

손가락 움직임 인식을 위한 웨어러블 디바이스 설계 및 ML 기법별 성능 분석⁺

(Design and Performance Analysis of ML Techniques for Finger Motion Recognition)

정 우 순¹⁾, 이 형 규^{2)*}

(Woosoon Jung and Hyung Gyu Lee)

요 약 손가락 움직임 인식을 통한 제어는 직관적인 인간-컴퓨터 상호작용 방법의 하나이다. 본 연구에서는 여러 가지 ML (Machine learning) 기법을 사용하여 효율적인 손가락 움직임 인식을 위한 웨어러블 디바이스를 구현한다. 움직임 인식을 위한 시계열 데이터 분석에 전통적으로 사용되어 온 HMM (Hidden markov model) 및 DTW (Dynamic time warping) 기법뿐만 아니라 NN (Neural network) 기법을 적용하여 손가락 움직임 인식의 효율성 및 정확성을 비교하고 분석한다. 제안된 시스템의 경우, 경량화된 ML 모델을 설계하기 위해 각 ML 기법에 대해 최적화된 전처리 프로세스를 적용한다. 실험 결과, 최적화된 NN, HMM 및 DTW 기반 손가락 움직임 인식시스템은 각각 99.1%, 96.6%, 95.9%의 정확도를 제공한다.

핵심주제어: 동작 인식, 플렉스 센서, 휨 센서, 뉴럴 네트워크, 은닉마르코프 모델, 동적시간위핑, 시계열 데이터

Abstract Recognizing finger movements have been used as a intuitive way of human-computer interaction. In this study, we implement an wearable device for finger motion recognition and evaluate the accuracy of several ML (Machine learning) techniques. Not only HMM (Hidden markov model) and DTW (Dynamic time warping) techniques that have been traditionally used as time series data analysis, but also NN (Neural network) technique are applied to compare and analyze the accuracy of each technique. In order to minimize the computational requirement, we also apply the pre-processing to each ML techniques. Our extensive evaluations demonstrate that the NN-based gesture recognition system achieves 99.1% recognition accuracy while the HMM and DTW achieve 96.6% and 95.9% recognition accuracy, respectively.

Keywords: Gesture recognition, Flex (bend) sensor, Neural network, HMM, DTW, Time series classification (TSC)

* Corresponding Author: hglee@daegu.ac.kr

+ 이 논문은 2015년 대구대학교 학술연구비지원에 의한 논문임
Manuscript received March 20, 2020 / accepted April 22, 2020

1) 대구대학교 대학원 정보통신공학과, 제1저자

2) 대구대학교 ICT융합학부, 교신저자

1. 서 론

손가락은 가장 적은 힘으로도 세밀한 움직임이 가능한 신체 부위로써, 인간-컴퓨터 상호작용 (Human-computer interaction: HCI)의 효과

적인 인터페이스로 활용되어왔다 (Oka et al., 2002; Ren et al., 2011). 손가락 움직임을 인식하는 것은 뇌파, 음성과 마찬가지로 매우 직관적인 소통 수단이 될 수 있으므로 비장애인뿐만 아니라 몸이 불편한 환자 또는 장애인에게 훌륭한 인터페이스(수화)를 제공할 수 있다.

이러한 장점을 바탕으로, 손가락 움직임 인식에 관한 많은 연구가 이루어져 왔다. 손가락 움직임 인식 연구는 카메라를 이용하는 영상/비전 처리 방법과 몸에 부착된 센서를 이용하는 두 가지 형태로 연구가 주로 진행되어왔다. 영상/비전 기반 인식 시스템은 인식대상에 센서를 부착할 필요가 없으므로 사용이 쉽고, 높은 확장성을 제공한다는 장점이 있다. 반면, 단점으로는 피사체와 카메라 사이의 거리, 카메라의 각도 및 해상도에 따라 인식의 정확성이 달라지며, 영상처리의 특성상, 센서 기반의 시스템보다 비교적 많은 컴퓨팅 자원이 요구된다.

이에 반해 부착형의 센서 기반 인식시스템의 경우, 착용의 불편함이 있지만, 다양한 사용 환경 변화에서도 비교적 안정적인 인식성능을 보이면서도, 영상/비전 기반 시스템보다 적은 컴퓨팅 자원으로 구현할 수 있는 장점이 존재한다. 따라서 본 연구에서는 제한된 자원을 사용하는 웨어러블 디바이스에서도 구현 가능한 손가락 움직임 인식 디바이스를 구현하고, 사용된 인식 기법에 따른 정확성 평가를 수행한다.

지난 수십 년간 컴퓨터 기술의 발달과 함께 이론적으로만 연구되던 ML (Machine learning) 기법이 점차 많은 분야에서 실질적으로 사용되기 시작했으며, 특정 분야에서의 분류 성능(정확도 및 시간당 처리량)은 이미 인간의 한계를 뛰어넘고 있다 (Langlotz et al., 2019). 특히 CNN (Convolutional neural network)을 중심으로, 풍부한 데이터셋 (Dataset)과 컴퓨팅 자원을 활용한 NN 아키텍처에 관한 연구가 주를 이루고 있다. 이러한 방식의 연구에서, 모델 크기(입력, 계층의 수, 계층별 노드의 수 등)의 증가와 성능의 향상은 정비례하지 않는 모습을 보이고 있다 (Canziani et al., 2016). 이는 대부분의 경우 미미한 성능 향상을 위해 메모리를 포함하는 막대한 컴퓨팅 자원이 추가로 요구됨을 의미

한다.

최근 모바일 환경에 최적화된 NN 아키텍처를 탐색하기 위한 연구들이 진행되어왔으나 (Tan et al., 2019), 역시 영상/비전 기반 인식 시스템을 구현하기 위하여 스마트폰 수준의 컴퓨팅 자원이 요구된다.

본 연구에서는 고성능 CPU, GPU, 전용 하드웨어 가속기 등의 방대한 컴퓨팅 자원을 사용하는 기존 NN 아키텍처 연구와는 달리, 제한된 컴퓨팅 자원과 메모리를 갖는 웨어러블 디바이스에서의 손가락 움직임 인식 응용을 위해 정확도-컴퓨팅 자원 간 Trade-off 관계를 고려한 경량화된 NN 아키텍처 구조를 탐색한다. 고해상도 이미지 처리와 같이 입력 데이터의 크기가 큰 응용이 아닌 경우, 전통적인 ML 기법들도 여러 분야에 성공적으로 적용되어 왔으므로 (Lee and Kim, 1999; Lichtenauer et al., 2008) 시계열 데이터 분류를 위한 HMM (Hidden markov model)과 DTW (Dynamic time warping) 기법을 적용하여 구현된 시스템과 제안된 NN 기법과의 비교 분석을 진행한다. HMM 및 DTW 기법 역시 정확도-컴퓨팅 자원 간 최적의 Trade-off를 제공하기 위해, 전처리 (Pre-processing)를 통한 최적화 및 모델의 크기에 관한 탐색을 진행한다.

제안된 손가락 움직임 인식 시스템의 성능을 검증하기 위해 미국의 수화 표준인 ASL (American sign language)에 정의된 알파벳 중 7가지에 대응하는 동작을 사용한다. ASL은 표준화된 규격이기에 객관적인 성능평가 지표로 활용될 수 있으며, 제안된 시스템을 통해 청각 장애인과의 의사소통에 큰 기여를 할 수 있을 것으로 기대된다.

2. 손가락 움직임 인식 시스템 구성

2.1 플렉스 센서 기반 웨어러블 디바이스

본 연구에서는 데이터 수집을 위하여 다섯 개의 플렉스 센서가 부착된 장갑 형태의 웨어러블 디바이스를 구현하여 각 ML 기법별 학습 및 평

가를 진행한다. 플렉스 센서는 휘어짐의 정도에 따라 저항이 변하는 일종의 가변 저항으로, ADC (Analog to digital converter) 채널을 통해 웨어러블 디바이스의 제어기로 입력된다.

2.2 ML 모델 적용을 위한 데이터 처리

한 번에 처리될 입력 데이터의 수는 ML 모델에서의 차원의 수를 의미한다. 이는 폭발적인 연산량 증가를 야기할 수 있으므로, 입력 데이터는 ML 모델에 적용되기 전, 전처리 단계를 통하여 정확도의 손실이 크게 일어나지 않는 범위 내에서 입력되는 데이터의 수 및 변화량을 감소시키는 것이 효과적이다. 이에 본 연구에서는 센서의 표본화 주기 및 손가락의 움직임 속도를 고려하여, 10개 단위의 데이터를 수집한 후, 이를 평균하여 하나의 값만 ML 모델의 입력으로 보내는 방식의 다운샘플링 (Down sampling)을 적용하였다.

메모리 사용량 및 연산 복잡도 감소를 위해 데이터 양자화 (Quantization)를 전처리 단계에 포함하여 설계하였다. 특히 HMM 방법은 유한 상태 모델에 기반을 두므로, HMM의 상태 수를

줄이는 것이 모델의 경량화에 유리하다. 이에 본 연구에서는 Fig. 1와 같이 1,024 단계 (10bit) 해상도를 갖는 ADC 데이터를 양자화를 통해 6단계 해상도를 갖는 값으로 변환하여 ML 모델의 입력으로 사용한다.

3. 시계열 데이터 분류를 위한 전통적 ML 기법

손가락 움직임은 시간에 따라 변화하는 시계열 데이터이므로, 시계열 데이터의 분류를 위해 사용되어온 전통적인 기법인 HMM과 DTW 모델을 적용하였다. 데이터 입력부터 ML 모델 적용까지의 전체 프로세스는 Fig. 2와 같다.

3.1 HMM (Hidden Markov Model)

시간의 흐름은 뒤로 진행할 수 없으므로 단방향 진행만 허용되는 좌우모델로 HMM을 설계하였다. HMM의 주 요소는 관측상태(O)와 은닉상태(S)로 구성되어있다. Fig. 3와 같이 본 연구에서 적용된 HMM의 관측상태(O)는 ‘전처리된




Fig. 1 Pre-processing of Raw Data




Fig. 3 Example of Left-to-right Model (left) & HMM Applied in the Application (right)

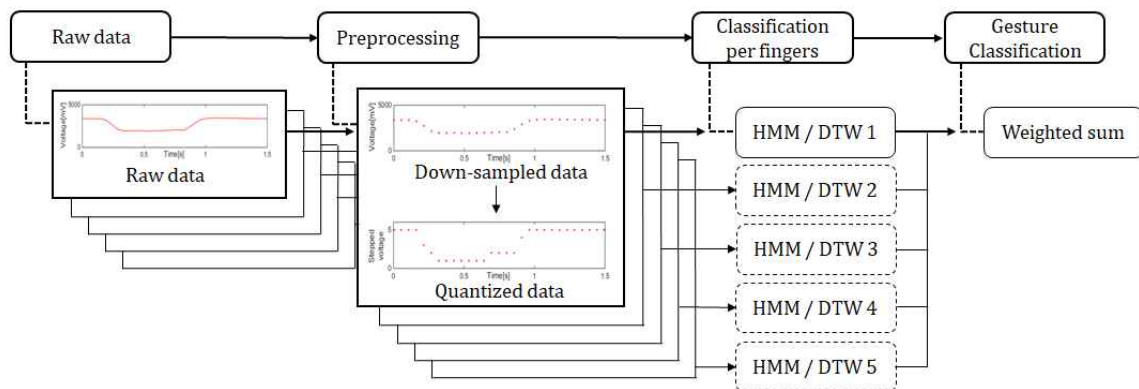


Fig. 2 System Integration Model

ADC 데이터(플렉스 센서의 저항)를 의미하며, 은닉 상태(S)는 ‘관측상태(O)를 몇 단계로 군집화할 수 있는가’를 의미한다.

HMM의 성능에 영향을 끼치는 주된 요소는 은닉상태 수라고 볼 수 있다. 반복적인 실험을 통하여 본 응용에서의 최적의 은닉상태 수는 5로 결정되었다. 은닉상태 수가 5를 초과하는 경우, 정확도의 향상 없이 모델의 복잡도만 증가시켜 계산 복잡도의 증가만 일으키는 것을 확인하였다.

3.2 DTW (Dynamic Time Warping) 기반 손가락 움직임 인식

DTW에서의 학습은 다수의 데이터셋의 정보를 반영하는 하나의 대표 템플릿 (Template)을 생성하는 것으로 진행된다. 본 연구에서는 대표 템플릿을 생성하는 방법으로 Petitjean et al. (2011)이 제안한 DBA (DTW barycenter averaging) 알고리즘을 적용하였다. 평가 과정은 DBA 알고리즘으로 생성된 대표 템플릿과 입력 데이터의 유사도를 계산하는 것으로 진행된다. Fig. 4는 DBA 알고리즘을 적용하여 여러 개의 학습 표본을 바탕으로 생성된 대표 템플릿을 나타낸다.




Fig. 4 Example of Training Samples (left) & Representative Template Generated by the DBA Algorithm (right)

3.3 가중합 방법을 이용한 분류

손 전체의 움직임을 인식하기 위해서는 다섯 손가락의 움직임을 모두 분석해야 한다. Fig. 2에 나타난 프로세스와 같이 해당 시스템은 모든 손동작에 해당하는 각 손가락 별 가능성(Likelihood)를 출력하고, 이를 종합적으로 판단하여 손 전체 움직임을 추론해야 한다. 이러한

종합적인 판단 과정에서 손가락 별 최대 가능성(Maximum likelihood)를 모두 균등하게 고려하는 방법으로 추론할 경우 문제가 발생한다.

예를 들어, Fig. 5와 같이 ‘D’와 ‘V’에 해당하는 동작의 경우, 두 동작의 유일한 차이점은 중지 손가락이며, 나머지 손가락들의 동작은 실질적으로 같은 동작이다. 따라서 나머지 손가락들에 대해서도 최대 가능성을 균등하게 생각하여 추론한다면, ‘D’를 ‘V’로, ‘V’를 ‘D’로 추론하는 경우가 발생한다. 이러한 경우로 인한 정확도 저하를 막기 위해, 본 연구에서는 가중합 (Weighted sum) 방법을 이용하여 최종 추론을 진행한다. 제안된 방법은 임계값 (Threshold) 이상의 가능성을 갖는 동작들은 높은 크기의 가중치를 할당하고, 나머지 경우에는 가중치를 0으로 할당한다. 사용되는 임계값은 여러 번의 실험을 통해 얻어진 최대 가능성도의 표준편차에 비례하여 결정하였다. 최종적으로 모든 손가락의 출력(가능도×가중치)을 더하여 가장 큰 값을 갖게 되는 동작을 최종 인식되는 동작으로 결정하게 된다.




Fig. 5 Alphabets ‘D’ and ‘V’ as Defined in ASL (American Sign Language)

4. 신경망 회로 기반 데이터 분류 기법

4.1 NN (Neural Network) 모델 설정

본 연구의 주목적은 제한된 컴퓨팅 환경(웨어러블 디바이스)에 적용 가능한 ML 시스템을 구현하여 손가락 움직임을 인식하는 것이다. 손가락 움직임의 경우 동작 범위가 넓지 않으며, 뇌파 및 근전도 신호 등에 비해 민감하지 않으므로, 다른 기법에 비해 간단한 구조를 갖는 인공신경망 기법인 FNN (Feedforward neural network)을 적용한다 (Schmidhuber, 2015).

길이가 서로 다른 데이터를 입력으로 하는 HMM과 DTW 기법과는 달리, FNN으로의 적용을 위해서는 입력 데이터의 길이가 고정되어야 한다. 이에 본 연구에서는 데이터의 다운샘플링이 일어나는 전처리 과정에서 동작 당 고정된 수의 데이터를 출력하는 수정된 기능의 다운샘플링을 구현하였다. 실제 FNN의 입력으로 전달되는 데이터의 수는 기존의 HMM과 DTW와의 비교 형평성을 고려하여, HMM과 DTW방법에서 관측된 평균 데이터 수와 동일한 12로 설정하였다. 따라서 NN 입력층의 총 노드 수는 다섯 손가락을 모두 고려해야 하므로, 12×5 로 결정하여 실험을 진행하였다. 분류하고자 하는 ASL 알파벳은 총 7가지이므로, Fig. 6에서 보는 것과 같이 입력 층의 노드 수는 60개, 출력층의 노드 수는 7개로 결정된다.




Fig. 6 Architecture of the Recognition System using NN and Flex Sensors

4.2 경량화를 위한 최적 NN 아키텍처 탐색

입력과 출력계층의 노드 수는 실험환경에 따라 결정되는 반면, 은닉계층에 대한 설정(은닉 계층 수 및 계층별 노드의 수)은 컴퓨팅/메모리 자원 요구량과 정확도에 대한 분석이 필요하다. 이에 주어진 컴퓨팅 자원의 사용을 최소화하면서도 일정 수준 이상의 정확도를 보장받기 위해 최적의 은닉계층 및 노드 수를 탐색하는 실험을 진행하였다. 모든 실험에 대한 하이퍼 파라미터인 학습률 (Learning rate), 반복수 (Epoch), 배치 크기 (Batch size)는 각각 0.0075, 1,000, 1로 설정되었으며, 활성화 함수로는 ReLu (Rectified linear unit) 함수를 적용한다. 이에 대한 구조탐색 결과는 Table 1과 같으며, $60 \times 20 \times 7$ 의 구조가

최대한의 정확도를 갖는 동시에 가장 경량화될 수 있는 구조로 나타난다.

Table 1 Performance by NN Architectures

Layer dimensions	Accuracy (%)	# of Hidden Layers	#of Nodes in Hidden Layer
$60 \times 40 \times 7$	99	1	40
$60 \times 20 \times 7$	99	1	20
$60 \times 14 \times 7$	73	1	14
$60 \times 7 \times 7 \times 7$	58	2	14
$60 \times 10 \times 7$	70	1	10
$60 \times 5 \times 5 \times 7$	57	2	10

해당 실험 결과, 단 하나의 은닉계층을 갖는 구조로도 충분한 성능을 보이는 것을 알 수 있다. 은닉계층의 역할은 비선형 문제의 해결로 알려졌으며, 일반적으로 하나의 은닉계층만으로도 대부분의 비선형 문제가 해결되는 특징이 있기 때문이다 (Shafi et al., 2007).

5. 실험 결과

5.1 실험 환경 및 데이터 수집

Fig. 7과 같이 ATmega328 MCU 기반의 Arduino Uno 보드와 플렉스 센서를 장착에 부착한 형태로 웨어러블 디바이스를 제작하였다. 손가락 전체의 움직임을 인식하기 위하여 한 개의 2.2인치 센서(엄지손가락)와 4개의 4.5인치 센서, 총 5개의 플렉스 센서가 사용되었으며, MCU의 ADC 채널에 연결되어 손가락이 움직인 정도를 측정한다.



Fig. 7 Prototype of Wearable Device

HMM과 DTW 기법의 정확도 평가 수단으로 MATLAB이 사용되었으며, NN 기법의 경우 Pytorch 라이브러리를 사용하여 Google의 Colab 환경에서 NN 모델을 평가하였다.

평가를 위해 정의된 동작은 Fig. 8과 같이 ASL에 대응하는 7가지 알파벳이며, 시작/종료 를 구분 짓기 위한 포즈를 정의하였다. Fig. 9은 해당 포즈를 활용하여 ASL의 알파벳 ‘V’에 대응하는 동작을 입력하는 예를 나타낸다.




Fig. 8 Alphabets in ASL and Gesture Definition to Indicate the Start/end of Gesture




Fig. 9 Example of Continuous Gesture ‘V’

데이터 수집을 위해 제작된 웨어러블 디바이스를 착용 후, 정의된 동작(총 7개 동작)마다 200개의 표본(총 1,400개)을 수집하였다. 수집된 전체 데이터 중 700개의 표본은 제안된 모델들의 학습을 위해, 나머지 700개의 표본은 성능 평가용으로 사용되었다.

5.2 실험 결과 분석

Table 2는 각 사용된 ML 기법별/동작별 실험 결과를 나타내며 NN, HMM, DTW 기법 순으로 각각 99.1, 96.6, 95.9%의 정확도(평균값) 나타낸다. 동작 별 분류의 정확도를 살펴보면, HMM과 DTW 기법에서 동작 ‘C’에 대한 정확도가 유난히 낮은 것을 알 수 있는데, 이는 Fig. 10처럼 정의된 동작 간에 유사한 동작이 존재하여 해당 기법들만으로는 쉽게 구분하지 못하는 것으로 분석된다. DTW 기법의 경우 동작 ‘O’에 대한 인식률이 92%로 동작 ‘C’와의 혼동이 주된 이유로 분

Table 2 Performance of HMM, DTW, AND NN

Gesture	Accuracy (%)		
	HMM	DBA-DTW	NN
A	99	94	99
B	100	99	100
C	90	90	99
D	94	97	99
F	99	100	100
O	97	92	98
V	97	99	99
Average	96.6	95.9	99.1

석된다. 이에 반해 NN 기법은 비교적 작은 크기의 네트워크 모델만으로도 대부분의 동작에 대해 98% 이상의 정확도를 보인다.




Fig. 10 Alphabets ‘C’ and ‘O’ as Defined in ASL (American sign language)

Table 3은 가장 높은 정확도를 갖는 NN 기법에 관한 혼동 행렬 (Confusion matrix)이며, 특정 경우에 편향된 오분류 (Misclassification)를 하지 않는 것을 알 수 있다. 다만 동작 ‘O’의 경우 일부 ‘C’나 ‘A’으로 분류되는 경우가 발생했는데, 이 경우는 학습에 사용되는 데이터셋의 증가를 통해 개선할 수 있을 것으로 기대된다.

Table 3 Confusion Matrix (60×20×7) for NN

Predictions	V	1		1				99
	O							98
	F					100		
	D				99			
	C			99	1		1	1
	B		100					
	A	99						1
		A	B	C	D	F	O	V
		Labels						

5.3 계산/구현 복잡도 분석

본 연구에서 적용된 각 ML 모델은 구현 방식의 차이로 인해 모델별로 적용된 자원의 형태가 상이하므로 각 ML 모델의 직접적인 연산량을 비교하기에는 어려움이 있으나, 이를 간접적으로 비교하기 위해 각 모델의 파라미터 개수(가중치 수)를 분석하여 비교한 결과는 Table 4와 같다.

Table 4 Performance by ML Techniques

ML techniques	HMM	DTW	NN
# of Parameters	1,925	420	1,367
Accuracy(%)	96.6	95.9	99.1

DTW 기법의 경우 NN 기법과 비교했을 때, 약 3.2%의 성능 감소를 보이지만 69.3%의 적은 파라미터 개수를 요구하고 있다.

6. 결론

본 연구에서는 플렉스 센서를 활용한 웨어러블 디바이스 기반의 손가락 움직임 시스템을 구현하고 3가지 ML 기법을 사용하여 손가락의 연속적인 움직임을 분류하였다. 기법별 분류 정확도는 NN, HMM, DTW 기법 순으로 각각 99.1%, 96.6%, 95.9%로 확인되었으며, NN이 가장 높은 정확도를 제공하는 것으로 확인되었다.

손가락 움직임을 인식하는 데 있어서, 비록 NN 기법에 비교하여 정확도가 다소 낮지만, 전통적인 ML 기법인 DTW와 HMM에서도 비교적 잘 작동하는 것을 볼 수 있었다. 특히 DTW의 경우 학습 표본 수가 충분하지 않더라도 양질의 적은 표본으로도 잘 작동한다는 점과 적은 수의 파라미터 사용한다는 점은 제한된 자원을 사용하는 웨어러블 디바이스에 효율적으로 사용할 수 있을 것으로 판단된다.

본 연구의 한계점으로는 ML을 적용하기에 부족한 표본의 확보, 시작/종료 추출 방법의 부재가 있으며, 이를 보완하고 향후 과제로 에너지

소모 분석이 추가된다면 메모리-에너지-성능 측면으로 최적화된 응용을 제공하는데 기여할 수 있을 것으로 보인다.

References

- Canziani, A., Culurciello, E., and Paszke, A. (2016). *An Analysis of Deep Neural Network Models for Practical Applications*, arXiv:1605.07678v4
- Langlotz, C. P., Allen, B., Erickson, B. J., Kalpaphy-Cramer, J., Bigelow, K., Cook, T. S., Flanders, A. E., Lungren, M. P., Mendelson, D. S., Rudie, J. D., Wang, G., and Kandarpa, K. (2019). A Roadmap for Foundational Research on Artificial Intelligence in Medical Imaging: From the 2018 NIH/RSNA/ACR/The Academy Workshop, *Radiology*, 291(3), 781-791. <https://doi.org/10.1148/radiol.2019190613>.
- Lee, H. K., and Kim, J. H. (1999). An HMM-based Threshold Model Approach for Gesture Recognition, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 21(10), 961-973. <https://doi.org/10.1109/34.799904>
- Lichtenauer, J. F., Hendriks, E. A., and Reinders, M. J. T. (2008). Sign Language Recognition by Combining Statistical DTW and Independent Classification, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 30(11), 2040-2046. <https://doi.org/10.1109/TPAMI.2008.123>
- Oka, K., Sato, Y., and Koike, H. (2002). Real-time Fingertip Tracking and Gesture Recognition, *IEEE Computer Graphics and Applications*, 22(6), 64-71. <https://doi.org/10.1109/MCG.2002.1046630>
- Petitjean, F., Ketterlin, A., and Gancarski, P. (2011). A Global Averaging Method for Dynamic Time Warping with Applications to Clustering, *Pattern Recognition*, 44(3), 678-693. <https://doi.org/10.1016/j.patcog.2010.09.013>
- Ren, Z., Meng, J., Yuan, J., and Zhang, Z. (2011). Robust Hand Gesture Recognition with

Kinect Sensor, *MM'11 - Proceedings of the 2011 ACM Multimedia Conference and Co-located Workshops*, 759-760.

<https://doi.org/10.1145/2072298.2072443>.

Schmidhuber, J. (2015). Deep Learning in Neural Networks: An overview, *Neural Networks*, 61, 85-117. <https://doi.org/10.1016/j.neunet.2014.09.003>

Shafi, I., Jamil, A., Shah, S., and Kashif, F. (2007). Impact of Varying Neurons and Hidden Layers in Neural Network Architecture for a Time Frequency Application, *2006 IEEE International Multitopic Conference*, Islamabad, pp. 188-193. <https://doi.org/10.1109/INMIC.2006.358160>

Tan, M., Chen, B., Pang, R., Vasudevan, V., Sandler, M., Howard, A., and Lee, Q. V. (2019) *MnasNet: Platform-Aware Neural Architecture Search for Mobile*, arXiv:1807.11626



정 우 순 (Woosoon Jung)

- 정회원
- 대구대학교 임베디드시스템 공학과 학사
- 대구대학교 정보통신공학과 석사
- 대구대학교 정보통신공학과

박사과정

- 관심분야 : 저전력 시스템 설계, 패턴인식, AI



이 형 규 (Hyung Gyu Lee)

- 정회원
- 서울대학교 전기컴퓨터공학부 석사
- 서울대학교 전기컴퓨터공학부 박사
- 대구대학교 정보통신대학

ICT융합학부 인공지능전공 부교수

- 관심분야 : 저전력 시스템 설계, 에너지 하베스팅, 저전력 메모리