

## 장단기 메모리를 이용한 노인 낙상감지시스템의 정규화에 대한 연구

정승수<sup>1</sup> · 김남호<sup>2</sup> · 유윤섭<sup>3\*</sup>

### Study of regularization of long short-term memory(LSTM) for fall detection system of the elderly

Seung Su Jeong<sup>1</sup> · Namg Ho Kim<sup>2</sup> · Yun Seop Yu<sup>3\*</sup>

<sup>1</sup>Undergraduate student, Department of Electrical, Electronic, and Control Eng., Hankyong National University, Anseong, 17579 Korea

<sup>2</sup>Assistance Professor, Convergence Technology Campus of Korea Polytechnic, Sengnam, 13590 Korea

<sup>3\*</sup>Professor, ICT&Robotics Eng. and IITC, Hankyong National University, Anseong, 17579 Korea

#### 요 약

본 논문에서는 고령자의 낙상상황을 감지할 수 있는 텐서플로우 장단기 메모리 기반 낙상감지 시스템의 정규화에 대하여 소개한다. 낙상감지는 고령자의 몸에 부착한 3축 가속도 센서 데이터를 사용하며, 총 7가지의 행동 패턴들에 대하여 학습하며, 각각 4가지는 일상생활에서 일어나는 패턴이고, 나머지 3가지는 낙상에 대한 패턴이다. 학습시에는 손실함수(loss function)를 효과적으로 줄이기 위하여 정규화 과정을 진행하며, 정규화 과정은 데이터에 대하여 최대최소 정규화, 손실함수에 대하여 L2 정규화 과정을 진행한다. 3축 가속도 센서를 이용하여 구한 다양한 파라미터에 대하여 정규화 과정의 최적의 조건을 제시한다. 낙상 검출율면에서 SVM을 이용하고 정규화 127과 정규화율  $\lambda$  0.00015일 때 Sensitivity 98.4%, Specificity 94.8%, Accuracy 96.9%로 가장 좋은 모습을 보였다.

#### ABSTRACT

In this paper, we introduce a regularization of long short-term memory (LSTM) based fall detection system using TensorFlow that can detect falls that can occur in the elderly. Fall detection uses data from a 3-axis acceleration sensor attached to the body of an elderly person and learns about a total of 7 behavior patterns, each of which is a pattern that occurs in daily life, and the remaining 3 are patterns for falls. During training, a normalization process is performed to effectively reduce the loss function, and the normalization performs a maximum-minimum normalization for data and a L2 regularization for the loss function. The optimal regularization conditions of LSTM using several falling parameters obtained from the 3-axis accelerometer is explained. When normalization and regularization rate  $\lambda$  for sum vector magnitude (SVM) are 127 and 0.00015, respectively, the best sensitivity, specificity, and accuracy are 98.4, 94.8, and 96.9%, respectively.

**키워드** : 텐서플로우, 낙상 감지, 노령층, 장단기 메모리

**Keywords** : Tensorflow, Fall detection, The elderly, Long short-term memory(LSTM)

Received 20 August 2021, Revised 9 September 2021, Accepted 12 September 2021

\* Corresponding Author Yun Seop Yu(E-mail: ysyu@hknu.ac.kr, Tel:+82-31-670-5293)

Professor, Department of Electrical, Electronic, and Control Eng., Hankyong National University, Anseong, 17579 Korea

Open Access <http://doi.org/10.6109/jkiice.2021.25.11.1649>

print ISSN: 2234-4772 online ISSN: 2288-4165

© 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.  
Copyright © The Korea Institute of Information and Communication Engineering.

## I. 서 론

고령화 사회에 진입하게 됨으로써 늘어나는 고령층 인구들의 문제들 중 하나인 무릎관절증을 비롯하여 여러 가지 노인성 질환들로 인한 낙상 문제가 화두가 되고 있다. 이러한 낙상 문제로 인하여 노인들의 일상생활에서 여러 가지 문제가 일어날 수 있는데 그중 타박상이나 골절 심하면 뇌출혈 등으로 사망에 이를 수도 있게 된다. 이러한 문제를 빠르게 인지하고 조치를 취하고자 낙상 관련 문제에 관한 연구들도 활발히 진행되고 있고 [1], 이러한 낙상관련 문제를 빠르게 탐지하기 위해 스마트폰을 이용한 시스템도 연구되고 있다[2]. 기존의 연구들 중에 3축 가속도 센서를 이용하여 진행된 임계값 방식의 낙상감지 시스템[3-4]은 전력 소모에 관련되어 장점이 있지만, 정확성이 떨어지고 데이터의 세부적인 패턴에 대한 정확한 판별이 떨어진다는 단점이 있다. 이 단점을 보완하기 위하여 데이터 패턴을 학습할 수 있는 LSTM(long short-term memory)을 기반한 딥러닝을 이용한 낙상감지시스템이 발표되었다[5]. LSTM은 단순한 인공 신경망 모델과는 다르게 과거의 이벤트가 미래의 결과에 영향을 줄 수 있는 순환 구조(directed cycle)를 가지고 있기 때문에 번역, 음성인식, 추가예측 등 다양한 분야에서 활용되고 있다[6-8]. 이런 딥러닝을 이용한 시스템은 데이터를 이용하여 세부적인 행동패턴을 인지하고 예측할 수 있으며, 비슷한 패턴의 데이터를 구별하는데 강점을 가진다.

LSTM 기반의 낙상감지시스템은 3축 가속도 센서를 이용하여 SVM(Sum Vector Magnitude)와 같이 파라미터화해서 정규화(normalization) 과정[9]을 거치고, 그 후에 LSTM에 적용하여 학습을 진행하게 된다. 여기서 LSTM의 손실함수(loss function)를 더 효과적으로 떨어트려서 학습의 효율을 높이기 위해서 L2 정규화(regularization)과정[10]을 진행한다. 그리고 이러한 L2 정규화 과정은 학습이 진행될수록 역전파시에 학습능률이 저하되는 vanishing gradient 문제[11]를 해결하기 위해 사용되기 때문에 시스템과 잘 작용가능한 정규화 과정을 찾아내야 한다. 지금까지는 LSTM 기반의 낙상감지시스템에서 정규화에 대한 연구 결과가 발표되지 않았다.

본 논문은 3축 가속도 센서를 이용하여 측정된 데이터를 파라미터화한 가공 데이터를 LSTM을 이용하여

학습할 때, 정규화 과정의 최적 조건을 찾는 방법을 기술한다. 또한, 다양한 정규화 조건에 따라서 낙상과 일상생활의 정확성을 판별해서 최적의 정규화 조건을 제시한다. II장은 LSTM 기반의 낙상감지시스템에 대해서 간략히 설명한다. III장은 다양한 정규화 조건에 따른 낙상검출 결과를 비교해서 최적의 조건을 설명하고, IV장에서 결론을 제시한다.

## II. 낙상감지 시스템

### 2.1. 낙상감지 시스템 개요

그림1은 LSTM기반 시스템의 구조도이다.




Fig. 1 Flow chart of fall recognition system

그림 1에서 3축 가속도 센서는 고령자의 몸에 부착되어 실시간으로 벡터값을 출력한다. 3축 가속도 센서는 목걸이 형태로 착용해서 가슴 위치에 있으며, 여러 가지 일상생활 패턴들과 낙상상황에서의 패턴들을 측정한다. 3축 가속도 센서로부터 측정된  $x$ 축,  $y$ 축,  $z$ 축의 고유 벡터인  $A_x$ ,  $A_y$ ,  $A_z$ 를 추출한다. 이 데이터들은 SVM, 각도  $\theta$ , DSVM(differential SVM), GSVM(gravity-weight SVM)과 같은 파라미터는 각각  $A_{SVM}$ ,  $\theta$ ,  $A_{DSVM}$ ,  $A_{GSVM}$ 로 다음 식(1)-(4) 같이 표현되고 계산된다[12].

$$A_{SVM}(i) = \sqrt{A_x^2(t) + A_y^2(i) + A_z^2(i)} \quad (1)$$

$$\theta(i) = \tan^{-1} \left( \frac{\sqrt{A_y^2(i) + A_z^2(i)}}{A_x(i)} \right) \times \frac{180}{\pi} \quad (2)$$

$$A_{DSVM}(i) = \frac{\sqrt{(A_x(i) - A_x(i-1))^2 + (A_y(i) - A_y(i-1))^2 + (A_z(i) - A_z(i-1))^2}}{\quad} \quad (3)$$

$$A_{GSVM}(i) = \frac{\theta(i)}{90} \times A_{SVM}(i) \quad (4)$$

데이터의 행동패턴은 각각 4가지의 일상생활부분 Walking, Lying, Running, Jumping과 3가지의 낙상부분 Fallforward, Fallsideways, Fallbackward로 이루어져 있다. 이들 데이터들을 먼저 학습용과 테스트용으로 8:2의 비율로 Validation을 진행한다. 각각 데이터의 차원을 맞게 배치시키고, 오버플로우 방지와 효과적인 손실함수 수렴을 위해 최대최소 정규화 과정을 진행한다. 그 후로 입력 값에 대하여 라벨링을 one hot encoding 방식 [13]을 이용하여 처리하고, 이를 확인용 데이터로 사용한다. 그리고 처리가 완료된 데이터는 LSTM으로 학습하며, 학습이 완료되면 테스트용 데이터를 이용하여 결과가 산출된다. 산출된 결과는 각각의 정규화 차트에 따라 분류하고 이를 이용하여 비교분석을 진행한다.

### 2.2. LSTM

그림2는 LSTM기반 시스템 구조도[14]이다.




Fig. 2 Structure of the LSTM [14]

RNN(Recurrent Neural Network)은 단순한 인공 신경망 모델과는 다르게 과거의 이벤트가 미래의 결과에 영향을 줄 수 있는 순환 구조를 가지고 있기 때문에 시계열 데이터를 예측할 수 있지만 학습을 거치면 거칠수록 역전파에서 vanishing gradient 문제가 발생한다[11]. LSTM은 그림 2에 보여진 것처럼 RNN의 구조에 cell-state와 input-gate, forget-gate, output-gate를 추가한 구조이다. cell state는 컨베이어 벨트 역할을 해서 state가 꽤 오래 경과하더라도 gradient가 비교적 잘 전파되게 된다[14]. 이러한 구조 덕분에 기존의 RNN에서 일어나는 vanishing gradient 문제를 어느 정도 방지할 수 있게 되었다. 이러한 LSTM에 기반해서 사람의 행동을 감지하는 시스템 [15]을 낙상감지에 적용한다.

### 2.3. 정규화

3축 가속도 센서를 이용하여 추출한 데이터를 이용

하여 파라미터화한 데이터인 SVM을 구하고 손실함수를 최소화하기 위한 정규화 과정을 진행한다. 이 정규화 과정은 데이터부분에서 최대최소(min-max) 정규화과정[8]과 손실함수 부분에서 정규화율(regularization rate;  $\lambda$ )를 이용한 L2정규화 과정이 포함되어 있다[10]. 데이터의 최대최소 정규화 과정에는 7가지의 패턴에 대한 데이터를 오버플로우의 방지와 효과적인 손실함수 수렴을 위해 작은 값으로 만들어준다. 데이터  $x$ 의 최대최소 정규화는 다음 식(5)와 같이 표현된다[9].

$$z = \frac{x - x_{\min}}{x_{\max} - x_{\min}}, \quad (5)$$

여기서  $x_{\min}, x_{\max}$ 는  $x$ 의 최대값과 최소값을 나타낸다. 정규화를 통한 학습효율의 차이를 보기 위하여 255, 127, 1의 세 가지 경우에 대해서 데이터를 정규화한다.

손실함수  $L$ 은 L2정규화를 이용하고, L2정규화의 손실함수  $L_\lambda$ 는 다음 식(6)과 같이 표현된다[16].

$$L_\lambda = \text{Min} [L(W) + \lambda \|W\|_2], \quad (6)$$

여기서  $W, \lambda, \|W\|_2$ 는 각각 가중치, 정규화율, L2 Norm을 나타낸다. 손실함수에서 정규화를 하는 과정은 L1정규화, L2정규화와 같이 여러 가지로 분류할 수 있는데 여기서 사용한 방법은 L2정규화인  $\lambda$  값을 변화시키는 방법을 사용하였다.  $\lambda$ 가 커질수록 모델은 단순해지며 과소적합(underfitting)하게 되고,  $\lambda$ 가 작아질수록 모델은 복잡해지고 과적합(overfitting)하게 된다. 따라서  $\lambda$  값을 잘 조정하여 최적의  $\lambda$ 를 찾아내야한다. 정규화를 통한 학습효율의 차이를 보기 위하여 각각 0.015, 0.0015, 0.00015로 나누어 학습을 진행하였다.

## III. 정규화 결과



### 3.1. 낙상감지 시스템 실험 환경

가속도 센서 데이터는 총 10명에게서 습득하였고, 샘플링 속도는 100Hz의 속도로 샘플링 하였으며, 가속도 센서는 허리에 착용하여 진행하였고, 행동패턴은 총 7가지의 패턴으로 4가지는 일상생활부분, 나머지 3가지는 낙상부분으로 분류하였다[17]. 실험시 낙상부분과 높기를 측정할 때는 매트리스로 넘어지는 동작을 측정하였고, 나머지부분에 대해서는 일반적으로 측정하였

다. 각각의 샘플들은 5초동안의 움직임으로 데이터를 추출하였으며, 8명에게서는 각 행동마다 20개씩 취득하였고, 나머지 2명에게서는 각 행동마다 10개씩 취득하였다. 여기서 걷기부분과 눕기부분에서 누락된 데이터를 각각 1개씩 제외하여 일상부분 638개, 낙상부분 480개를 이용하여 총 1138개를 이용하였다. 취득한 데이터를 이용하여 파라미터화하였다. 딥러닝을 이용한 학습은 아나콘다를 이용한 가상환경에서 파이썬의 텐서플로우를 이용하여 진행하였으며, 각각의 데이터 처리는 파이썬을 이용했다.

### 3.2. 실험 결과

데이터 정규화는 255, 127, 1의 세 가지 경우에 각각  $\lambda$ 는 0.015, 0.0015, 0.00015의 세 가지로 나누어 LSTM으로 학습을 진행한 낙상감지 결과에 대해서 설명한다. 그림 3은 파라미터 SVM을 이용해서 LSTM 정규화의 9가지 경우에 대해서 7가지 행동 패턴을 감지한 정확도의 시각화를 나타낸다. 그림3은 LSTM을 이용하여 나온 결과를 혼돈행렬(confusion matrix)로 나타낸 것이다. 왼쪽 위에서부터 차례대로 Walking, Lying, Running, Jumping, Fallforward, Fallsideways, Fallbackward 순으로 이어지며, 색이 적색일수록 결과가 집중되어 있고, 자색일수록 결과가 비어있는 것으로 그려진다. 표1은 그림 3에 보여진 결과를 요약하여 낙상 및 일상생활에 대하여 각각 판별한 혼돈 행렬과 정확도를 나타낸다. 표1에서  $\lambda$ 가 작을수록 더 좋은 낙상 검출율(specificity) 정확도를 보였다.



**Fig. 3** Visualization of pattern accuracy with 9 types of regularization case. (a) Normalization=1,  $\lambda = 0.0015$ , (b) Normalization=127,  $\lambda = 0.0015$ , (c) Normalization=255,  $\lambda = 0.0015$ , (d) Normalization=1,  $\lambda = 0.00015$ , (e) Normalization=127,  $\lambda = 0.00015$ , (f) Normalization=255,  $\lambda = 0.00015$ , (g) Normalization=1,  $\lambda = 0.015$ , (h) Normalization=127,  $\lambda = 0.015$ , (i) Normalization=255,  $\lambda = 0.015$ .

**Table. 1** Confusion matrix of SVM,  $\theta$ , DSVM, GSVM.

Parameter	Regularization		TP	TN	FP	FN
	Normalization	$\lambda$				
SVM	1	0.00015	114	86	10	13
		0.0015	111	85	11	16
		0.015	105	75	21	22
	127	0.00015	125	91	5	2
		0.0015	106	84	12	21
		0.015	109	13	83	18
	255	0.00015	104	91	5	23
		0.0015	116	90	6	11
		0.015	111	78	18	16

표 2는 파라미터인 SVM,  $\theta$ , DSVM,GSVM을 LSTM의 다양한 정규화와  $\lambda$  값에 대해서 Sensitivity, Specificity, Accuracy 조사한 결과이다. 파라미터 별로 가장 검출율이 좋은 최적의 정규화와  $\lambda$ 를 조사할 때, SVM을 이용하고 Normalization = 127과  $\lambda=0.00015$ 일 때 Sensitivity 98.4%, Specificity 94.8%, Accuracy 96.9%로 가장 좋은 정확도를 보였다.

**Table. 2** Sensitivity, Specificity, and Accuracy of SVM,  $\theta$ , DSVM, GSVM.

Parameter	Regularization		Sensitivity [%]	Specificity [%]	Accuracy [%]
	Normalization	$\lambda$			
SVM	1	0.00015	89.8	89.6	89.7
		0.0015	87.4	88.5	87.9
		0.015	82.7	78.1	80.8
	127	0.00015	98.4	94.8	96.9
		0.0015	83.5	87.5	85.3
		0.015	85.8	13.5	54.8
	255	0.00015	81.9	94.8	87.5
		0.0015	91.3	93.8	92.4
		0.015	87.4	81.3	84.8
$\theta$	1	0.00015	74.8	94.8	83.5
		0.0015	89.8	80.2	85.7
		0.015	92.1	81.3	87.5
	127	0.00015	87.4	76	82.6
		0.0015	91.3	94.8	93.8
		0.015	90.6	81.3	86.6
	255	0.00015	85	78.1	82.1
		0.0015	93.7	86.5	90.6
		0.015	92.1	82.3	87.9
DSVM	1	0.00015	92.9	19.8	61.5
		0.0015	92.1	87.5	90.2
		0.015	90.6	93.8	92
	127	0.00015	71.7	55.2	64.6
		0.0015	85.8	90.6	87.9
		0.015	96.1	93.8	95.1
	255	0.00015	66.9	86.5	75.4
		0.0015	92.1	95.8	93.8
		0.015	76.4	75	75.8
GSVM	1	0.00015	81.1	92.7	86.1
		0.0015	91.3	96.9	93.8
		0.015	91.3	94.8	92.9
	127	0.00015	92.1	87.5	90.2
		0.0015	96.9	78.1	88.8
		0.015	92.9	87.5	90.6
	255	0.00015	78	88.5	82.6
		0.0015	94.5	77.1	87
		0.015	95.3	89.6	92.9

#### IV. 결론

고령자의 낙상을 감지하기 위해서 고령자의 몸에 착용한 3축 가속도 센서 데이터를 이용한 가공한 파라미터 데이터를 LSTM에 적용했다. 가공한 파라미터는 최대최소 정규화를 사용하였고, LSTM 정규화의 손실함수는 L2정규화를 이용하여 이에 따른 기본 학습과 정규화된 학습에 대한 결과를 비교해 보았다. 파라미터 별로 가장 검출율이 좋은 최적의 정규화와  $\lambda$ 를 조사해서 최적의 파라미터를 얻어야 한다. 본 연구에서는 SVM 파라미터에 Normalization = 127과  $\lambda=0.00015$ 을 적용할 때 가장 좋은 일상생활 및 낙상 검출율을 얻었다. 이를 통하여 노인분들의 낙상감지에 대해 더 나은 판별 방법을 고안할 수 있을 것이고, 낙상감지를 보다 더 신속히 판별할 수 있을 것으로 전망된다.

#### ACKNOWLEDGEMENT

This research was supported by the Basic Science Research Program through NRF of Korea funded by the Ministry of Education (NRF-2019R1F1A1060383)

#### REFERENCES


- [ 1 ] Top Ten Reviews for Fall Detection of Seniors. Purch.com [Internet]. Available: <http://www.toptenreviews.com/health/senior-care/best-fall-detection-sensors/>
- [ 2 ] S. S. Khan and J. Hoey, "Review of fall detection techniques: A data availability perspective," *Medical Engineering & Physics*, vol. 39, pp. 12-22, Jan. 2017. DOI: 10.1016/j.medengphy.2016.10.014.
- [ 3 ] S. Khojasteh, J. R. Villar, C. Chira, V. M. González, and E. de la Cal, "Improving fall detection using an on-wrist wearable accelerometer," *Sensors*, vol. 18, no. 5, pp. 1350, Apr. 2018. DOI: 10.3390/s18051350.
- [ 4 ] T. Xu, Y. Zhou, and J. Zhu, "New advances and challenges of fall detection systems: A survey" *Applied Sciences*, vol. 8, no. 3, pp. 418, 2018. DOI: 10.3390/app8030418.
- [ 5 ] H. Li, A. Shrestha, H. Heidari, J. L. Kerneec, and F. Fioranelli, "Bi-LSTM network for multimodal continuous

- human activity recognition and fall detection,” *IEEE Sensors Journal*, vol. 20, no. 3, pp. 1191-1201, 2019.
- [ 6 ] S. Hochreiter and J. Schmidhuber, “Long Short-Term Memory,” *Neural Computation*, vol. 9, no. 8, pp. 1735-1780, Nov. 1997. DOI: 10.1162/neco.1997.9.8.1735.
- [ 7 ] M. Roondiwala, H. Patel, and S. Varma, “Predicting Stock Prices Using LSTM,” *International Journal of Science and Research*, vol. 6, no. 4, pp. 1754-1756, Apr. 2017.
- [ 8 ] T. Hayashi, S. Watanabe, T. Toda, T. Hori, J. L. Roux, and K. Takeda, “Duration-Controlled LSTM for Polyphonic Sound Event Detection,” *IEEE/ACM Trans. Audio Speech Lang. Process.*, vol. 25, no. 11, pp. 2059-2070, 2017. DOI: 10.1109/taslp.2017.2740002.
- [ 9 ] D. Freedman, R. Pisani, and R. Purves, *Statistics : Fourth International Student Edition*, New York, NY: W. W. Norton & Company, 2007.
- [10] Regularization for Simplicity: Lambda, Google Developers, 2020 [Internet]. Available: <https://developers.google.com/machine-learning/crash-course/regularization-for-simplicity/lambda?hl=ko>.
- [11] Vanishing gradient problem, wikipedia [Internet]. Available: [https://en.wikipedia.org/wiki/Vanishing\\_gradient\\_problem](https://en.wikipedia.org/wiki/Vanishing_gradient_problem).
- [12] N. H. Kim and Y. S. Yu, “Fall Recognition Algorithm Using Gravity-Weighted 3-Axis Accelerometer Data,” *Journal of the Institute of Electronics and Information Engineers*, vol. 50, no. 6, pp. 254-259, Jun. 2013.
- [13] M. K. Dahouda and I. Joe, “A Deep-Learned Embedding Technique for Categorical Features Encoding,” *IEEE Access*, vol. 9, pp. 1, 2021. DOI: 10.1109/access.2021.3104357.
- [14] K. Li, X. Zhao, J. Bian, and M. Tan, “Sequential learning for multimodal 3D human activity recognition with Long-Short Term Memory,” in *Proceeding of 2017 IEEE International Conference on Mechatronics and Automation (ICMA)*, pp. 1556-1561, 2017. DOI: 10.1109/icma.2017.8016048.
- [15] LSTMs for Human Activity Recognition, github 2020 [Internet]. Available: <https://github.com/guillaume-chevalier/LSTM-Human-Activity-Recognition>.
- [16] T. V. Laarhoven, “L2 regularization versus batch and weight normalization,” arXiv:1706.05350v1, 2017.
- [17] D. Lim, C. Park, N. H. Kim, S. H. Kim, and Y. S. Yu, “Fall-Detection Algorithm Using 3-Axis Acceleration: Combination with Simple Threshold and Hidden Markov Model,” *Journal of Applied Mathematics*, vol. 2014, pp. 8, 2014. DOI: 10.1155/2014/896030.



**정승수(Seung Su Jeong)**

2015년 3월 - 현재 한경대학교 전기전자제어공학과 재학  
 ※ 관심분야 : 기계학습, 딥러닝, 고령친화 IT 기술



**김남호 (Nam Ho Kim)**

1996년 2월 고려대학교 전자공학과 (공학사)  
 1998년 2월 고려대학교 일반대학원 전자공학과 (공학석사)  
 2013년 2월 한경대학교 바이오정보기술전문대학원 신호처리전공 (공학박사)  
 2015년 8월 - 현재 한국폴리텍대학교 분당융합기술교육원 임베디드시스템학과 조교수  
 ※ 관심분야 : 임베디드시스템, 신호처리, 기계학습, 딥러닝, 고령친화 IT 기술



**유윤섭(Yun Seop Yu)**

1995년 8월 고려대학교 전자공학과 (공학사)  
 1997년 8월 고려대학교 일반대학원 전자공학과 (공학석사)  
 2001년 8월 고려대학교 일반대학원 전자공학과 (공학박사)  
 2001년 9월 - 2002년 9월 미국 NIST 초청연구원  
 2014년 1월 - 2015년 7월 Georgia Institute of Technology Visiting Scholar  
 2002년 10월 - 현재 한경대학교 전기전자제어공학과 교수  
 ※ 관심분야 : 반도체 소자 및 회로 설계, 고령친화 IT 기술