

# 인공지능 기술을 활용한 사용자 상태 모니터링 데이터 분석

□ 박철수, 조태흠, 석우준, 황보선\* / 광운대학교, \*삼성전자

## 요약

사용자의 건강 및 인지 상태 모니터링을 위해 다양한 생체신호를 측정 및 분석하여 예측할 수 있다. 특히 최근 상용화되고 있는 웨어러블 센서 시스템을 이용하여 손쉽게 심전도나 액티그래피 움직임 정보를 사용자로부터 일상생활 중 장시간 얻어낼 수 있다. 그러나 사용자 상태 예측을 위한 기존 생체신호 분석 모델들은 생체신호 데이터의 성질을 최대한 반영하지 못하여, 본 논문에서는 최근 급속도로 발전하고 있는 인공지능 딥러닝 기술을 이용한 극복 방안에 대해 소개한다. 상태 모니터링의 구체적인 응용 예로 사용자 스트레스 및 수면 모니터링 분석에 생체신호 데이터 기반 딥러닝 기술을 적용하여 기존 모델보다 높은 성능을 보여주고 있다.

## I. 서 론

다양한 상황에서 사용자의 정신적 또는 신체적 상태를 모니터링하기 위하여 얼굴 표정이나 몸짓, 움직임, 생체신호 등에 대한 다양한 정보를 추출하

고 있다. 특히 최근 웨어러블 기술들의 발전으로 사용자가 일상생활 중 항상 착용하며, 자신도 인지하지 못하는 사이 지속적으로 사용자의 다양한 생체정보를 측정할 수 있게 되었다.

심장의 상태를 전기적으로 측정할 수 있는 심전도 센서는 최근 패치형태로 소형화되어 병원에 가지 않더라도 어디서나 장시간 불편함 없이 착용하여 개인 심전도 데이터를 얻을 수 있다[1]. 심전도 정보를 통해 사용자의 심장 상태 정보 및 자율신경계 반응을 얻을 수 있어, 최근에는 이를 통해 사용자의 스트레스 정도를 모니터링하는데 활용하는 연구가 활발하다[2].

사용자의 행동 상태 정보를 모니터링하기 위해서는 액티그래피라는 손목 시계 형태의 가속도 센서 데이터를 활용하는데, 이는 웨어러블 손목 밴드 형태로 이미 많은 상용 제품들이 나와있어 손쉽게 일상생활 중의 움직임 정보를 얻어낼 수 있다. 특히

이러한 액티그래피 정보를 사용자의 수면 중 얻어내고 이를 모니터링하여 수면의 질을 평가하는데 많이 사용되어지고 있다[3].

사용자 상태 모니터링을 위한 이러한 생체신호 정보는 현재까지 대부분 특정 모델 기반 특징점 추출을 통해 이루어지고 있다. 그러나 이러한 모델들은 대부분 신호들의 정형성 및 선형성을 가정한 모델들을 적용하고 있기에, 거의 대부분의 생체신호들이 갖고 있는 비정형성 및 비선형성의 특징을 반영하여 분석하기 어려운 문제가 있다[2]. 따라서 생체신호 데이터로부터 모델을 설계하고 최적화하는 알고리즘이 필요하며, 이를 위해 최근 급속히 성장하고 있는 딥러닝 모델이 그 가능성을 보여주고 있다.

본 논문에서는 앞서 언급된 생체신호의 특징을 반영하여 심전도 및 액티그래피 데이터로부터 딥러닝 모델을 설계할 수 있는 Deep ECGNet[2]과 DeepACTINet[3]을 소개하며, 이 알고리즘들이 사용자의 스트레스 분석 및 수면 분석에 있어 기존 모델 기반 알고리즈다 보다 우수한 성능을 낸다는 것을

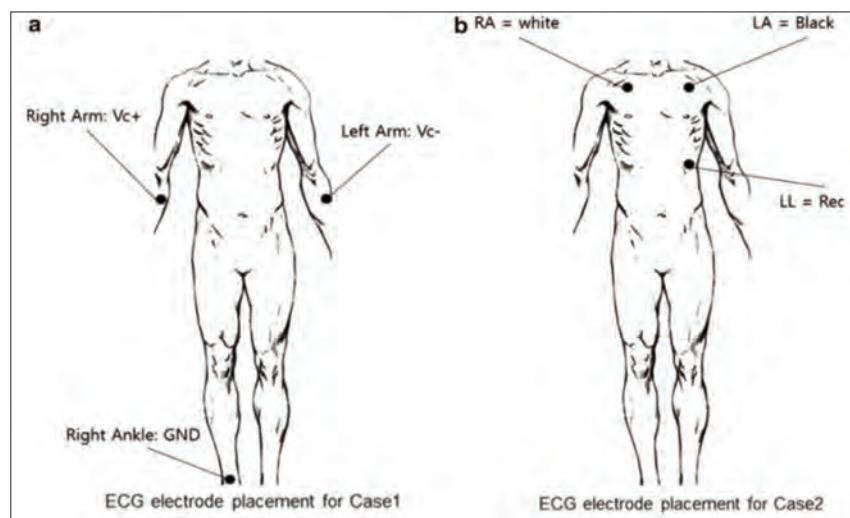
보일 것이다.

## II. 사용자 상태 측정 시스템 개요

사용자의 상태를 측정할 수 있는 신호는 전기적으로 측정할 수 있는 뇌파 및 심전도, 근전도, 안전도 등과, 사용자의 움직임 및 행동을 모니터링하는 가속도 및 자이로 센서 신호 등을 예로 들 수 있다. 전기적으로 측정할 수 있는 신호 중 심전도가 다른 신호 대비 손쉽게 측정이 가능하며, 심박 정보를 가장 정확하게 얻어낼 수 있다. 사용자의 움직임 정보는 손목 시계 형태의 가속도 센서를 활용하여 일상생활 중의 걸음 수 및 움직임의 양 등을 예측할 수 있다.

### 1. 심전도 측정 센서

심전도는 <그림 1>과 같이 센서를 양쪽 팔 및 오른쪽 다리 또는 심장 주변에 위치한 세 개의 전극을



<그림 1> 심전도 측정 센서 위치[Hwang 2018]

이용하여 측정할 수 있다[2]. 또한 최근에는 소형 패치형태로 구현이 되어 손쉽게 일상생활 중 장시간 측정이 가능한 시스템들이 상용화되고 있다. 이렇게 측정된 심전도 신호로부터 가장 신호가 높은 지점(R 피크)들을 찾아내고, 이들의 변화를 분석하여 심박수와 관련이 있는 자율신경계의 변화 추이를 예측하고 이를 통해 사용자의 상태 변화를 추정한다.

## 2. 움직임 측정 센서

사용자의 움직임은 휴대용 손목시계 형태의 가속도 센서를 이용하여 일상생활 중 장시간 측정할 수 있으며, 이러한 측정 기록 방법을 액티그래피라고 한다[4]. 이렇게 측정된 액티그래피 신호는 그 크기를 계산하여 사용자의 움직임을 모니터링하고, 이를 분석하여 수면 및 행동 패턴 등을 추정한다.

## III. 인공지능 딥러닝 알고리즘

심전도 및 액티그래피 신호 분석을 위한 기존 방법들은 대부분 모델 기반의 특징점 추출 알고리즘에 의존하였다. 이렇게 추출된 모델 기반 특징점들을 기계 학습 분석을 통하여 사용자의 상태를 최종 추정하는 방법이 대부분이었다. 그러나 이러한 방법들은 고정된 모델 및 가정을 통해 분석이 이루어지기 때문에 시간에 따라 지속적으로 그 특징이 변하는 생체신호 분석에는 최적이라고 하기 어렵다. 예를 들어 주파수 특징점 추출을 위한 푸리에 분석은 모든 신호가 정형적 그리고 선형적이라고 가정하여 고정된 정현파 모델을 이용한 분석을 수행하기 때문에, 비정형 및 비선형성을 갖는 생체신호 분

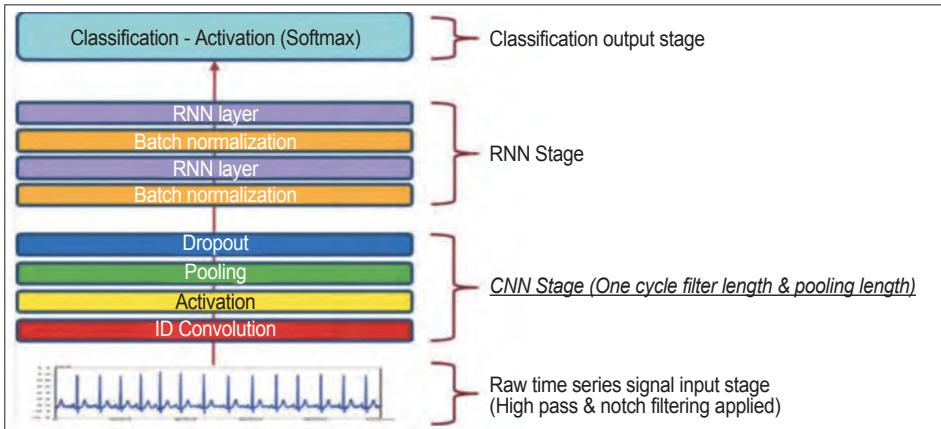
석에 최적이라고 말하기는 어려울 수 있다[2].

최근 급속도로 발전하고 있는 딥러닝 기술은 이러한 고정된 모델 및 가정에 기반하지 않고 데이터로부터 그 특징을 추출하여 분석을 한다[2]. 좀 더 구체적으로는 입력 신호와 그 신호에 따른 상태를 딥러닝 네트워크 구조에 대입하고 최적화 기술을 활용하여 네트워크의 파라미터 값들을 찾아내어 최적의 모델을 데이터 자체로부터 유도하는 End-To-End 기술이다.

이러한 딥러닝 알고리즘 또한 기존의 특징점 추출 알고리즘으로부터 획득한 특징점을 입력으로 받아 모델을 만들어가는 방법들이 제시되고 있으나, 본 기고에서는 생체신호 고유의 특징인 비정형 및 비선형성을 반영하기 위하여 데이터 자체를 입력으로 사용하여 디자인하는 End-To-End 딥러닝 구조를 강조하고자 한다. 특히 심전도 및 액티그래피 신호 분석을 위하여 최근 개발된 Deep ECGNet과 Deep ACTINet을 소개하며, 생체신호 분석에 있어 딥러닝 End-To-End 모델의 중요성을 논하겠다[2,3].

### 1. Deep ECGNet

심전도 신호 분석을 위하여 <그림 2>와 같은 딥러닝 구조가 설계되었다[2]. Deep ECGNet은 심전도 신호의 특징점을 입력으로 받지 않고 심전도 데이터 자체가 입력으로 들어가게 되고, 입력 신호의 패턴을 딥러닝 구조 내에서 찾아내기 위하여 Convolutional Neural Network(CNN) 레이어를 거치게 된다. 특히 CNN 구조 내에서는 필터 및 Pooling 레이어의 크기를 결정하기 위하여 심전도의 생리학적인 특징을 바탕으로 설계해야 최적의 심전도 패턴 추출 성능을 기대할 수 있다[2]. CNN 구조를 통해 얻어낸



&lt;그림 2&gt; 심전도 분석을 위한 Deep ECGNet[2]

심전도 패턴 정보는 Recurrent Neural Network (RNN) 구조를 거치며 시간에 따라 유사한 패턴이 나타나는 시계열 심전도 신호의 순차적인 특징을 추출하게 된다.

## 2. Deep ACTINet

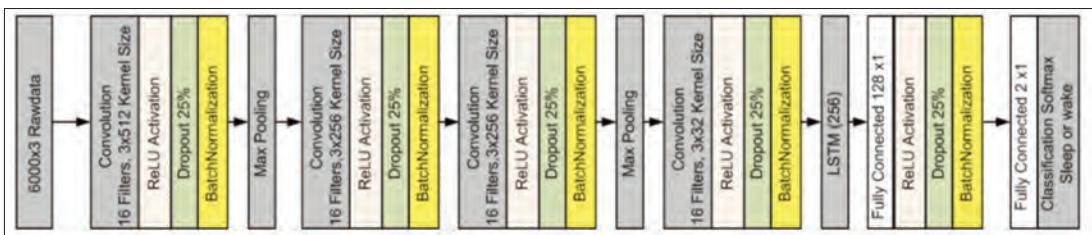
액티그래피의 가속도 센서 데이터 분석을 위하여 최근 Deep ACTINet이 <그림 3>과 같이 설계되었다[3]. 가속도 센서 데이터의 패턴을 추출하기 위하여 네 개의 CNN 구조가 설계되었으며, 시계열의 순차적인 패턴을 찾아내기 위한 RNN 구조 Long Short-Term Memory(LSTM)이 적용되었다.

## IV. 딥러닝 알고리즘의 사용자 상태 분석

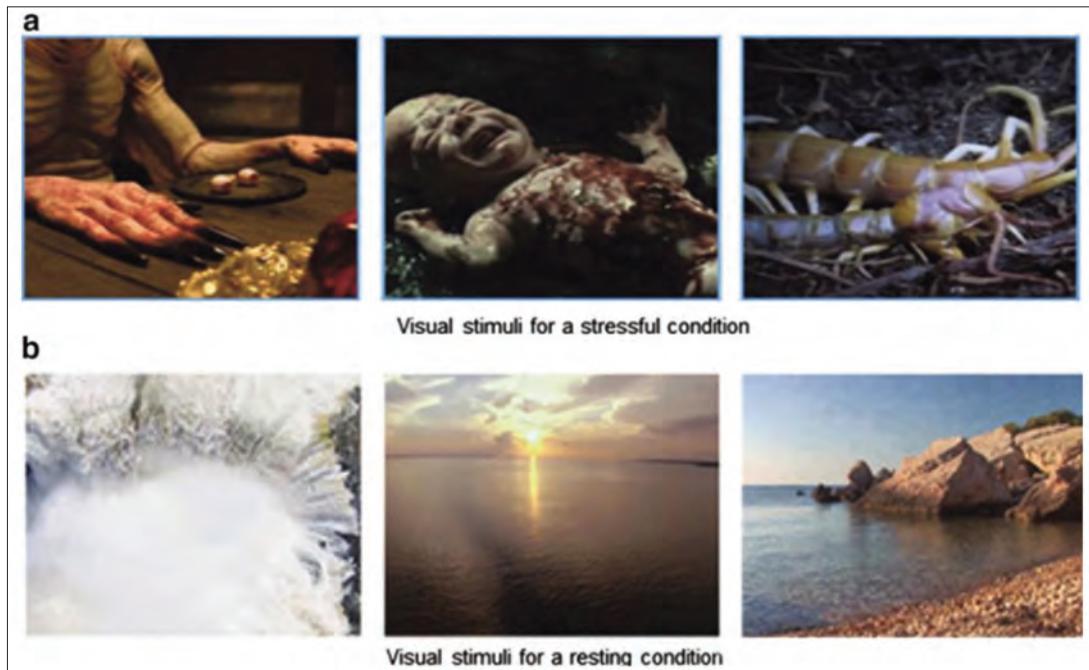
### 1. 심전도 스트레스 분석

<그림 4>와 같이 사용자에게 스트레스를 유발하거나 평온한 상태를 유도할 수 있는 비디오 클립을 보여주며 측정된 심전도 신호를 비교 분석 하여, 사용자 스트레스 예측 및 추정을 하고자 하였다[2].

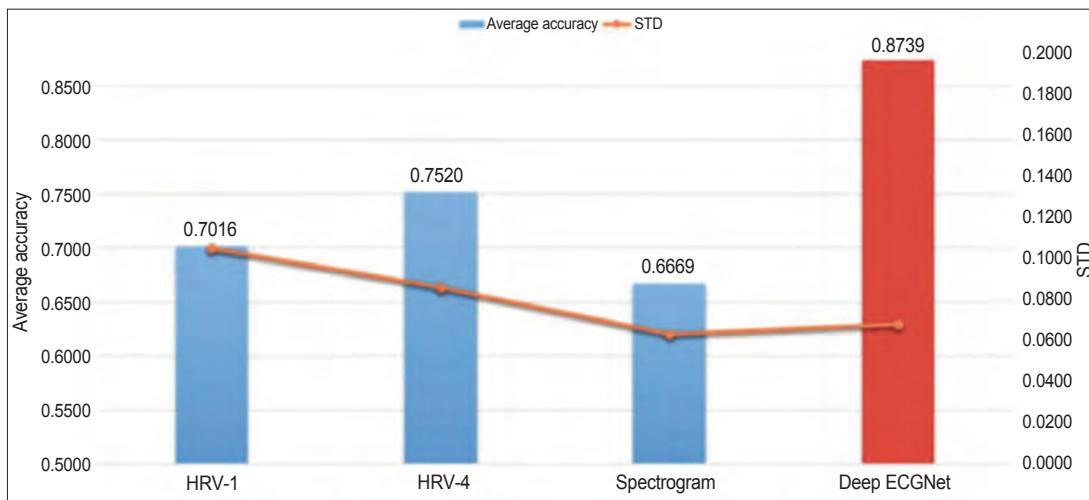
20명의 실험 대상군에게 <그림 4>와 같은 비디오 클립을 보여주며 획득한 심전도 신호를 Deep ECGNet을 통하여 학습하고, 학습된 모델의 스트



&lt;그림 3&gt; 액티그래피 가속도 센서 데이터 분석을 위한 Deep ACTINet[3]



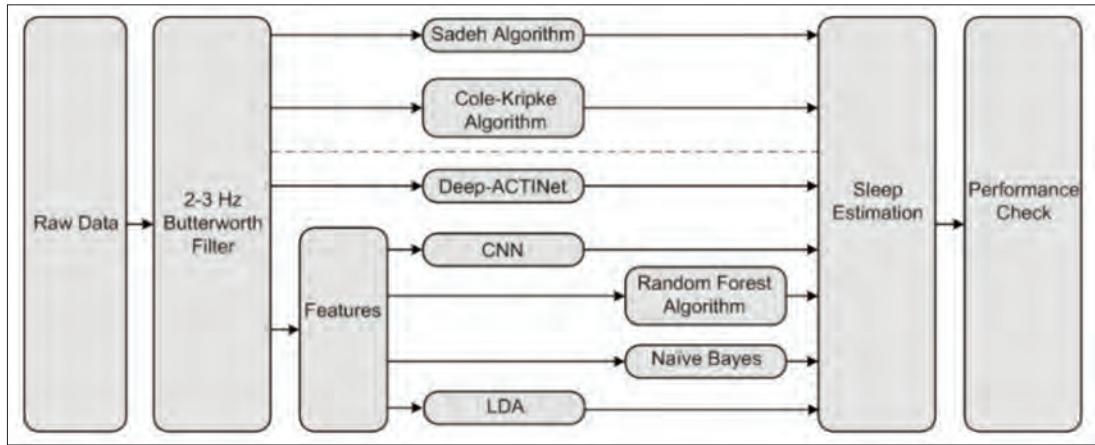
〈그림 4〉 스트레스 및 평온한 상태를 유발하는 비디오 클립 예시[2]



〈그림 5〉 Deep ECGNet의 스트레스 예측 성능[2]

레스 예측 성능을 확인하였다. 〈그림 5〉는 Deep ECGNet의 성능을 기존 모델 기반 특징점 추출 방법(HRV-1 및 HRV-4, Spectrogram)과 비교하여

나타낸 결과이다. 심전도 기반 스트레스 예측에 있어서 기존 모델 기반 방법보다 10% 이상 뛰어난 성능을 얻어낼 수 있었다.



&lt;그림 6&gt; 액티그래피 가속도 센서 데이터 분석 벤치마크 실험[3]

## 2. 가속도 센서 수면 분석

휴대가 편리한 손목시계 형태의 가속도 센서는 일상 생활 중 손쉽게 액티그래피 신호를 얻을 수 있게 해 준다. 특히 수면 중에도 수면을 방해하지 않으며 센서 작용이 가능하여 많은 수면 모니터링 연구에 사용되어지고 있다. 이렇게 얻어낸 가속도 센서 신호는 현재까지 대부분 그 절대적인 크기만을 보고 수면 중 어느정도 움직였는지를 바탕으로 수면 중인지 아닌지를 판단한다.

Deep ACTINet을 활용하여 좀더 정확한 가속도

센서 기반 수면 분석을 하였다. 이를 위해 10명의 실험 대상군으로부터 7일동안 연속 측정한 액티그래피 신호를 획득하였다[3]. 기존 전통적인 방법의 수면 분석 알고리즘 및 특징점 기반 기계 학습 알고리즘들과 Deep ACTINet의 성능을 비교하기 위하여 <그림 6>과 같은 벤치마크 실험을 설계하였다.

<표 1>은 <그림 6>의 벤치마크 테스트 결과를 나타낸 것이다. 전통적인 수면 분석 알고리즘인 Sadeh, Cole-Kripke 알고리즘 뿐만 아니라 기존 특징점 기반 머신러닝 분석 방법들(Feature-Based CNN, Random Forest, Naïve Bayes,

&lt;표 1&gt; 수면 분석 벤치마크 테스트 결과[3]

Methods	Accuracy (%)	Recall (%)	Precision (%)
Sadeh	$84.91 \pm 3.80$	$89.03 \pm 6.41$	$89.19 \pm 3.74$
Cole-Kripke	$80.30 \pm 4.13$	$79.38 \pm 6.48$	$90.73 \pm 5.25$
<b>Deep-ACTINet</b>	<b><math>89.65 \pm 3.67</math></b>	<b><math>92.99 \pm 4.32</math></b>	<b><math>92.09 \pm 2.11</math></b>
Feature-Based CNN	$84.14 \pm 3.88$	$90.40 \pm 3.13$	$87.08 \pm 3.55$
Random Forest	$85.60 \pm 4.06$	$91.06 \pm 6.30$	$87.71 \pm 2.34$
Naïve Bayes	$81.43 \pm 7.51$	$86.21 \pm 9.72$	$86.72 \pm 2.99$
LDA	$82.78 \pm 2.16$	$87.54 \pm 3.65$	$86.93 \pm 3.05$

LDA)보다도 Deep ACTINet이 우수한 성능을 얻어 낸다는 것을 확인할 수 있었다.

## V. 결 론

본 논문에서는 사용자의 상태 모니터링을 위한

인공지능 딥러닝 기술에 대해 소개하였다. 시간에 따라 지속적으로 변하는 생체 신호의 특징을 좀 더 정확하게 분석하기 위해서는, 고정된 모델이 아닌 데이터 기반으로 모델이 형성되는 End-To-End 딥러닝 모델을 심전도 스트레스 예측과 수면 상태 모니터링에 적용해야 더 좋은 성능을 낸다는 것을 확인할 수 있었다.

### 참고 문헌

- [1] 이원규, 하용남, 윤희남, 김기언, 박광석, T-REX: 일상생활 중 심전도 모니터링을 위한 패치형 시스템. 대한의용생체공학회 춘계 학술대회 2014. 05
- [2] B. Hwang, J. You, T. Vaessen, I.M. Germeyns, C. Park, and B.T. Zhang, Deep ECGNet: An Optimal Deep Learning Framework for Monitoring Mental Stress Using Ultra Short-Term ECG Signals. *TELEMEDICINE and e-HEALTH* 24 (2018), pp. 1-20
- [3] T. Cho, U. Sunarya, M. Yeo, B. Hwan,, Y.S. Koo, and C. Park, Deep-ACTINet: End-to-End Deep Learning Architecture for Automatic Sleep-Wake Detection Using Wrist Actigraphy. *Electronics* 9 (2019), pp. 1-21
- [4] 김종원, 수면연구를 위한 액티그라피 정량분석 방법론. 수면정신생리 2016

### 필자소개



#### 박 철 수

- 2004년 : 서강대학교 전자공학과 학사
- 2006년 : 서울대학교 의용생체공학과 석사
- 2012년 : 임페리얼 칼리지 런던 박사
- 2014년 ~ 현재 : 광운대학교 컴퓨터정보공학부 교수
- 주관심분야 : 인공지능, 머신러닝, 생체신호처리



#### 조 태 흠

- 2017년 : 광운대학교 산업심리학전공 학사
- 2020년 : 광운대학교 지능정보시스템 임베디드SW공학과 석사
- 주관심분야 : 인공지능, 머신러닝, 빅데이터 분석

## 필자 소개



### 석우준

- 2017년 : 광운대학교 로봇학부 지능시스템 전공(학사)
- 2019년 : 광운대학교 지능정보시스템 임베디드 SW 공학과(석사)
- 주관심분야 : 인공지능, 머신러닝, 빅데이터 분석



### 황보선

- 2004년 : 서강대학교 전자공학과 학사
- 2007년 : 서울대학교 의용생체공학 석사
- 2019년 : 서울대학교 컴퓨터공학과 박사
- 2007년 ~ 현재 : 삼성전자 반도체 기술연구소
- 주관심분야 : AI/ML 알고리즘, 딥러닝, 시계열데이터분석, *Simulation intelligence*