

DATA
BIG
2023. 07

Vol. 1, NO. 1

(Serial Number 1)

Journal of Big Data Service

the first issue of an academic journal

- A Case Study on the Failure Prediction and Cause Explanation based on Equipment Sensor Data using LSTM and LRP Jon-Hwi Lee · Jae-Young Lee · Seon-Hyo Jung · Jin Young Choi
- Rapid Response System for the Detection of In-Hospital Clinical Deterioration Using Attention Bi-Direction Network Thanh-Cong Do · Hyung-Jeong Yang
- A Review of Research Topic Trend on Corporate Entrepreneurial Orientation Changlim Joo
- Design and Implementation of Fire Evacuation Direction Guidance System using Dijkstra Algorithm Yun-Koo Kang · Kwan-Hee Yoo
- Examination on the Applicability of Motion Amplification Technology by Event Sensor Jin Myoung Jang · Kyung Ho Sun · Byung Ok Kim · Sung Min Eom · Yun Ho Shin
- Multi-Dimensional Analysis of Job Recommendation Service Information Saksonita Khoeurn · Eun-Seon Choi · Yoo-Hee Park · Wan-Sup Cho
- A Study on Clustering-based Color Extraction Method for Pill Classification Sun-Young Ihm
- A Study on Tree Recognition and Classification Using LIDAR Image Data Moon-Seok Kang · Il-Gun Park

통권
1

제 1 권 1 호


빅데이터서비스학회 논문집
Journal of Big Data Service

ISSN 2983-3221

Journal of Big Data Service

빅데이터서비스 학회 논문집

학술지 창간호



DATA
BIG
2023년 7월

제 1 권 1 호


(통권 제1호)

빅데이터서비스학회 학술지 창간호

- LSTM 및 LRP를 활용한 설비 센서 데이터 고장 예측 및 원인 설명 사례 연구 이준휘 · 이재영 · 정선호 · 최진영
- Rapid Response System for the Detection of In-Hospital Clinical Deterioration Using Attention Bi-Direction Network 도탄공 · 양형정 · 김수형 · 고보건
- 기업의 기업가적 지향성 연구 동향 분석 주창림
- 다익스트라 알고리즘을 이용한 화재 피난 방향 안내 시스템의 설계 및 구현 강운구 · 류관희
- 이벤트 센서 기반 모션증폭 기술 적용 가능성 고찰 장진명 · 선경호 · 김병옥 · 엄성민 · 신윤호
- 일자리 추천서비스 정보의 다차원 분석 니따 · 최은선 · 박유희 · 조완섭
- 알약 분류를 위한 클러스터링 기반 색상 추출 기법 연구 임선영
- 라이다 화상 데이터를 활용한 수목 인식 및 분류에 대한 연구 강문석 · 박일건

Journal of Big Data Service

빅데이터서비스 학회 논문집



학술지 창간호

빅데이터서비스학회 학술지 창간호

- LSTM 및 LRP를 활용한 설비 센서 데이터 고장 예측
및 원인 설명 사례 연구 이준휘 · 이재영 · 정선호 · 최진영
- Rapid Response System for the Detection of In-Hospital Clinical Deterioration Using Attention
Bi-Direction Network 도탄공 · 양형정 · 김수형 · 고보권
- 기업의 기업가적 지향성 연구 동향 분석 주창림
- 다익스트라 알고리즘을 이용한 화재 피난 방향 안내 시스템의 설계 및 구현 강윤구 · 류관희
- 이벤트 센서 기반 모션증폭 기술 적용 가능성 고찰 장진명 · 선경호 · 김병옥 · 엄성민 · 신윤희
- 일자리 추천서비스 정보의 다차원 분석 니따 · 최은선 · 박유희 · 조완섭
- 알약 분류를 위한 클러스터링 기반 색상 추출 기법 연구 임선영
- 라이다 화상 데이터를 활용한 수목 인식 및 분류에 대한 연구 강문석 · 박일건



빅데이터서비스학회 논문집

제1권 제1호(통권 1호)

2023. 07



THE KOREA
BIG DATA SERVICE SOCIETY
한국빅데이터서비스학회



빅데이터서비스학회 논문집

Journal of Big Data Service

제1권 제1호(통권 1호)

2023. 07

C O N T E N T

- LSTM 및 LRP를 활용한 설비 센서 데이터 기반 고장 예측 및 원인 설명 사례 연구
..... 이준휘 · 이재영 · 정선효 · 최진영 5
- Rapid Response System for the Detection of In-Hospital Clinical Deterioration
Using Attention Bi-Direction Network
..... 도탄공 · 양형정 · 김수형 · 고보건 17
- 기업의 기업가적 지향성 연구 동향 분석 주창림 31
- 화재 발화 위치 및 다익스트라 알고리즘을 이용한 피난 방향 안내 시스템의 설계
..... 강윤구 · 류관희 49
- 이벤트 센서 기반 모션증폭 기술 적용 가능성 고찰
..... 엄성민 · 나웅재 · 장진명 · 신경호 · 김병옥 · 신윤희 59
- 일자리 추천서비스 정보의 다차원 분석 최은선 · 크연삭소니파 · 박유희 · 조완섭 69
- 알약 분류를 위한 클러스터링 기반색상 추출 기법 연구 임선영 79
- 라이다 화상 데이터를 활용한 수목 인식 및 분류에 대한 연구
..... 강문석 · 박일건 85



Journal of Big Data Service

Vol. 1, No. 1

July 2023

C O N T E N T

- A Case Study on the Failure Prediction and Cause Explanation based on
Equipment Sensor Data using LSTM and LRP
..... Jon-Hwi Lee · Jae-Young Lee · Seon-Hyo Jung · Jin Young Choi 5
- Rapid Response System for the Detection of In-Hospital Clinical Deterioration Using
Attention Bi-Direction Network
..... Thanh-Cong Do · Hyung-Jeong Yang · Soo-Hyung Kim, Bo-Gun Kho 17
- A Review of Research Topic Trend on Corporate Entrepreneurial Orientation
..... Changlim Joo 31
- Design of Evacuation Direction Guidance System using Fire Location and
Dijkstra Algorithm
..... Yun-Koo Kang · Kwan-Hee Yoo 49
- Examination on the Applicability of Motion Amplification Technology
by Event Sensor
..... Sung Min Eom · Woong Jae Na · Jin Myoung Jang ·
Kyung Ho Sun · Byung Ok Kim · Yun Ho Shin 59
- Multi-Dimensional Analysis of Job Recommendation Service Information
..... Eun-Seon Choi · Saksonita Khoeurn · Yoo-Hee Park · Wan-Sup Cho 69
- A Study on Clustering-based Color Extraction Method for Pill Classification
..... Sun-Young Ihm 79
- A Study on Tree Recognition and Classification Using LIDAR Image Data
..... Moon-Seok Kang · Il-Gun Park 85



LSTM 및 LRP를 활용한 설비 센서 데이터 기반 고장 예측 및 원인 설명 사례 연구*

A Case Study on the Failure Prediction and Cause Explanation
based on Equipment Sensor Data using LSTM and LRP

이존휘¹, 이재영¹, 정선효¹, 최진영^{1**}

¹아주대학교 산업공학과

Jon-Hwi Lee¹, Jae-Young Lee¹, Seon-Hyo Jung¹, Jin Young Choi^{1**}

¹Department of Industrial Engineering, Ajou University

요 약

4차 산업혁명으로 인해 데이터 기반의 공정 모니터링 방안 및 공정관리 기법에 대한 관심이 높아지고 있으며, 설비의 고장 진단 및 고장 예측과 관련하여 인공지능 모델을 활용하는 방안이 활발히 연구되고 있다. 그러나 설비의 고장 발생 시점을 예측하고, 예측한 고장의 판단 근거를 함께 제시할 수 있는 연구는 제한적이다. 이에 본 연구에서는 다변량 설비 시계열 데이터를 처리하기 위한 고장 예측 모델로 LSTM 모델을 활용하여 고장 시점을 포함한 고장의 예측을 수행한다. 또한, 예측된 고장에 대해, LRP를 활용한 설명 가능 모델을 적용하여 해당 고장 판단의 근거를 함께 제시한다. LRP를 통해 고장 예측에 대한 기여도가 높은 설비 센서 측정값을 확인하였고, 이를 고장 판단 근거로 보는 것이 합리적인지를 실제로 설비 센서 측정값에서 이상치가 나타났는지 비교하여 검증하였다.

주제어: LSTM, LRP, XAI, 고장 예측

* 이 성과는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. 2020R1F1A1073199).

** Corresponding Author: Jin Young Choi (choijy@ajou.ac.kr)

Abstract

With the advent of the Industry 4.0, data-driven process monitoring and process control methods are explosively increased. The application method of AI models on fault diagnosis and failure prediction in relation to equipment failures is actively being studied. However, studies that can predict the time for occurring equipment failures and provide evidence for the predicted failures are limited. In this study, an LSTM model is used for a fault prediction model to processing multivariate equipment time series data, including predicting the failure time. Additionally, an interpretable model using LRP is applied to the predicted failures to provide the evidence for the fault diagnosis. Through LRP, the contribution of equipment sensor measurements with high relevance to failure prediction is determined, and the reasonability of considering them as evidence for fault diagnosis is validated by comparing them with anomalies in actual equipment sensor measurements.

Keyword: LSTM, LRP, XAI, Failure prediction

1. 서론

제조산업의 지능화, 고도화로 인해 생산설비 및 제조공정의 데이터 수집량은 큰 폭으로 증가하였다. 또한, 4차 산업혁명 시대의 도래로 인해 스마트 팩토리를 중심으로 한 데이터 기반의 실시간 공정 모니터링 방안 및 공정관리 기법에 대한 관심은 나날이 높아지는 추세이다. 특히 생산설비에서 수집되는 실시간 데이터를 기반으로 한 공정 모니터링 및 공정 내 설비의 이상탐지(Anomaly detection), 결함진단(Fault diagnosis) 분야에 인공지능 기반 의사결정을 활용하는 방안이 활발히 연구되고 있다[1]. 결함진단은 특히 설비의 고장 진단 및 고장 예측과 관련이 깊은 연구 분야이다.

결함진단에 인공지능 기반 의사결정을 적용한 기존 연구에서는 설비에서 수집된 센서 측정값과 CNN 모델을 활용한 자동화 기계 고장 진단 기법[2]을 제시하였으나, 미래의 고장 시점을 예측하거나 고장 판단의 근거를 제시할 수 없었다. 또한, 다른 기존 연구에서는 다변량 센서 데이터와 LSTM 모델을 활용한 fault detection 방법[3]을 제안하였으나, 고장 판단의 근거를 제시하는 부분에 대해서는 다루고 있지 않았다. 이렇듯 인공지능 기반 모델을 활용해 설비의 고장 발생 시점을 예측하고, 예측한 고장 판단의 근거를 함께 제시할 수 있는 연구는 제한적이며, 이는 고장 예측에 대한 구체적인 시점과 고장 판단 근거를 함께 제공하는 능력이 부족하기 때문에 선제적인 고장 예방조치를 기대하기 어렵다는 문제점이 존재한다.

이에 본 연구에서는 Long Short-Term Memory(LSTM) 기반의 고장 예측 모델을 통해 미래의 고장 시점을 예측하고, 예측된 결과에 eXplainable Artificial Intelligence(XAI) 기법 중 하나인 Layer-wise

Relevance Propagation(LRP)를 적용하여 인공지능 모델이 예측한 고장 판단의 근거를 함께 제시하는 사례 연구를 수행하였다. 고장 예측 모델에 사용된 설비 센서 데이터는 Kaggle의 pump_sensor_data[4]를 사용하였으며, 고장 예측 모델은 복수의 과거 시점 데이터를 입력받아 복수의 미래 시점 데이터를 예측할 수 있는 many-to-many 구조의 LSTM 모델을 사용하였다. 또한, LSTM 모델이 예측한 고장 시점의 신빙성을 확인하기 위해 LRP를 적용한 설명 가능 모델을 구축하였다. LRP가 적용된 설명 가능 모델은 고장 예측 모델이 학습한 가중치를 바탕으로 예측한 결과의 relevance score를 계산하여 레이어 단위로 역전파를 수행한다. 역전파가 완료되면 고장 예측의 판단 근거로 각 센서 값이 얼마의 기여도를 갖는지를 계산할 수 있으며, 이를 통해 어떤 센서가 고장 예측의 원인인지 설명할 수 있다[5]. 고장 예측 모델과 설명 가능 모델을 대상으로 진행한 실험 결과, 고장 예측 모델은 86개의 고장 시점을 포함한 60,283개의 시점에 대해 54개의 고장 시점을 올바르게 예측하였으며, 예측된 고장 시점 중 실제로 고장이 발생한 시점에 대해 설명 가능 모델을 적용하여 특정 센서에서 relevance score가 지속적으로 높게 나타나는 것을 확인하였다. 또한, 설명 가능 모델에 사용된 LRP 결과의 신빙성을 검증하기 위해 고장 판단 근거로 지목된 고장 시점의 센서 측정값 평균이 고장 판단 근거로 지목되지 못한 고장 시점의 센서 측정값 평균을 비교하여 설비 센서 측정값에서 실제로 이상치가 발생하였는지 분석하였다. 그 결과, relevance score가 지속적으로 높게 나타나는 고장 시점의 실제 센서 측정값 평균이 그렇지 않은 고장 시점의 실제 센서 측정값보다 현저히 낮은 수치로 나타나는 것을 확인하였다.

본 연구에서 소개된 고장 예측 모델은 센서 데이터가 수집된 시점의 고장 상태를 판정하는 것이 아니라, 다수의 과거 시점 센서 데이터를 통해 다수의 미래 고장 발생 시점을 예측할 수 있다. 또한, 설명 가능 모델을 통해 고장 예측 모델이 예측한 고장의 판단 근거를 함께 제시하는 방식을 시도하였다. 이는 다양한 센서를 통해 모니터링 되는 생산설비에 대해 미래의 고장 발생 시점을 포함한 고장 예측에 적용될 수 있으며, 예측된 고장 시점이 어떤 센서로 인해 판단되었는가에 대한 정보를 함께 제공하여 고장 예측에 대한 납득할 만한 근거를 함께 제공할 수 있다. 이를 바탕으로 생산설비의 고장 원인을 분석하고 선제적인 고장 예방조치를 수행하는데 활용될 수 있다.

본 논문의 구성은 다음과 같다. 먼저 2장에서는 다양한 XAI 기법과 이를 적용한 고장 예측 연구에 대해 소개한다. 3장에서는 고장 예측 모델과 설명 가능 모델에 대해 설명하며, 모델 학습 및 예측에 사용된 데이터와 실험 결과는 4장에 정리한다. 마지막으로 5장에서는 본 연구의 수행 결과에 대한 결론 및 의의에 대해 서술한다.

II. 관련 연구

XAI는 인공지능 모델 특유의 black-box 특성을 해결하기 위한 방법론으로, 인공지능 모델의 예측 과정을 투명하게 해석하여 인공지능 모델이 예측한 결과에 대한 신빙성을 제공하기 위한 기술이다[6]. 현재까지 연구된 대표적인 XAI 기법은 LIME[7], SHAP[8], CAM[9], Grad-CAM[10], LRP[11] 등이 존재한다. XAI

기법은 모델이 예측한 결과를 어느 범위까지 해석할 수 있는지에 따라 ‘일부(local)’ 해석 기법과 ‘전체(global)’ 해석 기법으로 분류될 수 있다[12]. 또한, 모델을 해석하는 접근 방식에 따라서 학습된 모델의 파라미터를 활용하는 ‘역전파(backpropagation)’ 방식과 입력 데이터의 특성을 변화시켜 활용하는 ‘섭동(perturbation)’ 방식으로 분류될 수 있다[12]. LIME과 SHAP는 섭동 방식을 기반으로 모델의 일부 해석과 전체 해석이 모두 가능한 기법이며, CAM과 Grad-CAM은 역전파 방식을 기반으로 모델의 일부 해석을 가능케 하는 기법이다[12]. 또한, LRP는 역전파 방식을 기반으로 모델의 일부 해석과 전체 해석이 모두 가능한 기법이다[12].

각 기법의 특징을 정리하면 다음과 같다. Local Interpretable Model-agnostic Explanations (LIME)은 다양한 분류 모델 및 회귀 모델의 예측 결과에 적용될 수 있는 설명 가능한 인공지능 기법으로, 선형 근사(linear approximation)를 통해 모델의 예측 결과를 부분적으로 해석하는 기법이다[7]. LIME은 특히 텍스트 및 이미지 처리 분야에서 모델의 예측 결과에 대해 신뢰할 수 있는 설명력을 제공하며, 학습된 모델의 개별적인 예측 결과들을 신뢰할 수 있도록 설명하여 기계학습 시스템과 인간 사이의 효과적인 상호작용에 기여했다[7]. SHapley Additive exPlanations(SHAP)는 Shapley 값을 기반으로 유의미한 특징(feature)을 변화시켜 기여도를 계산해내는 기법이다[8]. 전체 특징의 기여도 합은 일정하게 유지되기 때문에 어떤 특징을 제거하였을 때의 기여도 변화를 구할 수 있게 되며, 이는 각 특징의 독립성이 유지되는 경우에 유효한 기여도를 계산해낼 수 있다[8]. Class Activation Mapping(CAM)은 CNN 기반 클래스 분류 모델에 적용되는 설명 가능한 인공지능 기법으로, global average pooling을 통해 탐색된 객체의 위치를 시각화하는 것이 핵심이다[9]. 시각화는 CNN 모델에서 탐지된 유의미한 객체를 강조(highlighting)하는 것으로 수행되며, 주어진 이미지에 대해 모델이 예측한 클래스 점수를 시각화하는 방식을 사용한다[9]. Gradient-weighted Class Activation Mapping(Grad-CAM)은 CNN 모델에 global average pooling을 사용하는 CAM 기법을 보완하여 보편적인 CNN 모델에 적용 가능한 것이 특징이다[10]. Grad-CAM은 gradient를 기반으로 모델의 가중치를 시각화하는 방식을 사용하며, 이미지 분류 결과에 대해 유의미하게 사용된 부분을 강조하는 것이 가능하다[10]. 마지막으로, Layer-wise Relevance Propagation(LRP)는 비선형 분류 모델의 분류 결과를 설명하기 위해 고안되었으며, 분류 결과를 특징 벡터(feature vector)로 분해(decomposition)하여 기여도(relevance score)를 계산하는 방식을 사용한다[11]. 분류 결과의 분해가 완료되면 모델이 학습한 가중치를 이용하여 각 레이어 단위로 relevance score를 역전파하여 최종적으로 모델이 예측한 결과에 대한 입력 데이터의 기여도를 계산할 수 있다[13]. LRP를 응용한 기존 연구에서는 CNN 기반 분류 모델에 LRP를 적용하여 분류된 이미지의 어느 픽셀이 분류 결과에 높게 기여하였는지 나타내는 LRP 기반 시각화를 수행하였다[14].

특히 고장 예측 모델에 XAI 기법을 적용한 연구는 LSTM 모델을 통해 단일 시점의 베어링의 고장 상태 예측을 수행하는 연구[5]를 들 수 있다. 해당 연구에서는 예측한 결과에 LRP를 활용하여 예측에 유의미한 영향을 갖는 특성을 추출하고, 이를 예측 모델에 반영하여 학습의 효율성 및 정확도 개선을 달성하였다. 또한, 핫 스트립 밀(Hot strip mill) 설비의 고장 상태 예측에 Variational Auto-Encoder(VAE) 모델을 사용한 연구[15]에서는 VAE 모델의 예측 결과에 SHAP 기법을 적용하여 고장 예측에 유의미한 영향을 준 특징(Feature)를 함께 제시하였다.

III. 모 델

1. 고장 예측 모델

고장 예측에는 many-to-many 구조의 LSTM 모델이 사용되었다. LSTM 모델은 시계열 데이터를 다루는데 적합한 모델로 널리 사용되고 있으며, many-to-many 구조가 적용된 LSTM 모델은 복수의 과거 시점 데이터를 입력하여 복수의 미래 시점 예측값을 출력할 수 있다. 이를 통해 과거의 설비 센서 측정값을 기반으로 미래의 설비 상태를 예측하는 고장 예측 모델을 생성하였다.

Fig. 1은 본 논문에서 사용한 many-to-many 구조의 LSTM 모델을 나타내고 있다. LSTM 모델의 입력값으로 사용되는 인풋 데이터는 설비의 상태 정보를 수집하는 6종류의 센서 데이터와 설비 상태 레이블을 10회 timestep 단위로 분할하여, LSTM 모델에 투입할 수 있게 3차원 형태로 가공한 데이터이다. 이때, 인풋 데이터의 60%는 LSTM 모델의 학습(training) 데이터로 사용되고, 13%는 검증(validation) 데이터로 사용된다. 나머지 27%는 시험(test) 데이터로 사용되어 학습이 완료된 LSTM 모델의 예측 성능 평가에 사용된다.

Many-to-many 구조가 반영된 LSTM 모델의 학습 및 예측은 다음과 같이 이루어진다. 먼저, 10회 timestep 단위로 묶은 6종류의 센서 측정값과 설비 상태 레이블을 인풋 데이터로 입력한다. 입력된 인풋 데이터를 통해 LSTM 모델은 각 timestep에 대한 6종류의 센서 측정값이 10회 timestep 이후에는 어떤 상태 레이블로 나타나는지를 학습하게 된다. 또한, 10회 timestep 단위로 학습이 진행되기 때문에 시계열 데이터




Figure 1. Many-to-many LSTM model

의 특성을 모델이 학습할 수 있게 된다. 이렇게 학습이 완료된 LSTM 모델에 시험 데이터를 투입하면 6개 센서에 대한 과거 10회 timestep의 시계열 데이터를 바탕으로 미래 10회 timestep의 설비 상태를 확률 벡터값으로 예측할 수 있다. 이때, 예측한 설비 상태는 고장 확률 벡터값에 임계값을 적용해 판정하는데, 계산된 고장 확률 벡터값이 임계값 이하인 경우에는 정상 상태로 판정하며, 임계값을 초과하는 경우에는 고장 상태로 판정한다. 고장 및 정상 상태를 판정하는 임계값의 설정에 대해서는 4장의 2절에서 자세히 다루고 있다.

본 논문에서 사용한 고장 예측 모델의 구조는 Fig. 2에 나타나 있다. 먼저, Input 레이어는 6개의 노드로 구성되어 있는데, 이를 통해 10회 timestep의 6종류의 센서 측정값을 입력받을 수 있다. 두 번째 레이어인 LSTM 레이어는 128개의 노드로 구성되어 있으며, Input 레이어를 통해 10회 timestep의 6종류의 센서 측정값을 입력받아 학습을 수행한다. 마지막 레이어인 Dense 레이어는 2개의 노드로 구성되어 있으며, 최종적으로 해당 시점이 정상에 가까운지, 고장에 가까운지를 각각에 대한 확률 벡터로 나타낸다.




Figure 2. Structure of LSTM model

2. 설명 가능 모델

설명 가능 모델은 고장 예측 모델에서 예측한 결과의 신빙성을 확인하기 위해 LRP(Layer-wise Relevance Propagation)를 적용한 모델이다[5]. LRP를 적용한 설명 가능 모델은 고장 예측 모델에서 각 노드가 학습한 가중치를 바탕으로 layer마다 relevance score를 계산하여 역전파 과정을 반복한다. 최종적으로 각각의 인풋 데이터의 relevance score인 R_x 를 계산하는데, 계산된 R_x 가 클수록 해당 센서의 측정값이 해당 시점의 상태 레이블을 예측하는데 높은 기여도를 갖고 있음을 나타낸다. 본 연구에서는 고장 예측 모델인 LSTM 모델에서 예측한 정상 및 고장 확률 벡터부터 역전파 과정을 적용하였으며, 최종적으로 학습에 사용된 각 인풋 데이터에 대한 기여도 R_x 값을 계산해냈다. 이를 통해, 6종류의 센서 중에서 예측한 확률 벡터값에 대해 높은 기여도를 갖는 센서 측정값이 어떤 센서의 측정값인지를 나타낼 수 있다. 예를 들어, 모델의 예측 결과

가 고장인 경우, 어떤 센서의 측정값이 고장을 예측하는데 결정적으로 기여하였으며, 각 센서의 측정값이 고장을 예측하는데 기여한 정도는 얼마인지 확인할 수 있다.

IV. 실험

1. 데이터 분석 및 전처리

실험에 사용한 데이터는 급수 펌프 설비 데이터로 52개의 센서 값과 상태 레이블, 타임스탬프를 포함하고 있다. 상태 레이블은 '정상', '고장', '수리'의 3가지 레이블이 존재하며, 수집된 설비 데이터는 1분 간격으로 측정된 시계열 데이터이다. 상태 레이블의 '수리' 상태는 '고장' 상태가 발생한 직후 정상가동 시점까지 수리되고 있는 상태를 나타낸다. 즉, 정확한 고장 발생 시점의 상태 레이블은 '고장'이며, '고장'이 발생한 직후부터 다시 '정상' 상태가 되기 전까지는 모두 '수리' 상태 레이블이 나타난다. Mean Time to Repair(MTTR) 관점에서 볼 때, 고장 발생 시점부터 정상가동 시점까지는 시스템이 정상적으로 작동하지 못하는 것으로 간주하기 때문에, '수리' 상태 역시 '고장' 상태로 볼 수 있다. 따라서 Table 1과 같이 '수리' 상태 레이블을 모두 '고장' 상태 레이블로 변경하였다.

52개의 센서 데이터 중 상태 레이블에 유의미한 영향을 주는 데이터를 추출하기 위해 센서 데이터에 SelectKBest 패키지와 XGBoost 모델을 사용하여 최종적으로 유의미한 6개의 센서를 선정하였다. 선정된 센서에 대해 결측치가 존재하는 27개 시점의 데이터를 제거하고, 센서 데이터의 정규화를 진행하였다. 또한, LSTM 모델의 인풋 데이터로 사용하기 위해 Fig. 3와 같이 3차원 데이터로 가공하였으며, 최종적으로 6종류의 센서 측정치를 10회 timestep으로 묶은 220,283개의 데이터로 변환하는데 성공했다.

2. 실험 결과

고장 예측 모델의 학습에 사용된 학습 데이터는 130,000개, 검증 데이터는 30,000개를 사용하여 학습을 진행하였고, 나머지 60,283개의 데이터는 모두 시험 데이터로 사용하였다. 반복적인 학습을 통해 예측 성능이 높은 파라미터를 선택하였으며, 최종 파라미터의 batch size는 128, epoch은 4, optimizer는 adam을 사용하였다. Fig. 4는 고장 예측 모델의 임계값에 대한 f1-score를 나타낸 것이다. 0.8의 임계값 부근에서 모델의 종합적인 예측 성능인 f1-score가 높게 나타났기 때문에, 고장 예측 모델에서 정상 및 고장 예측의 임계값으로 0.8을 사용하였다.

Table 1. The number of failure data

변경 전		변경 후	
고장	7	고장	14,484
수리	14,447	수리	0




Figure 3. Input data structure




Figure 4. F1-score for threshold

학습이 완료된 고장 예측 모델에 시험 데이터를 투입하여 예측을 진행하였고, 예측된 결과에 설명 가능 모델을 적용하여 Rx 값을 계산해냈다. Fig. 5은 시험 데이터의 6,469번째 시점부터 6,478번째 시점까지 10회 timestep의 인풋 데이터에 대한 Rx 값을 나타내고 있다. 해당 센서 측정값으로 예측된 10회 timestep의 상태 레이블은 모두 고장으로 예측되었으며, 6종류의 센서 중 sensor_02의 Rx 값이 10회 timestep 동안 상대적으로 높은 수준을 유지하는 것을 확인할 수 있다. 이는 sensor_02의 측정값이 고장 상태의 판단에 높은 기여도를 갖고 있음을 나타낸다.




Figure 5. Rx graph for 10 timesteps

Table 2. Identified fault occurrence time for 50 timesteps

센서	고장 판단 근거로 지목된 고장 시점 개수	고장 판단 근거로 지목된 고장 시점의 센서 측정값 평균	고장 판단 근거로 지목되지 못한 고장 시점의 센서 측정값 평균
sensor_02	3	0.8640	0.8660
sensor_04	2	0.0005	0.2354
sensor_10	1	0.1528	0.3248
sensor_11	5	0.3074	0.5658
sensor_39	0	-	0.1431
sensor_42	0	-	0.0827

설명 가능 모델을 통해 높은 Rx 값을 갖는 센서 측정값이 실제로 설비 고장과 관련된 이상치인지 확인하기 위해, 고장으로 예측한 시점 중, 실제 레이블이 고장인 50회 timestep을 대상으로 Table 2와 같이 검증을 진행하였다. 각 센서 데이터에 포함된 10회 timestep에 대하여, Rx 값이 0.5 이상인 횟수가 5회 이상인 경우를 유의미한 고장 판단의 근거로 지목하였으며, 고장 판단 근거로 지목된 고장 시점과 지목되지 못한 고장 시점에 대하여, 각각의 센서 측정값 평균을 비교해 유의미한 차이가 존재하는지 확인했다. 고장으로 예측한 시점 중, 실제 레이블이 고장인 50회 timestep 동안 고장 판단 근거로 지목된 고장 시점 개수는 sensor_11이 5개로 가장 많았으며, sensor_02는 4개, sensor_04는 2개, sensor_10은 1개의 고장 판단 근거로 지목된 고장 시점을 갖는다. 이를 기반으로 계산된 고장 판단 근거로 지목된 고장 시점의 센서 측정값의 평균은 sensor_02에서 0.8640, sensor_04에서 0.0005, sensor_10에서 0.1528, sensor_11에서 0.3074로 나타났다.

고장 판단 근거로 지목된 고장 시점과 고장 판단 근거로 지목되지 못한 고장 시점의 센서 측정값 평균을 비교해본 결과 sensor_11에서 0.2584로 가장 큰 차이가 나타났고, sensor_04에서 0.2349, sensor_10에서 0.172, sensor_02에서 0.002의 차이를 보였다. 이는 sensor_02를 제외한 sensor_04, sensor_10, sensor_11에서 고장 판단 근거로 지목된 고장 시점의 센서 측정값이 고장 판단 근거로 지목되지 못한 고장 시점의 센서 측정값보다 훨씬 낮은 이상치로 나타나는 것을 확인할 수 있다. LRP를 통해 계산된 Rx 값이 센서 측정값의 고장 예측에 대한 기여도를 잘 반영하고 있음을 나타낸다.

V. 결 론

본 연구는 설비 관련 정보를 나타내는 센서 측정값 데이터를 시간 축을 포함한 3차원 데이터로 변환하고, 이를 기반으로 고장 예측 모델인 LSTM 모델을 학습하여 고장 시점을 포함한 고장의 예측을 진행하였다. 또한, 고장 예측 모델에 LRP를 적용한 설명 가능 모델을 통해, 고장 예측 모델에서 예측한 고장에 대해, 어떤 센서 측정값으로 인해 고장이 예측되었는지를 Rx 값을 계산하여 설명하였다. 추가적으로, 설명 가능 모델의

결과로 계산된 Rx 값을 바탕으로 고장 판단 근거로 지목된 고장 시점의 센서 측정값 평균이 고장 판단 근거로 지목되지 못한 고장 시점의 센서 측정값 평균보다 이상치에 가깝다는 점을 확인하며 Rx 값이 나타난 센서 측정값의 고장 판단 기여도가 합리적임을 검증하였다. 이는 LRP 결과를 통해 고장 판단의 기여도가 높은 데이터와 그렇지 않은 데이터를 구분하여, 고장 판단에 유의미한 데이터를 선별해낼 수 있다는 가능성을 나타낸다.

예측된 설비 고장에 대한 판단 근거를 제시하는 것은 고장 예측에 대한 신빙성을 제공할 뿐, 직접적으로 해당 고장의 발생 원인을 제시하는 것과는 별개 수준의 해결책으로 생각될 수 있다. 그럼에도 예측된 설비의 고장이 어떤 센서값에 근거하여 발생하는지 사전에 파악 가능하다면, 해당 센서가 측정하는 요소에 대한 사전 점검 및 설비 점검의 근거로 활용될 여지는 충분하다. 예측 결과만을 제공하는 기존의 인공지능 기반 의사결정과는 다르게, 예측에 대한 신빙성 있는 판단 근거를 함께 제시하는 편이 공정 내 설비 모니터링 및 유지보수 측면에서도 유용하게 사용될 것이다. 또한, 고장 판단의 근거로 지목된 센서가 설비의 어떤 정보를 수집하는가에 따라, 설비 고장의 원인을 탐색하는 데에도 활용될 여지가 있다.

본 연구에서는 연속적인 고장 시점에 대해 일정 수준 이상의 relevance score가 지속적으로 관측되는 경우의 평균값을 기준으로 이상치를 비교하는 방식을 사용하였으며, 명확한 검증 정확도를 제시할 수 없다는 한계점이 있다. 향후 연구에서는 LRP 결과의 검증과 관련하여 검증 정확도를 명확하게 제시할 수 있는 방안을 탐색하여 적용해 볼 계획이다.

참고문헌

- [1] J. H. Cho and J. O. Lee, "A Predictive System for Equipment Fault Diagnosis based on Machine Learning in Smart Factory," *KNOM Review*, vol. 24, no. 1, pp. 13-19, 2021.
- [2] K. W. Kang and K. M. Lee, "CNN-based automatic machine fault diagnosis method using spectrogram images," *Journal of the Institute of Convergence Signal Processing*, vol. 21, no. 3, pp. 121-126, 2020.
- [3] Y. U. Song and S. Baek, "Real-time fault detection in discrete manufacturing systems via LSTM model based on PLC digital control signals," *Journal of Society of Korea Industrial and Systems Engineering*, vol. 44, no. 2, pp. 115-123, 2021.
- [4] *Pump sensor data*, 2018, [Online]. Available: <https://www.kaggle.com/datasets/nphantawee/pump-sensor-data>.
- [5] H. Wu, A. Huang, and J. W. Sutherland, "Layer-wise relevance propagation for interpreting LSTM-RNN decisions in predictive maintenance," *The International Journal of Advanced Manufacturing Technology*, pp. 1-16, 2022.
- [6] H. Kim and T. J. Lee, "정보보호 분야의 XAI 기술 동향," *REVIEW OF KIISC*, vol. 31, no. 5, pp. 21-31, 2021.
- [7] M. T. Ribeiro, S. Singh, and C. Guestrin, "Why should i trust you?" Explaining the predictions of any classifier," In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, San Francisco, CA, USA, 2016, pp. 1135-1144.
- [8] S. M. Lundberg and S. I. Lee, "A unified approach to interpreting model predictions," *Advances in Neural Information Processing Systems*, Long beach, CA, USA, 2017, pp. 4765-4774.
- [9] B. Zhou, A. Khosla, A. Lapedriza, A. Oliva, and A. Torralba, "Learning deep features for discriminative localization," In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Las Vegas, NV, USA, 2016, pp. 2921-2929.
- [10] R. R. Selvaraju, M. Cogswell, A. Das, R. Vedantam, D. Parikh, and D. Batra, "Grad-cam: Visual explanations from deep networks via gradient-based localization," In *Proceedings of the IEEE International Conference on Computer Vision*, Venice, Italy, 2017, pp. 618-626.
- [11] S. Bach, A. Binder, G. Montavon, F. Klauschen, K. R. Müller, and W. Samek, "On pixel-wise explanations for non-linear classifier decisions by layer-wise relevance propagation," *PloS one*, vol. 10, no. 7, e0130140, 2015.
- [12] A. Das and P. Rad, "Opportunities and challenges in explainable artificial intelligence (xai): A survey," *arXiv preprint*, arXiv:2006.11371, 2020.
- [13] J. H. Ahn, *XAI Explainable Artificial Intelligence, Anatomy of Artificial Intelligence*. Wikibooks, 2020.
- [14] B. Zhang, L. Ding, Z. Feng, M. Zhu, T. Lei, M. Xing, and X. Zhou, "CNN-LRP: understanding

convolutional neural networks performance for target recognition in SAR images,” *Sensors*, vol. 21, no. 13, 4536, 2021.

- [15] J. Jakubowski, P. Stanisz, S. Bobek, and G. J. Nalepa, “Anomaly detection in asset degradation process using variational autoencoder and explanations,” *Sensors*, vol. 22, no. 1, 291, 2021.



Rapid Response System for the Detection of In-Hospital Clinical Deterioration Using Attention Bi-Direction Network*

Thanh-Cong Do¹, Hyung-Jeong Yang^{1**}, Soo-Hyung Kim¹, Bo-Gun Kho²

¹Department of Artificial Intelligence Convergence, Chonnam National University

²Pulmonology and Critical Care Medicine, Chonnam National University Hospital

도탄공¹, 양형정^{1**}, 김수형¹, 고보건²

¹전남대학교 인공지능융합학과

²전남대학교병원 내과

요 약

병원 환경 내에서 환자 상태의 악화가 발생하면 의료 서비스에 상당한 부담이 된다. 이러한 경우 신속한 임상 개입이 중요하며 임상 수치로부터 조기 징후를 감지하고 심정지를 예방하기 위해 중환자실(ICU)은 신속 대응 시스템(RRS)을 광범위하게 사용한다. 최근 몇 년 동안 심정지, 패혈증 예측 또는 ICU로의 이송과 같은 집중 치료 영역에서 딥러닝(DL) 및 전자 건강 기록(EHR)의 사용이 증가하고 있다. DL 기반 애플리케이션은 순차 시계열 데이터에서 학습할 수 있지만 해석력이 부족하여 민감도가 낮고 지연 경보율이 높아 임상에 적용하기 어렵다. 본 연구에서는 고차원 순차 데이터를 보간하여 심정지 환자의 이상 상태를 감지하는 해석 가능한 end-to-end 딥러닝 아키텍처를 제안한다. 실험은 전남대학교 병원(CNUH)에서 수집한 개인 임상 데이터 세트에서 수행되었고 실험 결과는 다른 최첨단 방법과 비교하여 우리 모델의 잠재적 성능을 보여주었다.

주제어: 임상 악화, 신속한 대응 시스템, 딥러닝

* 이 논문은 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(RS-2023-00208397). 또한, 과학기술정보통신부 및 정보통신기획평가원의 인공지능융합혁신인재양성사업 연구 결과로 수행되었음(IITP-2023-RS-2023-00256629).

** Corresponding Author: Hyung-Jeong Yang (hjyang@jnu.ac.kr)

Abstract

In hospitals globally, the occurrence of clinical deterioration within the hospital setting poses a significant burden on healthcare. Rapid clinical intervention becomes a crucial task in such cases. To detect early signs of clinical decline and prevent cardiac arrest, the intensive care units (ICUs) widely employ rapid response systems (RRSs). In recent years, there has been an increasing use of deep learning (DL) and electronic health records (EHR) in the intensive care domain, such as the prediction of cardiac arrest, sepsis, or transferring to ICUs. DL-based applications are able to learn from sequential time-series data. However, their lack of interpretability leads to low sensitivity and high late alarm rates, and are thus difficult to apply to the clinical settings. In this research, we propose an interpretable end-to-end deep learning architecture that interpolates high-dimensional sequential data and detects the abnormal status of cardiac arrest patients. The experiments are conducted on a private clinical dataset collected from Chonnam National University hospital (CNUH). The experimental results have shown the potential performance of our model, compared to some other state-of-the-art methods.

Keyword: Clinical deterioration, Rapid response system, Deep learning

1. Introduction

There has been an increase in the number of patients and the overcrowding of emergency departments recently, which are causing adverse outcomes of treatment. In-hospital clinical deterioration events such as cardiac arrest is considered as a major burden in most ICU, which affects patient mortality [1-3]. Previous studies indicates that 80% of cardiac arrest patients can be early detected, because the sign of deterioration can be shown up 8-24 hours before the event [4-6]. However, this work faces many difficulties because a single vital sign usually does not accurately predict patient prognosis [7]. In fact, the survival discharge rate of cardiac arrest patients is less than 20% [8, 9].

RRS has been introduced in many hospitals as a clinical supporting tool for clinician to provide rapid intervention to cardiac arrest patient [10, 11]. Some traditional RRSs using the modified early warning score (MEWS) which calculates a weighted score for each vital sign and then finds patients with event based on the sum of the scores [12]. However, this method includes limitations of low sensitivity or high false-alarm rates [12, 13]. The National Early

Warning Score has been introduced recently, which shows the outstanding predicting performance over previous systems in terms of cardiac arrest and mortality [14].

In recent years, the increased access to EHR has motivated the development of artificial intelligence models to predict clinical events in ICU [15-17]. There have been several attempts to apply artificial neural networks (ANN) to detect in-hospital events, which achieve a lot of attention [18-20]. Utilizing ANN has shown better performance than the traditional scoring systems, which predict the cardiac arrest earlier with better accuracy [20]. However, these DL-based models usually faced the limitations in terms of lacking interpretability, being perceived as a 'black box' that does not offer any understanding of the underlying features learned from the data [21]. In this work, we defined interpretability as the clinician's ability to examine the most important patterns of input time-series that exert the highest influence on the predicted probability of the model.

The medical time-series data captured in an EHR is frequently limited, noisy, and incomplete, particularly when obtained in non-critical care units, posing a challenge for recurrent deep learning models that rely on evenly spaced data points. In this paper, we proposed an approach of predicting in-hospital clinical deterioration of cardiac arrest patients. Our proposed framework architecture is based on the Bi-directional LSTM (BiLSTM) to capture information from both past and future contexts, allowing it to learn better feature representation of sequential patterns in the data. In addition, we also utilize the attention mechanism to improve the interpretability of DL-based model by exploring the underlying feature representation of different time-series signals, and then fuse the information to predict the final outcome. The primary contributions of this paper are described as follows:

- We proposed an end-to-end DL-based framework to deal with the detection of in-hospital clinical deterioration. The proposed method is based on BiLSTM architecture that takes into account the context from both previous and future time steps, capturing more comprehensive representations and more robust to input variations and noise.
- In the medical context, interpretability is considered as one of the key components of clinical utility [22]. Our model presents good interpretability by utilizing the attention mechanism that emphasizes those parts of the multivariate time-series that are most relevant to the output target.
- Our proposed system shows the better performance on two clinical dataset compared to baseline approaches. We also conduct the experiments with cross-validation strategy to present the generalization of the model.

The rest of the paper is organized as follows: Section 2 begins with some description about the related works on RRS models for clinical deterioration. Section 3 presents the detail architecture of our proposed system. Dataset information and the experiment results are reported in section 4. Finally, section 5 is about the conclusion and some future work for our study.

II. Related works

In this section, we review some recent DL-based applications for predicting in-hospital clinical deterioration. RNN-based models recently show great potential in medical and healthcare domain because of the capability for capturing sequential patterns in time-series [23]. The study in [22] developed prediction models for 3 events: sepsis, acute kidney injury (AKI) and mortality. Each model utilized the bidirectional long short-term memory (Bi-LSTM) architecture to design binary classification models. The experiment results show the superior performances of the Bi-LSTM models compared to some other machine learning methods. A deep early warning system (DEWS) has been proposed in [18] to predict in-hospital cardiac arrest from 0.5 to 24 hours before the event. DEWS consisted of 3 RNNs with LSTM unit to deal with long-term dependency problem. The model is tested on 2 clinical datasets, and it outperforms MEWS, logistic regression, and random forest in all metrics. Another study [20] applies the architecture of 3 ANNs for early detection of patients at risk of cardiac arrest. The first network is a multi-layer perceptron (MLP) that uses baseline variables (age, sex, initial vital signs, ...). The second network consists of LSTM layers stacked with MLP layers which uses 12 recent updates of vital signs within the past 6 hours as input. The third model is the hybrid model of LSTM and MLP where the sequence data and static data are processed separately first, and then fused to generate the output. All the above methods usually outperform traditional scoring systems. However, these approaches do not have good interpretability and may not be capable of capturing comprehensive representations of time-series.

Some recent research has applied the attention mechanism to their models, which improves the interpretability as it highlights those parts of the input data that most contribute to the model's decision. In conventional sequence-to-sequence modeling scenarios, attention allows the model to selectively learn deferentially from the more and less significant segments of the

input sequence. In the context of healthcare environments, attention models have received modest acknowledgment and have been applied to tasks such as the classification of atrial fibrillation in electrocardiogram (ECG) data [24, 25], forecasting future diagnoses [26, 27], and predicting the likelihood of high-risk vascular disease by leveraging both diagnosis codes and medication information. A DL-based framework which utilizes MLP along with attention mechanism is proposed in [28]. This approach shows the competitive performance compared to MLP, linear regression and stacked denoising auto-encoder (SDAE) for the task of clinical prediction for heart failure patients.

III. Proposed method

This section shows our proposed DL-based framework for an early detection system of in-hospital clinical deterioration prediction. In this paper, our proposed method a multi-task problem: predicting the patient future clinical status and forecasting the vital signs measurements of the next time-point. We use fixed length of input sequence $n \in \{8, 12, 24\}$ and a sliding step $k=1$ as shown in Fig. 1. We consider the task of patient clinical status predicting as an abnormal detection problem. The abnormal status is defined as the time in which the clinicians recognize some abnormal changes in patients' measurements which will probably lead to cardiac arrest. The overall architecture of the proposed framework is shown in Fig. 2.

The input of our proposed framework includes multivariate time series with N features of length T , which is denoted as $X = (x_1, x_2, \dots, x_T)^T \in R^{T \times N}$. We also use some other clinical information are non-time-series data. Besides, we also introduce a masking vector $M = (m_1, m_2, \dots, m_T)^T \in \{0, 1\}^N$ to denote the missing value information:




Figure 1. Input and output samples

$$m_t^n = \begin{cases} 1, & \text{if } x_t^n \text{ is observed} \\ 0, & \text{otherwise} \end{cases} \quad (1)$$

After data preprocessing step, the input data go through a BiLSTM network to extract both forward and backward latent features. We combine these two latent features and serves them as input for the attention module to capture the important information. The output of attention layers is then go through two different branches to predict the clinical status and estimate the vital signs.

1. Data preprocessing

For the task of clinical deterioration prediction, we use two types of input features: the vital signs which are measured every hour; and the clinical features which are recorded discontinuously. In the medical context, most healthcare dataset usually face the problem of missing values. In this work, for the vital signs, we apply the carry-forward method for missing data imputation if data existed before the missing time points. If not, we fill the missing data with the mean of non-missing values of each patient. For the lab tests, since each patient has only a few records, we duplicate these values for every time point between two records.

Class imbalance is one of the main problems in medical anomaly detection because most of the data are normal [18, 23]. With such imbalanced dataset, the DL models usually perform poorly on the minority class (positive class). Several time-series augmentation techniques are mentioned in [29] that generate more samples of minority class to control the imbalance problem. In this work, we apply two data augmentation methods as in [30] which are cropping and label expansion. Besides augmentation, we also apply data normalization to enhance the robustness of the model. In this work, we normalize the input time-series with standard normalization as follow:

$$\bar{x} = \frac{x - \mu}{\sigma} \quad (2)$$

with x is input time-series, μ and σ are the mean and standard deviation of the input data.




Figure 2. The overall architecture of the proposed method

2. Model architecture

The multivariate input time-series are first processed by a BiLSTM network in order to maximize the information from both past and future contexts. The LSTM cells outperform common RNNs by dealing with the problem of “long-term dependency”, using the gates that can hold the information prematurely. For each element in each input sequence, we updated the hidden state h_t as follow:

$$\begin{aligned}
 f_t &= \sigma(W_{f,x} x_t + W_{f,h} h_{t-1} + b_f) \\
 \tilde{s}_t &= \tanh(W_{s,x} x_t + W_{s,h} h_{t-1} + b_s) \\
 i_t &= \tanh(W_{i,x} x_t + W_{i,h} h_{t-1} + b_i) \\
 s_t &= f_t \otimes s_{t-1} + i_t \otimes \tilde{s}_t \\
 o_t &= \sigma(W_{o,x} x_t + W_{o,h} h_{t-1} + b_o) \\
 h_t &= o_t \otimes \tanh(s_t)
 \end{aligned} \tag{3}$$

with x_t is the first vector at each time step, $W_{f,x}$, $W_{f,h}$, $W_{s,x}$, $W_{s,h}$, $W_{i,x}$, $W_{i,h}$, $W_{o,x}$, $W_{o,h}$ are the weight matrices; b_f , b_s , b_i , and b_o are bias vectors; f_t , i_t , and o_t contains activation values for the forget gate, input gate and output gate, respectively; and h_t is the latent state at time t . We denote $\bar{h}_t$ as the average of the two hidden state vectors, which is served as the input for the attention layers. For each input vital sign, we measure the important information at each time point t as follow:

$$e_{i,j} = U_j a(W_j \overline{h_{t,j}} + b_j) \quad (4)$$

with a is the rectified linear unit. Next, we calculate the attention weights assigned to the hidden states as follow:

$$\alpha_{t,j} = \frac{\exp(e_{t,j})}{\sum_{t=1}^T \exp(e_{t,j})} \quad (5)$$

and the final context vector is calculated as follow:

$$z_j = \sum_{t=1}^T \alpha_{t,j} \overline{h_{t,j}} \quad (6)$$

Then, this context vector is processed by two dense layers for detecting the abnormal status and forecasting vital signs.

3. Objective function

To solve the imbalance problem, we utilize the focal loss as the final objective function for the abnormal detection task. It is an extension of the common cross-entropy loss with a scaling factor that can down-weight the effect of samples in the majority class and focus the model on hard samples. The focal loss can be expressed as follows:

$$L_{clinical} = -\alpha_t (1 - \rho_t)^\gamma \log(\rho_t) \quad (7)$$

with ρ_t is the predicted probability, $(1 - \rho_t)^\gamma$ is the scaling factor, α_t is the weighting parameter. For the vital signs forecasting, we apply the mean square error (MSE). It is noted that we exclude the inputted missing data when calculating the loss function by using the masking vector M . The loss function for vital signs forecasting is as follow:

$$L_{vs} = \sum_{t=1}^T (x_{t+1} \odot m_{t+1} - \tilde{x}_{t+1} \odot m_{t+1})^2 \quad (8)$$

with $\tilde{x}$ is the predicted vital signs. The final loss function is expressed as:

$$L_{final} = L_{clinical} + L_{vs} \quad (9)$$

IV. Experiments

In this section, we aim to evaluate our proposed attention BiLSTM (ABiLSTM) for clinical deterioration prediction on a practical healthcare dataset. This research was permitted by the Independent Institutional Review Board (IRB) of Chonnam National University Hospitals. The primary database used for the experimental is licensed patient data provided by Chonnam National University Hwasun Hospital's doctors. The dataset contains the information of 2,615 patients from two hospitals. The main types of features include demographic, vital signs, and laboratory tests. There are four vital signs: systolic blood pressure (SBP), heart rate (HR), respiration rate (RR), and Oxygen saturation (SaO2), which are measured every hour. The laboratory tests contain information collected from patients' blood, including alanine transaminase (ALT), blood urea nitrogen (BUN), aspartate aminotransferase (AST), the white blood cells count (WBC count), C-reactive protein (CPR), albumin, lactate, total protein, platelet, hemoglobin (Hgb), Alkaline phosphatase, Total calcium, Total bilirubin, Creatinine, Glucose, Sodium, Chloride, Potassium. The dataset is imbalance with only 41 patients with events (1.5%).

The experiments are carried out in PyTorch using the Adam optimizer and a learning rate of 0.0001. We also apply five-fold cross validation for training to present the generalization of the model. We use the original CNUH dataset with the total of 317,006 time points but only 1,042 abnormal time points.

In this paper, we present an evaluation of our proposed ABiLSTM and compare the performance with some other state-of-the-art model for time-series forecasting. As we describe in previous sections, we perform the experiment with input window sizes $n \in \{8, 12, 24\}$. The two evaluation metrics that we use to estimate the performance of the models are the area under the receiver operating characteristic curve (AUROC) and the area under the precision-recall curve (AUPRC), which represent well the minority class in an imbalance dataset [31]. Table 1 shows the performance of our model on the CNUH dataset compared with other approaches having different lengths of input sequences. It is obvious that the proposed method outperforms the others on both metrics. The table also indicates that the input

Table 1. Clinical status prediction results with different input length

Model	8 hours		12 hours		24 hours	
	AUROC	AUPRC	AUROC	AUPRC	AUROC	AUPRC
LSTM	0.86 ± 0.02	0.70 ± 0.04	0.87 ± 0.05	0.69 ± 0.04	0.75 ± 0.07	0.65 ± 0.06
Transformer	0.89 ± 0.06	0.79 ± 0.09	0.89 ± 0.04	0.80 ± 0.07	0.81 ± 0.07	0.67 ± 0.05
BiLSTM	0.88 ± 0.06	0.77 ± 0.05	0.90 ± 0.08	0.79 ± 0.05	0.83 ± 0.06	0.68 ± 0.07
ABiLSTM	0.92 ± 0.07	0.81 ± 0.03	0.95 ± 0.04	0.83 ± 0.02	0.87 ± 0.09	0.79 ± 0.05




Figure 3. Two prediction result samples

sequence length of 12 hours achieves the best results, whereas the input sequence of 24 hours generally shows a poor performance. It can be inferred from the experiment results that the input window time length of 24 hours is too long for the model to learn the time-series correlations effectively, whereas the window size of 8 hours is too short to capture all the necessary information.

We also visualize some prediction results samples in Fig. 3. It is shown that the proposed ABiLSTM performs better than the other models, and it generally returns high probabilities for abnormal time points. The figures also indicate the stability of our approach at low late alarm rates meanwhile other methods usually capture the positive status later.

Table 2 presents the vital signs forecasting results, in terms of the mean absolute error (MAE). It is shown that our proposed model also achieves good performance for this task with low MAE in all of the vital signs.

Table 2. Vital signs prediction results

Vital sign	MAE
HR (bpm)	7.24 ± 1.6
RR (bpm)	1.02 ± 0.3
SBP (mmHg)	5.47 ± 1.07
SaO2 (%)	5.29 ± 0.96

V. Conclusion

In this paper, we propose a DL-based framework for clinical deterioration prediction attention bi-direction network. It is obvious that the reason for the outstanding performance of ABiLSTM is the contribution of the more comprehensive representations some from both forward and backward path of the Bi-direction network. In addition, the attention mechanism enhances the interpretability of our model by emphasizing the parts of multivariate time-series that are most relevant to the final prediction. Whenever there is an abnormal change among features, the attention mechanism captures the abnormal correlations to speculate that an incident has occurred with the patient. Therefore, it can deal with many complex circumstances in multivariate time-series.

■ Reference

- [1] B. C. Sun, R. Y. Hsia, R. E. Weiss, D. Zingmond, L. J. Liang, W. Han, H. McCreath, and S. M. Asch, "Effect of emergency department crowding on outcomes of admitted patients," *Annals of emergency medicine*, vol. 61, no. 6, pp. 605-611, 2013.
- [2] E. C. Stecker, K. Reinier, E. Marijon, K. Narayanan, C. Teodorescu, A. Uy-Evanado, K. Gunson, J. Jui, and S. S. Chugh, "Public health burden of sudden cardiac death in the United States," *Circulation: Arrhythmia and Electrophysiology*, vol. 7, no. 2, pp. 212-217, 2014.
- [3] R. Graham, M. A. McCoy, and A. M. Schultz, "Current status and future directions: board on health sciences policy; institute of medicine," *Strategies to Improve Cardiac Arrest Survival: A Time to Act*. Washington, DC: National Academic Press, 2015.
- [4] T. J. Hodgetts, G. Kenward, I. G. Vlachonikolis, S. Payne, and N. Castle, "The identification of risk factors for cardiac arrest and formulation of activation criteria to alert a medical emergency team," *Resuscitation*, vol. 54, no. 2, pp. 125-131.
- [5] V. M. Nadkarni et al., "First documented rhythm and clinical outcome from in-hospital cardiac arrest among children and adults," *JAMA*, vol. 295, no. 1, pp. 50-57, 2006.
- [6] W. Hong, A. Earnest, P. Sultana, Z. Koh, N. Shahidah, and M. E. H. Ong, "How accurate are vital signs in predicting clinical outcomes in critically ill emergency department patients," *European Journal of Emergency Medicine*, vol. 20, no. 1, pp. 27-32, 2013.
- [7] R. M. Merchant et al., "Incidence of treated cardiac arrest in hospitalized patients in the United States," *Critical care medicine*, vol. 39, no. 11, pp. 2401-2406, 2011.
- [8] E. J. Benjamin et al., "Heart disease and stroke statistics-2017 update: a report from the American Heart Association," *Circulation*, vol. 135, no. 10, pp. e146-e603, 2017.
- [9] J. P. Nolan, J. Soar, A. Cariou, T. Cronberg, V. R. Moulaert, C. D. Deakin, B. W. Bottiger, H. Friberg, K. Sunde, and C. Sandroni, "European resuscitation council and European society of intensive care medicine 2015 guidelines for post-resuscitation care," *Intensive care medicine*, vol. 41, pp. 2039-2056, 2015.
- [10] D. A. Jones, M. A. DeVita, and R. Bellomo, "Rapid-response teams," *New England Journal of Medicine*, vol. 365, no. 2, pp. 139-146, 2011.
- [11] S. L. Kronick, M. C. Kurz, S. Lin, D. P. Edelson, R. A. Berg, J. E. Billi, J. G. Cabanas, D. C. Cone, D. B. Diercks, J. Foster, R. A. Meeks, A. H. Travers, and M. Welsford, "Part 4: systems of care and continuous quality improvement: 2015 American Heart Association guidelines update for cardiopulmonary resuscitation and emergency cardiovascular care," *Circulation*, vol. 132, no. 18_suppl_2, pp. S397-S413, 2015.
- [12] G. B. Smith, D. R. Prytherch, P. E. Schmidt, and P. I. Featherstone, "Review and performance evaluation of aggregate weighted 'track and trigger' systems," *Resuscitation*, vol. 77, no. 2, pp.

- 170-179, 2008.
- [13] S. Romero-Brufau, J. M. Huddleston, J. M. Naessens, M. G. Johnson, J. Hickman, B. W. Morlan, J. B. Jensen, S. M. Caples, J. L. Elmer, J. A. Schmidt, T. I. Morgenthaler, and P. J. Santrach, "Widely used track and trigger scores: are they ready for automation in practice?," *Resuscitation*, vol. 85, no. 4, pp. 549-552, 2014.
 - [14] Royal College of Physicians, "National Early Warning Score (NEWS) 2: standardising the assessment of acute-illness severity in the NHS: Additional Implementation Guidance," *London: RCP: Royal College of Physicians*, 2017.
 - [15] J. Kim, Y. R. Park, J. H. Lee, J. H. Lee, Y. H. Kim, and J. W. Huh, "Development of a real-time risk prediction model for in-hospital cardiac arrest in critically ill patients using deep learning: retrospective study," *JMIR Medical Informatics*, vol. 8, no. 3, e16349, 2020.
 - [16] H. C. Thorsen-Meyer, A. B. Nielsen, A. P. Nielsen, B. S. Kass-Hansen, P. Toft, J. Schierbeck, T. Strøm, P. J. Chmura, M. Heimann, L. Dybdahl, L. Spangsege, P. Hulsén, K. Belling, S. Brunak, and A. Perner, "Dynamic and explainable machine learning prediction of mortality in patients in the intensive care unit: a retrospective study of high-frequency data in electronic patient records," *The Lancet Digital Health*, vol. 2, no. 4, pp. e179-e191, 2020.
 - [17] S. L. Hyland, M. Faltys, M. Hüser, X. Lyu, T. Gumbsch, C. Esteban, C. Bock, M. Horn, M. Moor, B. Rieck, M. Zimmermann, D. Bodenham, K. Borgwardt, G. Rätsch, and T. M. Merz, "Early prediction of circulatory failure in the intensive care unit using machine learning," *Nature medicine*, vol. 26, no. 3, pp. 364-373, 2020.
 - [18] J. M. Kwon, Y. Lee, Y. Lee, S. Lee, and J. Park, "An algorithm based on deep learning for predicting in-hospital cardiac arrest," *Journal of the American Heart Association*, vol. 7, no. 13, e008678, 2018.
 - [19] A. Rajkomar, E. Oren, K. Chen, A. M. Dai, N. Hajaj, M. Hardt, P. J. Liu, X. Liu, J. Marcus, M. Sun, P. Sundberg, H. Yee, K. Zhang, Y. Zhang, G. Flores, G. E. Duggan, J. Irvine, Q. Le, K. Litsch, A. Mossin, J. Tansuwan, D. Wang, J. Wexler, J. Wilson, D. Ludwig, S. L. Volchenboum, K. Chou, M. Pearson, S. Madabushi, N. H. Shah, A. J. Butte, M. D. Howell, C. Cui, G. S. Corrado, and J. Dean, "Scalable and accurate deep learning with electronic health records," *NPJ digital medicine*, vol. 1, no. 1, 18, 2018.
 - [20] D. H. Jang, J. Kim, Y. H. Jo, J. H. Lee, J. E. Hwang, S. M. Park, D. K. Lee, I. Park, D. Kim, and H. Chang, "Developing neural network models for early detection of cardiac arrest in emergency department," *The American journal of emergency medicine*, vol. 38, no. 1, pp. 43-49, 2020.
 - [21] F. E. Shamout, T. Zhu, P. Sharma, P. J. Watkinson, and D. A. Clifton, "Deep interpretable early warning system for the detection of clinical deterioration," *IEEE journal of biomedical and health informatics*, vol. 24, no. 2, pp. 437-446, 2019.
 - [22] M. Sung, S. Hahn, C. H. Han, J. M. Lee, J. Lee, J. Yoo, J. Heo, Y. S. Kim, and K. S. Chung,

- "Event prediction model considering time and input error using electronic medical records in the intensive care unit: Retrospective study," *JMIR medical informatics*, vol. 9, no. 11, e26426, 2021.
- [23] Z. C. Lipton, J. Berkowitz, and C. Elkan, "A critical review of recurrent neural networks for sequence learning," *arXiv preprint*, arXiv:1506.00019, 2015.
- [24] E. Choi, M. T. Bahadori, L. Song, W. F. Stewart, and J. Sun, "GRAM: graph-based attention model for healthcare representation learning," In *Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, Halifax, NS, Canada, 2017, pp. 787-795.
- [25] C. Yin, R. Zhao, B. Qian, X. Lv, and P. Zhang, "Domain knowledge guided deep learning with electronic health records," In *Proceedings of the 2019 IEEE International Conference on Data Mining (ICDM)*, Beijing, China, 2019, pp. 738-747.
- [26] L. J. Liu, V. Ortiz-Soriano, J. A. Neyra, and J. Chen, "Kgdl: knowledge graph guided double attention lstm for rolling mortality prediction for aki-d patients," In *Proceedings of the 12th ACM Conference on Bioinformatics, Computational Biology, and Health Informatics*, Houston, TX, USA, 2021, pp. 1-10.
- [27] P. Velickovic, G. Cucurull, A. Casanova, A. Romero, P. Lio, and Y. Bengio, "Graph attention networks," In *Proceedings of the 6th International Conference on Learning Representations*, Vancouver, Canada, 2018.
- [28] M. A. Ahmad, C. Eckert, and A. Teredesai, "Interpretable machine learning in healthcare," In *Proceedings of the 2018 ACM International Conference on Bioinformatics, Computational Biology, and Health Informatics*, Washington DC, USA, 2018, pp. 559-560.
- [29] P. Chen, W. Dong, J. Wang, X. Lu, U. Kaymak, and Z. Huang, "Interpretable clinical prediction via attention-based neural network," *BMC Medical Informatics and Decision Making*, vol. 20, no. 3, pp. 1-9, 2020.
- [30] C. Dos Santos and M. Gatti, "Deep convolutional neural networks for sentiment analysis of short texts," In *Proceedings of COLING 2014, the 25th International Conference on Computational Linguistics: Technical papers*, Dublin, Ireland, 2014, pp. 69-78.
- [31] J. Kong, W. Kowalczyk, S. Menzel, and T. Bäck, "Improving imbalanced classification by anomaly detection," In *Proceedings of International Conference on Parallel Problem Solving from Nature*, Leiden, Netherlands, 2020, pp. 512-523.



기업의 기업가적 지향성 연구 동향 분석

A Review of Research Topic Trend on Corporate Entrepreneurial Orientation

주창림^{1*}

¹이화여자대학교 기업가센터

Changlim Joo^{1*}

¹Center for Entrepreneurship, Ewha Womans University

요 약

기업가정신은 기회발굴을 통한 기업의 성장과 발전을 위한 토대로, 경제 성장 및 변화의 동력이다. 하지만, 기업가정신에 대한 정의와 영역은 계속 발전 및 성장하고 있어, 이에 대한 개념정립이 필요하다. 본 연구에서는 기업가적 지향성 개념을 활용하여 기업가정신의 연구트렌드와 방향성을 검토하여, 향후 연구 발전방향에 대해서 검토한다. 이를 위해 비정형 빅데이터, 특히 언어부분에 활용되는 텍스트마이닝 기법을 활용하여, 1983년 이후부터 기업가정신 지향성 관련 논문의 초록을 분석하였다. 이를 통해 4개 구간으로 연구주제를 검토하여 8개 분야의 연구주제와 주요 단어를 도출하였다. 이를 통해, 기업가적 지향성이 개인보다 조직, 기업에 중점을 두고 있음을 파악할 수 있다. 기업가적 지향성은 과거 기업의 선택하는 전략적 지향성 중 하나에서 생존을 위해 기업가정신을 반영해야 하는 필수적 요소로 인식됨을 확인할 수 있다. 결과적으로 혁신에 기반한 생존 그리고 성장과 발전에 대한 영역이 기업가적 지향성 관련 연구의 주제가 되어가고 있다. 본 연구는 구간별 누적 데이터를 통해 기업가적 지향성 관련 연구에 대한 전체 시점의 연구를 파악할 수 있었지만, 최근 시점의 주요 연구주제를 파악하기 위해서는 별도의 구간별 데이터 정리가 필요하다.

주제어: 기업가정신 지향성, 비정형 빅데이터, 토픽 모델링

* Corresponding Author: Changlim Joo (cl33@ewha.ac.kr)

Abstract

Entrepreneurship is a foundation for corporate growth and development through the discovery of opportunities, and an engine of economic growth and change. However, as the research scope of entrepreneurship continues to develop and grow, it is necessary to establish the definition. In this study, we examine the research trends and directions of entrepreneurship using the concept of entrepreneurial orientation, and consider the direction of future research development. For this purpose, we used unstructured(atypical) big data, especially the text mining technology used for the language part, and analyzed abstracts of articles related to entrepreneurial orientation from 1983 onwards. As a result, research themes were examined in four period sections, and research themes and main words were derived in eight fields. This makes it possible to understand that entrepreneurial orientation places more emphasis on organizations and companies than on individuals. In addition, it can be confirmed that the entrepreneurship has changed from the strategic selection area of the company to the essential survival factor. As a result, the area of innovation-based survival, growth, and development has become the subject of entrepreneurial orientation-related research. In this study, we were able to grasp research from all perspectives on entrepreneurial orientation-related research through cumulative data for each period. It is necessary to reorganize the data as each section in order to grasp the major research topics as the recent point in time.

Keyword: Entrepreneurial orientation, Unstructured(atypical) big data, Topic modeling

1. 서론

기업가정신 관련 연구는 경제학의 공급 측면의 성장을 설명하는 동인으로 시작되어, 기업의 조직 연구 분야에서 계속 발전 및 성숙되어 가고 있다[1]. 기업가정신에 대한 연구 분야는 1970년대의 석유파동, 경제침체, 급격한 기술진보 그리고 국제 경제통상의 증가와 같은 국제적인 시대 변화에 따라 파생된 불확실성의 증가가 주요 원인으로 이 분야의 연구가 급격히 증가하였다[2]. 이는 기업가는 공급측면의 한 축인 기업을 창출 및 관리하면서 경제의 성장을 이루는 동인이기 때문이다[3-5].

기업가정신 연구 분야는 기업가정신에 대한 다양한 주제 정의로 인해 개념적으로 여전히 발전되어 가고 있는 분야로 이는 연구의 성장과 확장에 도움이 되지만, 반대로 정의의 불명확성으로 인해 연구 영역과 주제의 혼재의 문제를 가져온다[2]. 그나마 기업가정신의 연구 영역 중 기업가적 지향성(Entrepreneurial Orientation, EO)을 중심으로 하거나 활용한 연구는 EO가 개념적으로 잘 정립되어 실증연구 분야에서 상

당히 앞서 나아가고 있다[1]. 이에 따라, EO 연구는 기업가정신 연구 영역에서 중심개념이 되어, 실증적인 연구를 비롯하여 이론적인 분야에서도 상당한 관심을 받아왔다[6].

현 시점에서 누적된 기업가정신 분야의 연구를 통해, 기업가정신의 개념을 정립하거나 혹은 정립방향을 제시할 필요가 있으며, 이 중 개념적으로 정립이 명확한 EO에 대한 연구주제와 연구 트렌드에 대한 조사와 연구는 이에 부응할 수 있다. 따라서, EO의 발전과정을 통해 기업가정신 연구의 주제와 정의에 대해서도 좀 더 보편적인 정의가 수립될 수 있도록 하는데 필요한 준거점을 제시할 연구가 필요하다. 또한, EO는 기업가가 아닌 기업을 대상으로 진행하는 연구이기 때문에 기업을 대상으로 한 기업가정신 관련 연구의 트렌드를 살펴보는 데도 도움이 된다. 이에 맞추어 EO의 개념적 정의를 살펴보고, 연구 주제와 트렌드를 살펴보고자 한다.

미래 예측과 트렌드 등 동향 분석을 위해서 활용되는 일반적인 방식은 전문가를 활용하는 방법이다. 대표적인 방식이 델파이(Delphi) 기법이다. 이는 Rand Corporation에서 미래 기술 예측을 위해 개발되어 다양한 형태로 발전하여 활용된 방식으로 전문가를 활용하면서도 좀 더 객관화할 수 있는 과정을 거치게 된다[7]. 델파이 기법은 전문가들의 지식을 활용하면서도 해당 의견을 집약할 수 있기 때문에 다양한 영역에서 폭 넓게 활용할 수 있지만, 수차례의 의견 취합 시도를 거쳐 진행함에 따라 복잡하고 시간과 비용에 있어서도 상당한 수준이 소요된다. 또한 참여하는 전문가들의 인식의 차이와 의견에 대한 합의 그리고 개별 영향력으로 인해 왜곡이 일어날 수 있어서 이의 활용에는 상당히 엄격한 절차와 정확성이 요구된다[7, 8].

전문가의 의견에 의존하는 방식에 더하여 객관적인 분석을 진행하는 방식으로, 전문가의 지식이 녹아든 문헌을 통해 연구의 트렌드 등 동향을 분석하는 방식으로 키워드 분석, 인용 분석, 군집 분석, 네트워크 분석 방식을 적용하는 계량형 서지분석이 선호되고 있다. 왜냐하면, 질적 분석은 비용과 시간의 문제로 인해 양적 근거가 부족한 점을 극복할 수 있기 때문이다. 하지만, 이 역시도 거시적인 관점의 맥락을 고려한 연구가 미비한 편이다[9].

최근에는 데이터의 빅데이터화 및 비정형화 데이터의 한계를 극복하는 방법론이 발전함에 따라 전문가에 완전히 의존하는 정성적인 질적 분석의 약점을 극복할 수 있게 되었다. 또한, 대량의 문서들에서 숨겨져 있는 주제를 찾아내는 통계적 방법론이 출현하면서 질적인 데이터를 활용한 양적인 분석이 가능하게 되었다. 이런 대표적인 방식 중 하나가 텍스트마이닝 기법의 하나인 토픽 모델링(Topic Modeling) 분석이다. 토픽 모델링은 구조화되지 않은 방대한 양의 빅데이터를 활용한다. 특히 텍스트 정보에 숨겨진 주제들을 추론하여 핵심 주제를 탐색하는데 주로 활용된다[10]. 이런 토픽 모델링 기법 중 주제들을 도출하기 위해서 Dirichlet 분포를 기반으로 한 확률모형으로 특정 주제를 찾아내는 Latent Dirichlet Allocation(이하 LDA) 기법이 많이 활용되고 있다.

본 연구는 1차적으로 EO 연구에 나타나는 주요 단어들을 빈도분석과 워드 클라우드를 통한 시각화를 통해 살펴본 후 LDA를 통해 각 주제에 변화에 대해서 실증분석을 실시한다.

II. 이론적 배경 및 분석 방법론

1. EO의 개념적 정의

다양한 조직에서 보편적으로 사용할 수 있는 조직구조를 측정할 수 있는 규격화된 척도를 개발하려는 1960년대의 Aston Group의 연구와 1970년대 기업의 상황을 측정하는데 더해서 기업의 정책 등 기업의 유형과 그에 맞춘 전략을 결합한 McGill Group의 연구에 따라 EO의 개념적 토대가 마련되었다. 그 후 Miller (1983)[11]의 연구를 통해 EO의 척도가 개념적으로 제시되어 연구되기 시작했다. 이 연구를 통해 기업가정신 연구의 초점이 개인뿐만 아니라 기업으로 확대되었다[1].

초기 창업기업이건 기존의 성장기업이건 간에 기업가정신은 기회발굴을 통한 기업의 성장과 발전을 위한 기술적 토대가 된다[12]. 경제학에서 중소기업은 경제시스템 내에서 특히, 고용과 성장 측면에서 중요한 역할을 담당하고 있으며, 기업가정신은 이런 중소기업에 특별히 중요한 역할을 담당하고 있다[13, 14]. 왜냐하면, 급격한 환경변화와 경쟁의 심화는 중소기업이 기업가정신 발현을 통해 혁신적 역량의 증가를 가져올 새로운 방법을 찾도록 유도하기 때문이다[15]. 이에 따라, 비록 기업가정신에 대한 연구가 개인에서 시작되었지만, 확대되어 혁신적인 조직을 대상으로 성장하고 있다[2, 16]. 결과적으로 이런 기업의 기업가정신을 제시하는 개념에 대한 연구가 EO이다[2]. 이런 기업의 기업가적인 지향성 즉 기업가적으로 행동하는 정도를 나타내는 지표가 EO인 것이다[11, 12, 14, 17-20]. 결과적으로 EO는 기업의 의사결정을 하는 성향과 스타일에 따라 나타남에 따라 기업의 변화 동인으로 전략과 문화에 초점을 두고 있다[21-23].

이런 EO에 대한 개념을 최초로 정립한 Miller (1983)[11]는 기업의 기업가적 특징 그리고 제품 시장 혁신과 어느 정도 위험을 감수하는지 여부 그리고 경쟁자에 비해 혁신을 통해 선도적으로 활동하는 3가지 개념이 맞물린 개념으로 정리했다(p. 771). 이런 밀러의 연구를 통해 EO는 혁신성(Innovativeness), 위험의 감수(Risk-Taking), 그리고 선도성(Proactiveness)의 3가지 개념으로 구성됨을 알 수 있다[6, 11, 12, 17, 22, 24-26]. 그 후 Lumpkin과 Dess [27]의 주장에 따라 EO를 구성하는 동인의 발현요소가 추가된 5가지 구성요소에 대한 부분과 EO를 단일차원으로 볼 것인지, 아니면 EO를 구성하는 각 요소별로 구분하여 볼 것인지에 대한 부분, 즉 EO의 차원성에 대한 논쟁이 발생하여 연구의 폭을 넓히고 있다[1].

2. 텍스트마이닝과 토픽 모델링

텍스트는 언어의 특징과 같이 비정형적이며 변화가 많다. 이에 따라 다양한 정보를 갖추고 있어, 전개되는 내용 상호간의 공통적인 맥락이 없으면 이해가 어렵다. 따라서 이러한 비정형적인 데이터로부터 일상적이지 않으며, 흥미로운 주제를 객관적으로 추출하는 작업을 텍스트마이닝 (Text Mining) 이라 한다[28]. 내재된 정보를 바탕으로 패턴 혹은 관계를 파악하기 위해 텍스트를 구성하는 주요 어휘(Word) 중 단어(Token)에 집중하여 그 출현 빈도 등을 파악하고 이를 시각화하는 방식으로 분석이 진행되고 있다.

토픽 모델링은 구조화되지 않은 방대한 문헌 집단을 구성하는 비정형 텍스트에 존재하는 주제 그리고 대

상 문서 내에 내재한 주제를 찾아내는 알고리즘을 의미한다. 같은 맥락에서 나타날 수 있는, 그리고 같은 비슷한 주제를 나타내는 단어들을 하나의 군으로 묶어주는 그룹화(Grouping)하는 것을 주제화라고 하며, 이때 맥락과 관련된 단어들을 이용해서 유사한 의미를 가지고 있는 단어들을 클러스터링 하는 방식이 토픽 모델링이다. 이미 출현하는 단어들의 빈도 분석 등을 통해 문헌 내의 용어분포는 알 수 있지만, 주제들의 용어 분포는 사전에 알 수 없다. 해당 문제를 해결하기 위해 가정이 필요하고, 각 문헌들에서 관찰이 가능한 용어 분포로부터 주제의 용어 분포를 추정하는 단계가 필요하다. 각 단어들은 문헌 내에 잠재적 Dirichlet 확률 분포를 가지고 있다는 이론 하에 토픽 모델링을 하는 작업이 LDA이다[29].

III. 연구 방법

1. 분석 개요

1983년 이후 출간된 기업가적 지향성에 대한 논문에 대해 검색하여 논문 발간 현황을 우선 살펴본다. 그 후 해당 논문들의 초록(Abstract)을 확보하고, 해당 초록에 등장하는 단어들에 대한 빈도 분석을 R을 통해 진행한다. 그 후 토픽 모델링을 위해 Mallet 기반의 y-text-miner를 통해 주제 분류를 진행한다.

각각의 분석은 연도별 구간을 설정하여, 각각의 기간별 비교를 진행한다. 이를 통해, 기간별 변화를 살펴본다.

2. 데이터 개요 및 분석 구간

KAIST가 구독하는 ProQuest (<https://www.proquest.com>)를 통해 자료를 확보하였다. 해당 DB는 학술 전 분야에 걸친 주요 학술 저널의 데이터베이스로, 해당 저널에서 구독하는 분야는 의학(생명과학), 공학, 과학, 인문학, 사회과학 분야 등 전 분야의 저널 자료 4,000여 종으로 SCI, SSCI, SCIE 등록 저널 다수를 포함하고 있다. 해당 DB에서 초록상 기업가적 지향성을 주요 키워드를 통해 추출하였으며, 논문에 있어서도 Peer Reviewed 저널에 한하였다. 또한 저널 종류도 scholarly journals로 정했으며, 그 중 영문의 article로 한정하여 자료를 확보하였다. 이 중 중복된 문건을 제외하고 EO의 개념이 출현한 1983년 Miller [11]의 연구 이후부터 2019년까지 출간된 논문 1,534건의 논문 초록을 확보하여 해당 문헌 내용을 분석하였다.

연도별 간행되는 논문의 변화를 살펴보면 Fig. 1과 같이 EO의 개념이 성립된 1983년 이후로 서서히 증가하다가 2000년대 중반부터 관련 연구가 증가함을 알 수 있다. 연구 트렌드의 변화를 누적된 결과로 봄으로써 시작부터 해당기간까지 전부를 볼 수 있기 때문에, 전체 현상과 변화를 하기 위해서 전체 누적 논문의 대략 50% 미만인 구간을 설정하여 분석한다.

Fig. 1과 Table 1에 나타난 바와 같이 확보한 DB의 상 2004년 이후 5년마다 2배 이상의 관련 논문이 출현하고 있음을 알 수 있다. 이에 따라, 구간 1은 2004년까지, 구간 2는 2009년까지, 구간 3은 2014년까지, 구간 4는 전체구간인 2019년까지로 설정하였다.




Figure 1. Published papers by year

IV. 분석 결과 및 결론

1. 분석 결과 및 시사점

a) 단어 출현 빈도

연도별 간행 논문의 현황을 살펴보면, 2004년 이후 매5년마다 과거의 논문 수 이상이 나타나고 있다. 이를 보면, 기업가적 지향성과 관련된 주제의 연구 혹은 기업가적 지향성을 요인으로 활용한 연구의 증가가 기하급수적으로 늘어나는 시점임을 알 수 있다.

Table 1. Published papers by ranges of years

구분 연도	해당기간 논문수	비율	누적 논문수	누적 비율
1983~2004	131	8.54%	131	8.54%
1983~2009	201	13.10%	332	21.64%
1983~2014	385	25.10%	717	46.74%
1983~2019	817	53.26%	1,534	100%




Figure 2. Most frequent word
(~2004, top 100).




Figure 3. Most frequent word
(~2009, top 100).




Figure 4. Most frequent word
(~2014, top 100).




Figure 5. Most frequent word
(~2019, top 100).

출현 단어의 빈도분석을 살펴보면 구간별로 Figs. 2-5와 같다. 상기에 표기된 Figs. 2-5는 각 구간별로 출현빈도가 가장 높은 100개의 단어를 표기한 것이다. 다음의 Table 2는 각 구간별 상위 20개의 단어의 현황을 표시하였다.

기업가적 지향성 관련 단어가 계속 상위를 차지하고 있다. 하지만, 기업보다 개인에 중점을 두는 기업가(entrepreneur)의 출현 빈도의 비율은 꾸준히 하락(8위 → 11위 → 16위 → 20위권 외)하는 것을 볼 수 있다. 그 외에 기업의 전략적 성향을 반영하는 지표이기 때문에 기업에 대한 단어(3위 및 6위 → 4위 및 10위 → 6위 및 8위 → 7위 및 9위)와 전략과 관련된 단어(16위 → 16위 → 19위 → 17위)는 상대적으로 큰

변화없이 유지되고 있다. 그 외에 실증조사에 많이 활용됨에 따라 기업의 성과 관련 단어가 상대적으로 상위로 진출한 후 꾸준히 출현하고 있다(14위 → 6위 → 4위 → 5위). 그 외에 시장 관련 단어가 2009년부터 출현하여 조금씩 순위가 상승(20위 순위권 외 → 19위 → 17위 → 16위)하고 있으며, 기업가적 지향성의 한 부분을 차지하고 있는 혁신(innovation)이 독립적으로 2014년까지의 연구에 출현한 후 급하게 출현빈도가 성장(20위 순위권 외 → 20위 순위권 외 → 20위 → 14위)하고 있다.

Table 2. The top-20 frequent words for each range of years

~2004년		~2009년		~2014년		~2019년	
단어	빈도	단어	빈도	단어	빈도	단어	빈도
entrepreneurial	238	entrepreneurial	718	entrepreneurial	1,610	entrepreneurial	3,744
orientation	175	orientation	545	orientation	1,260	orientation	2,932
firms	105	study	287	eo	749	eo	2,042
study	91	firms	260	performance	728	study	2,040
business	75	eo	255	study	707	performance	1,981
firm	68	performance	242	firms	606	research	1,451
management	62	research	233	research	562	firms	1,248
entrepreneurs	61	entrepreneurship	205	firm	519	entrepreneurship	1,167
entrepreneurship	61	business	200	entrepreneurship	484	firm	1,135
eo	61	firm	192	abstract	435	paper	1,029
research	59	entrepreneurs	171	publication	432	relationship	968
managers	54	publication	169	business	394	business	939
marketing	52	abstract	168	paper	391	results	779
performance	52	paper	153	relationship	337	innovation	764
results	48	management	141	results	309	findings	752
strategic	47	strategic	138	entrepreneurs	298	market	663
orientations	45	results	136	market	297	strategic	656
organizational	42	small	135	small	286	small	649
paper	42	market	132	strategic	286	social	622
characteristics	40	relationship	120	innovation	271	smes	611
누적 문헌수	131	누적 문헌수	332	누적 문헌수	717	누적 문헌수	1,534

b) 주제 분류 및 변화

LDA를 통해 주제를 선별하기 위해 선행되어야 하는 작업이 주제 분류의 수를 결정하는 것이다. 이는 연구자가 사전에 결정하는 것이기 때문에 대량의 문헌의 주제 분류에 있어서 적절한 수의 주제를 찾아야만 한다. 이에 따라, 4종, 6종, 8종, 10종, 12종의 주제 분류별 주요 단어를 각각 10개씩 선별하는 작업을 진행하였다. LDA의 특성상 분류 주제의 수를 설정함에 있어, 임의로 설정한 후 해당 주제를 다시 도출해야 한다. 이에 따라, 분류된 단어의 구성을 보고 주제를 도출해야 한다. 하지만, 해당 방법론의 한계 상 주제 선

정에 대해 이견이 발생할 여지가 있다. 다만, 해당 연구에서는 4에서 12종까지의 6구간을 나눠 분류를 진행한 후 결과의 주안점을 둔 분류가 가능한 사항까지 진행하였으며, 다른 분류 단어의 내용까지 검토하였다. 5개의 주제 분류 내역 중 기업가정신 연구 관련 10년 이상의 전문가 3인과의 표적 집단면접 (Focus Group Interview, FGI)를 통해 8종으로 분류한 작업의 결과를 최종 선정하였다. 또한, LDA 분석을 통해 각 그룹에 배정된 주요 5~6개의 단어를 통해 주제 정의 작업을 진행하였다. 8종의 분류작업을 거쳤을 때, 그룹 내 주요 단어의 중복성, 주제 정의의 명확성 등에서 4개 구간 모두에서 문제가 가장 적은 형태임을 확인하였다. 이를 통해, 개인적인 주관에 배제할 수 있는 참고자료로 활용하여 이견의 여지를 줄일 수 있도록 노력했다. 또한, 분류의 다양화 과정을 통해, 분류 기준의 수가 많아질수록 주제간 주요 단어에서 중복 출현의 빈도가 줄어드는 것을 발견하였다. 하지만, 그 수가 늘어남에 따라 그다지 중요해 보이지 않는 단어가 주제별로 포함됨에 따라, 주제 선정에 있어 애로사항으로 작용하는 것을 발견하였다. 따라서, 기존에 주요 출현빈도 단어를 바탕으로 한 주제 명칭 작업에 있어서 뿐만 아니라 적절한 분류 기준의 수에 있어서도 전문가의 활용이 필요함을 다시 확인하였다. 이에 대한 최종 결과를 Tables 3-6에 제시하였다.

Table 3. Representative topics for eight research categories (~2004)

주제	경쟁 전략	개인과 성장 관리
관련단어	firm (81.00) strategic (34.00) marketing (31.00) business (30.00) technology (21.00) competitive (18.00)	manager (32.00) value (17.00) business (13.00) achievement (12.00) career (12.00) entrepreneurial behavior (11.00)
주제	건강 관련 산업 생태계	세대 변화
관련단어	service (13.00) health care (10.00) association (7.00) family (7.00) change (6.00) hospital (5.00)	post (18.00) secondary (9.00) start (9.00) chinese (9.00) distance education (8.00) traditional (7.00)
주제	일본 경제 성장	시장 중심 해외 진출
관련단어	japanese (22.00) economic (13.00) venture (13.00) development (11.00) start (9.00) growth (8.00)	market (17.00) market orientation (12.00) organizational (9.00) academic (7.00) foreign investment (5.00) direct foreign (4.00)
주제	다국적 사업	EO 연구

주제	경쟁 전략	개인과 성장 관리
관련단어	international (18.00) global (13.00) business (13.00) specific (12.00) framework (9.00) career (7.00)	firm (33.00) entrepreneurial orientation (31.00) research (30.00) relationship (28.00) study (27.00) performance (24.00)

Table 4. Representative topics for eight research categories (~2009)

주제	해외 지향적	개인 및 여성
관련단어	international (55.00) family (21.00) global (20.00) born (19.00) foreign (18.00) export (13.00)	manager (33.00) career (30.00) gender (23.00) woman (20.00) achievement (20.00) individual (20.00)
주제	경쟁 전략	사회적 서비스
관련단어	entrepreneurial (284.00) firm (212.00) strategic (110.00) market (105.00) organizational (83.00) business (83.00)	service (23.00) business (18.00) rural (17.00) entrepreneurship education (17.00) individual (15.00) social (15.00)
주제	기업 성장과 정부	지역 및 국가
관련단어	technology (46.00) start (24.00) company (23.00) growth (22.00) government (17.00) sbir (15.00)	indigenous (52.00) business (46.00) entrepreneurial attitude (36.00) cultural (24.00) country (23.00) self (23.00)
주제	영역별 기업가정신	연구 활동
관련단어	university (32.00) academic (20.00) private (18.00) social (18.00) institutional (15.00) public (14.00)	eo (201.00) firm (104.00) risk (72.00) study (70.00) relationship (69.00) performance (68.00)

Table 5. Representative topics for eight research categories (~2014)

주제	영역별 기업가정신	연구 활동
관련단어	university (78.00) country (64.00) entrepreneurial activity (41.00) national (39.00) institutional (37.00) level (36.00)	entrepreneurial (618.00) business (241.00) study (211.00) risk (196.00) relationship (139.00)
주제	지역 및 국가	성장 및 변화
관련단어	indigenous (60.00) japanese (28.00) venture (28.00) health (23.00) low (22.00) chinese (18.00)	service (55.00) career (42.00) value (37.00) growth (26.00) design (23.00) organizational (21.00)
주제	중소기업	개인 및 여성
관련단어	firm (387.00) performance (197.00) sme (140.00) relationship (129.00) family (121.00)	student (84.00) self (70.00) entrepreneurial attitude (50.00) gender (43.00) individual (37.00) woman (32.00)
주제	경쟁 전략	사회적 기업
관련단어	firm (395.00) market (247.00) strategic (190.00) marketing (130.00) innovation (123.00) career (7.00)	social (72.00) sustainable (32.00) economic (31.00) rural (26.00) post (25.00) performance (24.00)

Table 6. Representative topics for eight research categories (~2019)

주제	기업의 성과	사회 변화
관련단어	firm (703.00) performance (315.00) risk (295.00) relationship (222.00) level (199.00) proactiveness (198.00)	social (51.00) environment (41.00) visual (38.00) affordance (33.00) post (28.00) people (26.00)

주제	기업의 성과	사회 변화
주제	중소기업	가족기업과 해외시장
관련단어	firm (1002.00) sme (570.00) relationship (544.00) market (519.00) performance (465.00)	international (349.00) family (303.00) export (95.00) foreign (83.00) global (72.00)
주제	기술기반 혁신기업	국가 및 기관
관련단어	business (163.00) university (161.00) technology (136.00) public (102.00) economic (97.00) innovation (77.00)	country (89.00) national (67.00) cultural (65.00) indigenous (59.00) self (54.00) institutional (52.00)
주제	사회적 기업	EO 연구
관련단어	social (305.00) entrepreneurial (180.00) entrepreneurship (139.00) sustainable (127.00) sustainability (71.00)	study (388.00) individual (233.00) business (220.00) student (214.00) self (210.00) result (194.00)

전체적인 기간에 걸쳐 꾸준히 나타나는 주제는 해당 연구의 주제인 EO와 관련된 연구물에 대한 부분이다. 해당 주제에 대한 설명이 필요한 만큼 꾸준히 나타나고 있는 것으로 보인다.

기업의 경쟁전략 부문은 계속 나타났으나, 2019년 전체적인 연구부분에서는 전략 관련 단어가 주요 관련 단어에 사라졌다. 이는 기업가적 지향성이 기업의 전략적 선택이기 보다는 경쟁의 규모 증가와 함께 심화로 인해, 기업의 변화를 위한, 기업의 라이프 사이클을 변화시키는 혁신의 주요 동인[30]이기 때문에 최근 연구 주제에서 하위로 배치된 것으로 보인다. 이에 따라, EO의 시작점인 기업의 전략적 형태가 아닌, 기업의 전략적 형태를 취하는 근본적인 동인으로 기업가정신을 고찰해 봐야 할 시점으로 보인다.

도전적인 기업 중 대표적인 사례인 해외 지향적인 Born Global 형 기업에 대한 연구 역시 다국적 기업의 사례에서 점차 기업의 성장에 맞추어 가족기업과 Born Global 형 기업에 대한 연구로 진화한 형태로 주제가 변경됨을 알 수 있다. 또한, 특정 산업의 생태계 연구에서 점차 지역, 기관, 대학 등 혁신의 참여 주체와 함께 정부의 역할 등의 국가와 기관, 지역과 국가 등의 유사 주제가 계속 출현하고 있다.

기업의 성장과 성과와 관련된 연구는 2004년까지의 연구 결과물의 집계에서는 주제로 도출되지 않았으나, 2009년까지의 연구 성과부터 꾸준히 나타나고 있다. 하지만, 2019년 연구 성과의 주제를 이루는 요소로 선

도성(Proactiveness)이 제시될 정도로 세부 구성 요소가 다변화함을 보여주고 있다. EO 자체가 해당 주제에 상위에 관련 단어이나 제시 단어 축소 원칙에서 배제되었지만, 이를 통해 EO를 구성하는 차원에 대한 논쟁 중 하나인 EO의 다중차원 혹은 단일차원과 관련된 주제, 즉 EO를 구성하는 개별 요소 자체가 독립적인 요인이라는 주장[27]에 맞추어 다중차원 연구와 연계되어 출현한 것으로 보인다.

새롭게 나타나는 분야는 혁신의 기반인 신기술과 그의 생산자에 대한 부분으로 기술기반 혁신기업에 대한 분야가 2019년 전체 기간에는 나타남에 비해, 기존의 연구에서는 찾아보기 어렵다. 즉, 최근의 연구에서 기업가정신 따른 본연의 결과인 혁신[31]의 원천에 대한 연구가 진행됨을 알 수 있다.

EO의 탄생배경이며, 기업가정신 발현의 효과에 대한 시작점인 기업의 고용창출 그리고 경제에서 혁신자의 역할에 대한 연구의 중심인 중소기업과 벤처[2, 32, 33]는 2014년까지의 연구에서부터 단독 주제로 선정되어 계속 진행되고 있다. 이는 기업의 성과와 성장 그리고 그에 따른 변화와 단독으로 구성된 주제로 연구 대상으로 꾸준히 위치함을 알 수 있다.

사회적 기업 등 기업의 본연의 목적 외 특정 목적을 달성하기 위해 기업이라는 도구를 활용하는 부분은 계속 주제로 확인되고 있으나, 개인 및 여성 등 EO를 위해 기반이 되는 기업의 구성 요소에 대한 부분은 축소되는 것으로 보인다.

2. 한계점 및 연구의 의의

데이터 확보의 접속 한계로 인해 1,500여건 발표된 논문에 대해서만 분석이 되었고, 그 외 Google scholar 상 검색되는 40여만 건의 연구에 대해서는 확인이 불가능하였다. 물론 Google scholar에 확인되는 문서는 학술대회 발표 건을 비롯하여 다양한 연구 및 저술 결과를 전부 포함하고 있으나, 그에 비해 Academic Research Library-ProQuest에서 확인되는 기업가적 지향성 관련 연구결과는 부족한 것이 사실이다. 이에 따라, 보다 많은 문헌을 가진 DB를 대상으로 한 연구가 필요하다.

출현 단어의 빈도 분석은 대략적인 방향성을 찾을 수 있는 장점이 있다. 하지만, 구간별 출현 단어 빈도의 분석은 설정 구간의 특성상 과거 데이터가 사라지지 않고 누적되어, 해당 시점의 누적 빈도에 어떤 구간에 영향을 미치는 확인이 어렵다. 이에 따라, 구간별 보유 데이터의 색인 작업을 통해 비교를 진행할 수 있으나, DB작업을 위한 시간 등이 부족하여 공통된 주요 출현 어휘와 변화를 가져오는 어휘 구분을 진행한 것은 아쉬운 부분이다.

연구를 위해 설정한 구간에 있어서도, 계속 누적된 기간을 통해 새로운 효과의 반영분을 파악했기 때문에, 새로운 기간, 부연하면, 2004년부터 2009년까지의 기간, 2009년부터 2014년까지의 기간, 2014년부터 2019년까지의 기간만의 특성을 반영하지 못했다. 이에 따라, 빈도 분석뿐만 아니라 토픽 모델링을 통한 주제 분석에 있어서도, 개별 기간의 독자적인 특성을 파악하고, 이를 통해 전체 변화뿐만 아니라 변화의 동인을 파악할 필요가 있다. DB의 색인 작업을 통해 어휘 빈도 분석과 함께 진행할 필요가 있다.

이 연구는 본격적인 연구를 위한 방법론 검토 및 확인에 의의가 있다. 이 연구에 따라 기업의 기업가정신 부분의 연구는 기업의 전략적 선택 방향 중 하나가 아니, 새로운 시장과 제품 그리고 이를 출시하는 방식

등 새로운 도전이 필수임을 제시하고 있다. 더불어, 사회 변화의 중심인 기업가정신의 발현의 핵심 주체가 중소기업을 비롯한 소규모에서 활발하다는 점이 연구 활동에서도 발견되어, 우리나라와 같이 대기업 중심의 경제사회에 변화가 필요한 정책적 함의를 연구 활동에서 찾을 수 있을 것으로 기대된다.

또한, 방법론 측면에서 문헌의 수가 많아짐에 따라 더욱 더 정교한 분류가 가능해 지는 LDA의 특성상 2009년 이후의 LDA 결과 값을 살펴보면, 주제 분류에 대한 할당된 주요 단어의 관련성과 동질성이 점차 높아진다는 점이 발견되었다. 이에 따라, 더 많은 데이터를 기반으로 분석을 진행할 때, 연구동향의 변화와 방향을 더 명확히 파악할 수 있을 것으로 기대된다.

참고문헌

- [1] V. Edmond and J. Wiklund, "The historic roots of entrepreneurial orientation research," *Historical foundations of entrepreneurial research*, H. Landström and F. Lohrke, eds., pp. 142-160, Glos (UK): Edward Elgar Publishing, 2010.
- [2] B. Cornelius, H. Landström, and O. Persson, "Entrepreneurial studies: The dynamic research front of a developing social science," *Entrepreneurship Theory and Practice*, vol. 30, no. 3, pp. 375-398, 2006.
- [3] V. H. Dehejia, and N. Rowe, "The effect of business cycles on growth: Keynes vs. Schumpeter," *Economic Inquiry*, vol. 36, no. 3, pp. 501-511, 1998.
- [4] F. Castellacci, and J. Zheng, "Technological regimes, Schumpeterian patterns of innovation and firm-level productivity growth," *Industrial & Corporate Change*, vol. 19, no. 6, pp. 1829-1865, 2010.
- [5] M. C. Becker, and T. Knudsen, "Schumpeter 1911: Farsighted visions on economic development," *American Journal of Economics and Sociology*, vol. 61, no. 2, pp. 387-403, 2002.
- [6] J. G. Covin, K. M. Green, and D. P. Slevin, "Strategic process effects on the entrepreneurial orientation-sales growth rate relationship," *Entrepreneurship Theory and Practice*, vol. 30, no. 1, pp. 57-81, 2006.
- [7] F. Hasson, S. Keeney, and H. McKenna, "Research guidelines for the Delphi survey technique," *Journal of Advanced Nursing*, vol. 32, no. 4, pp. 1008-1015, 2000.
- [8] C. Suh, E. Kim, and Y. Lee, "The development of Delphi support decision system on the web," *The Journal of Information Systems*, vol. 10, no. 1, pp. 5-25, 2001.
- [9] P.-C. Lee, and H.-N. Su, "Investigating the structure of regional innovation system research through keyword co-occurrence and social network analysis," *Innovation*, vol. 12, no. 1, pp. 26-40, 2010.
- [10] M. Steyvers, and T. Griffiths, "Probabilistic topic models," *Handbook of Latent Semantic Analysis*, T. K. Landauer, D. S. McNamara, S. Dennis and W. Kintsch, eds., pp. 424-440: Routledge, 2007.
- [11] D. Miller, "The correlates of entrepreneurship in three types of firms," *Management Science*, vol. 29, no. 7, pp. 770-791, 1983.
- [12] G. T. Lumpkin, and G. G. Dess, "Clarifying the Entrepreneurial Orientation Construct and Linking It to Performance," *The Academy of Management Review*, vol. 21, no. 1, pp. 135-172, 1996.
- [13] O. F. Collins and D. G. Moore, *The organization makers: A behavioral study of independent entrepreneurs*, New York: Appleton-Century-Crofts, 1970.
- [14] J. Wiklund, and D. Shepherd, "Entrepreneurial orientation and small business performance: a configurational approach," *Journal of Business Venturing*, vol. 20, no. 1, pp. 71-91, 2005.
- [15] W. Aloulou, and A. Fayolle, "A conceptual approach of entrepreneurial orientation within small

- business context,” *Journal of Enterprising Culture*, vol. 13, no. 01, pp. 21-45, 2005.
- [16] J. A. Schumpeter, *Capitalism, Socialism and Democracy*, London: Routledge, 1942.
- [17] J. G. Covin, and D. P. Slevin, “Strategic management of small firms in hostile and benign environments,” *Strategic Management Journal*, vol. 10, no. 1, pp. 75-87, 1989.
- [18] S. A. Zahra, “Predictors and financial outcomes of corporate entrepreneurship: An exploratory study,” *Journal of Business Venturing*, vol. 6, no. 4, pp. 259-285, 1991.
- [19] S. A. Zahra, and J. G. Covin, “Contextual influences on the corporate entrepreneurship-performance relationship: A longitudinal analysis,” *Journal of Business Venturing*, vol. 10, no. 1, pp. 43-58, 1995.
- [20] J. Wiklund, “The sustainability of the entrepreneurial orientation-performance relationship,” *Entrepreneurship Theory and Practice*, vol. 24, no. 1, pp. 39-50, 1999.
- [21] G. T. Lumpkin, and G. G. Dess, “Linking two dimensions of entrepreneurial orientation to firm performance: The moderating role of environment and industry life cycle,” *Journal of Business Venturing*, vol. 16, no. 5, pp. 429-451, 2001.
- [22] J. G. Covin, and W. J. Wales, “The Measurement of Entrepreneurial Orientation,” *Entrepreneurship Theory and Practice*, pp. no-no, 2011.
- [23] A. Fayolle, O. Basso, and V. Bouchard, “Three levels of culture and firms’ entrepreneurial orientation: A research agenda,” *Entrepreneurship and Regional Development*, vol. 22, no. 7-8, pp. 707-730, 2010.
- [24] K. Gary A, “Cross-cultural reliability and validity of a scale to measure firm entrepreneurial orientation,” *Journal of Business Venturing*, vol. 12, no. 3, pp. 213-225, 1997.
- [25] D. W. Lyon, G. T. Lumpkin, and G. G. Dess, “Enhancing entrepreneurial orientation research: operationalizing and measuring a key strategic decision making process,” *Journal of Management*, vol. 26, no. 5, pp. 1055-1085, 2000.
- [26] P. M. Kreiser, L. D. Marino, and K. M. Weaver, “Assessing the Psychometric Properties of the Entrepreneurial Orientation Scale: A Multi-Country Analysis,” *Entrepreneurship Theory and Practice*, vol. 26, no. 4, pp. 71-93, 2002.
- [27] G. T. Lumpkin, “Clarifying the entrepreneurial orientation construct and linking it to performance,” *Academy of management Review*, vol. 21, no. 1, pp. 135-172, 1996.
- [28] A. Kao and S. R. Poteet, Eds., *Natural language processing and text mining*. Berlin: Springer Science & Business Media, 2007.
- [29] D. M. Blei, “Probabilistic topic models,” *Communications of the ACM*, vol. 55, no. 4, pp. 77-84, 2012.
- [30] J. A. Schumpeter, and U. Backhaus, “The Theory of Economic Development,” *Joseph Alois Schumpeter: entrepreneurship, style and vision*, J. G. Backhaus, pp. 61-116, Boston: Springer Science & Business Media, 2002.

- [31] J. A. Schumpeter, "Theorie der wirtschaftlichen Entwicklung. Dunker & Humblot, Leipzig," *The Theory of Economic Development*, 1912.
- [32] D. L. Birch, *The job generation process*. Cambridge, MA: MIT Program on Neighborhood and Regional Change, 1979.
- [33] Z. J. Acs and C. P. Kindleberger, *The changing structure of the U.S. economy: lessons from the steel industry*. Praeger, 1984.



화재 발화 위치 및 다익스트라 알고리즘을 이용한 피난 방향 안내 시스템의 설계*

Design of Evacuation Direction Guidance System using Fire Location and Dijkstra Algorithm

강윤구¹, 류관희^{2**}

¹(주)삼인에이치엔티

²충북대학교 소프트웨어학과

Yun-Koo Kang¹, Kwan-Hee Yoo^{2**}

¹SAMINHNT Co., Ltd.

²School of Computer Science, Chungbuk National University

요 약

본 연구는 센서를 활용하여 화재 시 발화 지점을 추정하고, Dijkstra 알고리즘을 활용한 최단거리 대피 경로 생성 및 피난방향 안내 시스템을 설계 한다. 건물에서 화재가 발생했을 경우 탈출을 위해서 최적의 경로로 유도하게 된다면 많은 대피자가 탈출에 성공할 수 있다. 따라서 본 연구에서는 온도 센서를 활용하여 정확한 발화점을 파악한 후, 시인성을 향상 시킨 표시장치에 안전한 최단 탈출 경로를 정확하게 안내함으로써 많은 대피자들이 혼란을 피해 안전하게 탈출에 성공할 수 있도록 테스트를 통해 유효성을 검증하였다.

주제어: IoT, 재난감지 센서, 알고리즘

* The Ministry of Science and ICT (MSIT), Korea, under the Grand Information Technology Research Center support program (IITP-2023-2020-0-01462), supervised by the Institute for Information & Communications Technology Planning & Evaluation (IITP).

** Corresponding Author: Kwan-Hee Yoo (khyoo@chungbuk.ac.kr)

Abstract

This study estimates the ignition point in the event of a fire using sensors, and designs a shortest-distance evacuation path generation and evacuation direction guidance system using the Dijkstra algorithm. In the event of a fire in a building, many evacuees can succeed in escaping if they are guided in the optimal path for escape. Therefore, in this study, after identifying the exact ignition point using a temperature sensor, the effectiveness was verified through tests so that many evacuees could safely escape from confusion by accurately guiding the safe shortest escape path to a display that improved visibility.

Keyword: IoT, Disaster detection sensor, Algorithm

1. 서론

지난 20여년간 중대형 재난재해(화재)의 발생은 도시구조의 복잡화와 고층화, 밀집화 등에 의해 지속해서 발생 하였고, 재난재해 발생으로 인한 인명피해는 Fig. 1 [1]과 같이 재난 발생에 대한 인지부족 및 구조 복잡도, 대피 방법 어려움에 따라 증가 하고 있다.

현 소방안전 규정에는 화재경보, 화재진압(소화전, 스프링클러, 소방서 통보 등), 화재대피(비상구 표시, 피난안내표시 등)로 구분되어 규제 및 행정지도를 하고 있으며, 국가안전관리기본계획에 따르면 재난안전정책의 최상위 계획(5개년)으로 “재난안전사고 사망자 40% 감축”을 핵심지표로 설정하고 2017년 기준 27,154명 수준인 재난안전사고 사망(통계청 사망원인 통계 중 사망의 외인에 의한 사망)을 2024년까지 대폭 감축하기 위해 기본 계획 수립 및 세부계획 추진 중이다.

향후 대형 복합건물(대형화, 복잡화, 밀집화 등)은 지속적으로 증가할 것이고 이에 따라 기본 소방시설 규정에서 규제하고 있는 화재 인지의 정보 전달 및 대피방법으로는 피해를 최소화하기 어렵기 때문에 화재에 대비한 대피 자동안내 시스템의 도입이 필요하다.

본 연구는 화재 발생 시 위치의 정확한 판단과 최단 탈출 경로 및 우회 경로 분석을 포함한 안내시스템을 개발하기 위한 것이다. 구체적으로는, 상황실에서 화재 등의 건물 내에서 발생하는 재난으로 피난을 필요로 하는 경우에 이를 인지하고, 디스플레이를 이용하여 피난 방향을 안내할 수 있도록 기능하는, 화재 시 피난 방향 안내시스템에 관한 것이다.

기존에는 건물의 천장이나 벽 등에 비상구 유도등이 설치되어 화재 등의 비상시 사람에게 탈출구 위치만 확인 시키도록 설치되어 있었다[2]. 이러한 기술은, 실제 피난 가능한 지역을 고려하지 않은 상태의 피난 유도를 지시함에 따라, 피난 중 제대로 된 파악을 할 수 없는 상태의 대피자로 하여금, 위험에 처하게 되는 경

우가 발생한다.

즉, 화재의 발생이 비상구 측에서 발생하더라도 비상구 유도등만 있는 관계로 더 큰 인명피해를 발생시키는 문제점과 혼란을 일으키는 문제점이 있어 Fig. 2와 같이 화재 시 피난 경로를 표기하는 피난 방향을 선택적으로 조절하여 화재 반대 방향으로 사람을 유도할 수 있도록 하는 것이 절실하다.




Figure 1. Major problems among failure factors to prevent the spread of disaster (fire)




Figure 2. Evacuation direction indication

II. 이론적 배경

본 연구에서는 다양한 재난 재해 중에서 화재에 착목하여 화재 시 건물의 화재 발생 상황을 정확하게 파악하고 대피자가 안전하게 대피할 수 있도록 온도 센서와 다익스트라 알고리즘(Dijkstra Algorithm)을 활용

한 화재 위치의 정확한 판단 및 최단 탈출 경로, 우회 경로 분석을 포함한 안내시스템 개발에 목적을 두고 있다. 또한 화재 발생 시 대피자에게 탈출구 안내 표시 식별을 용이하게 하여 빠르게 대피할 수 있도록 하는데 목적이 있다.

다익스트라 알고리즘(Dijkstra Algorithm)은 최적의 경로 산출은 실행시간이 빠르고 각 지점마다 거리에 대한 가중치가 양수인 점을 고려하여 음의 가중치가 없는 그래프에서 한 노드에서 다른 모든 노드까지 최단 거리를 구하는 알고리즘이다.

이번 연구는 기존 소방안전 관리법 외 ‘안전 피난 경로 보조 도구’로 활용 할 수 있으며, 기존 감지기의 한계인 층 또는 건물 단위로만 화재 발생 위치가 확인되던 부분을 센서를 이용하여 정확한 화재 발생 위치를 확인 가능하게 하고, 비상구 표시등에 의한 탈출구 위치만 확인되던 기존 방식에서 탈출 가능한 방향과 출구를 최단 경로로 정확히 확인하여 대피자를 빠른 시간에 위험지역에서 벗어날 수 있게 할 수 있다.

대피 경로 표시장치를 대피자의 무릎 높이에 설치하여, 화재 시 연기 및 그을음으로 인해 가시도가 감소되는 천정형 비상구 표시 장치와 천정 광원을 사용해 바닥에 대피경로를 표시하는 방식[3]보다 가시도를 개선하고 대피자가 탈출하는데 더 용이하게 할 수 있다.

또한 기존 감지기와는 다르게 새로운 센서 퓨전 방식과 디지털트윈 등을 활용하여 동적 환경에 대한 대응이 가능하고 관제센터의 진화를 기대할 수 있다.

Ⅲ. 화재 피난 방향 안내 시스템

일반적으로 사용하는 감지기의 종류는 온도, 연기, 가스 감지기가 있으며 기존 감지의 한계(정확한 화재 위치 확인이 어려움)를 개선 하고자 다양한 감지기 중에서 온도(열)에 의한 감지 방식에 대한 연구를 진행하였다.

Fig. 3과 같이 기존 감지기의 동작 방식은 수신기가 내보낸 전압이 감지기 작동 시 접점이 붙어 쇼트가 되면 종단저항을 거치지 않고 수신기로 전압이 들어가 수신기가 화재 상황을 인지하는 형태이다.

화재 발생 시 대피에 대한 선행 연구 중 ‘특허 제10-2077801 화재 대피 경로 안내 시스템’[3]에서는 광원을 천장에 장착하여 화재 시 바닥에 탈출 경로를 표시하는 방식을 사용하였다. 화재 시에는 불에 의한 열의 위험성이 크다고 생각하는 경향이 있으나 실제 인명피해의 위험성은 화재 발생 시 연기에 의한 영향이 크다. 화재 시 상부로 이동한 연기 농도의 증가는 가시도를 감소시켜, 화재로부터의 피난을 저해하는 중요한 특성이며[4], 건물에 익숙하지 않은 대피자의 경우 가시도의 감소는 연기의 형성과 집결, 분자의 크기와 배치, 조명의 성질, 관측자의 신체적 및 정신적 상태 등에 따라 좌우된다. 따라서 광원이 천장에 있는 경우 화재 시 연기나 불길로 인해 바닥에 제대로 표지 되지 않을 가능성이 많아 이번 연구에서는 Fig. 4와 같이 디스플레이를 무릎높이에 장착하여 식별을 용이하게 하였다.


구분	내 용
기존구성	1)기존 화재 감지기와 P형 수신기는 아래 그림과 같이 연결 되어 있음(30개 연결 가능). 2)화재시 : 수신기에서 약 DC 24V의 전압이 공급 -> 화재감지기(점점 쇼트) -> 수신기
동작방식 (화재시)	 P형 수신기 감지기 작동시 접점이 붙어 쇼트가 됨 전류방향 종단저항 10kΩ

Figure 3. Classical sensor behavior


기존(천장에서 바닥으로 표현, 가시도 감소)	개선(무릎 높이 설치하여 가시도 향상)
	

Figure 4. Differences from existing patents

실험 진행을 위하여 전체 구성은 Fig. 5와 같이 DHT22 온도센서, 64x32 LED Matrix, Zigbee Gateway, Raspberry PI를 사용하였으며, 통신 방식은 Zigbee 무선통신과 UTP 유선통신을 혼용하였다.

실험 진행은 Fig. 6과 같이 건물 복도에 온도센서를 일정 간격으로 설치하고 가상 화재 상황을 연출하여

화재 위치를 확인 후 Display에 대피 경로를 표시하는 순서로 진행하였다.

실제 건물에 설치하여 센서 동작, Display 표시, 통신거리에 따른 동작여부 등을 확인 하고, 다익스트라 알고리즘에 의한 최단 탈출 경로를 분석 하여 관리프로그램의 대피경로 안내 출력 내용과 Display 표시 내용의 동일여부를 확인하였다.



구분	온도센서	Display	Gateway
모델명 /사진	DHT22 	64x32 RGB LED Matrix 	Xbee PRO S2C Zigbee 
특징	온도 측정 범위 -40 ~ 80°C	Display resolution 64 x 32 = 2048dots	전파거리 실내 : 90m 개활지 : 3200m
구성	 	 	 

Figure 5. Experimental configurator



Figure 6. Experimental procedure

N. 결 론

프로젝트 실험 시 가상 화재 상황을 발생시켜 각 온도 센서로 부터 시간별로 온도 데이터를 수집한 결과는 Fig. 7과 같다. 특정 센서의 온도가 상승하면, Fig. 8과 같이 관리프로그램에서 감지하여 정확한 화재 위치(센서#3)와 온도(60℃)를 표시하였다.




Figure 7. Sensor monitoring results




Figure 8. Displaying the detection results and location of the management program

관리프로그램의 화재 위치 감지 후 다익스트라 알고리즘을 통한 최단 탈출 경로를 분석하여 피난 방향을 관리프로그램의 화면에 표시하고 복도에 설치된 Display에 전송함으로써 동일한 방향을 표시하였다. 이번 연구에서는 센서를 활용하여 화재 발생 위치의 정확도를 향상 시켰고, 다익스트라 알고리즘을 활용한 최단 거리의 탈출구와 방향 안내에 대한 정확도를 향상 시켰다.

기존 특허의 탈출 방향 표시 방법을 개선하여 무릎 높이에 표시함으로써 시인성 측면에서 향상 되었고, 실제 건물에 설치 및 실험을 통한 검증으로 기존 소방 안전 관리법의 피난 경로 보조 도구로 활용 가능성을 확인하였다.

향후에는 건물 내 무선통신방식에 의한 거리의 한계점을 극복할 방법과 화재로 인한 정전 시 배터리 사용에 대한 추가 연구 및 음성안내를 접목하여 재난지역 탈출 효율을 향상시킬 방안에 대한 연구를 진행 할 예정이다.

▣ 참고문헌

- [1] 최영, “국내 대형화재 사고의 피해 확산 요인에 관한 연구 : - 공통적인 문제점 분석을 중심으로 -,” *서울시립대학교 학위논문*, 2017.
- [2] 정종진, “유도등 설치유형 및 피난구 출입문 개폐방향에 따른 재실자의 피난경로 선택패턴분석,” *한국화재소방학회 논문지*, vol. 33, no. 6, pp. 28-64, 2019.
- [3] 김기열, “화재 대피 경로 안내 시스템,” KR102077801 B1, 2020.
- [4] 최연이, “초고층 빌딩 화재 시 USN 적응적 라우팅을 이용한 피난 유도 시스템 설계,” *한양대학교 대학원 학위논문*, 2013.



이벤트 센서 기반 모션증폭 기술 적용 가능성 고찰*

Examination on the Applicability of Motion Amplification Technology by Event Sensor

엄성민¹, 나웅재¹, 장진명², 신경호³, 김병옥³, 신윤희^{1**}

¹부산대학교 조선해양공학과/GCRC-SOP

²삼성전자

³한국기계연구원 시스템다이나믹스실

Sung Min Eom¹, Woong Jae Na¹, Jin Myoung Jang²,

Kyung Ho Sun³, Byung Ok Kim³, Yun-Ho Shin^{1**}

¹Department of Naval Architecture and Ocean Engineering,

Pusan National University/GCRC-SOP

²Samsung Electronics

³Department of System Dynamics, Korea Institute of Machinery and Materials

요 약

기계 설비에서 발생하는 진동은 고장 및 오작동 방지 등을 위한 상태감시를 위해 상시 계측되며, 주로 압전 소자를 활용한 주요 위치의 진동을 계측하여 분석한다. 최근에는 프레임 카메라를 이용하여 객체 인식 및 영상 신호 처리를 이용하여 대상체의 상태감시를 시도하고 있으며 이에 대한 상용화 및 실적용을 위하여 다양한 신호 처리 기법이 개발되고 있다. 최근, 대상체의 움직임에 중점을 둔 이벤트 기반 비전 센서(Event-based Vision Sensor)는 대상체의 임의의 위치에서 고주파수 진동 측정에 용이한 이점을 가지고 있기에 이 기술의 개발에 대한 관심이 고조되고 있다. 이벤트 기반 비전 센서를 활용한 기계 설비 진동 계측은 아직까지 영상처리를 통한 진동 신호 도출에 초점을 맞추고 있기에 영상 자체에 대한 가시화에 대한 연구는 많이 이루어지지 않고 있다. 본 연구에서는 영상으로부터 도출 가능한 진동 신호를 가시화하기 위한 모션증폭 기술에 대하여 소개하고, 이벤트 센서를 활용하여 이를 실적용할 방안 및 가능성에 대하여 고찰하고자 한다. 그리고, 향후 이벤트 센서에서 촬영된 영상 기반의 상태 감시 기술에 모션증폭 기술의 접목가능성에 대하여 논하고자 한다.

* 이 논문은 2023년도 한국산업기술평가원(기계·장비산업기술개발-제조장비실증 사업: 데이터 기반 지능형 밸런싱 시스템 실증, 과제번호: 20023396)의 지원을 받아 수행된 연구임.

** Corresponding Author: Yun-Ho Shin (shinyh77@pusan.ac.kr)

주제어: 모션증폭, 이벤트 기반 비전센서, 진동가시화, 상태감시

Abstract

Vibrations generated in mechanical system are constantly measured for the purpose of fault monitoring and malfunction detection, mainly by measuring the vibrations at key locations using piezoelectric point based sensors. Recently, object recognition and image based signal processing have been attempted for condition monitoring of the target object using frame based cameras, and various signal processing techniques are being developed for commercialization and practical application. Recently, there has been growing interest in the development of event-based vision sensors, which focus on the movement of the target object, as they have advantages in measuring high-frequency vibrations from arbitrary positions of the target object. However, research on visualization of the video itself has not been extensively conducted as vibration measurement of mechanical equipment using event-based vision sensors still primarily focuses on deriving vibration signals through image processing. In this study, we aim to introduce motion amplification techniques for visualizing vibration signals that can be derived from videos, and discuss the potential and possibilities of applying these techniques in practical settings using event based vision sensors. Furthermore, we intend to examine the potential integration of motion amplification techniques into video-based condition monitoring technologies using event sensors in the future.

Keyword: Motion amplification, Event-based vision sensor, Vibration visualization, Condition monitoring

1. 서론

시각을 통해 취득하는 다양한 정보는 시각 기관이 가지는 분해능 등의 한계로 인해 분석 가능한 정보에 한계를 가진다. 즉, 시각을 통해 정량화하거나 분석하기 힘든 정보들이 존재하며 정적 평형 상태의 대상체의 일정 수준 이상의 움직임으로 정의되는 진동 또한 그 중 하나이다. 기계 설비에서 발생하는 진동은 고장 및 오작동 방지 등을 위한 상태감시를 위해 상시 계측되며, 주로 압전소자를 활용한 가속도 센서를 이용하여 주요 위치의 진동을 계측하여 분석한다. 최근에는 프레임 카메라를 이용하여 객체 인식 및 영상 신호 처리를 이용하여 대상체의 상태감시를 시도하고 있으며 이에 대한 상용화 및 실적용을 위하여 다양한 영상 신호 처리 기법이 개발되고 있다.

최근, 대상체의 움직임에 중점을 둔 이벤트 기반 비전 센서(Event-based Vision Sensor)는 대상체의 관

심 위치(ROI, Region of Interest)에서 고주파수 진동 측정에 용이한 이점을 가지고 있기에 관련이 기술 개발에 대한 관심이 고조되고 있다. 이벤트 기반 비전 센서는 전통적인 프레임 기반 영상 센서와는 다른 작동 원리를 가지며, 이는 인간의 시각에서 영감을 받은 동적 비전 센서(DVS)[1]로서 픽셀이 밝기 변화를 감지할 때만 정보(Event)를 생성하기 위해 반응한다. 각 픽셀은 독립적으로 이벤트를 생성하기에 완전히 비동기적으로 작동하며[2], 이벤트 기반 카메라의 비동기성은 배경 잡음 최소화, 넓은 동적 작동범위 및 시간 해상도 등 여러 가지 이점을 가지고 있다[3]. 또한, 이벤트 기반 카메라는 마이크로초 단위의 빠른 샘플링 시간을 가지며, 움직임에 대한 영상의 뭉개짐 없이 비교적 높은 주파수의 움직임을 감지할 수 있다[4]. 다만, 아직까지 이벤트 기반 비전 센서를 활용한 기계 설비 진동 계측은 영상처리를 통한 진동 신호 도출에 초점을 맞추고 있기에[5] 영상 자체에 대한 가시화에 대한 연구는 많이 이루어지지 않고 있다.

본 연구에서는 영상으로부터 도출 가능한 진동 신호를 가시화하기 위한 모션증폭 기술에 대하여 소개하고, 이벤트 센서를 활용하여 이를 실적용할 방안 및 가능성에 대하여 고찰하고자 한다. 그리고, 향후 이벤트 센서에서 촬영된 영상 기반의 상태 감시 기술에 모션증폭 기술의 접목가능성에 대하여 논하고자 한다.

II. 이벤트 기반 모션증폭 기술 적용

1. 이벤트 기반 비전 센서

이벤트 기반 비전 센서[5]는 픽셀 위치에서 시간에 따라 이벤트가 발생되면 극성이 달라지며 이분법적으로 트리거된다. 즉, 이벤트($e_k\{x_k, y_k\}$)는 시간 t_k 에서 밝기 변화에 대해 증가 또는 감소하는 경우에 극성 p_k 가 각각 1 또는 0의 값을 갖게 된다. Eq. 1과 같이 미리 정의된 임계값 (양수 또는 음수의 C 값)을 초과하는 로그 기준 강도의 변경이 발생할 때 트리거가 발생한다[3].

$$|\log [I(x_k, y_k, t_k)] - \log [I(x_k, y_k, t_{k-1})]| > C, \quad (1)$$

여기서 $I(x_k, y_k, t_k)$ 는 임의의 시간에서의 픽셀 강도를 나타내며, 임계값 C 는 이벤트 트리거의 감도를 조절하는 요소이다. 즉, 임계값 C 를 적절하게 설정하여 이벤트 프레임의 잡음을 완화하면서 관심 대상인 동적 객체만 이벤트 프레임에 남게 된다. 이에 대한 예시는 Fig. 1에 나타내었으며, 이러한 특성을 활용하여 객체를 인지 및 추적하는 방식으로 영상 신호를 활용할 수 있다.

2. 모션증폭 기술 적용

인간의 시각 체계는 눈에 비치는 정보들을 망막에 투영하고 이에 대한 위치, 색상, 세기를 뇌에서 인식한다. 그러나 이러한 시각 체계는 제한된 시공간적 감도로는 받아들이기 힘들거나 불가능한 정보들이 존재한다.




Figure 1. Example image of rotary machine by event based vision sensor according to trigger criteria




Figure 2. Block diagram of motion amplification process

다. 모션증폭 기술은 시각 체계로 받아들이기에 한계를 가지는 정보들을 증폭을 통해 기존에 보이지 않았던 정보들을 가시화하기 위한 기술이다. 이러한 모션증폭 기술은 크게 두 가지 방식으로 분류되며 이는 라그랑지안 방법(Lagrangian method)과 오일러리안 방법(Eulerian method)이다[6]. 라그랑지안 방법은 단일 픽셀 각각의 움직임을 시간에 걸쳐 추적하고 해당 픽셀 각각의 움직임에 대한 벡터를 계산하여 증폭하는 기술이다. 이 방법은 현재까지 연구되고 있으나 일반적으로 계산비용과 오류가 크다고 알려져 있다. 오일러리안 방법은 고정된 기준 프레임 내에서 각 위치의 시간 경과에 따른 색상 등의 변화를 관찰하여 각 픽셀 위치에서 시간에 따른 강도 변화를 증폭시키는 방식을 취한다. 최근에는 주로 오일러리안 방법에 기반하여 움직임을 증폭시키며 이에 대한 연구 결과가 지속적으로 제시되고 있으며[6], 입력 영상 정보를 공간 및 시간 주파수 대역으로 변환하고 다양한 필터링을 통해 대상체의 색상 혹은 경계 정보를 증폭한 영상을 도출해 낸다. Fig. 2는 해당 영상의 증폭 과정을 블록선도를 통해 나타낸 그림이며, 증폭인자(α)를 활용하여 도출 영상의 증폭량과 노이즈 수준을 조절한다[6].

Ⅲ. 고 찰

본 절에서는 모션증폭 기법의 이벤트 센서로의 적용에 앞서 프레임 기반 센서로 촬영된 영상을 기준으로 모션증폭 기법의 적용 절차를 정립하였다. 복부 호흡 영상을 기준으로 영상증폭 기법 적용의 효과를 관찰하였으며 이를 앞서 기술한 이벤트 센서 기반의 촬영 영상으로 확장 적용하였다.

1. 프레임 기반 영상에 대한 모션증폭

본 연구에서는 다양한 모션증폭 기법 중 상대적으로 구현이 용이한 차분 영상을 활용한 모션증폭 기법을 프레임 기반 영상에 대해 적용하였다. Fig. 3은 영상을 활용한 모션증폭 절차를 개략적으로 기술하고 있으며, 이를 활용하여 복부에 대한 호흡 영상의 증폭 결과를 기술하고자 한다.

영상은 시판 중인 휴대전화(iPhone 12, Apple)에 내장된 카메라를 활용하여 30fps로 촬영하였으며, 호흡하는 복부를 대상으로 14초 분량의 영상을 촬영하였다. Fig. 4는 촬영 영상을 공학용 분석 프로그램(Matlab 2022, MathWorks)을 활용하여 분석 및 영상 처리하기 위해 430장의 이미지로 전환한 결과를 나타내었다.




Figure 3. Motion amplification for frame based video

영상 내에서 증폭하고자 하는 관심 구역(ROI, region of interest)을 설정하고 1차 저역통과필터(Low pass filter, 1st order butterworth type)를 설계하였으며, 필터의 차단주파수는 1.8Hz로 설정하고 각 프레임 구성하는 픽셀 간의 시간에 따른 신호에 이를 적용하였다. 이를 요약하여 정리하면 Fig. 5와 같다.

필터를 통과한 영상들에 대해 영상의 평균을 제외한 차분 영상을 계산하고, 증폭계수를 이용하여 후처리한 증폭 영상을 도출한다. 최종적으로 원 영상에 차분 영상을 기준으로 증폭한 영상을 더해두면 증폭 영상 도출이 가능하며, 이를 요약하면 Fig. 6과 같다.


상기 기술한 절차를 전체 영상에 적용하여 전체 영상에 대한 증폭 영상을 도출한다. Fig. 7에는 원본 영상과 증폭 영상을 비교하여 도시하였으며, 영상 증폭의 결과로 원본 영상에서 상대적으로 구분하기 어려운 복부 호흡의 외관이 보다 명확하게 관찰할 수 있음을 확인하였다.

2. 이벤트 기반 측정 결과에 대한 모션증폭

이벤트 기반의 영상 신호는 프레임 기반의 영상 신호와는 달리 상대적으로 높은 샘플링으로 영상 촬영이 가능하며, 높은 주파수로 운전되는 기계 장비 계의 상태감지에 적용할 수 있다. 본 절에서는 펌프에서 토출되는 물의 변동압력으로 인해 배관계가 흔들리는 경우와 기계 가공을 위해 사용되는 선반의 회전 부위를 대상으로 이벤트 기반 영상에 대해 모션증폭 기법을 적용하여 그 실적용 가능성을 고찰하였다.


#1. 복부 호흡 Video

* Framework : ① Input Data




* Belly Video

: 14초 분량 / 호흡하는 복부를 대상으로 촬영



· Input Data인 Video 시퀀스를
frame 단위로 분해




* 430 frames

: Input Video를 **frame 단위로**
총 430장으로 분해


Figure 4. Step 1: input data pre-processing for belly video

* Framework : ② Frame Filtering



· 각 frame에 R.O.I 설정 및
설계한 **Low pass filter**를 필터링

2) Low pass filtering



* R.O.I frame

(307×164×3)

· 1차 butterworth 필터를 설계,

Sampling frequency : 30 Hz / cut-off frequency : 1.8 Hz

· frame을 구성하는 각 pixel들의 시간에 따른 색상 변화 신호에 **Low pass filtering**

Figure 5. Step 2: definition of ROI and application of low pass filter

Original frame + processed frame =



* result frame
(404×720×3)

* Framework : ③ Filtered-frame Processing



· 필터링한 frame을 후처리를 통해 증폭시켜
result frame을 얻어냄

· 원본 frame에 증폭시켜 후처리한 processed frame을 씌워줘서
result frame을 얻어냄

$$\alpha \times (\text{filtered frames} - \text{average frame}) =$$



* processed frame
(307×164×3)

· 필터링한 각 frame에 average frame 차이 값에

증폭계수를 통해 증폭시켜 후처리한 processed frame을 얻어냄

Figure 6. Step 3: motion amplification of filtered images




Figure 7. Motion amplification results

본 연구에서 사용한 이벤트 기반 비전 센서는 PROPHESSEE 사의 PEK4MHDCD 모델이며, 이에 대한 세부적인 사양은 Table 1에 기술하였다. 배관계와 선반 장비의 운전주파수 등을 고려하여 영상 처리 시 대역 통과필터를 설계·적용하였으며 3.1절에서 기술한 프레임 영상에 대한 모션증폭 절차를 적용하였다. Fig. 8은 그 결과를 원본 영상과 함께 나타내었으며, 이로부터 이벤트 기반 촬영 영상에 대한 모션증폭 가능성을 확인하였다. 여기서 배관 계에 대한 펌프 운전주파수는 14Hz이며, 선반 운전 시 회전주파수는 23Hz이다. 촬영 영상은 증폭기법 적용을 통해 장비 거동이 보다 명확하게 관찰되었으며, 영상의 질도 함께 향상되었다. 다만, 해당 영상에 대한 증폭 결과는 0과 1로 이루어진 이벤트 영상 신호를 기준으로 하기에 증폭률에 한계를 가지고 있으며 이에 대한 후처리 방식에 대해 추가적인 고찰이 필요하다고 판단된다.

Table 1. Specifications of the event sensor

Model: PEK4MHDCD	
Resolution	1280 x 720 pixels
Pixel size	4.86 μm x 4.86 μm
Maximum event rate	1 G events/s
Dynamic range	> 120 dB
Casing dimension (mm)	H38 x W38 x D50




Figure 8. Motion amplification results for example mechanical systems

IV. 결 론

본 연구에서는 기본적인 모션증폭 기법의 이벤트 센서 기반 영상으로의 적용 가능성에 대해서 검토하였다. 이벤트 센서의 작동 원리를 설명하고, 프레임 기반 센서로 촬영된 영상을 기준으로 모션증폭 기법의 적용 절차를 정립하였다. 복부 호흡 영상을 기준으로 영상증폭 기법 적용의 효과를 관찰하였으며 이를 이벤트 영상으로 확장 적용하였다. 이 과정에서 저역 및 대역통과필터, 증폭계수 등의 재설계가 대상 영상에 따라 추가적으로 필요함을 확인하였으며, 이벤트 센서 기반의 신호 증폭 시 이에 대한 민감도가 더 높아짐을 확인하였다. 배관 및 선박 기계를 대상으로 이벤트 센서를 통해 촬영한 영상들에 대한 모션증폭이 가능함을 확인하였으며, 상대적으로 증폭계수 선정에 민감함을 관찰하였다. 또한, 진동 증폭 시 잡음이 함께 증폭되는 상황이 발생됨에 따라 향후 필터 및 증폭계수 설계에 대한 추가적인 검토가 필요하다.

참고문헌

- [1] P. Lichtsteiner, C. Posch, and T. Delbruck, "A 128 x 128 120db 30mw asynchronous vision sensor that responds to relative intensity change," in *Proceedings of the 2006 IEEE International Solid State Circuits Conference-Digest of Technical Papers*, San Francisco, CA, USA, 2006, pp. 2060-2069. <https://doi.org/10.1109/ISSCC.2006.1696265>.
- [2] E. Mueggler, G. Gallego, H. Rebecq, and D. Scaramuzza, "Continuous-time visual-inertial odometry for event cameras," *IEEE Transactions on Robotics*, vol. 34, no. 6, pp. 1425-1440, 2018. <https://doi.org/10.1109/TRO.2018.2858287>.
- [3] Z. Lai, I. Alzugaray, M. Chli, and E. Chatzi, "Full-field structural monitoring using event cameras and physics-informed sparse identification," *Mechanical Systems and Signal Processing*, vol. 145, pp. 344-351, 2020. <https://doi.org/10.1016/j.ymssp.2020.106905>.
- [4] G. Gallego, H. Rebecq, and D. Scaramuzza, "A unifying contrast maximization framework for event cameras, with applications to motion, depth, and optical flow estimation," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Salt Lake City, UT, USA, 2018, pp. 3867-3876. <https://doi.org/10.1109/CVPR.2018.00407>.
- [5] W. J. Na, K. H. Sun, B. C. Jeon, and Y. H. Shin, "Event-based micro vibration measurement using phase correlation template matching with event filter optimization," *Measurement*, vol. 215, pp. 112867, 2023. <https://doi.org/10.1016/j.measurement.2023.112867>.
- [6] H. Y. Wu, M. Rubinstein, E. Shih, J. Guttag, F. Durand, and W. Freeman, "Eulerian video magnification for revealing subtle changes in the world," *ACM Transactions on graphics (TOG)*, vol. 31, no. 4, pp. 1-8, 2012. <https://doi.org/10.1145/2185520.2185561>.



일자리 추천서비스 정보의 다차원 분석*

Multi-Dimensional Analysis of Job Recommendation Service Information

최은선¹, 크언삭소니따¹, 박유희¹, 조완섭^{2**}

¹충북대학교 빅데이터학과

²충북대학교 경영정보학과

Eun-Seon Choi¹, Saksonita Khoeurn¹, Yoo-Hee Park¹, Wan-Sup Cho^{2**}

¹Department of Bigdata, Chungbuk National University

²Department of Management Information Systems, Chungbuk National University

요 약

일자리 추천 시스템은 구직자와 구인자의 정보를 바탕으로 가장 적합한 매칭을 구직자 (혹은 구인자)에게 자동으로 추천하는 시스템으로 최근에는 인공지능 기술을 사용하여 추천의 만족도를 높이고 있다. 본 연구에서는 대표적인 공공 취업 알선 포털인 워크넷에서 제공한 기존 추천 서비스 결과에 대한 데이터를 다각도로 분석함으로써, 추후 개인화를 통한 개선방안 제시를 위한 초기연구로 활용함에 목적을 둔다.

주제어: 빅데이터, 인공지능, 추천 알고리즘

Abstract

The job recommendation system is a system that automatically recommends the most suitable match to job seekers (or job seekers) based on the information of job seekers and companies. Recently, various artificial intelligence technologies based on big data are used to increase the satisfaction of recommendations. In this study, we multi-dimensionally analyze data on the results of the existing recommendation service provided by Worknet, a representative public job placement

* 이 논문은 2022년도 한국고용정보원의 “AI 일자리 추천서비스 성능 개선을 위한 알고리즘 기초 연구”용역과제 내용을 기반으로 작성되었음.

** Corresponding Author: Wan-Sup Cho (wscho@chungbuk.ac.kr)

portal, and aim to use it as an initial study to suggest improvement plans through personalization in the future.

Keyword: Big data, Artificial intelligence, Recommendation algorithm

I. 서론

대표적인 공공취업알선 포털인 워크넷[1]은 1천만명 이상의 개인회원을 대상으로 구직활동을 지원하고 있다. 과거의 취약계층 위주에서 최근에는 청년층의 구직활동도 활발하게 이루어지고 있어 구직자의 편의성과 효과성을 제공하는 것이 중요한 과제로 부각 되고 있다. 구직자 (혹은 구인자)가 편리하게 구직활동을 할 수 있도록 지원해야 하며, 잡매칭의 결과인 추천이 구직자와 구인자가 효과적으로 연결되도록 지원해야 한다.

워크넷의 추천시스템은 다양한 인공지능 알고리즘을 적용하면서 발전해 왔다. 구직자와 구인자의 특성을 분석하여 잡매칭을 효율화하는 방안과 함께 다양한 데이터 마이닝 기법과 인공지능 기법을 활용하여 추천의 품질을 높이는 연구를 수행해왔다. 최근에는 워크넷에 축적되는 빅데이터를 활용하여 딥러닝 기반의 추천을 수행하고 있으나, 추천의 품질 (recall, precision)을 높이는 연구는 앞으로도 지속되어야 한다. 또한, 추천의 품질 못지않게 구직자 혹은 구인자의 편의성 증진과 선호도를 반영하는 것도 고객의 만족도를 높이는 데 중요한 과제이다.

본 연구에서는 구직자-구인자 추천의 품질을 높이기 위해서 기존의 추천 결과를 다각도로 분석한 후 문제점 및 결론을 도출하고, 이를 바탕으로 추후 개인화를 통한 개선방안을 제시하기 위한 초기연구로 활용함에 목적을 둔다. 논문의 구성은 다음과 같다. 제2장에서 관련 연구를 소개하고 제3장에서 기존 추천시스템에 대한 다차원 분석과 매칭 결과에 대한 평가 결과를 설명한다. 마지막으로 제4장에서는 결론을 제시한다.

II. 이론적 고찰

추천시스템이란 사용자가 관심을 가질만한 콘텐츠(상품, 영화, 이미지, 뉴스, 회사 등)를 추천하는 시스템으로 사용자의 선호도나 과거 행동을 토대로 사용자에게 적합한 콘텐츠를 선정하는 시스템이다. 추천시스템의 목적은 1차 적으로 사용자가 선택할 가능성이 높은 아이템을 추천하는 것이지만 장기적으로 사용자 만족도나 신뢰감을 높이는 것도 중요하다. 이를 위해 정확도뿐 아니라 심리적 요소나 UI 편의성도 중요하게 고려되어야 한다.

현대 추천시스템은 데이터 마이닝 기술의 한 종류인 연관분석 기반으로 개발되었으나 2006년 이후 넷플릭스 데이터를 사용한 협업 필터링 방식이 개발되었고, 이후 구글 알파고 등과 같은 딥러닝 기술을 활용하

추천시스템이 발달하게 되었으며, 현재는 Factorization Machine, 강화학습, 딥러닝 방식을 이용한 초개인화 추천 시스템[2], 그래프 기반 추천 시스템(Graph Neural Network) 등으로 발전해 나아가고 있으며[3, 4], 발전 과정에 관한 세부적인 내용은 아래의 Fig. 1 [5]과 같다.

현대 사회에서 추천 시스템은 다양한 분야에 활용되고 있는데 현대인이 즐겨보는 YouTube와 Netflix에서 시청한 영상과 유사한 영상을 추천하고 Amazon 및 쿠팡 같은 온라인 마켓에서 사용자가 과거에 구매하거나 관심을 가진 물건과 유사한 물건들을 웹 페이지의 상단에 노출시키는 것이 대표적인 사례이다. 인터넷의 발전으로 콘텐츠가 넘쳐나는 현대사회에서 AI 기반의 개인화된 콘텐츠 추천은 소비자에게 적합한 콘텐츠를 찾는데 걸리는 시간을 줄여주고, 콘텐츠 소유자에게는 적합한 고객을 제시할 수 있어 많은 조직에서 도입하는 추세이다. 실제로 Netflix 시청 시간의 70~80%는 Netflix 추천 시스템을 기반으로 이루어지고, Amazon 구매 건 중 35%가 추천된 제품이라고 알려져 있다.




Figure 1. Advances in recommendation systems

Ⅲ. 추천 데이터의 분석

본 연구에서는 워크넷[1]에서 생성한 추천 결과에 대하여 다차원 분석기법을 사용하여 추천 결과의 유용성을 평가하고, 이를 바탕으로 개선방안을 제시하고자 한다.

1. 데이터셋 소개

본 연구에서는 다차원 분석기법을 사용하여 기존 추천시스템의 구인, 구직 데이터와 추천 및 지원 데이터

를 분석하고 의사결정에 유용한 insight를 발견하며, 나아가 AI모형을 개발하는데 기초 자료로 활용 하고자 한다.

사용되는 데이터는 워크넷 추천시스템 운용과정에서 생성된 구직자, 구인자, 추천, 지원 데이터이다. 데이터 수집 기간은 2021년 1월 1일부터 동년 12월 31일까지이며, 추천과 지원 데이터는 레코드 수가 4천만건을 초과하는 대용량 데이터이므로 실제 분석에서는 9월 1일부터 9월 30일까지 1개월치 데이터셋 만을 사용하였다. 데이터의 종류 및 크기는 다음과 같으며, Table 1에서 상세한 내역을 보여주고 있다.

- 구직 데이터: 구직자가 입력하는 정보 (4,383,020 건)
- 구인 데이터: 구인자가 입력하는 정보 (1,639,486 건)
- 추천 데이터: 시스템에서 구직자에게 추천하는 기업 리스트 (5,179,784 건)
- 지원 데이터: 구직자가 지원하는 기업 리스트 (708,250 건)
- 각종 코드 데이터: 직종, 전공, 자격, 업종, 지역 정보에 대한 코드

Table 1. Description of the data used in the analysis

구분	설명	비식별화 처리
구직 데이터	워크넷 구직자의 구직신청 시 데이터	인증번호 비식별화 희망월급(1백만원 단위 버림) 연락처, 이름, 주민번호 등 개인정보 제외 희망직무내용 제외(텍스트 필드) 나이 5세 단위로 변경 구직자 연령 20세 미만, 65세 이상 제외 취득 건이 5건 미만인 자격증 NULL 값 처리
구인 데이터	워크넷 구인자의 구인공고 등록 시 데이터	인증번호 비식별화 월급(1백만원 단위 버림) 연락처, 이름, 주민번호 등 개인정보 제외 직무내용 제외(텍스트 필드) 나이 5세 단위로 변경
입사 지원 데이터	워크넷 구직자의 구인공고 입사 지원 데이터	인증번호 비식별화 구직, 구인 데이터에 존재하는 사용자로 한정
추천 데이터	구직자에게 제공한 AI 추천 채용정보 데이터	인증번호 비식별화 구직, 구인 데이터에 존재하는 사용자로 한정
지역코드	5자리 구분코드	
직종코드	한국고용직업분류(KECO) 6자리 코드	
전공코드	11자리 구분코드	
자격코드	7자리 구분코드	
업종코드	5자리 구분코드	

2. 기존 추천에 대한 분석

본 연구에서는 9월 1일부터 9월 30일까지 이루어진 추천 5,179,784 건에 대하여 다음을 기준으로 분석하여 추천의 유효성을 평가한다. 분석 방법은 Power BI[6]을 사용하여 데이터를 모델링한 후, 다차원 분석 기법을 사용하여 다각도로 분석하였다.

a) 추천/지원 건수에 대한 분석

9월 1일부터 9월 30일까지 시스템에서 추천한 건수는 5,179,784 건이지만 실제로 지원한 건수는 708,250 건으로 나타났으며, 이 중에서 추천 이후에 지원이 이루어진 건은 43,805 건(0.85%)으로 매우 적은 것으로 분석되었다. 현재 시스템은 각 구직자에게 50여건 정도를 추천하고 있다. 그러나 너무 많은 추천을 하게 되면 정보 과다로 관심사가 떨어질 수 있으며, 구직자가 추천된 회사들 중에서 지원할 회사를 선별하는 노력이 증가하게 되므로 시스템에 대한 만족도 저하가 우려된다. 따라서 각 구직자에게 제공할 적절한 구인회사의 수에 대한 추가적인 연구가 필요하며, 한 가지 방법은 사용자가 그 수를 제어할 수 있도록 개인화하는 방법을 사용할 수도 있다.

b) 연령대별 추천건수의 적절성 분석

연령대별 구직건수는 Figs. 2와 3에 나타난 바와 같이 25세 구간이 최고치이며, 60세 구간이 그 다음을




Figure 2. Comparison of job search cases(left) and recommendation cases(right) by age group




Figure 3. Comparison of the number of jobs(above) and job openings (below) by province

차지한다. 연령대별로 구직건수와 추천건수를 비교하면 20세 구간의 경우 구직건수 비율은 11.04%이지만 추천건수 비율은 6.21%로 구직건수에 비해 추천건수가 적게 나타났다. 반면에 35세 구간 이후부터는 구직건수에 비해 추천건수가 상대적으로 높게 나타나고 있어 청년층에 더 많은 추천이 필요하다.

c) 지역별 추천 분석

구인 대비 구직건수(=구인 당 구직건수)를 분석한 결과 대전과 서울의 경우 구인 당 구직건수가 5 이상으로 높지만(구직이 어려운 지역) 충남과 경기도의 경우 2 보다 적게 나타나므로 대전에서 충남으로, 서울에서 경기도로 구직자의 희망근무지역 변경을 유도할 필요가 있다. 다만, 현재 자료는 각 구인 건 별로 분석한 것이며, 구인 건은 구인 인원수와 차이가 있으므로 실제 정책을 수립할 때는 구인 건 별로 구인 인원수를 추가하여 분석하는 등 보완할 필요가 있다.

d) 업종 별 구인 신청횟수

Fig. 4는 구인신청 정보를 분석한 결과로 사회복지 서비스업의 구직자 수가 가장 많으며(18%), 이는 2위인 도매 및 상품중계업보다 3배 이상의 규모로 나타났다. 그러나 이를 지역 별로 드릴다운해서 보면 지역

별로 차이가 있음을 알 수 있다. 대부분의 지역에서 사회복지 서비스업의 구직자수가 많았지만 강원도의 경우 '가구 내 고용활동'이 가장 많은 구인신청 건수(33.43%)를 보여주고 있어 사회복지서비스 분야보다 3배 이상 높은 것으로 분석되었으며, 이러한 현상은 광주광역시, 세종시, 울산광역시 등에서 유사하게 나타났다. 반면, 경상남도의 경우 기계, 금속, 자동차, 운송장비 등 기계류 분야의 구인신청건수가 타 분야에 비해 높다.

e) 구직자-구인자 속성 일치 여부

추천 데이터에 포함된 구직자와 구인자의 희망사항 일치여부를 분석한 결과는 Table 2와 같이 요약된다. 일치하는 비율이 높지 않은 경우에 대하여 추천 시점에서 실제로 일치하는 구인회사가 없어서 그런 것인지, 실제로는 일치하는 회사가 있음에도 추천 알고리즘에서 이를 발굴하지 못한 결과인지는 추가적인 분석이 필요하다(방대한 데이터로 인해 처리시간이 오래 걸리고, 고성능 컴퓨터가 필요함). 일부 추천/지원 데이터에 대하여 정밀 분석을 수행한 결과 일치비율을 더 높일 수 있음을 확인하였으며, 전체적으로는 방대한 데이터 분석 문제로 향후 과제로 남겨두었다.




Figure 4. Comparison of job openings by industry

Table 2. The matching rate and threshold of job seekers and employers

희망사항	일치 비율	설명 (한계)
희망근무지역	81%	광역시 수준에서 일치여부를 분석했으며, 광역시가 달라도 인접한 기초지자체가 있으므로 더욱 정교한 분석이 필요함
직종	66%	현재 분석에서는 유사직종을 고려하지 않았으며, 향후 직종 별 유사도를 감안하여 분석평가할 필요가 있음
경력	89%	
급여충족	51%	구인자가 제공하는 급여가 구직자의 희망금액 이상이면 일치하는 것으로 분석했음 (급여의 차이를 감안할 필요가 있음)
자격증	76%	현재 분석에서는 유사 자격증은 고려하지 않았으며, 향후 유사직종을 고려하여 분석 평가할 필요가 있음
직무역량		추천 시점에서 실제 높은 유사도를 가진 구인회사가 있음에도 추천에 배제되는 경우가 발견됨(코사인 유사도 함수를 이용하여 구직자-구인자 직무역량 유사도를 측정하였음). 다만 AI 추천 알고리즘이 이를 배제한 이유는 명확히 알 수는 없으므로 추가 연구가 필요함
구직목적		취업알선: 45%, 구직급여: 22%, 국민취업지원제도: 14%, 직업훈련: 2%, 기타: 2%, 공백: 14% → 공백을 줄이는 노력이 필요함
속성에 대한 일치정도		각 추천 건에 대하여 직종, 지역, 자격증, 경력, 급여, 직무역량 속성의 일치여부를 계산한 결과(각 속성이 일치하면 100점, 아니면 0점으로 계산) 추천 데이터셋의 경우 평균 238점, 지원 데이터셋의 경우 320점으로 분석됨 → 추천에서 속성이 일치하는 정도는 높지 않으며(추천 데이터셋의 경우 2.38개의 속성이 일치하고, 지원 데이터셋의 경우 3.2개의 속성이 일치함), 향후 이를 개선하기 위한 노력이 필요함

3. 고 찰

고용정보원 일자리 추천시스템에서 추천한 2021년 9월 데이터에 대하여 몇 가지 기준을 설정하여 적합성을 분석하였다. 요약하면 추천이 지원으로 이어지는 비율이 높지 않으므로 (이는 추천회수가 많을 경우 자연스러운 현상이기도 함) 높여 나갈 필요성이 있다. 또한, 연령대별, 지역별, 업종별 특이점을 분석하여 개선방안을 제시하였다. 그리고 구직자-구인자의 속성에 대한 일치 여부를 분석한 결과 6개 중에서 2.4개 정도 일치하는 것으로 나타나 이를 높이는 노력이 필요한 것으로 보인다. 또한, 이러한 속성의 일치 정도를 높이는 노력과 함께 실제 개인이 우선시하는 속성이 우선 적으로 만족 되도록 추천하는 것이 더욱 중요한 과제이다. 구직자마다 취업에서 중요하게 생각하는 요소가 다르므로 모든 사람을 만족시키는 하나의 추천 알고리즘은 존재하지 않을 것이다.

IV. 결 론

고용정보원 일자리 추천시스템에서는 구직자에게 적합한 구인 회사를 찾아 추천하기 위해 기존의 추천 알고리즘뿐 아니라 최신의 딥러닝 기법까지 다양한 방법을 사용하여 연구개발과 시스템을 구축해서 운영해 오고 있다. 그러나 추천시스템을 최적화하기 위해서는 추천 결과에 대한 (자동화된)평가체계 구축을 통해 지속적으로 개선하는 노력이 필요하다. 측정되는 만큼 개선할 수 있기 때문이다. 또한, 추천에서 개인의 선호도를 반영하여 고객의 만족도는 높이는 것도 중요한 과제이다. 그리고 인공지능은 나날이 발전하고 있으므로 그래프 추천과 같은 새로운 추천 알고리즘의 연구 및 도입도 검토할 필요성도 있을 것으로 보인다. 이러한 노력을 통해 추천 후 실제 지원으로 이어지는 비율을 개선하고, 개인화를 통해 사용자 만족도를 높이는 연구를 지속적으로 해 나가야 할 것이다.

▣ 참고문헌

- [1] 한국고용정보원, *워크넷 - 구인/구직*, Available here: <https://www.work.go.kr>.
- [2] X. He, L. Liao, H. Zhang, L. Nie, X. Hu, and T. S. Chua, "Neural collaborative filtering," In *Proceedings of the 26th International Conference on World Wide Web*, Perth, Australia, 2017, pp. 173-182.
- [3] S. Wang, L. Hu, Y. Wang, X. He, Q. Z. Sheng, M. A. Orgun, L. Cao, F. Ricci, and P. S. Yu, "Graph learning based recommender systems: A review," In *Proceedings of the 30th International Joint Conference on Artificial Intelligence (IJCAI-21)*, Montreal, Canada, 2021, pp. 4644-4652.
- [4] R. Ying, R. He, K. Chen, P. Eksombatchai, W. L. Hamilton, and J. Leskovec, "Graph convolutional neural networks for web-scale recommender systems," In *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, London, UK, 2018, pp. 974-983.
- [5] X. Wang, X. He, and T. S. Chua, "Learning and reasoning on graph for recommendation," In *Proceedings of the 13th International Conference on Web Search and Data Mining*, Houston, TX, USA, 2020, pp. 890-893.
- [6] B. I. Power, U. Excel, P. B. Desktop, and P. Tiles, "Microsoft power bi," Available here: <https://powerbi.microsoft.com/en-us>, 130, 2021.



알약 분류를 위한 클러스터링 기반색상 추출 기법 연구*

A Study on Clustering-based Color Extraction Method for Pill Classification

임선영**

배재대학교 컴퓨터공학과

Sun-Young Ihm**

Department of Computer Engineering, Pai Chai University

요 약

알약 식별은 의약품 안전을 보장하는 가장 중요한 작업 중 하나이다. 본 연구는 제한 된 수의 이미지로 알약의 색상을 인식하기 위하여 이미지의 색상을 단순화 시키고, 색상을 추출하는 방법을 제안한다. 이를 위해 먼저 정확한 색상 인식을 위해 HSV 방식을 기반으로 이미지를 변환한 후, 밝기를 조정한다. 다음으로 색상 양자화를 통해 이미지의 색상을 단순화 시키고, 주요 색상을 바탕으로 색상을 인식한다.

주제어: 알약 분류, 빅데이터, 색상 양자화, 클러스터링

Abstract

Pill identification is one of the most important tasks to ensure drug safety. This study proposes a method of simplifying the color of the image and extracting the color in order to recognize the color of the pill with a limited number of images. To this end, the image is first converted based on the HSV method for accurate color recognition, and then the brightness is adjusted. Next, the color of the image is simplified through color quantization, and the color is recognized based on the main color.

Keyword: Pill classification, Big data, Color quantization, Clustering

* 이 성과는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. 2021R1C1C2011105).

** Corresponding Author: Sun-Young Ihm (sunnyihm@pcu.ac.kr)

I. 서론

최근 건강에 대한 관심이 높아지면서 질환으로 알약을 복용하는 사람들 외에도 식생활 및 건강에 도움이 되는 알약을 복용하는 사람들이 증가하고 있다. 의약품통합정보시스템에 따르면 약 20,000여 가지 이상의 알약이 국내에 유통되고 있다. 시스템에서 기본적인 약 정보를 제공하고 있지만 알약을 검색하기 위해서는 알약의 세부 사항을 사용자가 일일이 선택하고 입력해야 하는 불편함이 있다. 이를 해결하기 위해 알약 검색을 자동화하는 연구들이 진행되고 있다. 알약의 형태와 색상을 기준으로 특징을 추출하고 인식하는 방법[1, 2]들이 연구되었으며, 최근 알약을 인식하기 위해 딥러닝을 활용하는 연구들이 시도되고 있다. 이미지의 귀퉁이의 참조보드와 Deep Convolutional Network를 통해 자동으로 알약을 식별하고 검증하는 연구[3]가 제안되었고, RetinalNet, SSD, YOLO를 기반으로 알약을 실시간으로 인식하는 방법들을 연구[4]에서 비교 분석하였다.

알약을 자동으로 인식하기 위해서는 알약의 색상, 모양, 크기 등의 정보를 인식해야 하는데, 그 중에서도 색상은 알약을 구분해주는 중요한 요소이다. 알약의 모양, 크기 등이 같은 알약이라도 색상이 다를 수 있다. 예를 들어 당뇨병 환자의 혈당 수치를 조절하는 아마릴 알약은 모양과 크기가 동일하지만 용량을 색상으로 구별하고 있다. 알약의 색상을 인식하기 위해 딥러닝을 활용하는 방법이 연구되고 있으나, 딥러닝 기반의 방법은 색상별로 학습 데이터를 수집해야 하고, 학습 시간이 오래 걸리며 학습된 색상만을 인식할 수 있다. 따라서 본 연구에서는 클러스터링 방법을 기반으로 알약의 색상을 추출하고자 한다. 알약 이미지에는 수많은 색상이 포함되어 있는데, 색상을 인식하기 위해 먼저 색상 양자화를 진행하고, 다음으로 클러스터링을 통해 주요 색상을 추출한다.

II. 클러스터링 기반 알약 색상 추출

본 장에서는 클러스터링 방법을 기반으로 알약의 색상을 추출하는 방법을 설명한다. 먼저, 알약 이미지가 촬영된 환경에 따라 밝기가 다른데, 어두운 환경이라면 색상을 정확하게 검출하기가 어렵다. 따라서 먼저 HSV 방식을 기반으로 이미지를 변환한 후, 밝기를 조정하였다. 이후 색상 검출을 위하여 이미지는 다시 RGB 방식으로 변환하여 저장한다. Fig. 1은 HSV 기반으로 이미지를 변환한 결과이다.

다음으로 색상 양자화를 진행하였다. 색상 양자화는 영상이나 이미지 내의 다양한 색상을 제한된 색상으로 표현하는 것을 의미한다[5]. 초기 색상 양자화 연구는 이미지의 다양한 색상을 화면에 표시할 때, 이미지에 포함된 광범위한 색상을 줄이기 위해 활용되었다[6]. 이미지 디스플레이 장치들은 제한된 수의 색상만을 표시할 수 있기 때문이다. 최근에는 영상이나 이미지 분석에서 색상 양자화가 다양하게 활용되고 있다[7, 8]. 이미지에 수많은 색상이 담겨 있는데, 다양한 색상을 표현하는 것은 미적인 부분이나 표현력을 향상시킬 수 있지만, 문자 검출, 압축, 세그멘테이션이나 색상 분석 등의 많은 영상 분야에서 다양한 색상은 문제가




Figure 1. A result of brightness conversion based HSV

될 수 있다[9]. 색상 양자화의 목적은 원본 이미지와의 왜곡은 최소화 하되, 이미지에 존재하는 많은 색상을 제한된 크기의 팔레트로 표현하는 것이다. 알약 이미지에도 마찬가지로 배경, 음영 등 다양한 색상이 존재하는데, 알약을 분류하기 위해서는 알약의 대표되는 색상을 검출해야 한다. 따라서 본 연구에서는 k-means 클러스터링을 기반으로 색상 양자화를 수행하였다.

K-means 클러스터링은 대표적인 클러스터링 기법으로 임의의 k 개의 값을 입력 받아 k 개의 클러스터를 구축하는 것을 목표로 한다. 최초 입력 시 k 개의 클러스터가 임의로 설정되며, 매 반복에서 각 클러스터의 중심점과 입력된 모든 데이터와의 거리를 계산하여 최소 거리의 클러스터에 데이터를 포함시킨다. 그리고 각 클러스터의 중심점을 클러스터의 평균값으로 재설정 한 후, 재설정 된 중심점과 입력 데이터간의 거리를 다시 계산하여 클러스터를 재구성한다. 이를 반복하다 클러스터의 중심점이 변경되지 않으면 알고리즘은 종료한다.

본 연구에서는 k 를 3으로 설정하고 실험을 진행하였다. 대부분의 알약은 한 가지 또는 두 가지의 색상으로 이루어져 있기 때문에 알약의 최대 두 가지 색상과 배경색을 고려하여 k 는 3으로 설정하였다. Fig. 2는 k-means 클러스터링을 기반으로 색상 양자화를 수행한 결과이다. 좌측이 원본 알약 이미지이며, 우측이 색상 양자화가 수행 된 결과 이미지이다. 색상 양자화 수행 결과 원본 이미지에서 다양했던 색상이 단순화 된 것을 확인할 수 있다.

다음으로는 알약의 색상을 판별하기 위한 방법을 설명한다. 본 연구에서는 알약의 색상을 판별하기 위해서 색상 양자화 결과 이미지에서 가장 많은 비중을 차지하는 최우선 색상을 추출한다. 추출된 주요 색상을 RGB 컬러 기준 값에 따라 알약의 색상을 판별한다. RGB 컬러를 기준으로 색상을 판별하기 위해서 본 연구에서는 다음의 기준을 정의하였다.

Fig. 3은 Table 1의 기준을 바탕으로 색상을 도출한 결과이다. 기준에 따라 알약의 색상은 blue로 판별되었다. Fig. 4는 같은 과정을 거쳐 색상을 추출한 결과를 보이고 있다. 기준에 따라 각각 알약의 색상을 white와 red로 추출하였다.




Figure 2. A result of color quantization

Table 1. Color identification based RGB

R	G	B	Color
230 이상	230 이상	230 이상	white
230 이상	110 이상	120 이상 230 미만	orange
230 이상	110 미만	120 이상	red
230 미만	180 이상	230 이상	blue
230 미만	180 이상	230 미만	green

[149. 208. 251.]
 [218. 227. 249.]
 [244. 76. 84.]
 [0.60146256 0.35112144 0.047416]



Figure 3. A result of color identification



Figure 4. Results of color extraction of pill

III. 결론 및 향후 연구

본 연구에서는 알약을 자동으로 분류하기 위한 클러스터링 방법을 기반으로 알약의 색상을 추출하는 방법을 제안하였다. 알약의 색상은 알약을 분류하기 위한 주요 속성이다. 본 연구에서는 제한된 이미지로 색상을 인식하기 위하여 이미지의 색상을 단순화 시키고, 색상을 추출하였다. 먼저, 알약 이미지가 촬영된 환경에 따라 밝기가 다른데, 어두운 환경이라면 색상을 정확하게 검출하기가 어렵다. 따라서 먼저 HSV 방식을 기반으로 이미지를 변환한 후, 밝기를 조정하였다. 다음으로 k-means 클러스터링을 통해 색상 양자화를 수행하였으며, 알약의 주요 색상을 추출하였다. 도출된 색상은 RGB 기준에 따라 색상을 판별하여 알약의 색상을 도출하였다. 제안하는 방법은 학습 이미지가 부족한 상황에서 알약의 색상을 인식하기 위한 방법으로 활용될 수 있을 것으로 기대된다. 본 연구에서는 white, orange, red, blue, green 총 5가지의 색상만을 추출했다는 한계점이 있었다. 향후 연구로는 기본 색상들을 모두 추출하기 위하여 색상을 판별하기 위한 기준을 세밀화하고, 또한 다른 색상 추출 기법들과의 비교 실험을 진행할 예정이다.

▣ 참고문헌

- [1] E. Annasaro and A. Hema, "Color and Shape Feature Extraction and Matching in Pill Identification System," *International Journal of Computer Science and Information Technologies*, vol. 5, no. 5, pp. 1011-1015, 2014.
- [2] M. A. Vieira Neto, J. W. M. de Souza, P. P. Reboucas Filho and A. W. d. O. Rodrigues, "CoforDes: An Invariant Feature Extractor for the Drug Pill Identification," in *Proceedings of the 2018 IEEE 31st International Symposium on Computer-Based Medical Systems (CBMS)*, Karlstad, Sweden, 2018, pp. 30-35.
- [3] Y. F. Wong, H. T. Ng, K. Y. Leung, K. Y. Chan, S. Y. Chan and C. C. Loy, "Development of fine-grained pill identification algorithm using deep convolutional network," *Journal of Biomedical Informatics*, vol. 74, pp. 130-136, 2017.
- [4] L. Tan, T. Huangfu, L. Wu, and W. Chen, "Comparison of RetinaNet, SSD, and YOLO v3 for real-time pill identification," *BMC Medical Information Decision Making*, vol. 21, pp. 1-11, 2021.
- [5] M. E. Celebi, "An Effective Color Quantization Method Based on the Competitive Learning Paradigm," in *Proceedings of the 2009 International Conference on Image Processing, Computer Vision, and Pattern Recognition (ICCV'09)*, Las Vegas, NV, USA, 2009, pp. 876-880.
- [6] M. T. Orchard, and C. A. Bouman, "Color Quantization of Images," *IEEE Transactions on Signal Processing*, vol. 39, no. 12, pp. 2677-2690, 1991.
- [7] A. Pujol, and L. Chen, "Color quantization for image processing using self information," in *Proceedings of the 2007 6th International Conference on Information, Communications & Signal Processing*, Singapore, 2007, pp. 1-5.
- [8] J. Orwell, P. M. Remagnino, and G. A. Jones, "Optimal Color Quantization for Real-Time Object Recognition," *Real-Time Imaging*, vol. 7, no. 5, pp. 401-414, 2001.
- [9] H. J. Park and K. B. Kim, "Improved k-means Color Quantization based on Octree," *Journal of The Korea Society of Computer and Information*, vol. 20, no. 12, pp. 9-14, 2015.



라이다 화상 데이터를 활용한 수목 인식 및 분류에 대한 연구*

A Study on Tree Recognition and Classification Using LIDAR Image Data

강문석¹, 박일건^{1**}

¹(주)평화엔지니어링 기술연구소

Moon-Seok Kang¹, Il-Gun Park^{1**}

¹Pyunghwa Engineering Consultants Ltd. R&D Institute

요 약

인공지능 기술이 발달하면서 이미지를 활용하여 다양한 이미지를 분류하는 방법이 본격적으로 활용되고 있다. 이러한 인공지능 기술을 활용하여 라이다로 촬영한 수목에 대한 인식 및 이미지를 분류하는 연구를 진행하였다. 라이다 이미지의 수목 학습 시 수목에 대한 라이다 이미지 이외에도 실제 수목에 대한 사진, 잎에 대한 이미지, 수목의 성장 단계에 따른 사진 등을 함께 학습하였다. 실제로 촬영한 가로수 수목에 대한 라이다 영상을 활용하여 CNN 모델을 활용하여 학습 후 수종 분류에 대한 결과값을 도출하였다. 라이다 수목 이미지를 학습하지 않았던 1차부터 라이다 이미지를 학습한 3차까지 정답률은 6%에서 90%까지 크게 증가하였다. 하지만 학습을 통하여 라이다 이미지를 학습하였을 때 라이다 이미지에서 충분히 라이다 이미지를 통한 수목 분류가 가능할 것으로 예상된다. 하지만 라이다의 영상 특성상 나무 이외의 화상(건물, 도로, 자동차, 보행로 등)과 겹쳐 보이는 경우가 많으며 나무 객체 특성상 잎이 일부분만 촬영되거나 수형이 반영되지 않는 문제가 발생하였다. 향후 이러한 영상들에 대한 개선 및 라이다 영상에 대한 해상도 증가, 픽셀 이미지가 아닌 라이다 3차원 정보에 대한 직접적인 기술 개선이 필요할 것으로 예상된다.

주제어: 라이다, 수목분류, 이미지 분류, 머신러닝, CNN 모델

* 이 논문은 2023년도 국토교통과학기술진흥원의 온실가스 저감을 위한 국토도시공간 계획 및 관리기술 개발 사업의 지원을 받아 수행된 연구임(No. 1055001315).

** Corresponding Author: Il-Gun Park (igpark@pec.kr)

Abstract

As artificial intelligence technology develops, a method of classifying various images using images is being used in earnest. Using this artificial intelligence technology, a study was conducted to recognize and classify images of trees photographed with LIDAR. When learning trees of lidar images, in addition to lidar images of trees, photos of real trees, images of leaves, and photos according to the growth stage of trees were studied together. By using LiDAR images of actually photographed roadside trees, CNN models were used to derive results for tree species classification after learning. The correct answer rate increased significantly from 6% to 90% from the 1st, which did not learn lidar tree images, to the 3rd, which learned lidar images. However, when learning lidar images through learning, it is expected that tree classification through lidar images will be possible enough in lidar images. However, due to the image characteristics of LIDAR, it often overlaps with images other than trees (buildings, roads, cars, walking paths, etc.), and due to the characteristics of tree objects, only a part of the leaves is captured or the tree shape is not reflected. In the future, it is expected that improvements in these images, increased resolution of lidar images, and direct technological improvement for lidar 3-dimensional information rather than pixel images will be required.

Keyword: Lidar, Tree classification, Image classification, Machine learning, CNN model

1. 서론

도시지역에서 구성하는 대표적인 객체에는 건물과 수목이 있다. 수목은 도시에서 녹지공간을 제공하고 산소를 발생시키고 이산화탄소를 감소시킬 수 있는 중요한 지상객체이다. 이러한 수목의 3차원 공간정보를 구축할 때 기존에는 주로 항공사진을 활용한 방법을 주로 이용하였으나 라이다(LIDAR : Light Detection And Ranging) 장비의 도입으로 인하여 이러한 수목정보를 라이다를 이용하여 추출할 수 있다. 항공사진은 2D의 정보로 이뤄져 있는데 반해 라이다는 지상객체에 대한 3차원 좌표정보를 효율적으로 획득할 수 있는 장비로 자율주행 분야, 농업, 로봇 등 다양한 분야에서 활용되고 있다. 라이다는 초기부터 산림 분야에서 적극적으로 도입되었는데 수목의 치수 및 개체 수, 바이오매스, 탄소저장량 등을 측정하는 방법으로 주로 연구되었다. 하지만 라이다를 활용하여 수목을 분간하기에는 데이터의 방대함과 정확도 등으로 인해 어려움이 있었으며 범위가 제한적이었다. 하지만 인공지능이 발달하면서 이미지를 활용하여 다양한 이미지를 분류하는 방법이 본격적으로 활용되고 있다. 이러한 인공지능 기술을 활용하여 라이다 내 수목에 대한 인식 및 이미지를 분류하는 연구를 진행하고자 한다.

II. 선행연구

2000년 이후로 북미지역을 중심으로 라이다 연구가 진행되어 현재까지도 진행 중에 있다. 주로 항공 라이다를 활용한 경우에는 넓은 지역을 대상으로 3차원 형태로 데이터를 취득할 수 있을 뿐만 아니라 수목의 수관 변화를 다른 원격탐사 도구를 활용하는 것보다 정확하게 탐지할 수 있어 해당 분야에서 가능성을 인정 받아 활용되고 있다[1]. Vepakomma 외 [2-4]는 항공 라이다를 활용하여 침엽수림대에서 발생하는 숲 사이의 틈을 변화를 정량적으로 연구하였으며 정확도가 96%로 높게 나타나 해당 연구 방법에 대한 타당성을 보였다. 다중 시기 지상 라이다 데이터를 이용한 지역에서 단목단위의 수관 변화량을 정량화하는 방법에 대한 연구를 진행하였다[5].

국내에서는 항공영상과 라이다 데이터를 이용하여 한국의 침엽수림을 대상으로 수고를 추정하였으며 주로 산림자원과 관련된 조사방법에 관한 연구이거나 생체량에 대한 추정, 탄소 흡수량에 대한 분야가 주를 이루고 있다[6]. 하지만 주로 수목의 매스 및 수고, 수관 형태에 기반한 연구가 주를 이루고 있으며 라이다 데이터에 대한 수목 분류 방법에 대한 사례는 아직 미비한 상황이다. 또한, 주로 산림지역에 대한 연구가 주를 이루고 있으며 도시지역을 대상으로 한 연구는 부족하여 도시림 또는 가로수에 대한 연구가 필요하며 도시 지역의 수목 특성상 단일 수종이 아닌 혼합수종으로 되어 있어 수목에 따른 탄소 흡수량 산정 등 수목 분류에 대한 기술이 요구되고 있는 상황이며 이러한 라이다 데이터는 수목 분류 및 탄소흡수량 및 온실가스 산정량 등 도시 지역 수목에 대한 관리에 있어 중요한 데이터로 사용될 수 있을 것이라 예상된다.

III. 라이다 화상 촬영

라이더를 활용한 촬영은 차량용과 항공 라이다가 있으나 항공 라이다의 경우 도시단위의 규모에서 수목 군집을 측정하는데 적절하나 수목 객체 단위에서는 분별할 수 있을 정도로 해상도가 지원되지 않아 분별이 어렵기 때문에 차량용 라이다를 활용하여 도로변 가로수 및 도시 공원 내 수목에서 식재 포인트 클라우드 데이터를 취득하였다. 지점라이다의 경우 가장 정밀한 해상도를 얻을 수 있으나 도시지역의 수목을 다량으로 촬영하기에 부적합하여 가로수 측정에 가장 적합한 차량용 라이다를 활용하였다. 촬영 방법은 도로에서 라이




Figure 1. Photos taken in Suwon City using LIDAR

다 차량을 운전하면서 가로수가 설치된 지점을 중심으로 촬영을 진행하였다.

측정 지점은 수원시 수원시청 인근인 인계동에서 수원 월드컵 경기장 인근의 도로와 가로수를 대상으로 측정하였으며 측정 기간은 2020년 10월부터 11월까지 총 2개월간 라이다 데이터를 측정하였다.




Figure 2. LIDAR image (top view)




Figure 3. Resolution problems in tree segmentation in aerial LIDAR images

IV. 이미지 변환 및 추출

측정한 라이다 데이터를 기반으로 수목을 추출하였다. 신경망을 통한 전이학습을 진행하려면 라이다의 원본파일을 그대로 활용할 수 없기 때문에 신경망에서 확인할 수 있는 이미지 확장자로 변환 및 수목 이외의 영역을 제거하였다. 라이다에서 도로나 차량, 가로시설물과 같은 객체와 겹치는 경우에는 화상을 인식할 시 어려움이 있기 때문에 제외하였으며 또한, 수목의 정확한 수종 및 형상을 확인하기 위해 라이다 데이터 위치와 지도 서비스에서 제공하는 로드 뷰 및 실제 현장 조사를 통하여 자료 구축 후 대조하여 수목을 확인하였다.

라이다 데이터의 경우 점으로 이뤄진 3차원 데이터이므로 이미지 분석할 경우 이미지가 보여 지는 방향에 대한 고려가 필요하다. 평면의 경우 수목의 특징 및 수형, 잎의 질감, 높이 등 수목 분류에서 활용될 수 있는 주요 정보를 알고리즘이 확인할 수 없기 때문에 수목의 입면이 잘 보이는 형태 중심으로 입력 값을 설정하였다.

현재 라이다데이터에서는 다양한 시점에서 나무의 수형을 확인할 수 있는데 평면의 경우 나무의 평면 형상만 확인 가능하여 나무의 특징적인 모습을 확인하기 어려우며 입면이나 아이소메트릭의 경우 나무의 특징적인 형상을 확인할 수 있으나 아이소메트릭 뷰의 경우 시점이나 일부 각도에 따라서 나무의 특징적인 모습을 확인이 가장 용이했으며 라이다 이미지 특성상 객체가 겹쳐지는 문제로 인해 도로에서 입면으로 분석하였을 때 건물 이미지나 주변 사물과 겹치는 문제가 발생하여 적절한 이미지를 확보하기 어려워 라이다 영상의 아이소메트릭 뷰를 주로 활용하여 나무의 이미지를 입력을 진행하였다.




Figure 4. Tree area extraction from LIDAR images



Figure 5. Tree views captured in LIDAR images

분석에 사용할 수목 선정의 경우 지피식물이나 관목류의 경우 라이다 데이터를 기반 하여 수종 확인 및 분간이 어렵기 때문에 2m 이상 교목 위주로 선정하였으며 분석 수목 선정 범위도 한국에서 가로수 이용 수종이 가장 많은 10종(은행나무, 벚나무, 이팝나무, 느티나무, 양버즘나무, 배롱나무, 단풍나무, 메타세콰이어, 소나무, 백합나무)으로 선정하였다. 가로수 수종 다양화 정책으로 회화나무, 산딸나무, 모감주나무 등 다른 수종도 함께 식재 되어있으나 주요 수종 5종(은행나무, 벚나무, 이팝나무, 느티나무, 양버즘나무)이 전체 가로수의 절반 이상을 차지하고 있기에 여유 수종을 고려하여 대표적으로 많이 식재되어 있는 수종 10종을 선정하였다.

V. 분석 방법

분석 방법은 CNN 기법을 활용하였다. CNN은 Convolutional Neural Network로 이미지의 공간 정보를 유지한 상태로 학습이 가능한 모델로 수동으로 특징을 추출할 필요 없이 데이터로부터 직접 학습하는 딥러닝을 위한 신경망 아키텍처이다. CNN은 주로 이미지나 영상 데이터를 처리할 시 많이 활용되는데 영상에서 객체, 얼굴, 장면 인식과 같은 패턴을 추출할 때 유용하며 이미지 인식 분야와 같은 분야에서 많이 활용되고 있다.

Table 1. Tree species selection

수목명	학명	분류
은행나무	Ginkgo biloba	Deciduous broad-leaved tree
벚나무	Prunus sect. Cerasus	Deciduous broad-leaved tree
이팝나무	Chionanthus retusus Lindl.& Paxton	Deciduous broad-leaved tree
느티나무	Zelkova serrata	Deciduous broad-leaved tree
양버즘나무	Platanus occidentalis L.	Deciduous broad-leaved tree
배롱나무	Lagerstroemia indica	Deciduous broad-leaved tree
단풍나무	Acer palmatum	Deciduous broad-leaved tree
메타세콰이어	Metasequoia glyptostroboides	Deciduous broad-leaved tree
소나무(곰솔)	Pinus thunbergii PARL.	Evergreen coniferous tree
백합나무	Liriodendron tulipifera	Deciduous broad-leaved tree




Figure 6. Structure of CNN algorithm

그리고 이미지 분류를 위해서는 참고할 데이터셋이 필요하기 때문에 기존의 수종에 대한 입면 자료 이미지와 라이다 데이터에서 활용한 데이터를 함께 입력하여 데이터셋을 진행하여 전이 학습(Transfer learning)을 이용해 분류 모델 학습을 진행하였다. 나무의 경우 봄철, 여름철, 가을철, 겨울철 수형 및 잎의 색깔 변화가 발생하기 때문에 기본 데이터셋에서 수형 변화를 관찰할 수 있도록 다양한 데이터를 삽입하였다. 또한 라이다 데이터의 경우 점으로 이뤄진 데이터이기 때문에 라이다에서 측정된 사진에서도 이미지를 넣을 수 있도록 한다. 또한, 기존의 수목 이미지로만 이미지를 분류하기에는 데이터의 부족함이 있기 때문에 Generic dataset을 통한 사전 학습된 데이터셋을 통해 구축하고 추가적으로 이미지를 분류하여 삽입하였다. 이러한 전이학습에는 PyTorch를 활용하여 구축된 데이터셋을 활용하였다. 파이토치는 오픈소스 머신 러닝 라이브러리로 자연어와 같은 어플리케이션에 사용되며, GPU 사용이 가능하여 빠르다는 장점을 가지고 있다. 또한, Torchvision 모델을 이용해서 ImageNet 대회에서 사용된 사전학습 모델을 쉽게 사용할 수 있다는 특징을 가지고 있다. 본 연구에서는 Torchvision 모델을 활용하여 이미지 분석에 활용하였다.




Figure 7. Tree LIDAR image analysis algorithm




Figure 8. Transfer learning model conceptual diagram

VI. 학습 데이터 수집 및 학습 결과

학습 데이터의 경우 인터넷 검색 엔진을 통하여 크롤링 하여 데이터를 수집하였으며 학습한 결과 이외에도 수목에 대한 계절별 입면변화 및 수형이미지, 가로수의 형태, 각 나무의 잎이나 질감, 열매, 단풍에 대한 이미지를 수집하여 각 특징별로 10개 이상을 학습하였다. 최종적으로 학습에 필요한 이미지 데이터의 수는




Figure 9. Tree image change by season (Sawleaf Zelkova)




Figure 10. Tree images (Sawleaf Zelkova)

Street tree form



Figure 11. Street tree images

Leaves, bark, fruit



Figure 12. Tree detail images




Figure 13. Accuracy vs. number of epochs




Figure 14. Loss vs. number of epochs

1,680건을 활용하였으며 테스트에 활용한 수목 라이다 이미지의 수는 195건을 활용하였다. 그 외 추가적인 이미지에 대해 학습이 필요한 경우 데이터를 추가하여 학습할 수 있도록 하였다. 수목의 경우 계절에 따라 잎의 발생 및 소실, 색의 변화, 단풍 등이 계절마다 다르게 발생하기 때문에 4계절에 따라 이미지의 수형도 같이 수집하여 전이학습에 학습하여 분석할 수 있도록 하였다. 또한, 단목으로 식재되어 있는 경우와 노거수와 같이 대형으로 성장하는 경우, 식재한 지 오래되지 않은 묘목의 이미지, 수형의 아래에서 촬영한 경우도 학습할 수 있도록 하였다. 가로수에서 열주형으로 식재되어 있는 경우와 단독으로 식재되어 있는 경우, 나무

의 개체에 따른 크기 변화, 이식 간격에 따라서 달라지는 형상 등 다양한 경우를 학습할 수 있도록 하였다. 수목의 형상에 대한 이미지 외에도 열매나 잎사귀, 낙엽, 수피 등 다양한 이미지를 학습할 수 있도록 하였는데 이미지 크롤링의 경우 검색엔진 Bing에서 검색되는 이미지를 활용하여 크롤링 작업을 진행하였으며 수종별로 추가적으로 100개 이상의 이미지를 머신러닝에서 학습할 수 있도록 하였다. 학습이 완료된 모델은 변수를 그대로 통제하기 위하여 모델 프리징을 실시하였다.

준비된 데이터셋을 CNN 학습 모델을 활용하여 학습을 진행하였으며 학습 횟수(Epoch)는 50번으로 설정하였다. 처음 학습을 하였을 때는 Loss값은 1.4108에 정확도가 53%정도로 나타나 낮게 나타났으나 5번째에서부터 Loss값 0.1769, 정확도 94.667%로 상승하였으며 최종적으로 Loss값 0.0111, 정확도 99.86%로 나타났다.

실험적으로 학습된 모델을 평가하였을 때 실제 이미지와 분석 결과가 일치하는 결과를 나타내었으나 일부 이미지에서 불일치하는 결과가 나타났다.




Figure 15. Learning model evaluation results




Figure 16. Result of learning model mismatch
(answer: pine tree, prediction: Metasequoia)

Ⅶ. 라이다 이미지 분석

PyTorch를 활용하여 코드 작성 후 라이다 이미지 입력하고 머신러닝을 통하여 분석하였을 때 결과에 대해서 사전 검토를 진행하였다. 라이다 이미지의 경우 측정한 라이다 지점에서 확인할 수 있는 벚나무, 은행나무, 소나무, 느티나무 총 4종으로 선별하여 진행하였으며 벚나무 라이다 이미지 12점, 은행나무 이미지 13점, 소나무 이미지 10점, 느티나무 이미지 15점을 가지고 테스트를 진행하였다. 라이다로 촬영한 영상의 경우 데이터 확인을 위해 실제 위치에서 현장만 사진 촬영 및 현장 확인을 진행하였으며 실제 라이다 영상과 대조 및 확인 작업을 진행하였다.

1차에서는 라이다 이미지를 학습하지 않은 신경망을 대상으로 분석하였다. 라이다 이미지를 학습하지 않은 경우에는 50개의 이미지 중에서 3개의 이미지를 맞춰 정답률 6%로 매우 저조하게 나타났다. 이미지 3개 모두 다 벚나무를 대상으로 정답을 맞추었으며 은행나무나 소나무, 느티나무는 모두 다 오답으로 판정되었다.

라이다 이미지를 학습하기 전 모델에서는 수목에서는 주로 벚나무나 이팝나무, 백합나무 등 주로 잎의 색깔이 확연하게 차이나는 이미지를 대상으로 나무를 판별하였다. 이는 라이다 이미지에서 이미지 촬영이 되지 못한 부분은 흰색으로 처리되어 색깔을 가지지 않는 점화 상으로 처리되는데 이를 벚나무, 이팝나무 등으로 판별하는 것으로 예상된다.



Figure 17. LIDAR tree image library




Figure 18. Comparison of real trees and LIDAR images




Figure 19. Judgment incorrect cases




Figure 20. LIDAR image examples by species

2차에서는 분석해야하는 수종에 대한 대표적인 라이다 이미지 2개씩 추가적으로 학습하여 분석을 진행하였다. 학습에 사용한 라이다 수목 이미지는 분석 이미지가 아닌 별도의 이미지를 활용하여 모델 학습을 진행하였다. 2차 분석에서는 50개의 이미지 중에 27개의 정답을 맞춰 정답률은 54%로 크게 상승하였다. 특히 은행나무의 경우 정답률이 100%로 크게 상승하였으며 소나무의 경우 50%, 느티나무의 경우 53%로 모두 상승하였다. 하지만 벚나무의 경우 아무런 라이다 이미지를 학습하지 않은 1차 때는 벚나무 경우 25%의 정답률을 나타냈었으나 2차에서 라이다 이미지 학습 이후 오히려 8%로 감소하였다. 3차에서는 수종별로 5개 이상의 라이다 이미지로 모델을 학습시켜 진행하였다. 3차 분석에서는 분석 대상 50개의 이미지 중에 45개의 이미지에 대한 수종을 맞춰 전체 정답률이 90%로 크게 상승하였다. 2차 때 정답률이 낮았던 벚나무는 83%로 상승하였으며 은행나무의 경우 92%, 소나무는 80%, 느티나무는 100%로 상승하였다.

VIII. 이미지 분류 결과

라이다 수목 이미지를 학습하지 않았던 1차부터 라이다 이미지를 학습한 3차까지 정답률은 6%에서 90%까지 크게 증가하였다. 1차에서는 분류기준에서 도입되지 않은 이팝나무나 양버즘나무, 백합나무 등 흰색 꽃이 피거나 잎이 있는 수종이 주로 많이 채택되었는데 이는 라이다 이미지 특성상 라이다 센서가 색을 감지하지 못한 부분에는 흰색으로 처리되어 오답의 원인이 되기도 하였다. 하지만 모델 학습을 통하여 라이다 이

미지를 학습하였을 때 수종에 대한 화상이 정확하지 않은 라이다 이미지에서도 충분히 수종 구분이 가능할 것으로 보인다. 특히 사진 이미지랑 다르게 라이다 이미지의 경우 화상에서 나타나는 수종의 범위나 경계가 사진 이미지에 비해 명확하지 않고 기존 수목 사진에 비해 채도나 명도가 낮은 편이라 수종 분별에 어려움이 있을 것이라 예상되지만 단풍이 발생하는 시기이거나 꽃이 개화하는 시기일 경우 이미지가 확연하게 구별할 수 있기 때문에 수종에 대한 분별이 상승될 것으로 예상된다. 라이다로 수목을 분류할 경우 다양한 시기와 수종의 라이다 이미지를 통하여 학습을 진행한다고 하면 충분히 라이다 이미지 상에서 수종 분별이 가능할 것으로 예상된다.

Table 2. Learning model image prediction result

자료명	1차 예측	정답여부	2차 예측	정답여부	3차 예측	정답여부
벚나무1	벚나무	O	은행나무	X	벚나무	O
벚나무2	벚나무	O	은행나무	X	벚나무	O
벚나무3	양버즘나무	X	은행나무	X	벚나무	O
벚나무4	양버즘나무	X	은행나무	X	은행나무	X
벚나무5	양버즘나무	X	은행나무	X	벚나무	O
벚나무6	양버즘나무	X	은행나무	X	은행나무	X
벚나무7	양버즘나무	X	단풍나무	X	벚나무	O
벚나무8	양버즘나무	X	단풍나무	X	벚나무	O
벚나무9	단풍나무	X	벚나무	O	벚나무	O
벚나무10	벚나무	O	은행나무	X	벚나무	O
벚나무11	이팝나무	X	은행나무	X	벚나무	O
벚나무12	이팝나무	X	느티나무	X	벚나무	O
은행나무1	메타세콰이어	X	은행나무	O	은행나무	O
은행나무2	벚나무	X	은행나무	O	은행나무	O
은행나무3	단풍나무	X	은행나무	O	은행나무	O
은행나무4	단풍나무	X	은행나무	O	은행나무	O
은행나무5	단풍나무	X	은행나무	O	은행나무	O
은행나무6	메타세콰이어	X	은행나무	O	은행나무	O
은행나무7	단풍나무	X	은행나무	O	은행나무	O
은행나무8	양버즘나무	X	은행나무	O	은행나무	O
은행나무9	이팝나무	X	은행나무	O	벚나무	X
은행나무10	벚나무	X	은행나무	O	은행나무	O
은행나무11	양버즘나무	X	은행나무	O	은행나무	O
은행나무12	백합	X	은행나무	O	은행나무	O
은행나무13	벚나무	X	은행나무	O	은행나무	O
소나무2	백합	X	소나무	O	소나무	O
소나무3	이팝나무	X	느티나무	X	소나무	O

자료명	1차 예측	정답여부	2차 예측	정답여부	3차 예측	정답여부
소나무4	백합	X	소나무	O	소나무	O
소나무5	벚나무	X	소나무	O	소나무	O
소나무6	단풍나무	X	소나무	O	소나무	O
소나무7	벚나무	X	이팝나무	X	소나무	O
소나무8	벚나무	X	이팝나무	X	느티나무	X
소나무9	양버즘나무	X	소나무	O	소나무	O
소나무10	벚나무	X	이팝나무	X	이팝나무	X
소나무11	벚나무	X	은행나무	X	소나무	O
느티나무1	이팝나무	X	은행나무	X	느티나무	O
느티나무2	이팝나무	X	느티나무	O	느티나무	O
느티나무3	양버즘나무	X	느티나무	O	느티나무	O
느티나무4	양버즘나무	X	느티나무	O	느티나무	O
느티나무5	양버즘나무	X	느티나무	O	느티나무	O
느티나무6	양버즘나무	X	은행나무	X	느티나무	O
느티나무7	이팝나무	X	느티나무	O	느티나무	O
느티나무8	단풍나무	X	느티나무	O	느티나무	O
느티나무9	이팝나무	X	느티나무	O	느티나무	O
느티나무10	이팝나무	X	은행나무	X	느티나무	O
느티나무11	이팝나무	X	은행나무	X	느티나무	O
느티나무12	이팝나무	X	은행나무	X	느티나무	O
느티나무13	단풍나무	X	느티나무	O	느티나무	O
느티나무14	이팝나무	X	은행나무	X	느티나무	O
느티나무15	이팝나무	X	은행나무	X	느티나무	O
정답 수		3	-	27	-	45
정답률		6%	-	54%	-	90%



(a) Ginkgo



(b) Cherry



(c) A pop tree



(d) Lily tree

Figure 21. Examples of species with large differences in color

IX. 결론 및 고찰

라이다로 촬영한 수종 이미지의 경우 모델에 사진 분류에 필요한 경계나 이미지 정보가 카메라 촬영 이미지에 비해 적다는 문제점을 가지고 있지만 라이다로 촬영한 수목의 경우에도 학습할 데이터가 충분히 입력이 된다고 하면 정확도가 개선될 수 있을 것이라 예상된다.

하지만 라이다의 영상 특성상 나무 이외의 화상(건물, 도로, 자동차, 보행로 등)과 겹쳐 보이는 경우가 많으며 나무 객체 특성상 잎이 모두 찍히지 않거나 수형이 반영되지 않는 문제가 발생하였다. 이러한 문제점 때문에 수작업으로 배경을 제외하거나 라이다 자체에서 나무 객체만 분리하여 선별하는 과정이 필요할 것으로 보인다.

라이다 촬영 시 향후 객체분류에 대한 기본이 필요할 것으로 보이며 기존의 디지털 카메라로 촬영한 나무 이미지의 경우 높은 정확도를 보이는데 반해 라이다의 경우 이미지가 특히 일부 촬영이 제대로 되지 않은 이미지의 경우 하얀색으로 표시되는 경우가 있는데 이를 하얀 꽃이 피는 벚꽃나무 또는 이팝나무, 백합나무로 인식하는 문제점이 발생하였다. 라이다 이미지에 대한 개선이 필요할 것으로 보인다. 예를 들면 라이다 이미지의 색재현도, 이미지 해상도 상승 등 향후 연구에서는 나무별로 측정할 경우 다양한 상황에서 데이터셋이 필요할 것으로 보인다. 해당 연구에서는 최소한의 이미지만으로 전이학습을 진행하였으며 육안으로도 분간이 어려운 나무의 경우 분석대상에서 제외하였다. 하지만 라이다 이미지 특성상 모든 나무들이 충분한 데이터를 가지고 있지 않기 때문에 이러한 결점을 보완하거나 예측할 수 있는 특징을 학습하여 수목을 예측할 수 있도록 하여야 한다.

현재 라이다에서 도로 및 도심지를 촬영할 경우 대용량 데이터로 인해 즉각적으로 라이다 분석에 활용하기는 어려웠다. 먼저 라이다 데이터를 처리할 수 있는 고사양의 컴퓨터와 소프트웨어가 부족했으며 라이다 데이터 촬영본에서도 수목 객체를 인식하기 위해서는 현재 자동화 소프트웨어는 개발되어 있지 않으며 객체의 범위도 애매한 부분이 있어 수작업으로 나무에 대한 구분을 지어야 할 수 있었다.

또한, 현재 머신러닝 구조상 대용량의 데이터를 기반으로 딥러닝하여 구분하는 방식인데 현재 파이토치에서 라이다와 같이 실시간으로 3D 이미지를 분석하여 분류해주는 방식은 없으며 라이다와 같은 3D 객체를 대상으로 분석을 하려면 기술적인 문제가 지속적으로 개선되어야 할 것이다.

▣ 참고문헌

- [1] M. A. Lefsky, W. B. Cohen, G. G. Parker, and D. J. Harding, "Lidar remote sensing for ecosystem studies: Lidar, and emerging remote sensing technology that directly measures the three-dimensional distribution of plant canopies, can accurately estimate vegetation structural attributes and should be of particular interest to forest, landscape, and global ecologists," *BioScience*, vol. 52, no. 1, pp. 19-30, 2002.
- [2] U. Vepakomma, B. St-Onge, and D. Kneeshaw, "Spatially explicit characterization of boreal forest gap dynamics using multi-temporal lidar data," *Remote Sensing of Environment*, vol. 112, no. 5, pp. 2326-2340, 2008.
- [3] U. Vepakomma, B. St-Onge, and D. Kneeshaw, "Response of a boreal forest to canopy opening: assessing vertical and lateral tree growth with multi-temporal lidar data," *Ecological Applications*, vol. 21, no. 1, pp. 99-121, 2011.
- [4] U. Vepakomma, D. Kneeshaw, and M. J. Fortin, "Spatial contiguity and continuity of canopy gaps in mixed wood boreal forests: persistence, expansion, shrinkage and displacement," *Journal of Ecology*, vol. 100, no. 5, pp. 1257-1268, 2012.
- [5] M. D. Olivier and S. Robert, "A method to quantify canopy changes using multi-temporal terrestrial lidar data: Tree response to surrounding gaps," *Agricultural and Forest Meteorology*, vol. 237, pp. 184-195, 2017.
- [6] 황세란, 이미진, and 이임평, "항공 라이다데이터를 이용한 개별수목탐지 및 평균수고추정," *한국공간정보학회지*, vol. 20, no. 3, pp. 27-38, 2012.

ISSN 2983-3221

빅데이터서비스학회 논문집 제1권 제1호

2023년 7월 31일 인쇄

2023년 7월 31일 발행

발행인 : 최상현

발행처 : 빅데이터서비스학회

주 소 : (28644) 충북 청주시 서원구 충대로 1, 충북대학교 경영정보학과

연락처 : 043-261-2114, kbigdatapaper@gmail.com

홈페이지 : <http://www.jbig.or.kr>

인 쇄 : 한국학술정보(주)

〈비매품〉

※ 논문 및 단보 등을 포함한 본 학회지에 게재된 모든 자료의 저작권은 빅데이터서비스학회에게 있으며, 본 학회지에 수록된 자료 이용은 본 학회의 동의를 받아야 한다.