

부품 수명주기를 고려한 서비스 부품의 수요예측에 관한 연구

권익현*

*인제대학교 산업경영공학과

A study on service parts demand forecasting considering parts life cycle

Ick-Hyun Kwon*

*Department of Industrial and Management Engineering, Inje University

Abstract

This research studies on the demand forecasting for service parts considering parts life cycle, that gets relatively less attentions in the field of forecasting. Our goal is to develop forecasting method robust across many situations, not necessarily optimal for a limited number of specific situations. For this purpose, we first extensively analyze the drawbacks of the existing forecasting methods, then we propose the new demand forecasting method by using these findings and reinforcement leaning technique. Using simulation experiments, we proved that the proposed forecasting method is better than the existing methods under various experimental environments.

Keywords : Demand forecasting, Service part, Life cycle, Inventory obsolescence, Reinforcement learning

1. 서론

서비스 부품(service parts)은 자동차, 항공, 중공업, 가전제품, 정보통신, 정보기술, 첨단기술(high-tech), MRO(maintenance, repair, operations), 군수물자 및 국방 무기(조선, 항공기 등) 시스템, 고가의 자본재(capital goods) 등을 포함하는 다양한 산업에서 활용되고 있으며, 전 세계적으로 약 2조 달러 규모의 이상의 시장을 형성하고 있다. AMR Research의 조사결과 2001년 기준 미국에서 발생한 서비스 부품과 관련된 비용은 약 7,000억 달러 가량이며, 이는 미국 GDP의 약 8%에 해당하는 큰 규모이다. 또한 미국 항공산업의

경우 연간 100억 달러 이상을 서비스 부품과 관련된 비용으로 지출하고 있다.

서비스 부품의 재고는 최종 소비자를 위한 판매후 서비스(after-sales service)와 제조업체 설비의 유지 보수 및 이들에 대한 목표 서비스 수준 준수를 위해 공급망 상의 적절한 위치에서 관리되어야 한다. 그러나 아래의 예를 포함하는 다양한 원인으로 인하여 서비스 부품을 관리하는 것은 매우 복잡하고 어려운 과제로 인식되고 있다.

† This work was supported by the Ministry of Education of the Republic of Korea and the National Research Foundation of Korea (NRF-2015S1A5A8015259)

† Corresponding Author : Ick-Hyun Kwon, Department of Industrial and Management Engineering, Inje University, 197 Inje-Ro, Gimhae-Si, Gyeongsangnam-Do, 621-749, E-mail: ikwon@inje.ac.kr

- 제품의 복잡성 증대로 인한 많은 종류의 서비스 부품 필요
- 간헐적(intermittent), 불규칙적(erratic)이며 변화가 심한(lumpy) 수요 패턴
- 서비스 부품의 부족으로 인한 고객 불만을 방지하기 위해 매우 높은 서비스 수준 요구사항의 충족
- 제품 수명주기 단축으로 인한 진부화(obsolescence) 위험성

이 가운데 특히 간헐적 수요 패턴은 서비스 부품의 일반적인 특성이라 할 수 있다. 간헐적 수요(intermittent demand)란 수요가 매 단위기간마다 발생하지 않고 산발적으로 생성되는 수요를 말하며, 간헐적 수요가 발생했을 경우 수요의 크기 또한 단일 사이즈 또는 일정한 값을 갖는 것이 아니기 때문에 수요 예측에 많은 어려움이 발생하게 된다(Silver et al., 1998). 즉 간헐적 수요의 경우 수요의 크기(demand size) 뿐만 아니라 수요의 발생간격(inter-demand interval) 또한 함께 예측하여야 하는 특성으로 인해 간헐적 수요의 예측에는 많은 어려움이 따르는 실정이다.

Knecht et al.(1993)의 연구에 따르면 서비스 부품의 판매후 서비스를 통해 창출되는 수익이 기업 전체 수익의 약 10~20%를 차지하고 있으며, 이 비중은 점차 증가할 것으로 예측하였다. 또한 서비스 부품에 대한 효율적인 판매후 서비스를 제공하는 것은 기업의 전략적 측면에서도 많은 기여를 하게 된다. 일반적으로 고객은 다른 분야와 비교하여 서비스 부품의 가격에는 상대적으로 덜 민감한 반응을 보이는 경향을 나타낸다. 이는 해당 서비스 부품의 부재로 인한 생산 또는 서비스의 차질로 발생하는 손해가 서비스 부품의 가격에 비해 상대적으로 매우 크기 때문이다. 따라서 효율적인 서비스 부품의 관리정책은 고객의 만족도와 충성도를 향상시킬 수 있으며 이를 통해 기업의 매출과 신뢰도를 향상시키는 효과를 낼 수 있을 것이다.

앞서 살펴본바와 같이 서비스 부품의 종류는 매우 다양하며 산업계에서 차지하는 비중 또한 매우 크다는 것을 알 수 있으며, 서비스 부품에 대한 수요예측을 통해 얻을 수 있는 이익(예: 재고비용 감소 및 고객 서비스 수준 증가 등) 역시 매우 클 것으로 예상된다. Boone et al.(2008)은 Delphi 연구기법을 통해 서비스 부품 관리자에 대한 설문조사 결과 서비스 부품의 수요예측이 서비스 부품 관리에 있어서 가장 중요한 핵심 요소라는 결과를 도출하였다. 따라서 서비스 부품에 대한 수요예측 방법에 관한 연구는 이론적인 측면 뿐만 아니라 실제적인 측면에서 매우 가치 있는 분야

라고 할 수 있다.

최근 산업계에서는 판매후 서비스(after-sales service) 및 서비스 부품에 대한 수요예측의 중요성을 인식하고 서비스 부품의 관리에 많은 투자를 하는 기업이 늘어나고 있다. 이러한 추세로 인하여 Aberdeen Research의 조사결과 2005년 기준으로 서비스 부품 관리를 위해 사용되는 소프트웨어 시장의 규모가 약 1억 달러 정도에 이를 것으로 예측한 바 있으며 이 규모는 앞으로 계속 증가할 것이다.

그럼에도 불구하고 아직까지 대부분의 기업에서는 서비스 부품의 특성을 충분히 인식하지 못하고 완제품 재고나 제품생산에 사용되는 부품들과 유사한 방식으로 수요예측 및 재고관리를 수행하고 있는 실정이다. 일반적으로 실제 현장에서 서비스 부품에 대한 수요예측을 위해 single exponential smoothing(SES)이나 simple moving average(SMA) 등을 주로 사용하고 있다. 그러나 이러한 일반적인 예측기법들은 서비스 부품의 일반적 특성인 간헐적 형태의 수요를 효과적으로 반영하지 못하는 단점으로 인해 정확한 수요예측에 한계가 있다.

Croston(1972)은 비록 single exponential smoothing이 일반적으로 널리 사용되는 수요예측 방법이지만 single exponential smoothing이 간헐적 수요에 대한 수요예측에 사용될 경우의 문제점을 처음으로 지적한바 있다. Single exponential smoothing은 그 특성상 가장 최근의 수요에 가장 큰 가중치를 부여하기 때문에 실제로 수요가 발생한 기간에 대한 예측값이 가장 작으며, 수요가 발생한 바로 다음 기간에 대한 예측값이 가장 큰 값을 갖게 된다.

Croston(1972)은 이러한 single exponential smoothing의 단점을 극복하고 간헐적 수요의 특성을 반영할 수 있는 새로운 수요예측 기법을 제안하였다. 그는 기본적으로 수요는 Bernoulli process에 따라 발생하는 것으로 가정하였으며, 수요예측을 '0이 아닌 수요의 예측값(z_t)' 과 '수요발생 간격의 예측값(p_t)' 인 두 가지 부분으로 분리하고 각각의 값을 single exponential smoothing을 사용하여 예측하였다. t 기간의 실제수요를 y_t , 가장 최근에 0이 아닌 수요가 발생한 이후 현시점까지의 시간간격을 q , simple exponential smoothing에서 사용되는 smoothing parameter를 α 라고 할 경우 Croston의 예측방법은 다음과 같은 절차로 진행된다.

```

If  $y_t = 0$  then

     $z_t = z_{t-1}, p_t = p_{t-1}, q = q + 1$ 

Else

     $z_t = \alpha y_t + (1 - \alpha) z_{t-1},$ 
     $p_t = \alpha q + (1 - \alpha) p_{t-1}, q = 1$ 
    
```

[Figure 1] Procedure for Croston's forecasting

t기간의 예측수요 \hat{y}_t 은 0이 아닌 수요의 예측값(z_t)과 수요발생 간격의 예측값(p_t)을 결합한 $\hat{y}_t = z_t / p_t$ 의 형태로 계산되며, 이 값은 0이 아닌 수요가 발생했을 경우에만 갱신된다. 특히, 수요가 매기간마다 발생하는 경우 Croston의 예측방법은 일반적인 SES(single exponential smoothing)과 동일한 결과를 보이게 된다.

Syntetos and Boylan(2001)은 Croston의 예측방법으로 계산되는 \hat{y}_t 는 Croston의 주장과 달리 실제 수요보다 적게 평가(underestimation)되는 경향을 보이며, 이러한 이유로 인하여 positive biased된 예측결과를 나타낸다는 사실을 수학적 분석을 통해 증명하였다. 후속 연구로써 Syntetos and Boylan(2005)은 이러한 Croston의 예측방법의 문제점을 개선하는 아래 수식 (1)과 같은 방법을 제안하였으며, 이 수식은 근사적으로 unbiased한 예측결과를 보임을 수학적 증명과 시뮬레이션을 통해 입증하였다.

$$\hat{y}_t = (1 - \alpha/2) \cdot (z_t / p_t) \quad (1)$$

한편 일반적으로 제품(product)의 수명주기와 해당 제품이 필요로 하는 서비스 부품의 수명주기는 밀접한 관계를 갖게 된다. 제품의 수명주기는 Bass 확산 모델(diffusion model) (Bass, 1969)을 통해 묘사가능하며 일반적으로 도입기, 성숙기, 쇠퇴기 등으로 구분되어진다. 마찬가지로 서비스 부품의 수요 역시 특정한 시차간격(time lag)을 두며 제품의 수명주기에 상응하여 변하게 된다.

최근 들어 기업간 경쟁의 심화, 기술혁신, 소비자 구매행동의 변화 등으로 인하여 제품의 수명주기는 점차 짧아지는 경향을 나타내고 있으며 이로 인하여 서비스 부품의 수명주기 역시 점차 짧아지는 추세를 나타낸다. 이러한 이유로 인하여 많은 서비스 부품이 진부화되어 상당기간 동안 수요가 발생하지 않은 사례가 증가하고 있다. 한 석유화학회사의 사례에 따르면 서비스 부품의

약 54% 정도가 최근 5년 내에 수요가 전혀 발생하지 않았으며(Molenaers et al., 2010), Syntetos et al.(2009)은 그들의 논문을 통해 일본계 가전제품 제조회사의 경우 10년 이상 수요가 전혀 발생하지 않은 서비스 부품이 존재하는 사례를 소개한 바 있다.

따라서 서비스 부품의 진부화로 인한 수요 감소 또는 수요발생 중단에 대응하기 위한 방안이 필요하지만 서비스 부품의 진부화를 고려한 수요예측 방법에 대한 연구는 많지 않은 실정이다. 최근 이러한 문제를 해결하기 위해 Teunter, Syntetos and Babai(Teunter et al., 2011)에 의해 TSB라는 방법이 제안되었으나 개선해야 할 부분이 많이 존재하고 있다. 서비스 부품에 대한 수요예측 방법이 실제적으로 적용되기 위해서는 부품 진부화를 포함하는 부품 수명주기를 고려할 수 있는 수요예측 방법에 대한 연구가 절실히 필요하리라 판단된다.

서비스 부품 관리의 중요성은 다양한 산업분야에 걸쳐 지속적으로 증가하는 추세를 보이고 있으며 이에 상응하여 서비스 부품 관리에 대한 학계와 산업계의 연구 또한 꾸준히 증가하고 있다(Altay and Litteral, 2011). 특히 Syntetos and Boylan(2001)의 연구 이래로 서비스 부품에 대한 수요예측을 다루는 연구는 폭발적으로 증가하고 있다. 한 예로 가장 대표적인 서비스 부품의 수요예측에 관한 논문으로 평가받고 있는 Croston(1972)의 연구는 2008년 기준으로 최근 4년간 30회 이상의 피인용 횟수를 기록하고 있다.

이러한 서비스 부품의 수요예측에 대한 활발한 연구에도 불구하고 여전히 가장 우수하면서 실제적으로 적용 가능한 예측방법으로 평가받을 만한 연구결과가 도출되지 못하고 있으며, 이로 인해 새로운 수요예측 결과를 실제 산업계에 적용하여 큰 효과를 도출한 사례 또한 거의 드문 실정이다. 특히 최근 들어 기업간 경쟁의 심화, 기술혁신, 소비자 구매행동의 변화 등으로 인하여 제품의 수명주기는 점차 짧아지는 경향을 나타내고 있으며 이로 인하여 서비스 부품의 수명주기 역시 점차 짧아지는 추세를 나타내고 있으나, 서비스 부품의 수명주기를 고려하는 수요예측에 대한 연구는 거의 존재하지 않고 있다.

2. 본론

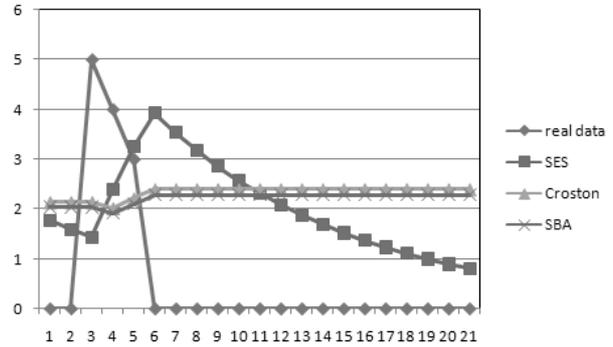
본 논문에서는 그동안 서비스 부품의 수요예측에서 간과되어 왔던 분야인 서비스 부품의 진부화로 인한 수요 감소 또는 수요발생 중단에 대응하기 위한 서비스 부품의 수명주기를 고려한 수요예측 방법에 대한

연구를 다루고자 한다. 최근 이러한 문제를 해결하기 위해 Teunter, Syntetos and Babai에 의해 TSB라는 방법이 제안되었고, 기존의 예측방법에 비해 우수함을 보이고 있다. 그러나 이 또한 robust한 결과를 도출하지 못할 뿐만 아니라 사용되는 모수(parameter)에 따라 예측성능의 편차가 매우 심한 단점을 보이고 있다. 본 연구에서는 제품 수명주기에 의해 발생하는 non-stationarity를 해결하기 위해 기존 TSB의 단점을 보완할 수 있는 강화학습(reinforcement learning) 기반의 적응형 수요예측 방법을 제안하고자 한다. 강화학습은 최근 불안정한 수요하의 공급망 환경에서 전체 최적화를 위한 새로운 접근방법으로 주목받고 있으며 다양한 비교 실험을 통해 우수성이 검증된 바 있기 때문에 본 연구가 제안하는 접근방법의 타당성을 더해주고 있다.

2.1 접근방법

서비스 부품의 진부화로 인하여 오랜 기간 또는 더 이상 수요가 발생하지 않는 사례가 많으며 이러한 문제를 신속히 파악하여 해당 부품의 재고수준을 낮추는 방식이 재고비용 절감차원에서 효과적일 것이다. 그러나 기존의 Croston의 예측방법과 SBA의 경우 [Figure 1]과 수식 (1)에서 보듯이 수요가 발생하지 않은 기간에 대해서는 예측수요를 갱신하지 않기 때문에 가장 최근에 갱신된 예측수요를 나머지 수요가 발생하지 않은 기간 동안의 예측수요로 계속해서 사용하게 된다.

즉, 아래 [Figure 2]에서 보듯이 만약 특정 서비스 부품의 수요가 5기간에 마지막으로 발생한 이후 나머지 기간에서는 더 이상 수요가 발생하지 않았을 경우 Croston의 예측방법과 SBA는 5기간의 수요를 토대로 6기간의 수요를 예측하고 이 예측수요를 나머지 7기간에서부터 21기간에서도 동일하게 적용하게 된다. 따라서 실제 6기간 이후 해당 부품의 수요는 더 이상 발생하지 않음에도 불구하고 동일한 수의 부품을 나머지 기간 동안에도 지속적으로 요청하는 수요예측을 하며 이로 인하여 과도한 부품 재고를 보유하는 결과를 초래하게 된다. 이와 달리 SES의 경우 수요의 발생 여부와 상관없이 매기간 예측수요를 갱신하기 때문에 수요가 발생하지 않은 6기간 이후의 예측수요를 지속적으로 감소시켜 부품 진부화에 효과적으로 대응하는 것을 볼 수 있다.



[Figure 2] Comparison of demand forecasting with inventory obsolescence case

따라서 서비스 부품의 진부화로 인한 수요 감소 또는 수요발생 중단에 대응하기 위한 방안이 필요하지만 서비스 부품의 진부화를 고려한 수요예측 방법에 대한 연구는 많지 않은 실정이다. 최근 이러한 문제를 해결하기 위해 Teunter, Syntetos and Baba는 Croston의 예측방법을 변형한 새로운 수요예측 방법(이하 TSB)을 제안한 바 있다. Croston의 예측방법과 달리 TSB는 수요발생 간격을 갱신하는 대신 수요발생 확률(probability of demand occurrence) p'_t 을 아래와 같은 exponential smoothing 방식으로 수요의 발생 여부와 상관없이 매기간 갱신한다. t 기간의 예측수요 \hat{y}_t 은 수요발생 확률 p'_t 와 0이 아닌 수요의 예측값(z_t)과의 곱으로 나타낼 수 있다.

$$\begin{aligned} &\text{If } y_t = 0, \\ &p'_t = p'_{t-1} + \beta(0 - p'_{t-1}), \quad z_t = z_{t-1}, \quad \hat{y}_t = p'_t z_t \\ &\text{Else,} \\ &p'_t = p'_{t-1} + \beta(1 - p'_{t-1}), \\ &z_t = \alpha y_t + (1 - \alpha) z_{t-1}, \quad \hat{y}_t = p'_t z_t \end{aligned}$$

(where α and β are smoothing parameters)

따라서 TSB 방식은 수요가 발생하지 않을 경우 p'_t 값이 줄어들게 설계되었으며, 아주 많은 기간 동안 수요가 발생하지 않을 경우 수요 예측값을 0으로 수렴하게 함으로써 서비스 부품 진부화에 효과적으로 대응할 수 있도록 하였다. Croston의 예측방법 및 SBA와 달리 TSB는 α, β 2개의 smoothing parameter를 사용하는데 이는 수요발생 확률은 매기간 갱신하는 반면 0이 아닌 수요의 예측값(z_t)의 경우 수요 발생시에만 갱신하기 때문에 β 는 α 보다 일반적으로 작은 값을 사용하는 것이 보다 합리적일 것이다.

Teunter et al.(2011)은 Croston의 예측방법과 SBA와 달리 TSB는 unbiased한 예측값을 도출함을 수학적으로 증명하였다. 또한 TBS의 성능평가를 위하여 안정적인 수요 및 진부화가 발생하는 간헐수요 하에서 다양한 실험을 수행하였으며, ME(mean error)와 MSE를 평가척도로 사용하였을 경우 TSB가 Croston의 예측방법과 SBA에 비해 우수한 성능을 보임을 증명하였다.

TSB는 Croston의 예측방법과 SBA에 비해 우수함을 보였지만 smoothing parameter α 와 β 값에 매우 민감하게 반응하였다. 수요가 안정적일 경우 작은 smoothing parameter 값들을 사용할수록 좋은 결과를 나타내었으며, 진부화의 정도가 심할수록 큰 smoothing parameter 값들을 사용할수록 좋은 결과를 보여주었다. 이는 직관적으로 판단하였을 경우 충분히 예측 가능한 결과로써, 수요가 안정적일 경우 작은 smoothing parameter를 사용하여 최근 수요에 작은 가중치만을 반영하더라도 정확한 예측이 가능하다. 반면에 최근 급격한 수요분포의 변화가 발생하였다면 최근 수요에 보다 많은 가중치를 주어 변화된 수요 분포를 신속히 반영하여 예측하는 것이 효과적일 것이며, 이를 위해서는 보다 큰 smoothing parameter를 사용하는 것이 타당할 것이다.

그러나 특정한 몇 가지 실험환경(특히 수요가 안정적이거나 진부화의 정도가 완만할 경우)에서는 수요의 형태에 적합하지 않은 smoothing parameter가 선택되지 않았을 경우 오히려 Croston의 예측방법이나 SBA에 비해 열등한 결과를 보이기도 하였다. 즉 안정적인 수요하에서 큰 smoothing parameter를 사용할 경우 최근 발생한 수요의 작은 변화에도 지나치게 민감하게 반응하게 되어 수요예측치의 편차를 증가시키게 되고 이는 수요예측 결과를 나쁘게 만든다. 반대로 진부화가 심하게 나타나는 수요에 대해 매우 작은 smoothing parameter를 사용하여 예측할 경우 수요 변화에 신속하게 대응하지 못하여 수요예측 결과를 악화시키는 결과를 초래하게 된다.

따라서 TSB를 사용하여 우수한 예측결과를 도출하기 위해서는 수요의 형태에 적합한 smoothing parameter를 선택하는 것이 중요하며, 특히 진부화가 빠르게 진행되며 non-stationary한 형태를 나타내는 수요의 경우 고정된 하나의 값의 smoothing parameter를 사용하기 보다는 수요 형태의 변화에 적응적으로 대응하기 위해 smoothing parameter 또한 적응적으로 변화시키는 것이 바람직할 것이다.

따라서 본 연구에서는 TSB를 사용하여 제품 진부화가 발생하는 서비스 부품의 수요를 예측하고자 하며,

TSB의 예측성능을 극대화시키기 위하여 수요의 변화에 부응하여 적응적으로 smoothing parameter를 선택하는데 도움을 줄 수 있는 강화학습 기반 적응형 smoothing parameter 선택 모델을 제안하였다.

본 연구에서는 강화학습(reinforcement learning) 기법의 일종인 행동-보상 학습(action-reward learning)을 이용하여 시간에 따라 변화하는 고객 수요에 대처할 수 있도록 smoothing parameter를 적응적으로 조정하는 방법론을 제시하였다. 행동-보상 학습이란 에이전트의 시행착오(trial-and-error)를 이용한 Markov decision process(MDP) 기반 기계학습(machine learning) 방법으로써 주어진 환경 하에서 가장 높은 보상을 얻을 수 있는 행동이 다음 계획기간에 선택될 확률이 높아지도록 학습함으로써, 고객 수요의 변화에 대처하여 최적의 행동이 선택될 수 있도록 지원한다. 강화학습(행동-보상 학습)은 여러 가지 가능한 행동(action)들 중에서 최적의 행동을 선택하기 위해 시행착오(trial and error)를 통한 반복학습을 기본 원리로 한다. 강화학습에서는 에이전트(agent)라 불리는 학습자(learner) 또는 의사결정자(decision maker)가 불확실한(non-deterministic) 환경에서 특정한 행동을 선택하면 그에 따라 대상 환경의 상태(state)가 변화하고, 상태의 변화에 따라 해당 행동에 대한 보상(reward)이 결정된다.

본 연구에서는 MSE(mean squared error)나 ME(mean error) 등의 예측오차 평가척도를 최소화하는 적합한 smoothing parameter를 적응적으로 조정하며, 학습의 속도 및 효율성을 극대화하기 위해 기존의 retrospective analysis 기법(Kim et al, 2008)을 응용하였다. 특히 강화학습은 최근 불안정한 수요하의 공급망 환경에서 전체 최적화를 위한 새로운 접근방법으로 주목받고 있으며 다양한 비교 실험을 통해 우수성이 검증된 바 있어, 본 연구가 제안하는 접근방법의 타당성을 더해주고 있다.

2.2 제안된 방법론

TSB의 예측성능을 극대화하기 위해서는 시간에 따라 변화하는 고객 수요를 기반으로 smoothing parameter α 와 β 값이 동적으로 조정되어야 하는데, 본 연구에서는 이러한 문제를 해결하기 위하여 강화학습(reinforcement learning) 기법의 일종인 행동-보상 학습(action-reward learning)(Sutton and Barto, 1998)을 이용하여 α 와 β 값을 적응적으로 조정하는 방법을 제시하였다.

행동-보상 학습은 여러 가지 가능한 행동(action)들 중에서 최적의 행동을 선택하기 위해 고안된 학습방법이다. 일반적으로 모든 시스템은 에이전트와 그의 환경으로 구성되어 있다고 볼 수 있다. 에이전트(agent)는 그가 처한 환경에서 자신의 목적을 달성하기 위한 최적의 의사 결정을 하여야 하는데 이를 위하여 시행착오(trial-error)를 반복적으로 시행하여 가장 좋은 정책을 찾을 수 있도록 학습한다.

본 연구에서 사용한 행동-보상 학습은 Sutton and Barto(1998)를 참조하였으며 개념적인 수식은 다음과 같다.

$$\text{NewEstimate}(\alpha_i, \beta_j) \leftarrow \text{OldEstimate}(\alpha_i, \beta_j) + \text{StepSize}[\text{CurrentReward}(\alpha_i, \beta_j) - \text{OldEstimate}(\alpha_i, \beta_j)] \quad (2)$$

위의 수식은 특정한 시점에서 특정 행동 집합 (α_i, β_j) , $\alpha_i \in A$, $\beta_j \in B$ 에 대한 예상 보상값 $(\text{NewEstimate}(\alpha_i, \beta_j))$ 을 학습하는 식이다. 즉, 선택할 수 있는 행동의 수가 복수일 때, 현재 시점에서 선택된 행동에 대해서 얻어진 보상값 $(\text{CurrentReward}(\alpha_i, \beta_j))$ 을 이용하여, 선택된 행동에 대한 기존의 예상 보상값 $(\text{OldEstimate}(\alpha_i, \beta_j))$ 과의 차이의 일정비율 (StepSize) 만큼을 더해나가며 조정해 나가며, 전체 계획기간 동안 이러한 학습과정과 선택을 반복적으로 수행한다.

본 연구에서는 주어진 수요형태의 특성에 적합한 smoothing parameter 값의 조합을 선택해야 하는데, 이 경우 MSE(mean squared error)나 ME(mean error) 등과 같은 예측오차 평가척도가 α 와 β 를 선택하는 기준이 된다. 위의 수식 (2)에 의해서 계산된 행동별 예상 보상값(현재 시점까지 누적되어 계산된 MSE 또는 ME)은 수식 (3)과 같은 softmax rule에 의해서 다음 시점에 선택할 새로운 행동을 확률적으로 선택하는 데에 사용된다. 본 연구와 같은 예측오차 최소화 문제의 경우 $\text{NewEstimate}(\alpha_i, \beta_j)$ 값이 작을수록 수식 (3)의 오른쪽 분자값은 증가하기 때문에 (α_i, β_j) 의 선택 확률은 높아지게 된다.

$$\text{Pr}[\text{new action} = (\alpha_i, \beta_j)] = \frac{e^{-\text{NewEstimate}(\alpha_i, \beta_j)}}{\sum_{\alpha_k \in A, \beta_l \in B} e^{-\text{NewEstimate}(\alpha_k, \beta_l)}} \quad (3)$$

행동(본 연구에서는 smoothing parameter인 (α, β)

의 조합)에 대해서는, 불안정한 수요에 적절히 적응하기 위하여 미리 설정된 범위내의 고정값을 대상으로 학습을 진행하도록 설계되었다(예: $A = \{0.1, 0.2, 0.3\}$, $B = \{0.01, 0.02, 0.03, 0.04, 0.05, 0.1, 0.2, 0.3\}$). 또한 매 시점마다 선택된 smoothing parameter 값 이외의 다른 smoothing parameter들의 조합에 대한 결과값(MSE 또는 ME 등의 예측오차)은 시간을 되돌려서(1기간 이전 시점) 이미 발생한 수요를 이용하여 평가하는 retrospective analysis(Kim et al, 2008) 기법을 적용함으로써 학습 효율을 향상시킬 수 있다. 즉, 매 기간 모든 후보 (α, β) 의 조합에 대한 예상 예측오차를 갱신해 나간다. 이러한 빠른 학습을 가능하게 하는 retrospective analysis는 일반적으로 제한된 수의 수요 데이터를 토대로 예측을 진행하는 서비스 부품의 특성상 매우 효과적임이 판명되었다.

3. 실험 및 결과분석

본 연구에서는 제안된 방법을 정량적으로 평가, 분석하기 위하여 ME(mean error)와 MSE(mean squared error)를 평가척도로 사용하였으며, TSB를 포함하여 SBA, Croston, SES 등의 기존 수요예측 방법론과의 비교를 위해 아래와 같이 크게 3가지 실험환경을 구성하였다. 수요의 크기(demand size)는 Logarithmic 분포를 따르며, 수요의 발생간격(inter-demand interval)은 Bernoulli process를 따르는 것으로 가정하였다. Logarithmic 분포는 연속적(continuous) 형태인 정규분포 등과 달리 이산적(discrete)인 형태를 나타냄으로 현실적인 수요 형태를 보다 잘 반영할 수 있으며, 평균(μ) 및 표준편차(σ)의 비율에 따라 완만한(slow moving) 수요부터 매우 변화가 심한(lumpy) 수요를 표현가능하다는 장점 또한 존재한다.

Logarithmic 분포의 형태를 결정하는 모수 c ($0 < c < 1$)는 $c = 0.001$ ($\mu = 1, \sigma = 0$)과 $c = 0.9$ ($\mu = 4, \sigma = 5$)를 각각 사용하여 완만한(slow moving) 수요($c = 0.001$ 으로 설정한 경우)와 매우 변화가 심한(lumpy) 수요($c = 0.9$ 로 설정한 경우)를 각각 반영할 수 있도록 하였다. 매 실험은 10,000기간 동안 수행한 결과를 평균한 것이며 보다 정확한 실험을 위해 이러한 실험을 10회 반복한 평균을 최종 실험 결과 값으로 사용하였다.

- 실험환경 1 (Stationary demand): 수요발생 간격 $p = 0.2$ 를 따르는 안정적인 수요분포
- 실험환경 2 (Linearly decreasing demand): 초기 수요발생 간격 $p_0 = 0.2$ 에서부터 시작하여 마지막 기간의 수요발생 간격이 0이 되는 수요분포
- 실험환경 3 (Sudden obsolescence): 5,000기간 동안 수요발생 간격 $p = 0.2$ 의 안정적인 수요분포를 따르다가 갑작스러운 진부화로 인해 나머지 기간 동안 수요가 전혀 발생하지 않는 조건

아래 <Table 1>에서부터 <Table 6>은 3가지 실험 환경에 따른 실험결과를 요약하여 보여주고 있다. 실험 결과에서 알 수 있듯이 제안된 수요예측 방법이 기존의 수요예측 방안에 비해 두 가지 평가적도(ME, MSE) 모두에 대해 전체적으로 우수한 성능을 나타낼 수 있다.

4. 결론

본 연구에서는 제품 수명주기에 의해 발생하는 non-stationarity를 해결하기 위해 기존 TSB의 단점을 보완할 수 있는 강화학습(reinforcement learning) 기반의 적응형 수요예측 방법을 제안하였다. TSB의 예측성능을 극대화하기 위해서는 시간에 따라 변화하는 고객 수요를 기반으로 smoothing parameter들의 값이 동적으로 조정되어야 하는데, 본 연구에서는 이러한 문제를 해결하기 위하여 강화학습(reinforcement learning) 기법의 일종인 행동-보상 학습(action-reward learning)을 이용하여 smoothing parameter 값을 적응적으로 조정하는 방법을 제시하였다. 강화학습은 최근 불안정한 수요하의 공급망 환경에서 전체 최적화를 위한 새로운 접근방법으로 주목받고 있으며 다양한 비교 실험을 통해 우수성이 검증된 바 있기 때문에 본 연구가 제안하는 접근방법의 타당성을 더해주고 있다. 다양한 실험환경하에서 비교실험을 수행한 결과 본 연구에서 제안된 수요예측 방법이 기존의 수요예측 방안에 비해 전체적으로 우수한 성능을 나타냄을 확인할 수 있었다.

5. References

[1] Aberdeen Group (2005), The service parts management solution selection report.
[2] Altay, N. and Litteral, L.A. (2011), "Service parts management: demand forecasting and inventory control", Springer.

[3] Itay, N., Rudisill, F. and Litteral, L.A. (2008), "Adapting Wright's modification of Holt's method to forecasting intermittent demand", *International Journal of Production Economics*, 111:389-408.
[4] Bacchetti, A. and Saccani, N. (2012), "Spare parts classification and demand forecasting for stock control: investigating the gap between research and practice", *Omega*, 40:722-737.
[5] Bass, F. (1969), "A new product growth model for consumer durables", *Management Science*, 15:215-227.
[6] Boone, C.A., Graighead, C.W. and Hanna, J.B. (2008), "Critical challenges of inventory management in service parts supply: a Delphi study", *Operations Management Research*, 1:31-39.
[7] Chaharsooghi, S.K., Heydari, J. and Zegordi, S.H. (2008), "A reinforcement learning model for supply chain ordering management: an application to the beer game", *Decision Support Systems*, 45:949-959.
[8] Croston, J.D. (1972), "Forecasting and stock control for intermittent demands", *Operational Research Quarterly*, 23:289-304.
[9] Dekker, R., Pince, C., Zuidwijk, R. and Jalil, M.N. (2013), "On the use of installed base information for spare parts logistics: a review of ideas and industry practice", *International Journal of Production Economics*, 143:536-545.
[10] Fildes, R., Nikolopoulos, K., Crone, S.F. and Syntetos, A.A. (2008), "Forecasting and operational research: a review", *Journal of the Operational Research Society*, 59:1150-1172.
[11] Gallagher, T., Mitchke, M.D. and Rogers, M.D. (2005), "Profiting from spare parts", *Mcknksey Quarterly*.
[12] Gosavi, A. (2009), "Reinforcement learning: a tutorial survey and recent advances", *INFORMS Journal on Computing*, 21:178-192.
[13] Jiang, C. and Sheng, Z. (2009), "Case-based reinforcement learning for

- dynamic inventory control in an multi-agent supply-chain system”, *Expert Systems with Applications*, 36:6520–6526.
- [14] Kim, C.O., Kwon, I.H. and Baek, J.G. (2008), “Asynchronous action-reward learning for nonstationary serial supply chain inventory control”, *Applied Intelligence*, 28:1–16.
- [15] Knecht, T., Leszinski, R. and Weber, F.A. (1993), “Making profits after the sale”, *McKinsey Quarterly*.
- [16] Molenaers, A., Baets, H., Pintelon, L. and Waeyenberg, G. (2010), “Criticality classification of spare parts: a case study”, 16th International Working Seminar on Production Economics.
- [17] Muckstadt, J.A. (2004), “Analysis and algorithms for service parts supply chains”, Springer.
- [18] Pontrandolfo, P., Gosavi, A., Okogbaa, O.G. and Das, T.K. (2002), “Global supply chain management: a reinforcement learning approach”, *International Journal of Production Research*, 40:1299–1317.
- [19] Silver, E.A., Pyke, D.F. and Peterson, R. (2008), “Inventory management and production planning and scheduling”, John Wiley & Sons.
- [20] Smart, C.N. (2002), “Accurate intermittent demand/inventory forecasting: new technologies and dramatic results”, In: *Proceeding of APICS International Conference*, C-08.
- [21] Sutton, R.S. and Barto, A.G. (1998), “Reinforcement learning”, MIT Press.
- [22] Syntetos, A.A., Babai, M.Z. and Altay, N. (2012), “On the distribution of spare parts”, *International Journal of Production Research*, 50:2101–2117.
- [23] Syntetos, A.A. and Boylan, J.E. (2001), “On the bias of intermittent demand estimates”, *International Journal of Production Economics*, 71:457–466.
- [24] Syntetos, A.A. and Boylan, J.E. (2005), “The accuracy of intermittent demand estimates”, *International Journal of Forecasting*, 21:303–314.
- [25] Syntetos, A.A., Keyes, M. and Babai, M.Z. (2009), “Demand categorisation in a European spare parts logistics network”, *International Journal of Operations and Production Management*, 29:292–316.
- [26] Teunter R.H., Syntetos, A.A. and Babai, M.Z. (2011), “Intermittent demand: linking forecasting to inventory obsolescence”, *European Journal of Operational Research*, 214:606–615.
- [27] Zarandi, M.H.F., Moosavi, S.V. and Zarinbal, M. (2013), “A fuzzy reinforcement learning algorithm for inventory control in supply chains”, *International Journal of Advanced Manufacturing Technology*, 65:557–569.

<Table 1> Experimental result in case of Case 1($c = 0.001$)

	ME					MSE				
	α			β	absolute average	α			β	average
	0.10	0.20	0.30			0.10	0.20	0.30		
SBA	-0.0089	-0.0088	-0.0120	-	0.0099	0.1763	0.1774	0.1788	-	0.1775
Croston	0.0026	0.0155	0.0261	-	0.0147	0.1763	0.1782	0.1810	-	0.1785
SES	-0.0022	-0.0013	-0.0006	-	0.0014	0.1840	0.1945	0.2061	-	0.1949
TSB	-0.0150	-0.0150	-0.0150	0.01	0.0053	0.1760	0.1760	0.1760	0.01	0.1840
	-0.0090	-0.0090	-0.0090	0.02		0.1766	0.1766	0.1766	0.02	
	-0.0061	-0.0061	-0.0061	0.03		0.1774	0.1774	0.1774	0.03	
	-0.0045	-0.0045	-0.0045	0.04		0.1783	0.1783	0.1783	0.04	
	-0.0036	-0.0036	-0.0036	0.05		0.1792	0.1792	0.1792	0.05	
	-0.0022	-0.0022	-0.0022	0.10		0.1840	0.1840	0.1840	0.10	
	-0.0013	-0.0013	-0.0013	0.20		0.1945	0.1945	0.1945	0.20	
	-0.0006	-0.0006	-0.0006	0.30	0.2061	0.2061	0.2061	0.30		
New	-	-	-	-	0.0012	-	-	-	-	0.1753

<Table 2> Experimental result in case of Case 1($c = 0.9$)

	ME					MSE				
	α			β	absolute average	α			β	average
	0.10	0.20	0.30			0.10	0.20	0.30		
SBA	-0.0167	-0.0418	-0.0651	-	0.0136	8.3531	8.4167	8.4958	-	8.4219
Croston	0.0252	0.0440	0.0669	-	0.0454	8.3609	8.4561	8.5989	-	8.4720
SES	-0.0046	0.0017	0.0038	-	0.0034	8.6066	9.0464	9.5465	-	9.0665
TSB	-0.0323	-0.0619	-0.0811	0.01	0.0284	8.3304	8.3436	8.3725	0.01	8.4941
	-0.0190	-0.0477	-0.0670	0.02		8.3495	8.3660	8.3962	0.02	
	-0.0108	-0.0383	-0.0573	0.03		8.3679	8.3886	8.4214	0.03	
	-0.0052	-0.0314	-0.0499	0.04		8.3842	8.4095	8.4458	0.04	
	-0.0010	-0.0259	-0.0436	0.05		8.3986	8.4288	8.4691	0.05	
	0.0111	-0.0078	-0.0213	0.10		8.4564	8.5099	8.5735	0.10	
	0.0199	0.0069	-0.0008	0.20		8.5699	8.6564	8.7634	0.20	
	0.0224	0.0116	0.0064	0.30	8.7022	8.8072	8.9474	0.30		
New	-	-	-	-	0.0029	-	-	-	-	8.3975

<Table 3> Experimental result in case of Case 2($c = 0.001$)

	ME					MSE				
	α			β	average	α			β	average
	0.10	0.20	0.30			0.10	0.20	0.30		
SBA	0.0672	0.0535	0.0452	-	0.0553	0.0977	0.0966	0.0968	-	0.0970
Croston	0.0763	0.0712	0.0718	-	0.0731	0.0990	0.0990	0.1008	-	0.0996
SES	0.0158	0.0083	0.0056	-	0.0099	0.0959	0.1009	0.1063	-	0.1010
TSB	0.0669	0.0669	0.0669	0.01	0.0311	0.0970	0.0970	0.0970	0.01	0.0971
	0.0506	0.0506	0.0506	0.02		0.0948	0.0948	0.0948	0.02	
	0.0402	0.0402	0.0402	0.03		0.0940	0.0940	0.0940	0.03	
	0.0331	0.0331	0.0331	0.04		0.0938	0.0938	0.0938	0.04	
	0.0281	0.0281	0.0281	0.05		0.0939	0.0939	0.0939	0.05	
	0.0158	0.0158	0.0158	0.10		0.0959	0.0959	0.0959	0.10	
	0.0083	0.0083	0.0083	0.20		0.1009	0.1009	0.1009	0.20	
	0.0056	0.0056	0.0056	0.30	0.1063	0.1063	0.1063	0.30		
New	-	-	-	-	0.0085	-	-	-	-	0.0956

<Table 4> Experimental result in case of Case 2($c = 0.9$)

	ME					MSE				
	α			β	average	α			β	average
	0.10	0.20	0.30			0.10	0.20	0.30		
SBA	0.4250	0.2680	0.1841	-	0.2924	8.5839	8.6347	8.7239	-	8.6475
Croston	0.4893	0.3863	0.3573	-	0.4110	8.6594	8.7895	9.0010	-	8.8166
SES	0.1612	0.0828	0.0556	-	0.0999	8.6543	9.0769	9.5600	-	9.0971
TSB	0.7088	0.6859	0.6730	0.01	0.3200	8.9642	9.2291	9.5383	0.01	8.7580
	0.5290	0.5083	0.4966	0.02		8.6729	8.8792	9.1136	0.02	
	0.4185	0.3993	0.3883	0.03		8.5481	8.7256	8.9208	0.03	
	0.3459	0.3280	0.3174	0.04		8.4873	8.6503	8.8242	0.04	
	0.2954	0.2786	0.2685	0.05		8.4548	8.6107	8.7731	0.05	
	0.1775	0.1646	0.1574	0.10		8.4147	8.5709	8.7282	0.10	
	0.1094	0.0998	0.0963	0.20		8.4528	8.6271	8.8094	0.20	
0.0848	0.0758	0.0738	0.30	8.5423	8.7271	8.9269	0.30			
New	-	-	-	-	0.0867	-	-	-	-	8.5488

<Table 5> Experimental result in case of Case 3($c = 0.001$)

	ME					MSE				
	α			β	average	α			β	average
	0.10	0.20	0.30			0.10	0.20	0.30		
SBA	0.1040	0.1034	0.0995	-	0.1023	0.1057	0.1068	0.1070	-	0.1065
Croston	0.1149	0.1264	0.1355	-	0.1256	0.1082	0.1127	0.1169	-	0.1126
SES	0.0168	0.0084	0.0056	-	0.0103	0.0888	0.0929	0.0985	-	0.0934
TSB	0.0746	0.0746	0.0746	0.01	0.0352	0.0951	0.0951	0.0951	0.01	0.0917
	0.0586	0.0586	0.0586	0.02		0.0914	0.0914	0.0914	0.02	
	0.0470	0.0470	0.0470	0.03		0.0896	0.0896	0.0896	0.03	
	0.0384	0.0384	0.0384	0.04		0.0887	0.0887	0.0887	0.04	
	0.0321	0.0321	0.0321	0.05		0.0882	0.0882	0.0882	0.05	
	0.0168	0.0168	0.0168	0.10		0.0888	0.0888	0.0888	0.10	
	0.0084	0.0084	0.0084	0.20		0.0929	0.0929	0.0929	0.20	
0.0056	0.0056	0.0056	0.30	0.0985	0.0985	0.0985	0.30			
New	-	-	-	-	0.0097	-	-	-	-	0.0905

<Table 6> Experimental result in case of Case 3($c = 0.9$)

	ME					MSE				
	α			β	average	α			β	average
	0.10	0.20	0.30			0.10	0.20	0.30		
SBA	0.3857	0.3508	0.3114	-	0.3493	4.5714	4.5988	4.6357	-	4.6020
Croston	0.4286	0.4376	0.4423	-	0.4362	4.6127	4.7003	4.8202	-	4.7111
SES	0.0671	0.0336	0.0224	-	0.0410	4.4121	4.6454	4.9053	-	4.6543
TSB	0.2861	0.2576	0.2312	0.01	0.1390	4.4133	4.4032	4.4016	0.01	4.3855
	0.2340	0.2118	0.1903	0.02		4.3623	4.3643	4.3719	0.02	
	0.1945	0.1770	0.1591	0.03		4.3355	4.3450	4.3586	0.03	
	0.1651	0.1509	0.1357	0.04		4.3216	4.3364	4.3544	0.04	
	0.1430	0.1314	0.1181	0.05		4.3148	4.3337	4.3554	0.05	
	0.0882	0.0833	0.0753	0.10		4.3187	4.3512	4.3864	0.10	
	0.0576	0.0564	0.0517	0.20		4.3747	4.4230	4.4767	0.20	
0.0469	0.0467	0.0431	0.30	4.4539	4.5139	4.5823	0.30			
New	-	-	-	-	0.0365	-	-	-	-	4.3615

저자 소개

권익현



고려대학교 산업공학과에서 학사, 석사 및 박사학위를 취득하였다. 현재 인제대학교 산업경영공학과 조교수로 재직 중에 있다. 주요 관심분야는 물류 및 공급망관리, 생산계획 및 통제, 서비스 사이언스 등이다.