

시계열분석과 강화학습을 활용한 오프라인 매장

적정재고 연구

김진규¹

¹ 고려대학교 컴퓨터정보통신대학원

gaon11212@hanmail.net

A Study on Appropriate Inventory of Off-line Store using Time Series and Reinforce Learning

Jin-Kyu Kim¹

¹Graduate School of Computer & Information Technology, Korea University

요 약

최근 공급망 이슈로 재고관리의 중요성이 커지는 상황이다. 본 연구에서는 시계열분석과 강화 학습을 이용해 오프라인매장의 적정재고를 관리하는 방안을 연구하였다. 연구결과 방안을 활용해 효율적인 재고관리가 가능함을 확인하였다. 향후 온라인 매장으로의 연구확대를 기대한다.

1. 서론

최근 러시아와 우크라이나 전쟁, 코로나 19 팬데믹 등으로 물자의 이동이 제한되고 공급망이 흔들리는 이슈가 발생했다. 또한 지정학적 상황으로 인해 반도체와 같은 핵심부품 등의 수출제재가 발생했고 이러한 이슈들은 공급망의 재편으로 이어지고 있다.[1] 수출에 대한 국가경제의 의존도가 높은 우리나라의 경우 이러한 공급망 재편에 민첩하게 대응해야 하는 상황이다.


공급망은 크게 구매, 제조, 판매, 마케팅 등 단계로 나뉘며, 적정량의 재고 수준을 유지하는 재고관리를 통해 시장 상황에 민첩하게 대응하고 비용을 절감하는 것이 중요하다. 본 연구에서는 위 단계 중 판매 단계에서 유통채널 간 필요한 수량만큼 상품을 발주하고 입고하는 Sell-in 프로세스, 상세하게는 오프라인 매장의 판매량 수요예측과 예측된 수요를 바탕으로 적정한 재고를 산정하는 기법에 대해 연구하고 대안을 제안해보고자 한다.

2. 용어 설명 및 문제제기

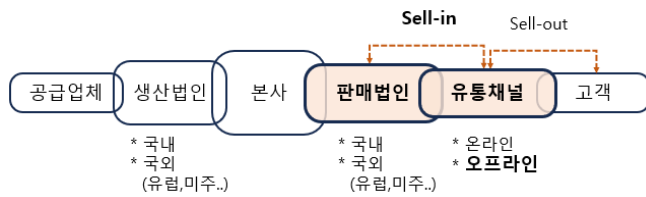
2.1 SCM

SCM(Supply Chain Management)이란 공급망 관리를 뜻하며 생산에 필요한 자재, 부품의 구매부터 제조, 판매, 상품의 마케팅에 이르는 물류의 흐름을 연속된 업무고리(Chain)의 연결 관점에서 해석하고 필요한 정보가 효율적으로 흐르도록 지원하고 관리하는 시스템을 말한다. 기업은 SCM 을 이용해 자원을 효율적으로 배치할 수 있고 이를 통해 원가 절감과, 빠르게 변화하는 시장 상황에 대한 민첩한 대응을 할 수 있다.

공급망 단계별로 주요 의사결정 시 활용하기 위해 기계학습 기법을 수요예측, 이상감지 등의 도메인 분야에 도입하려는 연구는 다양하게 진행되고 있다. 예를 들어 구매단계에서의 제품-부품 군집화, 제조단계에서의 공정 이상감지, 판매 및 마케팅단계에서의 판매량 수요예측 등이 있다.



(그림 1) SCM 프로세스와 본 연구범위



(그림 2) 공급연결고리 중 Sell-in 프로세스

2.2 재고관리

재고관리는 공급망 관리에서 기업의 원가 관리를 위해 중요하게 연구되고 있다. 적정량의 재고 수준을 유지함으로써 고객의 수요에 적절하게 대응할 수 있고 불필요한 비용 절감을 할 수 있다. 불필요한 비용의 종류에는 크게 두 가지가 있다. 첫째로 재고 부족은 고객 서비스 수준 하락비용 및 판매기회 상실비용을 발생시킬 수 있다. 반면에 재고 과잉은 추가적인 재고유지 비용의 발생을 초래할 수 있다. [2]

재고관리 프로세스는 매장관리자의 상품에 대한 발주로 시작되며 리드타임(상품 이동시간)을 거쳐 입고가 완료되면 재고관리가 시작된다. 확보된 재고에 대해 고객 판매를 진행하고 판매된 수량과 예상했던 판매 수량 대비 예상치 못한 수요에 대응하기 위한 안전재고를 감안하여 적정한 발주를 수행하며 프로세스가 발주 주기에 따라 반복된다.

오프라인 매장에서 효율적인 재고관리를 하기위해 의사결정이 필요한 단계는 크게 판매량에 대한 예측 단계와 적정한 발주수량, 안전재고에 대한 산출단계로 나눌 수 있다. 기존에도 각 단계에 대한 관련연구가 있었지만 단계별로 개별적인 연구가 대부분이었다.

본 연구에서는 이 두 단계를 연결하여 한번에 적용할 수 있는 모델을 제안하고자 한다.

3. 연구 방법

3.1 데이터 수집 및 처리

Kaggle 에서 제공하는 수요예측 데이터셋 중 10 개 매장, 50 개 품목에 대해 2013-01-01 부터 2017-12-31 까지 5 년 동안의 일별 판매량 데이터를 다루는 데이터셋을 활용하였다. 매장 및 품목별 탐색결과 전체기간 평균 판매량이 가장 많은 매장 및 품목을 선택하여 분석을 진행하였다. 발주 후 입고까지 소요되는 리드타임은 2 일로 가정하였다. 판매량이 재고량보다 클 때 타 매장의 재고를 이동 입고하여 판매하고 해당 매장의 판매는 실기한 것으로 간주하였다. 연구단계는 시계열분석을 활용해 판매량을 예측하는 1 단계와 1 단계 실험 중 가장 좋은 성능을 보인 모델의 결과를 바탕으로 강화학습을 활용해 적정재고를 산출하는 2 단계로 나눠 연구를 진행하였다. train 기간은 2013-01-01 부터 2017-09-30 까지, test 기간은 2017-10-01 부터 2017-12-31 까지로 하여 각각 학습과 예측 및 평가를 진행하였다.

3.2 시계열분석을 활용한 판매량 예측

시계열분석이란 어떤 현상에 대하여 과거에서부터 현재까지의 시간흐름에 따라 기록된 데이터를 바탕으로 미래의 변화에 대한 추세를 분석하는 기법이다. 본 연구에서는 시계열분석 기법 중 대표적인 기법인 ARIMA 를 활용하여 기존 현장에서 사용하던 통계적 기법과 비교 분석을 진행한다.

ARIMA 는 Auto Regressive Integrated Moving Average 의 약어로 과거 시계열 관측값과 오차를 기반으로 현재의 시계열 관측값을 설명하는 일반화된 모형이다. ARIMA 모형을 적용하기 위해서는 데이터가 평균과 분산 측면에서 정상성(Stationary)를 유지해야 하며 정상성을 유지하지 않을 경우 차분(difference)을 통해 데이터의 정상성을 확보한 후 적용할 수 있다. [3]

3.3 강화학습을 활용한 적정재고 산출

강화학습이란 현재의 상태(State[S])에서 에이전트가 어떤 행동(Action[A])을 취할 때 외부 환경으로부터의 보상(Reward[Q])이 최적화되는지 학습하는 기계학습의 한 유형이다. 본 연구에서는 강화학습을 재고관리에 적용하여 상태[S]에는 재고 및 판매, 에이전트에는 상품담당자 또는 매장담당자, 행동[A]에는 발주 및 입고, 보상[Q]에는 실기량과 재고량의 개념을 대입한다. 학습할 정책(Policy[π])에는 발주량에 대한 보정계수와 안전재고를 대입하여 불안정하게 변화하는 수요에 유연하게 대응할 수 있도록 한다. 재고부족으로 인한 판매실기를 큰 리스크로 인식하는 현장의 경험을 활용하여 실기량에 제약을 취해 페널티를 크게 하였다. 목표는 누적된 보상[G]인 실기량²과 재고량의 합이 가장 적게 산출되는 최적 정책(π^*)을 찾는 것이다.

$$Q_{\pi^*} = \underset{\pi}{\operatorname{argmin}} Q_{\pi}(s, a) \\ = \underset{\pi}{\operatorname{argmin}} [G | S=s, A=a]$$

* G(누적보상) = 실기량² + 잔존재고량

* 실기량 = $-\min[(\text{전일재고} + \text{당일입고} - \text{당일판매}), 0]$

* 잔존재고량 = $\max[(\text{전일재고} + \text{당일입고} - \text{당일판매}), 0]$

(수식 1) 최적 정책 및 보상 산출 방법

발주, 입고, 재고, 판매는 일별로 발생하며 실기량, 재고량도 일별로 계산한다. 최종적으로 테스트기간 전체에 대해 누적보상으로 최적 정책을 산출한다. 시계열분석 모델로 예측한 판매량을 바탕으로 발주를 진행하고, 발주를 통해 리트타임이 지난 후 입고된 상품이 전일재고와 합산되어 당일 판매를 위한 재고로 사용된다.

4. 연구 결과


4.1 시계열분석을 활용한 판매량 예측 결과

예측 정확도는 2017-10-01 부터 2017-12-31 까지 학습에 사용되지 않은 3 개월의 데이터에 대한 판매량을 통계적 기법과 ARIMA 모델로 예측한 후 MAPE,

SMAPE, MSE, MAE 등 평가지표로 예측값을 평가하였다. Grid Search 방법을 통해 ARIMA 모델에서 최적 파라미터(p:6,q:4)를 확인하였고 모델링에 적용하였다. 테스트 결과 ARIMA 모델을 사용하는 것이 통계적 기법을 사용하는 것 보다 모든 평가지표에 대한 예측 정확도가 높게 나오는 것을 확인할 수 있었다.

예측 모델	MAPE	SMAPE	MSE	MAE
직전1주일 판매량평균	14.01	13.38	352.03	15.40
직전1개월 판매량평균	16.34	14.65	479.16	17.02
ARIMA(6, 1, 4) 모델	11.58	11.19	268.70	12.99
ARIMA(6, 2, 4) 모델	11.36	11.14	273.75	12.78

(표 1) 예측 모델별 판매량 예측 정확도 비교



(그림 3) 알고리즘별 시계열 예측결과

MSE 평가지표를 기준으로 할 때 예측 정확도가 가장 높게 나온 ARIMA 모델의 파라미터는 (p:6,d:1,q:4)이며 이 모델을 이용해 예측한 판매량을 바탕으로 적정재고 산출을 위한 강화학습 시뮬레이션을 진행하였다.

4.2 강화학습을 활용한 적정재고 산출 결과

시계열분석 모델을 통해 예측한 판매량에 보정계수 안전재고를 적용해 적정재고(보상)을 산출하는 정책을 학습하였다. 전일 잔존재고가 안전재고보다 작을 시 보정계수를 적용한 비율로 발주수량을 늘리도록 하였다. 그 외의 경우 전일 잔존재고와 안전재고의 차이만큼의 비율로 발주수량을 줄이도록 했다.

$$\text{If } (S > x) \rightarrow p_{\text{발주}} = (S - x) \times C / 100 \\ \text{else} \rightarrow p_{\text{줄수}} = (S - x) / 100$$


* S : 안전재고, C : 보정계수, x : 전일 잔존재고(전일 마감 후 재고)

* S와 C는 하이퍼파라미터

$$\text{Action(발주수량)} = \text{시계열분석을 통해 예측한 판매량} \times (1 + p)$$

(수식 2) 발주수량 보정

보정계수와 안전재고를 조정하며 테스트기간에 대해 누적보상(실기² + 재고비용)을 매일 계산하였고 그 결과 누적보상이 최소가 되는 최적 정책(π^*)을 도출하였다. 해당 정책을 적용하였을 때 누적보상은 78.5가 나왔으며 이는 통계적 기법을 사용하였을 때 얻게 되는 보상인 135.3 보다 더 나은 결과임을 확인할 수 있었다.



(그림 4) 보정계수, 안전재고에 따른 Reward

본 연구모형을 적용하였을 때 일반적인 통계적 기법을 사용하였을 때 보다 더 효율적인 재고관리를 할 수 있다는 결론을 얻을 수 있었다.

5. 결론 및 향후 과제

본 연구에서는 효율적인 오프라인 매장 재고관리를 위한 시계열분석 기반 판매량 예측과 강화학습 기반 적정재고 산출방안을 제안하였다. 연구 결과 시계열 분석과 강화학습을 활용한 재고관리 모델이 기존 통계적 기법을 통한 재고관리 방식보다 더 효율적인 것을 확인할 수 있었다. 판매기회 상실과 부진재고, 두 가지 측면에서 모두 비용 발생이 감소하는 것을 확인할 수 있었다.

기업 매출 증대를 위해 매장과 품목의 확대는 필수적이거나 이를 관리할 인력과 비용은 대체로 제한적이다. 모든 매장과 품목에 대해 재고를 관리하기 힘든 상황에서 특정 품목을 제외한 나머지 품목에 대해 효율적인 재고관리가 필요할 경우 본 연구에서 제안하는 방법을 활용할 수 있을 것이라 기대한다. 코로나 19 팬데믹 이후 비대면 거래가 일반화된 시점에서 추

후 온라인 매장의 적정재고 관리방안으로 연구범위를 확장해보고자 한다.

참고문헌

- [1] 주호재, “현장 컨설턴트가 알려주는 공급망 관리 (SCM) 성공 전략”, 성안당, 2022
- [2] 권익현, “강화학습 기반의 다단계 공급망 분배계획”, 대한안전경영과학회지, 2014, vol.16 no.4 pp.323-330
- [3] 하준수, “시계열 분석 기반 신뢰구간 추정을 활용한 항만 물동량 이상감지 방안”, 한국항만경제학회지, 2021, pp.179-196