

순환 아키텍처 및 하이퍼파라미터 최적화를 이용한 데이터 기반 군사 동작 판별 알고리즘

김준호

공군사관학교 기계공학과
(7512832@mnd.go.kr)

박재민

공군사관학교 기계공학과
(7512864@mnd.go.kr)

채건주

공군사관학교 기계공학과
(7512972@mnd.go.kr)

박경원

공군사관학교 기계공학과
(kyeongwon.park@alumni.kaist.ac.kr)

군인의 동작 및 운동 상태를 인식하는 기술은 웨어러블 테크놀로지와 인공지능의 결합으로 최근 대두되어 병력 관리의 패러다임을 바꿀 기술로 주목받고 있다. 이때 훈련 상황에서의 평가 및 솔루션 제공, 전투 상황에서의 효율적 모니터링 기능을 의도한대로 제공하기 위해서는 상태 판별의 정확도가 매우 높은 수준으로 유지되어야만 한다. 하지만 입력 데이터가 시계열 또는 시퀀스로 주어지는 경우, 기존의 피드포워드 신경망으로는 분류 성능을 극대화하는데 한계가 발생한다. 전장에서의 군사 동작 인식을 위해 다루지는 인간의 행동양식 데이터(3축 가속도 및 3축 각속도)는 시의존적 특성의 분석이 요구되기 때문에, 본 논문은 순환 신경망인 LSTM(Long-short Term Memory) 네트워크를 활용하여 취득 데이터의 이동 양상 및 순서 의존성을 파악하고 여덟 가지의 대표적 군사 동작(Sitting, Standing, Walking, Running, Ascending, Descending, Low Crawl, High Crawl)을 분류하는 고성능 인공지능 모델을 제안한다. 이때, 학습 조건 및 모델 변수는 그 정확도에 결정적인 영향을 끼치지만 인간의 수동적 조정이 필요해 비용 비효율적이고 최적의 값을 보장하지 못한다. 본 논문은 기계 스스로 일반화 성능이 극대화된 조건들을 취득할 수 있도록 베이지안 최적화를 활용해 하이퍼파라미터를 최적화한다. 그 결과, 최종 아키텍처는 학습 가능한 파라미터의 개수가 유사한 기존의 인공 신경망과 비교해서 오차율이 62.56% 감소할 수 있었으며, 최종적으로 98.39%의 정확도로 군사 동작 인식 기능을 구현할 수 있었다.

주제어 : 딥러닝, 동작 인식, 웨어러블 기기, 순환 신경망, 하이퍼파라미터 최적화.

논문접수일 : 2022년 11월 18일 논문수정일 : 2022년 12월 6일 게재확정일 : 2022년 12월 12일
원고유형 : 학술대회 Fast Track 교신저자 : 박경원

1. 서론

인간과의 상호작용을 토대로 포스트 모바일 시대의 대표적인 주자로 주목받고 있는 웨어러블 기술은 핵심 요소 기술의 조합을 통해 구현되고 있다. 그 중에서도 IMU(Inertia Measurement Unit)는 학계 및 산업계 양쪽에서 지대한 관심을 받고 있는 웨어러블 센서 시스템 중 하나이다.

IMU는 기본적으로 가속도계, 자이로스코프, 그리고 자력계의 조합으로 신체의 힘 또는 각속도를 측정하는 장비이지만, 최근에는 이를 신체에 부착해서 사용자의 행동양식과 연계된 새로운 정보를 취득할 수 있다는 사실이 밝혀지고 있다. 예를 들어 Slade et. al. (2021)은 IMU를 활용해 인간의 산소 소모량을 추정하는 방법론을 제시한 바 있으며 Han et. al. (2019)는 IMU를 통해 실

시간 보행 위상을 검출하는 알고리즘을 제안했다. 그 중에서도 IMU를 활용한 사용자 의도 파악 및 현 상태 판별의 동작 인식(Motion Recognition) 기술은 가장 유망한 응용 사례 중 하나이다(W. Zhuang et. al., 2019).

동작 인식 기술은 군용 어플리케이션으로 확대될 때 그 기대효과가 매우 클 것으로 예상된다(T. Wyss et. al., 2010). 그 초기 연구로 생체 센서를 이용한 군인의 보행 위상 검출 알고리즘이 각 인원의 이동 상태에 대한 기초적인 단서를 제공하기도 하였다(K. Steel et. al., 2015). 이는 보다 실질적인 전장 상황을 가정한 단체 보행(Group Walking)에서의 위상 분석을 가능케 해 개인이 아닌 부대 단위에서의 이동 모니터링 방향을 제시하기도 했다(P. Fernandez-Lopez et. al., 2017). 하지만 이러한 시도들은 군인이 실제로 보행 이외의 더 복잡한 동작을 수행하게 된다는 사실을 간과한다는 한계를 드러내기도 했다. 군인이 주변 환경 및 전장 상황에 맞춰 유동적으로 수행하게 될 동작 상태에 대한 보다 면밀하고도 다층적인 구분은 훈련 상황에서 개별 병력의 수행 상태를 판별, 디브리핑 및 솔루션을 제공하는 데 사용되거나 전투상황에서는 보다 효율적·사실적인 모니터링을 가능케 할 수 있다. 이러한 흐름에 맞춰 Park et. al. (2016)은 IMU를 기반으로 군인의 다양한 동작 중의 입각기를 인식하는 알고리즘을 제안하기도 하였다. 그 긍정적인 방향성에도 불구하고, 이러한 시도들은 분류 방법론으로 다소 고전적이고 비효율적인 모델을 활용한다는 특징이 있다. 최근에는 IMU와 인공 신경망을 융합해서 매우 편리하면서도 강력한 모델을 개발하고자 하는 시도가 활발하다(W. Tao et. al., 2018). 인공 신경망은 강력한 일반화 성능과 더불어 효율적 분류 능력을 제공할 수 있어 그 응

용 가치가 매우 높은 기술로 여겨진다.

이러한 군용 동작 인식 기술에게 기대되는 효과를 온전히 형성하기 위해서는 그 신경망 분류 모델의 정확도가 매우 높은 수준으로 유지되어야 한다. 하지만, 입력 데이터가 시 계열 또는 시퀀스로 주어지는 상황에서는 기존 신경망의 데이터 분류 능력에 구조적인 한계가 발생한다. FCN(Fully Connected Neural Network)은 인공지능 모델의 대표적 구조로서 히든 레이어 및 비선형 활성화 함수를 통해 두 데이터 사이의 복잡한 상관관계를 파악하는 데 탁월한 성능을 보였지만(김유영 등, 2016; Muratore et. al., 2022), 시퀀스 인풋에 대해서는 LSTM(Long-short Term Memory)과 같은 순환 신경망이 더욱 효과적인 기능을 제공하는 것으로 알려져 있다(Odhiambo et. al., 2022; 안성만 등, 2017; 최지혜 등, 2020). 군용 웨어러블 데이터에 순환 신경망이 적용된다면 그 값을 더욱 면밀하게 분석하고 활용할 수 있게 될 것이다.

본 논문에서는, LSTM 및 하이퍼 파라미터 최적화를 이용한 초고성능 데이터 기반 군사 동작 판별 모델이 소개된다. 우리가 다루고자 하는 데이터는 군인이 발목에 IMU를 착용한 상태에서 대표적인 군사 동작을 수행하여 측정된 3축 가속도 및 3축 각속도 데이터이다. IMU를 통해 취득하는 이러한 동적 데이터는 그 자체로는 의미가 없고, 동작 중 신체 좌표의 실시간 조정을 통해 사용자 스스로 형성하는 다이내믹스의 분석이 있어야만 유의미한 정보를 찾아낼 수 있다. 각 동작 중 짧은 시간 동안 누적된 가속도 및 각속도의 변화양상을 분석하여 활용하기 위해 LSTM을 적용한다.

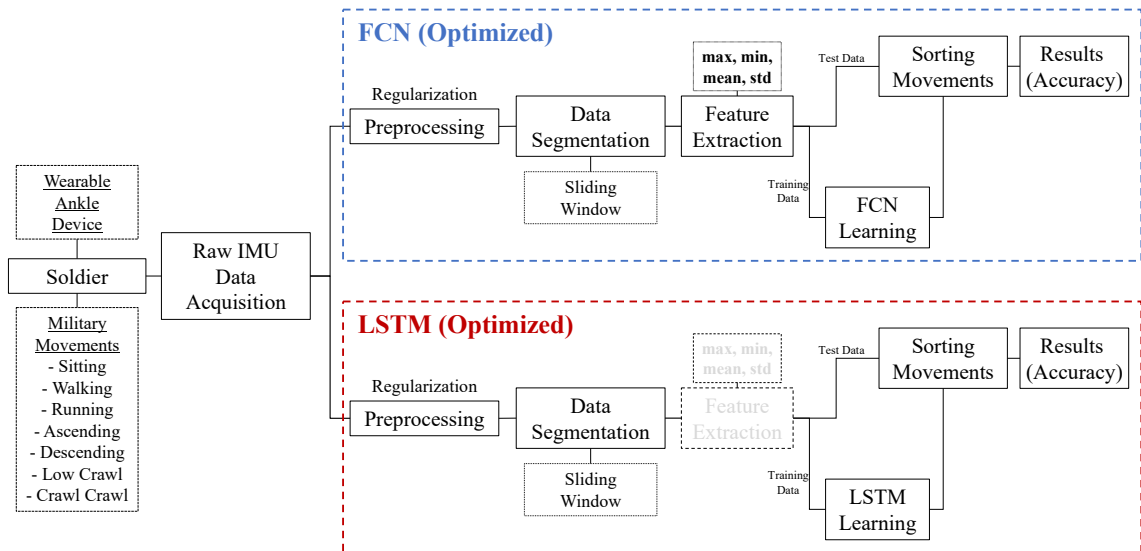
이때, 학습 조건 및 모델 변수를 어떠한 값으로 설정해야 제안된 모델이 최적의 성능을 나타

널 지는 여전히 알 수 없다. 사람이 개입하는 튜닝 과정은 시간 비효율적이고 최적의 값을 보장하지 못한다. 이러한 불확실성이 개입되는 수동 튜닝 방식 대신 우리는 베이지안 최적화 방법(최진탁 등, 2022)을 적용하여 사전 정보를 최적값 탐색에 활용하고 가장 효율적인 형태로 LSTM 모델의 하이퍼파라미터를 탐색하고자 한다. 최종적으로, 본 논문은 FCN과 LSTM을 비교하여 여덟 가지 대표적인 군사 동작(Sitting, Standing, Walking, Running, Ascending, Descending, Low Crawl, High Crawl)을 분류하는 최선의 모델이 무엇인지 밝혀내 관련 인공지능 기술의 새로운 방향성을 제시한다. 군사 동작은 일반 상황에서의 동작과 달리 보다 복잡적이고도 이질적인 행동 양식에 대한 분석을 요구하므로, 웨어러블 센서 및 데이터 기반 학습 기법을 활용한 기타 운동 분석에 대한 연구에도 큰 기여를 할 수 있을 것으로 기대된다.

2. 연구 개요 : Opt-FCN 및 Opt-LSTM의 활용


그림 1은 이번 논문에서 소개하는 연구 내용의 개요를 블록 다이어그램으로 나타낸다. 본 연구는 IMU 기반 발목형 웨어러블 디바이스로부터 사전에 측정된 x, y, z축 가속도 및 x, y, z축 각속도 데이터를 활용한다. 총 여덟 가지 동작에 대해 약 10,000개의 동작 데이터를 취득했고, 이번 연구에서는 각 동작 상태를 판별하는 최적의 분류 알고리즘이 무엇인지 탐색하는 과정에 초점이 맞춰진다. 각 방법론의 네트워크 구성 및 학습 조건은 최적화 과정을 거쳐 결정되므로, 평시의 네트워크와 구분하기 위해 Opt-FCN (Optimized FCN) 및 Opt-LSTM (Optimized LSTM)으로 표기한다.

각 알고리즘의 진행 순서는 다음과 같다. 먼저 측정 데이터는 전처리 과정(Preprocessing)으로서



〈그림 1〉 전체 시스템의 블록 다이어그램

각 채널별 평균 및 표준편차에 맞춰 정규화된다(Regularization). 이후, 정규화된 데이터 셋은 길이가 10으로 설정된 슬라이딩 윈도우(Sliding Window)에 의해 나뉜다(Data Segmentation). 그림 2는 IMU로부터 측정된 로우 데이터(Raw Data)를 슬라이딩 윈도우로 잘라내 학습이 가능한 형태로 가공한 모습을 나타낸다(Feature 1~6: x, y, z축 가속도 및 x, y, z축 각속도).



〈그림 2〉 인풋 데이터: 정규화된 x, y, z축 가속도 및 x, y, z축 각속도

슬라이딩 윈도우의 길이를 이와 같이 설정하게 된 요인은 다음과 같다. 학습될 인풋 데이터의 길이가 길수록 일반적으로 더 많은 정보를 네트워크에 전달할 수 있다. 하지만, 이는 알고리즘의 반응성(Responsiveness)을 저하하여 판별 간격이 늦어지는 결과를 초래한다. 군용 동작 인식 기술의 기대 효과를 고려하여, 정보량 및 반응성이라는 두 특성을 적절히 중재하기 위한 수단으로 약 1초간의 판별 간격을 선택하게 되었다(IMU의 샘플링 주기: 125ms).


슬라이딩된 데이터 셋은 이후 Opt-FCN 및

Opt-LSTM 각각의 학습 과정에 활용되고 시험 상황에서의 정확도를 비교하여 더 나은 판별 알고리즘이 결정된다. 학습 시 FCN 및 LSTM 사이의 가장 주요한 차이는 인간이 개입되는 정도의 차이이다. FCN은 시 계열 데이터를 직접적으로 다루는 데 구조적인 한계가 있기 때문에 대표적인 그래프 특성을 추출하는 별도의 과정이 알고리즘에 요구된다. 반면 LSTM은 자동적으로 시의존적 특성을 분석하고 이를 각 가중치에 반영할 수 있으므로 특성 추출 단계가 별도로 요구되지 않는다. 각 방법론에 대한 설명은 아래에서 상세히 다뤄진다.


3. 인공지능을 활용한 군사 동작 인식 알고리즘

3.1. FCN 기반 군사 동작 인식 알고리즘

그림 3은 본 논문에서 제안된 FCN 기반 군사 동작 인식 알고리즘을 나타낸다. 총 6개의 물리량(3축 가속도 및 3축 각속도)이 각 동작 중 변화하는 양상을 분석하기 위해, 인풋 레이어(Input Layer)는 슬라이딩된 훈련 데이터의 그래프 특성을 먼저 추출한다. 본 논문에서는 그 특성으로 가장 대표적인 경향성 지표 네 가지를 선택했다(최댓값(Max), 최솟값(Min), 평균(Mean), 표준 편차(SD)). 각 특성은 그래프의 변이 양상이 어떻게 설정되어 있는지 효과적으로 드러낼 수 있는 지표가 된다. 6개 데이터 채널에 대한 추출 과정을 거쳐 얻어진 총 24개의 인풋 노드(X_1, X_2, \dots, X_{24})는 히든 레이어(Hidden Layer)를 통한 가중치 연산 및 활성화함수를 거쳐 최종적으로 각 동작 클래스에 속하게 될 확률(Y_1, Y_2, \dots, Y_8)으로 변환된



〈그림 3〉 FCN을 활용한 군사 동작 인식 알고리즘



〈그림 4〉 RNN의 구조

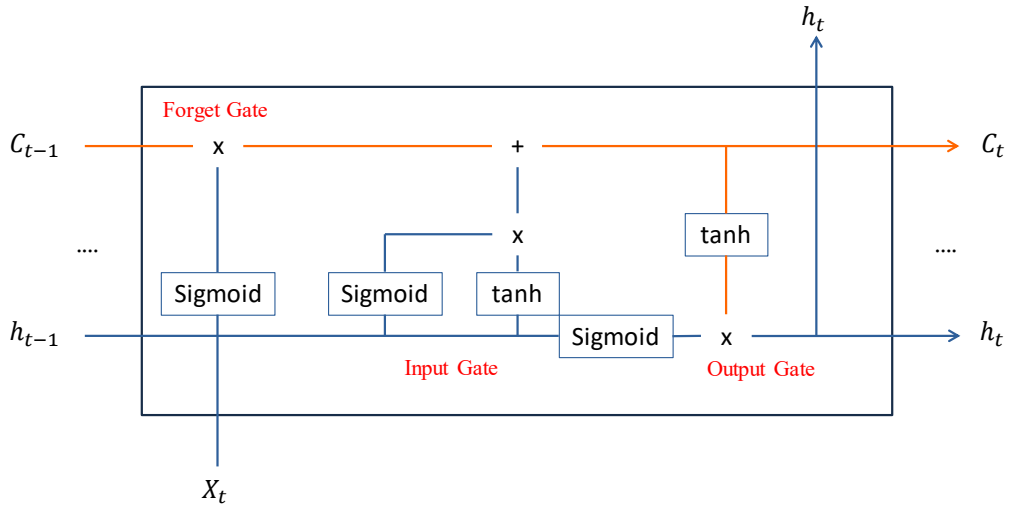
다. 이때 각 확률은 교차 엔트로피 오차(Cross Entropy Loss)를 통해 네트워크 학습의 진행 정도를 평가하는 데 사용된다. 여기서 그래프 특성을 선정하는 과정에 있어 인간의 조정이 개입되었다. 이는 개별적인 데이터 값을 인풋으로 써야 하는 FCN 프레임워크의 특성에 의해 발생했다.

3.2. LSTM 기반 군사 동작 인식 알고리즘

그림 4는 순환 아키텍처의 가장 초기 형태인 순환 신경망(Recurrent Neural Network, RNN)의 구조를 나타낸다. 같은 형태의 셀이 인풋 데이터의 각 순서에 맞게 차례로 적용되고, 내부적으로

새로운 상태인 히든 스테이트(Hidden State)가 공유되며 시퀀스 데이터의 순서 의존성을 학습하는 개념이다. 인풋 데이터(X_1, X_2, \dots, X_T)의 길이는 슬라이딩 윈도우의 크기 T 와 동일하고, 이는 곧 순환 아키텍처 내 셀의 개수와도 일치한다.

하지만, 최근 응용 연구에서는 RNN을 사용하는 사례가 극히 드물다. 그 이유는 장기 의존성(Long Dependency) 문제라고 정의된 RNN의 기울기 소실 문제 때문이다. 시퀀스의 크기에 따라 학습이 원활하게 진행되지 않는 경우를 방지하기 위해, 최근에는 LSTM이 순환 아키텍처의 대표 명사로서 활용되고 있다(안성만 등, 2017; 최지혜 등, 2020).



〈그림 5〉 LSTM 셀의 구조

그림 5는 임의의 시점 t 에 대한 LSTM 셀의 내부 구조를 나타내고 있다. 장기의존성 문제를 보완하기 위해 히든 스테이트(h_t)에 더불어 셀 스테이트(C_t)를 정의하고, 게이트(Forget Gate, Input Gate, Output Gate)라는 단계적 과정을 추가했다 (Yong Yu et. al., 2019). 셀 스테이트는 각 게이트와 상호적으로 작동하며 시 계열 데이터 내 과거 정보를 얼마나 지우고 현재의 정보를 얼마나 기억할 지를 결정한다. 즉, LSTM은 셀 스테이트를 통해 전체 타임 스텝 내 종합적인 정보를 기억할 수 있게 된다. 이러한 LSTM의 장점을 바탕으로 본 논문에서는 순환 아키텍처로서 LSTM을 선택, 기계 스스로 인풋 데이터의 이동 양상을 추적할 수 있도록 유도하였다.

3.3. 베이지안 최적화를 이용한 학습 모델 최적화

각 네트워크의 기대 효과에도 불구하고 그 학습 결과는 학습 조건 및 모델 내부 변수 등의 하

이퍼파라미터에 의해 달라질 수 있다. 따라서 어떤 파라미터 설정이 인풋 데이터에 맞게 시스템을 구조화하여 최고의 결과를 이끌어낼 수 있을지 탐색해볼 필요가 있다. 본 논문에서는, 최적의 하이퍼파라미터 조합을 찾아 네트워크의 분류 능력을 극대화하기 위해 베이지안 최적화 기법을 활용한다. 베이지안 최적화는 Surrogate Model 및 Acquisition Function의 조합으로 제일 유용하다고 판단되는 하이퍼파라미터의 집합을 가장 효율적인 방식으로 찾아내는 서치 방식이다 (최진탁 등, 2022). 본 연구에서는 목적 함수로 정확도가 채택되었다.

4. 실험 결과

4.1. 실험 조건

본 연구는 공군 항공우주의료원 기관 생명 윤리위원회 승인(ASMC-22-IRB-008)을 받아 진행

되었다. LSTM의 학습조건(초기 학습률, 최대 에포치 수, 미니배치 사이즈 등) 및 모델 구성 변수(히든 유닛의 개수)는 조정이 가능한 하이퍼파라미터로 최적의 학습 결과를 유도하기 위해 최적화된다. 이때, 학습가능한 파라미터의 개수는 딥러닝 모델의 복잡도(Complexity)를 결정하는 요소로 학습 결과의 분포를 나타내는 편향(Bias) 및 분산(Variance)과 매우 큰 상관관계가 있다. 따라서, LSTM과 FCN의 원활한 비교·분석이 가능하게끔 학습가능한 파라미터의 개수를 두 모델 간 통제변인으로 설정하였다. 두 경우 모두 훈련 데이터는 정규화된다. 시험 데이터는 임의의 시험 상황을 가정하기 위해 훈련 데이터의 평균 및 표준편차에 대해 정규화되었다. 모든 학습 과정에서 Adam Optimizer가 공통적으로 활용되었고 과적합 방지를 위해 조기 종료(Early Stopping, Patience value: 20)를 설정했다.

4.2. 하이퍼파라미터 최적화 및 딥러닝 모델 학습


표 1은 베이지안 최적화로 얻어진 Opt-LSTM 모델의 파라미터들을 요약해서 나타내고 있다. 표 2는 베이지안 최적화로 얻어진 Opt-FCN 모델의 파라미터들을 요약한다. 각 하이퍼파라미터를 활용하여 학습한 결과는 아래와 같이 나타난다.

〈표 1〉 LSTM 최적화의 결과


Network	Data Type	Optimizer	Number of Hidden Units
LSTM	Sequence	Adam	78
Initial Learning Rate	Minibatch Size	Max. Epochs	Patience Value
0.0041	34	44	20

〈표 2〉 FCN 최적화의 결과

Network	Data Type	Optimizer	Number of Hidden Layers
FCN	Feature	Adam	2
Initial Learning Rate	Minibatch Size	Max. Epochs	Number of Hidden Nodes
0.0052	34	49	149



〈그림 6〉 두 딥러닝 모델의 학습 결과: 손실함수(교차 엔트로피 오차)



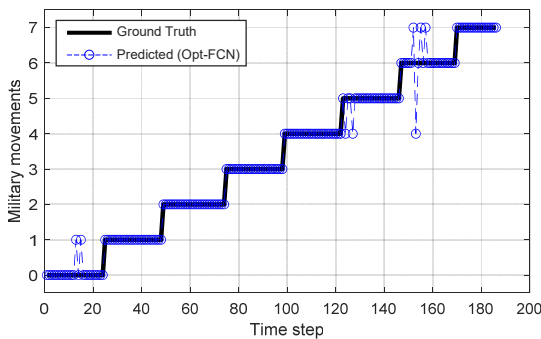
〈그림 7〉 두 딥러닝 모델의 학습 결과: 분류 정확도

그림 6은 Opt-FCN과 Opt-LSTM의 학습 시간이 경과함에 따라 손실 함수가 감소하는 양상을 비교하고 있다. Opt-FCN의 경우 100회 이전의 타임 스텝까지는 매우 급격하게 분류 오차를 줄여

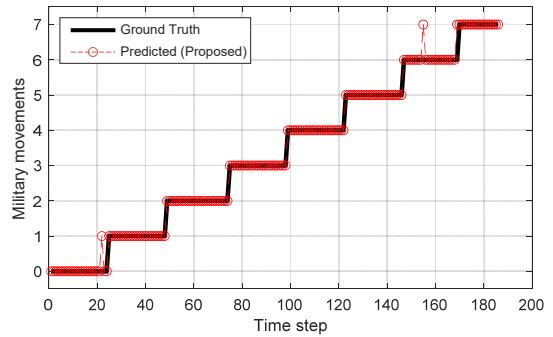
나갈 수 있었지만, 학습이 경과되는 300~600회 사이의 스텝에서 학습 오차가 다시 늘어나는 양상을 보였다. 이는 기존에 학습된 가중치가 새로이 설정되는 훈련 데이터에 잘 적응하지 못하는 경향을 보이고 있기 때문이다. 반면 Opt-LSTM은 효과적으로 시퀀스 데이터의 순서 의존성을 학습하고 꾸준히 손실 함수가 감소하는 경향을 보인다. 그 감소의 끝에, 조기 종료 조건을 만족하여 Opt-FCN보다 훈련의 시간도 짧게 설정될 수 있었다.

그림 7은 Opt-FCN과 Opt-LSTM의 훈련 분류 정확도의 양상을 나타내고 있다. 이는 손실함수에서 추정 가능한 정보와 매우 유사하다. 다만 손실함수의 경우 오차의 정도를 연속적인 값에 반영할 수 있어 더욱 면밀한 분석을 허용하는 반면, 정확도는 그 결과의 전반적인 양상을 요약해서 나타낼 수 있다는 특징이 있다. 그림 6에서 추론할 수 있는 바와 마찬가지로 Opt-LSTM이 학습 과정이 진행될수록 더 높은 정확도에 수렴하는 모습을 보일 수 있었다.

4.3. 제안된 순환 아키텍처 기반 모델의 최종 검증




〈그림 8〉 학습된 모델의 검증: Opt-FCN의 동작 상태 예측 결과




〈그림 9〉 학습된 모델의 검증: Opt-LSTM의 동작 상태 예측 결과

그림 8과 그림 9는 학습된 Opt-FCN 및 Opt-LSTM 모델을 시험 상황에 놓았을 때 보이는 분류 결과를 요약한다. 각 그림의 Military Movement축의 0은 Sitting, 1은 Standing, 2는 Walking, 3은 Running, 4는 Ascending, 5는 Descending, 6은 High Crawl, 7은 Low Crawl을 나타낸다. FCN 모델의 최종 인식 정확도는 95.70%로 전반적으로 높은 정확도를 보였다. 추출된 네 가지 그래프 특성이 효과적으로 데이터의 이동 양상을 드러내고 있음을 의미한다. 하지만, Opt-LSTM의 경우 그 수준을 넘어서는 98.39%의 정확도를 보였다. 이는 오차율이 62.56% 감소한 결과이다. 인간이 주변 환경과 상호작용하며 스스로의 의도로 신체 좌표를 생성할 때, Opt-LSTM은 그 행동 양식을 분석하는 데 있어 가장 효과적인 수단이 될 수 있음이 드러났다. 각 동작 상태에 대한 더욱 세밀한 분석은 혼동 행렬을 통해 확인될 수 있다.



〈그림 10〉 Opt-FCN의 분류 결과: 혼동 행렬



〈그림 11〉 Opt-LSTM의 분류 결과: 혼동 행렬

그림 10은 최종적인 Opt-FCN 모델의 시험 결과를 혼동 행렬로 나타낸다. 그림 11은 최종적인 Opt-LSTM 모델의 시험 결과를 혼동 행렬로 나타낸다. 두 경우 모두 Sitting 및 High Crawl 상태에서 오차가 발생했다. 특히 High Crawl은 Opt-FCN 및 Opt-LSTM에 있어 공통적으로 가장 큰 오차율을 보인 상태이다(각각 17.39% 및 8.696%). High Crawl은 사용자의 에너지 소모량이 크게

요구되는 다소 고된 동작으로, 연속으로 수행하는 와중 사용자가 동작을 수행하는 과정에서 시간에 따른 피리가 발생한 것으로 예상된다. 이는 더 많은 데이터를 확보하여 딥러닝 모델이 동작 중의 다양한 변이 상황에 대해 적응할 수 있도록 유도하여 해결할 수 있다. 약간의 오차 상황을 감안하더라도, 제안된 LSTM 기반 딥러닝 알고리즘은 FCN 기반 방식에 비해 인간이 개입되는 요소가 한 단계 적음에도 불구하고 더 뛰어난 순서 의존성 캡처 능력을 보일 수 있었다. LSTM을 활용하여 군인의 주요 동작 상태를 구분하고 이를 실시간으로 인식할 수 있는 가능성이 확보된 것이다.

5. 결론

본 연구 결과를 통해 군사 동작 중 측정된 동적 데이터를 다룰 때의 방향성이 성공적으로 제시될 수 있었다. 각 동적 데이터의 이동양상을 파악하는 데 있어 LSTM과 같은 순환 아키텍처는 효과적인 솔루션을 제공할 수 있다. 이와 더불어, 하이퍼파라미터 최적화 기법은 제시된 모델의 성능을 더욱 끌어올리는 역할을 수행한다.

이러한 결과에도 불구하고, 추후 연구로 남은 2%의 오차율을 완전히 제거하기 위한 과제가 남아있다. 웨어러블 기술은 인간의 신체와 직접적인 상호작용을 지속하는 시스템이 대부분이기 때문에, 약간의 오차도 알고리즘의 오작동을 야기해 군인과 같은 실제 착용자 및 관리자에게 큰 혼란을 불러올 수 있다. 또한, 동작에 대한 다양성을 더욱 확보하여 군인이 일상 훈련 중 보이는 행동양식에 맞춰 상태를 확인할 수 있는 범용적 모델을 개발할 필요도 있다. 이러한 과제들은 제

안된 군용 웨어러블 어플리케이션의 적용 가능성을 증진하는 결과를 불러올 수 있다. 마지막으로, 본 연구는 복잡한 군사 동작의 구분을 위해 LSTM 네트워크 구조를 최적화하는 방식을 선택하였지만 군사 어플리케이션이라는 도메인에 맞게 기존 기법을 개선·수정하여 네트워크의 성능 및 적용성을 증진시킬 필요가 있다.

군사적 관점에서 볼 때, 본 연구결과는 현재 제20전투비행단에 국내 최초로 도입된 지능형 스마트비행단의 발전에 이바지할 수 있을 것으로 기대된다. 웨어러블 기기를 통한 군사행동 인식을 통해 기지방호작전에서 유무인 복합 경계작전 중 인간과 무인기의 상호작용에 도움을 줄 수 있으며, 또한 시공간에 영향을 받지 않고 교육훈련을 수행할 수 있음과 동시에 실전적 및 초실감형 교육훈련 환경 조성에 이바지할 수 있을 것이다. 더불어서, 기지 및 활주로의 보호가 중요한 공군 특성상 지휘통제실 중심의 부대 종합상황 감시 및 통제 기반 체계의 확립이 매우 중요한데, 본 연구결과를 이에 실제로 응용하여 적용시키는 것이 향후 과제로 남아있다.

참고문헌(References)

[국내 문헌]

- 김유영, and 송민. “영화 리뷰 감성분석을 위한 텍스트 마이닝 기반 감성 분류기 구축.” *지능정보연구* 22, no. 3 (2016): 71-89.
- 안성만, 정여진, 이재준, and 양지현. “한국어 음소 단위 LSTM 언어모델을 이용한 문장 생성.” *지능정보연구* 23, no. 2 (2017): 71-88.
- 최지혜, 김민승, 이찬호, 최정환, 이정희, and 성태웅. “Hybrid CNN-LSTM 알고리즘을 활용

한 도시철도 내 피플 카운팅 연구.” *지능정보연구* 26, no. 2 (2020): 131-145.

- 최진탁, 강경태. (2022). 재활 로봇을 위한 심전도 (ECG) 실시간 데이터 베이지안 최적화 분석 기술”. *한국컴퓨터정보학회 학술발표논문집*, 30(2), 53-56.

[국외 문헌]

- Fernandez-Lopez, P., Sanchez-Casanova, J., Liu-Jimenez, J., & Morcillo-Marin, C. (2017, October). Influence of walking in groups in gait recognition. In 2017 International Carnahan Conference on Security Technology (ICCST) (pp. 1-6). IEEE.
- Han, Y. C., Wong, K. I., & Murray, I. (2019). Gait phase detection for normal and abnormal gaits using IMU. *IEEE Sensors Journal*, 19(9), 3439-3448.
- Muratore, F., Ramos, F., Turk, G., Yu, W., Gienger, M., & Peters, J. (2022). Robot learning from randomized simulations: A review. *Frontiers in Robotics and AI*, 9.
- Odhiambo, C. O., Saha, S., Martin, C. K., & Valafar, H. (2022). Human Activity Recognition on Time Series Accelerometer Sensor Data using LSTM Recurrent Neural Networks.
- Park, S. Y., Ju, H., & Park, C. G. (2016). Stance phase detection of multiple actions for military drill using foot-mounted IMU. sensors, 14, 16.
- Slade, P., Kochenderfer, M. J., Delp, S. L., & Collins, S. H. (2021). Sensing leg movement enhances wearable monitoring of energy expenditure. *Nature communications*, 12(1), 1-11.
- Steel, K., Ellem, E., & Baxter, D. (2015). The application of biological motion research: biometrics, sport, and the military. *Psychonomic*

- bulletin & review, 22(1), 78-87.
- Tao, W., Lai, Z. H., Leu, M. C., & Yin, Z. (2018). Worker activity recognition in smart manufacturing using IMU and sEMG signals with convolutional neural networks. *Procedia Manufacturing*, 26, 1159-1166.
- Wyss, T., & Mäder, U. (2010). Recognition of military-specific physical activities with body-fixed sensors. *Military medicine*, 175(11), 858-864.
- Yu, Y., Si, X., Hu, C., & Zhang, J. (2019). A review of recurrent neural networks: LSTM cells and network architectures. *Neural computation*, 31(7), 1235-1270.
- Zhuang, W., Chen, Y., Su, J., Wang, B., & Gao, C. (2019). Design of human activity recognition algorithms based on a single wearable IMU sensor. *International Journal of Sensor Networks*, 30(3), 193-206.

Abstract

A Data-driven Classifier for Motion Detection of Soldiers on the Battlefield using Recurrent Architectures and Hyperparameter Optimization

Joonho Kim* · Geonju Chae* · Jaemin Park* · Kyeong-Won Park**

The technology that recognizes a soldier's motion and movement status has recently attracted large attention as a combination of wearable technology and artificial intelligence, which is expected to upend the paradigm of troop management. The accuracy of state determination should be maintained at a high-end level to make sure of the expected vital functions both in a training situation; an evaluation and solution provision for each individual's motion, and in a combat situation; overall enhancement in managing troops. However, when input data is given as a timer series or sequence, existing feedforward networks would show overt limitations in maximizing classification performance. Since human behavior data (3-axis accelerations and 3-axis angular velocities) handled for military motion recognition requires the process of analyzing its time-dependent characteristics, this study proposes a high-performance data-driven classifier which utilizes the long-short term memory to identify the order dependence of acquired data, learning to classify eight representative military operations (Sitting, Standing, Walking, Running, Ascending, Descending, Low Crawl, and High Crawl). Since the accuracy is highly dependent on a network's learning conditions and variables, manual adjustment may neither be cost-effective nor guarantee optimal results during learning. Therefore, in this study, we optimized hyperparameters using Bayesian optimization for maximized generalization performance. As a result, the final architecture could reduce the error rate by 62.56% compared to the existing network with a similar number of learnable parameters, with the final accuracy of 98.39% for various military operations.

Key Words : Data-driven Model, Motion Recognition, Wearable Device, Recurrent Architecture, Hyperparameter Optimization

Received : November 18, 2022 Revised : December 6, 2022 Accepted : December 12, 2022

Corresponding Author : Kyeong-Won Park

* Mechanical Engineering, Republic of Korea Air Force Academy

** Corresponding author: Kyeong-Won Park

Department of Mechanical Engineering, Republic of Korea Air Force Academy

#330, DanJe-Kwan, 635 Namil-myeon, Danjae-ro, Sangdang-gu, Cheongju-si, Chungcheongbuk-do, 28187, Korea

Tel: +82-43-290-6572, E-mail: kyeongwon.park@alumni.kaist.ac.kr

저 자 소개



김준호

2019년~현재 대한민국 공군사관학교(ROKAF) 기계공학과 학사과정 재학.
관심분야는 딥러닝 알고리즘, 인공지능, 3D 프린팅.



채건주

2019년~현재 대한민국 공군사관학교(ROKAF) 기계공학과 학사과정 재학.
관심분야는 딥러닝 알고리즘, 공군 내 인공지능 응용, 무인항공.



박재민

2019년~현재 대한민국 공군사관학교(ROKAF) 기계공학과 학사과정 재학.
관심분야는 딥러닝 알고리즘, AI 조종사 개발.



박경원

2019년 한국과학기술원(KAIST) 기계공학과 학사. 2019년~2021년 동 대학원 기계공학과 석사. 2021년~현재 대한민국 공군사관학교(ROKAF) 교수사관.
관심분야는 웨어러블 응용, 인간능력 증강, 로봇시스템 설계 및 제어 등.