

Two-Stage 머신러닝 기반 제조업 불량 핵심인자 추출 정합성 향상 기법

이호진¹, 정의홍¹, 조창권¹, 조수정², 안성수^{1*}
¹POSCO 품질기술부, ²POSCO DX 전략실

hoho-z@posco.com, je1436@posco.com, birang99@posco.com, soojung@posco.com,
virtuor@posco.com

Two-Stage Stratified Machine-Learning Approach for Identifying Root-Cause Factors In Manufacturing Processes

Hojin Lee¹, Uihong Jeong¹, Changkwon Cho¹, Soojung Cho², Seongsoo Ahn^{1*}
¹Department of Quality System, ²DX Strategy Office, POSCO, Republic of Korea

요약

본 논문은 단일 단계 접근 시 층별 요인의 특성이 변수 중요도를 왜곡하는 층별 편향 문제를 다룬다. 이를 해결하기 위해, 층별화 요인(S)으로 대표 층을 선정하고 해당 층에서 조업 변수(O)만으로 학습하는 Stratified Two-Stage ML 을 제안한다. 11 개 불량 사례 실험에서 제안법은 Hit@5=1.00 을 기록하여 기존 방법(RF=0.30, Drop Column ΔF1=0.10) 대비 우수하였다. 본 연구는 층별 편향 제거와 해석 가능성 강화에 기여한다.

I. 서론

Industry 4.0 이후 제조 현장에는 대규모 센서 데이터가 축적되었고, 머신러닝은 품질 검사와 공정 모니터링에 폭넓게 도입되고 있다[1]. 그러나 전체 시스템의 AI 전환은 비용과 공정 연계성 문제로 한계가 있어, 국소적 원인 규명(root cause)으로 사용하여 기존 시스템과 도메인 지식을 활용한 개선이 주로 이루어지고 있다.

기존 연구에서는 변수 중요도(feature importance) 기법이 원인 규명에 적용되었으며[2], Rotter et al.[3]은 전통적 중요도와 딥러닝 기반 방법을 실제 데이터에서 비교하였다. 다만 해당 연구는 상대적으로 단순한 공정, 제품군을 대상으로 했기 때문에 층별화 요인에 따른 편향 문제가 크게 드러나지 않았다. 반면 실제 제조 현장은 제품과 공정이 다양하여, 단일 단계 접근 시 층별 편향이 불가피하게 발생한다.

따라서 복잡한 제조 데이터에서 층별 편향을 제거하고 핵심 조업 인자를 안정적으로 규명할 수 있는 새로운 접근이 필요하다.

II. 본론

II-1. 데이터 및 설정

본 연구는 2022-2025 년 제조 현장의 불량 사례 중 당사 엔지니어가 핵심 영향인자를 확인한 11 건을 정답셋으로 사용하였다. 모든 사례는 동일 입력 데이터셋으로 학습되었으며, 전처리 과정은 (1) 수치형 결측치는 0 으로 대체, (2) 범주형 결측치는 “Missing”으로 처리 후 원-핫 인코딩, (3) 식별자 열 제거로 통일하였다. 데이터 전반에

클래스 불균형이 존재하나, 본 연구는 방법 간 상대 성능 비교를 목적으로 하므로 별도의 보정은 수행하지 않았다.

II-2. 제안 방법 : Stratified Two-Stage ML

제조 데이터는 층별화 요인(S)에 따라 조업 변수(O)의 효과가 달라진다. 그러나 단일 단계 학습은 이를 고려하지 않으므로 조업 변수의 효과가 희석되거나 층별 요인 자체가 원인처럼 높은 중요도로 산출되는 층별 편향이 발생한다.

변수 중요도의 이상적 정의는 아래와 같이, 각 층 조건부 효과의 가중 평균이다.

$$I^*(o) = \sum_{s \in S} P(S=s) I(o|S=s), o \in O$$

하지만 단일 단계 학습은 조업 변수와 층의 특성 효과의 상관으로 편향 항 $B(o)$ 이 발생하여 핵심인자가 희석되거나 층별 특성 요인이 원인처럼 과대 평가된다.

$$I^{\text{단일단계}}(o) = I^*(o) + B(o)$$

본 연구에서는 이를 해소하기 위하여 대표 층을 먼저 선정하고, 해당 층에서 조업 변수만을 평가하는 Stratified Two-Stage ML 을 제안한다.

Stage1(층 선정), 층별화 요인(S)만으로 Random Forest 및 Rulefit 으로 학습하여 후보층을 생성하고 WRAcc 로 평가 및 대표 층(z^*)을 선택한다.

$$WRAcc(z) = p(z)(p(y=1|z) - p(y=1))$$

Stage2(조건부 중요도 산출) : 선택된 층(z^*)에서 조업 변수(O)만을 입력하여 Random Forest 를 학습하고 변수 중요도를 산출한다. 이를 통해 층 조건부 효과를 반영할 수 있다.

II-3. 비교 및 평가 방법

아래와 같이 총 세 가지 방법을 비교하고 평가하였다.

- 1) RF : Random Forest 모델 학습 및 Gini 중요도 산출
- 2) DC : Rotter et al.[3] Drop Column 방식으로 기준 F1 대비, 변수 제거 후 5-fold 재학습 성능 감소량을 중요도로 정의
- 3) 제안법 : Stage1 에서 층을 선정한 뒤 해당 층에서만 Random Forest Gini 중요도 산출하였다.

각 사례에 대해서 당사 엔지니어 정답인자의 순위(1=최상위)를 기록하였다. 평가지표는 사례별 순위와 Hit@5 이며, 동점 발생 시 평균 순위를 기록하였다.

II-4. 실험결과 및 분석

공정	불량유형	영향인자 순위(r_c)		
		(1)RF	(2)DC	(3)TS
A 공정	채질	3	79	1
	형상	14	63	1
	표면	6	37	1
	표면	111	49	2
B 공정	채질	125	51	4
C 공정	표면	81	37	3
D 공정	채질	4	28	1
	채질	31	24	3
E 공정	표면	5	67	2
	표면	7	5	1
F 공정	채질	24	15	1
Hit@5		0.3	0.1	1.0

[표 1. 세 방법에 따른 사례별 정답인자 순위 및 Hit@5]

표 1 은 세 방법에 대한 비교 결과를 요약하였다. 제안 방법은 모든 사례에서 정답 인자를 Top-5 내에 포함시켜 Hit@5=1.00 을 달성하였다. 반면 RF(Gini)는 0.30, Drop-Column($\Delta F1$)은 0.10 에 그쳤다.

제안 방법은 층별 특성 효과를 제거하여 핵심 원인인자를 안정적으로 상위에 배치되었으며, RF(Gini)는 층 특성 효과가 상위에 배치되는 현상을 보였다. Drop Column 방법의 경우에는 다중공선성이 심한 제조 데이터 환경에서 단일 변수 제거 효과가 미미해 과소추정 되었다.

III. 결론

본 연구는 층별 특성 요인으로 인한 변수 중요도 왜곡 문제를 해결하기 위해 Stratified Two-Stage ML 을 제안하였다. 11 개 실제 불량 사례 실험에서 제안법은 모든 사례에서 Hit@5=1.00 을 기록하여 기존 방법(RF, Drop-Column) 대비 현저히 우수함을 보였다.

이 결과는 본 연구가 단순한 알고리즘 개선을 넘어, 실제 제조 현장에서 현장 엔지니어가 핵심 인자를 신뢰성 있게

확인할 수 있는 절차를 제공한다는 점에서 의의가 크다. 특히 규칙 기반 층 선정과 조건부 중요도 산출의 조합은 설명 가능성을 높여 즉시 개선 지침으로 활용될 수 있다.

다만 본 연구는 단일 대표 층만 고려했으며, 다수의 층을 동시 평가 다양한 ML 기법 비교 및 실제 라인 적용 검증은 추후 과제로 남아 있다.

향후 연구에서는 다층적 확장과 최신 기법과의 비교를 통해 일반화 가능성을 높이고, 실시간 분석 환경에 접목함으로써 지속적인 품질 개선 플랫폼으로 발전시킬 예정이다.

ACKNOWLEDGE

본 연구는 당사 DX 전략실의 지원으로 수행되었으며, 특히 IT 인프라 구축과 시스템 협조에 도움을 주신 관계자분들께 감사드립니다.

참 고 문 헌

- [1] Bonomi, N., et al.: Smart quality control powered by machine learning algorithms. In: 2021 IEEE CASE, pp. 764–770 (2021)
- [2] Carletti, M., Masiero, C., Beghi, A., Susto, G.A.: Explainable machine learning in industry 4.0: evaluating feature importance in anomaly detection to enable root cause analysis. In: 2019 IEEE SMC, pp. 21–26 (2019)
- [3] Rotter, D., Liebgott, F., Kessler, D., Liebgott, A., & Yang, B. (2023). Machine Learning-Based Identification of Root Causes for Defective Units in Manufacturing Processes. In Advances in Automotive Production Technology – Towards Software-Defined Manufacturing and Resilient Supply Chains (SCAP 2022) (pp. 245–258). Springer.
- [4] Breiman, L., Friedman, J. H., Olshen, R. A., Stone, C. J.: Classification and Regression Trees. Wadsworth, Belmont (1984)
- [5] Montgomery, D. C.: Introduction to Statistical Quality Control, 8th ed. Wiley, Hoboken (2019)
- [6] Juran, J. M., De Feo, J. A.: Juran's Quality Handbook: The Complete Guide to Performance Excellence, 7th ed. McGraw-Hill, New York (2017)