

Park's Vector 패턴과 CNN을 이용한 유도전동기 고정자 고장진단방법

Diagnosis Method for Stator-Faults in Induction Motor using Park's Vector Pattern and Convolution Neural Network

고 영 진*, 김 귀 남**, 김 용 현***, 이 범***, 김, 경 민****★

Yeong-Jin Goh*, Gwi-Nam Kim**, YongHyeon Kim***, Buhm Lee*** and Kyoung-Min Kim****★

Abstract

In this paper, we propose a method to use PV(Park's Vector) pattern for inductive motor stator fault diagnosis using CNN(Convolution Neural Network). The conventional CNN based fault diagnosis method was performed by imaging three-phase currents, but this method was troublesome to perform normalization by artificially setting the starting point and phase of current. However, when using PV pattern, the problem of normalization could be solved because the 3-phase current shows a certain circular pattern. In addition, the proposed method is proved to be superior in the accuracy of CNN by 18.18[%] compared to the previous current data image due to the autonomic normalization.

요 약

본 논문에서는 CNN(Convolution Neural Network)을 이용한 유도전동기 고정자 고장진단에 PV(Park's Vector)패턴을 특징으로 활용하는 방법을 제안하였다. 기존의 CNN을 이용한 유도전동기 고장진단 방법은 3상 전류를 이미지화하여 진단을 수행하였으나, 이 방법은 인위적으로 전류의 시작점, 위상 등을 맞춰 정규화를 수행해야하는 번거로움이 존재하나, PV패턴을 이용할 경우 일정 원의 패턴을 나타내기 때문에 정규화의 문제를 해결 할 수 있었다. 또한 PV패턴을 이용할 경우, 특징벡터가 자동적으로 정규화됨에 따라 기존의 전류데이터를 이미지화한 결과보다 CNN의 정확도 측면에서 18.18[%] 우수함을 실험을 통해 확인할 수 있었다.

Key words : 3-Phase Induction Motor, Fault Diagnosis, ITSC, CNN, PVA

* Dept. of Electrical Engineering, Tongmyong University

** Dept. of Mechanical and Automotive Engineering,
Suncheon Jeil College

*** Dept. of Electrical and Semiconductor Engineering,
Chonnam National University

★ Corresponding author

E-mail : kkm@jnu.ac.kr, Tel : +82-61-659-7316

※ Acknowledgment: This research was supported by the Technology development Program of MSS [S2635396](Research Village, 2018), [S2682436] and the Ministry of Trade, Industry & Energy (MOTIE) [P0006665].

Manuscript received Sep. 14, 2020; revised Sep. 25, 2020; accepted Sep. 25, 2020.

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.

1. 서론

유도전동기의 고장은 크게 기계적 결함과 전기적 결함요소로 나뉘며, 기계적 결함은 통상 베어링, 회전자바 고장을 나타내며, 전기적 고장은 고정자고장을 나타낸다[1]. 고장빈도는 기계적 결함이 많으나, 상시 점검이 잘 이뤄지는 부분이며, 고장진단 시스템 측면에서도 DFT를 이용한 측대파 알고리즘이 구축되어 있어 고장진단에 유용하게 활용되고 있다[2].

하지만, 전기적 결함은 점검과정에서 육안으로 확인이 어려워 시스템적 측면으로 의존해야하나 시스템적 측면에서 진단이 이뤄질 시 미세한 결함을 검

출하는데 어려움이 따른다. 이에 많은 연구들에서는 이를 ITSC(Inter Turn Short Circuit)이라 정의하여 이를 진단하는데 연구를 진행하고 있다[3].

ITSC를 진단하기 위해 전기적 요소임에 따라 MCSA(Motor Current Signal Analysis)를 이용하여 주로 연구가 되고 있으며, DFT, 역상성분분석, 고조파분석 등 복잡한 해석으로 접근을 하여 진단 도구로 활용하였으나, 진단방법이 복잡해짐에 따라 이를 간소화하기 위해 PVA(Park's Vector Approach)를 이용하여 단순화하도록 하고 있다. 그럼에도 불구하고 실질적인 ITSC를 진단하는데는 어려움이 따른다[4].

최근에는 이를 진단하고자 ANN(Artificial Neural Network), CNN(Convolution Neural Network) SVM (Support Vector Machine), Perceptron 등과 같이 AI기술이 적용되어 진단도구로 활용되고 있다[5]. 이러한 진단기술은 고정자 결함진단에 긍정적인 발전을 이루었으며 그 성능이 입증되었다[6]. 또한, 최근 Deep Learning기술을 기반으로 한 데이터 기반 접근 방식은 기존의 결함진단방식과 비교하여 ITSC검출에 강점을 보였으며, 이를 통해 Deep Learning의 고장진단 방법이 방대한 데이터를 이용할 경우 강력한 성능을 보임을 확인하였다.

[7]의 논문에서는 전동기의 접촉식 진동센서를 이용하여 CNN을 적용하여 turn-to-phase진단을 하였으나 ITSC에 접근하지 못하였으며, [8]에서는 1차원상의 전류값을 취한 후 CNN방식을 이용하여 각 고장(베어링, 회전자, 고정자고장)을 분류하도록 하였으나 ITSC진단에 적용되지 못하였다. 이에 [9]에서는 3상 전류를 2차원 행렬화하여 CNN을 적용하여 ITSC 진단을 실시하였다.

한편, CNN을 적용하기 위해서는 이미지에 대해 정규화(normalization)할 필요가 있으며 정규화를 할 경우 쉽고 빠르게 최적화 고장진단을 수행할 수 있다. 하지만 기존의 연구들에서 수행된 3상 전류를 2차원 행렬화하여 이미지화시킬 경우 3상 전류의 시작 포인트, 위상차 등을 자동적으로 설정되지 않고 임의로 설정해야하는 번거로움이 존재한다[10]. 또한, 다양한 노이즈가 발생함에 따라 정규화된 이미지도 불규칙성을 띄게 된다.

이에 본 논문에서는 CNN 알고리즘을 적용하는데 있어서 3상 전류성분의 정보를 유지한 채, 정규화 과정의 문제를 해결하기 위해 PV(Park's Vector)

패턴을 적용하였으며, 기존의 전류 데이터를 이미징화한 CNN 방법과 비교함으로써 효율성을 입증하도록 하였다.

II. 실험 및 측정환경

1. 고정자 고장조건

본 연구의 고정자 권선은 인위적으로 턴 간 단락을 구성하였으며 그림 1과 같이 고정자 한 상에 권선을 외부 탭에 연결하였다.




Fig. 1. External tab of the turn short circuit motor.
그림 1. 외부 탭을 이용한 턴 단락을 위한 결선

그림 1에서 확인할 수 있듯이 구성된 턴 단락 외부 탭의 연결을 1번과 3번 탭을 연결하였을 경우, 고정자내 권선 중 인접한 두 개의 권선만이 단락된 것을 나타내며, 이 상태를 2턴 단락 또는 ITSC라고 한다. 이 때 5번 탭에 결선을 추가할 경우 총 4개의 권선이 단락되며, 이를 4턴 단락이라고 한다. 다음 표 1은 각 턴 단락별 결선 번호이며 이를 통하여 정상상태 및 고장상태에 대한 고정자 턴 단락 조건을 구성하였다.

Table 1. Line number of each turn short paragraph.

표 1. 각 턴단락별 결선번호

No.	1-3	3-5	5-7	7-9	9-11
Turn Short	2(ITSC)	4	6	8	12

2. 측정환경조건

3상 유도전동기의 전류 측정은 그림 2와 같이 인버터와 유도 전동기 1[HP]를 이용하였으며, 사용된 유도전동기의 스펙은 다음 표 2와 같다.

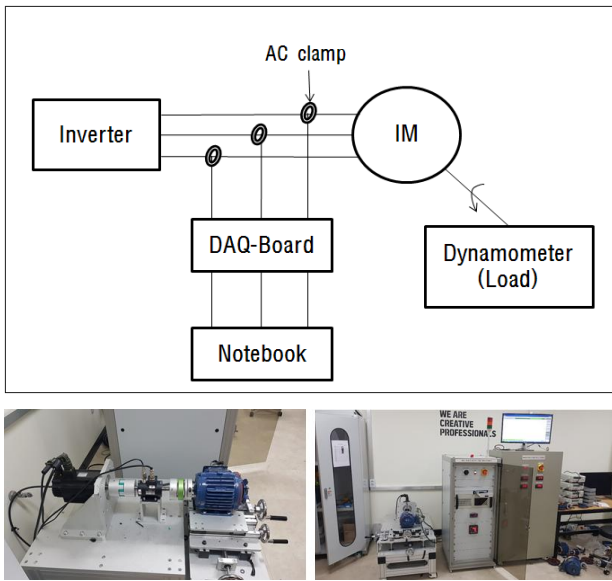


Fig. 2. Experimental device configuration.
그림 2. 실험장치 구성

Table 2. Motor specifications.

표 2. 모터 사양

Description	Value
Power	0.75 [kW] (1[HP])
Input Voltage	220[V]/380[V]
Full Load Current	3.8[A]/2.2[A]
Supply Frequency	60[Hz]
Number of Pole	4
Number of Rotor Slot	44
Number of Rotor Slot	36
Full Load Torque	0.43[kg·m]
Rated Speed	1690[rpm]

데이터 수집은 Fluke사 i5s AC current clamp를 이용하여 National Instruments의 USB-DAQ 9215A with BNC로 데이터수집으로 사용하였으며, 전부 하속도 1690[rpm]에서 무부하 속도1800[rpm]까지 각 30초 동안 측정하였다. 데이터 측정에 있어서 샘플링 속도는 10[Ks/s], 샘플링 수는 10[Ks], 샘플링 주기를 1[s]로 하였다.

3. 노이즈 필터링

3상 유도전동기의 전원 전류 신호는 맥동상태에 따라 60[Hz]의 전원 신호 외에 노이즈 성분이 포함되어 있다. 이러한 노이즈 성분은 인버터를 이용하여 유도전동기를 운전할 때에 더욱 크게 나타난다.

따라서 유도전동기 권선 단락 고장 진단에서는 전원 전류 신호에 노이즈가 포함되어 있을 경우를 고려하여야 한다.

이에 본 논문에서는 Low-pass filter 중 무한임펄스응답(IIR)필터를 적용하여 버터워즈 3차로 컷오프 주파수 100[Hz]를 적용하여 노이즈를 제거해 주도록 하였다.

다음 그림 3은 출력된 3상의 전류값에 대하여 필터링 전과 후의 모습을 비교한 그래프이다. (a)의 경우 필터링이 되지 않은 3상 전류파형이며, (b)의 경우 필터링이 된 3상 전류 파형을 나타낸다.




Fig. 3. Filtering process for noise input power:
(a) before filtering and (b)after filtering.

그림 3. 필터링 적용: (a)필터링 적용전 (b)필터링 적용후

III. PV 패턴 추출

Park's Vector Approach는 1928년 R. H. Park's에 의해 처음 제안되었으며, 기본 아이디어는 3상유도전동기의 고정자권선의 접속방법에서 일반적으로 중성점을 사용하지 않는다는 점에 있다. 이에 Y결선을 가진 유도전동기의 경우 고정자전류는 영상 성분이 존재하지 않는다는 점을 시작으로 연구가 진행되었다[11].

Park's Vector는 3상 전류의 변수(I_A, I_B, I_C)로부터 I_d 와 I_q 로 변환하는 식을 다음과 같이 간단하게 정리가능하다.

$$I_d = \sqrt{\frac{2}{3}} I_A - \sqrt{\frac{1}{6}} I_B - \sqrt{\frac{1}{6}} I_C \quad (1)$$

$$I_q = \sqrt{\frac{1}{2}} I_B - \sqrt{\frac{1}{2}} I_C \quad (2)$$

이때, 주파수와 진폭이 일치하고 각각 정확하게 120° 의 위상차를 갖는 이상적인 전류 신호의 PVA 결과는 식 (3), (4)와 같다.

$$I_d = \left(\frac{\sqrt{6}}{2}\right) i_M \sin(\omega t) \quad (3)$$

$$I_q = \left(\frac{\sqrt{6}}{2}\right) i_M \sin\left(\omega t - \frac{\pi}{2}\right) \quad (4)$$

여기서, i_M 은 공급 전류의 피크값[A], ω 는 공급 각 주파수 [rad/s], t 는 시간 변수 [s]이다.

정상상태 전동기의 경우 완벽한 대칭 전압이 공급되며, 이 원의 궤적의 크기는 $(\sqrt{6}/2)i_M$ 이고, 궤적의 회전 주기는 ω 이다.

전동기의 공급전류에는 단지 정상성분만을 포함하게 되면서 그림 4의 좌측 그림과 같이 PV(Park's Vector) 패턴으로 나타낼 수 있다.




Fig. 4. Pattern of Park's Vector.
그림 4. Park's Vector의 패턴

정상적인 정상 AC 전동기의 경우 완벽한 대칭 전압이 공급되므로 전동기의 고정자 권선 전류 역시 위 조건과 같은 이상적인 전류 신호가 공급될 것이다. 따라서 이상적인 AC 전동기에 i_M 의 피크를 갖는 60[Hz]의 3상 전류신호(i_A, i_B, i_C)가 입력된다면, 궤적의 크기가 $(\sqrt{6}/2)i_M$ 인 그림 4의 실선과 같은 정원의 궤적이 120π [rad/s]의 속도로 그려질 것이다.

만약 고장상태가 발생할 경우, 전동기의 공급전류에는 역상 성분이 합쳐져 그림 4의 우측과 같이 원의 모양이 타원과 같이 표현된다.

이처럼 페이저 공간의 표기는 유도전동기의 단면에 위치하고 복소평면 상 3상에 임의의 순서 값으로 변환되어 복소평면에서 페이저 공간은 3상 공급 시스템의 각 주파수와 동일한 각속도로 회전한다는 원리로 PVA는 구성되어 있다.

IV. CNN 적용

1. 3상 전류 행렬화 이미지 추출




Fig. 5. Current matrix image by turn short.
그림 5. 턴 단락별 전류 행렬화 이미지

전류행렬화 이미지는 [9]의 논문에서 제안한 CNN 이미지 수집 방식을 이용하여, 임의의 시작 포인트를 A상의 시작점이 '0'인 점에서 설정해주도록 하여 이미지를 정규화시키도록 하였으며 3상 전류의 값에 대하여 각 상별로 1초 동안 수집한 데이터(90,000개 *3상)를 90*100행렬로 변환시켜 각 상에 대하여 R, G, B로 나타내었으며, 그림 5와 같이 64*64의 이미지로 축소시켜 주도록 하였다.

2. PV패턴 이미지 추출

앞 절에서 언급한 PVA를 이용하여 PV패턴을 이미지화하였으며, 전류 행렬화 이미지와 같이 동일시하기 위해 64*64의 이미지로 변환시켜주도록 하였다. 또한, 다양한 턴단락의 조건을 만들어주기 위해 그림 6과 같이 각 턴 단락별로 추출하였다. 그림

에서 확인할 수 있듯이 정상상태와 2턴 단락간의 차이는 거의 보이지 않으며 4턴 단락에서부터 조금씩 일그러짐을 확인할 수 있었다.

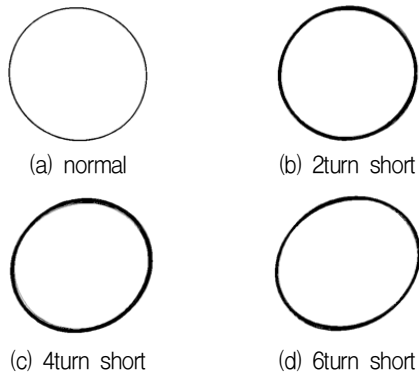


Fig. 6. Current matrix image by turn short.
그림 6. 턴 단락별 전류 행렬화 이미지

3. CNN 파라미터 선정

Deep Learning과 같은 알고리즘의 구성은 적합하게 동작하더라도 만족스럽지 못한 성능이 나오는 경우가 많다. 알고리즘에 대하여 어떠한 점이 문제인지를 파악하고 이를 해결하기 위해서는 실험을 통한 경험적 데이터를 통하여 알고리즘을 평가하고 그 파라미터를 수정하여 좋은 알고리즘을 얻는 것이 중요하다[12, 13].

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(Train data)는 1,080개, 테스트데이터(Test data)로 구분하였다. 또한 학습데이터 내부의 검증용을 위하여 전체 훈련데이터 중 검증데이터(Validation data)

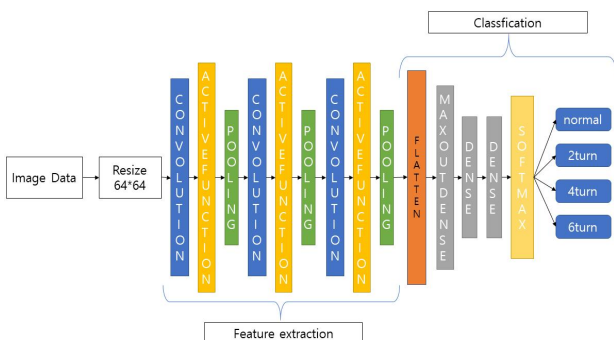


Fig. 7. Current matrix image by turn short.
그림 7. 턴 단락별 전류 행렬화 이미지


360개를 따로 구성하여 학습을 진행하였다. 즉, 전체 데이터 중 75%를 학습데이터, 테스트데이터는 25% 비율로 하였으며, 학습데이터 75% 중 25%를 검증 데이터로 활용하였다.

추출된 이미지는 그림 7과 같이 Convolution과 Pooling, Drop out을 반복하며 Fully Connected Layer을 통해 1차원 배열로 변환된 후 Dense와 Softmax 과정(Classification)을 거쳐 각 고장상황에 대하여 턴 단락 구분이 진행된다.


Convolution의 경우 3*3*64의 필터를 사용하였으며, 활성화 함수는 ReLu(Rectified Linear Unit)를 사용하였다. Pooling은 MaxPooling기법이며, Classification층의 Dense의 은닉층은 64-64-64로 3개의 층을 사용하였다.

4. CNN 적용 결과

다음 그림 8은 ReLu함수를 적용하여 훈련 횟수에 따른 오차율을 나타내고 있다.



(a) PV pattern image's error rate



(b) Current matrix image's error rate

Fig. 8. Error Rate according to epochs applied with ReLu.
그림 8. ReLu 함수 적용시 훈련횟수에 따른 오차율

그림 8의 (a)는 PV 패턴을 이미지화하여 ReLu함수를 적용한 오차감소율을 나타내며, 그림 8의 (b)는 전류를 2차원 이미지화하여 ReLu함수를 적용한 오차감소율을 나타내고 있다. 두 그림에서 알 수 있듯이 PV패턴의 이미지화한 특징을 활용할 경우, 빠른 오차율 감소가 됨을 알 수 있다.

다음 표 3은 CNN의 ReLu 함수를 이용하여 적용한 결과를 나타낸다.

Table 3. ReLu based fault classification accuracy.

표 3. ReLu 함수를 이용한 고장분류 정확도

	PV패턴 이미지[%]	전류 행렬화 이미지[%]
정상(normal)	80.92	100
2턴 단락(2turn fault)	76.55	50.61
4턴 단락(4turn fault)	75.78	61.25
6턴 단락(6turn fault)	100	98.02
전체 정확도(Accuracy)	99.41	81.23

전체적인 정확도에 있어서 PV패턴을 이미지화하여 특징으로 활용할 경우 전류 행렬화를 이미지화한 데이터보다 정확도에 있어서 18.18[%] 우수한 성능을 보였으며, 각 고장 상태별에서도 우수한 성능이 나타남을 알 수 있다.

V. 결론

본 논문에서는 최근 AI기술을 통한 다양한 진단이 적용됨에 따라 유도전동기의 고장자 고장진단을 위한 효율적인 방법을 제시하였다.

AI 기술 중, CNN을 이용한 방법은 2차원 데이터의 입력이 용이하고 훈련이 용이하며, 적은 매개변수라는 장점이 있어 최근 많은 연구가 진행되고 있다. 이러한 이유로 유도전동기 고장진단에 있어서 다양한 특징(전류, 진동, 소음 등)을 이미지화하여 적용하는 기술이 연구되고 있다.

하지만, CNN을 이용한 유도전동기 고장진단에 있어서 이미지의 정규화과정을 임의로 설정해야하는 번거로움이 있다.

이에 본 논문에서는 3상 전류성분의 데이터를 PV패턴으로 나타내어 자동적으로 정규화가 이뤄지도록 하였으며, 특정 패턴으로 정규화된 이미지로 인해 기존의 방법보다 18.18[%] 높은 정확도가 나타남을 실험을 통해 확인 할 수 있었다.

References

[1] Y.-J. Goh and O. Kim, "Linear Method for Diagnosis of Inter-Turn Short Circuits in 3-Phase

Induction Motors," *Applied Sciences*, vol.9, no.22, pp.4822, 2019. DOI: 10.3390/app9224822

[2] C. Yang, "Electrical monitoring for reliable detection of stator core lamination and rotor faults diagnosis in 3-phase induction motor," Doctor thesis, Korea University, 2019.

[3] Y. Chen, X. Zhao, Y. Yang and Y. Shi "Online Diagnosis of Inter-turn Short Circuit for Dual-Redundancy Permanent Magnet Synchronous Motor Based on Reactive Power Difference," *Energies*, vol.12, no.3, pp.510, 2019. DOI: 10.3390/en12030510

[4] 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 Sciences*, vol.10. no.6, pp.1996, 2020. DOI: 10.3390/app10061996

[5] 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, pp.2105, 2019. DOI: 10.3390/en12112105

[6] F. Filippetti, G. Frauceschini, C. Tassoni, and P. Vas, "Recent developments of induction motor drives fault diagnosis using AI techniques," *IEEE Trans. on Energy Conversion*, vol.19, no.4, pp. 1108-1116, 2004. DOI: 10.1109/41.873207

[7] 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," *2019 IEEE 6th International Conference on Industrial Engineering and Applications (ICIEA)*, pp.440-445, 2019. DOI: 10.1109/IEA.2019.8714900

[8] P. Chattopadhyay, N. Saha, C. Delpha and J. Sil, "Deep learning in fault diagnosis of induction motor drives," in *Proc. of the 2018 Prognostics and System Health Management Conference* pp. 1068-1073, 2018. DOI: 10.1109/PHM-Chongqing.2018.00189

[9] 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, no.6, pp.1475, 2020.

DOI: 10.3390/en13061475

[10] B.-S. Jeon, D.-J. Lee, S.-H. Lee, J.-W. Ryu and M.-G. Chun, "Fault Diagnosis of Induction Motor by Fusion Algorithm based on PCA and IDA," *Journal of the Korean Institute of Illuminating and Electrical Installation Engineers*, vol.19, no.2, pp.152-159, 2005.

<http://dx.doi.org/10.5207/JIEIE.2005.19.2.152>

[11] A. J. M. Cardoso, S. M. A. Cruz and D. S. B. Fonseca, "Inter-Turn Stator Winding Fault Diagnosis in Three-Phase Induction motors, by Park's Vector Approach," *IEEE Trans. Energy Convers*, vol.14, no.x, pp.595-598, 1999.

DOI: 10.1109/IEMDC.1997.604083

[12] D.-W. Kim, J.-W. Seok, and K.-S. Bae "Target/non-target classification using active sonar spectrogram image and CNN," *Institute of Korean Electrical and Electronics Engineers*, vol.22, no.4, pp. 044-1049, 2018.

DOI: 10.9717/kmms.2018.21.9.1062

[13] H. N. Nguyen and C. Lee, "Effects of Hyper-parameters and Dataset on CNN Training," *Institute of Korean Electrical and Electronics Engineers*, vol.22, no.1, pp.14-20, 2018.

DOI: 10.7471/ikeee.2018.22.1.14

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.

2015~2020.08 : Professor, Suncheon Jeil College.

2020.09~present : Professor, Tongmyong University

Gwi-Nam Kim (Member)



2011 : BS degree in Energy and mechanical engineering, Gyeongsang National University.

2017 : PhD degree in Energy and mechanical engineering, Gyeongsang National University.

2018.03~present : Professor, Suncheon Jeil College

YongHyeon Kim (Member)



2018 : BS degree in Electrical and Semiconductor Engineering, Chonnam National University.

2020 : MS degree in Electrical and Semiconductor Engineering, Chonnam National University.

Buhm Lee (Member)



1981 : BS degree in Electrical Engineering, Korea University.

1989 : MS degree in Electrical Engineering, Korea University.

1995 : PhD degree in Electrical Engineering, Korea University.

1995~present : Professor, Chonnam National University

Kyung-Min Kim (Member)



1988 : BS degree in Electrical Engineering, Korea University.

1991 : MS degree in Electrical Engineering, Korea University.

1996 : PhD degree in Electrical Engineering, Korea University.

1997~present : Professor, Chonnam National University