

## 행동-보상 학습 기법을 이용한 적응형 VMI 모형

김창우\* · †백준걸\*\* · 최진성\* · 권익현\*\*\*

### An Adaptive Vendor Managed Inventory Model Using Action-Reward Learning Method

Chang Ouk Kim\* · Jun-Geol Baek\*\*  
Jin Sung Choi\* · Ick-Hyun Kwon\*\*\*

#### ■ Abstract ■

Today's customer demands in supply chains tend to change quickly, variously even in a short time interval. The uncertainties of customer demands make it difficult for supply chains to achieve efficient inventory replenishment, resulting in loosing sales opportunity or keeping excessive chain wide inventories. In this paper, we propose an adaptive vendor managed inventory (VMI) model for a two-echelon supply chain with non-stationary customer demands using the action-reward learning method. The purpose of this model is to decrease the inventory cost adaptively. The control parameter, a compensation factor, is designed to adaptively change as customer demand pattern changes. A simulation-based experiment was performed to compare the performance of the adaptive VMI model.

Keyword : Adaptive VMI Model, Non-Stationary Customer Demand, Action-Reward Learning,  
Inventory Cost, Compensation Factor

논문접수일 : 2006년 3월 6일      논문제재확정일 : 2006년 7월 12일

\* 연세대학교 정보산업공학과

\*\* 인덕대학 산업시스템경영과

\*\*\* 고려대학교 산업시스템정보공학과

† 교신저자

## 1. 서 론

재고관리(inventory control)는 기업의 비용 절감 측면에서 오랫동안 중요한 문제로 연구되어 왔으며, 기업들은 적정량의 재고수준을 유지함으로써 고객의 수요에 빠르게 대처할 수 있을 뿐만 아니라 나아가 고객 만족을 통한 기업 이미지 상승을 도모하여 왔다. 그러나 재고과잉(over inventory)은 추가적인 재고유지비용(inventory holding cost)의 발생을 초래하고, 재고부족(shortage)은 고객 서비스 수준(service level)의 하락 및 판매기회상실비용(lost sales cost)의 발생을 초래하므로 적정한 재고수준을 유지할 수 있는 효율적인 재고관리에 대한 관심은 점점 높아지고 있다.

일반적으로 공급사슬 상에서 기업들이 사용해온 재고관리 모형은 소매업체(retailer)가 자신의 재고 수준을 조사하고 이에 따른 주문시점을 결정하여 공급업체(vendor)에게 주문을 전달하는 방식이 사용되어 왔다. 그러나 이러한 방식에서는 공급업체가 소매업체의 주문시점과 주문량을 미리 알 수 없기 때문에 소매업체가 원하는 시점에 정확한 수량의 제품을 공급하기 위해서는 필요한 양보다 많은 재고를 유지할 수밖에 없다. 이러한 현상은 공급사슬 전체에서 상위 단계로 올라갈수록 재고 보유량이 증가하는 채찍효과(bullwhip effect)를 유발하게 된다[8]. 채찍효과란 공급사슬 상의 하위 노드에서 발생하는 재고수준의 변화가 상위 단계로 전달될수록 변화의 증폭이 심화되는 현상을 의미한다.

최근 들어 이러한 문제점을 해결하기 위한 재고 관리 모형으로서 공급업체 중심의 재고관리 모형인 VMI(Vendor Managed Inventory)가 많은 기업들로부터 관심을 받고 있다[1]. VMI는 2단계 공급사슬(two-echelon supply chain)에서의 대표적인 재고관리 모형으로써 공급업체가 소매업체의 재고수준까지 통합적으로 관리하는 방식을 따른다. VMI 모형에서는 소매업체가 공급업체에게 실시간으로 판매정보와 재고수준정보를 제공하고, 공급업체는 소매업체로부터 제공받은 정보를 바탕으로 소매업-

체의 재고보충시점 및 공급량(replenishment quantity)을 결정하게 된다. 따라서 소매업체는 적시에 적정량의 재고를 보충 받을 수 있고 공급업체는 효율적인 공급계획을 수립할 수 있다는 장점을 지닌다[7, 9].

최근 들어 인터넷의 광범위한 보급은 전자상거래의 활성화를 초래하였고, 전자상거래를 이용하는 온라인상에서의 고객수요는 작은 가격차이만으로도 쉽게 변화하기 때문에 전반적으로 고객수요가 매우 불안정한 형태를 지니게 되었다. 또한, 비슷한 품질과 기능을 가진 다양한 제품의 출시로 인한 제품 차별성 부재는 고객수요의 불안정성을 증폭시키는 원인이 되었다.

고객수요의 불안정성은 수요예측의 불확실성을 증가시키는 원인이 되고, 수요예측의 불확실성 증가는 재고부족이나 불필요한 재고과잉을 유발시키며 이로 인한 재고비용의 발생을 초래한다. 따라서 많은 기업들이 불필요한 재고비용을 줄이기 위한 연구에 관심을 집중시키고 있으며, 특히 불안정한 고객수요 환경 하에서 재고비용을 줄이기 위한 연구에 많은 노력을 기울이고 있다[4, 6].

공급사슬에서의 효율적인 재고관리 방법을 제안한 기존의 연구들은 재고관리를 위한 수리적 모형을 정의하고, 이를 기반으로 최적해를 도출하는 방법을 제시하였다[2, 3, 11]. 그러나 수리적 모형을 이용한 방법은 고객수요가 안정적인 분포를 따른다는 가정 하에 최적해를 도출하는 방법을 제시하고 있기 때문에 고객수요가 불안정한 형태를 지닌 경우에는 적용하기 힘들다는 문제점을 지닌다. 따라서 불안정한 고객수요의 변화에 따라 재고관리를 위한 모수(parameter)를 적응적(adaptive)으로 제어(control)하는 재고관리 모형에 대한 필요성이 대두되었다[5].

VMI 모형에서 재고관리를 위한 정책은 다음과 같은 두 가지 형태로 나눌 수 있다.

첫 번째 정책은 소매업체와 공급업체가 소매업체의 재주문점(reordered point)과 목표재고수준(target inventory level)을 설정하고 이를 기반으로 재고를

보충하는 정책으로서, 공급업체는 소매업체의 재고 수준이 재주문점에 도달하는 순간 목표재고수준까지 재고를 보충하게 된다. 이러한 재고관리 정책은 소매업체의 재고수준을 일정하게 유지할 수 있기 때문에 고객수요가 안정적인 경우 효과적인 정책으로 사용될 수 있다. 그러나 고객수요가 불안정하게 변화하는 경우, 고객수요의 변화에 따라 소매업체의 재주문점과 목표재고수준이 다시 설정되어야 하고, 이로 인해 공급업체는 각각의 소매업체에 대한 재고보충시점과 공급량을 다시 조정해야하는 문제점이 발생한다.

두 번째 정책은 소매업체와 공급업체가 일정한 주문주기(ordering interval)를 설정하고 공급업체가 설정된 주문주기마다 다음 주기 동안 소매업체가 필요로 하는 재고를 보충하는 정책으로서, 매 주문주기마다 보충될 재고량이 주기적으로(periodically) 배송되기 때문에 공급업체가 다수의 소매업체와 거래하는 경우에도 생산계획 및 배송계획을 수립하기 용이하다는 장점을 지닌다.

일반적으로 VMI 모형을 이용하여 재고관리를 수행하는 경우 고정된 주문주기를 가지고 예측된 고객수요만큼 재고를 보충하는 두 번째 정책이 보편적으로 사용된다[1]. 그러나 두 번째 정책을 이용하여 재고를 보충하는 경우, 고객수요에 대한 예측의 정확도가 떨어지게 되면 소매업체에서 발생하는 재고비용이 증가하는 문제점이 발생한다.

따라서 본 연구에서는 고객수요가 불안정하게 변화하는 2단계 공급사슬에서 매 주문주기마다 공급업체가 소매업체에게 공급할 배송량을 고객수요의 변화에 따라 적응적으로 제어할 수 있는 적응형 VMI 모형을 제시하고자 한다. 단, 본 연구에서는 공급업체가 모든 소매업체들이 필요로 하는 재고를 충분히 공급할 수 있는 능력(capacity)을 갖추었다고 가정한다. 따라서 본 연구의 대상이 적응형 VMI 모형은 공급업체가 각각의 소매업체를 대상으로 일대일(one-to-one)로 재고를 보충하는 모형으로 단순화될 수 있다. 그리고 공급업체가 소매업체의 재고를 보충하기 위해 소요되는 리드타임(lead time)

은 소매업체의 주문주기에 포함되어 있다고 가정하고, 주문주기는 소매업체와 공급업체간의 합의에 의해 결정된다고 가정하였다.

본 연구의 대상이 되는 공급사슬에서 고객수요는 정규분포(normal distribution)를 따른다고 가정하였으며, 고객수요 분포의 평균(mean)과 분산(variance)이 시간의 흐름에 따라 불안정하게 변화하는 다음과 같은 두 가지 형태를 가정하였다.

첫째, 고객수요 분포의 평균과 분산이 급격하게 변화하는 펄스(pulse) 형태로써, 평균과 분산이 무작위로 추출된 주기마다 무작위로 변화하는 특징을 지닌다.

둘째, 고객수요 분포의 평균과 분산이 일정한 기울기를 지니며 변화하는 슬로프(slope) 형태로써, 평균과 분산이 무작위로 추출된 주기마다 무작위로 추출된 기울기에 따라 변화하는 특징을 지닌다.

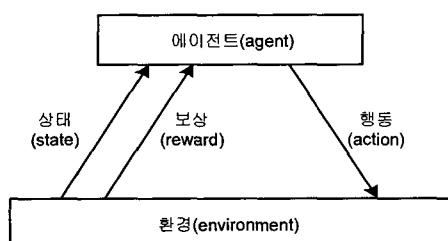
본 연구에서는 불안정하게 변화하는 고객수요를 예측하기 위해 시계열 분석(time series analysis) 방법 중 단기간 수요예측에 가장 많이 사용되는 이동평균법(moving average method)과 지수평활법(exponential smoothing method)을 이용하여 고객수요를 예측하였다[13, 16].

또한, 본 연구에서 제시하는 적응형 VMI 모형에서는 매 주문주기마다 예측고객수요(forecasted customer demand)와 실제고객수요(actual customer demand)를 비교하여 만약 실제고객수요가 예측고객수요보다 많을 경우 재고부족으로 인한 재고부족비용(shortage cost)이 발생하고, 실제고객수요가 예측고객수요보다 적을 경우 재고과잉으로 인한 재고유지비용(inventory holding cost)이 발생한다고 가정하였다.

따라서 본 연구에서 제시하는 적응형 VMI 모형에서는 소매업체별로 주문주기마다 발생하는 재고비용(재고부족비용 또는 재고유지비용)의 합을 최소화하는 것을 목적함수(objective function)로 사용한다. 결정변수(decision variable)는 공급업체가 매 주문주기마다 소매업체에게 공급해야 할 배송량이며, 배송량은 공급업체가 예측한 소매업체에서의

고객수요 예측치와 보상계수(compensation factor)에 의해 결정된다. 보상계수는 고객수요의 변화에 따라 배송량을 적응적으로 제어하기 위해 사용되는 모수(parameter)로써, 소매업체의 재고수준 샘플 경로(inventory level sample path)를 기반으로 매 주문주기마다 재고비용을 적응적으로 줄여나갈 수 있는 보상계수가 선택되어진다. 즉, 재고수준 샘플 경로를 기반으로 재고유지비용이 증가하는 추세를 보이는 경우에는 보상계수를 감산비율(음수)로 설정하여 다음 주문주기의 배송량을 감소시키고, 재고 부족비용이 증가하는 추세를 보이는 경우에는 보상계수를 가산비율(양수)로 설정하여 다음 주문주기의 배송량을 증가시킨다.

본 연구에서는 고객수요의 변화에 따라 배송량을 적응적으로 제어하기 위해 재고수준 샘플 경로를 기반으로 행동-보상 학습(action-reward learning)을 이용하여 매 주문주기마다 재고비용을 적응적으로 줄여나갈 수 있는 보상계수를 선택하는 방법을 제시하고자 한다. 행동-보상 학습은 강화학습(reinforcement learning)의 한 방법으로써 여러 가지 가능한 행동(action)들 중에서 최적의 행동을 선택하기 위해 고안된 학습방법이다[15].



[그림 1] 행동-보상 학습

행동-보상 학습의 기본 원리는 [그림 1]과 같다. [그림 1]에서 에이전트(agent)가 어떤 행동을 선택하면 그에 따라 대상 환경(environment)의 상태(state)가 변화하고, 상태의 변화에 따라 해당 행동에 대한 보상(reward)이 결정된다. 따라서 에이전트는 행동에 따른 보상의 합을 최대화하기 위해 가능한 행동들 중에서 보상 값이 가장 높은 행동을 선

택하고, 선택된 행동에 의해 변화된 상태에 따라 보상 값이 수정되는 과정을 반복함으로써 에이전트는 불확실한 환경에서의 학습을 수행할 수 있게 된다.

본 연구에서 제안하는 적응형 VMI 모형에 행동-보상 학습을 적용하면, 적응형 VMI 시스템이 에이전트가 되고 불안정한 고객수요를 갖는 공급사슬이 환경이 된다. 또한 주문주기마다 선택되어야 할 보상계수는 행동으로 정의될 수 있으며, 선택된 보상계수에 의해 결정되는 다음 주문시점에서의 재고수준(재고부족 또는 재고과잉)이 상태로 정의될 수 있다. 그리고 재고수준에 따라 발생하는 재고비용(재고부족비용 또는 재고유지비용)이 행동에 따른 보상으로 정의될 수 있다. 단, 본 연구에서 제시하는 적응형 VMI 모형에서는 재고비용이 보상으로 정의되었으므로 보상(재고비용) 값이 가장 적은 행동(보상계수)이 선택되어지는 것으로 수정되어져야 한다.

일반적으로 행동-보상 학습은 미리 정의된 상태별로 최적의 행동을 결정하는 마코프 의사결정 프로세스(Markov decision process)를 위한 기계학습(machine learning) 방법론이다[10, 15]. 그러나 본 연구의 대상이 되는 공급사슬에서는 고객수요가 시간에 따라 변화하는 불안정한 형태를 지니고 있기 때문에 안정적인 확률모형(예: 안정적인 고객수요 분포)에 따른 상태 변화를 전제로 하는 마코프 의사결정 프로세스가 적용될 수 없다. 따라서 본 연구에서는 실제재고관리 상황에서 재고수준 샘플 경로를 이용하여 매 주문주기마다 재고비용을 적응적으로 줄여나갈 수 있는 수 있는 보상계수를 선택하는 방법을 제시한다. 즉, 본 연구에서 제시하는 적응형 VMI 모형은 최적해를 제공하는 재고관리 모형이 아니고 재고수준 샘플 경로를 이용하여 고객수요의 변화에 따라 배송량을 적응적으로 제어하는 개념을 지닌 재고관리 모형이다.

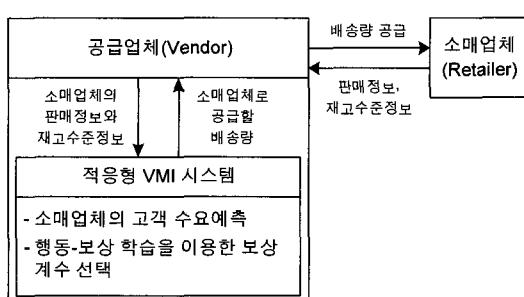
## 2. 적응형 VMI 모형

본 연구에서 제안하는 적응형 VMI 모형은 [그림

2]에서 제시한 바와 같이 공급업체가 매 주문주기마다 소매업체에 공급해야 할 배송량을 예측된 고객수요와 행동-보상 학습에 의해 선택된 보상계수를 이용하여 결정함으로써 매 주문주기마다 발생하는 재고비용을 적응적으로 줄여나가는 것을 목적으로 한다.

공급업체는 소매업체로부터 전송되는 판매정보와 재고수준정보를 이용하여 소매업체에서의 고객수요를 예측하고, 예측된 고객수요와 행동-보상 학습을 이용하여 선택한 보상계수를 이용하여 소매업체로 공급할 배송량을 결정한다. 또한 공급업체는 결정된 배송량을 소매업체에 보충하고 다음 주문주기까지 소매업체의 판매정보와 재고수준정보를 수집한 후, 이를 기반으로 다음 주문주기에 공급할 배송량을 결정하는 작업을 반복한다. 결론적으로 공급업체는 각각의 소매업체에 대해 미리 설정된 주문주기마다 다음과 같은 작업을 반복적으로 수행한다.

- 소매업체의 판매정보와 재고수준정보 수집
- 소매업체의 고객수요 예측
- 행동-보상 학습을 이용한 보상계수 선택
- 예측된 고객수요와 선택된 보상계수를 이용하여 소매업체로 공급할 배송량 결정
- 소매업체에 결정된 배송량 공급



[그림 2] 적응형 VMI 모형

## 2.1 기호 정의

본 연구에서 제시하는 적응형 VMI 모형을 설명하기 위해 필요한 기호는 다음과 같다.

$t$	: 주문주기 단위( $t=0,1,2,\dots$ )
$D_t$	: 주문주기 $t$ 기간동안의 실제고객수요
$\hat{D}_t$	: 주문주기 $t$ 기간동안의 예측고객수요
$I_t$	: 주문주기 $t$ 기간 초의 재고량
$Q_t$	: 주문주기 $t$ 기간 초의 배송량
$\rho_i$	: 보상계수
$i$	: 보상계수 인덱스( $i=1,2,\dots,n$ )
$\Theta$	: 보상계수 집합( $\Theta=\{\rho_1, \rho_2, \dots, \rho_n\}$ )
$h$	: 단위제품(SKU)당 재고유지비용
$s$	: 단위제품당 재고부족비용
$C_t(\rho_i)$	: 주문주기 $t$ 기간에서 보상계수 $\rho_i$ 를 선택했을 때 발생한 재고비용
$\bar{C}_t(\rho_i)$	: 주문주기 $t$ 기간에서 보상계수 $\rho_i$ 를 선택했을 때 계산된 가중평균재고비용(weighted mean inventory cost)

## 2.2 고객수요

본 연구의 대상이 되는 적응형 VMI 모형에서는 1장에서 기술한 바와 같이 불안정한 고객수요의 형태를 두 가지 형태(펄스 형태, 슬로프 형태)로 가정하였다. 펄스 형태는 온라인 시장에서 자주 나타나는 고객수요 형태로써 판매업체들 사이의 서비스, 제품 품질, 그리고 가격 등의 작은 차이로 인해 고객수요가 급격히 변화하는 형태를 나타낸다. 또한 슬로프 형태는 경제적 또는 기술적 상황의 변화로 인해 고객수요가 일정한 추세(trend)를 가지고 변화하는 형태를 나타낸다.

### 2.2.1 펄스 형태의 고객수요

본 연구에서 제안하는 적응형 VMI 모형에서는 고객수요가 정규분포를 따른다고 가정하였으며, 고객수요 분포의 평균과 표준편차가 시간에 따라 변화하는 불안정한 형태를 지닌다고 가정하였다.

펄스 형태의 고객수요는 고객수요 분포의 평균과 표준편차가 무작위로 추출된 주기마다 무작위로 변화하는 특징을 지닌다. 따라서 본 연구에서는 펄스 형태의 고객수요를 발생시키기 위해 고객수요 분포

의 평균(Mean)이 무작위로 추출된 주기( $T$ )마다 무작위로 변화하도록 하였으며, 고객수요 분포의 표준편차( $SD$ )는 평균에 변동계수( $CV$ : coefficient of variation)를 곱한 값을 사용하였다. 본 연구에서는 펠스 형태의 고객수요를 발생시키기 위해서 아래와 같은 수식을 사용하였다. 단, 아래의 수식에서  $MinT$ ,  $MaxT$ ,  $MinMean$ ,  $MaxMean$ ,  $CV$ 는 사용자에 의해 주어진다고 가정하였다.

$$T = U(MinT, MaxT)$$

$$Mean = U(MinMean, MaxMean)$$

$$SD = Mean \times CV$$

$$ActualCustomerDemand = N(Mean, SD^2)$$

### 2.2.2 슬로프 형태의 고객수요

슬로프 형태의 고객수요는 고객수요 분포의 평균과 표준편차가 무작위로 추출된 주기마다 일정한 기울기를 가지고 변화하는 특징을 지닌다. 따라서 본 연구에서는 슬로프 형태의 고객수요를 발생시키기 위해 고객수요 분포의 평균(Mean)과 표준편차( $SD$ )를 무작위로 추출된 주기( $T$ )와 기울기(Slope)를 기반으로 변화시키는 방법을 사용하였다. 본 연구에서 슬로프 형태의 고객수요를 발생시키기 위해서 사용한 수식은 다음과 같다. 단, 아래의 수식에서  $MinT$ ,  $MaxT$ ,  $MinSlope$ ,  $MaxSlope$ ,  $CV$ 는 사용자에 의해 주어진다고 가정하였다.

$$T = U(MinT, MaxT)$$

$$Slope = U(MinSlope, MaxSlope)$$

$$NewMean = OldMean + Slope$$

$$SD = NewMean \times CV$$

$$ActualCustomerDemand = N(NewMean, SD^2)$$

### 2.3 고객수요 예측

본 연구에서는 고객수요를 예측하기 위해 이동평균법(moving average method)과 지수평활법(exponential smoothing method)을 사용하였다.

#### 2.3.1 이동평균법을 이용한 고객수요 예측

이동평균법은 최근 데이터를 기반으로 고객수요를 예측하는 방법으로써 본 연구에서는 식 (1)과 같이 최근  $N$ 개의 데이터를 이용하여 다음 주문주기( $t+1$ ) 동안의 고객수요를 예측하였다. 단, 고객수요를 예측하기 위해 사용하는 데이터의 수( $N$ )는 사용자에 의해 주어진다고 가정하였다.

$$\widehat{D_{t+1}} = \frac{\sum_{i=0}^{N-1} D_{t-i}}{N} \quad (1)$$

#### 2.3.2 지수평활법을 이용한 고객수요 예측

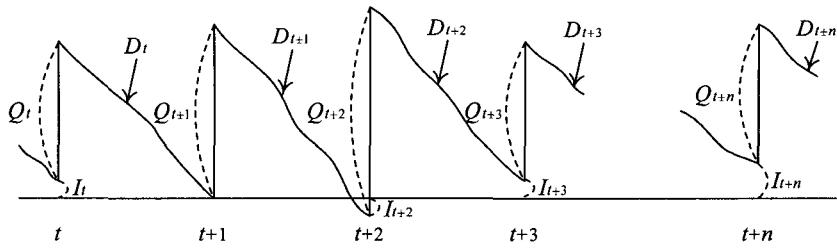
지수평활법을 이용하여 고객수요를 예측하는 경우에는 다음 주문주기( $t+1$ ) 동안의 고객수요 예측치( $\widehat{D_{t+1}}$ )가 현재 주문주기( $t$ )에서의 실제고객수요( $D_t$ )와 예측고객수요( $\widehat{D}_t$ )와의 차이에 평활상수(smoothing constant)  $\alpha$  ( $0 < \alpha < 1$ )를 곱한 값을 이용하여 다음과 같이 계산되어진다.

$$\widehat{D_{t+1}} = \widehat{D}_t + \alpha(D_t - \widehat{D}_t)$$

일반적으로 평활상수  $\alpha$ 는 0.1~0.3 사이의 값이 주로 사용되며 추세가 불안정한 경우에 0.5~0.9 사이의 값이 사용된다[16]. 본 연구에서는 가장 일반적으로 사용되는 평활상수 값인  $\alpha=0.1$ 을 사용하여 고객수요를 예측하였다.

### 2.4 행동-보상 학습을 이용한 보상계수 선택

본 연구에서 제시하는 적응형 VMI 모형에서 공급업체는 다음 주문주기에 소매업체에게 공급할 배송량을 결정하기 위해 시계열 분석 방법을 이용하여 고객수요를 예측한다. 그러나 불안정하게 변화하는 미래의 고객수요를 정확하게 예측한다는 것은 불가능하며, 이로 인해 [그림 3]에서 제시한 바와 같이 매 주문시점마다 재고부족([그림 3]에서  $I_{t+2}$ ) 또는 재고과잉([그림 3]에서  $I_{t+3}$ )으로 인한 재고비용이 발생하게 된다.



[그림 3] 재고 수준(inventory level)

주문주기  $t$  기간 초의 재고량  $I_t$ 는  $t-1$  기간 초에 공급된 배송량( $Q_{t-1}$ )과  $t-1$  기간 초의 재고량( $I_{t-1}$ )의 합에서  $t-1$  기간동안 발생한 실제고객수요( $D_{t-1}$ )를 뺀 값으로 아래와 같이 계산되어질 수 있다.

$$I_t = I_{t-1} + Q_{t-1} - D_{t-1} \quad (t=1,2,\dots)$$

$I_t$ 가 양수(재고파잉)일 경우에는 단위제품당 재고유지비용( $h$ )이 발생하고,  $I_t$ 가 음수(재고부족)일 경우에는 단위제품당 재고부족비용( $s$ )이 발생한다. 따라서 본 연구에서 제시하는 적응형 VMI 모형은 공급사슬에서 발생하는 재고비용을 최소화하는 것을 목표로 하기 때문에 목적함수가 다음과 같이 정의된다.

$$\min \sum_{t=1}^{\infty} (\epsilon \times |I_t|), \text{ where } \epsilon = \begin{cases} h & \text{if } I_t \geq 0 \\ s & \text{if } I_t < 0 \end{cases}$$

본 연구의 대상이 되는 공급사슬에서 만약 주문주기가 한번만 존재하고, 한번의 주문주기가 끝난 시점에서의 재고비용을 최소화하는 문제라고 가정하면 이는 Newsboy(이하 NB로 표현한다.) 재고관리 모형으로 정의될 수 있다[12]. NB 재고관리 모형은 고객수요가 안정적인 정규분포를 따르는 경우, 주문주기가 끝난 시점에서 발생하는 재고비용을 최소화할 수 있는 최적해를 제공할 수 있다. 따라서 만일 고객수요의 불안정성이 작다면 NB 재고관리 모형을 매 주문주기마다 반복적으로 적용함으로써 재고비용을 최소화 할 수 있는 최적 배송량을 도출할 수 있다[1].

NB 재고관리 모형에서 주문주기  $t$  기간 초의 배송량  $Q_t$ 는 고객수요 예측치( $\hat{D}_t$ )에 안전재고(safety stock)를 더한 값으로 계산되어지며, 안전재고는 안정적인 고객수요를 갖는 재고관리 모형에서 고객수요의 불확실성을 반영하는 유일한 척도인 표준편차를 이용하여 식 (2)와 같이 계산되어진다. 식 (2)에서  $z$ 는 NB 재고관리 모형에서 고객수요가 정규분포를 따른다는 가정 하에 표준정규분포(standard normal distribution)의 CDF(cumulative distribution function)와 단위제품당 재고유지비용( $h$ ), 그리고 단위제품당 재고부족비용( $s$ )에 의해 계산된다[12].  $MAD_t$ 는 주문주기  $t$  기간에서 고객수요의 평균절대편차(mean absolute deviation)를 나타내는 값으로써  $\gamma$ 는  $MAD_t$  값의 변화를 제어하는 역할을 수행하는데 일반적으로  $\gamma$ 의 값은 0.1이 주로 사용된다[16].

$$SafetyStock = z \cdot \hat{\sigma}_t \quad (2)$$

$$\text{단, } z = \Phi^{-1}\left(\frac{s}{s+h}\right),$$

$$\hat{\sigma}_t \approx 1.25 \times MAD_t,$$

$$MAD_t = (1-\gamma)MAD_{t-1} + \gamma |D_{t-1} - \hat{D}_{t-1}|.$$

고객수요가 안정적인 분포를 따르는 경우에는 NB 재고관리 모형이 VMI 환경에서 효과적으로 사용될 수 있다. 그러나 고객수요의 불안정성이 큰 상황에서는 예측된 고객수요의 불확실성을 보정할 수 있는 추가적인 개념이 배송량을 계산할 때 포함되어져야 한다. 본 연구에서는 이를 위해 시간의 흐름

에 따라 불안정하게 변화하는 고객수요를 기반으로 행동-보상 학습에 의해 재고비용을 최소화할 수 있는 보상계수를 선택하고, 선택된 보상계수에 의해 배송량을 적응적으로 조정할 수 있는 방법을 제시한다.

행동-보상 학습을 이용한 보상계수 선택 방법을 설명하기 위해서 우선 주문주기  $t$  기간에서의 보상계수로  $\rho_i$ 가 선택되었다고 가정하면, 주문주기  $t$  기간 초에 공급해야 할 배송량  $Q_t$ 는 식 (3)과 같이 계산되어진다.

$$Q_t = \hat{D}_t + (1 + \rho_i) \cdot \hat{\sigma}_t - I_t \quad (3)$$

본 연구에서는 보상계수( $-1 < \rho_i < 1$ )를 고객수요의 변화에 따라 안전재고의 크기를 보정하는 값으로 정의하였으며, 선택 가능한 보상계수의 집합  $\Theta = \rho_1, \rho_2, \dots, \rho_n$ 는 공급업체와 소매업체의 합의에 의해 결정된다고 가정하였다.

만약 주문주기  $t$  기간( $[t, t+1]$ ) 동안 발생한 실제 고객수요가  $D_t$ 라고 가정하면 주문주기  $t+1$  기간 초의 재고량  $I_{t+1}$ 은  $I_{t+1} = I_t + Q_t - D_t$ 가 되고, 이에 따른 재고비용은 아래와 같이 계산된다. 즉,  $t+1$  기간 초의 재고량  $I_{t+1}$ 에 의해 발생하는 재고비용은  $Q_t$ 에 의해 결정되고,  $Q_t$ 는 보상계수  $\rho_i$ 에 의해 결정되므로  $t+1$  기간 초의 재고비용은  $\rho_i$ 에 의한 함수( $C_{t+1}(\rho_i)$ )로 표현된다.

$$C_{t+1}(\rho_i) = \epsilon \cdot I_{t+1}, \text{ where } \epsilon = \begin{cases} h & \text{if } I_{t+1} \geq 0 \\ s & \text{if } I_{t+1} < 0 \end{cases}$$

위에서 기술한 바와 같이 매 주문주기  $t$  기간에서의 보상계수  $\rho_i$ 를 어떤 값으로 선택하느냐에 따라 재고비용( $C_{t+1}(\rho_i)$ )이 달라지기 때문에 본 연구에서는 행동-보상 학습을 이용하여 재고비용을 최소화할 수 있는 보상계수  $\rho_i$ 를 선택하는 방법을 제시하고자 한다. 본 연구에서 제시하는 행동-보상 학습에서는 식 (4)를 통해 보상계수  $\rho_i$ 에 대한 가중 평균재고비용(weighted mean inventory cost)이 학습되어진다.

$$\overline{C_{t+1}}(\rho_i) = \overline{C}_t(\rho_i) + \beta_t^i [C_t(\rho_i) - \overline{C}_t(\rho_i)] \quad (4)$$

식 (4)에서  $\beta_t^i$ 는 학습모수(learning parameter)로써 행동-보상 학습의 학습속도를 조절하는 역할을 수행한다. 즉, 고객수요의 변화가 급격한 경우에는  $\beta_t^i$ 를 큰 값으로 설정하여 과거보다는 현재의 고객수요 데이터를 많이 반영한 학습을 수행할 수 있도록 하고, 반대로 고객수요가 안정적일 경우에는  $\beta_t^i$ 를 작은 값으로 설정하여 과거와 현재의 고객수요 데이터가 비슷하게 반영된 학습이 수행될 수 있도록 한다. 본 연구에서는 학습모수인  $\beta_t^i$ 를 결정하기 위해 추적신호(tracking signal) 기법을 사용한다. 추적신호 기법은 과거의 데이터와 현재의 데이터를 비교하여 현재 데이터가 과거 데이터에 비해 얼마나 많이 변했는지를 추적하는 기법이다[16]. 추적신호 기법을 이용하는 경우  $\beta_t^i$ 는 식 (5)을 통해 계산될 수 있다.

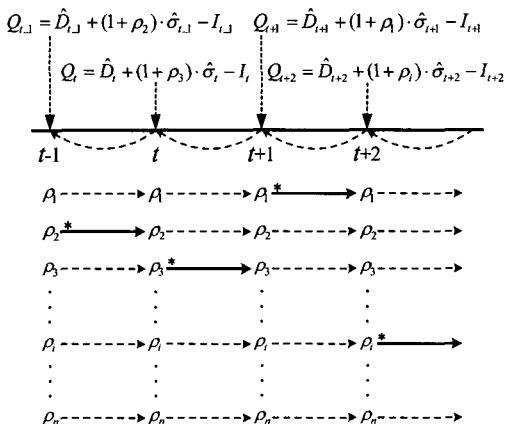
$$\beta_t^i = \left| \frac{MD_t^i}{MAD_t^i} \right| \quad (5)$$

$$\text{단, } MD_t^i = (1 - \gamma) MD_{t-1}^i + \gamma |C_t(\rho_i) - \overline{C}_t(\rho_i)|, \\ MAD_t^i = (1 - \gamma) MAD_{t-1}^i + \gamma |C_t(\rho_i) - \overline{C}_t(\rho_i)|.$$

식 (5)에서  $MD_t^i$ 는 주문주기  $t$  기간에서의 보상계수로  $\rho_i$ 를 선택했을 경우 발생하는 재고비용의 평균편차(mean deviation)를 의미하고,  $MAD_t^i$ 는 평균절대편차(mean absolute deviation)를 의미한다. 또한 추적모수(tracking parameter)인  $\gamma$ 는  $MD_t^i$ 와  $MAD_t^i$  값의 변화를 제어하는 역할을 수행하는데 일반적으로  $\gamma$ 의 값은 0.1이 주로 사용된다[16].

식 (4)에서 기술한 바와 같이 주문주기  $t$  기간에서의 보상계수  $\rho_i$ 에 대한 가중평균재고비용( $\overline{C_{t+1}}(\rho_i)$ )을 학습하기 위해서는 이전 주문주기( $t-1$ )에서 선택 가능한 모든 보상계수들( $\rho_i, i=1, 2, \dots, n$ )에 대한 실제재고비용( $C_t(\rho_i), i=1, 2, \dots, n$ )이 주어져야 한다. 그러나 실제 재고관리 상황에서는 주문주기  $t-1$  기간에서의 가중평균재고비용을 최소화할 수 있는

하나의 보상계수(이하  $\rho^*$ 로 표현한다.)만이 선택되어지기 때문에 다른 보상계수들( $\rho_j \in \Theta - \rho^*$ )에 대한 실제재고비용을 알 수 없다는 문제가 발생한다. 따라서 본 연구에서는 [그림 4]에서 제시한 바와 같은 회귀적 분석 방법(regressive analysis method)을 이용하여 선택 가능한 모든 보상계수에 대한 가중평균재고비용을 학습할 수 있는 방법을 제시한다.



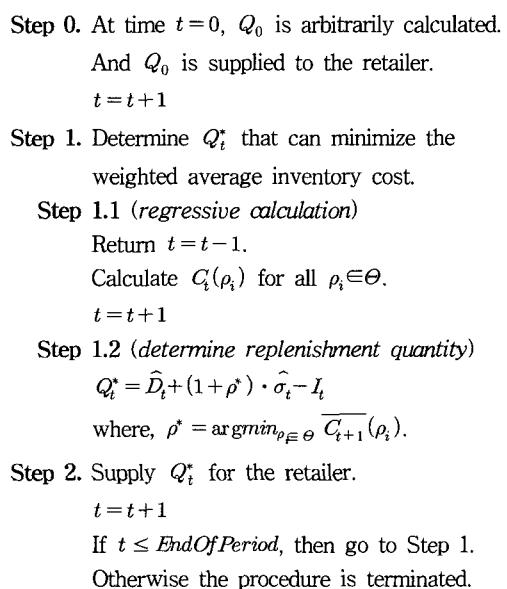
[그림 4] 회귀적 분석 방법

[그림 4]에서 굵은 실선으로 표시된 화살표는 특정 주문주기에서 가중평균재고비용을 최소화할 수 있는 보상계수( $\rho^*$ )로 선택된 것에 대한 실제재고비용을 계산하는 것을 의미하고, 점선으로 표시된 화살표는 선택되지 않은 나머지 보상계수( $\rho_j \in \Theta - \rho^*$ )들에 대한 가중평균재고비용을 학습하기 위해 이전 주문주기 시점으로 회귀하여 각각의 보상계수에 대한 실제재고비용을 계산하는 것을 의미한다.

예를 들어, 주문주기 t 기간의 배송량  $Q_t$ 를 결정하기 위해서는 식 (4)에서 제시한 가중평균재고비용( $\overline{C_{t+1}}(\rho_i)$ )이 최소화 될 수 있는 보상계수  $\rho^*$  ( $\rho^* = \operatorname{argmin}_{\rho_i \in \Theta} \overline{C_{t+1}}(\rho_i)$ )가 선택되어져야 한다. 선택 가능한 모든 보상계수  $\rho_i \in \Theta$ 에 대한 가중평균재고비용  $\overline{C_{t+1}}(\rho_i)$ 을 학습하기 위해서는  $C_t(\rho_i)$ 를 알고 있어야 하는데,  $C_t(\rho_i)$ 는 주문주기 t-1 기간의 배송량( $Q_{t-1}$ )과 주문주기 t-1 기간동안의 실제재고

객수요( $D_{t-1}$ )에 의해 계산되어진다. 그러나 [그림 4]에서 나타낸 바와 같이 주문주기 t-1 기간의 보상계수로  $\rho^* = \rho_2$ 가 선택되어지고 이를 기반으로 배송량  $Q_{t-1}$ 이 결정되어졌기 때문에 보상계수  $\rho_2$ 에 대한 실제재고비용( $C_t(\rho_2)$ )은 계산할 수 있지만 나머지 보상계수( $\rho_j \in \Theta - \rho_2$ )에 대한 실제재고비용( $C_t(\rho_j)$ )은 계산할 수 없다. 따라서 본 연구에서는 주문주기 t-1 기간 동안의 실제고객수요( $D_{t-1}$ )를 알 수 있는 주문주기 t 시점에서 가상으로 주문주기 t-1 시점으로 회귀하여, 나머지 보상계수들( $\rho_j \in \Theta - \{\rho_2\}$ )이 선택되어졌다고 가정하고 배송량  $Q_{t-1}$ 을 계산한 후 이를 바탕으로 모든 보상계수들에 대한 실제재고비용  $C_t(\rho_j)$ 를 계산한다. [그림 4]는  $Q_t$ 를 결정하기 위한 보상계수로써  $\rho^* = \rho_3$ 가 선택되어졌음을 나타내고 있으며, 추후  $Q_{t+1}$ 을 결정하기 위한 보상계수를 선택하기 위해서는 위에서 기술한 회귀적 분석 방법이 다시 적용되어져야 한다.

회귀적 분석 방법에 의해 주문주기 t 기간의 배송량  $Q_t$ 를 결정하는 구체적인 절차는 [그림 5]와 같다.



[그림 5] 배송량( $Q_t$ ) 결정 절차

### 3. 실험 및 결과 분석

#### 3.1 시뮬레이션 환경 설정

본 연구에서 제시한 적응형 VMI 모형의 성능을 평가하기 위해 시뮬레이션을 이용하여 NB 재고관리 모형과의 비교를 수행하였다. <표 1>은 시뮬레이션을 통해 성능을 비교할 4가지 재고관리 모형을 나타내고 있다.

<표 1> 재고관리 모형

재고관리 모형	고객수요 예측 방법
AVMI(EXPO)	지수평활법(exponential smoothing method) ( $\alpha = 0.1$ )
NB(EXPO)	지수평활법(exponential smoothing method) ( $\alpha = 0.1$ )
AVMI(MA)	이동평균법(moving average Method) ( $N=4$ )
NB(MA)	이동평균법(moving average method) ( $N=4$ )

<표 1>에서 AVMI로 표현된 모형은 본 연구에서 제시한 적응형 VMI(adaptive VMI) 모형을 의미하고 NB로 표현된 모형은 NB 재고관리 모형을 의미한다. 또한 팔호안의 EXPO와 MA는 각각 고객수요를 예측하기 위해 지수평활법과 이동평균법이 사용되었음을 나타내고 있다.

시간의 흐름에 따라 불안정하게 변화하는 고객수요는 펄스 형태와 슬로프 형태로 가정하였으며, 각각의 고객수요 형태에 대한 설정은 <표 2>와 <표 3>에 기술하였다.

<표 2> 펄스 형태의 고객수요

	$T$	Mean	CV
Case I	$T = U(0,30)$	$Mean = U(50,90)$	0.05
Case II	$T = U(0,20)$	$Mean = U(50,90)$	0.10

<표 3> 슬로프 형태의 고객수요

	$T$	Slope	CV
Case III	$T = U(0,30)$	$Slope = U(-1,1)$	0.05
Case IV	$T = U(0,20)$	$Slope = U(-2,2)$	0.10

공급업체와 소매업체의 협상에 의해 결정되는 보상계수 집합( $\Theta = \rho_1, \rho_2, \dots, \rho_n$ )은  $\{-0.25, -0.20, -0.15, -0.10, -0.05, 0, 0.05, 0.10, 0.15, 0.20, 0.25\}$ 라고 가정하였다.

각각의 재고관리 모형에 대한 실험은 3000 기간의 주문주기 동안 수행하였으며 실험의 안정화 기간(transient period)을 100 기간으로 설정하였다. 그리고 각각의 재고관리 모형에 대한 평균재고비용(average inventory cost)은 20회의 실험을 통해 산출된 재고비용들의 평균으로 계산하였다. 재고비용을 계산하기 위해 필요한 단위제품당 재고유지비용( $h$ )과 재고부족비용( $s$ )은 보편적으로 많이 사용되는 1:1 비율과 1:10 비율, 그리고 1:20 비율 3가지로 설정하였다[12].

#### 3.2 실험결과

##### 3.2.1 펄스 형태의 고객수요

펄스 형태의 고객수요는 고객수요 분포의 평균(Mean)과 표준편차(SD)가 무작위로 추출된 주기( $T$ )마다 무작위로 변화하는 특징을 지닌다. 본 연구에서는 펄스 형태의 고객수요를 <표 2>에서 기술한 바와 같이 두 가지 경우(Case I과 Case II)로 가정하여 실험을 수행하였다. Case II는 Case I에 비해 고객수요 분포의 평균과 분산이 변화하는 주기가 짧고 CV 값이 크게 설정된 경우로써 고객수요의 불안정성을 높인 설정이다.

펄스 형태의 고객수요를 기반으로 <표 1>에서 제시한 4가지 재고관리 모형에 대한 실험을 수행한 결과는 <표 4>와 같다. <표 4>는 Case I과 Case II에 대한 실험결과를 재고유지비용과 재고부족비용의 비율( $h:s$  ratio)에 따라 정리한 것으로써, Case II의 경우 고객수요의 불안정성이 Case I에 비해 높기 때문에 모든 재고관리 모형에서 평균재고비용이 상대적으로 증가한 것을 알 수 있다. 또한 모든 재고관리 모형에서  $h:s$  ratio가 커질수록(예를 들어 1:20) 평균재고비용이 증가하는 것을 알 수 있는데, 이는 재고부족비용( $s$ )이 상대적으로 크게 설정되었

기 때문으로 해석할 수 있다.

<표 4>에서 네 번째 열(column)에 나타낸 값은 20회의 실험을 통해 산출된 재고비용들의 평균을 나타내고, 다섯 번째 열과 여섯 번째 열은 각각 20회의 실험을 통해 산출된 재고비용들 중에서 최소값과 최대값을 나타낸다. 그리고 마지막 열에 나타낸 값은 본 연구에서 제시한 적응형 VMI 모형(AMVI)을 적용하였을 경우 NB 재고관리 모형(NB)에 비해 줄일 수 있는 평균재고비용의 비율(inventory cost reduction ratio)을 나타낸다.

<표 4>를 통해 알 수 있듯이 Case I과 Case II 모두에 대해 본 연구에서 제시한 적응형 VMI 모

형이 NB 재고관리 모형에 비해 평균재고비용이 작은 효율적인 재고관리 모형임을 알 수 있다. 그리고 모든 재고관리 모형에 대해 이동평균법(MA)을 이용하여 고객수요를 예측하는 것이 지수평활법(EXPO)을 이용하여 고객수요를 예측하는 것에 비해 평균재고비용을 줄일 수 있는 효율적인 방법임을 알 수 있다. 결론적으로 펠스 형태의 고객수요를 갖는 공급사슬에서는 본 연구에서 제시한 적응형 VMI 모형을 이용하여 재고관리를 수행하고 이동평균법을 이용하여 고객수요를 예측하는 것(AMVI(MA))이 가장 효율적인 재고관리 방법임을 알 수 있다.

〈표 4〉 펠스 형태의 고객수요에 대한 시뮬레이션 결과

Case	h:s ratio	재고관리 모형	재고비용(inventory cost)			재고비용 감소비율
			평균값	최소값	최대값	
Case I $T = U(0,30)$ $CV = 0.05$	1:1	AVMI(EXPO)	6.9011	6.4293	7.2743	6.3636%
		NB(EXPO)	7.3701	6.8478	7.7225	
		AVMI(MA)	5.2843	5.0754	5.4840	1.0542%
		NB(MA)	5.3406	5.1311	5.4760	
	1:10	AVMI(EXPO)	15.5726	14.3774	16.5462	8.6871%
		NB(EXPO)	17.0541	15.7935	17.7636	
		AVMI(MA)	13.1609	12.5341	13.6905	3.5676%
		NB(MA)	13.6478	12.8302	14.2419	
	1:20	AVMI(EXPO)	22.4106	20.4578	23.8570	10.3504%
		NB(EXPO)	24.9980	23.0738	26.1360	
		AVMI(MA)	19.4266	18.4303	20.3387	6.6751%
		NB(MA)	20.8161	19.4043	21.8589	
Case II $T = U(0,20)$ $CV = 0.10$	1:1	AVMI(EXPO)	9.7935	9.4017	10.2379	5.2578%
		NB(EXPO)	10.3370	9.5634	10.9707	
		AVMI(MA)	8.8968	8.4966	9.2031	0.3294%
		NB(MA)	8.9262	8.7149	9.1810	
	1:10	AVMI(EXPO)	22.5497	21.4749	23.6332	8.2450%
		NB(EXPO)	24.5760	20.7536	22.0704	
		AVMI(MA)	20.6022	19.2533	21.7013	4.5133%
		NB(MA)	21.5760	20.7536	22.0704	
	1:20	AVMI(EXPO)	32.1837	30.3343	34.1256	9.5676%
		NB(EXPO)	35.5887	32.0247	37.7670	
		AVMI(MA)	28.9939	26.8095	30.8903	9.8575%
		NB(MA)	32.1645	30.7425	33.1016	

### 3.2.2 슬로프 형태의 고객수요

슬로프 형태의 고객수요는 고객수요 분포의 평균(Mean)과 표준편차(SD)가 무작위로 추출된 주기( $T$ )마다 일정한 기울기(Slope)를 가지고 변화하는 특징을 지닌다. 본 연구에서는 슬로프 형태의 고객수요를 <표 3>에서 기술한 바와 같이 두 가지 경우(Case III과 Case IV)로 가정하여 실험을 수행하였다. Case IV는 Case III에 비해 고객수요 분포의 평균과 분산이 변하는 주기가 짧고, 고객수요 분포의 평균이 변화하는 기울기와  $CV$  값이 크게 설정된 경우로써 고객수요의 불안정성을 높인 설정이다.

슬로프 형태의 고객수요를 기반으로 <표 1>에서

제시한 4가지 재고관리 모형에 대한 실험을 수행한 결과는 <표 5>와 같다. <표 5>는 Case III과 Case IV에 대한 실험결과를  $h:s$  ratio에 따라 정리한 것으로써, Case IV의 경우 고객수요의 불안정성이 Case III에 비해 높기 때문에 모든 재고관리 모형에서 평균재고비용이 상대적으로 증가한 것을 알 수 있다. 또한 Case III과 Case IV 모두에 대해 본 연구에서 제시한 적용형 VMI 모형이 NB 재고관리 모형에 비해 평균재고비용이 작은 효율적인 재고관리 모형임을 알 수 있다. 결론적으로 슬로프 형태의 고객수요를 갖는 공급사슬에서도 펄스 형태의 고객수요를 갖는 경우와 마찬가지로 본 연구에서 제시

<표 5> 슬로프 형태의 고객수요에 대한 시뮬레이션 결과

Case	h:s ratio	재고관리 모형	재고비용(inventory cost)			재고비용 감소비율
			평균값	최소값	최대값	
Case III $T = U(0,30)$ $Slope = U(-1,1)$ $CV = 0.05$	1:1	AVMI(EXPO)	3.4836	3.2537	3.7501	5.2365%
		NB(EXPO)	3.6761	3.4705	3.9927	
		AVMI(MA)	2.9963	2.9124	3.0844	2.5974%
		NB(MA)	3.0762	2.9714	3.1481	
	1:10	AVMI(EXPO)	7.3675	7.0094	7.8280	13.0504%
		NB(EXPO)	8.4733	7.9353	9.0309	
		AVMI(MA)	6.8833	6.7400	7.0350	0.7054%
		NB(MA)	6.9322	6.6495	7.2238	
	1:20	AVMI(EXPO)	10.1159	9.6708	10.7625	18.5469%
		NB(EXPO)	12.4193	11.5681	13.1011	
		AVMI(MA)	9.4207	9.1556	9.6734	5.9501%
		NB(MA)	10.0167	9.5678	10.5308	
Case IV $T = U(0,20)$ $Slope = U(-2,2)$ $CV = 0.10$	1:1	AVMI(EXPO)	6.5055	6.3300	6.7380	3.5193%
		NB(EXPO)	6.7428	6.4564	7.1472	
		AVMI(MA)	6.0981	5.9404	6.3176	2.5956%
		NB(MA)	6.2606	6.1100	6.4426	
	1:10	AVMI(EXPO)	14.5545	14.0374	15.0065	7.9423%
		NB(EXPO)	15.8102	15.0872	16.9726	
		AVMI(MA)	14.1436	13.7373	14.9845	0.0608%
		NB(MA)	14.1522	13.5790	14.5881	
	1:20	AVMI(EXPO)	20.3371	19.6114	21.0162	12.8069%
		NB(EXPO)	23.3242	22.1804	25.1869	
		AVMI(MA)	19.4162	18.8672	20.9597	5.1318%
		NB(MA)	20.4665	19.3489	21.3945	

한 적응형 VMI 모형을 이용하여 재고관리를 수행하고 이동평균법을 이용하여 고객수요를 예측하는 것(AVMI(MA))이 가장 효율적인 재고관리 방법임을 알 수 있다.

<표 4>와 <표 5>의 실험결과를 통해 슬로프 형태의 고객수요를 갖는 공급사슬에서의 평균재고비용이 펄스 형태의 고객수요를 갖는 공급사슬에서의 평균재고비용보다 작다는 것을 알 수 있는데, 이는 슬로프 형태의 고객수요가 펄스 형태의 고객수요에 비해 상대적으로 작은 불안정성을 지니고 있기 때문에 모든 재고관리 모형에서 상대적으로 정확한 배송량을 산출할 수 있었던 것으로 해석할 수 있다.

#### 4. 결 론

본 연구에서는 고객수요가 불안정하게 변화하는 2단계 공급사슬에서 효율적인 재고관리를 수행하기 위한 방법으로 공급업체가 소매업체를 대상으로 미리 설정된 주문주기마다 공급해야 할 재고량을 고객수요의 변화에 따라 적응적으로 제어할 수 있는 적응형 VMI 모형을 제시하였다. 본 연구에서 제시한 적응형 VMI 모형은 고객수요의 변화에 따라 배송량을 적응적으로 제어하기 위해 재고수준 샘플 경로를 기반으로 행동-보상 학습을 이용하여 매 주문주기마다 재고비용을 적응적으로 줄여나갈 수 있는 보상계수를 선택하는 방법을 제시하였다.

본 연구에서 제시한 적응형 VMI 모형의 성능을 평가하기 위해 2가지 형태(펄스 형태, 슬로프 형태)의 불안정한 고객수요를 갖는 공급사슬을 대상으로 시뮬레이션을 수행한 결과 본 연구에서 제시한 적응형 VMI 모형이 NB 재고관리 모형에 비해 평균 재고비용이 작은 효율적인 모형임을 알 수 있었다.

추후 연구과제로는 본 연구에서 제시한 적응형 VMI 모형을 다단계(multi-echelon) 공급사슬로 확장하여 적용할 수 있는 방법에 대한 연구와 보다 현실적인 상황에서의 문제 해결을 위해 배송시간이 주문주기에 포함되지 않은 경우에도 적용될 수 있는 모형에 대한 연구가 필요하다고 판단된다.

#### 참 고 문 헌

- [1] Achabal, D.D., S.H. McIntyre, S.A. Smith, and K. Kalyanam, "A Decision Support System for Vendor Managed Inventory," *Journal of Retailing*, Vol.76, No.4(2000), pp.430-454.
- [2] Andersson, J., S. Axsater, and J. Marklund, "Decentralized Multi-echelon Inventory Control," *Production and Operations Management*, Vol.7, No.4(1998), pp.370-386.
- [3] Axsater, S., "A framework for decentralized multi-echelon inventory control," *IIE Transactions*, Vol.33, No.2(2001), pp.91-97.
- [4] Disney, S.M. and D.R. Towill, "The effect of vendor managed inventory (VMI) dynamics on the Bullwhip Effect in supply chains," *International Journal of Production Economics*, Vol.85, No.2(2003), pp.199-216.
- [5] Gavirneni, S. and S. Tayur, "An efficient procedure for non-stationary inventory control," *IIE Transactions*, Vol.33(2001), pp.83-89.
- [6] Graves, S.C., "A Single-Item Inventory Model for a Non-Stationary Demand Process," *Manufacturing and Service Operations Management*, Vol.1, No.1(1999), pp.50-61.
- [7] Kaipia, R., J. Holmstrom, K. Tanskanen, "VMI : What are you losing if you let your customer place orders?," *Production Planning and Control*, Vol.13, No.1(2002), pp.17-25.
- [8] Lee, H.L., V. Padmanabhan, and S. Whang, "Information Distortion in Supply Chain : The Bullwhip Effect," *Management Science*, Vol. 43, No.4(1997), pp.546-558.
- [9] Lee, H.L., K.C. So, and C.S. Tang, "The Value of Information Sharing in a Two-Level Supply Chain," *Management Science*, Vol.46, No.5 (2000), pp.626-643.

- [10] Mitchell, T.M., *Machine Learning*, McGraw-Hill, 1997.
- [11] Moinzadeh, K., "A Multi-Echelon Inventory System with Information Exchange," *Management Science*, Vol.48, No.3(2002), pp.414-426.
- [12] Nahmias, S., *Production and Operations Analysis*, McGraw-Hill, 2000.
- [13] Patel, N.S. and S.T. Jenkins, "Adaptive Optimization of Run-To-Run Controllers : The EWMA Example, *IEEE Transactions on Semiconductor Engineering*, Vol.13, No.1(2000), pp.97-107.
- [14] Simchi-Levi, D., P. Kaminsky, and E. Simchi-Levi, *Designing and Managing the Supply Chain*, McGraw-Hill, 2000.
- [15] Sutton, R.S. and A.G. Barto, *Reinforcement Learning*, MIT Press, 1998.
- [16] Trigg, D.W. and A.G. Leach, "Exponential smoothing with an adaptive response rate," *Operational Research Quarterly*, Vol.18, No.1 (1967), pp.53-59.