

클라우드 컴퓨팅 환경에서 강화학습기반 자원할당 기법

최영호*, 임유진°, 박재성*

Reinforcement Learning Approach for Resource Allocation
in Cloud Computing

Yeongho Choi*, Yujin Lim°, Jaesung Park*

요약

다양한 강점을 지닌 클라우드 서비스는 현대 IT 사업에 주요 이슈 중 하나이다. 클라우드 환경에서 서비스 제공자는 사용자의 동적인 자원 요구량을 예측하여 사용자의 QoS를 만족시켜야 한다. 사용자의 자원 요구량을 예측하는 기존 모델들은 사용자의 QoS는 만족시키지만 서비스 제공자의 이득은 보장하지 않는다. 본 논문에서는 Q-learning 기반의 자원 예측 모델을 제안하여 사용자의 QoS 뿐만 아니라 서비스 제공자의 이득을 최대화하였다. 또한 제안 기법의 성능 분석을 위해 실측 데이터를 이용하여 다른 예측 모델들과 비교함으로써 제안 기법의 우수함을 증명하였다.

Key Words : cloud computing, VM provisioning, resource allocation, Q-learning, reinforcement learning

ABSTRACT

Cloud service is one of major challenges in IT industries. In cloud environment, service providers predict dynamic user demands and provision resources to guarantee the QoS to cloud users. The conventional prediction models guarantee the QoS to cloud user, but don't guarantee profit of service providers. In this paper, we propose a new resource allocation mechanism using Q-learning algorithm to provide the QoS to cloud user and guarantee profit of service providers. To evaluate the performance of our mechanism, we compare the total expense and the VM provisioning delay with the conventional techniques with real data.

1. 서론

유동성, 확장성, 편의성, 낮은 비용과 같은 다양한 강점을 지닌 클라우드 서비스는 현대 IT 사업에서 주요 이슈 중 하나이다. 클라우드 서비스는 서비스 대상에 따라서 기업을 위한 프라이빗 클라우드, 일반 대중

을 위한 퍼블릭 클라우드, 보안 기능과 비용의 효율성을 강화한 하이브리드 클라우드로 구분한다^[1]. 또한 IaaS(Infrastructure as a Service), PaaS(Platform as a Service), SaaS(Software as a Service) 같이 사용자의 요구에 따라 다양한 유형의 서비스를 제공한다. 특히, IaaS에서 서비스 제공자는 물리적인 자원을 가상화를

* 본 연구는 경기도의 경기도지역협력연구센터(GRRC) 사업의 일환으로 수행하였음 [(GRRC수원2014-B3), 클라우드 기반 지능형 영상 보안 감시 시스템 개발].

° 본 연구는 미래창조과학부 및 정보통신산업진흥원의 산학협력 특성화 지원사업 의 연구결과로 수행되었음 (NIPA-2014-H0808-14-1003).

• First Author : University of Suwon, Department of Computer Science, ceewoo@suwon.ac.kr, 학생회원

° Corresponding Author : University of Suwon, Department of Information Media, yujin@suwon.ac.kr, 종신회원

* University of Suwon, Department of Information Security, jaesungpark@suwon.ac.kr, 종신회원

논문번호 : KICS2015-03-044, Received March 3, 2015; Revised March 24, 2015; Accepted March 24, 2015

이용하여 VM(Virtual Machine) 단위로 사용자들에게 제공한다^{2,3)}.

클라우드 환경에서 사용자가 요구하는 자원의 양과 유형은 동적이기 때문에 사용자의 QoS(Quality of Service)를 만족시키는 것은 어렵다. 사용자의 QoS를 만족시키고 효율적인 자원 관리를 위해서는 사용자들의 요구를 정확히 예측하고 이를 기반으로 자원을 준비하는 것이 필요하다. 따라서 사용자의 동적인 자원 요구에 따라 효율적으로 자원을 할당하기 위한 VM 프로비저닝이 필요하다. VM 프로비저닝(VM provisioning)은 가까운 미래에 발생할 자원 요구량을 예측하고, 해당 요구량을 만족시키기 위해 자원을 미리 준비하는 기술이다. VM 프로비저닝은 사용자의 QoS를 만족시키고 자원 관리 비용을 최소화하여 서비스 제공자의 이득을 최대화한다. 서비스 제공자는 사용자에게 SLA(Service Level Agreement)에 계약된 QoS를 제공해야 한다. 서비스 제공자가 QoS를 만족시키면 사용자로부터 서비스 이용에 대한 대가를 받지만, 만족시키지 못하면 서비스 제공자는 사용자에게 그에 따른 penalty를 지급해야 한다. 사용자의 QoS를 떨어뜨리는 주된 원인 중 하나는 VM 프로비저닝 지연시간이다. VM 프로비저닝은 VM 생성, VM 할당 및 배분, 소프트웨어 설치, VM 검증, 안정성 확인 등을 위한 지연시간이 발생한다. 따라서 VM 프로비저닝 지연시간을 줄이기 위하여 자원 요구량을 예측하고 필요한 서비스 자원을 사전에 준비하는 기법이 요구된다. 따라서 2장에서는 QoS 제공을 위한 VM 프로비저닝 기법과 기존의 자원 요구량 예측 모델들을 설명한다. 3장과 4장에서는 사용자의 QoS를 만족시키고 서비스 제공자의 이득을 최대화하기 위한 새로운 자원 요구량 예측 모델을 제안하고 성능을 평가한다. 마지막으로 5장에서 결론을 맺는다.

II. 관련 연구

클라우드 환경에서 사용자에게 QoS를 제공하기 위해서는 VM 프로비저닝 지연시간을 최소화해야 한다. VM 프로비저닝을 위한 추가적인 지연시간의 발생을 최소화하기 위해서 서비스 제공자는 자원 요구량을 예측하고 이를 기반으로 자원을 미리 준비한다. 이때 자원 요구량에 대한 정확한 예측 기술이 요구된다.

2.1 VM 프로비저닝

VM 프로비저닝은 두 가지 방법(reactive와 proactive)으로 자원을 관리 한다¹⁾. 첫째로, reactive 방법은 서

버가 모니터링을 통하여 자원 요청량이 증가했음을 확인하면 그때 자원을 할당한다. Reactive 방법은 새로운 VM의 생성과 할당이 즉시 실행된다면 효과적이다. 하지만 실제로 VM의 생성과 할당에는 지연시간이 요구된다. 이것은 일반적인 서비스에는 적합할 수도 있지만 실시간 처리를 요구하는 서비스에는 적합하지 않다. 따라서 reactive 방법은 VM 프로비저닝 지연시간을 발생시키고 사용자의 QoS를 떨어뜨릴 수 있다. 둘째로, proactive 방법은 자원 요구량을 예측하여 사전에 필요한 자원을 준비하는 방법이다. VM 프로비저닝은 서비스 제공자가 준비한 자원의 양과 사용자가 요구한 자원의 양의 차이에 따라 두 가지 상황이 가능하다. 첫째로, 서비스 제공자가 준비한 자원의 양이 사용자가 요구한 자원의 양 보다 많은 경우 오버 프로비저닝(over-provisioning)이 발생한다. 오버 프로비저닝일 때 서비스 제공자는 잉여 자원에 따른 기회비용이 발생한다. 둘째로, 서비스 제공자가 준비한 자원의 양이 사용자가 요구한 자원의 양 보다 적은 경우 언더 프로비저닝(under-provisioning)이 발생한다. 언더 프로비저닝일 때 부족한 자원을 추가로 준비하기 위한 VM 프로비저닝 지연시간이 발생한다. 이러한 추가적인 지연시간의 발생은 사용자의 QoS를 떨어뜨릴 수 있으며, 이로 인한 SLA 위반 시 서비스 제공자는 사용자에게 penalty를 지급해야 한다. 따라서, 서비스 제공자는 다양한 자원 요구량을 예측하여 미리 준비함으로써 오버 프로비저닝에 따른 기회비용과 언더 프로비저닝에 따른 지연시간의 발생을 예방해야 한다. 그러므로 정확하게 자원 요구량을 예측하고 이를 기반으로 자원 준비량을 결정할 수 있는 기법이 필요하다.

2.2 시계열 예측(time series prediction)

시계열 예측 기법은 대표적인 자원 예측 기법 중 하나이다. 시계열은 일정 시간 간격으로 배치된 데이터들이다. 시계열 예측 기법은 주어진 과거 데이터를 보고 수학적 모델 기반으로 미래의 발생 데이터를 예측하는 것이다. 시계열 데이터를 분석하는 대표적인 수학적 모델은 AR(Auto Regressive), I(Integrated), MA(Moving Average) 등이 있다. 이 세 가지 모델들은 연속적인 과거 데이터에 의존하여 미래의 데이터를 예측한다. [4]는 오버 프로비저닝과 언더 프로비저닝 경우를 고려하여 서비스 제공자의 손해를 계산하는 함수를 제안하였다. 제안된 함수에 AR, MA 등의 시계열 예측 기법을 이용한 예측값을 적용하여 서비스 제공자의 손해를 계산하고 비교하였다. 기존의 많은 시계열 예측 모델은 사용자의 요구량을 정확하게

예측하여 사용자의 QoS를 보장하는 것을 목표로 한다. 이러한 모델들은 사용자에게 QoS는 제공하지만 서비스 제공자의 이득을 보장하지는 않는다. 본 논문에서는 사용자에게 QoS를 제공하면서도 서비스 제공자의 이득을 최대화하기 위하여 강화 학습 알고리즘을 이용한 VM 프로비저닝 모델을 제안한다.

2.3 강화 학습(reinforcement learning)

강화 학습은 동적인 환경 하에서 시행착오를 거쳐 환경으로부터 주어지는 보상(reward)을 최대화하기 위한 학습 방법이다. 강화 학습 환경 내에서 행동하는 에이전트(agent)는 특정 상태(state)에서 가능한 행동(action)들 중 하나를 택해 행하고 다른 상태로 이동하게 된다. 이동하면서 환경으로부터 행동의 대가에 해당하는 보상을 받게 된다. 강화 학습의 목표는 이러한 보상의 총합을 최대화하는 것이다. 본 논문에서는 과거 사용자의 자원 요구량을 기반으로 학습된 정보를 사용하여 미래에 제공할 자원의 양을 결정 및 준비함으로써 사용자의 QoS를 높이고 서비스 제공자의 이득을 최대화하고자 한다.

III. 제안 모델

클라우드 컴퓨팅 환경에서 서비스 제공자는 사용자에게 스토리지, CPU, 메모리 등과 같은물리적인 자원을 VM 단위로 제공한다. 본 논문에서 제안한 모델은 VM 프로비저닝 지연시간을 최소화하여 사용자의 QoS를 보장하고 서비스 제공자의 이득을 최대화하는 자원의 양을 결정하고 준비한다. 표 1은 제안 모델에서 사용되는 파라미터를 보여준다.

표 1. 제안 모델을 위한 파라미터 정의
Fig. 1. Parameters for our model

parameter	description
res_{delay}	VM provisioning delay
$res_{service}$	Service response time
res_{SLA}	Threshold of service response time to be guaranteed by SLA
$VM_{demanded}$	amount of resource demanded by user
$VM_{prepared}$	amount of resource prepared by service provider
E_{total}	Total expense for service providing
$C_{service}$	Cost for a unit of providing resources
C_{over}	Cost for a unit of idle resources in over-provisioning
C_{under}	Penalty for a unit of SLA violation resources in under-provisioning

3.1 VM 프로비저닝 지연시간

서비스 제공자가 사전에 준비한 자원이 사용자가 요구한 자원보다 많다면 지연시간은 발생하지 않는다. 하지만 서비스 제공자가 사전에 준비한 자원이 사용자가 요구한 자원보다 적다면 부족한 자원을 준비하기 위한 VM 프로비저닝 지연시간이 발생한다. VM 프로비저닝 지연시간은 시간은 다음과 같이 정의한다.

$$res_{delay} = \begin{cases} 0 & (if\ over-provisioning) \\ (vm_{demanded} - vm_{prepared}) * t_{vm} & (if\ under-provisioning) \end{cases} \quad (1)$$

식 (1)에서 t_{vm} 은 부족한 자원을 준비하는데 소요되는 자원 당 준비시간을 의미한다. VM 프로비저닝 지연시간으로 인한 서비스 응답 시간이 SLA에 명시된 서비스 응답 시간을 초과한다면 서비스 제공자는 사용자에게 penalty를 지급해야한다.

3.2 서비스 제공자의 총 경비

기존의 시계열 예측 기법을 이용한 모델들은 사용자의 QoS 보장에 초점을 맞추어, 사용자가 요구하는 자원의 양을 정확하게 예측하는 것을 목적으로 한다. 제안 모델은 서비스 응답 시간에 따른 사용자의 QoS 뿐만 아니라 서비스 제공자의 이득도 보장한다. 서비스 제공자가 서비스 제공을 위해 소비하는 총 경비를 최소화하여 이득을 최대화 할 수 있다. 서비스 제공자의 총 경비는 다음과 같이 정의 할 수 있다.

$$E_{total} = \begin{cases} vm_{demanded} * C_{service} + (vm_{prepared} - vm_{demanded}) * C_{over} & (if\ over-provisioning) \\ vm_{prepared} * C_{service} + (vm_{demanded} - vm_{prepared}) * C_{under} & (if\ under-provisioning) \end{cases} \quad (2)$$

식 (2)에서 서비스 제공자는 오버 프로비저닝 경우, 서비스 제공에 필요한 비용(전기, 인건비 등)과 잉여 자원에 따른 기회 비용이 발생한다. 언더 프로비저닝 경우, 서비스 제공에 필요한 비용과 부족한 자원으로 인하여 발생 할 수 있는 SLA 위반에 대한 penalty가 발생한다. 제안 모델은 서비스 제공자의 총 경비를 최소화하는 VM 프로비저닝 자원의 양을 결정한다.

3.3 Q-learning 기반 자원 예측 모델

본 논문에서는 Q-learning 알고리즘을 이용하여 사용자의 QoS를 보장하고 서비스 제공자의 총 경비를

최소화하는 예측 모델을 제안한다. Q-learning 알고리즘은 강화 학습 방법들 중 대표적으로 쓰이는 알고리즘으로써 시간 변화에 따른 적합도 차이를 학습에 이용하는 TD-learning(Temporal Difference learning)의 한 종류이다. Q-learning에서는 특정한 상태에 놓여있을 때, 취할 수 있는 각각의 행동에 대한 보상을 이용하여 Q-value를 학습한다. Q-value는 $Q(s, a)$ 로 표현한다. 시간 t 에서 현재 상태를 $s \in S$, 행동 $a \in A$ 라 할 때 $Q(s_t, a_t)$ 는 다음과 같다⁵⁾.

$$Q_{t+1}(s_t, a_t) = Q_t(s_t, a_t) + \alpha(R_{t+1} + \gamma \max_a Q(s_{t+1}, a) - Q_t(s_t, a_t)) \quad (3)$$

식 (3)에서 α 는 learning rate로 Q-value에 대한 새로운 정보가 이전 정보 보다 어느 정도 비중 있는지를 나타낸다. γ 는 discount factor로 보상에 대한 중요성을 나타낸다. 여기서 행동 선택은 일반적으로 ϵ -greedy 방식이나 Boltzmann exploration을 사용한다⁶⁾.

제안 모델에서 상태는 사용자가 요구한 자원의 양에 대한 정보이고 $s_t = \{vm_{demanded}\}$ 로 정의한다. 행동은 자원 양의 증가와 감소를 행할 수 있고 $A = \{decrease, zero, increase\}$ 로 정의한다. 보상 함수(reward function)는 자원 예측률과, SLA에 의한 서비스 응답 시간과 실제 서비스 응답 시간의 비율을 계산하여 다음과 같이 정의한다.

$$R = \beta \left| 1 - \frac{vm_{prepared}}{vm_{demanded}} \right| + (1 - \beta) \frac{(res_{service} + res_{delay})}{res_{SLA}} \quad (4)$$

식 (4)에서 β 는 자원 예측률과 서비스 응답시간에 대한 가중치를 나타내고, 서비스 응답 시간 $res_{service}$ 는 서비스 처리 시간과 서비스 처리율을 이용하여 계산한다⁷⁾. 일반적인 Q-learning 모델과 달리 본 논문의 제안 모델은 서비스 제공자의 총 경비를 최소화하는 것이 목적이므로 Q-value가 작아지는 방향으로 학습한다. 따라서, 자원 예측률이 높고 서비스 응답 시간이 낮을수록 보상은 작은 값을 갖는다.

제안 모델은 첫째로, 사용자가 서비스 자원 $vm_{demanded}$ 요구하면 서비스 제공자는 사용자의 요구 정보를 기반으로 현재 상태 s_t 를 확인한다. 둘째로, 서비스 제공자는 사전에 준비된 $vm_{prepared}$ 을 제공하여 서비스를 처리하고 res_{delay} 를 확인한다. 셋째로, 현재

상태 s_t 를 기반으로 Q-value가 가장 작은 자원의 양을 다음 서비스를 위해 준비한다. 마지막으로 Q-value의 정보를 갱신한다.

IV. 성능 분석

본 논문에서는 클라우드 환경에서 사용자의 자원 요구량을 Q-learning 기반으로 예측하는 모델을 제안하였다. 본 논문에서 서비스 제공자가 제공하는 VM 자원은 *mips*와 코어 수로 정의한다. 사용자는 서비스 제공자에게 서비스에 필요한 데이터 크기(data size)와 코어 수(num of cores)를 요청한다. 서비스 제공자는 요청 받은 데이터 크기와 코어 수를 이용하여 데이터 처리에 필요한 *mips*를 식 (5)와 같이 계산한다⁸⁾.

$$mips = \frac{data.size}{num.of.cores} \quad (5)$$

서비스 제공자가 사전에 준비한 *mips*가 사용자가 요구한 *mips*보다 많다면 잉여 *mips*에 따른 기회 비용이 발생하고 서비스 제공자가 사전에 준비한 *mips*가 사용자가 요구한 *mips*보다 적다면 부족한 *mips*만큼의 penalty를 지급해야 한다. 이러한 추가 경비의 발생은 서비스 제공자에게 손해이다.

제안 모델은 Q-learning 알고리즘의 사용을 위해 *mips*의 상태는 $S = \{100, 200, \dots, 900, 1000\}$ 로 정의하고 행동은 $A = \{-100, 0, 100\}$ 로 정의하여 *mips*의 증가와 감소를 행한다. 제안 모델에서는 90% 확률로 ϵ -greedy 방식을 사용하여 Q-value 가장 낮은 행동을 행하며 10% 확률로 임의의 행동을 행한다. 제안 모델의 예측 결과를 평가하기 위하여 3장에서 제안한 VM 프로비저닝 지연시간과 서비스 제공자의 총 경비에 대한 정의를 사용한다. 실험은 시간 단위(a unit of time) 당 한 번의 서비스를 제공하며 실험 환경에서 사용되는 파라미터들은 $C_{service} = \$4$, $C_{over} = \$4$, $C_{under} = \$10$, $res_{SLA} = 0.432ms$ 로 설정하였다. 또한 언더 프로비저닝일 때 부족한 자원을 준비하는데 소요되는 시간 t_{vm} 는 평균 $0.0005ms$ 이고 표준편차가 평균의 5%인 정규분포를 따른다⁹⁾. 본 논문에서 제안 기법의 성능을 분석하기 위해 사용자의 자원 요구량에 대한 실측 데이터(Intel Netbatch Grid, 2012년 10월 - 2012년 12월까지 데이터)를 이용하였다¹⁰⁾. 또한 CLT(Central Limit Average), EWMA, AR과 VM 프로비저닝 지연시간과 서비스 제공자의

총 경비를 비교하였다.

(그림 1)은 제안 기법을 사용했을 때의 서비스 제공자의 총 경비가 다른 예측 기법을 사용했을 때의 총 경비들 보다 작음을 보여준다. 제안 모델의 총 경비 E_{total} 은 CLT 모델을 사용한 경우의 총 경비 보다 28.2%, EWMA 보다 33.9%, AR 보다 40.8% 낮다. (그림 2)는 예측 기법을 사용했을 경우에 발생하는 VM 프로비저닝 지연시간의 평균을 비교한 것이다. 그림에서 보는 바와 같이 추가적인 VM 프로비저닝에 소요되는 시간이 다른 예측 기법들 보다 낮다. 표 2에서 사용자의 QoS에 영향을 주는 언더 프로비저닝의 발생 정도를 백분율로 나타내었다. 제안 모델이 가장 낮은 37.8%로 추가적인 VM 프로비저닝 지연시간의 발생 확률이 가장 낮으므로 다른 예측 모델 보다 사용자의 QoS를 보장 확률이 높다는걸 알 수 있다. 표 2에서 예측 기법들을 사용했을 경우 제안 모델의 초당 서비스 처리율이 5.02로 다른 예측 모델보다 높은 서비스 처리율을 보여준다. 이러한 실험 결과를 바탕으로 본 논문의 제안 기법이 사용자에게 QoS를 보장하




그림 1. 예측 모델에 따른 서비스 제공자의 총 경비 비교
Fig. 1. Performance evaluation for the total expense




그림 2. 예측 모델에 따른 VM 프로비저닝 지연시간 비교
Fig. 2. Performance evaluation for the VM provisioning delay

표 2. 예측 모델에 따른 언더 프로비저닝 발생 확률
Table 2. Performance evaluation for the under-provisioning probability

parameter	our	CLT	EWMA	AR
VM provisioning delay(ms)	0.19	0.34	0.42	0.25
under-provisioning count(%)	37.8	59	64.4	41
service rate	5.02	2.89	2.35	3.92

고 서비스 제공자의 이득을 최대화하는 VM 프로비저닝 자원의 양을 결정할 수 있음을 알 수 있다.

V. 결 론

본 논문에서는 사용자의 QoS를 보장하고 서비스 제공자의 이득을 최대화하기 위한 VM 프로비저닝 기법 제안을 위하여, 강화 학습 방법을 기반으로 자원 요구량을 예측하는 모델을 제안하였다. 기존의 AR과 EWMA 같은 시계열 모델은 사용자에게 QoS를 제공하지만 서비스 제공자의 이득을 보장하지는 않는다. 따라서 본 논문에서는 Q-learning 알고리즘을 기반으로 자원 요구량을 예측하는 모델을 제안하였다. 제안 모델은 사용자의 QoS를 보장하고 서비스 제공자의 이득을 최대화하기 위해 VM 프로비저닝 지연시간과 서비스 제공자의 총 경비를 최소화하는 예측 모델을 제안하였다. 또한 제안 모델의 성능 평가를 위하여 VM 프로비저닝 지연시간과 서비스 제공자의 총 경비를 정의하였다. 이러한 정의를 기반으로 제안 모델과 기존 예측 모델의 성능을 비교함으로써 제안 모델이 다른 예측 기법 보다 VM 프로비저닝 지연시간과 서비스 제공자의 총 경비가 작다는 것을 증명하였다.

References

- [1] J. Almeida, V. Almedia, D. Ardagna, C. Francalanci, and M. Trubian, "Resource management in the autonomic service-oriented architecture," in *Proc. IEEE ICAC 2006*, pp. 84-92, Dublin, Ireland, Jun. 2006.
- [2] H. Kim and H. Kim, "Control algorithm for virtual machine-level fairness in virtualized cloud data center," *J. KICS*, vol. 38C, no. 6, pp. 512-520, Jun. 2013.
- [3] M. Kim and M. Park, "Energy-aware virtual

machine deployment method for cloud computing,” *J. KICS*, vol. 40, no. 1, pp. 61-69, Jan. 2015.

- [4] Y. Jiang, C. Perng, T. Li, and R. N. Chang, “Cloud analytics for capacity planning and instant VM provisioning,” *IEEE Trans. Network and Service Management*, vol. 10, no. 3, pp. 312-325, May 2013.
- [5] T. Ahn, Y. Kim and S. Lee, “Dynamic resource allocation in distributed cloud computing,” *J. KICS*, vol. 38B, no. 7, pp. 512-518, Jul. 2013.
- [6] R. E. Parr, “Hierarchical control and learning for markov decision processes,” Ph.D. dissertation, University of California, Berkeley, CA, 1998.
- [7] A. M. Daniel, W. D. Lawrence, and A. F. A. Virgilio, *Performance by Design*, Prentice Hall, 2003.
- [8] R. N. Calheiros, R. Ranjan, A. Beloglazov, C. A. F. De Rose, and R. Buyya, “CloudSim: A toolkit for modeling and simulation of cloud computing environments and evaluation of resource provisioning algorithms,” *Software: Practice & Experience*, vol. 4, no. 1, pp. 23-50, Jan. 2011.
- [9] C. C. Li and K. Wang, “An SLA-aware load balancing scheme for cloud datacenters,” in *Proc. IEEE ICOIN 2014*, pp. 58-63, Phuket, Thailand, Feb. 2014.
- [10] D. G. Feitelson, *Parallel workloads*, <http://www.cs.huji.ac.il/labs/parallel/workload/>

최 영 호 (Yeongho Choi)



2013년 2월 : 수원대학교 정보 미디어학과 졸업
 2013년 9월~현재 : 수원대학교 컴퓨터학과 석사과정
 <관심분야> Cloud Computing, Auction System, Resource Allocation

임 유 진 (Yujin Lim)



2000년 2월 : 숙명여자대학교 전 산학과 박사
 2013년 2월 : Tohoku University, Dept, of Information Sciences 박사
 2014년~현재 : 수원대학교 정보 미디어학과 교수

<관심분야> Wireless Communication, Cloud Computing

박 재 성 (Jaesung Park)



2001년 2월 : 연세대학교 전기, 전자공학과 박사
 2001년~2002년 : University of Minnesota (PostDoc.)
 2002년~2005년 : LG전자(선임 연구원)
 2014년~현재 : 수원대학교 정보

보호학과 교수