

# 클라우드 컴퓨팅 환경에서 빅데이터 처리를 위한 ART 기반의 적응형 자원관리 방법

조규철\* · 김재권

## Adaptive Resource Management Method base on ART in Cloud Computing Environment

Kyucheol Cho\* · JaeKwon Kim

### ABSTRACT

The cloud environment need resource management method that to enable the big data issue and data analysis technology. Existing resource management uses the limited calculation method, therefore concentrated the resource bias problem. To solve this problem, the resource management requires the learning-based scheduling using resource history information. In this paper, we proposes the ART (Adaptive Resonance Theory)-based adaptive resource management. Our proposed method assigns the job to the suitable method with the resource monitoring and history management in cloud computing environment. The proposed method utilizes the unsupervised learning method. Our goal is to improve the data processing and service stability with the adaptive resource management. The propose method allow the systematic management, and utilize the available resource efficiently.

**Key words** : Cloud Computing, Big Data, ART (Adaptive Resonance Theory), Adaptive resource management

### 요 약

클라우드 환경은 빅데이터의 이슈와 데이터 분석을 가능하게 하는 기술로서, 이를 위한 자원 관리 기법이 필요하다. 현재까지의 자원관리 기법은 한정된 계산 방법을 이용하여 자원의 편중의 문제점이 있으며, 이를 해결하기 위해서 자원관리는 자원인력 정보를 활용한 학습기반의 스케줄링이 필요하다. 본 논문에서는 ART(Adaptive Resonance Theory)기반의 적응형 자원관리 기법을 제안한다. 제안하는 기법은 클라우드환경에서 모니터링 및 자원인력을 이용하여 작업의 적합한 할당이 가능하다. 제안하는 방법은 무감독 학습방법을 사용하며, 적응형 자원 관리를 통하여 서비스의 안정성과 데이터 처리성능을 향상시키는 것을 목적으로 한다. 제안하는 방법은 체계적인 자원관리가 가능하고 가용자원을 효율적으로 활용하여 요구 성능을 향상시킬 수 있다는 장점이 있다.

**주요어** : 클라우드 컴퓨팅, 빅데이터, ART(Adaptive Resonance Theory), 적응형 자원관리

## 1. 서 론

빅 데이터의 이슈와 데이터의 분석에 대한 중요성이 대두되고 있으며, 이를 처리하기 위해 ICT 기술을 사용한다.

이러한 빅 데이터 분석을 위한 클라우드 컴퓨팅은 가상환경에서 대용량 데이터 처리를 할 수 있는 인프라 환경을 제공한다(Espadas et al., 2013).

클라우드 컴퓨팅은 인터넷 환경에서의 서비스 지향의 분산 컴퓨팅 환경으로서, 가상 인프라 자원의 구성환경이 중요하다(Divyakant et al., 2011). 클라우드 컴퓨팅의 자원 인프라를 활용하는 IaaS(Infra as a Service)의 원활한 서비스 제공과 QoS의 보장 그리고 비용의 최소화를 위해서는 분산컴퓨팅 방식의 자원관리 기법이 중요하여 이를 해결하기 위한 연구가 진행 중이다(Kim et al., 2013).

**Received:** 23 July 2014, **Revised:** 28 September 2014,  
**Accepted:** 4 December 2014

\***Corresponding Author:** Kyucheol Cho

E-mail: kecho@etri.re.kr

Electronics and Telecommunications Research Institute

클라우드 환경에서 분산컴퓨팅은 여러 가상 자원과 물리자원을 하나의 클러스터로 묶어 고성능 컴퓨팅 단위로 구성하여 대용량 데이터를 처리할 수 있는 기술이다. 대용량 데이터 처리 서비스는 프로세스 결과와 통계적인 정보, 그리고 데이터의 성격에 대한 인터페이스로 운영되고 있다. 특히, 계층구조 형태의 데이터는 메타데이터와 표준 데이터뿐만 아니라 응용 프로세스 결과를 관리하기 위한 목적으로 활용되고 있다. 이러한 데이터는 클라우드 컴퓨팅 환경에서 할당된 자원들의 지식 및 정보전달의 구조로 활용될 수 있으며, 각 자원이 보유한 정보를 공유함으로써 협업을 통해 작업을 가능하게 한다(Thompson et al., 1994). 위와 같은 강점으로 고성능 컴퓨팅 성능이 요구되는 응용 도메인에서는 클라우드 컴퓨팅의 가상 자원 활용에 대한 아키텍처의 필요성과 요구사항이 증가하고 있다.

클라우드 컴퓨팅 환경에서는 가상자원을 활용하여 성능의 극대화와 QoS의 보장을 위해서는 요구하는 서비스의 특성과 역할에 맞는 작업할당 방법이 필요하다. 기존의 방법들은 자원의 CPU, RAM, Net I/O의 성능에 따라서 자원을 할당했으며, 이는 자원의 편중을 가져올 수 있다. 따라서 학습기법 기반의 스케줄링이 필요하며 자원의 이력상황에 적응할 수 있는 스케줄링이 필요하다(Chalmers et al., 2002).

본 논문에서는 자원의 관리뿐만 아니라 자원의 현황 파악, 모니터링 및 이력관리를 통해 최적의 자원을 각 작업별로 할당하는 방법으로 ART(Adaptive Resonance Theory)(Carpenter et al., 1988)기반의 적응형 자원관리기법을 제안한다. 제안하는 방법은 무감독 학습방법을 사용하며 동적 자원 관리기법을 통하여 서비스의 안정성과 데이터 처리성능을 향상시키는 것을 목적으로 한다.

제안된 기법에 대한 성능을 실험하기 위해, 클라우드 컴퓨팅 환경에서 대용량데이터 처리를 위한 적응형 자원관리와 혼합형 데이터 분류시스템 모델을 구현하였다. 또한 적응형 자원관리의 성능을 평가하기 위해 리스트 기반 동적 자원관리, 응답시간 기반 자원관리기법에 대한 데이터 처리시간 및 자원 활용률을 비교하여 본 논문의 우수성을 검증한다.

## 2. 관련 연구

### 2.1 자원관리 고려사항

클라우드 컴퓨팅 환경은 네트워크를 활용하여 신뢰성과 자원의 효율적인 관리를 위해 체계적인 분산처리 방법이 필수적이다. 분산처리는 부하분산 및 유기적인 작업수

행의 확장성과 안정성을 보장하는 유연한 구조를 갖기 위해, 시스템이 커질수록 에이전트에게 역할의 분산화와 위임기술을 적용한다(Jeffrey et al. 2008). QoS(Quality of Service)는 서비스기반 분산컴퓨팅환경에서 서비스 질을 향상시키는 중요한 요소로써, 자원예약을 통해 향상된 QoS를 보증하기 위한 효과적인 메커니즘으로 알려졌다. 또한 SLA(Service Level Agreements)와 프로토콜 프로세스는 자원 소유주와 시간간격에 대한 협상으로 자원을 관리하는 프로토콜을 언급하고 있다. SNAP(Service Negotiation and Acquisition Protocol)는 자원의 활용보다는 시간관리와 자원활동에 중점을 두고 프로토콜을 사용하며, 단일 작업을 수행할 수 있는 최적의 메시지를 생성하여 원격 SLA 메시지를 통한 서비스를 제공한다.

서비스의 질을 향상시킬 수 있는 자원을 제공하기 위해, 자원클러스터를 이용하여 동일한 자원형태와 선호하는 유용성 있는 자원을 생성한 후 이를 백업하여 사용한다. 이러한 다중 자원 예약(Georgiopoulos et al., 1991)은 자원예약을 위한 우선순위기반의 방법(Baxt, 1995)으로 동적 자원 할당을 통해 성능을 보장하고 있다. 위와 같이 고성능 작업을 수행하기 위해서 분산컴퓨팅환경을 구성을 통해 협업 환경을 만들어야 한다. 또한 운영 자원들을 동적으로 관리하여 작업을 할당할 때에는 자원의 상태를 고려해야 한다.

클라우드 환경에서 대용량 데이터 처리는 고성능 작업수행을 실현함에 있어 가용자원 구성의 복잡성 및 상호운영을 위한 유연성뿐만 아니라 다양한 요소를 고려해야 하므로, 기존의 자원할당기법을 해결할 수 있는 자원관리기법이 요구되고 있다. 본 논문에서는 자원의 현황을 관리, 작업수행 모니터링, 서비스 처리결과에 대한 이력관리를 고려하여 새로운 자원관리기법에 적용한다.

### 2.2 ART 기반 자원관리 방법

Fig. 1은 적응형 자원관리에서 자원 클러스터를 ART(Adaptive Resonance Theory)기법을 이용하여 구성하는 방법이다.

ART는 신경망 모델 중에서 한가지로서, 무감독 학습 방법이며, 과거의 학습정보를 잊어버리지 않고, 새로운 정보를 쉽게 학습 할 수 있는 기법이다.

클라우드 환경에서 ART의 접목은 비용 절감에 대한 효과를 얻을 수 있다. Gopalakrishnan et al.(2011)은 비용의 최소화를 위해서 ART기반의 무감독 학습방법을 이용하여, 미리 자원할당 전략을 세워 자원 군집과 자원할당에 따르는 비용을 최소화하였다. 하지만, 비용에 따라서

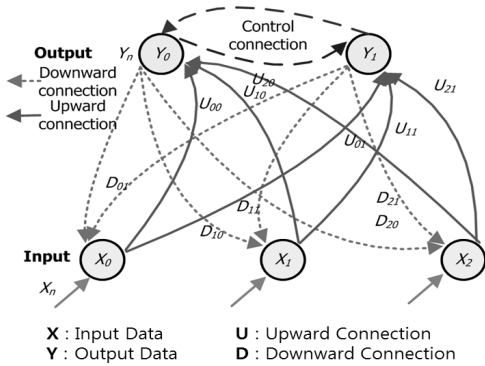


Fig. 1. ART based adaptive resource management

자원을 할당하는 서비스중심의 스케줄링의 비용을 더욱 최소화하기 위해서는 성능기반의 자원관리 스케줄링 기법이 필요하다. 따라서 본 논문에서는 무감독학습방법인 ART기반의 성능 중심의 스케줄링 방법을 이용한다.

ART기법을 3개의 입력 노드와 2개의 출력 노드를 사용한 예로, 이진입력이 제시되면 자원 분류작업이 진행되어 단지 하나의 출력만 반응하게 된다(Carpenter et al., 1988). ART기법은 2개의 층으로 이루어져 있으며, 입력과 출력 사이에는 상향에 대한 양방향 연결(U<sub>mn</sub>)과 하향에 대한 양방향 연결(D<sub>mn</sub>)이 있다. 또한 출력에는 자원 클러스터 제어에 관한 연결이 형성되어 있고, 출력되는 자원 클러스터 중에서 최대값을 출력한 클러스터를 유도해 내는 역할을 한다. D<sub>mn</sub>와 U<sub>mn</sub>는 n개 클러스터의 대표패턴을 기억하고, 입력 벡터 X에 가장 유사한 대표 입력 데이터를 기억하여 출력한다. 여기서 입력 벡터 X가 새로운 클러스터의 패턴인 경우에도 출력 유닛 중에서 반드시 하나의 최대값이 선정된다.

### 3. 동적 자원구성을 위한 적응형 자원관리

가상자원을 활용하여 서비스 성능을 높여야 하기 때문에 서비스 특성에 맞는 적당한 자원을 효율적으로 할당해야 한다. 이를 해결하기 위한 방법으로 클라우드 환경에서 데이터 처리를 위한 서비스 환경 구성과 적응형 자원관리를 통해 자원을 할당하는 방법에 대하여 서술 한다.

#### 3.1 적응형 자원관리 방법

단일 서비스를 제공하기 위한 자원 할당은 최적의 성능을 제공할 수 있는 자원을 높은 우선순위로 하여 선택한다. 하지만 서비스 클러스터를 구성하기 위한 여러가지

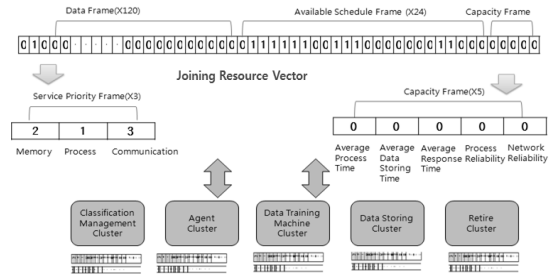


Fig. 2. Resource cluster of management method

패턴의 서비스를 제공하기 위해서는 자원의 성능이외에도 서비스 최적화와 더불어 서비스에 맞는 자원과 자원의 지원환경을 고려해야 한다(Divyakant et al., 2011).

적응형 자원관리는 2단계로 진행된다. 첫 번째 단계는 참여자원이 사용자 요구에 맞는 가상자원을 검증하는 단계이다. 가상자원이 보유한 성능(CPU, RAM, Net I/O, Net Download, Net Upload, Data Storage, Authority)에 따른 것으로, 처리해야하는 데이터 크기에 따라서 일정한 성능 이상인 자원들을 여과하며 두 번째 단계로 진행된다.

두 번째 단계는 Fig. 2와 같이 가상자원이 보유한 성능 및 정보를 ART기법에 적용하기 위해, 자원정보를 데이터화하여 서비스관리를 위한 대표 클러스터와 비교한다.

적응형 자원관리에서 사용되는 ART을 다음과 같이 정의한다. 입력데이터(x), 특징데이터 vector(w<sub>m</sub>)라고 할 경우, 식 (1)과 같이 표현할 수 있다.

$$\begin{aligned} y_m^0 &= w_m^t X \\ y^{k+1} &= \Gamma[w_m y^k] \\ y^0 &= w_x \end{aligned} \tag{1}$$

Eq. (1). Define of Input data and vector

데이터를 서비스 자원군에 위치시키는 절차에서 임계값을 ρ라고 할 때, n조(n-tuple)의 입력데이터와 최고층(top-layer)의 데이터 값을 매트릭스 w, v로 정의하여 식 (2)와 같이 초기화한다. 이진 단극의 입력데이터 x에 대한 모든 자원 정보데이터의 유사성을 검사한 결과는 식 (3)과 같다. 대표 자원클러스터(j)에 대해 자원정보 데이터 유사성을 검증하기 위해 식 (4)와 같이 수행한다.

$$W = \left[ \frac{1}{1+n} \right], V = [1], 0 < p < 1 \tag{2}$$

Eq. (2). Initial of W, V

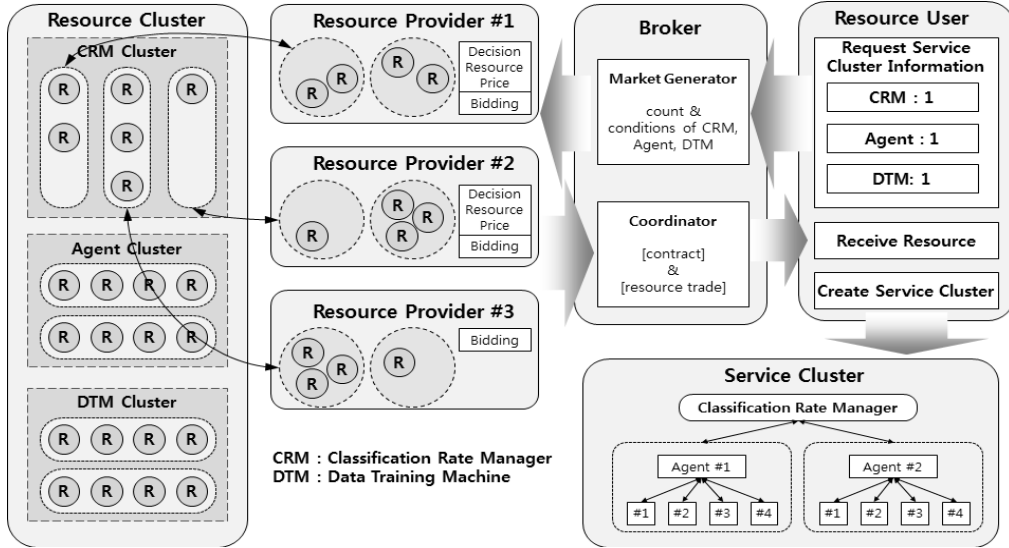


Fig. 3. Resource job allocation for service negotiation model

$$y_j^0 = \sum_{i=0}^n W_{ij}x_i = \max(m) \left( \sum_{i=1}^n W_{im}x_i \right) \quad (3)$$

m= 1, 2, ..., M

Eq. (3). Similarity result the all of the resource data

$$y_j^0 = \sum_{i=0}^n W_{ij}x_i = \max(m) \left( \sum_{i=1}^n W_{im}x_i \right) \quad (4)$$

Eq. (4). Similarity verification the resource cluster

가중치값을 색인중인 j는 증가시키며, 소속된 서비스자원클러스터 결과를 테스트함으로 입력 데이터벡터(i,j)의 가중치는 식 (5)와 같이 계산함으로써 서비스 자원클러스터 소속에 대한 정확성을 판단할 수 있다.

무감독학습을 통한 자원관리는 수식 (4)와 (5)에서 자원정보가 소속되고자하는 서비스자원클러스터에 가장 근접한 클러스터에 소속되고 weight(W)값을 갱신하여 훈련함으로써 서비스 클러스터의 특성을 유지시킨다.

$$W_{ij}(t+1) = \frac{v_{ij}(t)x_i}{0.5 + \sum_{i=1}^n v_{ij}(t)x_i} \quad (5)$$

$$v_{ij}(t+1) = x_i v_{ij}(t)$$

Eq. (5). Accuracy verification of Resource Cluster

### 3.2 자원할당 방법

가상자원은 적응형 자원관리를 통해 자원군집으로 구성된다. 이러한 가상자원에게 역할에 맞는 작업을 할당하기 위해서는 자원할당 전략이 필요하다. 또한 작업특성을 고려하여 자원군집 내의 모든 보유자원은 자원제공자의 제공전략에 따라 할당할 필요가 있다.

Fig. 3은 사용자(Resource User)가 서비스 클러스터를 구성하기 위해, 필요한 자원을 공급자(Resource Provider)로부터 수급 받는 서비스 협상모델 절차를 표현한 것이다. 사용자는 중개자(Broker)에게 서비스 클러스터를 구성하기 위해 필요한 자원의 정보를 전달한다. 이때 자원의 정보는 서비스 클러스터(Service Cluster)의 역할과 작업수행을 위한 요구 성능을 같이 정보화하여 요청한다.

제안하는 적응형 자원관리는 서비스 협상모델에 적용할 수 있도록 입찰/계약 모델을 이용한다. 사용자의 자원 요구에 맞추어 각 공급자들은 거래를 성사시키기 위해 자원 공급 능력에 따라 가격을 결정하여 입찰한다. 중개자는 자원 공급자에게 사용자의 자원요청 정보를 전달하고, 공급자의 가격입찰을 위한 시장을 개설한다. 공급자는 중개자로부터 수신한 정보를 바탕으로 자원클러스터(Resource Cluster)에서 자신의 소유한 자원에 대한 가격을 분류비율 관리자(Classification Rate Manager), 에이전트(Agent), 데이터 훈련 머신(Data Training Machine)에 대해서 각각 가격을 책정하여 입찰한다. 중개자는 공급자가 입찰한 가격에 대해서 조건에 맞는 자원과 수량을 결정하고 사용




Fig. 4. Resource demand prediction in Bayesian Network Model

자에게 최저가에 입찰한 공급자와 연결해준다. 이를 통해 사용자는 낙찰된 가격으로 각 자원들을 서비스 클러스터로 구성할 수 있게 된다. 이때 서비스 클러스터에 소속된 자원들은 사용자가 요청한 조건에 맞는 자원들로 구성되어 있으므로, 각 역할에 최적화된 자원으로 서비스를 제공할 수 있는 것이다.

이 모델에서 공급자는 데이터 분류 시 예상 처리시간의 추이를 분석하여 자원 요구를 예측함으로써, 공급가격을 결정하여 사용자에게 보유자원을 제공한다.

Fig. 4는 예상 처리시간을 통해 공급가격을 책정하기 위해 Bayesian Network(Jensen, 1996)를 이용하여 추론 전개과정을 표현한 그림이다.

자원 공급자는 시장 수요의 경향( $T_n$ )에 따라 서비스에 필요한 자원양( $Q$ )을 확보하여, 제공하는 전략을 수립할 수 있다. 자원 수요자의 자원 요청 반복값( $n$ )에 따른 자원 수요( $Q_n$ )가 많은 경우에는, 소비경향의 값이 증가하여 자원제공자는 자원 보유량을 늘리게 되고, 반대의 경우에는 소비경향의 값이 줄어들어 자원 보유량을 줄이게 된다. 그리고 소비경향과 자원 보유량은 이전의 서비스수행을 위해 사용된 자원의 수에 의해 조절된다. 그리고 자원공급자가 보유한 가용자원이 많으면 높은 이익을 위해 저가의 자원제공 정책을 적용하여 유휴자원을 줄이려고 할 것이다.

식 (6)은 자원공급자가 자원공급가격을 결정하기 위해 평형가격과 수량(Equilibrium Price and Quantity) 알고리즘(Kiekintveld et al., 2004)을 도입한 수식으로 사용자와 공급자간 자원의 가격평형 값을 제시한다. 그리고 공급자가 제시하는 가격은 자원공급자의 보유자원 유지비용( $rmc$ )과 이전 데이터 분류에서 자원 공급가( $R_{pn-1}$ ), 유휴 자원의 수( $R_{qn}$ )에 의해 조절된다.

자원할당 절차는 빅데이터처리를 위한 서비스 환경에서 서비스 자원환경을 서비스 요청에 민첩성있게 할당하여 서비스 환경을 구성함으로써 최적의 자원을 통한 서비스를 제공하는 기대효과가 있다.

$$R_{pn} = c * \frac{R_{pn-1} * 30 + 25 * R_{qn}}{R_{pn-1} * 20 + 30 * R_{qn}} \tag{6}$$

Eq. (6). Decision the resource supply price

## 4. 구현 및 시뮬레이션

제안하는 적응형 자원관리를 모의하기 위해 DEVS (Zeigler, 1996)/WS환경을 구축하여 실험 한다. 실험을 위하여 각 모듈과 서비스를 결합하여 모델링 한다.

### 4.1 실험 환경

DEVS W/S는 DEVS(Discrete Event System Specification) 기반에서 웹서비스를 지원하는 분산 시뮬레이션 환경이다. DEVS W/S에서 대용량데이터 처리를 위한 모델을 웹서비스 형태로 정의하고 모델링 구성요소를 컴포넌트화 하며, 해당 컴포넌트간의 SOAP(Simple Object Access Protocol)를 이용하여 정보를 송수신할 수 있다. 이때 각 메시지들은 XML(eXtensible Markup Language)로 정규화하여 컴포넌트끼리의 상호운영이 가능할 뿐만 아니라, 컴포넌트 재사용이 가능하므로 응용과 확장이 용이하다.

Fig. 5는 분산컴퓨팅에서 혼합형 데이터 분류 시뮬레이션을 위한 것으로, 시간서버 중심으로 STSI(Simulation Time Synchronization Infrastructure)가 구성되어 있다. 데이터 분류 시뮬레이션 시간을 웹서비스 실행단위에 참여한 모든 참여컴포넌트에게 전송하여 진행한다.

### 4.2 3-tier기반 데이터 처리 설계

클라우드 컴퓨팅환경에서 데이터 분류를 위한 자원들을 하나의 컴포넌트로 구성하여, 대용량데이터 처리를 위해 확장된 데이터 저장능력과 분류체계를 갖추고 있다.

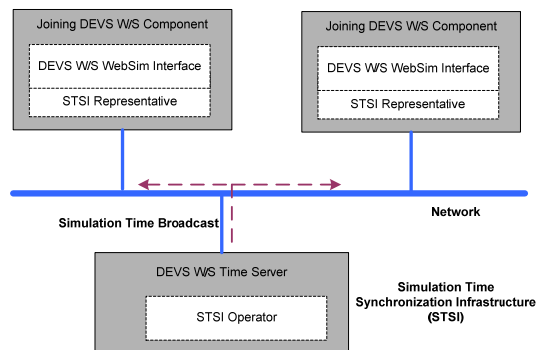


Fig. 5. Message processing structure

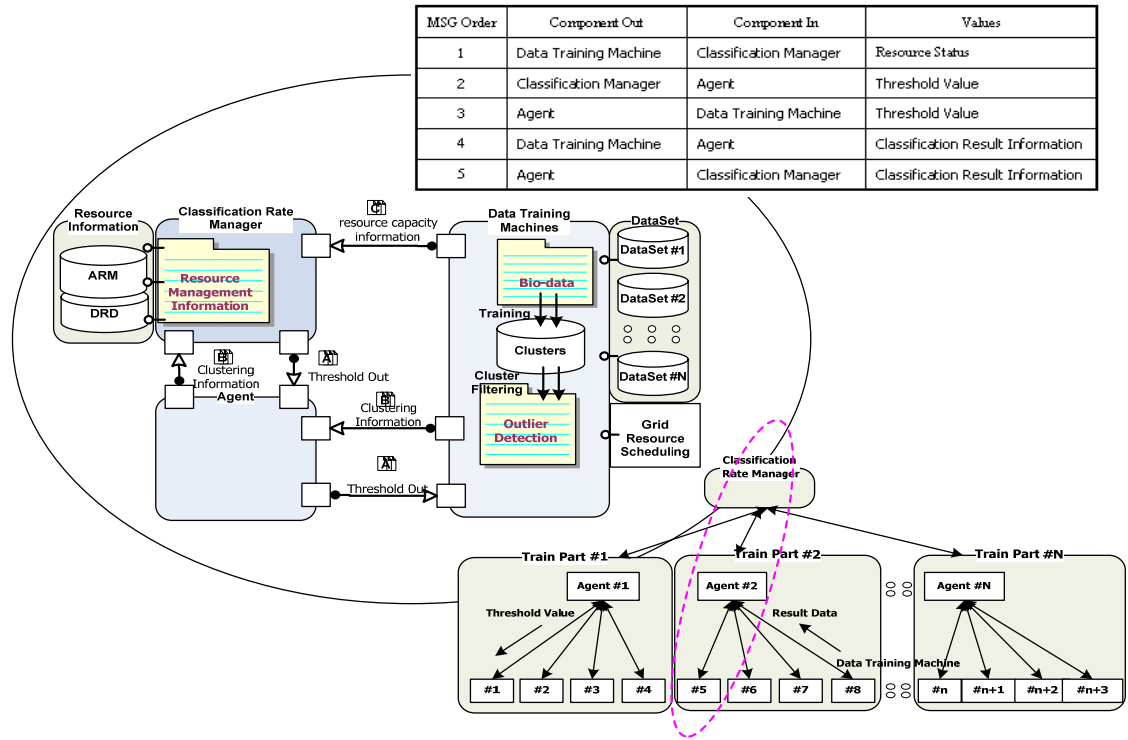


Fig. 6. Cloud computing based 3-tier data classification component

3-tier 기반 데이터 처리는 에이전트와 데이터 훈련 및 임계값을 조정하는 기능들을 각 자원에 할당하여 자원의 역할을 배분하여 수행한다. 3-tier 기반 데이터 처리는 분산 자원을 유기적으로 배치하여 전체 데이터 분류시간을 절약할 수 있게 된다.

### 5. 실험 및 결과

클라우드 컴퓨팅환경에서 가용자원에 대한 관리 성능을 분석하기 위해서 리스트 기반 동적 자원관리(ACM: Active Coordination resource Management), 응답시간 기반 자원관리(RTM: Responsible Time-based resource Management)을 본 논문에서 제안하는 동적 자원관리기법인 적응형 자원관리(ARM: Adaptive Resource Management) 기법에 대해서 자원 활용율과 데이터 처리시간을 비교하는 실험을 진행하였다. 본 논문의 실험을 위해 분산되어 있는 DEVS W/S환경을 가상으로 구성하여 Resource User를 1, 4, 8, 16, 32, 64개의 Resource Provider를 생성하여, 보유한 데이터를 Resource User가 학습 및 분류 테스트를 진행할 데이터를 수신하여 진행하였다. 각 구성

컴포넌트들간의 주요 통신 메시지 및 구성은 Fig. 6과 같이 3-tier로 구성되고, 서비스 클러스터는 관리체계를 분산화하여 병목현상을 방지함으로써 서비스의 안정화를 기대할 수 있다. 그리고 최하위 컴포넌트의 프로세스를 최소화하여 데이터 처리작업 위주의 가벼운 작업만 진행할 수 있는 장점을 기대할 수 있다. 생성된 서비스 클러스터의 예는 분류비율 관리자(Classification Rate Manager), 3개의 에이전트(Agent), 12개의 데이터 훈련 머신(Data Training Machine) 등 16개의 컴포넌트로 구성되어 있다. 그리고 참여자원의 속성값으로 CRM, Agent, DTM Cluster 등의 참여가능 서비스유형, 시간단위의 서비스 가능시간, 예약스케줄과 HIGH, MIDDLE, LOW 등의 3가지 값으로 기록된 저장공간, 네트워크 성능, 서비스성능레벨, 훈련데이터 보유수량 등의 정보를 실험을 진행하는 실제 물리 자원의 CPU, RAM, Net I/O, Net Download, Net Upload, Data Storage, Authority 을 DEVS W/S에서 처리가 가능하게 수치화하여 각 참여자원들의 단위데이터로 구성하였다.

그리고 Service Cluster에 3장에서 설명한 자원할당을 위한 엔진을 탑재하여 Resource User에 대한 가용자원과

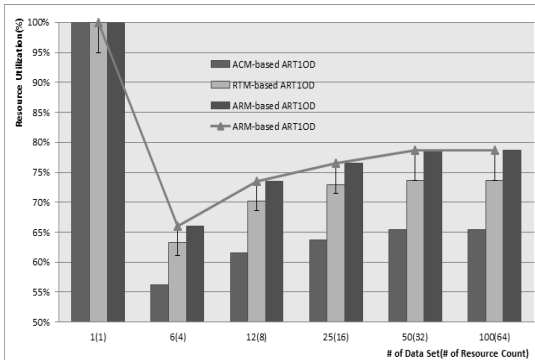


Fig. 7. Result of resource utilization

유용자원을 모니터링하면서, 분류인식률을 95%~96% 범위내에 유도할 때까지 시뮬레이션 Iteration을 반복 수행하였다.

### 5.1 자원 활용율

자원 활용율은 할당 받은 자원이 데이터 처리하는 동안 얼마나 효율적으로 자원을 활용하였는지를 알 수 있게 된다.

식 (7)은 혼합형 데이터 분류의 자원 활용율을 측정하는 수식으로써, 자원 활용율(RU: Resource Utilization)이 높다는 것은, 참여자원이 유사한 데이터 처리시간(PT: Processing Time)을 제공하고 있고 가용자원의 대기시간(WT: Waiting Time)을 줄임으로써, 자원을 꾸준히 사용하고 있음을 의미한다.

$$RU = \left( \frac{\sum_{i=1}^n PT(n)}{\sum_{i=1}^n PT(n) + WT(n)} \right) * 100 \quad (7)$$

Eq. (7). Resource Utilization

Fig. 7은 ACM기반 ART1 이상치 감시분류(ACM-based ART1OD), RTM기반 ART1 이상치 감시분류(RTM-based ART1OD)와 ARM기반 ART1 이상치 감시분류(ARM-based ART1OD) 모델들의 자원 활용율을 도식화한 것이다. ART1 이상치 감시 데이터 분류모델은 데이터 분류 훈련 컴포넌트들의 데이터 처리능력에 따라 처리시간 차이가 발생하기 마련이다. 그러므로 자원의 활용률이 높다는 것은, 자원들의 작업처리 능력의 차이가 적다는 것을 의미한다.

데이터 셋이 하나인 경우, 사용되는 자원 이 하나이므로 자원의 활용률은 100%라 할 수 있다. 하지만 실험 데이터를 분산시켜 데이터 분류를 진행하면서 이웃한 가상 자원들의 작업 종료를 기다리거나 메시지를 기다리는 동안에 대기시간이 발생하면서 자원의 활용률이 떨어지게 된다. ARM-based ART1OD 모델은 ACM-based ART1OD 모델보다 17%, RTM-based ART1OD 모델보다 12%의 자원 활용율을 향상시키는 것을 보여주고 있다.

3가지의 모델에 대해서, 분산컴퓨팅 ACM-based ART1OD 모델이 자원 활용도가 제일 낮은 것을 알 수 있다. 그 이유는 자원의 능력을 초과하지 않고 기본적인 프로세스 성능과 네트워크 성능에 대한 자원의 사용량만 고려했기 때문이다. RTM-based ART1OD 모델은 자원의 응답시간만을 고려하고 자원의 작업 수행간 발생하는 부하와 작업 시간을 고려하지 않았기 때문에 자원 활용율이 낮은 것으로 분석할 수 있다. 그러나 ARM-based ART1OD 모델은 자원의 데이터 보유상태, 자원의 작업 수행성능에 적합한 할당, 예상 처리시간 및 서비스 신뢰도를 고려하고, 자원 모니터링과 이력관리를 통해서 자원 활용율을 향상시켜 응답시간을 절약하고 있음을 알 수 있다.

### 5.2 데이터 처리시간

두 번째 실험은 각 모델에 대해서, 데이터 분류를 진행하면서 데이터 처리시간을 측정하여 그 성능을 비교하였다. 대용량데이터를 분류하고, 최적의 분류 성공율(95%)을 유도하기 위해서는 고성능의 작업 수행능력이 필요하게 된다. 처리시간이 짧다는 것은 가용자원을 원활하게 사용함으로써, 동적 자원관리를 통해 효율적인 자원운영이 진행되었음을 의미하게 된다.

Fig. 8은 실험 결과로서 ACM-based ART1OD 모델 및 RTM-based ART1OD 모델은 ARM-based ART1OD 모델보다 데이터 처리성능이 떨어지는 것을 알 수 있다.

이는 같은 데이터 분류기법을 적용하였으므로, 자원관리의 방법에 따라 다른 성능을 제공하고 있는 것이라 할 수 있다. 자원을 작업, 네트워크 상황, 기존 작업수행 중에 보유하고 있던 데이터를 수신하는 시간을 절약함으로써 프로세스 성능을 향상시켰음을 알 수 있다. 그림은 ARM-based ART1OD 모델은 ACM-based ART1OD 모델보다 59%, RTM-based ART1OD 모델보다 43%의 데이터 처리시간을 절약하고 있음을 보여주고 있다. 이는 여러 자원의 성능과 자원 현황모니터링, 작업 수행이력을 관리함으로써, 프로세스 성능이 크게 향상되었음을 알 수 있다.




Fig. 8. Result of processing time

## 6. 결 론

대용량의 데이터 이슈와 네트워크 및 정보기술의 발달로 이를 효율적으로 처리할 수 있는 컴퓨팅 기술이 필요하다. 클라우드 컴퓨팅은 가상자원을 이용하여 대용량 데이터 처리 서비스를 제공할 수 있으며, 이를 위해서는 체계적인 자원관리는 필수 사항이며, 자원관리 정책에 따라서 컴퓨팅의 성능을 극대화 할 수 있다.

본 논문에서는 ART기반의 적응형 자원관리 기법을 제안했다. 적응형 자원관리기법은 지속적인 고성능 작업수행을 위해 참여자원에 대한 데이터보유, 네트워크 성능, 가용스케줄, 예상 처리시간, 신뢰도 등에 대한 자원의 속성요소를 고려하여 수행 작업 가동시점에 맞춰 최적의 자원을 제공하였다. 실험을 통한 적응형 자원관리기법의 성능은 리스트기반 동적 자원관리 및 응답시간기반 동적 자원관리의 자원 활용율과 데이터 처리시간 비교를 통해 그 효과를 입증하였다. 또한 고성능 및 대용량데이터 처리를 위한 자원관리기법으로 적응형 자원관리 방법을 활용할 수 있으며, 이는 체계적인 자원관리가 가능하고 가용자원을 효율적으로 활용하여 요구 성능을 향상시킬 수 있다는 장점이 있다.

향후 연구로는 사용자 및 공급자의 다양한 요구사항을 반영하기 위해 참여자의 규칙과 룰을 세분화한 지식기반의 비용 및 서비스 만족도에 관한 연구를 진행 할 것이다.

## References

1. B. P. Zeigler, et al., "DEVS Framework for Modeling, Simulation, Analysis, and Design of Hybrid Systems in Hybrid II," Lecture Notes in CS. Springer-Verlag, Berlin, pp. 529-551, 1996.
2. C. Kiekintveld, M. P. Wellman, S. Singh, J. Estelle, Y.

- Vorobeychik, V. Soni and M. Rudary, "Distributed Feedback Control for Decision Making on Supply Chains", Proceeding of the 14th International Conference on Automated Planning and Scheduling, pp. 384-392, 2004.
3. Divyakant A., Sudipto D., and Amr E.A., "Big data and cloud computing: current state and future opportunities", Proceedings of the 14th International Conference on Extending Database Technology. ACM, pp. 530-533, 2011.
4. D. Jeffrey and G. Sanjay, "MapReduce: Simplified Data Processing on Large Clusters", Communications of the ACM, Vol. 51, No. 1, pp.107-113, 2008.
5. D. T. Chalmers and D. P. Behan, "The use of Constitutively Activity GPCRs in Drug Discovery and Functional Genomics", Nature Reviews, Drug Discovery, Vol. 1, No. 8, pp. 599-608, 2002.
6. Espadas, Javier, et al. "A tenant-based resource allocation model for scaling Software-as-a-Service applications over cloud computing infrastructures", Future Generation Computer Systems, Vol. 29, No. 1, pp.273-286, 2013.
7. F.V. Jensen, "An Introduction to Bayesian Networks", UCL press London, 1996.
8. G. A. Carpenter and S. Grossberg, "Adaptive Resonance Theory: Stable Self-Organization of Neural Recognition Codes in Response to Arbitrary Lists of Input Patterns", Proceeding of the 8th Conference of the Cognitive Science Society, Hillsdale, NJ: Erlbaum Associates, pp. 45-62, 1988.
9. J. D. Thompson, D. G. Higgins and T. J. Gibson, "CLUSTAL W: Improving the Sensitivity of Progressive Multiple Sequence Alignment through Sequence Weighting, Positriion-Specific Gap Penalties and Weight Matrix Choice", Nucleic Acids Res, Vol. 22, No. 22, pp. 4673-4680, 1994.
10. Kim J.K. and Lee J.S., "Fuzzy Logic-driven Virtual Machine Resource Evaluation Method for Cloud Provisioning Service", Journal of Korea Society for Simulation, Vol. 22, No. 1, pp. 77-86, 2013.
11. M. Georgiopoulos, G. L. Heileman and J. Huang, "Properties of Learning Related to Pattern Diversity in ART1", Neural Networks, Vol. 4, No. 6. pp. 751-757, 1991.
12. T. R. Gopalakrishnan Nair and P Jayarekha, "Pre-allocation Strategies of Computational Resources in Cloud Computing using Adaptive Resonance Theory-2," International Journal on Cloud Computing: Services and Architecture (IJCCSA), Vol. 1, No. 2, pp. 31-41, 2011.
13. W. G. Baxt, "Application of Artificial Neural Networks to Clinical Medicine," The Lancet, Vol. 346, No. 8983, pp. 1135-1138, 1995.





**조 규 철** (kccho@etri.re.kr)

2005 인하대학교 컴퓨터공학과 학사  
2007 인하대학교 컴퓨터정보공학과 석사  
2013 인하대학교 정보공학과 박사  
2011~현재 한국전자통신연구원 재직

관심분야 : 클라우드 컴퓨팅, 모델링 & 시뮬레이션, 역공학, 신재생에너지



**김 재 권** (jaekwonkorea@naver.com)

2011 가천의과학대학교 정보처리과 학사  
2013 인하대학교 컴퓨터정보공학과 석사  
2013~현재 인하대학교 컴퓨터정보공학과 박사과정

관심분야 : 클라우드 컴퓨팅, 인공지능, 모델링&시뮬레이션