

유도전동기의 고정자 고장 진단을 위한 CNN의 활성화 함수 선정

김경민* · 김용현* · 박근호* · 이 범* · 이상로** · 고영진****

A Activation Function Selection of CNN for Inductive Motor Static Fault Diagnosis

Kyoung-Min Kim* · Yong-Hyeon Kim* · Guen-Ho Park* · Buhm Lee* · Sang-Ro Lee** ·
Yeong-Jin Goh****

요 약

본 논문에서는 유도전동기 고정자 고장 진단에 있어서 활성화 함수가 미치는 영향을 분석하여 효율적인 CNN 활용 방법을 제안하였다. 일반적으로 유도전동기 고정자 고장 진단의 주된 목적은 미세한 턴 단락을 빠르게 진단함으로써 고장을 미리 방지함에 있다. 이에 활성화 함수 활용에 있어서 전반적인 고정자 고장에는 ReLu가 우수성을 보임을 알 수 있었으나, 미세한 턴 단락인 2턴 단락에 있어서는 Sigmoid 함수가 ReLu 함수보다 진단의 정확도에 있어서 23.23% 유용함을 실험을 통해 확인할 수 있었다.

ABSTRACT

In this paper, we propose an efficient CNN application method by analyzing the effect of activation function on the failure diagnosis of the inductive motor stator. Generally, the main purpose of the inductive motor stator failure diagnosis is to prevent the failure by rapidly diagnosing the minute turn short. In the application of activation function, experiments show that the Sigmoid function is 23.23% more useful in accuracy of diagnosis than the ReLu function, although it is shown that ReLu has superiority in overall fixer failure in utilizing the activation function.

키워드

ReLu, Matrix image, CNN, 3-phase induction motor, Fault Diagnosis
ReLu, 활성화 함수, 행렬화 이미지, 컨볼루션 인공 신경망, 3상 유도 전동기, 고장 진단

1. 서 론

최근 3상 유도전동기의 고장 진단기술은 ANN (:Artificial Neural Network), Fuzzy, SVM (: Support Vector Machine), Perceptron 등과 같은 지능형 결합

진단을 기반으로 한다[1-3].

이러한 방법은 고정자 고장의 결합 진단에 대한 긍정적인 발전을 이루었으며 그 성능을 입증하였다[4]. 또한, 최근 Deep Learning 기술을 기반으로 한 데이터 기반 접근 방식은 기존의 결합

*전남대학교 전기및반도체공학과(kkm@jnu.ac.kr, Received : Mar. 01, 2021, Revised : Mar. 24, 2021, Accepted : Apr. 17, 2021
cnrqjtk@gmail.com, rmsggh2411@gmail.com, * Dept. of Electrical and Semiconductor Eng. Chonnam National Univ.

buhmlee@hanmail.net, zerojin@sunchon.ac.kr) ** WP Co., Ltd.

† 교신저자 : 동명대학교 전기공학과

† Corresponding Author : Yeong-Jin Go

· 접수일 : 2021. 03. 01

Dept. of Electrical Eng. Tongmyeong University,

· 수정완료일 : 2021. 03. 24

Email : jericho90@naver.com

· 게재확정일 : 2021. 04. 17

진단 방식과 비교하여 최소 턴 단락 결합검출에 강점을 보였으며, 이를 통하여 Deep Learning 기반의 고장 진단 방법이 방대한 데이터를 이용할 경우 강력한 성능을 보임을 확인하였다.

최근 연구들에서는 Deep Learning의 CNN (Convolutional Neural Network)를 활용하여 많은 연구가 진행되었다. 이때, 데이터를 수집하는 방법, 특징을 추출하는 방법, 고장환경 및 조건 등에 따라 각각의 성능의 차이를 보인다.

일반적인 데이터를 취득하는 방법으로 MCSA(Motor Current Signature Analysis)를 사용하여 취득함으로써 추가적인 회로 구성없이 처리하도록 하고 있다.

측정된 전류 데이터를 1차원 배열을 통한 이미지화 함으로 고정자의 Turn-to-Turn 단락에 관해 연구를 진행하였으며, 특징 추출하는 방법을 FFT가 아닌, 전류 3상의 값을 각 상당 2,000개의 데이터를 2차원 행렬로 변환한 후 이미지화하였다[5-6].

한편, 유도전동기의 고장은 다양함에 따라 다양한 복합고장 환경하에 분류체계를 만들기 위해 [7]의 논문에서는 CNN을 이용한 복합고장진단 및 분류를 시행하였으나, 고장 상황에 대한 샘플데이터가 모호하고 고장 진단의 정확도만을 언급하였다.

최근에는 IOT Sensor의 보급으로 IOT Sensor를 이용하여 데이터를 수집 후, CNN을 활용하는 방법 또한 연구되었다.

[8]의 논문에서는 센서를 통해 수집된 데이터를 FFT 방법으로 고장 상황별 전류값을 이미지화하였으며, 이를 통한 CNN을 적용함으로 고장 진단을 수행하였다. 이때, 고장은 고정자의 Turn-to-Phase로 구성하였다.

이처럼 일반적으로 전류 데이터 및 과거 유도전동기의 고장 진단 및 모니터링환경에 적합한 방법인 PVA(Park's Vector Approach)를 CNN과 결합하여 연구가 진행되기도 하였다[9].

이처럼 CNN를 활용하여 진단하는 방법은 데이터를 이미지화하여 처리하기 때문에 CNN의 성능을 높이기 위해서는 전처리과정이 중요하며, 이미지의 데이터를 손실 없이 처리하기 위해서는 활성화 함수(Activation Function)가 중요하다[10].

이에 본 논문에서는 유도전동기의 고정자 고장 진단에 있어서 특징추출 방법으로 사용된 전류 데이터

를 이미지화하여 처리하는 방법에 있어서 Turn-to-Turn 고장을 2턴, 4턴, 6턴으로 세분화하여 CNN의 활성화 함수가 진단 정확도에 미치는 영향을 알아보고자 대표적인 활성화 함수인 Sigmoid, ReLu, Max out을 비교 분석하여 CNN을 활용한 유도전동기 고장 진단에 있어서 진단 특징 및 방법에 적합한 활성화 함수를 연구하도록 하였다.

II. 전류 데이터

2.1 전류 데이터의 수집

3상 전류 데이터의 경우 다이내모 시스템을 이용하여 인버터로 구동함으로써 이를 유도전동기와 연결하여 구성하였으며, 전 부하 속도인 1690[rpm]부터 무부하 속도 1800[rpm]까지 간격을 두어 3상 전류의 값을 그림 1과 같이 추출하였다[11].

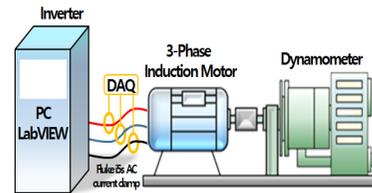


그림 1. 데이터 수집 과정
Fig. 1 Data collection process

위와 같은 조건을 통하여 1초당 수집한 각 상당 9,000개의 3상 전류 데이터를 사용하였으며, 이는 54개의 패턴으로 이루어진 1장의 이미지로 변환하여 연구에 적용하였다. 데이터수집은 Fluke사 i5s AC current clamp를 이용하였으며, National Instruments의 USB-DAQ 9215A with BNC로 데이터수집으로 사용하였다.

이때 측정된 전류 데이터는 많은 노이즈를 포함함에 따라 저역 필터를 적용하였으며, 측정된 3상 전류의 데이터는 3상을 2상으로 변환하여주기 위해 D-Q 변환을 활용하였으며, 2상의 전류값을 2차원 행렬로 구성하여 이미지로 저장되었다.

2.2 이미지 데이터 변환

2차원 행렬화 시킨 전류의 값을 패턴별 이미지 추출을 진행하기 위해 3상 전류 기준으로 데이터 1초 간격으로 구분하였으며, 이미지에 대한 규격을 통일하기 위하여 픽셀당 0부터 255까지의 스케일을 사용하였다. 또한 이미지 당 640*640으로 규격화하였다.

그림 2의 전류 행렬화 이미지는 M. Skowron, T. Kowalska가 제안한 CNN 방식의 이미지 수집 방식을 이용하여 전류값 변환 이틀 이미지화한 방식으로, 3상 전류의 값에 대하여 각 상별로 1초 동안 수집한 데이터(90,000개 * 3상)를 90*100 행렬로 변환시켜 각 상에 대하여 R, G, B로 이미지화시킨 것으로 90*100*3의 이미지를 출력하였다.

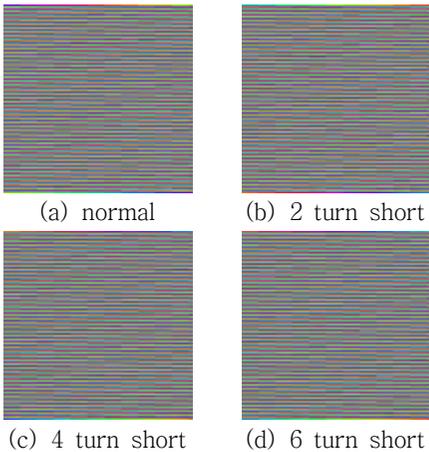


그림 2 턴 단락별 전류 행렬화 이미지
Fig. 2 Current matrix image by turn short

각 턴 단락별 이미지의 수는 1690[rpm]부터 1800[rpm]까지 10[rpm]간격으로 30초간 취득하였으며 이는 1sampling * 30seconds * 12가지 부하, 턴 단락마다 360가지의 패턴을 구성하였다. 전체 이미지의 수는 360개 이미지와 정상상태를 포함한 4가지 경우로 총 1,440개이며 무작위 선별을 통하여 학습데이터(Training data)는 1,080개, 테스트 데이터(Test data)로 구분하였다. 또한 학습데이터 내부의 검증을 위하여 전체 훈련데이터 중 검증데이터(Validation data) 360개를 따로 구성하여 학습을 진행하였다.

2.3 CNN 실험조건

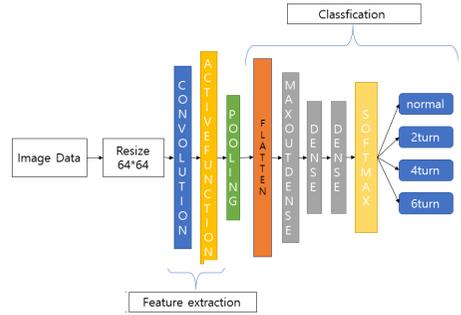


그림 3. CNN 구성
Fig. 3 Composition of CNN

CNN의 구성은 그림 3과 같이 하였으며, 초기 조건은 표 1과 같이 Epoch는 400, Convolution의 경우 3*3*64의 필터를 사용하였으며, Pooling은 Max Pooling 기법을 이용하였으며, Classification 층의 Dense의 은닉층은 64-64-64로 3개의 층을 사용하였다. 활성화 함수는 Sigmoid, LeRu, Max out을 통해 유도전동기 진단에 적합한 활성화 함수를 연구하였다.

표 1. 초기 파라미터
Table 1. Initial parameter

Parameter	Initial Value
Epoch	400
Convolution Layer	3*3*64
Pooling	Maxpooling
Dense	60-60-60
Activation function	Sigmoid, LeRu, Max out

III. 활성화 함수

3.1 Sigmoid 함수

Sigmoid 함수는 Logistic 함수라 불리며 가장 대표적인 활성화 함수 중 하나이다. 선형인 다층 퍼셉트론(MLP)에서 비선형 값을 얻기 위해 사용하기 시작하였으며 함수는 식(1)과 같으며 이에 따른 결과 그래프는 그림 4와 같이 얻을 수 있다.

x 는 0~255의 스케일을 0~1까지의 값으로 정규화시킨 것이다.

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (1)$$

$$f = 0 (x < 0)$$

$$f = x (x \geq 0)$$

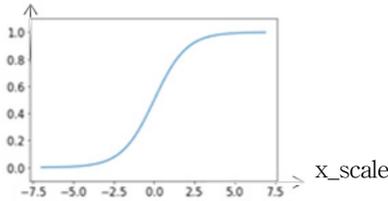


그림 4. Sigmoid 함수

Fig. 4. Sigmoid function

3.2 ReLu(:Rectified Linear Unit) 함수

ReLU(:Rectified Linear Unit)는 은닉층을 활성화하는 함수로 sigmoid와는 다른 방식으로 동작하는 활성화 함수이며, sigmoid나 tanh 함수와 비교했을 때 수렴 속도가 빠른 것이 특징이다. 이는 함수가 saturated 하지 않고 linear 하기 때문에 나타난다. 컨볼루션 레이어는 특징을 추출하는 기능을 하는 필터와 이 필터값을 비선형 값으로 바꾸어 주는 활성화 함수로 이루어져 있는데 이미지에 일반 신경망을 사용할 경우 거대한 수의 뉴런으로 인해 크기가 너무 커져서 과적합(Overfitting)이 발생할 수 있기 때문에 ReLU 활성화 함수를 사용한다.

ReLU 함수는 0보다 작으면 항상 0을, 0보다 크면 입력값 그대로 출력한다. ReLu함수는 식 (2)로 나타낼 수 있으며, 결과 그래프는 다음 그림 5와 같이 출력된다.

$$f = 0 (x < 0)$$

$$f = x (x \geq 0) \quad (2)$$

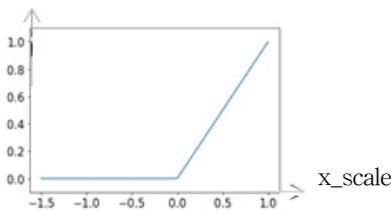


그림 5. ReLu 함수

Fig. 5. ReLu function

3.3 Max out 함수

Max out 함수는 ReLu가 갖는 장점을 모두 가지면서도 ReLu 함수의 '0 이하이면 0을 출력'에 대한 문제를 해결한 함수이며, 해당 층(Layer)의 가장 큰 노드 값을 선택해 결과값으로 정하는 수학적식이다. Max out은 식 (3)과 같으며, 이는 다음 그림 6과 같이 구조가 형성되어져 있다.

$$\max(w_1x + b_1, w_2x + b_2, w_3x + b_3, \dots, w_nx + b_n) \quad (3)$$

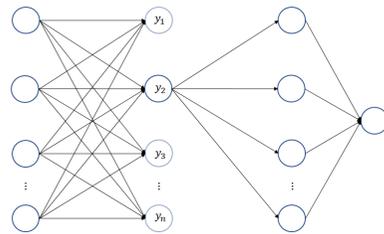


그림 6. Max out 구조

Fig. 6 Max out structure

IV. 실험 결과

표 2는 전류 행렬화 이미지를 사용하여 활성화 함수를 변화시켰을 때, 300번의 학습을 진행한 후, 정상 상태 및 각 턴 단락에 대한 고장분류 정확도를 나타낸 것이다.

표 2. 전류행렬 이미지를 이용한 고장분류 정확도
Table 2. Fault classification accuracy(Current matrix image)

	Sigmoid	ReLu	Max out
Normal	100	100	100
2-turn fault	73.84	50.61	0
4-turn fault	0	61.25	0
5-turn fault	70.42	98.02	82.81
Accuracy	80.8	81.23	80.36

실험 결과 ReLu 함수가 상대적으로 각 고장 턴 단락에 고르게 고장 진단 정확도를 나타내는 것으로 실험을 통해 알 수 있으나, 전반적으로 활성화 함수에 크게 영향을 받지 않는 것을 알 수 있다.

한편, 많은 연구에서는 미세한 턴 단락을 나타내는

2턴 단락을 진단하고자 큰 노력을 하고 있다. 이러한 이유는 미세한 턴 단락이 발생함에 따라 점차 턴 단락이 커짐에 따라(2천 단락-> 4천 단락-> 6천 단락) 초기에 빠르게 진단하기 위해서이다.

이에 본 논문의 실험 결과를 비추어볼 때, 미세한 턴 단락을 빠르게 검출하기 위해서는 Sigmoid 함수가 ReLu보다 23.23% 우수함을 알 수 있다.

V. 결 론

본 논문에서는 유도전동기 고정자 고장에 있어서 CNN을 활용한 진단 방법에 대하여 대표되는 활성화 함수가 미치는 영향을 분석하도록 하였다.

실험방법에 있어서 많은 논문에서 사용한 3상 전류 데이터를 D-Q 변환을 통해 2상으로 변환한 뒤 2차원 배열을 통한 이미지로 구성하도록 하였으며, 정상상태, 2천 단락, 4천 단락, 6천 단락으로 턴 단락별로 나타내었다.

이에 대표되는 활성화 함수인 Sigmoid, ReLu, Max-out을 통한 진단의 정확도를 비교하여 본 결과 전체적인 정확도에 있어서는 큰 차이는 없었으나, ReLu함수를 활용할 경우 턴 단락별 고르게 진단을 할 수 있음을 알 수 있었다.

그러나 유도전동기 고정자 고장 진단의 주요한 사항은 미세한 턴 단락을 빠르게 검출함을 목표로 연구되고 있다는 점을 고려할 때 2천 단락에 있어서 Sigmoid 함수가 ReLu 방법보다 진단 정확도에 있어서 23.23% 더 우수함을 알 수 있었다.

일반적으로 CNN을 이용한 방법에서 ReLu 방법이 우수하다고 알려졌으나, 본 논문의 실험 결과 유도전동기의 진단 특성에 맞춰볼 때 Sigmoid 함수가 유용함을 알 수 있었다.

향후 CNN을 적용한 유도전동기의 고정자 고장 진단에 있어서 Sigmoid함수와 ReLu함수를 병행하여 활용하는 방안에 관한 연구가 필요할 것으로 판단된다.

감사의 글

This research was supported by X-mind Corps program of National Research Foundation of Korea funded by the Ministry of Science, ICT (No. 2019H1D8A1109673).

This research was supported by MOTIE and KIAT through the National Innovation Cluster R&D program **P0006665**.

References

- [1] A. Boum, N. Y. J. Maurice, L. N. Nneme, and L. M. Mbumda, "Fault Diagnosis of an Induction Motor based on Fuzzy Logic, Artificial Neural Network and Hybrid System," *Int J of Control*, vol. 8, no. 2, 2018, pp. 42-51.
- [2] S. E. Pandarakone, Y. Mizuno, and H. Nakamura, "A Comparative Study between Machine Learning Algorithm and Artificial Intelligence Neural Network in Detecting Minor Bearing Fault of Induction Motors," *Energies*, vol. 12, no. 11, 2019, pp. 2105.
- [3] J. C. Quiroz, N. Mariun, M. R. Mehrjou, M. Izadi, N. Misron, and M. A. M. Radzi, "Fault detection of broken rotor bar in LS-PMSM using random forests," *Measurement*, vol. 116, 2018, pp. 273-280.
- [4] F. Filippetti, G. Frauceschini, C. Tassoni, and P. vas, "Recent developments of induction motor drives fault diagnosis using AI techniques," *IEEE Trans. on Eney Conversion*, vol. 21, 2006, pp. 1-8.
- [5] T. Khan, P. Alekhya, and J. Seshadrinath, "Incipient inter-turn fault diagnosis in induction motors using CNN and LSTMbased methods," *IEEE Industry Applications Society Annual Meeting, IEEE*, 2018, pp. 1-6.
- [6] M. Skowron, T. Kowalska, M. Wolkiewicz, and C. T. Kowalski, "Convolutional neural network-based stator current data-driven incipient stator fault diagnosis of inverter-fed induction motor,"

Energies, vol. 13, 2020, pp. 1-21.

- [7] P. Chattopadhyay, N. Saha, C. Delpha, and J. Sil, "Deep learning in fault diagnosis of induction motor drives," *Prognostics and System Health Management Conf.*2018, pp. 1068-1073.
- [8] J. H. Han, D. J. Choi, S. K. Hong, and J. S. Kim, "Motor fault diagnosis using CNN based deep learning algorithm considering motor rotating speed," *IEEE 6th Int. Conf. on Industrial Engineering and Applications (ICIEA)*. IEEE, pp. 440-445, 2019.
- [9] Y. J. Goh, G. N. Kim, Y. H. Kim, B. Lee, and K. M. Kim, "Diagnosis Method for Stator-Faults in Induction Motor using Park's Vector Pattern and Convolution Neural Network," *Institute of Korean Electrical and Electronics Engineers*, vol. 24, no. 3, 2020, pp. 883-889.
- [10] S. W. Park and D. Y. Kim, "Comparison of Image Classification Performance by Activation Functions in Convolutional Neural Networks," *Korea Multimedia Society*, vol. 21, no. 10, 2018, pp. 1142-1149.
- [11] Y. J. Goh and K. M. Kim "Inter-turn Short Circuit Diagnosis Using New D-Q Synchronous Min - Max Coordinate System and Linear Discriminant Analysis" *applied science*, vol. 24, no. 3, Mar. 2020, pp. 추가해주세요.

저자 소개



김경민(Kyoung-Min Kim)

1988년 고려대학교 전기공학과 졸업(공학사)
 1991년 고려대학교 대학원 전기공학과 졸업(공학석사)
 1996년 고려대학교 대학원 전기공학과 졸업 (공학박사)

1997년 ~ 현재 전남대학교 교수



김용현(Yong-Hyeon Kim)

2018년 전남대학교 전기및반도체공학과 졸업 (공학사)
 2020년 전남대학교 대학원 전기및반도체공학과 졸업 (공학석사)



박근호(Guen-Ho Park)

2021년 전남대학교 전기및반도체공학과 졸업 (공학사)
 2021~현재 전남대학교 대학원 전기및반도체공학과



이범(Lee Buhm)

1981년 고려대학교 전기공학과 졸업(공학사)
 1989년 고려대학교 대학원 전기공학과 졸업(공학석사)
 1995년 고려대학교 대학원 전기공학과 졸업 (공학박사)

1995년 ~ 현재 전남대학교 교수



이상로(Sang-Ro Lee)

1932년 고려대학교 금속공학과 졸업(공학사)
 1994년 고려대학교 대학원 금속공학과 졸업(공학석사)
 1996년 목포대학교 대학원 신소재공학과 졸업 (공학박사)

2019년 ~ 현재 ㈜더블유피 이사



고영진(Yeong-Jin Goh)

2008년 전남대학교 전기및반도체공학과 졸업 (공학사)
 2010년 전남대학교 대학원 전기및반도체공학과 졸업(공학석사)
 2016년 전남대학교 대학원 전기및반도체공학과 졸업 (공학석사)

2020.09~ 동명대학교 교수