

스마트 팩토리를 위한 센서 데이터 분석과 제품 불량 개선 연구

A Study on Sensor Data Analysis and Product Defect Improvement for Smart Factory

황세웅¹ · 김종혁¹ · 황보현우^{1*}

연세대학교 정보대학원¹

요 약

ICT 기술의 발전에 따라 제조 산업은 공정 상에서 생성되는 제조 데이터를 분석하여 효율을 높이고자 많은 노력을 하고 있다. 본 논문에서는 스마트 공장의 일환으로 의사결정나무 알고리즘(CHAID)을 이용한 데이터 마이닝 기반 제조공정을 제안한다. 약 5개월간 수집된 실제 제조 공정의 432개 센서 데이터를 활용하여 불량률이 낮은 안정적인 공정 기간과 불량률이 높은 불안정한 공정 기간 간에 유의미한 차이를 보이는 변수를 찾아냈다. 선정된 최종 변수가 불량률 개선에 실제로 효과가 있는지를 측정하기 위해 해당 변수의 안정 값 범위를 설정하여 14일 간 공정에서 해당 센서가 안정 값의 범위를 벗어나지 않도록 공정 설정 값을 조절했고, 불량률 개선의 효과를 측정하였다. 이를 통해 제조 산업에서 생성되는 공정 센서 데이터를 활용 및 분석하여 불량률을 개선할 수 있는 실증적인 가이드라인을 제시할 수 있을 것으로 기대한다.

■ 중심어 : 스마트 팩토리, 인터스트리 4.0, 센서, 예지 정비, 의사결정나무

Abstract

In recent years, many people in the manufacturing field have been making efforts to increase efficiency while analyzing manufacturing data generated in the process according to the development of ICT technology. In this study, we propose a data mining based manufacturing process using decision tree algorithm (CHAID) as part of a smart factory. We used 432 sensor data from actual manufacturing plant collected for about 5 months to find out the variables that show a significant difference between the stable process period with low defect rate and the unstable process period with high defect rate. We set the range of the stable value of the variable to determine whether the selected final variable actually has an effect on the defect rate improvement. In addition, we measured the effect of the defect rate improvement by adjusting the process set-point so that the sensor did not deviate from the stable value range in the 14 day process. Through this, we expect to be able to provide empirical guidelines to improve the defect rate by utilizing and analyzing the process sensor data generated in the manufacturing industry.

■ Keyword : Smart Factory, Industry 4.0, Sensor, Predictive Maintenance, Decision Tree

I. 서론

제조생산을 위한 수직적 통합 및 네트워크화된 제조 시스템을 다루는 Industry 4.0의 핵심 요소인 스마트 팩토리는 공정들을 빅데이터와 결합시켜 피드백을 제공하고 이를 활용하여 높은 효율성을 얻을 수 있도록 해준다[23]. 그리고 공장 내의 제조 가치사슬의 모든 구성 요소들이 즉각적으로 커뮤니케이션하고 수직·수평적 통합을 이루어 협업을 하는 공장 시스템이라 할 수 있다 [18, 19]. 특히 데이터를 저장하고 활용할 수 있는 기술이 향상됨에 따라 수많은 설비에서 생성되는 빅데이터를 활용하여 유의미한 정보를 찾고 그러한 정보를 통해 보다 나은 의사결정을 하기 위한 연구가 활발히 이루어지고 있다[4].

본 연구에서는 섬유 산업의 한 종류인 특수원사 공정을 중점으로 머신러닝 방법론의 한 종류인 의사결정나무(CHAD) 알고리즘을 이용하여 제품 불량률을 개선할 수 있는 방안을 제시하고 솔루션 및 기술 검증을 통하여 스마트 팩토리 구현을 위한 방법을 구체화 하고자 한다. 스마트 팩토리는 사물인터넷을 통해 제조 공정에서 생성되는 데이터를 실시간으로 확인하고 분석하여 제조 공정을 체계화 하고 제품 불량 원을 분석 및 개선한다[16]. 본 연구의 사례 공정은 실시간으로 데이터는 수집되고 있지만, 적재된 데이터를 적극적으로 활용하지 못하여, 빅데이터를 통한 공정 개선이 이루어 지지 않는 상황이다. 이처럼 데이터 확보 단계에서 활용 단계로 나아가는데 어려움을 겪는 제조 산업에 데이

터 분석 가이드라인을 제공하고자 한다.

이를 위해, 제II장에서는 특수원사 산업에 대한 관련 연구와 스마트 팩토리를 위한 제조 분야의 불량 원인 분석에 관한 연구를 정리하며, 본 연구의 차별성을 부각할 것이다. 제III장에서는 본 연구의 실증 분석을 위해 실험 데이터에 대한 조작적 정의와 더불어, 머신러닝 방법론 적용을 통한 분석과 최종 모델을 도출할 것이다. 제IV장에서는 본 연구의 결과를 정리하며, 연구의 학문적, 실무적 시사점을 제시할 것이다.

II. 관련 연구

2.1 특수원사 산업 개요

특수원사 섬유는 1971년, Dupont사의 직원이었던 스테파니 크월렉에 의해 Kevlar라는 방탄복 브랜드로 개발되었고, 미국 정부가 350만 달러를 특수원사 헬멧 생산에 투자하면서 국가적 차원의 산업으로 자리잡게 되었다[7]. 이후 네덜란드의 Akzo사에 의해 Twaron 이라는 제품이 출시되었고 Kevlar와 Twaron 두 브랜드로 시장이 형성되어 현재 약 7,800톤 규모로 성장하였으며 매년 6% 이상 성장하고 있다[12].

특수원사 섬유는 강철보다 약 5배 강한 인장강도를 가지고 있으면서도 가벼운 특성을 가진 재료로, 내열성, 비강도, 탄성률이 높아 고분자 복합 재료로써 다양하게 사용되고 있다[22]. 특수원사 섬유는 자체적으로 뛰어난 강도를 가지고 있고 에폭시 수지와 함께 경화하면 비강도와 탄성률이

〈표 1〉 특수원사 세계 시장규모 및 전망(한국섬유산업연합회, 2016)

	2013	2014	2015	2016	2017	2018	2022*
수량(톤)	54,800	59,600	64,200	68,800	73,600	78,600	99,300
전년대비	-	8.8%	7.7%	7.2%	7.0%	6.8%	26.3%
금액(억 원)	18,238	19,833	21,362	22,913	24,530	26,191	33,044
전년대비	-	8.7%	7.7%	7.3%	7.1%	6.8%	26.3%

* 2022년 전년대비는 전개년의 성장률임.

〈표 2〉 국내 특수원사 소재 업체 현황[7]

업체	주요 내용
A사	<ul style="list-style-type: none"> • 세계에서 4번째로 자체 특수원사 제품 개발 • 극세 특수원사 생산기술 개발 중 • 방탄용, 자동차·선박용 마찰재용, 광케이블 용도의 특수원사 생산
B사	<ul style="list-style-type: none"> • 자체 기술 개발을 통하여 특수원사 제품 개발 • 가벼우면서, 유연한 직조기술 자체 개발 중 • 방탄판 및 차량 방탄용 특수원사 개발 중
C사	<ul style="list-style-type: none"> • 2004~2009 국내 최초로 폴리에틸렌 제품 개발 • 다양한 굵기의 원사 생산 기술개발 및 생산 중

더욱 높아진다[20]. 이러한 특성으로 특수원사 소재는 방탄, 방염 등 특수 용도의 의류나 산업용 섬유(Industrial Textiles)로 활용되고 있다[15].

국내에서도 약 3개의 주요 회사가 특수원사를 생산하여 국내외에 판매를 하고 있다[7]. 국내 시장의 경우 광케이블 신규 수요 감소 및 방탄 소재 수요의 감소로 인해 2015, 2016년에 수요가 감소하였으나, 선진국의 자동차 수요 회복 및 동남아, 중남미 광케이블 수요 증가에 따른 해외 시장의 성장으로 인해 2017년부터 수요량이 다소 회복되고 있다[11].

섬유 산업에서는 CPS(cyber-physical systems)에 기반을 둔 공장으로서 ICT와 IoT 기술을 기존 생산 시스템에 통합하여 스마트 팩토리를 구현한다[14]. 섬유 산업에서도 스마트 팩토리의 일환으로 다양한 연구가 진행되고 있으며, 기본적인 티셔츠와 같은 단순한 제품을 생산 하더라도, 많은 양의 데이터가 생성되고 저장된다. 이러한 데이터에는 제품의 원자재, 기계 설정 및 품질 정보가 포함된다. 또한 섬유의 특성, 공정의 세세한 센서 값 등이 있는데, 공정 설정 값과 직물의 성능의 관계는 변수들의 복합적인 영향 또는 비선형인 경우가 많다[24].

2.2 스마트 팩토리 제조 시스템에서의 불량 원인 분석

제조업은 시간이 갈수록 제조 원가와 인건비가

상승하고 있으며, 수요의 불규칙성 또한 강해지고 있다. 그리고 생산 설비 및 시스템 복잡성으로 인해 생성되는 데이터는 기하급수적으로 증가하고 있다[1]. 이로 인해 생산성 감소가 일어나는 것을 방지하기 위해 많은 제조기업은 빅데이터를 기반으로 유의미한 정보를 발견하고 공정의 효율을 높이기 위해 적극적으로 노력하고 있다[4]. 그러한 일환으로 발전된 개념이 사물인터넷(IOT), 무선 센서 네트워크 및 빅데이터 등과 같은 다양한 정보통신기술을 적용한 스마트 팩토리다[23].

스마트 팩토리 제조 공정은 데이터마이닝을 통해 리스크 관리와 품질 관리가 가능하기 때문에 이를 위한 연구가 계속 이루어져야 한다[15]. 스마트 팩토리를 효과적으로 적용하기 위해서는 제조 공정에서 생성되는 센서 데이터나 작업 데이터를 수집 및 분석하고, 도출된 결과를 제조 운영관리 및 품질 관리에 적용해야 한다[25]. 실시간 공정 상황 감시와 이상 징후 조기 감지를 위해 Legacy System이 통합적으로 연계된 플랫폼을 적용하기도 하며, 다수의 센서 설비와 수집된 데이터를 관리할 수 있는 실시간·통합 인터페이스를 구축하여 체계적으로 저장 및 관리할 수 있는 환경이 필요하다[21].

스마트 팩토리에서 발생하는 제품의 불량관련 분석 연구는 크게 두 종류로 나눌 수 있다. 불량과 연관이 있는 변수(센서)를 찾아내는 방법을 연구한 것이 있고, 불량과 관련 있는 변수를 통해 불량을 판별하는 모델을 연구한 것이 있다. 김승

민[2]은 CCA(Canonical Correlation Analysis)를 이용한 상관분석을 하여 불량과 관련이 높은 공정을 찾아내는 연구를 진행하였고, 김주창 외[3]는 공정에서 유의미한 불량 원인을 도출하기 위해 의사결정 모델을 이용한 순차 마이닝 기반 제조공정을 제안하였다. 의사결정 모델은 데이터 마이닝의 예측 모델링 방법 중의 하나이며, 측정값과 결과값의 인과 관계를 예측하는 모델이다.

변수 값 이상을 판별하기 위해 사용되는 가장 기본적인 예측 및 탐지 방법은 회귀 모델을 통해 학습된 분석 모델을 기준으로 잡고 새로 입력되는 데이터 값을 대입하여 그 차이를 통해 이상을 감지하는 것이다. 보통 확률분포 모델과 비교하여 이상치를 검출하는 Model-based, 특정거리의 객체 밀도를 통해 이상치를 검출하는 Density-based, 각 요소들의 군집을 구성하여 이상치를 검출하는 Clustering-based, 각 요소 간 수리적 거리를 계산해 이상치를 검출하는 Distance-base 이렇게 4가지의 이상 탐지 기법이 사용된다[9].

그러나 가장 널리 사용되고 검증된 방법은 센서 데이터로부터 얻어진 평균값으로부터 일정 기준의 상·하한 값을 기준으로 두고 이를 시각화 하여 상·하한 범위에서 벗어나는 경우에 경

보를 한다[8]. 이는 공정 관리자가 실시간으로 확인할 수 있도록 모니터링 화면으로 제공되는 것이 좋다. <그림 1>과 같이 제조 공정의 불량률과 연관된 센서의 평균 값으로부터 일정 기준(예를 들어 2표준편차)으로 상한선과 하한선을 설정하고 해당 기준선을 초과한 센서 값이 나왔을 때 예지 경보를 발생시킬 수 있다[6].


이 밖에 다양한 기계 학습 방법론도 불량 원인 예측에 활용된다. SVM(Support Vector Machine)과 같은 분류 모델이나 베이지안 분류기(Bayesian classifier), 비선형 모델 생성에 적합한 인공신경망 등의 모델들을 적용하여 성과를 내는 경우도 있으나, 일반적으로 사용되지는 않는다[5].

2.3 본 연구의 차별성

최근 스마트 팩토리의 명목으로 센서 데이터를 활용한 다양한 제품 불량 개선 모델 연구가 활발히 이루어지고 있다. 하지만 다양한 분석 모델이 실험적으로 사용되고 있으며, 특정 도메인에만 국한된 방법론을 제시하고 있다. 또한 제품 불량률과 연관 있는 공정을 검출하는 것과 검출한 변수를 통한 불량 예측 분석을 함께 진

<표 3> 주요 이상 현상 탐지 기법(이준희, 2017)

기술	내용
Model-based	확률분포 모델과 비교하여 이상치를 검출
Density-based	특정거리의 객체 밀도를 통해 이상치를 검출
Clustering-based	각 요소들의 군집을 구성하여 이상치를 검출
Distance-base	각 요소 간 수리적 거리를 계산해 이상치를 검출



<그림 1> 상·하한 기준선을 활용한 공정 관리도

행한 연구는 거의 이루어지지 않았다. 따라서 본 연구는 두 가지 요소를 함께 고려하여 불량 예지 모델을 적용 했을 때 효과를 측정하고자 한다. 아울러 국내에서 거의 연구가 이루어지지 않았던 특수원사 공정에 적용하여 새로운 가이드라인을 제시하고자 한다.

III. 실험 설계

3.1 실험 데이터 정의

본 연구에서 사용될 데이터 집합은 실제 제조 공장에서 생성된 공정 설비 데이터다. 대상 제조업체에서는 초 단위의 센서 데이터는 히스토리안(Historian) DB에, 제품 생산 정보는 생산관리 시스템 DB에 적재되어 있었다. 해당 DB에서 연구와 관련된 총 984개 센서, 약 1,100억 건의 데이터를 추출하여 Data Mart를 구축하였다. 센서 데이터는 재료 투입 시점부터 방사까지 전 공정을 대상으로 하였다.

분석에 적합하도록 데이터를 표준화 및 가공하였다. 불량(절사)의 원인과 결과에 모두 연관되어 있어 분석결과를 왜곡시키는 변수(센싱 데이터)를 표준화 처리하였으며, 초(second)단위 센싱 데이터를 분(minute)단위 평균으로 변환하였다. 또한 데이터 분석에 사용되는 모델에 따라 데이터 형태를 행 또는 열 단위로 가공하였다.


최종 분석에 사용된 데이터는 2017년 10월부터 2018년 3월까지 약 5개월 간 적재된 데이터가 사용되었으며, 값이 0, 1로만 구성된 디지털 tag 변수와 중복 성향의 Tag들을 제거하여 432

개 센서 tag를 최종 분석 대상으로 선정하였다. 특수원사 전체 생산 건(타래 단위) 중 약 3.2%의 불량률을 보이고 있다.

3.2 방법론 적용을 통한 분석과 모델 도출

분석에 사용된 432개의 변수 중 특수원사 제품 불량과 관련 있는 변수를 찾아내기 위해 불량률이 낮았던 기간을 ‘Regular section’, 불량률이 높았던 기간을 ‘Defective section’으로 분리하여, 각 구간에 해당하는 변수의 값이 서로 차이가 있는 변수를 선정했다. 세부적으로는 기준이 되는 ‘Defective section’ 3영역이 지정 되었고, ‘Regular section’은 ‘Defective section’ 앞뒤로 6영역이 지정되었다. 그리고 ‘Defective section’은 불량률이 급등한 부분만을 대상으로 한 구간과 불량률이 높았던 전체 구간 두 종류로 나누었다. 그리고 공정 A호기의 데이터만 보거나, B호기만 보거나, A호기, B호기 전체를 함께 보는 세 가지 경우로 분류하고, 데이터 표준화 여부에 따라 두 종류로 구분했다. 이러한 경우의 수의 조합을 통해 총 72가지의 시나리오가 도출되었고, 의사결정나무 알고리즘(CHAD)을 통해 각 시나리오마다 유효 변수 상위 10개의 리스트를 산출했다.

의사결정나무는 의사결정규칙(decision rule)을 지정하여 분석 대상의 집단을 규칙에 따라 몇 개의 소집단으로 분류(classification)하거나 예측(prediction)을 할 수 있는 데이터 분석 방법인데, 집단 분류 방법이 직관적이기 때문에 다른 분석 방법인 판별 분석(Discriminant Analysis), 회귀분



〈그림 2〉 특수원사 불량률에 영향을 미치는 요소 분석 구조

〈표 4〉 분석 시나리오

시나리오 구성 내역					총 시나리오
기준 Defective section	분석 대상 설비	데이터 표준화 여부	Regular vs. Defective 비교 구간	Defective 구간선정	
1. 1지점 2. 2지점 3. 3지점	1. 전체 2. A호기 3. B호기	1. 미적용 2. 적용	1. Defective section 전 2. Defective section 후	1. 급등 구간 2. 전체 구간	3×3×2×2×2 = 총 72가지 시나리오

석(Regression Analysis), 신경망(Neural Networks) 등과 같은 방법들에 비해 해석이 용이하여 산업 실무에 사용하기 적합한 방법론이다[10].

의사결정나무에서 대표적으로 사용되는 알고리즘은 CHAID(Chi-squared Automatic Interaction Detector), CART(Classification and Regression Trees), C 5.0 등이 있다[13]. 본 연구에서는 의사결정나무 분석을 위해 SAS Enterprise Guide 7.1 솔루션을 사용하였으며, 기본적으로 제공하는 CHAID 알고리즘을 사용하였다. CHAID 알고리즘은 목표변수가 범주형일 때, Pearson의 카이제곱 통계량을 분리기준으로 사용한다. 카이제곱 통계량은 다음과 같이 정의된다[17].

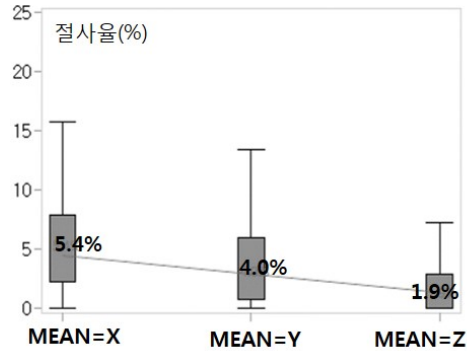
$$x^2 = \sum_{i,j} \left(\frac{(f_{ij} - e_{ij})^2}{e_{ij}} \right)$$

분석에 사용된 총 72가지의 시나리오 조합을 정리하면 <표 4>와 같다.


산출된 유효 변수들 중 단 다섯 개의 변수가 72개 시나리오에서 모두 유의미하게 나왔다. 이

에 따라 의사결정나무로 도출된 다섯 개의 변수를 최종 후보 변수로 선정하였고, 공정 실무자들과 FGD를 통해 실무적 입장에서 의미 없는 변수 네 가지를 제외하여, 최종적으로 하나의 유효 변수를 선정하였다.

최종 선정된 변수는, 불량률이 낮았던 ‘Regular section’과 불량률이 높았던 ‘Defective section’ 간에 차이가 유의미하게 나타났다. 최종 선정된 태그값 평균이 X일 경우 5.4%의 불량률을 나타냈고, Z일 경우, 1.9%로 확연히 낮은 불량률을 나타냈다.



〈그림 3〉 최종 선정 변수와 불량률 관계



〈그림 4〉 최종 선정 변수의 안정 범위

따라서 최종 선정된 변수의 'Regular section' 평균 값인 Z 의 2표준편차 구간인 $Z-2\sigma \sim Z+2\sigma$ 을 불량률 안정 범위로 설정하였다.

IV. 결 론

본 연구에서는 약 5개월간 수집된 실제 특수원사 공정의 432개 센서 데이터를 활용하여 불량률이 낮은 안정적인 공정과 불량률이 높은 불안정한 공정의 차이를 의사결정나무 알고리즘(CHAID)을 통해 분석하였다. 그 결과, 불량률과 유의미한 관련이 있는 5개의 변수를 도출했고, 실질적인 활용이 가능한 변수를 선택하기 위해, 실무진과의 FGD를 통해 하나의 변수를 최종 선정했다.

선정된 최종 변수가 불량률 개선에 실제로 효과가 있는지를 측정하기 위해, 2017년 10월부터 2018년 3월까지 약 5개월 중 'Regular section'에 해당되는 기간의 최종 변수 평균값 Z 를 구한 후, Z 의 2 표준편차 구간인 $Z-2\sigma \sim Z+2\sigma$ 를 안정 값 구간으로 설정하였다. 그리고 2018년 7월부터 14일간 공정에서 최종 변수 센서가 안정 값의 범위를 벗어나지 않도록 공정 설정 값을 조절했다. 그 결과, 실험 데이터 기준 3.2%였던 제품 불량률이 테스트 기간인 14일간 2.7%로 약 15.6%(0.5%p) 가량 개선되었다.

이를 통해 특수원사 산업에서 생성되는 공정 센서 데이터를 활용 및 분석하여 불량률을 개선할 수 있는 실증적인 가이드라인을 제시할 수 있다. 수 많은 설비에서 생성되는 빅데이터를 활용하여 유의미한 정보를 찾고 그러한 정보를 통해 보다 나은 의사결정을 하는 스마트 팩토리 구현을 위한 방안을 구체화 하였다. 하지만 검증 기간이 비교적 짧기 때문에 해당 변수의 설정 값에 대한 효율성은 보다 면밀한 검토가 필요할 것으로 보인다. 그리고 본 연구에서 사용된 모델은 실무진과의 FGD를 포함하기 때문에

실무진의 역량과 관여 정도에 따른 영향력에 대한 측정도 필요할 것으로 보인다.

참 고 문 헌

- [1] 김수영, 송민강, "MI-NPS 디지털팩토리 방법론을 활용한 생산능력의 향상 및 최적 레이아웃 구축에 관한 연구: 자동차 부품 Shaft 제조라인 적용 사례", 생산성논집, 제28권, 제1호, pp. 47-73, 2014.
- [2] 김승민, 백준걸, "정준상관분석을 이용한 공정 설비 상태에 영향을 미치는 변수 선택", 한국경영과학회 학술대회논문집, pp.3915-3921, 2015.
- [3] 김주창, 정호일, 유현, 정정용, "스마트 공장에서 의사결정 모델을 이용한 순차 마이닝 기반 제조공정", 한국융합학회논문지, 제9권, 제3호, 2018.
- [4] 노규성, 박상휘, "제조실행시스템에의 빅데이터 적용방안에 대한 탐색적 연구", Journal of Digital Convergence, 제12권, 제1호, pp.305-311, 2014.
- [5] 노선영, 서봉균, 이상완, 김준우, "스마트 팩토리 고도화를 위한 예측 분석 시스템 프레임워크 설계", 한국통신학회 학술대회논문집, pp.791-792, 2017.
- [6] 배재호, "롤 형상 필름 생산에서 두께평활도 개선을 위한 고정굴곡부 발현 모형 및 개선 모델", 산업경영시스템학회지, 제38권, 제3호, pp.21-28, 2015.
- [7] 서혁, 신종필, 강윤구, "국가 차원에서 챙겨야 할 군용 방탄복 산업의 현실태 및 정책 방향제안", 국방과 기술, 제423호, pp.62-75, 2014.
- [8] 안동혁, "제조공정에서의 지속적 예지 분석을 위한 조건", 한국콘텐츠학회지, 제15권, 제3호, pp.21-26, 2017.
- [9] 이준희, 김신령, 김영곤, "빅데이터 분석을 활

- 용한 스마트 팩토리 이상탐지 및 보안 강화 시스템에 관한 연구”, 한국통신학회 학술대회 논문집, pp.347-348. 2017.
- [10] 최종후, 서두성, “데이터마이닝 의사결정나무의 응용”, 통계분석연구, 제4권, 제1호, pp.61-83, 1999.
- [11] 한국섬유개발연구원, 2017, <http://super.textopia.or.kr:8888/newsletter/170530/lib0101.pdf>.
- [12] 한국섬유산업연합회, 2016, http://www.kofoti.or.kr/bbs/data/1611_data_16.pdf.
- [13] Choi, J. H., S. T. Han, H. C. Kang, E. S. Kim, M. K. Kim, and S. K. Lee, *Data mining prediction and application*. Seoul: SPSS academy, 2002.
- [14] Gubbi, J., R. Buyya, S. Marusic, and M. Palaniswami, “Internet of Things (IoT): A vision, architectural elements, and future directions”, *Future Generation Computer Systems*, Vol.29, No.7, pp.1645-1660, 2013.
- [15] Jun, C., B. H. Kim, and J. Y. Lee, “A Big Data Analysis Platform based on the Manufacturing Specialized Library : A Case Study on Implementation of the Platform for Quality Problems”, *Journal of the Korean Institute of Industrial Engineers*, Vol.43, No.5, pp.380-387, 2017.
- [16] Kang, H. S., J. Y. Lee, S. Choi, H. Kim, J. H. Park, J. Y. Son, and S. D. Noh, “Smart manufacturing: Past research, present findings, and future directions”, *International Journal of Precision Engineering and Manufacturing-Green Technology*, Vol.3, No.1, pp.111-128, 2016.
- [17] Kass, G. V., “An exploratory technique for investigating large quantities of categorical data”, *Applied Statistics*, pp.119-127, 1980.
- [18] Lasi, H., P. Fettke, H. G. Kemper, T. Feld, and M. Hoffmann, “Industry 4.0”, *Business & Information Systems Engineering*, Vol.6, No.4, pp.239-242, 2014.
- [19] Lee, J., “Smart factory systems”, *Informatik-Spektrum*, Vol.38, No.3, pp.230-235, 2015.
- [20] Lee, M. K., S. B. Bae, J. K. Park, and S. G. Lee, “The Development of High Performance Nano-composites with Carbon Nanotube”, *Textile Coloration and Finishing*, Vol.26, No.2, pp.71-78, 2014.
- [21] Schlechtendahl, J., M. Keinert, F. Kretschmer, A. Lechler, and A. Verl, “Making existing production systems Industry 4.0-ready”, *Production Engineering*, Vol.9, No.1, pp.143-148, 2015.
- [22] Tanaka, K., K. Minoshima, T. Oya, and K. Komai, “Influences of stress waveform and wet environment on fatigue fracture behavior of aramid single fiber”, *Composites Science and Technology*, Vol.64, No.10-11, pp.1531-1537, 2004.
- [23] Wang, S., J. Wan, D. Li, and C. Zhang, “Implementing smart factory of industrie 4.0: an outlook”, *International Journal of Distributed Sensor Networks*, Vol.12, No.1, 2016.
- [24] Yildirim, P., D. Birant, and T. Alpyildiz, “Data mining and machine learning in textile industry”, *Wiley Interdisciplinary Reviews : Data Mining and Knowledge Discovery*, Vol.8, No.1, e1228, 2018.
- [25] Yin, S. and O. Kaynak, “Big data for modern industry : challenges and trends [point of view]”, *Proceedings of the IEEE*, Vol.103, No.2, pp.143-146, 2015.

저 자 소 개



황 세 응(Sewong Hwang)

- 2015년: 연세대학교 정보시스템 (석사)
- 2017년~현재 : 연세대학교 비즈니스 빅데이터 분석 박사과정
- 관심분야 : Smart Factory, IoT,

Big data, business strategy 등



김 중 혁(Jonghyuk Kim)

- 2016년 : 연세대학교 정보시스템 (박사)
- 2016년 : 가천대학교 글로벌 경제학과 겸임교수
- 관심분야 : Smart Factory, IoT, Big data, business strat-

egy 등



황보현우(Hyunwoo Hwangbo)

- 2017년 : 연세대학교 정보시스템 (박사)
- 2017년~현재 : 연세대학교 정보대학원 시간강사
- 2018년~현재 : 단국대학교 데이터지식서비스공학과 겸임

교수

- 관심분야 : IT Governance, Internet of Things, Distributed Sensor Network 등