

차량의 이동성 행동 프로파일을 이용한 DTMC 기반의 스마트 핸드오버 기법

준회원 한 상 혁*, 김 현 우*, 종신회원 최 용 훈*, 박 수 원**, 이 승 형***

A Smart DTMC-based Handover Scheme Using Vehicle's Mobility Behavior Profile

Sang Hyuck Han*, Hyun Woo Kim* *Associate Members*,
Yong-Hoon Choi*, Suwon Park**, Seung Hyuong Rhee*** *Lifelong Members*

요 약

차량과 같은 이동환경에서 무선 인터넷 서비스를 사용할 때, 불필요하게 발생하는 핸드오버는 서비스 품질 저하와 시그널링 오버헤드를 유발하여 실시간 멀티미디어 서비스 제공에 단점으로 작용한다. 본 논문에서는 Mobile Node (MN)가 일정한 이동패턴을 가지고 있을 때, Mobility behavior profile을 이용하여 생성한 DTMC을 이용하여 핸드오버의 발생 횟수를 감소시켜 무선 인터넷 서비스를 향상시킬 수 있는 핸드오버 방법을 제안한다. 기존 핸드오버 방법을 반복적으로 수행하며 Mobility behavior profile을 학습하고, Mobility behavior profile에 충분한 양이 학습되면 Mobility behavior profile을 이용하여 DTMC의 1-step & 2-step transition probability matrix를 생성한다. 그 이후에는 DTMC의 1-step & 2-step transition probability matrix를 이용하여 핸드오버를 수행하며 Mobility behavior profile을 계속 업데이트한다. 4개의 Mobility model에서의 실험을 통하여 평균 핸드오버 횟수와 평균 RSSI값, 그에 따른 Throughput을 비교한다.

Key Words : Handover Mechanism, Mobile Behavior Profile, Moving Pattern, Vehicular Environment, DTMC

ABSTRACT

For improvement of wireless Internet service quality at vehicle's moving speed, it is advised to reduce the service disruption time by reducing the handover frequency on vehicle's moving path. Particularly, it is advantageous to avoid the handover to cell whose dwell time is short or can be ignored in terms of service continuity and average throughput. This paper proposes the handover scheme that is suitable for vehicle in order to improve the wireless Internet service quality. In the proposed scheme, the handover process continues to be learned before being modeled to Discrete-Time Markov Chain (DTMC). This modeling reduces the handover frequency by preventing the handover to cell that could provide service sufficiently to passenger even when vehicle passed through the cell but there was no need to perform handover. In order to verify the proposed scheme, we observed the average number of handovers, the average RSSI and the average throughput on various moving paths that vehicle moved in the given urban environment. The experiment results confirmed that the proposed scheme was able to provide the improved wireless Internet service to vehicle that moved to some degree of consistency.

※ 이 논문은 2010년도 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. 2010-0027805, 인접 및 공유 대역에서 이중 무선망의 공존 방안 연구).

* 광운대학교 제어계측공학과 (allons-y@kw.ac.kr, kurenai0106@kw.ac.kr, yhchoi@kw.ac.kr),

** 광운대학교 전자통신공학과 (spark@kw.ac.kr), *** 광운대학교 전파공학과 (rhee@kw.ac.kr)

논문번호 : KICS2011-02-116, 접수일자 : 2011년 2월 17일, 최종논문접수일자 : 2011년 5월 20일

1. 서 론

최근 스마트폰이 널리 보급되면서, 집, 회사, 차량, 버스, 기차 등 모든 환경에서 무선인터넷 서비스를 제공 받는 것이 가능해졌다. 무선 인터넷 사업자들은 서비스 품질을 향상시키기 위해 cell 크기를 줄이는 한편, cell을 중첩하여 배치하는 경향을 보인다. 다수의 hot spot, microcell 등이 도심에 설치되어 있으며, 기차와 같은 대형 운송수단에는 이동 릴레이 (Mobile Relay Station)를 설치하기도 한다. 이와 같이 작고 중첩된 cell 환경에서는 핸드오버가 빈번하게 발생하게 되어 서비스 품질의 저하가 발생한다. 특히, 고속으로 이동하거나, cell 크기가 작은 도심 환경을 이동하는 차량환경에서는 cell 체류시간 (cell dwell time)이 수 초에 불과하여 만족스런 서비스를 사용자에게 제공하기 어렵다.

현재의 무선 인터넷 망에 (e.g., 3G or Mobile WiMAX) 적용되어 있는 핸드오버 기법은 신호의 세기를 기반으로 핸드오버가 가능한 Neighbor BS(Base station) list를 관리하며, Serving BS의 신호의 세기가 정해진 임계값 이하로 떨어지면, 핸드오버 절차를 수행한다. 이 때, 차량 환경에서는 다음과 같은 요소들이 고려되어야 한다.

- 체류시간이 짧은 BS으로의 핸드오버는 불필요하다. 예를 들어, 기존 핸드오버 방식에 의하면 차량이 이동함에 따라, BS 1, 2, 3로 순차적으로 핸드오버가 발생한다고 가정하자. 만일 BS 1에서 3로 직접 핸드오버 하여도 충분한 품질의 서비스 제공이 가능하다면, BS 2로의 핸드오버는 불필요하다.
- 차량은 도로위로만 주행이 가능하므로, 차량이 접근할 수 없는 영역을 주로 서비스하는 BS으로의 핸드오버는 피하는 것이 좋다. 이는 차량의 이동 패턴을 관찰함으로써 가능하다.
- 버스와 기차는 일정한 경로를 반복하여 이동한다. 도심의 차량도 특별한 경우를 제외하면 몇 가지의 경로만을 이동하는 특성을 가지게 된다. 따라서 historical records를 활용하는 것이 효과적이다.

핸드오버는 서비스 품질 저하와 시그널링 오버헤드를 유발하여 실시간 멀티미디어 서비스 제공에 단점으로 작용하므로 핸드오버 빈도를 줄이는 것이 중요하다. 핸드오버 시그널링 오버헤드를 줄이기 위해, 기존의 Location Management에서 많이 적용되던 위치 추정 기법을 핸드오버에 적용하는 연구들이 수행되었

다^[1-4]. [1]에서는 MN의 이동패턴을 이용하여 Target BS을 예측하여 핸드오버를 수행한다. 이로 인하여 네트워크 자원 이용률을 향상시킬 수 있고, 네트워크의 혼잡을 피할 수 있다. [2]에서는 MN의 순간적인 궤도 추적과 cell geometry, 그리고 MN의 전체적인 이동패턴을 이용하는 HLP(Hierarchical location prediction) 알고리즘을 이용하여 Target BS을 예측하고 핸드오버를 수행한다. 이로 인하여 MN에서 끊임없는 서비스를 제공할 수 있는 확률을 높여줄 수 있다. [3]에서는 MCAS(Motion classification assisted strategy)를 이용하여 MN의 지리적 위치와 이동속도를 구해낸다. 이를 이용하여 MN의 이동 시나리오를 예측하고 Target BS을 결정한 뒤 핸드오버를 수행한다. 이로 인하여 핸드오버 지연시간과 packet loss를 줄여줄 수 있다. [4]에서는 BS이 MN에게서 Previous BS과 Target BS을 수집하여 Mobility pattern table을 생성한다. 향후 다른 MN가 핸드오버를 위한 스캐닝을 수행할 때 BS에서 생성된 Mobility pattern table을 이용하여 주변의 Neighbor BS들이 아닌 자격을 갖춘 BS들만 스캐닝을 수행한다. 이로 인하여 핸드오버를 위한 스캐닝 시간을 단축시킬 수 있고, 핸드오버시 발생하는 packet loss를 줄여줄 수 있다. 이 연구들을 이용하면, 인접 기지국으로의 스캐닝을 줄일 수 있으며, 예측 결과가 타당한 경우, Target BS으로 정확히 핸드오버 할 수 있는 장점이 있다. 하지만 예측을 위한 계산량이 많거나, 알고리즘이 복잡하여 실제로 적용하는데 어려움이 있다.

최근 historical data를 핸드오버에 활용하는 연구가 진행되었다^[5-6]. [5]에서는 계산 오버헤드를 줄이기 위하여 이동방향에 따른 MN의 미래 위치를 구분하는 zone concept을 제안한다. L차 Markov predictor를 사용하여 MN의 서비스 요구성을 예측하고, historical records, 차량의 경로정보와 이동 방향 및 속도, BS의 체류 시간을 이용하여 MN가 핸드오버를 수행할 BS을 예측한다. [6]에서는 MN가 출발지점의 BS에서 도착지점의 BS까지 이동하는 동안의 total weight가 최대가 되도록 하는 BS들로 핸드오버를 수행하는 Maximum Total Weight (MTW) 방법과, step-by-step의 weight가 최대인 BS으로 핸드오버를 수행하는 Step-by-Step Maximum Weight (SSMW) 방법을 제안한다. 미시적인 관점에서는 차량의 이동 속도와 방향, 그리고 GIS 정보를 이용하여 예상되는 Target BS으로 핸드오버를 결정하며, 거시적인 관점에서는 차량의 이동 속성을 지속적으로 학습하여, 학습 결과를 토대로 Target BS을 예측하게 된다. 미시적인 이동만을

고려한 방식은 rural area에는 잘 적용될 수 있지만, 교차로가 많은 metropolitan area에는 적용하기 어렵다. 거시적인 관점은 방대한 양의 trace data들로부터 이동하는 차량의 Target BS을 예측하며, 지속적으로 학습데이터를 업데이트한다. 후자는 계산량이 많거나, 알고리즘이 복잡하여 차량 환경에 적용하기 어려운 단점이 있다. 참고문헌 [7]에서는 trace data들로부터 통계적인 이동 모델을 생성 연구를 수행하였다. 통계적인 이동 모델을 만드는 시스템은 wireless trace data와 지도를 입력 받는다. 여기서 지도는 지도의 그래프 정보와 BS, 빌딩, 교차로 등의 위치정보를 제공한다. 두가지의 입력을 받는 시스템은 Transition probabilities와 User density를 출력하고, 이 출력값들을 이용하여 통계적인 이동 모델을 생성한다. 여기서 User density는 MN의 출발장소와 도착장소를 결정하는 역할을 수행하고, Transition probabilities는 출발장소로부터 도착장소까지의 이동경로를 생성하는 역할을 수행한다. 본 논문에서는 차량의 이동 경로를 지속적으로 학습하여 Mobility behavior profile을 작성하며, 이를 토대로 차량의 핸드오버 과정을 Discrete-time markov chain (DTMC)으로 모델링한다. 핸드오버 시 이동해갈 가능성이 높은 Target BS으로 핸드오버를 수행함으로써, 불필요한 인접 기지국 스캐닝 절차와 핸드오버 절차를 제거할 수 있으므로 시그널링 오버헤드를 줄일 수 있다. 또한, 체류 시간이 짧으며, 핸드오버하지 않아도 서비스가 지속될 수 있는 BS으로의 핸드오버는 방지한다. 따라서 핸드오버 빈도를 줄일 수 있다. 본 논문에서는 차량별로 Mobility behavior profile을 유지한다.

본 논문의 구성은 다음과 같다. II장에서는 제안하는 핸드오버 기법에 대해서 설명을 하고, III장에서는 실험환경을 설명한다. IV장에서는 실험 내용을 통한 성능분석을 하고, V장에서는 결론을 맺는다.

II. 제안하는 핸드오버 기법

본 논문에서 제안하는 핸드오버 기법은 핸드오버 발생시 Serving & Target BS에 대한 데이터를 학습하여 Mobility behavior profile을 생성하고, 생성한 Mobility behavior profile을 바탕으로 DTMC의 1-step & 2-step transition probability matrix를 생성하여 그것들을 이용하여 핸드오버를 수행하는 기법이다.

본 논문에서 제안하는 핸드오버 기법은 그림 1과 같이 크게 세가지 단계로 나누어 볼 수 있다.

첫 번째 단계는, Mobility behavior profile을 생성

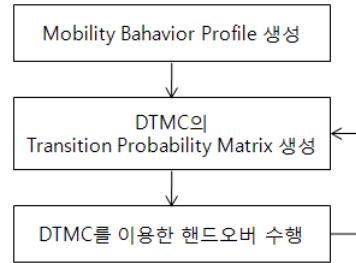


그림 1. 제안하는 핸드오버 기법

하는 단계이다. 이 단계에서는 MN가 기존 핸드오버 기법으로 핸드오버를 수행하며 핸드오버 정보를 학습하는 Mobility behavior profile을 생성한다. 생성된 Mobility behavior profile은 $n \times n$ 의 Handover records matrix Q 에 저장된다.

두 번째 단계는, DTMC의 Transition probability matrix를 생성하는 단계이다. 이 단계 첫 번째 단계에서 생성된 Handover records matrix Q 를 이용하여 DTMC의 1-step transition probability matrix와 2-step transition probability matrix를 생성한다.

세 번째 단계는, DTMC을 이용하여 핸드오버를 수행하는 단계이다. 이 단계에서는 두 번째 단계에서 생성한 1-step transition probability matrix와 2-step transition probability matrix를 이용하여 핸드오버를 수행한다. 핸드오버 수행 시 첫 번째 단계에서 생성된 Mobility behavior profile을 업데이트 해주고, 업데이트된 Mobility behavior profile은 $n \times n$ 의 Handover records matrix Q 에 저장된다. 모든 핸드오버가 종료 되면 다시 두 번째 단계로 돌아가 업데이트된 Handover records matrix Q 를 이용하여 DTMC의 Transition probability matrix를 재생성 한다.

2.1 학습을 통한 Mobility Behavior Profile 생성

초기에 Mobility behavior profile이 없는 경우 기존 핸드오버 기법으로 핸드오버를 수행하며 핸드오버 정보를 학습하여 Mobility behavior profile을 생성한다. Mobility behavior profile은 $n \times n$ 의 Handover records matrix Q 에 저장된다. Handover records matrix Q 는 다음과 같다.

$$Q = \begin{bmatrix} q_{11} & \cdots & q_{1n} \\ \vdots & \ddots & \vdots \\ q_{n1} & \cdots & q_{nn} \end{bmatrix} \quad (1)$$

초기값으로, Q 의 모든 elements는 0으로 설정하며 (i.e., $q_{ij} = 0$ for all i and j) 차량이 BS_i 에서 BS_j 로 한

드오버를 수행하면, q_{ij} 의 값을 1 증가시킨다.

기존 핸드오버 기법을 통한 Mobility behavior profile을 생성하는 방법은 그림 2의 플로우 차트와 같다.

본 논문에서는 스캐닝을 시작하는 임계값을 -80dB, 핸드오버 히스테리시스 마진을 3dB라고 가정하였고, 변수 s 는 Serving BS, 변수 f 는 Target BS, 변수 n 은 BS의 총 개수, 변수 t 는 프로세스의 진행시간을 의미한다. 변수 t 는 1당 100ms를 나타내기 때문에 핸드오버 기법은 100ms 간격으로 수행된다.

MN와 Serving BS간의 RSSI가 $RSSI_s(t) < -80dB$ 와 같은 조건을 만족하여 임계치 미만이 될 경우, 기존 핸드오버 기법(블록201)을 수행하여 핸드오버를 수행할 Target BS을 찾는다. 블록201은 그림 3의 플로우 차트와 같다.

아래의 조건을 만족하는 BS들 중 가장 큰 RSSI값을 BS_i 를 Target BS BS_f 로 지정한다.

$$RSSI_i(t) > RSSI_s(t), \quad 1 \leq i \leq n \quad (2)$$

조건에 만족하는 Target BS BS_f 를 찾은 경우, Handover records matrix \mathbf{Q} 의 q_{sf} 에 1을 증가시키고 Target BS BS_f 로 핸드오버를 수행한다. 조건에 만족하는 Target BS BS_f 를 찾지 못한 경우, 처음으로 돌아가 100ms 이후 모든 과정을 되풀이한다.

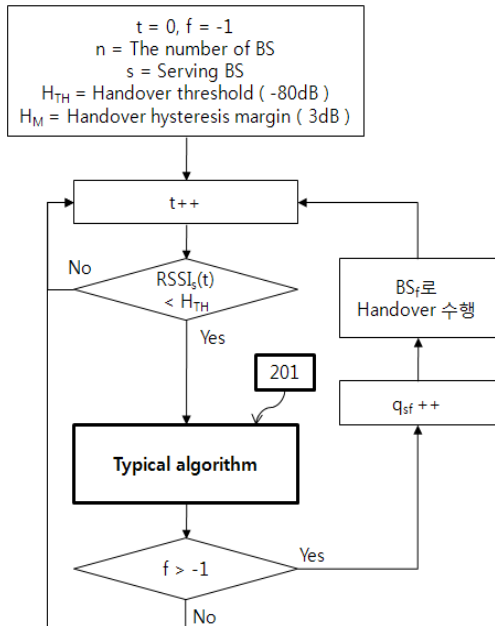


그림 2. 기존 핸드오버 기법을 통한 Mobility Behavior Profile 생성

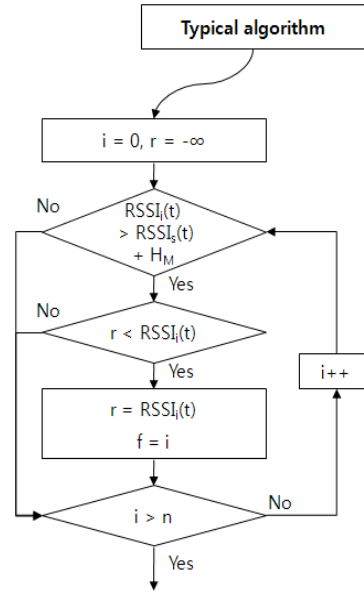


그림 3. 기존 핸드오버 기법

2.2 DTMC의 Transition Probability Matrix 생성

2.1장을 통해 생성한 Handover records matrix \mathbf{Q} 를 이용하여 제안하는 핸드오버 기법에서 사용하기 위한 DTMC의 1-step & 2-step transition probability matrix를 생성한다.

MN가 핸드오버 수행 돼 연결되는 BS들을 시간 순서대로 $\{X_0, X_1, \dots, X_t\}$ 와 같은 process로 나타낼 때, 핸드오버를 수행할 때는 현재 연결되어있는 Serving BS에 의해서만 영향 받기 때문에 process의 conditional pmf는 아래의 식처럼 Memoryless property를 갖는다.

$$P(X_{t+1} = b_{t+1} | X_t = b_t, X_{t-1} = b_{t-1}, \dots, X_0 = b_0) = P(X_{t+1} = b_{t+1} | X_t = b_t) \quad (3)$$

$$t \in \mathbb{N}_0, b_t \in \{BS_1, BS_2, \dots, BS_n\}, n = \text{The number of BS}$$

위의 process가 시간 t 에서 BS_i 에서 BS_j 로 핸드오버를 수행 할 1-step transition 하는 conditional pmf는 아래와 같다.

$$p_{ij}^{(1)}(t) = P(X_{t+1} = b_{t+1} = BS_j | X_t = b_t = BS_i) \quad (4)$$

BS_i 에서 BS_j 로 수행하는 핸드오버는 시간에 관계 없이 MN가 BS_i 에서 멀어지고 BS_j 로 근접하게 될 때 발생하게 된다. 그러므로 BS_i 에서 BS_j 로 핸드오버를 수행 할 1-step transition 하는 conditional pmf는 아

래의 식처럼 Time homogeneous property를 갖는다.

$$\begin{aligned}
 p_{ij} &= p_{ij}^{(1)} = p_{ij}^{(1)}(t) \\
 &= P(X_{t+1} = BS_j | X_t = BS_i) \\
 &= P(X_1 = BS_j | X_0 = BS_i)
 \end{aligned}
 \tag{5}$$

MN이 핸드오버를 수행하는 process는 Memoryless property와 Time homogeneous property를 갖기 때문에 DTMC을 구성할 수 있다.

임의의 BS_i에서 임의의 BS_j로 핸드오버 하는 process로 구성된 DTMC의 1-step transition probability p_{ij}들은 아래와 같은 특성을 갖는다.

$$\sum_j p_{ij} = 1, 0 \leq p_{ij} \leq 1
 \tag{6}$$

그렇기 때문에 Handover records matrix Q의 q_{ij}를 아래와 같이 변환하여 p_{ij}를 생성한다.

$$p_{ij} = \frac{q_{ij}}{\sum_j q_{ij}}
 \tag{7}$$

생성된 1-step transition probability들은 matrix 형태로 표현을 하고, 그 matrix를 1-step transition probability matrix P라 부른다. 1-step transition probability matrix P는 다음과 같다.

$$\mathbf{P} = \begin{bmatrix} p_{11} & \cdots & p_{1n} \\ \vdots & \ddots & \vdots \\ p_{n1} & \cdots & p_{nn} \end{bmatrix}
 \tag{8}$$

임의의 BS_i에서 임의의 BS_j로 핸드오버 하는 process로 구성된 DMTC의 2-step transition probability는 MN가 BS_i에 연결되어 있을 때, 2번의 핸드오버를 수행하여 BS_j로 연결 될 probability를 의미한다. 그러므로 2-step transition probability 는 1-step transition probability 를 2번 반복 수행한 결과와 같은 값을 갖는다. 2-step transition probability matrix P⁽²⁾는 아래의 식을 통하여 생성한다.

$$\mathbf{P}^{(m)} = \mathbf{P} \mathbf{P}^{(m-1)} = \mathbf{P}^m
 \tag{9}$$

2.3 DTMC을 이용한 핸드오버 기법

DTMC을 이용한 핸드오버 기법은 그림 4의 플로우 차트와 같다.

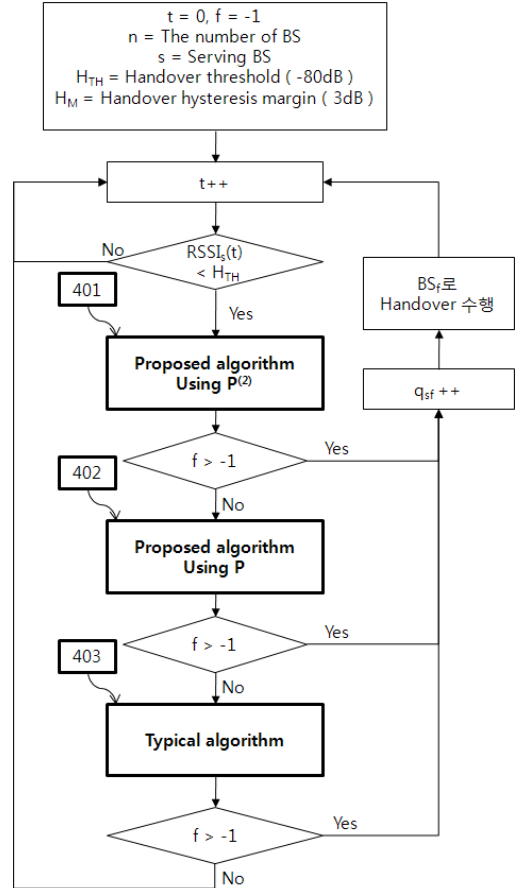


그림 4. DTMC을 이용한 핸드오버 기법

MN와 Serving BS간의 RSSI가 RSSI_s(t) < -80dB와 같은 조건을 만족하여 임계치 미만일 경우, 2-step transition probability matrix P⁽²⁾를 이용한 핸드오버 기법(블록401)을 수행하여 핸드오버를 수행할 Target BS를 찾는다. 블록401은 그림 5의 플로우 차트와 같다.

우선적으로 2-step transition probability matrix P⁽²⁾를 이용하여 Target BS을 찾는 이유는 다음과 같다. 기존 핸드오버 기법은 스캐닝을 수행할 때 최적의 BS을 찾아 핸드오버를 수행하는 것이 아니라 그 순간 신호의 세기가 가장 큰 BS으로 핸드오버를 수행한다. 만약 신호의 세기가 가장 큰 BS이 최적의 BS이 아닐 경우 신호의 세기가 가장 큰 BS으로 핸드오버를 수행한 뒤 곧이어 최적의 BS으로 핸드오버를 수행하게 되어 불필요한 핸드오버가 발생하는 결과를 초래하게 된다. 이와 같은 사건이 발생하게 되면 2-step transition probability matrix P⁽²⁾에서 Serving BS에서 최적의 BS으로 핸드오버를 수행하는 probability가

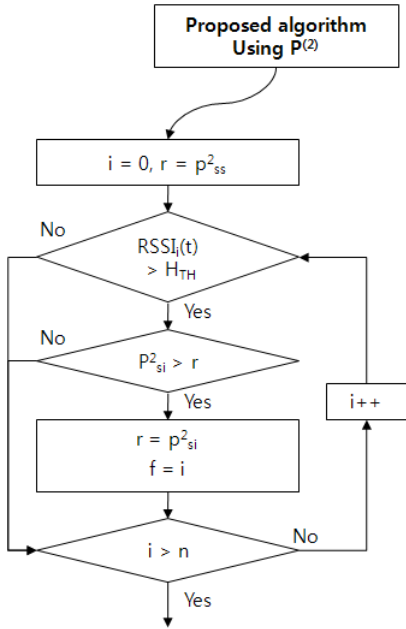


그림 5. 2-step transition probability matrix $P^{(2)}$ 를 이용한 핸드오버 기법

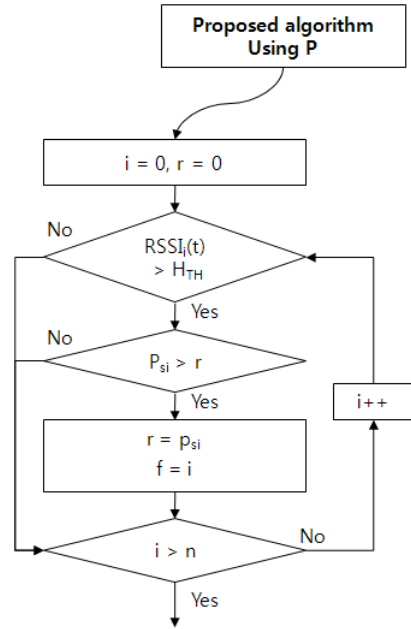


그림 6. 1-step transition probability matrix P 를 이용한 핸드오버 기법

높은 값을 갖게 된다. 그렇기 때문에 불필요하게 발생하는 핸드오버를 제거시켜주기 위해 우선적으로 2-step transition probability matrix $P^{(2)}$ 를 이용하여 Target BS을 찾게 된다. 그러나 최적의 BS이라 할지라도 임계치 이하의 RSSI값을 갖는다면 핸드오버가 불가능하게 되고, $p^{(2)}_{ss}$ 가 가장 큰 probability를 갖는다면 MN가 Serving BS에서 Neighbor BS으로 핸드오버를 수행한 뒤 다시 Serving BS으로 되돌아 온다는 뜻이기 때문에 1-step transition probability matrix P 를 이용하여야 한다. 그러므로 아래의 조건을 만족하는 BS들 중 가장 큰 probability를 갖는 BS_i 를 Target BS BS_f 로 지정한다.

$$RSSI_i(t) > -80dB, p^{(2)}_{si} > r, 1 \leq i \leq n \quad (10)$$

조건에 만족하는 Target BS BS_f 를 찾지 못한 경우, 1-step transition probability matrix P 를 이용한 핸드오버 기법(블록402)을 수행하여 핸드오버를 수행할 Target BS을 찾는다. 블록402는 그림 6의 플로우 차트와 같다.

1-step transition probability matrix P 에서 가장 큰 probability를 갖는다는 것은 해당 BS으로 핸드오버를 수행할 확률이 가장 크다는 것을 의미한다. 그러나 가장 큰 probability를 갖는 BS이라 할지라도 임계

치 이하의 RSSI값을 갖는다면 핸드오버가 불가능하게 된다. 그러므로 아래의 조건을 만족하는 BS들 중 가장 큰 probability를 갖는 BS_i 를 Target BS BS_f 로 지정한다.

$$RSSI_i(t) > -80dB, p_{si} > 0, 1 \leq i \leq n \quad (11)$$

조건에 만족하는 Target BS BS_f 를 찾지 못한 경우, 기존 핸드오버 기법(블록403)을 수행하여 핸드오버를 수행할 Target BS을 찾는다. 블록403은 그림 2의 플로우 차트와 같다.

1-step & 2-step transition probability matrix를 이용하여 Target BS을 찾지 못한 경우 기존 핸드오버 기법을 이용하는 이유는 MN가 다른 길로 이동하여 Mobility behavior profile에 학습되지 않은 BS로 핸드오버를 할 가능성도 있기 때문에, 그 경우에도 적절한 BS으로 핸드오버를 수행시켜줘야 하기 때문이다.

조건에 만족하는 Target BS BS_f 를 찾은 경우, Handover records matrix Q 의 q_{sr} 에 1을 증가시켜 업데이트를 하고 Target BS BS_f 로 핸드오버를 수행한다. 조건에 만족하는 Target BS BS_f 를 찾지 못한 경우, 처음으로 돌아가 100ms 이후 모든 과정을 되풀이한다.

MN가 이동을 모두 마치게 되면 2-2장으로 돌아가

업데이트 된 Handover records matrix Q 를 이용하여 1-step & 2-step transition probability matrix를 업데이트 시켜준다.

III. 실험환경

본 실험의 실험공간은 2km x 2km 이다.

실험공간 안의 3개의 Topology에서 실험을 진행한다. Topology 1은 총 16개의 BS들이 위치한다. 좌측 하단에 위치하는 BS은 (100m, 50m) 좌표에 위치하고 다른 BS들은 각각 600m씩 grid하게 떨어져서 위치한다. Topology 2는 총 49개의 BS들이 위치한다. 좌측 하단에 위치하는 BS은 (25m, 25m) 좌표에 위치하고 다른 BS들은 각각 300m씩 grid하게 떨어져서 위치한다. Topology 1과 Topology 2의 실험 공간은 2km x 2km 이고, 그림 7과 같다.

Topology 3의 실험 공간은 45km x 45km이고, 총 256개의 BS들이 위치한다. 좌측 하단에 위치하는 BS




그림 7. Topology 1과 Topology 2

는 (0m, 0m) 좌표에 위치하고 다른 BS들은 각각 300m씩 grid하게 떨어져서 위치한다. Topology 3은 그림 8과 같다.

본 실험에는 4개의 Mobility model의 실험을 통해 성능을 분석한다. Mobility model 1과 Mobility model 2는 Manhattan model로부터 추출하였고, Mobility model 3와 Mobility model 4는 실제 버스의 이동모델을 이용하였다. 4개의 이동모델은 그림 9와 같다.

Mobility model 1는 MN가 해당경로를 왕복하는 이동을 하게 되고, Mobility model 2는 해당경로를 한 바퀴 돌게 된다. 2개의 Mobility model의 MN는 72km/h의 등속도로 이동한다.

Mobility model 3는 서울 4433번 버스의 이동경로이고, Mobility model 4는 서울 4434번 버스의 이동경로이다. 2개의 Mobility model의 MN는 각 정류장과 정류장 사이를 10.8km/h, 21.6km/h, 43.2km/h의 속도 중 하나의 속도로 이동한다. 10.8km/h의 속도로 이동할 확률은 43%, 21.6km/h의 속도로 이동할 확률은 37%, 43.2km/h의 속도로 이동할 확률은 20%이다.

MN과 BS간의 RSSI값은 Cost 231 Hata propagation model^[8]을 이용하여 추출하였다. RSSI값의 추출에 관련된 parameter들은 다음 표 1과 같다.

Cost 231 Hata propagation model을 통해 추출해 낸 값이 $Y(\text{dB})$ 라면 생성되는 RSSI 값은 다음과 같다.

$$RSSI = 43(\text{dBm}) - Y(\text{dB}) - 10(\text{dB}) \quad (12)$$

MN의 평균 Throughput은 AMC set에 해당하는 Mobile WiMAX의 Downlink data rate^[9]를 이용하여,




그림 8. 실험공간 및 Topology 3

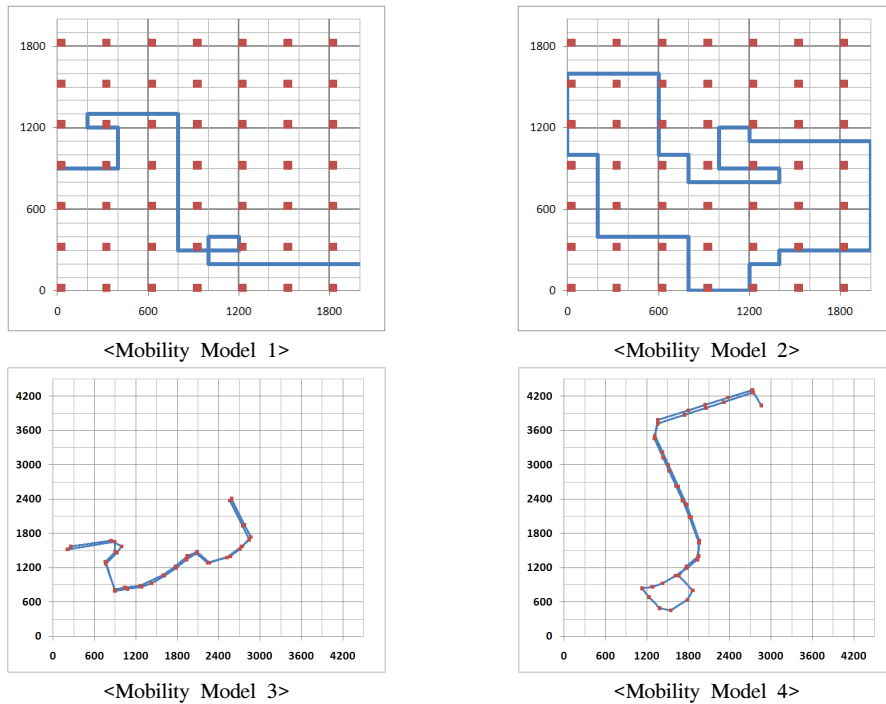


그림 9. 실험에서 사용되는 4개의 Mobility Model

표 2처럼 RSSI값에 해당하는 Throughput을 mapping 하여 도출해 내었다.

실험에서 제안하는 핸드오버 방법과 비교할 대조군으로 쓰일 핸드오버 기법은 그림 1과 그림 2에 나오는

기존 핸드오버 기법을 사용하였다.

IV. 실험 및 성능분석

4개의 Mobility model 실험에서는 5회의 learning을 수행한 뒤, 1-step & 2-step transition probability matrix를 생성하여 제안하는 핸드오버에 사용하였다. Mobility model 1, 2의 경우는 MN가 경로를 100% 지키며 9회의 learning을 더 수행한 뒤, 경로를 100%, 75%, 50%, 25% 지키며 이동하는 경우에 기존의 핸드오버 기법을 사용한 결과와 DTMC의 1-step & 2-step transition probability matrix를 이용한 핸드오버 기법을 사용한 결과를 비교하였다. Mobility model 3, 4의 경우는 MN가 경로를 100% 지키며 9회의 learning을 더 수행한 뒤, 경로를 100% 지키며 이동하는 경우에 기존의 핸드오버 기법을 사용한 결과와 DTMC의 1-step & 2-step transition probability matrix를 이용한 핸드오버 기법을 사용한 결과를 비교하였다. Mobility model 3, 4의 경우 경로를 100% 지키는 경우만을 실험한 이유는 Mobility model 3, 4는 실제 버스의 이동경로이기 때문에 항상 경로를 100% 지키며 이동하기 때문이다.

그림 10은 MN가 Mobility model 1, 2가 Topology

표 1. RSSI값의 도출에 관련된 parameter

Parameter	Value
BS Height	32 m
MN Height	1.5 m
Propagation Model	Cost 231 Hata Propagation Model
BS Maximum Power Amplifier Power	43 dBm
Penetration Loss	10 dB

표 2. AMC set에 해당하는 RSSI와 Data rate

Modulation	FEC rate	RSSI(dB)	Data rate (kbps) WiMax
64QAM	3/4	≥ -66.86	16848
64QAM	2/3	≥ -68.86	14976
16QAM	3/4	≥ -72.86	11232
16QAM	1/2	≥ -74.86	7488
QPSK	3/4	≥ -79.86	5616
QPSK	1/2	≥ -81.86	3744
QPSK	1/4	else	1872

1, 2에서 이동하는 동안에 발생한 핸드오버 횟수와 MN가 Mobility model 3, 4가 Topology 3에서 이동하는 동안 발생한 핸드오버 횟수를 나타내고, 그림 11은 제안하는 핸드오버 기법의 기존 핸드오버 기법과 비교했을 때 핸드오버 감소횟수를 나타낸다. MN가 Topology 1에서 Mobility model 1의 경로를 50% 지키며 이동하는 경우와, Topology 2에서 Mobility model 1의 경로를 25% 지키며 이동하는 경우를 제외

하고는 모든 경우에서 핸드오버가 감소하였다.

MN가 Topology 1에서 Mobility model 1의 경로를 이동할 때, 경로를 100%, 75% 지키며 이동하는 경우에는 핸드오버가 4회 감소하였고, 50% 지키며 이동하는 경우에는 동일하게 발생하였고, 25% 지키며 이동하는 경우에는 3회 감소하였다. MN가 Topology 2에서 Mobility model 1의 경로를 이동할 때, 경로를 100%, 75%, 50% 지키며 이동하는 경우는 핸드오버

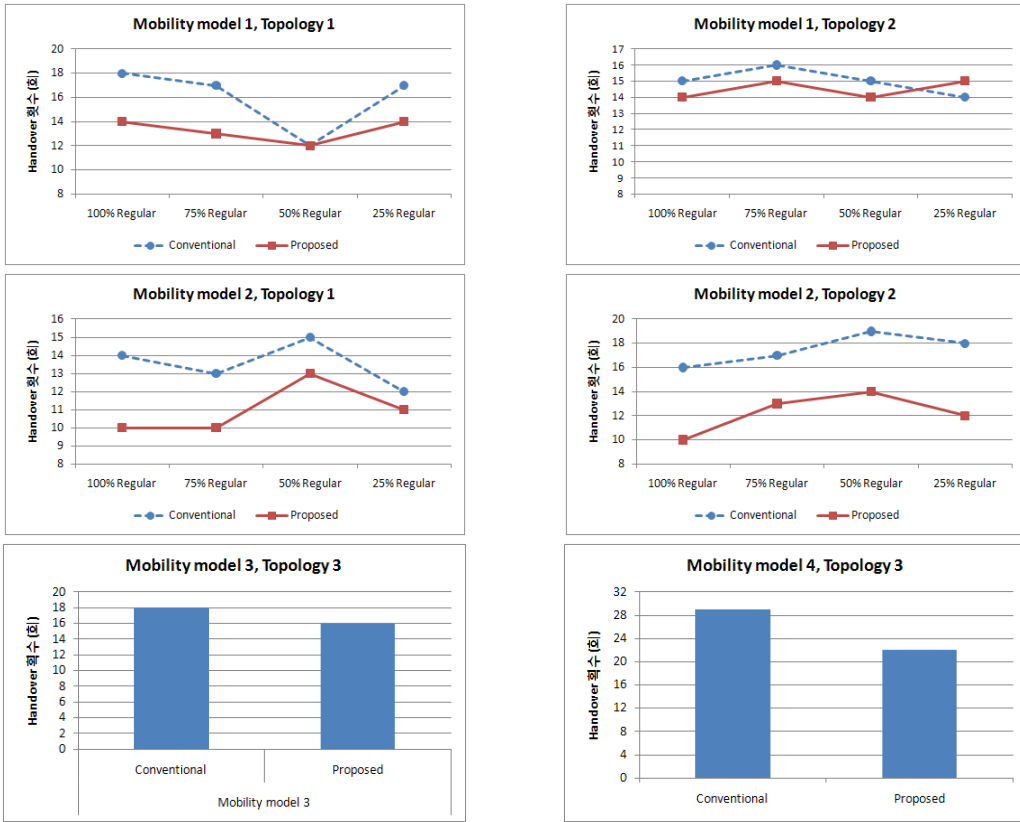


그림 10. 4개의 Mobility Model에서 발생한 핸드오버 횟수




그림 11. 4개의 Mobility Model에서 발생한 핸드오버 감소횟수

가 1회 감소하였고, 25% 지키며 이동하는 경우에는 1회 증가하였다.

MN가 Topology 1에서 Mobility model 2의 경로를 이동할 때, 경로를 100% 지키며 이동하는 경우에는 핸드오버가 4회 감소하였고, 75%, 50%, 25% 지키며 이동하는 경우에는 핸드오버가 이동하는 경우에는 각각 3회, 2회, 1회 감소하였다. MN가 Topology 2에서 Mobility model 2의 경로를 이동할 때, 경로를 100% 지키며 이동하는 경우에는 핸드오버가 6회 감소하였고, 75%, 50%, 25% 지키며 이동하는 경우에는 핸드오버가 이동하는 경우는 각각 4회, 5회, 6회 감소하였다.

MN가 Topology 3에서 Mobility model 3의 경로를 이동할 때 핸드오버가 2회 감소하였고, Mobility model 4의 경로를 이동할 때 7회 감소하였다.

다음과 같이 핸드오버의 횟수가 줄어든 이유는 Target BS이 2-step transition probability matrix를 이용하여 결정되어 신호의 세기에 의해 결정되던 BS을 건너 뛰어 다음 BS으로 핸드오버를 수행하는 경우가 발생하였기 때문이다. 경로를 100%, 75% 지키며 이동하는 경우에는 2-step transition probability matrix가 효과적으로 작용하여 모든 경우에서 핸드오버의 횟수가 줄어들었다. 그러나 50%, 25% 지키며 이동하는 경우에는 MN가 이동경로를 어떻게 벗어나느냐에 따라서 핸드오버의 횟수가 줄어들거나, 증가하거나, 동일하게 발생할 수 있다는 것을 확인하였다.

그림 12는 제안하는 핸드오버 기법의 기존 핸드오버 기법과 비교했을 때 평균 RSSI 이득을 나타낸다. MN가 Topology 1에서 Mobility model 1의 경로를 50%, 25% 지키며 이동하는 경우와, Topology 2에서 Mobility model 1의 경로를 25% 지키며 이동하는 경우를 제외하고는 모든 경우에서 평균 RSSI가 증가하였다.

MN가 Topology 1에서 Mobility model 1의 경로

를 이동할 때, 경로를 100%, 75% 지키며 이동하는 경우에는 평균 RSSI가 약 0.26dB 상승하였고, 50% 지키며 이동하는 경우에는 동일한 평균 RSSI가 관측되었고, 25% 지키며 이동하는 경우에는 약 0.26dB 감소하였다. MN가 Topology 2에서 Mobility model 1의 경로를 이동할 때, 경로를 100%, 75%, 50% 지키며 이동하는 경우는 평균 RSSI가 각각 약 0.35dB, 2.8dB, 0.57dB 상승하였고, 25% 지키며 이동하는 경우에는 약 4.04dB 감소하였다.

MN가 Topology 1에서 Mobility model 2의 경로를 이동할 때, 경로를 100%, 75%, 50%, 25% 지키며 이동하는 경우에는 평균 RSSI가 각각 약 0.4dB, 0.4dB, 0.32dB, 0.27dB 증가하였다. MN가 Topology 2에서 Mobility model 2의 경로를 이동할 때, 경로를 100%, 75%, 50%, 25% 지키며 이동하는 경우에는 평균 RSSI가 각각 약 2.95dB, 0.31dB, 2.2dB, 3.06dB 하였다.

MN가 Topology 3에서 Mobility model 3의 경로를 이동할 때 평균 RSSI가 약 3.72dB 증가하였고, Mobility model 4의 경로를 이동할 때 약 3.76dB 증가하였다.

다음과 같이 MN가 Topology 1에서 Mobility model 1의 경로를 50%, 25% 지키며 이동하는 경우와, Topology 2에서 Mobility model 1의 경로를 25% 지키며 이동하는 경우를 제외하고는 모든 경우에서 평균 RSSI가 증가한 이유는 신호의 세기에 의해 결정되던 BS이 최적의 BS이 아니라 2-step transition probability matrix를 이용하여 결정되는 BS이 최적의 BS이기 때문이다. 경로를 100%, 75% 지키며 이동하는 경우에는 2-step transition probability matrix가 효과적으로 작용하여 2-step transition probability matrix를 이용하여 결정되는 BS이 최적의 BS이 되는 경우의 확률이 더 높다. 그렇기 때문에 평균 RSSI가 증가하였다. 그러나 50%, 25% 지키며 이동하는 경우




그림 12. 4개의 Mobility Model의 평균 RSSI 이득

에는 MN가 이동경로를 어떻게 벗어나느냐에 따라서 2-step transition probability matrix를 이용하여 결정되는 BS이 최적의 BS이 되는 경우의 확률이 달라지기 때문에 평균 RSSI가 감소하거나, 증가하거나, 동일하게 발생할 수 있다는 것을 확인하였다.

그림 13은 MN가 Mobility model 1, 2가 Topology 1, 2에서 이동하는 동안의 평균 Throughput과 MN가 Mobility model 3, 4가 Topology 3에서 이동하는 동안의 평균 Throughput을 나타내고, 그림 14는 제안하는 핸드오버 기법의 기존 핸드오버 기법과 비교했을 때 평균 Throughput 이득을 나타낸다. MN가 Topology 1, 2에서 Mobility model 1의 경로를 50%, 25% 지키며 이동하는 경우를 제외하고는 모든 경우에서 평균 Throughput이 증가하였다.

MN가 Topology 1에서 Mobility model 1의 경로를 이동할 때, 경로를 100%, 75% 지키며 이동하는 경우에는 평균 Throughput이 약 138.98kbps 상승하였고, 50% 지키며 이동하는 경우에는 동일한 평균 Throughput이 관측되었고, 25% 지키며 이동하는 경우에는 약 181.83kbps 감소하였다. MN가 Topology

2에서 Mobility model 1의 경로를 이동할 때, 경로를 100%, 75% 지키며 이동하는 경우는 평균 Throughput이 각각 약 37.95kbps, 510.55kbps 상승하였고, 50% 25% 지키며 이동하는 경우에는 각각 약 225.94kbps, 860.89kbps 감소하였다.

MN가 Topology 1에서 Mobility model 2의 경로를 이동할 때, 경로를 100%, 75%, 50%, 25% 지키며 이동하는 경우에는 평균 Throughput이 각각 약 168.09kbps, 147.67kbps, 225.11kbps, 145.11kbps 증가하였다. MN가 Topology 2에서 Mobility model 2의 경로를 이동할 때, 경로를 100%, 75%, 50%, 25% 지키며 이동하는 경우에는 평균 Throughput이 각각 약 798.76kbps, 177.03kbps, 634.92kbps, 999.19kbps 증가하였다.

MN가 Topology 3에서 Mobility model 3의 경로를 이동할 때 평균 Throughput이 약 524.19kbps 증가하였고, Mobility model 4의 경로를 이동할 때 약 292.78kbps 증가하였다.

다음과 같이 MN가 Topology 1에서 Mobility model 1의 경로를 50%, 25% 지키며 이동하는 경우

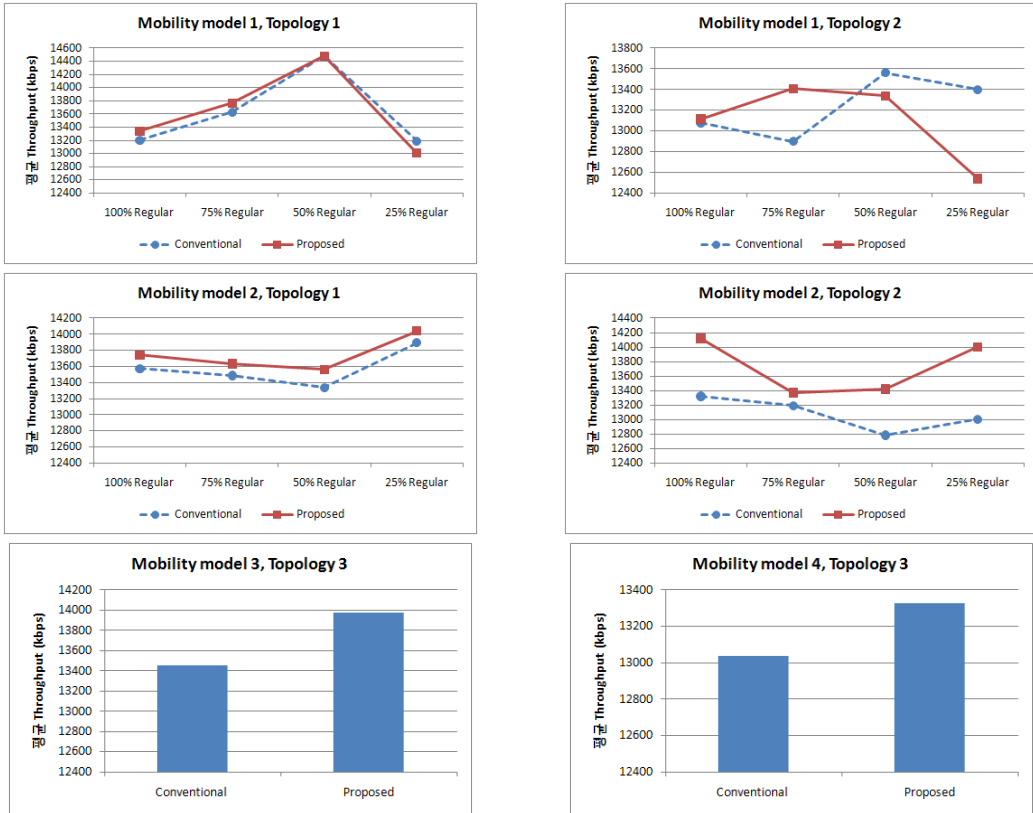


그림 13. 4개의 Mobility Model의 Throughput




그림 14. 4개의 Mobility Model의 평균 Throughput 이득

를 제외하고는 모든 경우에서 평균 Throughput이 증가한 이유는 평균 RSSI의 경우와 마찬가지로 신호의 세기에 의해 결정되던 BS이 최적의 BS이 아니라 2-step transition probability matrix를 이용하여 결정되는 BS이 최적의 BS이기 때문이다. 경로를 100%, 75% 지키며 이동하는 경우에는 2-step transition probability matrix가 효과적으로 작용하여 2-step transition probability matrix를 이용하여 결정되는 BS이 최적의 BS이 되는 경우의 확률이 더 높다. 그렇기 때문에 평균 Throughput이 증가하였다. 그러나 50%, 25% 지키며 이동하는 경우에는 MN가 이동경로를 어떻게 벗어나느냐에 따라서 2-step transition probability matrix를 이용하여 결정되는 BS이 최적의 BS이 되는 경우의 확률이 달라지기 때문에 평균 Throughput이 감소하거나, 증가하거나, 동일하게 발생할 수 있다는 것을 확인하였다.

V. 결론

본 논문에서는 무선 인터넷 서비스 성능의 향상을 위해 MN의 핸드오버 정보를 learning 하여 생성된 Mobility behavior profile을 이용하여 핸드오버를 수행하는 기법을 제안하였다. BS의 위치환경이 Manhattan model로부터 추출한 2개의 Mobility Model에서 MN가 경로를 100%, 75%, 50%, 25% 지키면서 이동할 경우와 2개의 실제 버스의 Mobility model에서 MN가 이동하는 경우 기존 핸드오버 기법과의 비교실험을 통하여 핸드오버 발생 횟수, RSSI, Throughput을 확인하였다.

Manhattan model의 경우 경로를 100%, 75% 지키면서 이동할 경우에는 거의 모든 경우 기존 방법보다 향상된 성능을 보이는 것을 확인할 수 있었고, 경로를 50%, 25% 지키면서 이동할 경우에는 때에 따라 향상된 성능을 보이기도, 좋지 않은 성능을 보이기도 하는

것을 확인할 수 있었다. 그리고 실제 버스의 Mobility model의 경우 기존 방법보다 향상된 성능을 보이는 것을 확인할 수 있었다. 이를 통하여 어느 정도의 일관성을 갖고 움직이는 MN에게는 향상된 무선 인터넷 서비스를 제공할 수 있다는 사실을 확인하였다.

참고 문헌

- [1] A. Aljadhaj and T. F. Znati, "Predictive mobility support for QoS, provisioning in mobile wireless environments," *IEEE J. Select. Areas Commun.*, Vol. 19, pp.1915-1931, Oct., 2001.
- [2] T. Liu, P. Bahl, and I. Chlamtac, "Mobility modeling, location tracking, and trajectory prediction in wireless ATM networks," *IEEE J. Select. Areas Commun.*, Vol.16, pp.922-936, Aug., 1998.
- [3] Gu Chen, Song Mei and Zhang Young, "Position-prediction-based Motion Classification Assisted Strategy in Mobility Management," *ICICS 2009.*, pp.1-5, Dec., 2009.
- [4] Zhenxia Zhang et al., "Reducing Handoff Latency for WiMAX Networks using Mobility Patterns," *WCNC 2010 IEEE.*, pp.1-6, Apr., 2010.
- [5] I. Akyildiz and W. Wang, "The Predictive User Mobility Profile Framework for Wireless Multimedia Networks," *IEEE/ACM Trans. on Networking*, Vol.12, No.6, pp.1021-1035, Dec., 2004.
- [6] E. Natalizio and G. Aloï, "Exploiting Recurrent Paths of Vehicular Users in a Third Generation Cellular System Urban Scenario," *in Proc*

