

<http://dx.doi.org/10.17703/JCCT.2025.11.1.683>

JCCT 2025-1-72

심층 신경망 기반 음성신호를 이용한 피로도 분류 모델

Fatigue Classification Model Using Speech Signals Based On Deep Neural Networks

권철홍*

Chul Hong Kwon*

요약 본 연구는 작업자의 피로를 객관적으로 평가하는 분류기를 심층 신경망 모델을 활용하여 개발하는 것을 목표로 한다. 현대 사회에서 작업 환경의 요구가 증가함에 따라 작업자는 신체적, 정신적 스트레스를 많이 받고 있으며, 이로 인해 피로 관련 안전사고의 위험이 증가하고 있다. 기존의 피로 측정 방법은 주관적인 방법과 객관적인 방식으로 피로를 평가할 수 있으나, 전문가의 개입과 많은 시간이 요구되어 일상적인 사용에는 한계가 있다. 본 연구에서는 이러한 한계를 극복하고자 음성신호를 기반으로 한 심층 신경망 모델을 제안한다. 본 연구에서는 피험자의 음성 데이터를 수집하고, 이를 기반으로 피로 수준을 5개 클래스로 분류한다. 음성신호에서 추출한 특징 파라미터를 이용하여 심층 신경망 모델을 학습시키고, 교차 검증을 통해 최적의 모델과 하이퍼파라미터를 선정한다. 실험 결과, 선정된 심층 신경망 모델은 85.39%의 높은 정확도로 5-레벨 피로 수준을 예측하였다. 이 모델은 피로를 실시간으로 평가할 수 있으며, 다양한 고위험 직종에 적용 가능한 실시간 평가 도구로 사용할 수 있다. 이러한 시스템은 작업장의 안전을 향상시킬 뿐만 아니라 사고를 예방하고 개인의 안전을 보장함으로써 사회적 비용을 줄일 수 있는 중요한 역할을 할 것이다.

주요어: 피로도 분류 모델, 심층 신경망, 음성신호

Abstract This study aims to develop a classifier that objectively assesses workers' fatigue using Deep Neural Networks(DNN) models. As the demands of modern work environments increase, workers are experiencing significant physical and mental stress, leading to a higher risk of fatigue-related accidents. While existing methods can assess fatigue both subjectively and objectively, they require expert intervention and are time-consuming, making them impractical for everyday use. To overcome these limitations, this study proposes a DNN model based on speech signals that can evaluate fatigue in real-time. The study involved collecting speech data from participants and classifying fatigue levels into five categories. Using features extracted from the speech signals, the DNN model is trained, and cross-validation is employed to select the optimal model and hyperparameters. The experimental results showed that the selected DNN model could predict the 5-level fatigue states with a high accuracy of 85.39%. This model can be used as a real-time assessment tool applicable to various high-risk occupations. This system not only enhances workplace safety and prevents accidents but also plays an important role in reducing social costs by ensuring individual safety.

Keywords: fatigue classification model, deep neural networks, speech signals

*정회원, 대전대학교 컴퓨터정보통신공학과 교수 (제1저자)
접수일: 2024년 10월 10일, 수정완료일: 2024년 11월 13일
게재확정일: 2024년 12월 5일

Received: October 10, 2024 / Revised: November 13, 2024
Accepted: December 5, 2024

*Corresponding Author: chkwon@dju.ac.kr
Dept. of Computer Information Communication Engineering,
Daejeon University, Korea

I. 서론

현대 사회에서 작업 환경의 요구가 증가함에 따라 작업자는 신체적, 정신적 스트레스를 많이 받고 피로 관련 안전사고 위험이 증가한다. 피로는 주관적 요소와 객관적 요소를 모두 포괄하는 다면적인 현상이다[1][2]. 중추 피로 또는 정신적 피로라고 불리는 주관적 피로는 정신적 기민성과 동기 부여의 감소를 특징으로 한다. 말초 피로 또는 작업 수행 피로는 피로의 신체적 측면과 관련되며 작업 중에 적절한 주의력과 수행 수준을 유지하는 신체의 능력을 반영한다.

주관적 피로를 측정하는 기존 방법에는 다차원 피로 척도와 같은 임상 척도가 가장 신뢰성이 높은 것으로 알려져 있다[3]. 반면, 업무 수행 피로도를 객관적으로 측정하는 방법은 근전도, 심전도, 호흡수, 피부 온도, 혈액 호르몬 수치와 같은 생리적 지표를 활용한다[4]. 생리학적인 신호를 통해 피로를 측정하는 방법은 의료 장비의 필요성, 복잡한 측정 절차, 피험자의 불편함 등으로 인해 일상생활과 실제 현장에 적용하기에 어려움이 따른다[5].

본 연구의 목표는 심층 신경망(Deep Neural Networks, DNN) 기술을 기반으로 객관적인 피로 평가 분류기를 개발하여 주관적인 피로 평가의 한계를 극복하는 것이다. 이 분류기는 현장에서 작업자의 피로를 평가하고 피로로 인한 위험을 완화할 수 있는 실시간 평가 도구로 적용할 수 있다.

사무실 환경에서는 반복적인 작업과 그에 따른 지루함이 심리적 활동을 감소시키고 업무 효율성을 저해할 수 있으므로 업무량으로 인한 정신적 피로에 관한 연구의 필요성이 부각 되고 있다. 미국을 비롯한 선진국에서는 근로자의 생리적 기능을 모니터링 하는 기술을 적극적으로 추구하고 피로를 완화하고 주의력을 강화하기 위한 약리학적 개입을 개발하고 있다. 이러한 발전에도 불구하고 피로 수준을 객관적으로 평가하기 위한 포괄적인 시스템은 아직 개발되지 않은 상황이다.

본 연구에서는 DNN 기술을 활용한 피로도 분류모델을 개발하여 피로 작업의 위험을 완화하는 것을 목표로 한다. 이 모델은 스마트폰이나 유사한 장치를 통해 현장에서 녹음한 음성신호를 사용하여 작업자의 피로 수준을 평가하므로 측정이 단순하고 객관적인 피로 수준을 제공하며, 실시간으로 피로 평가가 가능하다는 장점을 갖고 있다. 이는 특히 고위험 직종에서 실시간 피로 관리를 통해 사고를 예방하고 안전을 보장하는 데 크게 기여할 수 있다.

본 논문에서는 1장 서론에 이어 2장에서 음성 DB와 음성 특징 파라미터를 추출하는 방법을 설명한다. 3장에서 실험 환경 및 모델 학습 방법을 기술하고, 4장에서 DNN 모델을 설계하는 방법을 설명한다. 5장에서 본 논문에서 제안한 DNN 모델의 성능 평가 결과를 기술하고, 6장에서 결론을 맺는다.

II. 학습 DB와 음성 특징 파라미터

1. 학습 DB

모델 학습에 사용한 음성 DB는 다음과 같이 구성되어 있다. 피험자는 소방관, 경찰관, 군 조종사, 군인, 간호사 등으로 남성과 여성을 포함하고 있다. 피험자가 본인이 근무하는 사무실과 같은 실제 작업 환경에서 발화한 20초 분량의 문장을 지향성 마이크를 이용하여 수집한다. 음성 데이터는 16kHz, 16bit, 모노 형식이고, 녹음을 마친 뒤 음성신호의 크기가 10,000에서 25,000 사이가 되도록 크기를 조정한다. 이러한 과정은 음성 데이터의 일관성을 유지하고, 다양한 작업 환경에서의 피로 상태를 보다 정확하게 반영하기 위함이다.

본 연구에서 피로 레벨은 5개 클래스로 분류한다. 피로 레벨 1은 '최상의 컨디션', 레벨 2는 '좋은 컨디션', 레벨 3은 '보통 컨디션', 레벨 4는 '피로한 상태', 레벨 5는 '소진된 상태' 등을 나타낸다. 이러한 분류는 피로 수준에 따른 작업자의 상태를 명확하게 구분하고, 각 수준에 맞는 적절한 대처 방안을 마련하는 데 도움을 준다.

학습 DB에는 다음과 같은 방법으로 판정한 피로 수준 레이블이 포함되어 있다. 피험자가 녹음을 시작하기 전에 현재 컨디션을 백분율로 표시한 뒤 피로 다면평가 설문지를 작성하고, 백분율 값과 설문지 합계 점수를 종합적으로 분석하여 피로 수준 레이블을 예비 판정한다, 다음에 추가로 생리적 지표 측정을 통해 종합적인 피로 수준 평가를

받는다. 이러한 주관적 평가와 객관적 평가를 결합한 다각적인 접근 방식은 피로 수준 측정의 정확성을 높이며, 피로 모델의 학습에 있어 중요한 데이터를 제공한다.

2. 음성 특징 파라미터

음성 데이터에서 음성의 특징을 대표하는 특징 파라미터(Feature)를 추출하여 피로도 분류모델을 학습하는 데 사용한다. 음성 특징 파라미터를 추출하기 위해 오픈소스인 Parselmouth[6], OpenSmile[7], DisVoice[8] 등 음성분석 라이브러리를 연구하였다. 이 중에서 본 연구에서 성능이 가장 우수한 Parselmouth를 이용하여 특징 파라미터를 추출한다. Parselmouth는 파이썬에서 Praat[9]의 핵심 기능에 효율적이고 프로그래머 친화적인 방식으로 접근할 수 있게 해주는 오픈소스 파이썬 라이브러리이다.

사용한 음성 특징 파라미터는 표 1과 같다.

표 1. 음성 특징 파라미터
 Table 1. Speech features

기본주파수(F0)	Shimmer
Harmonic-to-Noise Ratio(HNR)	Amplitude Perturbation Quotient(APQ3)
Jitter	APQ5
Relative Average Perturbation(RAP)	APQ11
Pitch Perturbation Quotient(PPQ)	Difference of Differences of Amplitudes(DDA)
Difference of Differences of Periods(DDP)	

음성 특징 파라미터는 기본주파수(F0)의 평균값, 표준편차, 최솟값, 최댓값과, 음성신호의 주기성 정도를 나타내는 Harmonic-to-Noise Ratio(HNR)의 평균값, 연속적인 피치 주기의 평균 변화율인 Jitter, 연속적인 3개와 5개 분석 구간의 Jitter 평균인 Relative Average Perturbation(RAP), Pitch Perturbation Quotient(PPQ)와, 연속적인 피치 주기의 2차 미분에 해당하는 Difference of Differences of Periods(DDP), 연속적인 두 주기 구간의 진폭 평균 변화율인 Shimmer, 연속적인 3개, 5개, 11개 분석 구간의 Shimmer 평균인 Amplitude Perturbation Quotient(APQ3), APQ5, APQ11와, 연속적인 구간에서 진폭의 2차 미분에 해당하는 Difference of Differences of Amplitudes(DDA) 등이다. 이러한 다양한 파라미터들은 음성신호의 미세한 변화를 포착하여 피로 상태를 정밀하게 분석하는 데 도움을 준다.

기본주파수의 평균값, 표준편차, 최솟값, 최댓값은 음성의 기본적인 특성을 나타내며, 피로 상태에 따른 음성 변화의 기초적인 지표가 된다. HNR은 음성의 주기성과 노이즈 비율을 나타내어 음성의 품질을 평가하는 데 사용된다. Jitter와 Shimmer는 음성의 주기적 변화와 진폭 변화를 나타내어 피로로 인한 음성의 불안정성을 평가하는 데 유용하다. RAP, PPQ, DDP 등은 연속적인 피치 주기의 변화를 분석하여 피로 상태를 더욱 정밀하게 평가할 수 있게 한다.

이러한 음성 특징 파라미터들을 종합적으로 분석함으로써, 피로도 분류모델의 정확도를 높이고, 다양한 작업 환경에서의 피로 상태를 실시간으로 평가할 수 있는 능력을 갖추게 된다.

III. 실험 환경 및 모델 학습 방법

1. 실험 환경

모델을 학습하기 위하여 Python 버전 3.10.12, Keras 버전 2.15.0, Numpy 버전 1.25.2, Scipy 버전 1.11.4, Scikit-learn 버전 1.2.2 등을 사용하였다. 이러한 소프트웨어 환경은 최신 기술과 도구를 활용하여 효율적이고 효과적인 모델 학습을 가능하게 한다.

실험하기 전에 전체 데이터를 훈련과 테스트 데이터로 무작위로 나누어 사용한다. 전체 데이터는 피로 수준별로 균등하게 포함되어 있으며 총 4,690개이고, 학습에 사용된 DB는 전체 데이터의 80%로 피로 수준별로 750개씩 3,750개이며, 테스트 DB는 188개씩 940개이다. 이러한 데이터 분할 방법은 모델의 학습과 평가에 있어 공정성과 신뢰성을 확보하기 위함이다.

피로 평가의 신뢰성을 높이기 위해 데이터는 다양한 환경과 조건에서 수집되었으며, 피로 수준별로 균형 있게 분포되어 있어 모델이 다양한 피로 상태를 학습하고 평가할 수 있도록 한다. 데이터의 다양성은 모델의 성능과 일반화 능력을 높이는 데 중요한 역할을 한다.

2. 모델 학습 방법

Keras를 사용하여 DNN 모델을 설계하고 학습하는 과정은 다음과 같다. 제시한 다양한 계층과 함수를 조합하여 최적의 DNN 모델을 설계하고, 이를 통해 피로도 분류모델의 성능을 극대화할 수 있다.

1) 데이터 정규화

먼저 StandardScaler 함수를 이용하여 데이터를 정규화한다. 이 함수는 데이터를 평균이 0, 표준편차가 1이 되도록 조정한다. 데이터 정규화는 각 특징의 스케일을 맞추어 모델이 특정 특징 파라미터에 편향되지 않도록 한다.

2) 모델 학습 및 최적의 하이퍼파라미터 선택

설계된 모델은 훈련 데이터에 대해 5-fold 교차 검증방식을 사용하여 학습된다. 이 방법은 훈련 데이터를 5개 세트로 분할 하여 모델을 5번 학습하는 과정이며, 매번 다른 세트를 검증 세트로 사용하고 나머지 4개 세트를 훈련 데이터로 사용한다. 이 프로세스는 모델에 대한 최적의 하이퍼파라미터를 선정하기 위한 과정이다. 교차검증은 모델의 과적합을 방지하고 일반화 성능을 평가하는 데 유용하다.

3) 모델 학습에 사용된 함수

모델 학습에 사용된 옵티마이저는 AdaBelief이다. AdaBelief는 Adam만큼 빠른 학습 수렴 속도와 Stochastic Gradient Descent(SGD)와 비교할 만한 일반화 성능을 보여주며, 적응형 학습률 기능이 포함되어 있다[10].

학습률은 초깃값 0.01부터 시작되어 시간이 지남에 따라 ExponentialDecay 함수에 따라 학습률이 감소하여 모델이 원활하게 수렴하게 돕는다. 손실 함수는 다중 클래스 분류 문제에 적합한 Categorical cross_entropy로 설정한다. 모델 성능의 평가 지표는 정확도(Accuracy)를 사용한다.

AdaBelief 옵티마이저는 각 반복에서 학습률을 조정하여 최적의 학습 경로를 찾는 데 도움을 주며, 이는 모델의 수렴 속도를 높이고 학습 과정의 안정성을 향상한다. 또한, Categorical cross_entropy 손실 함수는 다중 클래스 분류 문제에서 모델의 예측 오류를 효과적으로 측정하고 최소화하는 데 사용된다.

4) 학습 파라미터

배치 크기는 64로 설정되어, 모델은 64개 샘플마다 가중치를 업데이트한다. 학습 프로세스는 10회 연속 에포크 동안 검증 손실이 개선되지 않으면 EarlyStopping 함수를 사용하여 훈련을 조기 종료한다. 이렇게 하면 모델의 과적합을 방지하고 계산 리소스를 절약할 수 있다.

배치 크기와 에포크 수는 모델의 학습 속도와 성능에 큰 영향을 미치며, EarlyStopping은 과적합을 방지하고 최적의 모델을 얻는 데 중요한 역할을 한다. 이러한 학습 파라미터는 모델의 효율적이고 효과적인 학습을 위해 실험을 통해 적절하게 설정된다.

5) DNN 모델 계층 구성 함수

Dense: 이 함수는 완전 연결(Fully connected) 신경망 계층을 나타내는데, 각 뉴런은 이전 계층의 모든 뉴런에 연결된다. 이는 모델이 복잡한 패턴을 학습하는 데 도움을 준다.

BatchNormalization: 이 계층은 입력을 평균 0, 표준편차 1로 정규화하여 각 미니 배치의 계층에 대한 입력을 표준화하는 데 사용된다. 이를 통해 학습 프로세스의 훈련 속도와 안정성을 향상할 수 있다.

Relu: 각 계층의 활성화 함수로는 ReLU(Rectified Linear Unit) 함수를 사용한다. 이는 모델에 비선형성을 도입

하여 복잡한 패턴을 학습하는 데 도움이 된다.

DropOut(): 이 계층은 학습 중에 업데이트할 때마다 입력 단위의 일부를 0으로 무작위로 설정한다. 이는 신경망이 특정 가중치에 덜 민감하도록 만들어 과적합을 방지하여 모델의 일반화 기능을 향상하도록 한다.

Dense 계층은 모델의 기본 구조를 이루며, BatchNormalization과 Relu 활성화 함수는 모델의 학습 효율성을 높이고 복잡한 데이터 패턴을 학습하는 데 기여한다. DropOut 계층은 과적합을 방지하고 모델의 일반화 성능을 향상하는 역할을 한다.

IV. DNN 모델 설계

본 연구에서 DNN 모델을 최적으로 구성하기 위해 다음 세 가지 모델을 설계하고 실험한다. 각 모델은 서로 다른 구조와 구성 요소를 사용하여 다양한 조건에서의 성능을 비교하고 평가한다.

1) 모델 Dense_1

첫 번째 모델은 [Dense-BatchNormalization-Relu-DropOut]으로 구성된 구조화된 계층의 조합을 활용한다. 이 조합을 한 세트로 하여 여러 세트를 반복하여 모델을 구성하며, 실험 단계에서 매번 세트 수와 Dense 노드 수를 다르게 설정한다. 목표는 세트와 Dense 노드 개수의 변화가 모델의 전체 성능에 어떤 영향을 미치는지 관찰하는 것이다.

2) 모델 Dense_2

두 번째 모델은 [Dense-BatchNormalization-Relu]로 구성된 조합을 한 세트로 하여, 모델 Dense_1과 유사하게 이 세트를 여러 번 반복하여 모델을 구성한다. 이 구성에서는 DropOut을 제외하고 BatchNormalization 및 Relu 함수의 영향에 중점을 둔다. 이 실험의 목적은 DropOut 없이 BatchNormalization이 있는 것이 모델 성능과 안정성, 특히 학습 효율성과 과적합 경향에 어떤 영향을 미치는지 확인하는 것이다.

3) 모델 Dense_3

세 번째 모델은 [Dense-Relu-DropOut]을 한 세트로 하여 모델 Dense_1, 2와 유사하게 이 세트를 여러 번 반복하여 모델을 구성한다. 이 모델은 BatchNormalization을 제외하고 Dense 계층, Relu 활성화 함수 및 DropOut 간의 상호작용에 중점을 둔다. 이 모델은 BatchNormalization 없이 DropOut의 존재가 학습 및 일반화 측면에서 모델 성능에 어떤 영향을 미치는지 관찰하는 것이 목적이다.

4) 최적의 모델 선정

앞서 기술한 3가지 모델을 실험한 결과, Dense_2 모델이 가장 우수한 성능을 보여주었다. 최적의 모델을 구성하기 위해 Dense 세트 수 및 Dense 노드 수를 변경하여 Dense_2에 대한 추가 실험을 진행한다. 결론적으로, Dense 노드와 세트의 다양한 구성을 실험하고, 가장 좋은 성능을 보이는 모델인 Dense_2에 초점을 맞춰 신경망의 최적 아키텍처를 설계한다. 이를 통해 피로도 분류모델의 성능을 극대화 한다.

V. 성능 평가

본 연구에서는 훈련 데이터를 이용하여 5-fold 교차검증 방식을 통해 가장 우수한 성능을 보이는 학습 모델에서 최적의 하이퍼파라미터를 선정한다. 교차검증 방식은 모델의 일반화 성능을 평가하고 과적합을 방지하는 데 효과적이다. 이후, 이 하이퍼파라미터가 적용된 모델에 별도로 구성된 테스트 데이터를 입력으로 정확도와 혼동 행렬 (Confusion matrix)을 사용하여 모델의 성능을 평가한다. 이러한 평가 방법은 모델의 예측 성능을 공정하게 분석할 수 있도록 한다.

그림 1은 최적의 하이퍼파라미터가 적용된 모델 Dense_2의 학습 성능 그래프를 보여준다. 그림에서 보듯이 학습이 적절하게 진행됨을 알 수 있다. 학습 곡선은 손실 함수 값이 안정적으로 감소하고, 정확도가 지속적으로 증가함

을 나타낸다.

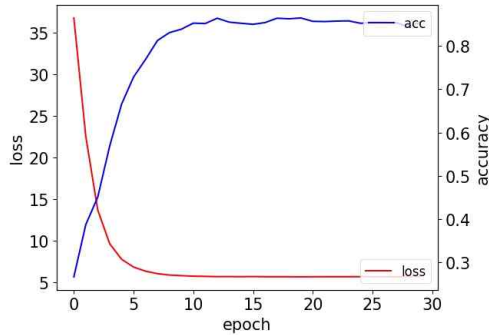


그림 1. 모델 Dense_2의 학습 성능 그래프
Figure 1. Training performance graph of model Dense_2

테스트 데이터에 대한 모델 Dense_2의 성능은 다음과 같다. 전체 테스트 데이터에서 학습된 모델이 바르게 예측한 데이터의 비율인 정확도는 85.39%로써 우수한 성능을 보인다. 이는 모델이 다양한 피로 수준을 비교적 정확하게 분류할 수 있음을 의미한다.

정확도에 대한 혼동 행렬은 표 2와 같다. 표 2를 보면, 피로 수준 1, 2, 3, 5는 각각 0.936, 0.899, 0.840, 0.899의 높은 정확도를 보인다. 피로 수준 4는 0.697의 정확도를 나타내며 피로 수준 3으로 오분류되는 경향이 있다. 이는 피로 수준 3과 4가 음성신호에서 비슷한 특징을 갖고 있다고 볼 수 있다.

혼동 행렬을 통해 모델이 특정 피로 수준을 어떻게 예측하는지, 그리고 어떤 수준에서 오분류가 발생하는지 명확하게 파악할 수 있다. 이는 모델의 개선 방향을 제시하는 데 중요한 정보이다.

표 2. 정확도에 대한 혼동 행렬
Table 2. Confusion matrix for accuracy

		피로 수준 예측값				
		1	2	3	4	5
피로 수준 레이블	1	0.936	0.027	0.005	0.011	0.021
	2	0.043	0.899	0.005	0.032	0.021
	3	0.032	0.0	0.840	0.128	0.0
	4	0.005	0.069	0.229	0.697	0.0
	5	0.0	0.064	0.021	0.016	0.899

VI. 결 론

본 연구는 심층 신경망 기술을 활용하여 작업자의 피로를 실시간으로 평가할 수 있는 시스템을 다룬다. 기존의 피로 측정 방법이 가진 한계를 극복하고, 음성 데이터를 이용하여 피로를 객관적으로 평가함으로써 작업 현장에서의 적용 가능성을 높인다. 음성신호 기반 피로 평가 시스템은 측정의 간편성과 실시간 평가가 가능하다는 장점을 제공한다.

본 연구는 피로 수준을 5단계로 설정하여 5-레벨 분류 문제를 다룬다. 실험 결과, 제안된 모델은 85.39%의 높은 정확도로 피로 수준을 예측한다. 연구 결과로부터 음성 데이터를 수집하여 피로 수준을 분류하는 것이 가능하다는 것을 알 수 있다.

이러한 연구 결과는 작업자의 피로 상태를 신속하게 파악하고, 적절한 대응을 통해 안전사고를 예방하는 데 기여할 수 있음을 의미한다. 또한, 실시간 피로 평가 시스템을 통해 작업자의 피로 상태를 지속적으로 모니터링하고, 필요한 조치를 신속히 취할 수 있게 된다.

이 연구는 비행기 조종사, 선박 승무원, 대형 차량 운전자, 소방관, 경찰관, 야간 근무 간호사, 생산 공장의 육체 작업자를 포함한 고위험 직종에 적용할 수 있다. 예상되는 결과는 작업장의 안전을 향상할 뿐만 아니라 사고를 예방하고 개인의 안전을 보장함으로써 사회적 비용을 줄일 수 있는 시스템이다.

추후 연구에서는 더 다양한 환경에서 데이터를 수집하고, 딥러닝 모델 개선을 통해 정확도를 높이는 방향으로 진행될 것이다. 추가 연구 대상인 딥러닝 모델은 Recurrent neural networks, Convolutional recurrent neural networks, ResNet, Convolutional attention-based bidirectional GRU model, Transformer-based model, Attention-based convolutional recurrent neural networks 등이다. 이러한 모델들은 더욱 정교한 피로 평가를 가능하게 하여 실시간 피로 관리 시스템의 효율성을 극대화할 것이다.

References

- [1] U. S. Choi and M. S. Song, "Concept Analysis: Fatigue," *Korean Journal of Women Health Nursing*, Vol. 9, No. 1, pp. 61-69, 2003.
- [2] I. G. Kim, "The Relationship Between The Types Of Stress Coping And Life Goals For College Freshmen," *International Journal of Advanced Culture Technology (IJACT)*, Vol. 8, No. 2, pp. 85-95, 2020.
- [3] S. H. Kim, S. H. Yoo, D. S. Kim, and Y. K. Lee, "Development And Validation Of A Daily Multidimensional Fatigue Inventory (DMFI)," *Journal of Ergonomics Society of Korea*, Vol. 43, No. 3, pp. 205-215, 2024.
- [4] S. W. Kim, S. J. Park, and Y. S. Lee, "Development Of Evaluation Method Of Driver's Fatigue By Physiological Signal," *Proceedings of Spring Conference of Korean Society of Automotive Engineers*, pp. 1208-1212, 2003.
- [5] S. H. Lee and C. H. Kwon, "Fatigue Classification Model Based On Machine Learning Using Speech Signals," *The Journal of Convergence on Culture Technology (JCCT)*, Vol. 8, No. 6, pp. 741-747, 2022.
- [6] Y. Jadoul, B. Thompson, and B. de Boer, "Introducing Parselmouth: A Python Interface To Praat," *Journal of Phonetics*, Elsevier, Vol. 71, pp. 1-15, 2018.
- [7] The Munich Open-source Media Interpretation By Large Feature-space Extraction (openSMILE) Toolkit, [Computer program] retrieved October 2024 from <https://audeering.github.io/opensmile/>
- [8] DisVoice, [Computer program] retrieved October 2024 from <https://github.com/jcvasquezc/DisVoice>
- [9] P. Boersma and D. Weenink, "Praat: Doing Phonetics By Computer," [Computer program]. version 6.4.13, retrieved October 2024 from <https://www.fon.hum.uva.nl/praat/>
- [10] J. Zhuang, T. Tang, Y. Ding, S. Tatikonda, N. Dvornek, X. Papademetris, and J. S. Duncan, "AdaBelief Optimizer: Adapting Stepsizes By The Belief In Observed Gradients," <https://doi.org/10.48550/arXiv.2010.07468>, 2020.

※ 이 논문은 2024학년도 대전대학교 교내학술연구비 지원에 의해 연구되었음.