율적인 인코딩 방법을 제안하였다.

통상 산업현장은 3상 교류 전원시스템으로 구축되어 있음에 따라 3상의 전류신호를 CNN에 이용할 경우, 채

널 수의 증가 및 처리시간 등의 문제가 발생할 수 있다. 이를 해결하고자 본 논문에서는 3상 유도모터에서 측정된 전류 데이터를 D-Q변환 동기좌표계로 변환하여 D축 성분만을 이용하여 1차원 신호만으로 구성하도록 하였다.

CNN의 적용함에 있어서 기존의 논문들에서는 3상 유도모터의 특정 부하 하에서만 실험한 반면, 본 논문에서는 무부하부터 전부하까지의 변화를 데이터로 구성하여 실험을 실시하였다. CNN은 resNET-50을 적용하였으며, 시계열 데이터에 적합한 입력 이미지 구성 방법을 파악하고자 SWM방식과 GAF방식을 적용하여 비교하도록 하였다.

학습에 참여하지 않은 데이터를 기반으로 테스트한 결과, GAF방식은 약 74%, SWM방식은 약 65%의 정확도를 보였으며, GAF방식이 약 9%의 높은 정확도를 보임을 알 수 있었다. 또한, 학습된 속도에 있어서 약 14.74[s]로 전체 시간 대비 차이가 없으며, 100 epoch 이하에서는 빠른 속도로 학습이 가능함을 알 수 있었다.

References

- [1] D. Wang, Q. Guo, Y. Song, S. Gao and Y. Li "Application of multiscale learning neural network based on CNN in bearing fault diagnosis," *J. Signal Process. Syst.* vol.91, no.4, pp.1205-1217, 2019. DOI: 10.1007/s11265-019-01461-w
- [2] F. Xue, W. Zhang, F. Xue, D. Li, S. Xie and J. Fleischer "A novel intelligent fault diagnosis method of rolling bearing based on two-stream feature fusion convolutional neural network," *Measurement*, vol.176, pp,109226, 2021. DOI:10.1016/j.measurement.2021.109226
- [3] X. Wang, D. Mao and X. Li "Bearing fault diagnosis based on vibro-acoustic data fusion and 1D-CNN network," *Measurement*, vol. 173, pp.108518, 2021. DOI: 10.1016/j.measurement.2020.108518
- [4] Z. Chen and W. Li "Multisensor feature fusion for bearing fault diagnosis using sparse auto-encoder and deep belief network," *IEEE Trans. Instrum. Meas.*, vol.66, no.7, pp.1693-1702, 2017. DOI: 10.1109/TIM.2017.2669947
- [5] H. Ren, J. F. Qu, Y. Chai, Q. Tang and X. Ye "Deep learning for fault diagnosis: The state of

the art and challeng.” *Kongzhi yu Juece/Control and Decision*, vol.32, no.8, pp.1345-1358, 2017.

DOI: 10.13195/j.kzyjc.2016.1625

[6] R. Zhang, L. T. Wu and Y. Guan “Transfer Learning With Neural Networks for Bearing Fault Diagnosis in Changing Working Conditions,” *IEEE Access*, vol.5, pp.14347-14357, 2017.

DOI: 10.1109/ACCESS.2017.2720965

[7] R. N. Toma, F. Piltan, K. Im, D. Shon, T. H. Yoon, D.-S. Yoo and J.-M. Kim “A Bearing Fault Classification Framework Based on Image Encoding Techniques and a Convolutional Neural Network under Different Operating Conditions,” *sensors*, vol.22, no.13, pp.4881, 2022.

DOI: 10.3390/s22134881

[8] J.-H. Chen and Y.-C. Tsai “Encoding candlesticks as images for pattern classification using convolutional neural networks,” *Financial Innovation*, vol.6, pp.26, 2020. DOI: 10.48550/arXiv.1901.05237

[9] K. S. Kiangala and Z. Wang “An Effective Predictive Maintenance Framework for Conveyor Motors Using Dual Time-Series Imaging and Convolutional Neural Network in an Industry 4.0 Environment,” *in IEEE Access*, vol.8, pp. 121033-121049, 2020. DOI: 10.1109/ACCESS.2020.3006788

[10] Y.-J. Goh and K.-M. Kim “Diagnosis of Inter Turn Short Circuit in 3-Phase Induction Motors Using Applied Clarke Transformation,” *Journal of IKEEE*, vol.27, no.4, pp.151-156, 2023.

DOI: 10.7471/ikeee.2023.27.4.518

BIOGRAPHY

Yeong-Jin Goh (Member)



2008 : BS degree in Electrical and Semiconductor Engineering, Chonnam National University.
 2010 : MS degree in Electrical and Semiconductor Engineering, Chonnam National University.

2016 : PhD degree in Electrical and Semiconductor Engineering, Chonnam National University.

2020.09~present : Professor, Tongmyong University