

<https://doi.org/10.7236/IIBC.2018.18.2.197>

IIBC 2018-2-24

중소기업 제조공장의 수요예측 기반 재고관리 모델의 효용성 평가

Effectiveness Evaluation of Demand Forecasting Based Inventory Management Model for SME Manufacturing Factory

김정아*, 정종필**, 이태현***, 배상민***

Jeong-A Kim*, Jongpil Jeong**, Tae-hyun Lee***, Sangmin Bae***

요약 다품종 소량생산체제인 중소기업 제조공장은 고객의 니즈를 대응하기 위해 제품을 대량생산하여 판매하는 형태이다. 이는 기업이 재고 부족에 따른 손실을 줄이기 위해 과도한 양의 자재 수급을 의미하고 높은 재고 유지비용이 발생한다. 그리고 수요 대응에 실패한 제품은 관리 창고에 쌓여 있어 재고 보관비용이 발생하는 현실이다. 본 논문은 이러한 문제를 보완하기 위해 시계열 분석 기법인 ARIMA모형을 이용하여 계절적 요인과 같은 시간적인 변동성을 찾아 수요를 예측하고 이를 통해 경제적 주문량 모형 기반의 수요예측 모델을 개발하여 재고 부족 위험을 예방한다. 또한 시뮬레이션을 수행하여 개발 모델의 효용성 평가하고 향후 중소기업에 적용하여 개발 모델의 효과를 입증한다.

Abstract SMEs manufacturing Factory, which are small-scale production systems of various types, mass-produce and sell products in order to meet customer needs. This means that the company has an excessive amount of material supply to reduce the loss due to lack of inventory and high inventory maintenance cost. And the products that fail to respond to the demand are piled up in the management warehouse, which is the reality that the storage cost is incurred. To overcome this problem, this paper uses ARIMA model, a time series analysis technique, to predict demand in terms of seasonal factors. In this way, demand forecasting model based on economic order quantity model was developed to prevent stock shortage risk. Simulation is carried out to evaluate the effectiveness of the development model and to demonstrate the effectiveness of the development model as applied to SMEs in the future.

Key Words : Inventory Management, Demand Forecasting, Economic Order Quantity, Time Series Analysis, Simulation

1. 서 론

대부분의 중소기업은 다품종 소량생산체제로 고객의 니즈에 따라 대량생산하는 형태로 운영되고 있다. IT기

술의 발전으로 현재에는 사물인터넷(Internet of thing, IoT)^[1,2] 환경이 구축되면서 고객의 요구도 진화되고 있다. 이에 따라 공장에서는 고객의 다양한 요구에 대응하기에는 어려운 현실이다. 또한 제품 트렌드의 급변한 상

*준회원, 성균관대학교 스마트팩토리융합학과

**정회원, 성균관대학교 스마트팩토리융합학과(교신저자)

***정회원, 마크에이티브

접수일자: 2018년 2월 4일, 수정완료: 2018년 3월 4일

게재확정일자: 2018년 4월 6일

Received: 4 February, 2018 / Revised: 4 March, 2018

Accepted: 6 April, 2018

**Corresponding Author: jpjeong@skku.edu

Department of Smart Factory Convergence, Sungkyunkwan University, Korea

황으로 개발과정에서 재개발의뢰, 신뢰성 부족 등의 문제가 발생됨에 따라 수요예측에 실패한 재고들은 관리창고에 보관되어 있다. 이는 재고의 낭비를 야기하며, 많은 재고를 유지하는 재고 유지비용과 주문비용이 높아지고 있다. 이러한 문제를 해결하기 위해 중소기업들은 효율적인 재고관리를 위한 기존의 경제적 주문량 모형(Economic order quantity, EOQ)^[3]을 적용하고 있다. 경제적 주문량 모형을 통해 최적 주문량을 도출하여 적절한 재고 유지비용과 보관비용을 줄일 수 있다^[4]. 그러나, 대부분의 중소기업에서 사용하는 경제적 주문량 모형은 수요와 리드타임이 고정적이지 않은 상황에서 적용하기 어렵다. 또한 재고 품목에 따른 미래 수요를 예측하지 못해 재고부족 위험에 따른 경제력 상실 문제가 발생한다^[5]. 그리고 이에 따른 대책으로 기업에서는 과도한 양의 자재를 수급하여 유지함에 따라 높은 재고유지 및 주문비용이 발생한다^[6]. 따라서 수요예측이 고려되지 않은 경제적 주문량 모형을 적용하기에는 쉽지 않다.

본 논문은 기존 경제적 주문량 모형의 문제점을 보완하기 위해 시계열 분석기법인 ARIMA (Autoregressive integrated moving average) 모형^[7]을 사용하여 수요량을 예측한다. 이를 통해 경제적 주문량 모형 기반의 수요 예측 모델을 개발한다. 개발한 모형의 효용성을 평가하기 위해 시뮬레이션을 수행하여 개발한 수요예측 모형의 효과를 확인하였다. 이러한 문제 해결이 필요한 국내 제조업체를 선정하여 적용함으로써 효과가 입증될 것으로 사료된다.

2절에는 경제적 주문량 모형과 시계열 분석 및 모형에 대한 관련연구를 설명한다. 3절에는 ARIMA 모형을 이용한 미래 수요량을 예측하고 수요예측기반의 경제적 주문량 모델 개발을 제안한다. 4절에는 예측한 수요량을 기반으로 개발한 모형을 평가하기 위해 시뮬레이션을 수행하여 효과를 입증한다. 마지막으로 5절에는 본 연구의 결론을 요약하고 향후 연구에 대해 설명한다.

II. 관련연구

중소 제조 기업은 다품종 소량생산 형태로 고객의 주문을 대략 예측하여 자재를 대량 구매하고 주문에 따라 재가공하여 판매하는 형태이다. 자재 주문의 리드타임이 비교적 길어지게 되면 고객의 니즈를 대응하기는 어렵다.

따라서, 경제적 주문량 모형을 사용하여 정확한 리드타임 파악과 적절한 주문량 파악을 할 수 있는 재고관리가 이루어져야 한다. 이를 통해 현장에서 발생하는 다양한 변수를 예측하여 효율적인 재고관리가 가능하다.

1. 경제적 주문량 모형

경제적 주문량 모형은 효율적인 재고관리를 위해 최적 주문량, 적절한 리드타임 주기, 안전재고 그리고 재주문점을 도출할 수 있다. 안전재고는 리드 타임 기간 동안의 재고 부족의 발생에 따른 위험을 예방한다. 또한 적절한 주문량을 계산하여 수요대비 재고유지비용, 재고수량 등을 줄이기 위한 재고 비용 절감을 위해 사용한다.

이를 해결하도록 최적 주문량을 계산을 위해 가정하였다.

- (1) 수요는 연간 일정하게 발생
- (2) 재고유지비용은 평균 재고 기준
- (3) 주문비용은 매입의 총 비용의 1%
- (4) 재고보유비용은 단위당 구입비용의 5%
- (5) 반품은 허용하지 않음

최적 주문량 계산을 위한 가정은 원재료 비용 상승이나 계절적 요인으로 인한 자재비용 상승 등 예상치 못한 변수들이 발생함에 따라 번번이 대응하기 어려운 상황으로 필요하다.

최적 주문량을 파악하기 위해 수식 (1)을 활용한다. 최적 주문량을 계산하기 위한 변수로 S는 단위 당 주문비용, H는 재고유지비용, 그리고 D는 연간 수요를 나타낸다^[8]. 남은 재고량이 미리 설정한 재 주문점(Reorder Point, ROP)에 도달할 때 발주를 넣는다.

$$EOQ = \sqrt{\frac{2DS}{H}} \quad (1)$$

리드타임과 수요의 표준편차를 계산하기 위한 수식 (2)를 활용한다. \bar{LT} 는 리드타임의 평균, σ_{LT} 는 리드타임의 표준편차, \bar{d} 는 수요의 평균 그리고 σ_d 는 수요의 표준편차를 나타낸다.

$$\sigma_{dLT} = \sqrt{\bar{LT}\sigma_d^2 + \bar{d}^2\sigma_{LT}^2} \quad (2)$$

재주문점을 나타내는 수식 (3)은 리드타임 L 을 통해 예상 수요와 서비스 수준에 맞춰 안전재고에 따라 설정한다. z 는 서비스 확률 계산을 위한 표준편차의 배수이며, $z\sigma_{dLT}$ 는 안전재고량을 그리고 \bar{d} 는 수요평균을 의미한다.

$$ROP = \bar{d} \times \overline{LT} + z\sigma_{dLT} \quad (3)$$

평균수요에 수식 (2)에서 얻은 평균리드타임을 곱한 후 안전재고를 더한 값을 의미한다. z 는 고객의 니즈를 대응하는 서비스 수준을 뜻하며 리드타임 동안 수요량이 공급량을 초과하지 않을 확률로 선택할 수 있다. 재주문점은 남은 재고량이 리드타임 기간 동안 고객의 니즈를 충분히 대응 가능하다고 판단하는 시점을 의미한다. 적시에 재주문점을 파악하기 위해서는 지속적인 재고조사가 필수적이다.

2. 수요예측을 위한 시계열 분석

수요예측은 원본 데이터에 근거하여 수요예측 패턴을 모색한다. 수요예측 패턴을 도출하기 위해 정성적 방법과 정량적 방법으로 구분할 수 있다. 정성적 방법은 수요 패턴을 찾기 위해 분석할 과거 데이터를 사용하지만 경향성을 확인하기 어려우며, 예측 대상이 정해지지 않았을 때 수리적 모형으로 이용한다. 반면 정량적 방법은 예측할 원본 데이터를 근거로 통계 분석하여 미래의 수요 패턴을 예측하는 방법이다. 수요예측 분석 방법은 시계열 모형, 인과모형 그리고 성장곡선 모형 등으로 구분할 수 있다^[9].

과거 자료에서 수요 값들이 존재할 경우 시계열 분석을 통해 수요예측에 활용할 수 있다. 시계열 분석은 주차별 주문에 따라 관측되는 패턴을 인식하고 추세나 계절적 요소에 따른 미래 수요를 예측할 수 있다^[10,11]. 시계열 분석 방법은 지수평활법, 이동평균법 그리고 ARIMA 모형 등이 있다. 이를 통해 고객의 니즈를 만족시키기 위해서는 수요량 예측은 필수적이다. 수요량 예측 기법인 ARIMA 모형은 자기회귀(Auto Regression, AR) 모형과 이동평균(Moving Average, MA) 모형이 결합된 혼합 모형으로 계절적이나 시간 흐름에 따른 시계열 변화를 예측하기 위한 계절적 자동 회귀 조건을 의미한다^[12]. 또한 비정상화 데이터인 ARIMA 모형은 ARIMA (p, d, q)로 표기한다. d는 차분의 차수, q는 MA 모형의 차수, 그리

고 p는 AR 모형의 차수를 나타낸다^[13]. ARIMA 모형은 과거의 데이터와 오차 파악하여 고객 수요 대응을 위한 수요 예측이 가능하다. 따라서, ARIMA 예측 모형을 이용하여 실제 중소기업의 과거 수요 값을 토대로 신뢰할 수 있는 수준의 미래 수요를 예측하여 적시에 고객의 니즈를 만족시키고 재고관리 비용을 절감하는 경제적 주문량 기반의 수요예측 모델을 개발한다.

III. 경제적 주문량 모형 기반 수요예측 모델 개발

1. 기존 경제적 주문량 모형의 문제점

현재 대부분의 중소기업들의 재고관리 문제로 인한 어려움을 겪고 있는 상황에서 출고량 및 출고 시기는 일정한 반면, 입고량 및 입고 시기가 불안정하다. 또한 출고량이 일정하게 유지할 경우 리드 타임이 일정하지 않는 상황으로 재고부족기간이 길어진다. 그리고 고객 수요 대응에 따라 적시에 공급을 못하면 신뢰성이 하락하고 손실은 높아져 미리 많은 재고를 확보하고 있다. 따라서 재고량 유지비용 창고 비용이 높아지고 있어 기업 경영이 어려운 현실이다.

기존 경제적 주문량 모형을 활용하여 어려움이 있는 중소기업들을 조사하여, 다품종 소량생산 형태의 비료 공급 및 생산 업체인 중소기업 D사를 선정하였다. D사는 고객의 주문을 대략 예측하여 원료를 대량 구매하고 주문에 따라 재가공하여 판매하는 형태이다. D사 기업의 경우 사내 내부 회의를 거쳐 결정된 주문량을 재주문 시점에 발주하게 된다. 그러나 이런 상황은 해당 원료에 대한 고객의 니즈에 따라 변동이 자주 발생하여 기업 매출에도 큰 영향을 끼친다. 따라서, 이러한 경제적 주문량 모형의 문제점을 해결하기 위해 기업에서 실제 활용 가능한 수요 예측 기반 모델 개발을 제안한다.

2. ARIMA 모형을 통한 미래 수요량 예측

고객의 니즈를 예측하면 리드타임 동안 수요를 대비할 수 있는 재고량을 파악할 수 있어 적절한 재고 유지와 관리가 가능하다. 고객 니즈를 만족하는 주문량을 파악하기 위해 과거 데이터를 근거로 수요패턴을 예측하기 위해 정량적 방법인 시계열 모형을 이용한다. 이를 통해 과거 데이터에서 시간이 흐름에 따라 수요 패턴을 찾고

이에 따른 미래 수요량을 예측한다. 그림 1은 시계열 분석 기법을 이용하여 고객의 니즈 대응을 위해 파악한 D사의 2013~2016년 4년간의 수요량인 시계열 자료이다.

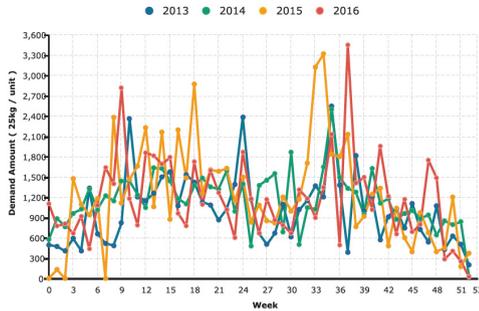


그림 1. D사의 연도별 수요량을 시각화하여 표현
Fig. 1. Visualize to express the year of demand value by D company

D사의 시계열 자료를 시각화하여 분석한 결과 봄(7~18주)과 가을(28~39주)이 비교적 다른 계절에 비해 수요량이 급증하였다.

추가적으로 정확한 계절적 요인을 파악하기위해 시계열 자료를 분해하여 계절적 요인이나 추세와 같은 수요 패턴을 확인하였다.

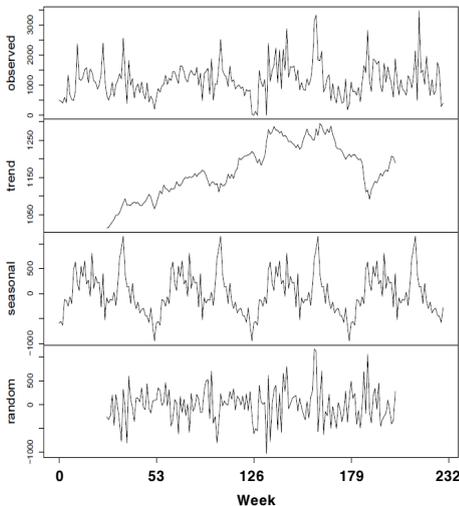


그림 2. 시계열 분해법을 통한 수요 패턴 확인
Fig. 2. Demand patterns through time series decomposition

그림 2는 시계열 분해법을 통해 시계열 데이터를 Observe, trend, seasonal 그리고 random 값으로 분해하

여 미래 수요 예측을 위한 계절적 수요 패턴을 확인하였다. 그림 3과 같이 최적의 ARIMA 모델을 도출하였다.

ARIMA(1,0,0)(1,0,0)₅₃ 모형은 AR(1)×SAR(1)₅₃을 계산한 것으로 AR 일반시점과 SAR 계절시점의 상호작용에 의해 AR(1)×SAR(1)₅₃ 모형이 보다 현실적인 모형이 된다.

$$Y_t = \alpha_1 Y_{t-1} + \alpha_1^* Y_{t-s} - \alpha_1 \alpha_1^* Y_{t-s-1} + \epsilon_t \quad (4)$$

ARIMA 모형은 수식 (4)^[14]에 의해 계산된다. Y_t는 t주 예측값이고, α₁은 AR(1)모형의 계수, α₁^{*} SAR(1)모형의 계수, s는 주기, t는 예측할 주차 그리고 ε_t는 오차값을 의미한다.

```
Series: demand_diff1
ARIMA(1,0,0)(1,0,0)[53] with zero mean
Coefficients:
ar1      sar1
-0.5240  -0.1914
s.e.     0.0586  0.0870

sigma^2 estimated as 285721:  log likelihood=-1609.51
AIC=3225.02  AICC=3225.14  BIC=3235.05
```

그림 3. 분석된 최적 ARIMA 모형
Fig. 3. Demand Forecast through the ARIMA Model of 2018.

그림 3의 도출된 ARIMA모형 결과인 ar1 값 -0.5230은 α₁을 뜻하고, sar1 의 값 -0.1914는 α₁^{*}을, -0.1003은 α₁ × α₁^{*}을 그리고 s는 53을 의미한다^[15].

$$Y_t = -0.5240 Y_{t-1} - 0.1914 Y_{t-53} - 0.1003 Y_{t-52} + \epsilon_t \quad (5)$$

분석한 모형은 수식 (5)에 따라 계산할 수 있다. 그리고 Backward 연산자는 계절성을 나타내고 B*로 표시하며, 주기 s는 위첨자로 적용한다.

$$\begin{aligned} Y_t &= \alpha_1 Y_{t-1} + \alpha_1^* Y_{t-s} - \alpha_1 \alpha_1^* Y_{t-s-1} + \epsilon_t \\ &\Leftrightarrow (1 + \alpha_1 B + \alpha_1^* B^s - \alpha_1 \alpha_1^* B^{s+1}) Y_t = \epsilon_t \\ &\Leftrightarrow (1 - \alpha_1 B)(1 - \alpha_1^* B^s) Y_t = \epsilon_t \\ &\Leftrightarrow (1 + 0.524B)(1 + 0.1914B^{53}) Y_t = \epsilon_t \end{aligned} \quad (6)$$

수식 (6)에 따라 그림 4의 2018년의 수요량을 측정할 수 있다. 그림 4는 ARIMA 모형을 이용하여 2013~2016 4년

간 데이터를 분석하여 시계열 분해법을 통해 파악한 계절적요인과 추세 패턴을 기반으로 예측한 수요량을 시각화 하였다.

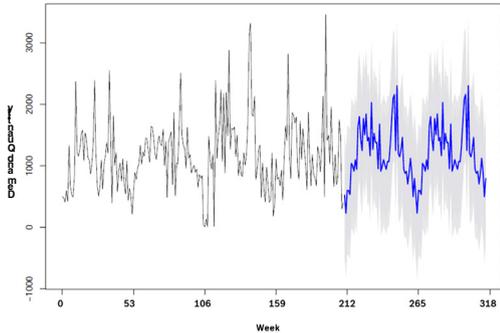


그림 4. ARIMA 모델을 통한 2018년 수요예측
 Fig. 4. Demand Forecast through the ARIMA Model of 2018.

D사는 연초 내부 회의에 의해 재고관리를 진행하기 때문에 요구사항인 2018년의 수요량 예측 값을 제시한다.

3. 예측한 수요 값에 따른 경제적 주문량 모형 개발

재주문점 계산은 수요 값에 따라 주문한 시점부터 주문이 도착한 주까지의 수요분포 값을 평균값으로 사용한다. 수식 (7)은 53주치(1년)에 대한 예측을 위해 주문한 주차부터 리드타임이 끝난 기간이 53주 이상인 경우를 나타낸다. 반면, 수식 (8)은 53주 이내인 경우에 대한 수식으로 수식 (7)과 (8) 두 가지로 나누어 분석하였다.

p 는 수요 값, $demand_i$ 는 i 주 수요평균 ($i=1,2 \dots 53$), $leadtime$ 은 리드타임, $week$ 는 주문한 주차이다.

$$-week + leadtime > 53 \text{ 일 때,}$$

$$p = \frac{\sum_{i=week}^{53} demand_i + \sum_{j=1}^{week+leadtime-53} demand_j}{leadtime} \quad (7)$$

$$-week + leadtime \leq 53 \text{ 일 때,}$$

$$p = \sum_{i=week}^{53} demand_i \div leadtime \quad (8)$$

위의 수식 (7),(8)을 활용하여 $week + leadtime$ 의 기준에 따라 재주문점 수식의 변화를 주었다. 수식 (9)는 ROP 재주문점, $leadtime_mean$ 은 리드타임에 대한 평균값, z

는 서비스 수준 그리고 $predict_dstd$ 은 수요에 따른 표준편차 분포를 의미한다.

$$ROP = p \times leadtime_mean + z \sqrt{leadtime_mean \times predict_dstd^2 + p^2 \times leadtime^2} \quad (9)$$

z 서비스 수준은 재고 부족 위험도에 따라 결정할 수 있다. 위험이 높을수록 서비스 수준은 낮아지며 반대로 위험이 낮으면 서비스 수준은 높아진다.

주차에 따른 $demand_i$ 수요평균 값보다 높은 수요 발생은 리드타임 간격을 짧게 하기 때문에 재고부족이 발생할 확률이 크다. 따라서, 최적 주문량을 도출할 필요가 있다.

$$order_input = leadtime_mean \times predict_demand \quad (10)$$

수식 (10)은 주문량을 계산하기 위한 수식이다. 수요값에 따라 리드타임 동안의 고객의 니즈에 대응하여 재고부족이 발생하는 위험을 방지하기 위해 미리 설정한 안전재고의 양에 따라 효율적인 주문량을 파악할 수 있다.

재고의 입·출입을 판단하기 위해 $stock$ 은 재고량을 뜻하는 변수로 설정하였다.

$$\text{입고 됐을 때는 } stock = stock + order_input$$

수요가 발생 했을 때는 $stock = stock - demand$ 로 재고량을 계산하였다. 수요의 랜덤값은 예측된 수요분포 데이터 상의 해당 주차의 수요값 $Demand_i$ ($i=1, 2, \dots, 53$)와 분포상의 해당 주차의 표준편차값 Std_i ($i=1, 2, \dots, 53$), 그리고 정규분포 랜덤 값을 rd 로 계산하였다. 해당 주차의 발생 수요는 D 를 의미하며 계산 수식은 (11)과 같다.

$$D = Demand_i + Std_i \times rd \quad (11)$$

리드타임의 랜덤값은 과거데이터 값을 주 별로 나눠 그 기간의 평균으로 계산하였다.

이와 같이 수요예측 기반 모델을 개발하였고 개발모델은 고객에 대한 서비스 수준은 높이고 재고비용은 낮출 수 있는 효과가 있었다. 이에 따른 정확한 평가를 위해 시뮬레이션을 수행하여 개발 모델의 효용성을 확인한

다. 따라서 현장에서 발생하는 예상치 못한 변수를 예측하여 주문시점부터 리드타임 동안에 발생하는 최적 주문량을 계산하여 재고관리에 있어 방향성을 나타내는 것이 필요하다. 이에 따라 경제적 주문량 모형 기반 수요 예측 모델을 개발한다.

IV. 경제적 주문량 모형 기반 수요예측 모델 효용성 평가

1. 시뮬레이션 구현

본 논문은 D사의 공급프로세스와 유사하게 설계한 알고리즘 통해 수요예측에 따른 최적의 재주문시점 및 주문량을 도출을 통해 시뮬레이션 한다. 효율적인 재고관리를 위해 경영자가 고려할 수 있는 상황을 가정하여 시뮬레이션을 수행하였다. 시뮬레이션 횟수 1000회, 시뮬레이션 1회당 1년치(53주), 수요/리드타임은 랜덤으로 발생, 리드타임동안 주문 요청 불가함, 서비스 수준 95%와

99%로 나누어 분석하였다. 그림 5와 같이 개발한 수요예측모델의 효용성을 평가하기 위한 시뮬레이션 알고리즘이다.

효율적인 재고관리를 위한 알고리즘을 통해 개발한 수요예측 모델은 재고부족 위험률을 예방을 위해 정량적 분석법인 시뮬레이션을 이용한다. 다음은 시뮬레이션에 대한 설명이다.

1년을 53주로 가정하고 ARIMA모형을 통해 예측한 수요값에 따른 랜덤값을 생성한다. 고객의 주문 요청이 들어오면 보유 재고량에서 요청한 양을 차감한다. 주문 여부에 따라 재주문점을 파악한다. 첫 주문 전에는 재주문점을 설정할 수 없기 때문에 0으로 초기값을 설정하고 랜덤으로 생성된 리드타임과 리드타임 동안의 수요분포의 평균값으로 재주문점을 계산한다. 보유 재고량이 재주문점 이하 이고 미주문상태 일 때 주문을 요청한다. 주문 요청 후 다음 주문의 리드타임동안의 수요량에 따라 재주문점을 다시 계산하기 위해 재주문점을 초기화해야 한다. 다음으로 최적주문량을 계산하고 주문을 요청한다. 설정된 리드타임이 지나고 나서 입고가 되면 주문여부 판단 변수를 0으로 초기화시키고 재고량에 입고량을 더하고 수요량은 차감한다. WEEK가 53주를 초과하면 시뮬레이션이 종료된다.

표 1은 시뮬레이션 전역변수로 변수명과 그 기능 그리고 초기값에 대해 설정을 정리하였다.

표 1. 시뮬레이션 전역변수 설정

Table 1. Setting simulation variables

| 변수명 | 기능 | 초기값 |
|---------------------|-----------------|----------------------|
| service | 서비스수준 (95%,99%) | 95 or 99 |
| N1 | 시뮬레이션 횟수 | 1000 |
| N | 53주 | 53 |
| demand_distribution | 수요 분포 | 원본데이터 |
| demand_std | 수요 표준편차 분포 | 원본데이터 |
| leadtime_mean | 리드타임 평균 | 14 |
| leadtime_std | 리드타임 표준편차 | 2 |
| M_short | 연간 재고부족 횟수 저장행렬 | 1×N1 영행렬 |
| M_shorttime | 연간 재고부족 기간 저장행렬 | 1×N1 영행렬 |
| M_order count | 주문량 평균 저장행렬 | 1×N1 영행렬 |
| z | 서비스 수준 배수 | norminv(service/100) |

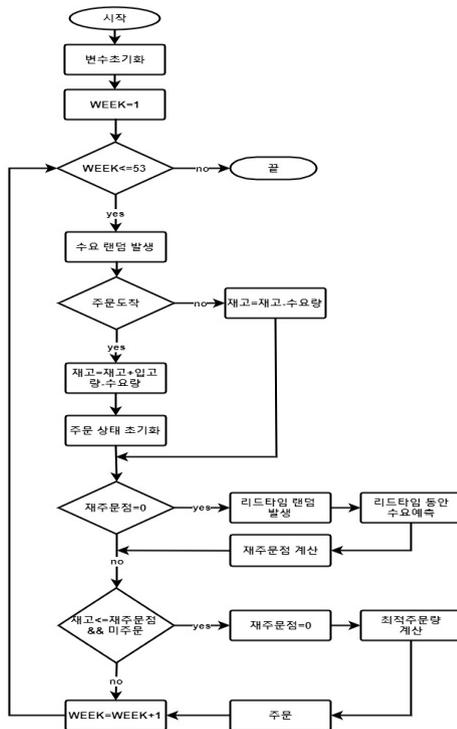


그림 5. 수요예측기반 모델 평가를 위한 재고관리 알고리즘
Fig. 5. Inventory Management Algorithm for Demand Forecasting Based Model Evaluation

D사의 경영자 요청에 의하여 서비스만족도 수준을 95%와 99%로 두 가지로 설정하였다. 그리고 서비스 수준 변화량에 따른 시뮬레이션의 결과에 대한 차이를 비교 분석한다. D사의 실제 수집한 원료 데이터를 ARIMA 모형을 통해 도출한 수요예측 데이터 값을 demand_distribution 수요 분포에 평균값으로 저장한다. demand_std는 수요 평균값의 표준편차의 값과 정규분포의 랜덤값이 생성하도록 설정하였다. 원본 데이터의 리드타임 기간을 분석한 결과 평균은 14주 표준편차는 2주로 확인되어 이를 초기값으로 설정하였다. 시뮬레이션을 통해 수요예측에 따른 미래 수요 값을 얻기 위해 53주 간의 재고부족 횟수, 재고부족 기간 그리고 주문량 평균값을 도출하도록 변수를 설정하였다.

표 2. 시뮬레이션 초기화 값 설정
 Table 2. Setting simulation initialization values

| 변수명 | 기능 | 초기화값 |
|-------------|---------------|----------|
| week | 해당 주 | 1 |
| week_arr | 입고 주 | 0 |
| order_input | 입고량 | 상관없음 |
| order_count | 주문 횟수 | 0 |
| stock | 재고량 | 22000 |
| short | 재고부족횟수 | 0 |
| short_time | 재고부족기간 | 0 |
| bet_short | 현재 재고부족 여부 판단 | 0 |
| bet_order | 현재 주문 여부 판단 | 1 |
| M_demand | 수요 저장 행렬 | 1× N 영행렬 |
| M_stock | 재고 저장 행렬 | 1× N 영행렬 |
| M_leadtime | 리드타임 저장 행렬 | 1× N 영행렬 |
| M_orderin | 최적 주문량 저장 행렬 | 1× N 영행렬 |
| M_weekarr | 주문 도착주 저장 행렬 | 1× N 영행렬 |
| M_weekorder | 주문 한 주 판단 행렬 | 1× N 영행렬 |

표 2는 시뮬레이션 수행 회당 변수와 그 기능 그리고 초기 값을 설정한 결과를 나타낸다. 초기 재고량은 1000번의 시뮬레이션 한 결과 평균 22,000(25Kg/포)으로 가정했을 때, 예측한 수요량을 대응하기가 가장 적합한 양의 결과이다. 이는 재고 부족 기간 동안의 고객의 니즈를 적절히 대응하기 위해 미리 높은 수준의 재고량을 확보를 의미한다.

설정된 변수인 service로 수요에 대한 서비스 수준을 조정할 수 있다. 이는 고객의 니즈를 만족시킴을 의미하며 경영자가 선택할 수 있다. 시뮬레이션에서는 95%, 99%

% 두 가지에 따른 결과와 그에 따른 효과의 차이를 확인하기 위해 나누어서 진행하였다.

```
demand_distribution=[550.75,571.75501,929.5,...];
% demand_distribution 수요분포 행렬
demand_std=[390.806457900000,293.820842500000,325.9593533000
00,348.643442500000,...];
% demand_std 표준편차 행렬
```

demand_distribution은 ARIMA 모형으로 예측된 수요값에 대한 수요분포 데이터 행렬이다. 또한, demand_std는 수요 평균에 대한 표준편차의 데이터의 행렬이다. 1년간의 적절한 수요 값을 파악하기 위해 1년을 53주로 정하여 시뮬레이션을 진행하였다. 과거의 수요값을 기반으로 고객의 니즈를 대응하기 위해 향후 미래 수요를 미리 예측으로 1년간 수요값을 랜덤으로 생성하였다.

```
demand=demand_distribution(1,week)+demand_std(1,week)*rand
n(1,1); % 해당 주차의 수요 랜덤값
```

demand는 해당 주차의 랜덤 수요값으로 정의하였다. 실제 공정과 유사하게 설정하기 위해 수요분포의 해당 주차의 수요 값과 표준편차의 정규분포로 난수생성을 구성하였다.

```
leadtime=round(leadtime_mean+leadtime_std*randn(1,1))
% 해당 주 리드타임 랜덤값 (주는 자연수로 계산해야 하기 때문에
반올림 처리)
```

leadtime은 해당 주차의 랜덤 리드타임 값이다. 리드타임은 데이터의 양이 많지 않아서, 전체데이터의 평균값과 표준편차의 정규분포 랜덤생성으로 구성하고 주치는 자연수 값이기 때문에, 반올림(round())처리 하였다.

2. 서비스 수준 95%와 99%에 따른 시뮬레이션 결과

경영자의 선택에 따른 서비스수준을 다르게 설정하면서 이에 대한 시뮬레이션 시각화 결과를 서비스수준 95%와 99%로 비교한다.

표 3은 서비스 수준이 95%일 때의 시뮬레이션 결과에 따른 재고부족 횟수, 재고부족 기간 그리고 주문횟수를 기본 경제적 주문량 모형으로 계산한 결과와 개발한 수요 예측 기반의 경제적 주문량 모형으로 계산한 결과 값을 나타낸다.

표 3. 서비스수준 95%일 때 시뮬레이션 결과
Table 3. The simulation result value when the service level is 95%.

| 경제적 주문량 모형 | | | | | |
|-------------|-------|-------|-------|-------|-------|
| 회 차 | 1 | 2 | 3 | 4 | 5 |
| 재고 부족 횟수(회) | 1.905 | 1.951 | 1.928 | 1.925 | 1.943 |
| 재고 부족기간(주) | 9.78 | 9.886 | 9.79 | 9.938 | 9.783 |
| 주문횟수(회) | 4.046 | 4.053 | 4.032 | 4.032 | 4.039 |

| 수요 예측 기반 경제적 주문량 모형 | | | | | |
|---------------------|-------|-------|-------|-------|-------|
| 회 차 | 1 | 2 | 3 | 4 | 5 |
| 재고 부족 횟수(회) | 0.635 | 0.69 | 0.672 | 0.695 | 0.683 |
| 재고 부족 기간(주) | 1.743 | 1.94 | 1.906 | 1.907 | 1.962 |
| 주문횟수(회) | 3.972 | 3.961 | 3.965 | 3.963 | 3.96 |

재고 부족 횟수는 재고량이 0으로 떨어질 때를 측정한다. 재고부족 기간은 보유재고량이 0 이하로 감소하고 새로 주문한 원료가 도착하여 다시 0 이상으로 증가할 때까지를 의미한다.

95%의 고객 대응에 따른 서비스 수준은 리드타임 기간 동안의 발생하는 수요량은 공급량을 초과하지 않을 확률이 95%임을 나타낸다. 고객 대응에 따른 서비스 수준을 95%로 선택한 경우 재고부족 위험은 5%를 의미한다.

현장에서 리드타임 기간이 일정하지 않으므로 주 단위로 세분화 하여 재고 부족기간과 이에 따른 최적 주문량을 분석함으로써 입고시기를 예측할 수 있다. 이를 통해 서비스수준 95%일 때 시뮬레이션 결과를 그림 6과 같이 시각화하여 표현하였다.

서비스 수준이 95%일 때, 기존 경제적 주문량 모형(Base)은 재고부족 횟수가 약 10회이고 재고 부족 기간은 2주로 높게 발생한 반면, 개발한 수요예측 기반 모델은(Predict) 재고부족 횟수가 약 2회이고 재고 부족기간은 1회로 높은 절감효과를 확인 할 수 있다.

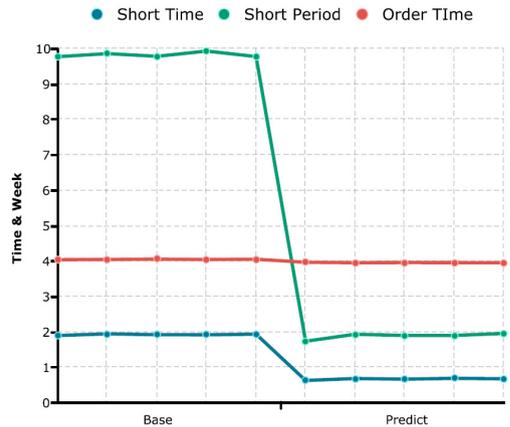


그림 6. 서비스 수준이 95%일 때 시뮬레이션 결과
Fig. 6. Simulation results when the service level is 95%.

표 4는 서비스 수준이 99%일 때의 시뮬레이션 결과에 따른 재고부족 횟수, 재고 부족 기간 그리고 주문횟수를 기본 경제적 주문량 모형을 적용하였을 때 결과와 개발한 수요 예측 기반의 경제적 주문량 모형을 적용하였을 때 도출한 결과이다.

표 4. 서비스수준 99%일 때 시뮬레이션 결과 값
Table 4. The simulation result value when the service level is 99%.

| 경제적 주문량 모형 | | | | | |
|-------------|-------|-------|-------|-------|-------|
| 회 차 | 1 | 2 | 3 | 4 | 5 |
| 재고 부족 횟수(회) | 1.673 | 1.707 | 1.729 | 1.655 | 1.666 |
| 재고 부족기간(주) | 7.991 | 8.201 | 8.028 | 7.999 | 8.132 |
| 주문횟수(회) | 4.102 | 4.087 | 4.033 | 4.101 | 4.102 |

| 수요 데이터 기반 최적주문량 | | | | | |
|-----------------|-------|-------|-------|-------|-------|
| 회 차 | 1 | 2 | 3 | 4 | 5 |
| 재고 부족 횟수(회) | 0.496 | 0.513 | 0.513 | 0.491 | 0.524 |
| 재고 부족기간(주) | 1.404 | 1.547 | 1.411 | 1.375 | 1.404 |
| 주문횟수(회) | 3.994 | 3.993 | 4 | 3.995 | 3.997 |

99%의 고객 대응에 따른 서비스 수준은 리드타임 기간 동안의 발생하는 수요량은 공급량을 초과하지 않을 확률이 99%임을 나타낸다. 고객 대응에 따른 서비스 수준을 99%로 선택한 경우 재고부족 위험은 1%를 의미한다. 그림7은 표 4의 서비스 수준이 99%일 때의 결과를 시각화하였다



그림 7. 서비스 수준이 99%일 때 시뮬레이션 결과
 Fig. 7. Simulation results when the service level is 99

서비스 수준이 99%일 때, 기존 경제적 주문량 모형 (Base)은 재고부족 횟수가 약 8회, 재고 부족 기간은 2 주로 높게 발생한 반면, 개발한 수요예측 기반 모델은 (Predict) 약 2회, 1회로 높은 절감효과를 확인 할 수 있다.

그림 8은 서비스 수준이 95%일 때와 99%일 때의 결과에 따라 재고 부족 횟수와 재고 부족 기간에 따른 값을 합산 한 후, 평균 값 후로 변환하여 그래프로 시각화 한다.

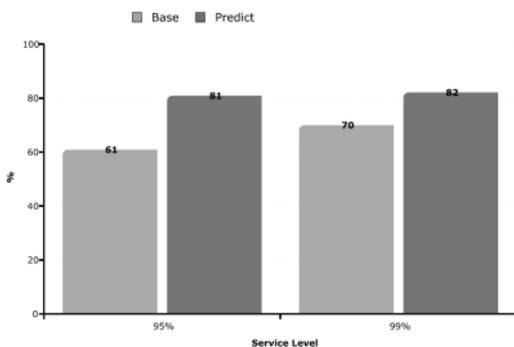


그림 8. 95% 99% 서비스 수준에 따른 결과 비교
 Fig. 8. 95% 99% Comparison of results according to service level

분석 결과, 시뮬레이션을 통해 기존 경제적 이론 최적 주문량과 수요 예측 기반 주문량으로 비교해 봤을 때, 기존 모델은 65% 절감했지만, 예측 모델은 81%의 절감 효과를 있다. 따라서, 예측 모델은 기존 대비 16% 더 높은 효율이 있음을 확인할 수 있다.

최종적으로 볼 때, 전체적으로 출고량 및 출고 시기는 일정한 반면, 입고량 및 입고 시기가 불안정하여 재고 부족 또는 안전재고 부족 등의 문제가 발생하였다. 이에 시계열 분해법을 통해 계절적 수요 패턴을 확인하였고 ARIMA 모형을 통해 신뢰성 있는 수준의 미래 수요량을 예측하였다. 예측한 수요값을 랜덤 값으로 생성하여 시뮬레이션에 적용하였다. 그 결과 경영자가 선택하는 고객 만족 서비스 95%와 99% 수준에 따라 낮아진 재고부족횟수를 시각화하여 표현함으로써 경영자는 예상 재주문점과 최적 주문량을 기반으로 효율적인 재고관리가 가능하고 이에 따른 비용절감을 예상한다.

V. 결론

본 논문에서는 다품종소량생체계의 중소기업 D사를 대상으로 다양한 재고를 효율적으로 관리할 수 있는 경제적 주문량 모형을 활용하여, 고객의 다양한 니즈를 만족하기 위한 수요예측을 제안하였다. 시계열 분해법을 통해 D사의 데이터를 분해하여 계절적 수요패턴을 확인하였고, ARIMA모형을 통해 2018년의 수요량을 예측하였다. 정확한 수요예측과 개발한 수요예측 모델의 효용성을 평가하기 위해 시뮬레이션을 수행하였다. 경영자 판단의 시점에서 시뮬레이션 결과를 시각화하여 표현함으로써 일정 시점에서 예상 재주문 시기를 기반으로 재고부족에 대한 위험을 판단하였다. 이를 통해 기존 경제적 주문량 모형의 비헤 개발한 수요예측 모델이 종합적으로 16% 절감 효과를 확인하였다. 또한 다품종 소량 생산 체계의 중소기업에서 다품종 간의 연관성으로 인하여 재주문점 및 서비스 수준을 설정함에 있어 예측하기 어려운 점을 시뮬레이션을 통하여 극복할 수 있을 것으로 사료된다. 향후에는 개발모델의 실제 활용을 위해 D사의 재고 공급 프로세스에 적용할 예정이다.

기존의 재고관리 시스템 또는 경제적 주문량 모형에 비하여 보다 중소기업의 현실 상황을 잘 반영하고 니즈에 부합하는 결과를 제시할 수 있을 것으로 예상된다.

향후 연구방안으로는 개발한 수요예측 모델을 통해 실시간 재고의 입·출입 데이터에 따른 최적 주문량, 리드타임 주기 그리고 안전재고를 확인할 수 있는 모니터링 시스템을 개발할 예정이다. 이는 중소기업의 스마트 팩토리를 적용한 것으로 제품 생산이 다품종소량생산에

서 고객 니즈에 따른 유연생산체제로 변화 될 것으로
사료된다.

References

- [1] J. Gubbi, 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.
DOI: <https://doi.org/10.1016/j.future.2013.01.010>
- [2] Sang-bong Park, Jeong-hwa Heo, "Implementation and design of fuse controller using single wire serial communication", *The Journal of the Institute of Internet, Broadcasting and Communication*, Vol.15, No.6, pp.251-255, 2015.
DOI: <https://dx.doi.org/10.7236/JIIBC.2015.15.6.251>
- [3] Harris F.W, "How Many Parts to Make at Once", *International Journal of Production Economics*, Vol 155, pp. 8-11, 2014.
DOI: <https://dx.doi.org/10.1016/j.ijpe.2014.07.003>
- [4] Jiali Zhu, Toshiya Kaihara, Nobutada Fujii, Daisuke Kokuryo, and Swee Skuik, "Extended EOQ Model Considering Recycling, Repair and Reuse in Reverse Supply Chain with Two Types of Demand Fluctuation", *International Symposium on Flexible Automation*, August, 2016.
DOI: <https://dx.doi.org/10.1109/ISFA.2016.7790152>
- [5] Zhou Cheng, Leng Kaijun and Shi Wen, "An Improved EOQ Model for Fresh Agricultural Product Considering Fresh-degree Sensitive Demand and Carbon Emission", *Advance Journal of Food Science and Technology*, Vol. 11, No. 4, pp. 350-355, 2016.
DOI: <https://dx.doi.org/10.19026/ajfst.11.2422>
- [6] Shirajul Islam Ukil, Md. Sharif Uddin, "A Production Inventory Model of Constant Production Rate and Demand of Level Dependent Linear Trend", *American Journal of Operations Research*, Vol. 6, No. 1, pp. 61-70, 2016.
DOI: <http://dx.doi.org/10.4236/ajor.2016.61008>
- [7] Box, GEP, Jenkins, GM and Reinsel, "Time Series Analysis: Forecasting and Control", 4th Edition, Wiley, Oxford, 2008.
DOI: <http://doi.org/10.1002/9781118619193>
- [8] Mi-Rye Kim, In-Ho Cho, "Analysis of Operation Cost Savings Effects of Direct Delivery Logistics Strategy Considering Carbon Emission", *Journal of the Korea Academia-Industrial cooperation Society*, Vol. 18, No. 6 pp. 653-661, 2017.
DOI: <https://dx.doi.org/10.5762/KAIS.2017.18.6.653>
- [9] Sang-Rok Yoo, YoungSoo Park, Jung-Sik Jeong, Chu-ISeong Kim, and Jae-Yong Jeong, "A Forecast Method of Marine Traffic Volume through Time Series Analysis", *Journal of the Korean Society of Marine Environment & Safety*, Vol. 19, No. 6, pp. 612-620, 2013.
DOI: <http://dx.doi.org/10.7837/kosomes.2013.19.6.612>
- [10] Jin-Ho Jeon, Min-Soo Kim, "A Study on Prediction the Movement Pattern of Time Series Data using Information Criterion and Effective Data Length", *The Journal of The Institute of Internet, Broadcasting and Communication*, Vol. 13, No. 1, pp. 101-107, 2013.
DOI: <https://dx.doi.org/10.7236/JIIBC.2013.13.1.101>
- [11] Mohammad Sabar Jamil, Saiful Akbar, "Taxi Passenger Hotspot Prediction using Automatic ARIMA Model", *3rd International Conference on Science in Information Technology (ICSITech)*, October, 2017
DOI: <http://dx.doi.org/10.1109/ICSITech.2017.8257080>
- [12] Tara Ahmed Chawsheen, Mark Broom, "Seasonal time-series modeling and forecasting of monthly mean temperature for decision making in the Kurdistan Region of Iraq", *Journal of Statistical Theory and Practice*, Vol. 11, No. 4, pp. 604-633, 2017.
DOI: <https://doi.org/10.1080/15598608.2017.1292484>
- [13] Rana Sabeeh Abbood Alsudan, Jicheng Liu1, "The Use of Some of the Information Criterion in Determining the Best Model for Forecasting of Thalassemia Cases Depending on Iraqi Patient

Data Using ARIMA Model”, Journal of Applied Mathematics and Physics, Vol.5, No.3, pp.667-679, 2017.

DOI: <https://dx.doi.org/10.4236/jamp.2017.53056>

[14] Makridakis, S, Wheelwright, S.C, and Hyndman, R.J, “Forecasting: Methods and Applications”, 3rd Edition, John Wiley & Sons, New York. 1998.

[15] Woo-Kyun Gam, Dong-li Lee, “A Study of Forward Buying and Transfer Effect with Intervention ARIMA Model”, Journal of Channel and Retailing, Vol. 22, No. 4, pp.1-22, 2017.

DOI: <https://dx.doi.org/10.17657/jcr.2017.10.31.1>

저자 소개

김 정 아(준회원)



- 2017.3 ~ : 성균관대학교 스마트팩토리융합학과 석사과정 재학중
- 2017.9 ~ : (주)마크에이트 연구소 연구원

<주관심분야 : 스마트팩토리, IT융합, 스마트 헬스케어, 사이버물리시스템, 사물인터넷, 웨어러블 컴퓨팅, 인공지능, 첨단 로봇 등>

정 종 필(정회원)



- 2008년 ~ 2009년 : 성균관대학교 컨버전스연구소 연구교수
- 2015년 ~ 현재 : 전자부품연구원 IoT융합연구센터 전문연구위원
- 2010년 ~ 현재 : 성균관대학교 정보통신대학 겸 산학협력단 교수
- 2016년 ~ 현재 : 성균관대학교 스마트팩토리융합학과 사업총괄책임자

<주관심분야 : 스마트팩토리, 모바일융합컴퓨팅, 센서 네트워크, 차량 모바일 네트워크, 네트워크 보안, IT융합, 인터랙션 사이언스, 스마트 헬스케어, IoT/M2M, 웨어러블 컴퓨팅 등>

이 태 현(정회원)



- 1994.3 ~ 1999.9 : 대우전자 ME 연구소 주임 연구원
 - 2009.3 ~ 2011.3 : KMS(주) 대표이사 (코스닥)
 - 2013.3 ~ 2015.2 : 성균관대학교 대학원 전자전기컴퓨터공학과 박사수료
 - 2015.3 ~ 2015.8 : 성균관대학교 대학원 휴먼ICT융합학과 산학협력 중점 교수
 - 2015.9 ~ 현재 : 성균관대학교 대학원 휴먼ICT융합학과 겸임 교수
- <주관심분야 : 스마트팩토리, 스마트헬스케어, IoT/M2M, IT융합, 모바일네트워크, 웨어러블 컴퓨팅, 모바일 진단 및 치료기기, 스마트병원 등>

배 상 민(정회원)



- 1997년 ~ 2015년 : 삼성전자 통신연구소/무선사업부 연구원 및 연구위원
 - 2016년 ~ 2018년 : 성균관대학교 정보통신대학 산학협력교수
 - 2018년 ~ 현재 : (주)마크에이트 IoT연구소장
 - 2018 ~ 현재 : 성균관대학교 정보통신대학 초빙교수
- <주관심분야 : 스마트팩토리, IoT, 모바일융합컴퓨팅, 스마트 헬스케어, 이동통신기술 등 >

※ This research was supported by Basic Science Research Program through the National Research Foundation of Korea (NRF) funded by the Ministry of Education (NRF-2016 R1D1A1B03933828). Corresponding author: Prof. Jongpil Jeong.