

필터류를 이용한 철강공장 압연 생산 데이터의 취득과 머신러닝의 효율화로 예방적 유지보수 방안 연구

조현성
부천대학교 전자공학과

A study on the acquisition of steel mill rolling production data using filters and preventive maintenance methods by improving the efficiency of machine learning

Hyun-Sung Cho
Division of Electric Engineering, Bucheon University

요약 개발된 칼만필터와 베이지안 기계학습을 응용한 예방적 유지보수 모델의 필요성은 정의된 수준의 가용성과 안정성을 유지하면서 총 유지 관리 비용을 최소화하는 것이다. 본 연구는 복잡한 수리 가능한 시스템에서 비용을 최적화하고 기계의 유효 수명을 향상시키기 위한 예방적 유지보수 스케줄링 모델을 제안한다. 유지보수 비용에는 임의 고장으로 인한 손실 비용, 수리 비용, 교체 비용 및 계획된 총 다운타임 비용이 포함된다. 검사, 수리 및 교체와 같은 다단계 예방 유지 관리 조치는 전체 계획 기간에 포함된다. 제철공장의 스마트팩토리 생산관리시스템에서 추출한 압연공정의 데이터를 기반으로 최적화 모델을 이용하였으며 최적의 솔루션을 제공하기 위해 시뮬레이션을 수행하였다. 데이터분석 프로그래밍 언어 R은 오픈 소스 플랫폼이며 RStudio는 R프로그램 작성 및 실행을 위한 통합 개발환경 프로그램(IDE)이다. 16GB RAM 및 Windows 10 Pro가 탑재된 Intel Core i5에서 실행되는 작업공간에서 R의 프로그램을 사용하여 칼만 필터와 베이지안 기계학습 알고리즘을 응용했다. 제안된 알고리즘과 수학적 모델을 제 4차 산업혁명의 스마트팩토리에 적용할 경우 유지보수 비용을 8~10%의 절감을 목표로 원가절감을 통한 기업경쟁력의 향상이 기대된다.

Abstract This study proposes a predictive maintenance scheduling model to optimize the cost and improve useful life of machines in complex repairable systems. A preventive maintenance model was applied using a developed Kalman filter and Bayesian machine learning to minimize the total maintenance cost while maintaining a defined level of availability and stability. Maintenance costs include loss costs due to random failures, repair costs, replacement costs, and total planned downtime costs. Multi-level preventive maintenance measures such as inspection, repair, and replacement are included in the overall planning period. An optimization model was used based on data from a rolling process extracted from a smart-factory production-management system for a steel mill. A simulation was performed to provide an optimal solution. A program in R was used to apply the Kalman filter and Bayesian machine learning algorithm. To provide an optimal solution using an optimization model, a Kalman filter and a Bayesian machine learning algorithm were applied using R. If the proposed algorithm and mathematical model are used in a smart factory, it could improve competitiveness through cost reduction by reducing maintenance costs by 8-10%.

Keywords : Artificial Intelligence, Convergence and Complex, Kalman Filter, Machine Learning, Predictive Maintenance

본 논문은 부천대학교 연구과제로 수행되었음.

*Corresponding Author : Hyun-Sung Cho(Bucheon Univ.)

email: joedaniel@bc.ac.kr

Received March 3, 2023

Revised March 27, 2023

Accepted April 7, 2023

Published April 30, 2023

1. 서론

1.1 연구배경 및 목적

오늘날의 자동화 세계에서 기계학습 기술은 수집된 데이터를 최대한 활용하기 위해 다양한 장소에서 적용되고 있다. 특히, 제4차산업의 융·복합 스마트팩토리에서 오류 예측은 중요한 주제이다[1]. 회전하는 기계 구성 요소의 상태를 모니터링하여 조기에 결함을 감지하고 기계 상태를 식별하여 실패 위험을 최소화할 수 있다. 상태 모니터링의 주요 목적은 2차 손상, 기계 가동 중지 시간, 잠재적인 안전 사고, 생산 손실 및 수리와 관련된 더 높은 비용을 유발할 수 있는 치명적인 기계 고장을 방지하는 것이다[2]. 본 연구에서 제안한 칼만필터 기반의 베이지안 기계학습 모델은 더 나은 예측정비의 성능을 위해 연구 개발하였다. 이러한 모델의 효율은 인위적인 알고리즘을 모의시험할 때 특정 매개변수의 변화에 따라 장애가 되는 데이터가 선택되어 나타난다[3]. 본 연구에서는 비교적 나은 성능을 보이는 베이지안 최적화를 사용한다. 베이지안 최적화는 단일 또는 많은 가우스 프로세스에서 알려지지 않은 함수를 가정하여 직전의 값과 현재값을 이용하여 사후 분포를 예측한다. 본 연구에서는 가장 널리 사용되는 군집분석 알고리즘 중 하나인 K-평균 군집분석 방법을 사용한다. 우리의 작업은 입력 값의 미세 조정과도 관련이 있으며, 이를 위해 다른 알고리즘인 칼만 필터[4]를 사용한다. 처음에 칼만 필터에서 제공한 값을 사용하여 k-평균 군집분석 메커니즘을 제공한다. 이들은 군집분석 절차를 개선하고 분류하기 위해 함께 작용한다.

개선된 반 지도학습의 K-평균 군집분석[5]은 데이터 양이 불충분한 상태에서 다중의 목표를 최적화할 때 반복되는 목적 함수의 수렴과 함께 필요하다. VANET [6] 및 로봇 공학 분야 [7]에 대한 확장 칼만 필터 접근 방식은 낮은 계산 요구 사항, 빠른 수렴 및 신뢰성을 달성하기 위한 사례이다. 기존 문헌에 의하면 이러한 제안된 접근 방식은 정확한 예측이 어렵다. 따라서 제안하는 연구는 칼만필터와 K-평균 군집분석의 조합을 이용하여 베이지안 분류의 성능을 향상시킬 수 있을 뿐만 아니라 데이터로부터 군집을 계산하는 시간을 줄일 수 있다.

베이지안 분류기는 해당 클래스의 속성 값에 대한 클래스 예측 지원을 제공한다. 베이지안 분석은 로봇 공학과 같은 지능형 시스템의 중추 역할을 할 수 있다. 이전 데이터의 분석은 서로 협력하여 동시에 분석할 수 있는 더 작은 데이터 세트로 분할하여 비교할 수 있다.

제안된 모델은 기존의 예측 알고리즘이 성능의 지속적

인 모니터링을 통해 동적 조건에 적응할 수 있도록 한다. 제안한 학습-예측 모델의 효율성을 평가하기 위해 K-평균 기법과 칼만 필터 알고리즘을 통해 정규화된 실시간 데이터의 예측 정확도를 향상시키는 베이지안 기계학습 모듈을 개발한다.

오픈 소스 모델은 실험 결과의 재현성 향상, 오류 감지 속도 향상, 기계학습 알고리즘 채택 속도 향상 등 많은 장점이 있다.

본 논문의 연구 목적은 각종 기계장치에서 발생하는 실시간 데이터를 모니터링하여 기계의 RUL(잔여 수명)을 예측하고 대처하는 것이다. 또한, 연구방법은

1. R 프로그램에서 범용성이 있는 라이브러리 dlm을 사용하여 알고리즘을 구현하며,
2. 칼만 필터와 선형·가우시안 상태 공간 모델의 매개변수에 관한 최대 우도 추정으로 베이지안 기계학습 예측 기법의 가능성을 확인하고, 자작 프로그램에 적용하여 모의시험을 한다.
3. 데이터 소스(press.csv)의 검정 변수를 사용하여 통계적 잡음 및 기타 부정확성을 확인하기 위한 제안된 베이지안 기계학습 모델을 적용하여 적합성을 판단한다.

논문의 나머지 부분은 4개의 섹션으로 구성된다. 2장에서는 칼만필터와 베이지안 기계학습 모델에 대한 가용 문헌에 대한 배경 및 관련 작업을 제시한다. 3장에서는 이 문서에서 구현에 사용되는 오픈 소스 소프트웨어 및 플랫폼에 대해 설명하고, 칼만 필터 기반 베이지안 기계학습의 예측 기법에 대해 설명한다. 4장에서는 칼만 필터 기반의 기계학습 모델을 사용하여 데이터에 대한 정합성 분석 결과를 보여준다. 마지막 섹션은 이 논문의 결론이다.

2. 관련 문헌 검토

예측유지보수는 4차산업혁명 시대에 지속 가능한 생산시스템의 주요 역할이 되고 있다. 지속적인 생산을 위해 기계가동중지 시간 및 비용을 최소화하고 수명주기를 최대화하여 생산 품질과 중단사태의 개선이 필요하다[8]. 이를 해결하기 위해 각종 센서에서 기하급수적으로 생산되는 공정 데이터를 자동으로 수집하고 처리하여 의사결정단계에 이르기 위해 이 섹션에서는 융합적인 칼만필터와 기계 학습 알고리즘을 사용하여 정확한 예측을 위한 베이지안 분석 및 프레임워크 분야의 배경 및 관련 작업

을 살펴본다.

Table 1은 예측정비의 자동화를 위한 칼만필터와 기계학습에 대한 알고리즘 활용 사례와 개선에 대한 설명을 제공한다.

Table 1. The algorithm use cases for an machine learning and Kalman filter for the automation of predictive maintenance

Type	Application	Reference	Evaluation
KF	Life Loss Prediction	Mahoor et al. [11]	Vulnerable to precise estimation.
	RUL (Time to Failure) Prediction	Kwon et al. [12]	
	Anomaly detection	Hovsepyan et al. [13-15]	
ML	Fault detection and process line maintenance notification	Isaacs et al. [16-20]	Vulnerable to realtime data processing.
	RUL prediction	Rahul et al. [21-27]	
	Optimal maintenance schedule	Shuai Guo [28]	
	Automated Error Detection	Chen et al. [29-31]	
	Hybrid decision support	Cho et al. [32,33]	
	Machine learning based on fuzzy logic	Leung, C. K.[34]	
Hybrid	Error prediction and dynamic change	Ullah et al. [35]	Present methodology to complement each other's weaknesses. However, the use of the null hypothesis is ignored.
	Data quality improvement and analysis/prediction	Al-Gharbi et al. [36]	
	State-of-charge estimation and error reduction	He et al. [37]	
	Linear data processing and nonlinear estimation	Agarwal et al. [38-40]	
	ARMA and sensor information prediction	Manoj, K. S. [41]	
	RUL prediction and fast data evaluation	Shuai Guo [28]	
	Improved stability and accuracy of received signals	Hsieh et al. [42]	

예측정비의 자동화를 위한 칼만필터와 기계학습에 대한 알고리즘 활용 사례에서 보는 바와 같이 칼만필터형은 실시간 데이터 취합에는 유리하지만 정밀한 추정에는 취약하여, 기계학습형의 장점인 정밀한 결과 값에 대한 보정이 필요하다. 따라서 이에 대한 개선방안으로 연구한 칼만필터와 기계학습 하이브리드형이 채택되어 더 나은 결과와 예상 데이터로 예측 모델을 구축하는데 많은 관심을 끌고 있다. 이때 직면하는 몇 가지 격차와 문제점이 있다.

- 공통 및 오픈 소스 프레임워크 플랫폼 데이터 분석을 위한 전체적인 접근 방식이 없다.
- 분류 및 클러스터링 알고리즘을 사용하여 정확도를 높이는 요구가 증가하고 있다.
- 가능한 한 최소한으로 노이즈 변화를 감소하기 위한 베이지안 학습 최적화 알고리즘을 지원하지 않고 있다.
- 통계 분석 프로그램인 R의 범용 라이브러리 dlm을 통한 시도는 아직 부재하다.

베이지안 추정에 대해 수행된 작업[9]은 귀무가설의 사용을 무시하고 베이지안 계층적 모델링을 위한 통계적 비교를 통해 베이지안 분석을 더욱 촉진하는 데 중점을 두고 있다. 베이지안 테스트에서 베이지안 상관 t 테스트, 베이지안 부호 순위 테스트 및 베이지안 계층 모델을 사용한다. 또한, 귀무가설에서 오류를 찾아 베이지안 분석을 통해 얻은 결과와 비교한다. 그리고 p-값이 귀무가설의 확률에 대한 합리적인 프로시가 아니라고 명시한다. 그러나 귀무가설을 사용한 통계 테스트는 기계학습에 더 많이 사용되고 있다.

귀무가설 유의성 검증[10]에서 이득을 얻는 베이지안 계층 모델에 대한 비교 연구를 제시했다. 또한, 두 가지 방법을 사용하여 두 가지 분류의 정확도를 교차 검증하고 비교했으며 귀무가설의 단점을 나열했다. 베이지안 가설 테스트를 사용하면 단점을 줄일 수 있다. 또한, 계층적 모델은 모든 데이터 세트에서 얻은 결과를 공동으로 분석하여 추정 오류를 상당한 비율로 줄인다.

3. 칼만 필터 기반의 베이지안 기계학습 예측 기법에 대한 설명

3.1 칼만 필터를 이용한 시계열 분석 기법

목적 확인 및 데이터 수집을 위해 본 연구에서는 통계 프로그램 R을 활용한 데이터 세트 press.csv를 사용한

다. 분석의 목적은 과거·현재·미래의 값을 정밀도가 높게 구하는 것으로 한다. 사용한 데이터(press.csv)는 제철공장에서 압연공정의 MES(생산관리시스템)로부터 취득한 압연공정 이상탐지 데이터이다.

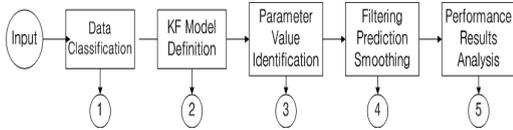


Fig. 1. A systematic schema of Kalman Filters

- ① 분석에서 우선 대상이 되는 데이터의 예비 조사가 필요하며 시간적인 패턴으로 주기성이 인정되는 범위에서 데이터 모델에 반영한다. ② 연속적인 분석을 위해 로컬 수준의 모델을 다음과 같이 정의한다.

$$x_t = x_{t-1} + \omega_t, \quad \omega_t \sim N(0, W) \quad (3.1)$$

$$y_t = x_t + v_t, \quad v_t \sim N(0, V) \quad (3.2)$$

로컬 레벨 모델의 상태 방정식 Eq. (3.1)은 직전의 값과 현재의 값이 대체로 같다는 것을 나타내며 특별한 시간 패턴을 포함하지 않는다. 그러므로 데이터에 대한 조사에서 얻은 지식이 반영된다고 생각할 수 있다. 이제 라이브러리 dlm을 사용하여 로컬 수준 모델을 정의한다. ③ 모델에 포함되는 매개 변수가 미지인 경우, 시계열의 추정에서 매개변수값을 특정할 필요가 있다. 본 연구의 매개 변수는 W, V이지만 특별한 단서없이 알 수 없으므로 이러한 매개 변수값을 식별해야 한다. 여기서 압출 데이터는 충분히 크기 때문에 매개변수를 확률 변수라고 생각하지 않는 경우에 근거해 최대 우도법을 적용한다. 최대 우도 추정에서의 표준 오차는 동일한 통계량을 갖는 다른 관측치를 가정할 때의 최대 우도 추정치의 평균적인 상태를 의미한다. 최대 우도 추정을 수행한 각 매개 변수의 표준 오차는 로그 우도 함수의 헤세 행렬(Hessian matrix)에서 구할 수 있다. 헤세 행렬은 함수의 2층 편미분을 요소로 하는 행렬이며, 이번 경우 대수 우도 함수 $\ell()$ 의 매개변수는 W, V이므로,

$$H = - \begin{bmatrix} \frac{\partial^2 \ell(W, V)}{\partial W \partial W} & \frac{\partial^2 \ell(W, V)}{\partial W \partial V} \\ \frac{\partial^2 \ell(W, V)}{\partial V \partial W} & \frac{\partial^2 \ell(W, V)}{\partial V \partial V} \end{bmatrix} \quad (3.3)$$

이 된다. 최대 우도 추정의 점근 특성[43]에 따라 음의 로그 우도 함수의 헤세 행렬에 대해 역행렬이 존재하면

대각항은 각 매개 변수에 대한 점근적 분산을 나타낸다. 이번 연구 사례에서는 매개변수가 지수 변환되고 있으므로, 이 값을 직접 이용할 수 없다. 이 때문에 본 논문에서는, 델타법을 이용해 지수 변환 후의 매개변수의 표준 오차를 구하기로 한다[44]. 델타법의 기본적인 사고방식은, 원하는 통계를 테일러 전개하고 1차 함수까지 중단하는 단순한 것이다. 구체적으로 단일 θ 로 착안하여 써보면

$$\begin{aligned} \text{Var}[\exp(\theta)] &\approx \text{Var}\left[\exp(\hat{\theta}) + \frac{\exp'(\hat{\theta})}{1!}(\theta - \hat{\theta})\right] \\ &= \exp^2(\hat{\theta}) \text{Var}[\theta - \hat{\theta}] = \exp^2(\hat{\theta}) \text{Var}[\theta] \end{aligned} \quad (3.4)$$

가 된다. 이번 연구 사례에서는 H^{-1} 의 대각항에 $\text{Var}[\theta]$ 가 들어 있으므로,

$$\begin{aligned} &\exp(\text{maximum likelihood estimate of a parameter}) \\ &\times \sqrt{\text{corresponding element of } \text{diag}(H^{-1})} \end{aligned} \quad (3.5)$$

이렇게 지수를 변환한 후 매개변수의 표준 오차가 구해진다. 결과적으로 최대 우도 추정의 표준 오차는 W에서 3979.086, V에서 0.000이라는 값을 얻는다. 마지막으로 매개변수의 최대 우도 추정 결과를 모델에 반영하면 W는 1, V는 27993.24라는 결과가 된다. 추정값과 표준오차를 비교하면 추정값에 비해 표준 오차가 큰 값이 된다(특히 W). 그러나 선형-가우시안 상태 공간 모델의 매개변수에 관한 최대 우도 추정에서는, 큰 표준 오차가 나오는 경향이 있다고 하는 지적도 있어[45], 무시하기로 하고 매개변수의 불확실성을 보다 적절하게 고려할 수 있도록 매개변수를 확률 변수라고 간주하여 베이스 추정을 실시하는 것이 적당하다. ④ 다음으로 필터링-예측-평활화를 수행한다. 얻어진 각 분포의 평균값과 그 신뢰 구간(95% 구간)을 그래프로 하여 결과를 확인해 간다.

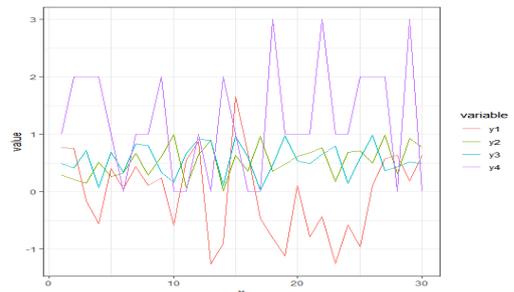


Fig. 2. The results of Kalman Filtering
ref.: y1(upper level), y2(sensor-1 data, n=10×3,400), y3(average), y4(lower level)

⑤ 마지막으로 결과를 확인하고 의미를 해석한다. 구체적인 진단 도구로서 우도와 예측 오차를 활용하기 때문에, 순서대로 설명한다. 우도는 모델의 선택 기준으로 써 모델이나 전체를 바꾸었을 때에는 우도를 비교해, 기본적으로는 우도가 가장 높아지는 조건을 찾게 된다. 선형·가우스형 상태 공간 모델에 있어서 시계열 전체의 우도 값을 계산한다. 함수 $d_{lmMLE}()$ 는 내부적으로 $d_{lmLL}()$ 를 활용하고 있다. 결과는 564.4952라는 값이 된다.

3.2 제안된 베이지안 기계학습 모델

데이터 처리의 역할은 다양한 기술을 통해 로컬 및 글로벌 리포트토리에서 데이터를 가져오는 만큼 매우 중요하다. 나중에 이 데이터는 다양한 기계 학습 알고리즘을 사용하여 훈련하고 모델링하여 전반적으로 더 좋고 정확한 예측에 도움이 된다. Bayesian Learning Probabilistic Model을 사용하는 기계 학습 알고리즘을 사용한 정확도 예측의 개념은 Fig. 3에 나와 있다.

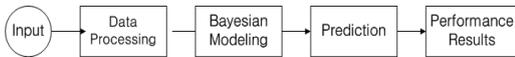


Fig. 3. An overview of machine learning-based accuracy prediction using Bayesian probabilistic models

베이지안 학습은 사전에 몇 가지 중요한 단계를 포함한다. 첫 번째 단계는 제공된 데이터의 기술적인 수학적 생성 모델을 설정하는 것이다. 매개변수의 각 값에 대해 관찰된 데이터의 확률을 제공하는 것은 확률(또는 우도) 함수이다[46]. 이 단계에서는 가장 정확하고 올바른 생성 모델을 찾아야 한다. 다음 단계는 데이터에 대한 각 매개변수 값의 신뢰성을 찾는 것이다. 목표는 관찰된 이전 데이터와 관련하여 가장 정확한 매개변수와 해당 값을 찾는 것이다. 세 번째 단계에서는 베이지안의 규칙을 사용하여 우도 함수와 사전 데이터를 결합하고 매개변수를 사용하여 사후 분포를 생성한다. 이 사후 분포는 예측된 데이터이다.

베이지안 확률은 베이지안 규칙의 평균과 확률 개념의 해석인 베이지안 추론으로도 이해할 수 있다. 베이지안 추론은 다음과 같이 추론할 수 있다.

$$P(n|m) = \frac{P(m|n)P(n)}{P(m)} \quad (3.6)$$

반면 n 과 m 은 n 이 m 을 기반으로 이해되는 두 가지

이벤트이다. 형식적 정의에서 하나의 사건은 가설로 취급하고 다른 사건은 특정 가설의 발생을 뒷받침하는 증거와 같다[47]. 두 이벤트 모두 서로 다른 발생 가능성을 처리하기 위한 것이다. 위의 Eq. (3.6)에서 사용된 베이저안 확률의 경우는 다음과 같이 이해할 수 있다.

- $P(n|m)$ 은 m 에 대한 n 의 사후 확률이다. 즉, 특정 이벤트가 발생한 것을 관찰한 후이다.
- $P(n)$ 은 특정 사건의 발생에 대해 가설을 세울 확률을 실제로 추정된 사전 확률이다.
- $P(m|n)$ 은 이벤트의 주어진/특정 발생을 기반으로 한 두 개의 서로 다른 이벤트를 관찰할 확률이다.
- $P(m)$ 은 특정 증거에 대한 관측 확률이다.

n 의 다른 값에 대해 $P(n|m)$ 에 영향을 미치는 매개변수는 $P(n)$ 및 $P(m|n)$ 이다. 사후 확률은 다음 가설을 정당화하는 사전 확률에 정비례하기 때문이다. 주어진 증거에 대해 고려되어야 한다(즉, 특정 사건에 대해). 따라서 Eq. (3.7)과 같이 추론할 수도 있다.

$$P(n|m) = \frac{P(m|n)P(n)}{P(m)}P(n) \quad (3.7)$$

데이터를 미리 결정된 k -숫자로 그룹화하기 위해 군집을 기반으로 접근하는 방식을 사용하여 분할하기 위해 비용 함수 ψ 를 최소화:

$$\psi = \sum_{i=1}^k \|d_i - C_j\|^q \quad (3.8)$$

여기서 C_j 는 j 번째 군집의 중심이며 찾아야 하는 데이터 객체는 d_j 이다. k 는 전체 군집을 생성하는 특정 데이터 세트의 요소 숫자이다. 특정 거리 함수 'q'의 기간에 언급된 일반적으로 고유한 정수이다. 군집의 중심은 데이터 세트의 각 속성에 대한 평균을 나타내며 평균은 실제로 특정 군집에 속하는 전체 객체 d_j 에 대해 계산된다. k -평균 군집분석을 위해 설계된 알고리즘은 데이터 세트에 대해 수행할 문제에 초점을 맞출 뿐만 아니라 [48]훈련된 기계학습 모델의 초기 가정으로써 칼만필터와 같이 지정된 데이터 세트에 대해 제공된 값 사이의 순서도 고려한다.

3.3 융·복합 칼만 필터 기반 베이지안 기계학습 분석

칼만 필터에는 예측 및 업데이트라는 두 가지 다른 단계가 있다. 예측 단계는 이전 기간의 데이터를 추정하고

현재에 대한 새 데이터의 근사치를 생성한다. 업데이트 단계의 경우 이전 데이터의 수정 사항을 기반으로 더 정확한 데이터가 계산된다. 즉, 현재 기간에 대한 예측 단계를 구체화한다.

$$\hat{Y}(K+1|k) = A(k)Y(k|k) + B(k)U(k) \quad (3.9)$$

베이저안 기반의 기계학습에서 $Y(n|m)$ 은 이전 Eq. (3.7) 및 Eq. (3.8)에서 언급한 바와 같이 m 주기의 데이터 시퀀스가 주어지면 주기 n 에서 X 의 추정치를 나타낸다. 선형 2차 추정, 칼만 필터의 다른 이름은 데이터의 노이즈를 필터링하는 데 사용할 수 있다. 이것은 우리가 사용한 데이터 세트의 플롯을 통해 추가로 설명된다. 초기 데이터 세트 또는 베이저안 분석 기능을 제공하는 데 사용되는 데이터 세트는 원래 예측의 정확도에서 큰 비중을 차지하는 예측의 백본을 형성한다. 이 초기 데이터를 먼저 정렬한 다음 베이저안 함수에 입력하면 더 나은 결과를 얻을 수 있다. 더 나은 접근 방식은 정렬된 데이터 자체에서 노이즈와 급격한 변동을 필터링하는 것이다.

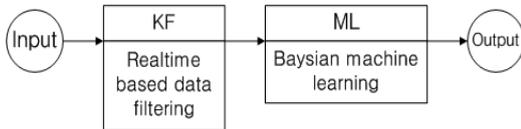


Fig. 4. An overview of Bayesian Analysis Based on Kalman Filters

<p>알고리즘 1: 칼만 필터링</p> <p>0. 시점 $t-1$에서 필터링 분포: m_{t-1}, C_{t-1}</p> <p>시점 t에서 갱신 절차</p> <ul style="list-style-type: none"> 1기 앞선 예측분포 <p>(평균) $a_t \leftarrow G_t m_{t-1}$</p> <p>(분산) $R_t \leftarrow G_t C_{t-1} G_t^T + W_t$</p> <ul style="list-style-type: none"> 1기 앞선 우도 <p>(평균) $f_t \leftarrow F_t a_t$</p> <p>(분산) $Q_t \leftarrow F_t R_t F_t^T + V_t$</p> <ul style="list-style-type: none"> 칼만 이득 <p>$K_t \leftarrow R_t F_t^T Q_t^{-1}$</p> <ul style="list-style-type: none"> 상태의 갱신 <p>(평균) $m_t \leftarrow a_t + K_t [y_t - f_t]$</p> <p>(분산) $C_t \leftarrow [I - K_t F_t] R_t$</p> <p>2. 시점 t에서 필터링 분포: m_t, C_t</p>

<p>알고리즘 2: 베이저안 기계학습[49]</p> <p>베이저안 기계학습은 조건부 및 전체 확률과 연쇄 규칙에 의존[50,51]한다.</p> <p>베이즈 정리는 Fig. 5와 같이 사후 확률 분포를 계산하기 위하여 목표하는 매개변수에 대한 입력 데이터로서 현재의 데이터와 사전 데이터를 이용한다.</p> <ul style="list-style-type: none"> • 사전 분포는 가설의 가능성을 나타낸다. • 우도 함수는 매개변수 θ, 즉 사전 데이터로부터 현재 취득한 데이터의 추정을 계산한다. • 증거는 가능한 모든 가설이 주어졌을 때 관찰된 데이터의 가능성을 측정한다. <div style="text-align: center;"> </div> <p>사후는 사전과 우도의 곱을 증거로 나눈 것이다. 따라서 이전 가정과 데이터를 모두 고려하여 업데이트된 가설의 확률 분포를 반영한다. 다르게 보면 사후 확률은 체인 규칙을 적용한 결과로, 데이터와 매개변수의 공동 분포를 분해한다.</p> <p>더 높은 차원의 연속 변수를 사용하면 공식이 더 복잡해지고 (다중) 적분을 포함한다. 또한 대체 공식은 확률을 사용하여 사후 확률을 이전 확률의 곱으로 우도 비율을 곱한 값으로 표현한다[52].</p>

Fig. 5. A method to Update the evidence from the Prior to the Posterior Probability Distribution

3.4 예방적 유지보수 스케줄링 모델

사용 중인 제철공장에서의 압연공정의 재공품의 표면결출 및 분류 데이터는 외부에 장착된 센서(열연공정 및 냉연공정의 SDD(Surface Defect Detector)에서 취득하여 MES(생산관리시스템)으로 보내지는데 원시 아날로그 신호에서 의미 있는 정보를 추출하려면 먼저 원하지 않는 주파수 스펙트럼을 칼만필터링하여 처리한다. 다음 단계는 처리된 신호에서 특징을 추출하여 조건 관련 정보를 생성하고 데이터를 압축하는 것이다. 재공품의 특성에 따라 시간 영역 또는 주파수 영역에서 특징을 추출할 수 있다. 그런 다음 추출된 특징을 베이저안 기계학습 알고리즘 훈련에 사용할 수 있다. 베이저안 기계학습은 사전 데이터로부터 현재 취득한 데이터의 추정을 계산한다.

예를 들어 재공품 모니터링의 기능이 재공품의 정상 또는 결함 상태에 연결된 경우 베이저안 기계학습 알고리즘을 사용할 수 있다. 여기에는 사후 예측값을 도출하기 위해 사전과 우도의 곱을 증거로 나눈 값이며 가정과

데이터를 고려하여 업데이트된 가설의 확률 분포를 반영한다.

베이저안 기계학습 모델이 학습된 후 모델에서 결과를 추정할 수 있다. 예를 들어 재공품 상태 모델(예측 모델)이 처리된 PDD 신호 및 재공품의 상태(레이블)에서 훈련되면 해당 상태에 따라 예측정비 스케줄에 반영하여 진행된다. Fig. 6는 칼만필터와 기계학습 알고리즘을 사용하는 예방정비의 절차에 따른 모델을 보여준다.

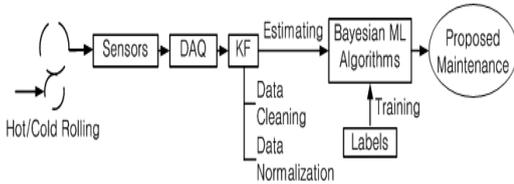


Fig. 6. Architecture of proposed predictive maintenance scheduling model

4. 결과 및 분석

이 섹션에서는 위에서 전제한 칼만필터를 이용하여 선별된 데이터를 취득하고 베이저안 기계학습으로 예방적 유지보수의 대한 상황판단을 하는 시뮬레이션 설정 및 결과가 제공된다.

4.1 시뮬레이션 설정

사용한 데이터(press.csv)는 제철공장에서 압연공정의 MES(생산관리시스템)로부터 취득한 압연공정 이상탐지 데이터이다. 참고로 압연공정은 200~400mm 두께의 슬라브 소재를 두 개의 롤러 사이를 통과시키며 고객이 요구한 두께로 가공하는 공정이며, 1차적으로 열간 상태에서 압연하는 열연 공정과 2차적으로 상온에서 압연을 실시하는 냉연 공정으로 구성되어 있다. 앞 공정에서의 품질 결함을 검출하지 못하고 후공정으로 보내지는 소재는 후공정에서 품질 악화, 설비 사고로 이어질 수 있다. 압연 공정 중 표면을 검사하는 장치는 빠른 속도로 진행 중인 표면에서의 결함을 빠르고 정확하게 검출하는 것이 중요하다. 현재도 SDD(Surface Defect Dectector)로 표면 결함 검출 및 분류를 하고 있으나 지속적인 성능 개선을 필요로 하고 있다.

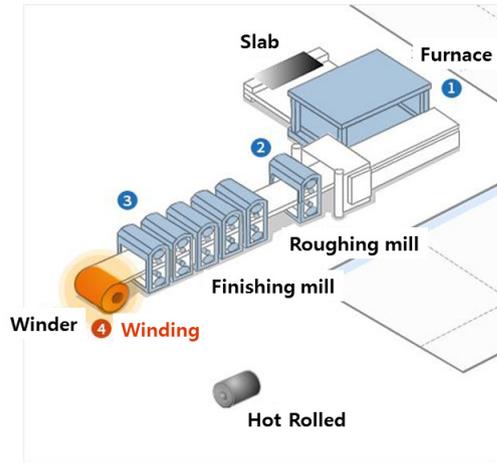


Fig. 7. 1st hot rolling

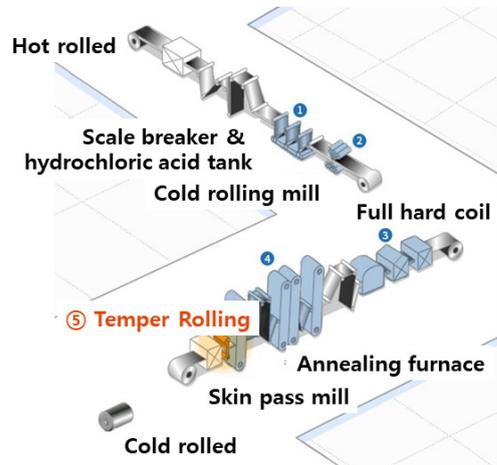


Fig. 8. 2nd cold rolling

제한한 칼만 파일러 기반 예측 모델의 효율성을 검증하기 위해 시뮬레이션을 수행하였다. 데이터분석 프로그래밍 언어 R은 오픈 소스 플랫폼이며 RStudio는 R프로그래밍 작성 및 실행을 위한 통합 개발환경 프로그램(IDE)이다. R에서 작업공간(WorkSpace)은 모든 입-출력작업이 이루어지는 기본 위치이다. 데이터나 스크립트파일의 열기나 저장하기, 생성한 변수나 함수 저장하기 등과 여러 다양한 입력 및 출력작업이 현재 설정된 작업 디렉토리에서 이루어진다. 즉, Environments에 있는 R객체, 소스 파일들, 명령기록(history), 작업폴더를 의미한다. 이 작업공간을 하나의 프로젝트 단위로 관리하면 소스 및 리소스들을 효율적으로 관리하기가 용이해진다.

효율성은 16GB RAM 및 Windows 10 Pro가 탑재된 Intel Core i5에서 실행되는 작업공간에서 이루어지고 데이터 세트는 (D:/R_Project)에 생성된다. 그리고 라이브러리는 범용성이 있는 dlm을 이용한다.

4.2 결과 및 논의

선형 및 가우시안 상태 공간 모델에서 추정할 데이터의 참값과 점 추정값 사이의 평균 제곱 오차를 최소화하는 최적의 순차 추정 방법은 이를 처음으로 명확하게 취급한 칼만필터에서 비롯된다. 이 접근 방식은 우리가 제거하거나 개선할 수 있는 모든 데이터 세트에 존재하는 노이즈의 양을 더욱 드러낼 것이다. 작은 데이터 세트를 사용했지만 칼만필터가 베이지안 분석을 위한 사전 입력으로 사용할 수 있는 K 평균과 함께 데이터를 안정화하는 데 좋은 결과를 제공한다는 것을 보여준다. 칼만필터는 노이즈를 줄이기 위해 데이터에 직접 적용된 다음 K-평균 함수에 공급되어 예측 메커니즘을 상당히 개선한다. 이 논문은 칼만 필터링을 사용하여 계산 횟수를 줄일 수 있다.

tsdiag()의 결과는 Fig. 9에 나와 있는 3개의 플롯으로, 위에서부터 순서대로 표준화 혁신, 자기상관 계수, 융박스(LjungBox) 검정의 p값이 된다. 규격화 혁신의 경우 극단적인 편향과 특히 큰 값이 남아 있지 않은지 확인한다. 이번 결과에서는 도표와 같이 극단적인 편향현상에 대한 특징은 남아 있지 않고, 계속되는 자기상관 계수에서도 큰 자기상관은 무관한 상태이다. 융 박스 검정의 p-값은 유의 수준의 기준으로 0.05를 점선으로 표시한다. 이 검정의 귀무 가설은 「계열 데이터는 독립이다」이므로, 이번 결과로부터는 이 귀무 가설은 기각되는 것을 알 수 있다.

Q-Q 플롯은 가로축이 정규 분포의 이론적인 분위점, 세로축이 데이터의 분위점을 나타내므로, 플롯의 결과가 대각선 방향 가이드라인에 가까울수록 데이터가 정규 분포를 따른다고 생각할 수 있다. 이론과 샘플 데이터가 서로 일치한 Fig. 10에서 플롯의 결과가 특히 $\pm 1\sigma$ 의 범위에서 가이드라인과 비례하기 때문에 표준화 혁신은 대개 정규 분포를 따르는 것으로 파악할 수 있다. Eq. (3-9)에서 언급한 칼만 필터 모델을 사용하여 더 나은 계열 데이터를 인식하는 훨씬 빠른 시나리오를 정당화한다.

또한, 철강회사의 MES(생산공정시스템)에서 추출한 압연공정 이상 탐지 데이터(press.csv)를 이용하여 베이지안 기계학습으로 다음의 결과를 도출하였다.

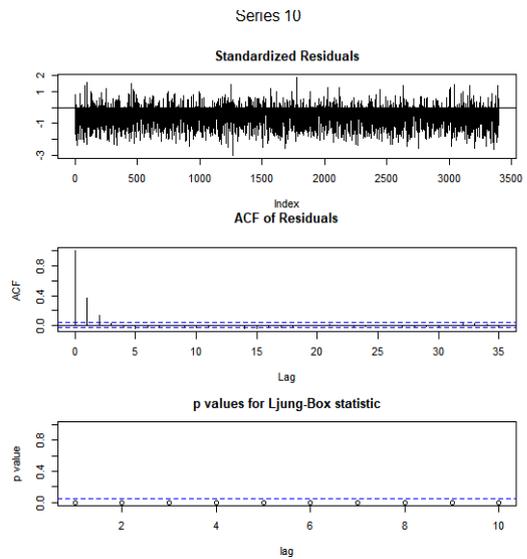


Fig. 9. Result of autocorrelation function tsdiag()

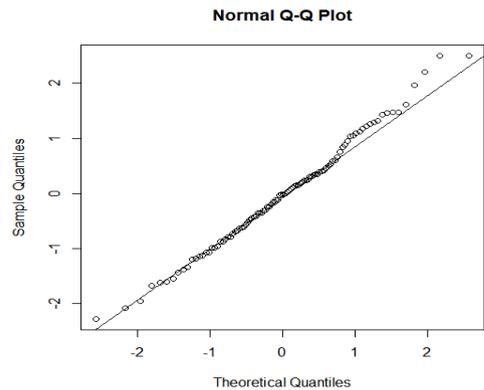


Fig. 10. Q-Q Plot

Reference	
Prediction	0 1
0	154 57
1	17 792
Accuracy : 0.9275	
95% CI : (0.9098, 0.9426)	
No Information Rate : 0.8324	
P-value [Acc > NIR] : < 2.2e-16	
Kappa : 0.7623	
McNemar's Test P-value : 5.797e-06	
Sensitivity : 0.9006	
Specificity : 0.9329	
Pos Pred Value : 0.7299	
Neg Pred Value : 0.9790	
Prevalence : 0.1676	
Detection Rate : 0.1510	
Detection Prevalence : 0.2069	
Balanced Accuracy : 0.9167	
'Positive' Class : 0	

Fig. 11. A result of Bayesian machine learning

5. 결론

오늘날 세계는 오픈 소스 소프트웨어의 증가 추세로써 개방된 공장이나 사무실에서 단순한 워드 프로세서 기능이나 강력한 응용 프로그램과 같은 개방된 환경의 소프트웨어를 폭넓게 사용하고 있다. 실시간 필요 데이터의 취득과 의사결정의 정확성을 위해 융·복합 칼만필터의 조합과 베이지안 분류를 이용한 오픈 소스 소프트웨어 데이터 예측과 같은 성능 향상 방법을 제시한다. 선형·가우시안 상태 공간 모델의 매개변수에 관한 최대 우도 추정에서 베이스 추정을 실시한다. 베이스 추정을 이용하면 우리가 알고 있는 불량이라는 증상이 있을 때 알아내야 할 불량의 원인 즉 '불량명'을 쉽게 찾아낼 수 있다. 즉, 불량에 대한 증상을 보이는 불량의 종류가 너무 많은 상황에서 관리자가 취할 수 있는 합리적인 전략은 해당 불량이 발생할 확률이 가장 높은 쪽으로 최종 결정을 내리는 방식이다. 적용한 방식은 다음과 같다.

첫째, 이 방법은 제한한 알고리즘이 데이터에서 군집을 계산하는 시간을 줄일 수 있다는 사실을 확인하기 위해 작은 데이터 세트에 적용된다. 이러한 예측 알고리즘은 디지털 혁명에서 데이터를 예측하는 데 매우 바람직하며 학습 알고리즘의 새로운 패러다임을 설계하는 데 도움이 된다. 오픈 소스 소프트웨어의 도움으로 실시간 데이터 취득과 동시에 군집의 매개변수 선별로 주목할 만한 시간에 효율적으로 군집의 헤드 선택 알고리즘을 구현한다.

둘째, 그리고 베이지안 기계학습은 표준 정규분포에 따르는 모델이 적절하여 보이고 전체 정확도가 92.75%로 구해진 것은 꽤 좋은 결과다. 이는 양품을 구분하는 것과 관련해서 데이터 세트가 유의미한 정보를 담고 있음을 의미한다. 또한 불량을 잘 예측하기도 한다. 특이도가 93%, 민감도가 90%, NPV가 97%, PPV가 72%로 측정된 결과가 근거가 된다.

칼만필터를 사용하여 노이즈 조건에 따라 훈련 모델을 변경할 수 있는 신경망을 사용하면 훨씬 고급 작업을 수행할 수 있을 것이다. 노이즈의 양은 필터링 알고리즘을 변경하여 선택하면 매개변수의 정확도와 수정을 달성할 수 있다. 이와 같이 입력 데이터 세트의 노이즈를 줄이기 위한 효율적이고 올바른 알고리즘을 선택하는 방법과 같은 주제에 대해 상당한 개선을 수행할 수 있을 것이다.

이와 같이 제안된 알고리즘과 수학적 모델을 제조 공장에서 활용할 경우 92.75%의 정확도 보여 기업경쟁력의 향상이 기대된다.

References

- [1] Neto, Anis Assad, et al. "Fault prediction as a service in the smart factory: addressing common challenges for an effective implementation." IFAC-PapersOnLine vol. 53, no. 2, pp. 10743-10748, 2020.
DOI: <https://doi.org/10.1016/j.ifacol.2020.12.2855>
- [2] Ahmed, Hosameldin; Nandi, Asoke K. Condition monitoring with vibration signals: Compressive sampling and learning algorithms for rotating machines. John Wiley & Sons, 2020.
- [3] Amruthnath, Nagdev; Gupta, Tarun. A research study on unsupervised machine learning algorithms for early fault detection in predictive maintenance. In: 2018 5th international conference on industrial engineering and applications (ICIEA). IEEE, pp. 355-361, 2018.
DOI: <https://doi.org/10.1109/IEA.2018.8387124>
- [4] Snoek, Jasper; Larochelle, Hugo; Adams, Ryan P. Practical bayesian optimization of machine learning algorithms. Advances in neural information processing systems, 25, 2012.
DOI: <https://doi.org/10.48550/arXiv.1705.04405>
- [5] X.Mai, J.Cheng and S.Wang, "Research on semi supervised K-means clustering algorithm in data mining," Cluster Computing, vol. 22, pp. 3513-3520, 2019.
DOI: <https://doi.org/10.1007/s10586-018-2199-7>
- [6] Bhargava, Arpita; Verma, Shekhar; Chaurasia, Brijesh Kumar. Kalman filter for trust estimation in VANETs. In: 2015 IEEE UP Section Conference on Electrical Computer and Electronics (UPCON). IEEE, pp. 1-6, 2015.
DOI: <https://doi.org/10.1109/UPCON.2015.7456757>
- [7] Urrea, Claudio, and Rayko Agramonte. "Kalman filter: historical overview and review of its use in robotics 60 years after its creation." Journal of Sensors 2021, pp. 1-21, 2021.
- [8] SI, Xiao-Sheng, et al. Remaining useful life estimation -a review on the statistical data driven approaches. European journal of operational research, 213.1: 1-14, 2011.
DOI: <https://doi.org/10.1016/j.ejor.2010.11.018>
- [9] Heaton, James B.; Polson, Nick G.; Witte, Jan Hendrik. Deep learning for finance: deep portfolios. Applied Stochastic Models in Business and Industry, 33.1: 3-12, 2017.
DOI: <https://doi.org/10.1002/asmb.2209>
- [10] Kangasrääsiö, Antti, et al. Inferring cognitive models from data using approximate Bayesian computation. In: Proceedings of the 2017 CHI conference on human factors in computing systems. pp. 1295-1306, 2017.
DOI: <https://doi.org/10.1145/3025453.3025576>
- [11] Kangasrääsiö, Antti, et al. Inferring cognitive models

- from data using approximate Bayesian computation. In: Proceedings of the 2017 CHI conference on human factors in computing systems, pp. 1295-1306, 2017.
DOI: <https://doi.org/10.1145/3025453.3025576>
- [12] Kwon, Jae Eon, et al. RUL Prediction of Switched Mode Power Supply Using a Kalman Filter Assisted Deep Neural Network. Processes, 10.1: 55, 2021.
DOI: <https://doi.org/10.3390/pr10010055>
- [13] S. Hovsepian, J. Papadoudis and P. Mercorelli, "Kalman Filter for Predictive Maintenance and Anomaly Detection," 2021 22nd International Carpathian Control Conference (ICCC), Velké Karlovice, Czech Republic, pp. 1-6, 2021.
DOI: <https://doi.org/10.1109/ICCC51557.2021.9454654>
- [14] B. Kroll, D. Schaffranek, S. Schriegel and O. Niggemann, "System modeling based on machine learning for anomaly detection and predictive maintenance in industrial plants," Proceedings of the 2014 IEEE Emerging Technology and Factory Automation (ETFA), Barcelona, Spain, pp. 1-7, 2014.
DOI: <https://doi.org/10.1109/ETFA.2014.7005202>
- [15] YANG, S. K. An experiment of state estimation for predictive maintenance using Kalman filter on a DC motor. Reliability engineering & system safety, 75.1: 103-111, 2002.
DOI: [https://doi.org/10.1016/S0951-8320\(01\)00107-7](https://doi.org/10.1016/S0951-8320(01)00107-7)
- [16] Isaacs, Dan, et al. Making factories smarter through machine learning. IIC Journal of Innovation, 3: 29-40, 2017.
DOI: <https://doi.org/10.1016/j.promfg.2020.10.169>
- [17] Amruthnath, Nagdev. Embedded fault class detection methodology for condition-based machine monitoring and predictive maintenance. Western Michigan University, 2019.
- [18] Mantravadi, Soujanya; Chen, L. I.; Moller, Charles. Multi-agent Manufacturing Execution System (MES): Concept, architecture & ML algorithm for a smart factory case. In: 21st International Conference on Enterprise Information Systems, ICEIS 2019. SCITEPRESS Digital Library, pp. 477-482, 2019.
DOI: <https://doi.org/10.5220/0007768904770482>
- [19] Neto, Anis Assad, et al. Fault prediction as a service in the smart factory: addressing common challenges for an effective implementation. IFAC-PapersOnLine, vol. 53, no. 2, pp. 10743-10748, 2020.
DOI: <https://doi.org/10.1016/j.ifacol.2020.12.2855>
- [20] Khan, K., Sohaib, M., Rashid, A., Ali, S., Akbar, H., Basit, A., & Ahmad, T. (2021). Recent trends and challenges in predictive maintenance of aircraft's engine and hydraulic system. Journal of the Brazilian Society of Mechanical Sciences and Engineering, vo. 43, no. 8, pp. 1-17.
DOI: <https://doi.org/10.1007/s40430-021-03121-2>
- [21] Rahul Rade. Predictive Maintenance for Digital Factory Automation, Siemens MakeIT Real Hackathon, c2021, Available From:
<https://imrahulr.github.io/Istm/kalman%20filter/siemens%20makeit%20real%20hackathon/2018/01/04/predictive-maintenance.html> (accessed Mar. 20, 2021)
- [22] Kroll, Björn, et al. System modeling based on machine learning for anomaly detection and predictive maintenance in industrial plants. In: Proceedings of the 2014 IEEE emerging technology and factory automation (ETFA). IEEE, pp. 1-7, 2014.
DOI: <https://doi.org/10.1109/ETFA.2014.7005202>
- [23] CHIU, Yu-Chen; CHENG, Fan-Tien; HUANG, Hsien-Cheng. Developing a factory-wide intelligent predictive maintenance system based on Industry 4.0. Journal of the Chinese Institute of Engineers, vo. 40, no. 7, pp. 562-571, 2017.
DOI: <https://doi.org/10.1080/02533839.2017.1362357>
- [24] Serradilla, Oscar, et al. Deep learning models for predictive maintenance: a survey, comparison, challenges and prospects. Applied Intelligence, vol. 52, no. 10, pp. 10934-10964, 2022.
DOI: <https://doi.org/10.1007/s10489-021-03004-y>
- [25] ABIDI, Mustufa Haider; MOHAMMED, Muneer Khan; ALKHALEFAH, Hisham. Predictive maintenance planning for industry 4.0 using machine learning for sustainable manufacturing. Sustainability, vo. 14, no. 6, pp. 3387, 2022.
DOI: <https://doi.org/10.3390/su14063387>
- [26] AYVAZ, Serkan; ALPAY, Koray. Predictive maintenance system for production lines in manufacturing: A machine learning approach using IoT data in real-time. Expert Systems with Applications, vo. 173, pp. 114598, 2021.
DOI: <https://doi.org/10.1016/j.eswa.2021.114598>
- [27] Faltinski, Sebastian, et al. Detecting anomalous energy consumptions in distributed manufacturing systems. In: IEEE 10th International Conference on Industrial Informatics. IEEE, pp. 358-363, 2012.
DOI: <https://doi.org/10.1109/INDIN.2012.6301142>
- [28] Shuai Guo. "Predictive maintenance." Data-Driven Predictive Maintenance In a Nutshell, Feb 15, 2021, Available From:
<https://towardsdatascience.com/data-driven-predictive-maintenance-in-a-nutshell-ccc65a13b998> (accessed Mar. 20, 2023)
- [29] Chen, Baotong, et al. Smart factory of industry 4.0: Key technologies, application case, and challenges. Ieee Access, 6: 6505-6519, 2017.
DOI: <https://doi.org/10.1109/ACCESS.2017.2783682>
- [30] WANG, Ke-Sheng, et al. Interpretation and compensation of backlash error data in machine centers for intelligent predictive maintenance using ANNs. Advances in Manufacturing, vo. 3, pp. 97-104, 2015.
DOI: <https://doi.org/10.1007/s40436-015-0107-4>
- [31] Çinar, Zeki Murat, et al. Machine learning in predictive maintenance towards sustainable smart

- manufacturing in industry 4.0. Sustainability, vol. 12, no. 19, pp. 8211, 2020.
DOI: <https://doi.org/10.3390/su12198211>
- [32] Cho, Sangje, et al. A hybrid machine learning approach for predictive maintenance in smart factories of the future. In: Advances in Production Management Systems. Smart Manufacturing for Industry 4.0: IFIP WG 5.7 International Conference, APMS 2018, Seoul, Korea, August 26-30, 2018, Proceedings, Part II. Springer International Publishing, pp. 311-317, 2018.
DOI: https://doi.org/10.1007/978-3-319-99707-0_39
- [33] Jeeredy, Sandeep, et al. Machine learning use cases for smart manufacturing kpis. In: 2019 IEEE International Conference on Big Data (Big Data). IEEE, pp. 4375-4380, 2019.
DOI: <https://doi.org/10.1109/BigData47090.2019.9006539>
- [34] LEUNG, Carson K., et al. An innovative fuzzy logic-based machine learning algorithm for supporting predictive analytics on big transportation data. In: 2020 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE). IEEE, pp. 1-8, 2020.
DOI: <https://doi.org/10.1109/FUZZ48607.2020.9177823>
- [35] Ullah, Israr; Fayaz, Muhammad; Kim, DoHyeun. Improving accuracy of the Kalman filter algorithm in dynamic conditions using ANN-based learning module. Symmetry, vo. 11, no.1, pp. 94, 2019.
DOI: <https://doi.org/10.3390/sym11010094>
- [36] Al-Gharbi, Salem, et al. Statistical methods to improve the quality of real-time drilling data. Journal of Energy Resources Technology, vol. 44, no. 9, pp. 093006, 2022.
DOI: <https://doi.org/10.1115/1.4053519>
- [37] HE, Wei, et al. State of charge estimation for Li-ion batteries using neural network modeling and unscented Kalman filter-based error cancellation. International Journal of Electrical Power & Energy Systems, vo. 62, pp. 783-791, 2014.
DOI: <https://doi.org/10.1016/i.ijepes.2014.04.059>
- [38] Agarwal, Varun Niraj, et al. Neural Network Aided Kalman Filter to Maximize Accuracy. In: 2022 International Conference for Advancement in Technology (ICONAT). IEEE, pp. 1-4, 2022.
DOI: <https://doi.org/10.1109/ICONAT53423.2022.9726059>
- [39] Morris, Kyle J., et al. Token-based adaptive time-series prediction by ensembling linear and non-linear estimators: a machine learning approach for predictive analytics on big stock data. In: 2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA). IEEE, pp. 1486-1491, 2018.
DOI: <https://doi.org/10.1109/ICMLA.2018.00242>
- [40] PEEL, Leto. Data driven prognostics using a Kalman filter ensemble of neural network models. In: 2008 international conference on prognostics and health management. IEEE, pp. 1-6, 2008.
DOI: <https://doi.org/10.1109/PHM.2008.4711423>
- [41] Manoj, K. S. Based on IoT and Fog Computing, A Machine Learning-Based Predictive Maintenance Approach for Optimal Asset Management in Industry 4.0. JOURNAL OF ALGEBRAIC STATISTICS, 1vo. 3, no. 3, pp. 3522-3528, 2022.
DOI: <https://publishoa.com/index.php/journal/article/view/1129>
- [42] Hsieh, Jia-You, et al. Study on the application of indoor positioning based on low power Bluetooth device combined with Kalman filter and machine learning. EasyChair Preprint, pp.1-9, 2019.
DOI: <https://easychair.org/publications/preprint/VhvV>
- [43] Hu, Bisong, et al. Space-time disease mapping by combining Bayesian maximum entropy and Kalman filter: the BME-Kalman approach. International Journal of Geographical Information Science, vol. 35, no. 3, pp. 466-489, 2021.
DOI: <https://doi.org/10.1080/13658816.2020.1795177>
- [44] Bansal, Arpit; Sharma, Mayur; Goel, Shalini. Improved k-mean clustering algorithm for prediction analysis using classification technique in data mining. International Journal of Computer Applications, vol. 157, no. 6, pp.0975-8887, 2017.
DOI: <https://doi.org/10.5120/IJCA2017912719?sid=semanticscholar>
- [45] Bantan, Rashad, et al. Bayesian analysis in partially accelerated life tests for weighted lomax distribution. Comput. Mater. Contin, vol. 68, pp.2859-2875, 2021.
DOI: <https://doi.org/10.32604/cmc.2021.015422>
- [46] LV, Yisheng, et al. Traffic flow prediction with big data: A deep learning approach. IEEE Transactions on Intelligent Transportation Systems, vo. 16, no. 2, pp.865-873, 2014.
DOI: <https://doi.org/10.1109/TITS.2014.2345663>
- [47] Kieling, Eduardo J., et al. Smartalloc: A model based on machine learning for human resource allocation in projects. In: Proceedings of the 25th Brazilian Symposium on Multimedia and the Web. pp. 365-368, 2019.
DOI: <https://doi.org/10.1145/3323503.3360643>
- [48] Balasundaram, A., Dilip, G., Manickam, M., Sivaraman, A. K., Gurunathan, K., Dhanalakshmi, R., & Ashokkumar, S. Abnormality identification in video surveillance system using DCT. Intelligent Automation & Soft Computing, vol. 32, no. 2, pp. 693-704, 2022.
DOI: <https://doi.org/10.32604/iasc.2022.022241>
- [49] ODSC Community. How Bayesian Machine Learning Works, c2020 [cited 2020 Sept. 22], Available from: <https://opendatascience.com/how-bayesian-machine-learning-works/> (accessed Mar. 20, 2023)
- [50] Bishop, Christopher M.; Nasrabadi, Nasser M. Pattern recognition and machine learning. 738p, New York: springer, pp. 738, 2006.
DOI: <https://doi.org/10.1117/1.2819119>
- [51] GELMAN, Andrew, et al. Bayesian data analysis, CRC press, pp. 675, 2013.

DOI: <https://doi.org/10.1201/b16018>

- [52] Andrews, Mark; Baguley, Thom. Bayesian data analysis. The Cambridge encyclopedia of child development, pp.165-169, 2017.
DOI: <https://doi.org/10.1201/b16018>
- [53] Heaton, James B.; Polson, Nick G.; Witte, Jan Hendrik. Deep learning for finance: deep portfolios. Applied Stochastic Models in Business and Industry, vol. 33, no. 1, pp. 3-12, 2017.
DOI: <https://doi.org/10.1002/asmb.2209>
- [54] Kangasrääsiö, Antti, et al. Inferring cognitive models from data using approximate Bayesian computation. In: Proceedings of the 2017 CHI conference on human factors in computing systems. pp. 1295-1306, 2017.
DOI: <https://doi.org/10.48550/arXiv.1612.00653>

조 현 성(Hyun-Sung Cho)

[정회원]



- 1993년 10월 : 호주 뉴사우스웨일즈대학교 기계·생산공학대학원 생산공학과 (공학석사)
- 2016년 2월 : 서울과학기술대학교 NID융합기술대학원 나노·IT융합 프로그램학과 (공학박사)

- 2016년 4월 ~ 2021년 3월 : 유한대학교 유니테크특별전 형반(스마트팩토리) 교수
- 2021년 4월 ~ 현재 : 부천대학교 전자공학과 교수

<관심분야>

자동화, 기계학습