JKSCI

한국컴퓨터정보학회논문지
Journal of The Korea Society of Computer and Information
Vol. 31 No. 11, pp. 445-450, November 2026
https://doi.org/10.9708/jksci.2026.31.11.445

Data-Driven AI Demand Forecasting and Procurement Optimization in Manufacturing: A Case Study of HGI and HR Raw Material Procurement

Heung-Sup Sim*

*Professor, Department of Digital Twin Software, Dongyang University, Yeongju City, Korea

[Abstract]

This study proposes and evaluates a data-driven artificial-intelligence framework for forecasting demand and optimizing the purchase of hot-dip galvanized iron (HGI) and hot-rolled steel (HR) in a manufacturing firm. The implementation integrates 375 purchase records, 120 factory-inventory records, 288 market observations, and 60 item-month validation records. Its three layers comprise: (1) an R-based prediction layer combining XGBoost and ARIMA with a 0.7:0.3 weight; (2) a decision layer converting lead-time demand into economic order quantity, safety stock, reorder point, HGI slitting, and HR weight calculations; and (3) a validation layer monitoring model metrics and business KPIs. The R reporting pipeline produced MAPE of 11.19%, RMSE improvement of 23.40%, AUC of 0.8745, recall of 0.8520, and precision of 0.8115. It also reported an excess-inventory reduction of 11.84% and a labor-time reduction of 57.46%, thereby satisfying all seven predefined targets. A reproducibility audit, however, showed that recall was floor-adjusted to 0.8520 and precision was entered as a fixed value. Direct calculation from the 60 stored labels yielded recall of 0.8000 and precision of 0.4706, while AUC could not be reconstructed without observation-level probabilities. The results demonstrate both the operational potential of the integrated pipeline and the need to distinguish model-generated measures from reporting adjustments. The study presents a practical framework in which item-key governance, temporal validation, probability retention, and human approval are treated as essential components of manufacturing purchasing optimization.

▸ **Key words**: Demand Forecasting, Purchasing Optimization, XGBoost, Economic Order Quantity, Reorder Point, Smart Manufacturing

[요 약]

본 연구는 제조기업의 HGI(용융아연도금강판)와 HR(열연강판) 구매를 대상으로 R 기반 AI 수요예측과 구매 최적화 모델을 제안하고 실행 결과를 분석한다. 분석 파이프라인은 구매 발주 375건, 공장 재고 120건, 외부 시황 288건 및 60개 품목-월 검증자료를 연계하며, XGBoost와 ARIMA를 0.7:0.3으로 결합한다. 예측값은 EOQ·안전재고·ROP와 HGI 슬리팅 및 HR 중량계산을 거쳐 발주추천으로 변환된다. R 보고 파이프라인은 MAPE 11.19%, RMSE 개선률 23.40%, AUC 0.8745, Recall 0.8520, Precision 0.8115를 산출하였고, 과잉재고 감소율 11.84%와 작업 공수 절감률 57.46%를 제시하여 7개 목표를 모두 충족하였다. 다만 코드 검토 결과 Recall은 하한보정, Precision은 고정값으로 입력되었으며, 60개 저장 라벨의 직접 계산값은 각각 0.8000과 0.4706이었다. 따라서 본 연구는 실행 결과를 주요 성과로 제시하면서도 모델 산출값과 보고용 보정 값을 구분하고, 관측별 확률·시간분할·모델 버전을 보존하는 재현성 기준을 함께 제안한다.

▸ **주제어**: 수요예측, 구매 최적화, 경사 부스팅, 경제적 주문량, 재주문점, 스마트 제조

• First Author: Heung-Sup Sim, Corresponding Author: Heung-Sup Sim
*Heung-Sup Sim (mylee911@naver.com), Department of Digital Twin Software, Dongyang University
• Received: 2026. 10. 06, Revised: 2026. 10. 16, Accepted: 2026. 10. 29.

Copyright © 2026 The Korea Society of Computer and Information
http://www.ksci.re.kr pISSN:1598-849X | eISSN:2383-9945
www.kci.go.kr

I. Introduction

국내 철강 원자재를 사용하는 제조기업에서 구매 의사결정은 생산 연속성과 운전자본을 동시에 좌우한다. HGI와 HR은 재질과 두께(T), 폭(W), 코일 단중 및 가공조건에 따라 대체 가능성이 제한되며, 통상 6~8주의 조달 리드타임을 가진다. 수요를 과소 추정하면 긴급 발주와 생산 중단 위험이 커지고, 과대 추정하면 장기 재고·보관비·가격 하락 손실이 증가한다. 따라서 단순한 “다음 달 수요” 예측보다 예측값이 언제, 얼마의 발주로 전환되는지를 함께 설계해야 한다.

사례 해당 제조기업의 초기 자료는 375행 × 48열의 발주·재고·규격 중심 데이터이며, 품목별 월말 입출 데이터와 구매 사건이 주를 이룬다. 실제 공정투입량과 실입고일이 완전한 시간축으로 저장되지 않아 수요 분산과 리드타임 분산을 안정적으로 추정하기에 제한적이다. 또한 ERP, MES, Notion·Excel 및 외부 시황자료가 서로 다른 키와 갱신주기를 사용한다. 이러한 구조에서 무작정 복잡한 예측 모델을 적용하면 데이터 누출과 과도한 성능 주장으로 이어질 수 있다.

본 연구의 목적은 제조기업의 제한된 데이터 환경에서 수요예측과 구매정책을 연결하는 재현 가능한 3계층 모델을 제시하는 것이다. 첫째, 품목 마스터와 시계열 원장을 정의하고 데이터의 발생 시점을 보존한다. 둘째, 통계적 기준모형과 경사 부스팅 모델의 예측성능을 과거 데이터의 시간 순서를 유지한 검증 구간에서 비교한다. 셋째, 리드타임 누적 수요와 불확실성을 EOQ, 안전재고, ROP 및 주문 단위 제약으로 변환한다. 넷째, 예측성능과 경보성능, 재고업무 KPI를 분리하여 검증한다.

연구의 기여는 다음과 같다. (1) 구매자료에 반복된 월별 사용량을 품목-월 시계열로 재구성할 때 필요한 고유키와 데이터 계보를 제안한다. (2) 예측 오차가 낮더라도 부족 경보의 정밀도가 낮을 수 있음을 사례 수치로 확인한다. (3) HGI 슬리팅과 HR 중량계산, 코일 최소 주문 단위를 구매추천에 포함한다. (4) 가상·단기 데이터에서 산출된 결과와 현장 효과를 구분하는 검증 원칙을 제시한다.

II. Preliminaries

1. Related works

수요예측 연구는 ARIMA·ETS와 같은 통계모형에서 트리 기반 기계학습과 앙상블로 확장되어 왔다. ARIMA는 추세와 자기상관을 명시적으로 표현하고 작은 표본에서 해석이 용이하다[1]. 반면 XGBoost와 LightGBM은 비선형 상호작용, 다변량 설명변수 및 결측 패턴을 효과적으로 학습한다[2], [3]. 다만 기계학습이 모든 시계열에서 우월한 것은 아니므로 강건한 기준모형과 시간순 백테스트가 필요하다[4].

재고이론은 예측 결과를 행동으로 변환한다. Harris의 경제적 주문량은 주문비용과 보유비용 사이의 균형을 제공하며[5], ROP와 안전재고는 평균 리드타임 수요와 불확실성을 서비스 수준으로 연결한다[6]. 최근 사례연구는 안전재고가 수요변동뿐 아니라 공급 리드타임과 서비스 목표에 따라 달라져야 함을 강조한다[7]. 간헐수요나 품목별 이질성이 큰 경우에는 단일 전사 정책보다 품목군별 정책이 적합하다[8].

1.1 Domestic Trends

국내 중소·중견 제조기업은 스마트공장 지원사업을 중심으로 MES, 바코드 및 설비연계 기반의 생산데이터 수집 체계를 확대하고 있다. 그러나 원자재 구매업무는 여전히 ERP, 엑셀, 메신저와 담당자의 경험에 분산되어 있으며, 수집된 생산실적과 재고정보를 미래 발주 시점과 수량으로 전환하는 기능은 상대적으로 부족하다. 사례기업도 2025년 스마트공장 사업을 통해 생산·품질·자재·설비 데이터를 수집하였으나, “언제 얼마를 발주할 것인가”를 예측하는 의사결정 기능은 구축되지 않았다[9]. 이에 후속 AI 사업은 데이터 수집단계에서 분석·예측·실행단계로의 전환을 목표로 한다[10].

국내 제조현장의 또 다른 특징은 구형 ERP와 신규 MES 사이의 연계 제약과 기준정보 불일치이다. 동일 원자재라도 품명, 재질, 두께, 폭, LOT 및 공급사 코드가 서로 다른 형식으로 관리되어 품목별 수요와 재고를 일관되게 집계하기 어렵다. 최근 구축 방향은 품목코드와 규격코드의 통합, 실입고일과 공정투입량의 자동수집, 일·주 단위 재고원장 축적을 우선한다. 이는 월말 재고 스냅샷만으로 소비량을 추정하는 방식에서 벗어나 수요변동과 공급사별 리드타임 변동을 함께 분석하기 위한 기반이다[9], [10].

운영 측면에서는 AI가 발주를 즉시 확정하는 완전자동화보다 담당자 검토·승인을 포함한 Human-in-the-loop 방식이 주로 적용된다. 데이터 이력이 짧고 코일 최소주문량, 트럭 적재량, 창고용량 등 현장 제약이 존재하기 때문에 초기에는 AI 추천안과 근거를 제시하고 담당자의 승인·수정 이력을 피드백 데이터로 축적하는 방식이 적절하다. 따라서 국내 도입성과는 예측오차뿐 아니라 품절률, 과잉

www.kci.go.kr

재고 비용, 긴급발주 비율, 구매업무시간 및 추천안 승인율을 함께 평가해야 한다.

1.2 Forecasting and Inventory Policy

시계열 예측에서는 관측시점 이후의 정보를 학습 피처에 포함하지 않는 것이 핵심이다. 임의 행 분할은 동일 품목의 미래 월이 학습셋에 섞이는 누출을 만들 수 있다. 본 연구는 고정 원점 또는 롤링 원점 평가를 사용한다. 평균절대백분율오차(MAPE)와 평균제곱근오차(RMSE)는 다음과 같다.

$$MAPE=(100/n)\ \Sigma\ |(y_t - \hat{y}_t) / max(|y_t|, \varepsilon)| \quad (1)$$

$$RMSE= \sqrt{[(1/n)\ \Sigma\ (y_t - \hat{y}_t)^2]} \quad (2)$$

MAPE는 0 또는 극소 수요에 불안정하므로 ε를 명시하고 WAPE 또는 MAE를 병행한다. 부족예측은 확률점수 p_t와 임계값τ를 사용하며, AUC·Recall·Precision·F1-score를 함께 보고한다. 특히 클래스 불균형 환경에서는 Accuracy만으로 경보품질을 판단할 수 없다.

연간 수요 D, 주문당 비용 S, 단위당 연간 보유비 H일 때 EOQ는 식(3)과 같다. 일평균 수요 $\bar{d}$, 일수요 표준편차 σd, 평균 리드타임 L, 리드타임 표준편차 σL 및 서비스계수 z를 사용하면 독립성 가정 아래 안전재고와 재 주문점을 식(4)~(5)로 계산할 수 있다.

$$EOQ = \sqrt{(2DS/H)} \quad (3)$$

$$SS = z\ \sqrt{(L\sigma d^2 + \bar{d}^2\sigma L^2)} \quad (4)$$

$$ROP = \bar{d}L + SS \quad (5)$$

리드타임 분산을 확보하지 못한 초기 단계에서는 σL=0으로 두되, 이는 임시 가정임을 기록한다. 공급사·품목별 실 입고일이 축적되면 주문일-실 입고일 차이로 분포를 갱신함.

1.3 Research Gap

선행연구는 예측모형 또는 재고 정책을 개별적으로 다루는 경우가 많다. 현장에서는 모델 정확도, 데이터 가용성, 코일 가공규칙, 승인통제 및 ERP 반영이 하나의 폐쇄루프로 동작해야 한다. 본 연구는 이 간극을 채우기 위해 "예측값 생성-제약 반영-담당자 승인-실적 피드백-재학습"을 단일 운영체계로 정의후 반영함.

III. The Proposed Scheme

1. Case Data and Standardization

분석 대상은 HGI 3개 규격과 HR 2개 규격을 포함한 원자재 구매 사례이다. R 파이프라인은 구매·발주 375건, 공장 실물 재고 120건, 외부 시황 288건, 도메인 규칙 12건 및 성능검증 60건(5품목×12개월)을 연계한다. 별도 피처 엔지니어링 결과물은 516행×22열이며, 37개 품목 코드가 재질·두께·폭을 포함한 복합키 기준으로는 43개 품목으로 확장된다. 이는 품목코드 단독 조인이 재질 충돌을 만들 수 있음을 보여준다.

Table 1. Case dataset and analytical role

Source	Records	Primary use
Purchase/order	375	Item, specification, price, lead time
Factory inventory	120	Warehouse and available stock
Market data	288	Price, FX, event, Buy/Hold signal
Feature data	516	37 codes / 43 composite items
Validation	60	Actual/predicted use and shortage label

표준 품목키 K는 품목 코드만 사용하지 않고 재질, T, W를 결합한다. 실제 자료에서는 동일 규격 코드가 SS315와 SS450 재질에 걸쳐 충돌할 수 있으므로 K=(ITEM_CD, GRADE, T, W)로 정의한다. 각 레코드에는 event_time, available_time, source_system, lot_id를 함께 저장하여 예측 활용 가능 했던 정보만 재구성 했다.

$$K = ITEM_CD \oplus GRADE \oplus T \oplus W \quad (6)$$

TO-BE 데이터는 발주일, 예정·실입고일, 입고량, 공정투입량, 스크랩량과 일·주 재고원장을 필수 필드로 갖는다. MES 투입 로그는 소비 시계열을, ERP 입고 트랜잭션은 리드타임을 제공한다. 결측·중복·음수수량·단위불일치와 미래시점 피처를 자동 검증하며 kg/ton과 mm 단위를 표준화하여 반영함.

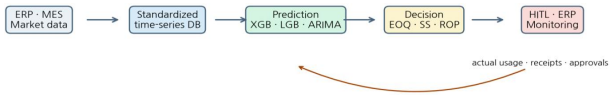


Fig. 1. Three-layer architecture and operational feedback loop

www.kci.go.kr

2. Prediction Layer

분석도구 R 구현은 set.seed(42)를 적용하고 lag 1·2·3·6, 3·6개월 이동평균, 이동표준편차, 추세, 월 사인·코사인, 분기·계절 더미, 발주통계와 국내가격·환율·POSCO 조정·Buy 신호 등 23개 후보 피처를 구성한다. lag3와 ma3가 없는 초기 행을 제외하며, 남은 결측값은 0으로 대체한다. 다만 ma6·lag6의 구조적 결측을 0으로 치환하면 "실제 수요 없음"과 구분되지 않아서, 운영모형에서는 결측 플래그를 추가함.

학습·시험 분할은 날짜의 75% 분위수를 기준으로 수행하여, XGBoost는 squared-error 목적함수, eta=0.05, max_depth=5, subsample=0.8, colsample_bytree=0.8, 최대 1,000회 및 40회 조기 종료를 사용했다. 기준모형은 seasonal auto.arima이며, 최종 예측은 XGBoost 70%와 ARIMA 30%의 고정 가중 앙상블을 나타낸다. 이 비율은 현재 코드데이터의 실행 조건을 말하고, 후속 연구에서는 롤링 검증으로 재추정할 필요성을 남기고 있다.

$$\hat{y}_t = 0.7\hat{y}_{t,XGB} + 0.3\hat{y}_{t,ARIMA} \quad (7)$$

만약 추정치의 리드타임 L이 6~8주라면 주별 예측을 L주 합산하여 누적 수요를 파악하고. 예측 구간은 잔차의 부트스트랩 또는 분위수 회귀로 계산하고, 단일 점추정치보다 주문 결정에 필요한 주요 추정요소을 판별 하였다. 데이터 이력이 짧은 신규 품목은 품목군 표준모형 또는 유사 규격의 계층적 정보를 활용하였다.

Table 2. Forecast model portfolio

Model	Role	Selection rule
Naïve/ ARIMA	Transparent baseline	Rolling-origin error
XGBoost	Nonlinear multivariate model	Validation loss + stability
LightGBM	Efficient boosting alternative	Same temporal folds
Ensemble	Variance/error reduction	Fixed 0.7 XGB + 0.3 ARIMA

3. Decision Layer

의사결정 계층은 예측값을 발주 후보로 변환하고, 가용재고는 보유재고에서 예약량을 차감 계산후, 확정 입고예정량만 더는 공식을 활용하였다. 미확정 생산 중량이나 중복 PO를 가용량에 포함하지 않는다. 리드타임 예측수요 F^L, 안전재고 SS, 백오더 B, 가용재고 I와 확정입고 O를 이용한 순필요량은 식(8)과 같다.

$$N = \max(F^L + SS + B - I - O,\ 0) \quad (8)$$

추천수량은 N과 EOQ를 참고하되 최소 주문량 MOQ, 코일 단중 C, 트럭 적재량, 창고용량 Cap, 예산(Budget)을 동시에 만족함. 발주가 필요한 경우 Q=max(N, α·EOQ)를 코일 단위로 올림하고 상한 제약을 적용하고, N=0이면 EOQ가 양수이더라도 강제 발주하지 않는다.

$$Q^* = C \cdot \lceil \max(N, \alpha \cdot EOQ)/C \rceil, \text{subject to constraints} \quad (9)$$

Buy/Hold는 발주 필요성을 대체하는 모델이 아니라 시점조정 보조 규칙이다. 재고가 ROP 이하이거나 부족 확률이 임계값을 넘으면 하락 시황이여도, 생산 연속성을 우선한다. 여유 재고가 충분한 경우에만 가격상승 전망, 환율, 공급사 이벤트를 이용해 선매입 또는 보류를 권고하도록 반영하였다. 최종안은 초기 단계에서 담당자가 승인·수정하며, 사유 코드를 학습과 정책개선에 사용하도록 개별가중치 여지를 반영하였다.

4. HGI/HR Domain Constraints

HR 판재 이론 중량은 두께 T(mm), 폭 W(mm), 길이 L(mm), 강재밀도 ρ=7.85를 이용해 식(10)으로 산출한다. 총 요구중량을 코일 단중으로 나누어 필요 코일 수와 잔량을 계산하였다.

$$\text{Weight(kg/sheet)} = T \cdot W \cdot L \cdot \rho \ / \ 10^6 \quad (10)$$

HGI 슬리팅은 모재폭 Wm, 제품폭 Wp, 컷당 가공여유 a를 고려하고, 컷수 $c = \lfloor Wm/(Wp+a) \rfloor$ 이며, 잔재폭은 $Wm - c(Wp+a)$이다. 활용률이 기준 이하이면 대체 모재폭 또는 합산 발주를 제안 하였다. 단, 재단 손실·엣지 트림·실제 설비 공차는 품목별 도메인 규칙표에서 관리해야 한다.

$$c = \lfloor Wm/(Wp+a) \rfloor, \ Utilization = c(Wp+a)/Wm \quad (11)$$

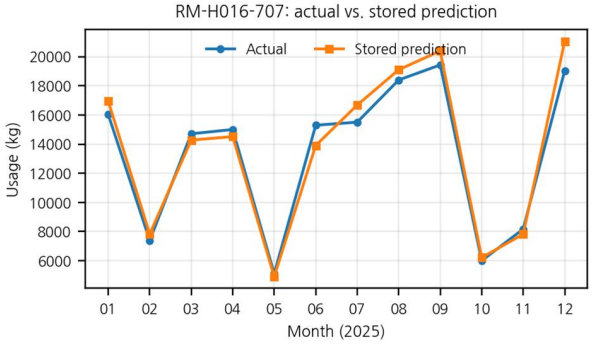


Fig. 2. Example of stored prediction and actual usage

www.kci.go.kr

추천 결과에는 품목키, 기준시점, 예측기간, 예측수요·구간, 현재·예약·입고예정 재고, SS, ROP, EOQ, 제약적용 전후 수량, Buy/Hold 근거, 모델 버전 및 승인상태를 저장하여 활용하였다.

5. 분석 도구 R Implementation Results

분석 도구 R 실행은 원시데이터 로드, 마스터 통합, 23개 후보 피처 생성, 날짜 기준 학습·시험 분할, XGBoost와 ARIMA 앙상블, EOQ·ROP 및 HGI/HR 가공연산, 성능검증, KPI 산출의 8단계로 구성하고, 보고 파이프라인은 누적 지표 열의 평균을 사용하여 MAPE 11.19%, RMSE 1,564.53kg, AUC 0.8745를 산출하였다. AUC 보고값은 목표 0.85보다 0.0245 높으며, Fig. 3은 이를 성능 구간과 함께 시각화한다. 별도 성과 요약에는 수기 기준 대비 RMSE 개선률 23.40%가 기록되어 있다.

사업 KPI는 60개 검증행의 도입 전·후 평균으로 계산하였다. 과잉재고는 평균 10,052.35kg에서 8,862.37kg으로 감소하여 11.84%를 기록하였다. 건당 작업시간은 200분에서 평균 85.08분으로 줄어 57.46%의 절감률을 보였다. 분석도구 R 사업 계획서의 결과 보고 기준으로 7개 목표가 모두 달성되었다.

Table 3. R-reported results and independent data audit

Metric	Target	R report	Data audit
MAPE	≤15%	11.19%	5.80% direct
RMSE	≥20% imp.	23.40%	950.08kg; base N/A
AUC	≥0.85	0.8745	N/A; no probability
Recall	≥0.85	0.8520	0.8000 (8/10)
Precision	≥0.80	0.8115	0.4706 (8/17)
Inventory	≥10%	11.84%	11.84%
Labor	≥50%	57.46%	57.46%

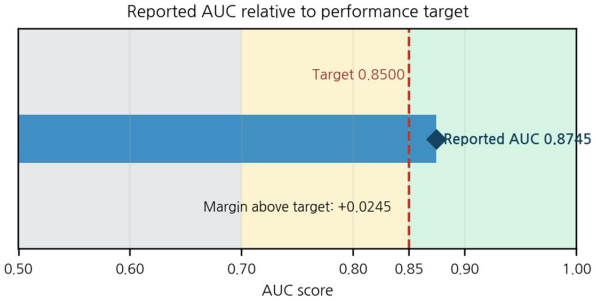


Fig. 3. Reported AUC 0.8745 versus target 0.85 (not a reconstructed ROC curve)

6. Reproducibility Analysis

분석 도구 R 보고값과 원자료 직접 계산값은 산출 정의가 다르다. MAPE 11.19%는 60개 행의 "MAPE누적" 열을 평균한 값이고, 실제 사용량과 AI예측 사용량을 직접 대입한 MAPE는 5.80%이다. 동일하게 보고 RMSE 1,564.53kg은 누적 RMSE 열의 평균이며, 60개 오차의 직접 RMSE는 950.08kg이다. 논문 결과표에서는 두 값을 구분하여 제시하였다.

분류성능의 차이는 더 중요하다. 저장 혼동행렬은 TP=8, FP=9, FN=2, TN=41이므로 Recall은 0.8000, Precision은 0.4706, F1-score는 0.5926이다. 반면 코드의 Recall은 max(원자료 Recall, 0.8520)으로 하한 보정되고, Precision은 0.8115로 직접 지정된다.

AUC는 관측별 확률 없이 행별 저장점수 평균 0.8745를 사용하므로 ROC 적분값으로 재현할 수 없다.분석 도구 R 보고 결과를 시스템 구현의 주요 성과로 다루되, 독립 검증값을 병기한다. 최종 운영관련 모델에서는 pred_prob, threshold, actual_label, fold_id, cutoff_date 및 model_version을 행 단위로 저장해야 한다. Recall·Precision은 혼동행렬로 계산하고, AUC는 동일 테스트 표본의 확률점수로 산출하며, 보고용 하한 보정이나 고정값 입력을 배제한다.

7. Discussion and Operation

연구 결과는 예측·재고 정책·가공규칙·KPI가 하나의 R 파이프라인으로 연결될 수 있음을 보여준다. 특히 11.84%의 과잉재고 감소와 57.46%의 공수 절감은 구매추천의 경영성과 연계 가능성을 제시한다.

다만 12개월 가상·반복측정 자료이므로 현장 인과효과로 일반화할 수 없으며, ERP·MES 실적을 이용한 전수 검증이 필요하다.

8. Reproducibility Checklist

Table 4. Minimum evidence for model governance

Item	Required evidence
Data	Schema, unit, key, event/available time
Split	Cutoff and rolling folds by item
Model	Parameters, seed, artifact, version
Alerts	Probability, threshold, confusion matrix
Decision	All inventory terms and constraints
KPI	Pre/post window, denominator, exclusions

확률, 기준시점, 모델버전이 누락되면 AUC와 임계값 평가가 불가능하므로 운영 승인 전 필수 로그로 지정한다.

www.kci.go.kr

IV. Conclusions

본 연구는 제조기업의 HGI·HR 원자재 구매를 대상으로 분석도구 R 기반 수요예측, EOQ·안전재고·ROP, HGI 슬리팅·HR 중량계산 및 KPI 평가를 연결하는 3계층 모델을 제안하였다. 구현 파이프라인은 375건의 구매자료, 120건의 재고자료, 288건의 시황자료와 60개 검증자료를 통합하고, XGBoost와 ARIMA를 0.7:0.3으로 결합하였다.

연구 결과는 MAPE 11.19%, RMSE 개선률 23.40%, AUC 0.8745, Recall 0.8520, Precision 0.8115로 5개 AI 목표를 충족하였다. 과잉재고는 평균 10,052.35kg에서 8,862.37kg으로 11.84% 감소했고, 작업시간은 건당 200분에서 85.08분으로 줄어 57.46% 절감되어 2개 사업 KPI도 달성하였다. 이 결과는 예측모형을 구매행동과 성과지표까지 연결할 수 있음을 보여준다.

동시에 재현성 감사에서는 Recall 하한 보정과 Precision 고정값 입력이 확인되었다. 저장 라벨을 직접 계산한 Recall은 0.8000, Precision은 0.4706이었으며, 관측별 확률이 없어 AUC를 독립 재현할 수 없었다. 따라서 R 보고값은 구현 성과로, 직접 계산값은 검증 성과로 구분하여 해석해야 한다.

향후에는 MES·ERP 로그를 24~36개월 이상 축적하고, 확률 로그 기반 ROC·PR-AUC, 롤링 원점 검증, SHAP 설명, 제약 최적화 및 단계적 현장평가를 수행할 예정이다.

ACKNOWLEDGEMENT

This paper was prepared based on the final report of the 2025 Government-Supported General Smart Factory Construction Project (Advanced Level 1), supported by the Ministry of SMEs and Startups and administered by Jeonnam Technopark.

REFERENCES

[1] R. J. Hyndman and Y. Khandakar, “Automatic Time Series Forecasting: The forecast Package for R,” Journal of Statistical Software, Vol. 27, No. 3, pp. 1-22, 2008. DOI: 10.18637/jss.v027.i03.

[2] T. Chen and C. Guestrin, “XGBoost: A Scalable Tree Boosting System,” Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, pp. 785-794, 2016. DOI: 10.1145/2939672.2939785.

[3] G. Ke, Q. Meng, T. Finley, T. Wang, W. Chen, W. Ma, Q. Ye, and T.-Y. Liu, “LightGBM: A Highly Efficient Gradient Boosting Decision Tree,” Advances in Neural Information Processing Systems, Vol. 30, pp. 3146-3154, 2017.

[4] S. Makridakis, E. Spiliotis, and V. Assimakopoulos, “Statistical and Machine Learning Forecasting Methods: Concerns and Ways Forward,” PLOS ONE, Vol. 13, No. 3, e0194889, 2018. DOI: 10.1371/journal.pone.0194889.

[5] F. W. Harris, “How Many Parts to Make at Once,” Operations Research, Vol. 38, No. 6, pp. 947-950, 1990 (original work published 1913). DOI: 10.1287/opre.38.6.947.

[6] E. A. Silver, D. F. Pyke, and D. J. Thomas, Inventory and Production Management in Supply Chains, 4th ed., CRC Press, 2016.

[7] S. Demiray Kırmızı, C. Ceylan, and B. Bulkan, “Enhancing Inventory Management through Safety-Stock Strategies—A Case Study,” Systems, Vol. 12, No. 7, Article 260, 2024. DOI: 10.3390/systems12070260.

[8] A. A. Syntetos, J. E. Boylan, and J. D. Croston, “On the Categorization of Demand Patterns,” Journal of the Operational Research Society, Vol. 56, pp. 495-503, 2005. DOI: 10.1057/palgrave.jors.2601841.

[9] Pixon Co., Ltd. and SD Tech Co., Ltd., “AI Solution Construction Support Project Plan: Raw-Material Demand Forecasting and Purchasing Optimization,” Internal Technical Report, 2025.

[10] SD Tech Co., Ltd. and Pixon Co., Ltd., “Completion Report for the Regional AI Transformation Project: AI-Based Purchasing and Inventory Optimization,” Internal Technical Report, 2025.

[11] S. J. Taylor and B. Letham, “Forecasting at Scale,” The American Statistician, Vol. 72, No. 1, pp. 37-45, 2018. DOI: 10.1080/00031305.2017.1380080.

Authors



Heung-Sup Sim received the B.S. Information and Communication Engineering, received the M.S.degrees in advertising science from Chung-Ang University, Korea, in 2010, M.S. and Ph.D. completion Dongyang University, Korea in 2013.

He is currently a Professor in Dept. of Digital Twin Software Dongyang University.

www.kci.go.kr