

은닉 마르코프 모형을 이용한 항공기 지상이동 운항모드 추정 방법 연구

A Hidden Markov Model Framework for Aircraft Taxi Mode Inference

홍성권^{1*}, 전대근¹, 은연주¹, 김현경¹

한국항공우주연구원¹

초 록

본 논문에서는 공항 지상 감시 장비(ASDE: Airport Surface Detection Equipment) 데이터를 이용하여 항공기의 지상이동 운항모드를 추정하는 방법을 제안하였다. 제안된 방법에서는 항공기의 운항모드와 그에 따라 관측되는 속도 및 가속도를 확률 변수로 정의함으로써, 확률적 추정방법을 통해 운항모드를 추정하였다. 운항모드를 추정하기 위한 모형으로서는 은닉 마르코프 모형(HMM: Hidden Markov Model)을 사용하였으며 실제 ASDE 데이터를 통해 제안된 방법의 성능을 검증해 보았다.

1. 서 론

항공교통량이 지속적으로 증가함에 따라 항공기의 출발부터 도착까지 전 단계에 걸쳐 비효율적인 운항이 발생하고 있다. 이러한 비효율성은 경제적 뿐 아니라 환경적인 문제까지 야기함으로써 점차 심각한 문제로 대두되고 있다. 특히 공항 지상에서는 활주로와 유도로 등의 제한된 자원을 다수의 항공기가 공유해서 사용하기 때문에 항공기의 비효율성이 더욱 극심하게 발생하게 되는데, 최근 들어 이와 같은 문제를 해결하고자 공항 지상에서의 항공기 흐름을 최적으로 제어하기 위한 다양한 방법들이 개발되고 있다[1-4]. 이러한 방법들은 항공기의 지상이동 시간 등을 정밀하게 예측함으로써 개별 항공기의 연료 소모나 공항 정체를 최소화 할 수 있는 최적의 항공기 출발 계획을 계산하게 된다.

이와 같이 공항 지상운영의 최적화에 대한 관심이 날로 증가함에 따라 항공기의 지상이동 특성에 대한 분석이 매우 중요해지고 있다. 예를 들어, 최적화 방법을 통해 신뢰성있는 출발 계획을 제공하기 위해서는 항공기의 지상이동 시간 예측이 매우 중요한데, 이를 위해서는 항공기의 지상이동 특성의 분석이 선행되어야 한다[5-7]. 또 다른 예로서, 개발된 최적화 방법의 효과를 정밀하

게 분석하기 위해서는 과거 지상 항공기 궤적으로부터 연료 소모량을 분석하거나[8], 지상에서의 항공기 운항을 잘 모사할 수 있어야 한다[9].

본 연구에서는 항공기의 지상이동 특성을 분석하는데 중요한 항공기의 운항모드를 추정하기 위한 방법을 제안하였다. 제안된 방법은 공항 지상 감시 장비(ASDE: Airport Surface Detection Equipment) 데이터가 주어졌을 때 항공기의 운항모드를 추정하는 방법으로서, 확률적 모형인 은닉 마르코프 모형(HMM: Hidden Markov Model)이 사용되었다. 제안된 방법은 실제 인천국제공항의 ASDE 데이터를 통해 그 성능을 검증해 보았다.

2. 지상이동 운항모드 추정 모형

ASDE(Airport Surface Detection Equipment)는 공항 지상감시 장비로서 공항 지상에서 이동하는 항공기의 위치 및 속도 등 다양한 정보를 제공하여 관제사들이 지상 항공기를 안전하고 효율적으로 관리할 수 있도록 한다. 또한 수집된 ASDE 데이터는 다양한 정보를 포함하고 있어 항공기의 지상이동 특성을 분석하는데 유용하게 사용될 수 있다. 이러한 ASDE 데이터로부터 항공기의 지상에서의 가속 및 감속의 특성이나 특정 유도로에서의 등속 이동속도, 또는 활주로 대기 시 정지한

시간 등을 효율적으로 분석하기 위해서는 항공기의 궤적을 운항모드 별로 구분하는 것이 매우 중요하다. 여기서 운항모드란 항공기의 동적 상태에 대한 정의로서, 본 연구에서는 정지(stop), 등속(constant speed), 감속(deceleration), 가속(acceleration)의 네 가지 운항모드를 고려하였다.

항공기의 궤적을 운항모드 별로 구분하기 위한 가장 일반적인 방법으로서, 각 모드별로 특정 변수에 대한 한계치(Threshold)를 설정하는 방법이 연구되었다[7, 8]. 하지만 이와 같은 방법은 연구자가 한계치를 임의로 설정해야 하며, 단일 한계치를 사용함으로써 결과가 데이터의 노이즈에 민감하다는 단점이 존재한다.

본 연구에서는 이와 같은 문제를 해결하기 위하여 확률적 추정방법을 사용하였다. 제안된 방법에서는 항공기의 지상이동 운항모드가 확률변수로 정의되며, ASDE 데이터는 각 운항모드에 종속적인 확률변수로서 정의되었다. 여기서 실제 항공기의 운항모드는 직접적으로 관측될 수 없으며 ASDE 데이터만이 관측될 수 있다. 또한 ASDE 데이터의 다양한 정보 중 앞서 정의된 네 가지의 모드를 추정하기 위하여 필요한 정보로서 항공기의 속도 및 가속도 정보만이 사용되었다.

2.1 은닉 마르코프 모형 (Hidden Markov Model)

은닉 마르코프 모형(HMM: Hidden Markov Model)은 확률 과정(stochastic process) 모형으로서 음성인식부터 교통 분야까지 다양한 패턴인식 및 추정문제에 사용되어왔다[10-12]. HMM은 크게 두 확률변수 S 와 Y 에 대한 확률과정을 가지는데, 여기서 S 는 실제로 관측할 수 없는 상태(hidden state 또는 state)에 대한 확률변수이며, Y 는 S 에 종속적인 확률변수로서 hidden state에 따라 관측되는 사건(observation)에 대한 변수이다. Fig. 3에는 HMM의 확률 과정이 대략적으로 나타나 있다. 그림의 점선 상단 부분은 관측할 수 없는 상태변수의 시간(t)에 따른 과정을 보여주며, 점선 하단 부분은 매 시간 상태 변수에 따라 특정 사건이 관측되는 과정을 보여준다.

HMM이 정의되기 위해서는 전이 행렬(transition matrix) A 와 관측 분포(observation distribution) B , 그리고 초기상태 분포(initial state distribution) π 의 세 가지 파라미터가 필요하다. 상태 변수 S 가

$s = \{s_1, s_2, \dots, s_N\}$ 의 상태를 가질 수 있을 때, 상태 변수에 대한 전이 행렬 $A = \{a_{ij}\}$ 의 각 원소는 다음과 같이 정의된다.

$$a_{ij} = P(S_{t+1} = s_j | S_t = s_i), \quad i, j = 1, 2, \dots, N \quad (1)$$

여기서 t 는 시간을 나타내고 S_t 는 시간 t 에서의 상태 변수를 나타내며, $a_{ij} \geq 0, \sum_{j=1}^N a_{ij} = 1$ 을 만족하여야 한다.

또한 관측 사건 변수 Y 가 $y = \{y_1, y_2, \dots, y_K\}$ 의 사건을 가질 때, j 번째 상태변수 하에서의 관측 분포 $B = \{b_j(k)\}$ 는 다음과 같이 정의된다.

$$b_j(y_k) = P(Y_t = y_k | S_t = s_j), \quad j = 1, 2, \dots, N, \quad k = 1, 2, \dots, K \quad (2)$$

여기서 Y_t 는 시간 t 에서 관측된 사건을 나타내며, $b_j(y_k) \geq 0, \sum_{k=1}^K b_j(y_k) = 1$ 을 만족하여야 한다.

마지막으로 초기 상태 분포 π 는 $t=1$ 에 대한 상태 변수의 확률 분포로서 다음과 같이 정의된다.

$$\pi_i = P(S_1 = s_i), \quad i = 1, 2, \dots, N \quad (3)$$

여기서 $\pi_i \geq 0$ 이며, $\sum_{i=1}^N \pi_i = 1$ 을 만족하여야 한다.




Fig. 3 Stochastic process of Hidden Markov Model

2.2 HMM을 이용한 항공기 지상이동 모형

본 연구에서는 항공기의 지상이동 운항모드를 HMM의 은닉 상태변수로 정의하였으며 ASDE 데

이터를 통해 관측할 수 있는 속도 및 가속도를 관측 사건으로 정의하였다. Fig. 4에는 항공기 지상이동을 모형화한 HMM의 개념도가 나타나 있다. 여기서 각 운항모드를 연결하는 선은 모드 간의 전이를 나타내며, 점선은 각 운항모드 별 속도 및 가속도의 관측 분포를 나타낸다.

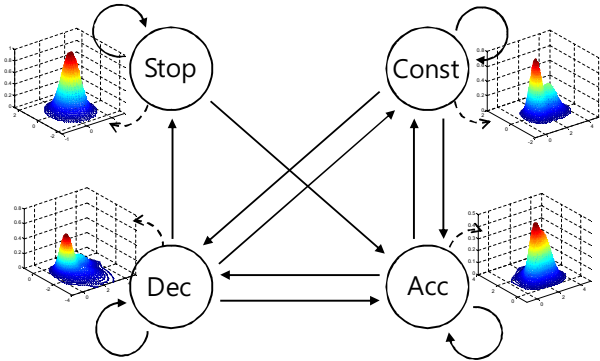


Fig. 4 Hidden Markov Model for aircraft ground operation

Fig. 4에 나타난 항공기 지상이동 모형의 경우 관측 사건이 속도 및 가속도로서 연속적인 값을 갖기 때문에 식 (2)에 사용된 이산 확률 분포 대신 확률 밀도 함수가 사용되어야 한다. 또한 동일한 운항모드 하에서도 다양한 속도 및 가속도 분포를 가질 수 있으므로 혼합 확률 분포를 사용하였으며, 이에 따라 식 (2)는 다음과 같이 변형될 수 있다[10].

$$b_i(y) = \sum_{m=1}^M w_m^i f(y|\mu_m^i, \Sigma_m^i), i = 1, 2, \dots, N \quad (4)$$

여기서 y 는 관측 변수 벡터로서, 본 모형에서는 속도 및 가속도를 나타내며, M 은 혼합 정규분포 성분의 개수, w 는 각 성분의 비율을 나타낸다. 또한 $f(\cdot|\mu, \Sigma)$ 는 평균 벡터를 μ , 공분산 행렬을 Σ 로 갖는 확률 밀도 함수를 나타내는데, 본 연구에서는 확률 밀도 함수 $f(\cdot)$ 로서 정규분포를 사용하였으며 속도와 가속도는 독립적이라고 가정하였다. 또한 모든 성분 비율의 합은 1이 되어야 하므로 다음을 만족하여야 한다.

$$\sum_{m=1}^M w_m^i, i = 1, 2, \dots, N \quad (5)$$

앞서 정의된 파라미터들로 정의되는 HMM을 $\lambda = (A, B, \pi)$ 라고 하자. 이 때, 본 연구에서 제안된 방법에서는 먼저 수집된 관측 사건 시퀀스 $\bar{y} = \{y_1, y_2, \dots, y_T\}$ 가 주어졌을 때 $P(\bar{y}|\lambda)$ 가 최대화 되는 $\hat{\lambda}$ 를 추정한다. 여기서 \bar{y} 는 수집된 ASDE 데이터의 지상이동 항공기 속도 및 가속도 시퀀스를 나타내며, 추정을 위해서는 반복적 최대 우도 추정방법을 기반으로 하는 Baum-Welch 알고리즘을 사용하였다[10]. $\hat{\lambda}$ 이 추정되면, 운항모드를 추정하고자 하는 지상이동 항공기의 속도 및 가속도 시퀀스 $\bar{y}' = \{y'_1, y'_2, \dots, y'_T\}$ 가 주어졌을 때, 각 관측 값에 해당하는 운항모드 시퀀스 $\bar{s} = \{s_1, s_2, \dots, s_T\}$ 를 추정하게 된다. 여기에는 $P(\bar{s}|\bar{y}, \lambda)$ 를 최대화 하는 \bar{s} 를 구하는 방법으로서는 동적 프로그래밍을 기반으로 하는 Viterbi 알고리즘이 사용되었다[10].

3. HMM 파라미터 및 모드 추정

3.1 HMM 파라미터 추정

본 절에서는 실제 ASDE 데이터를 통해 제안된 모형의 파라미터를 추정하고 그 성능을 검증해보았다. HMM의 파라미터를 추정하기 위해서는 과거 수집된 총 1000대의 항공기 운항자료가 사용되었으며, 본 연구에서는 공항의 이동지역 내의 항적만을 고려하였다. 또한 정지 모드를 제외한 각 모드 별 관측 분포의 혼합 성분 개수는 5개로 설정하였으며, 정지 모드의 경우 관측 분포로서 단일 정규분포를 따르는 것으로 가정하였다.

Fig. 5에는 추정된 HMM의 각 모드에 대한 관측 분포가 나타나 있으며, Table 1에는 이에 대한 파라미터들이 나타나 있다. 표에서 볼 수 있듯이 정지모드의 경우 속도와 가속도 모두 0에 가까운 평균과 작은 분산을 가지는 것을 볼 수 있다. 등속모드는 다섯 가지 분포의 혼합으로 구성되는데, 다섯 분포 모두 가속도에 대해서 0에 가까운 평균과 낮은 분산을 가지지만, 속도에 대해서는 각각 4.19 m/s, 6.09 m/s, 7.33 m/s, 9.14 m/s, 11.28 m/s의 평균과 다양한 분산을 가지는 것을 볼 수 있다. 감속 및 가속 모드의 경우 혼합 분포를 구성하는 다섯 가지의 분포가 속도 뿐 아니라 가속도에 대해서도 다양한 평균 및 분산을 가지는 것을 볼 수 있으며, 감속 모드의 경

우 모두 음의 가속도 평균을 갖고, 가속 모드의 경우 모두 양의 가속도 평균을 갖는 것을 볼 수 있다.

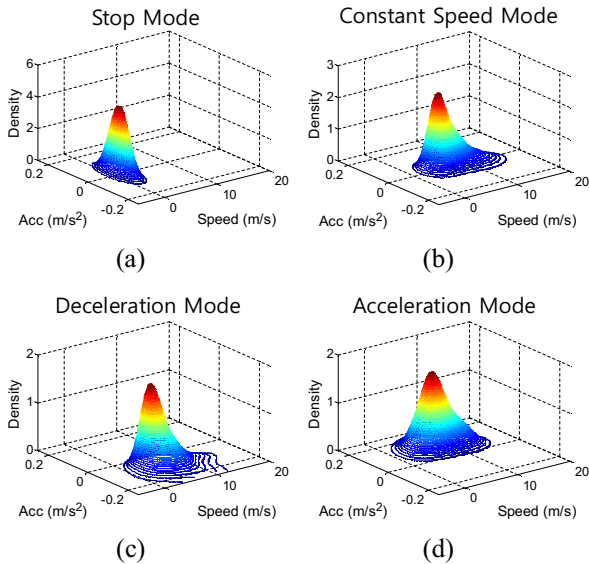


Fig. 5 Observation densities for each taxi mode

Table 1. Parameters of observation densities of Hidden Markov Model

| Mode | w | Speed (m/s) | | Acc (m/s ²) | |
|-------|------|-------------|------------|-------------------------|------------|
| | | μ | σ^2 | μ | σ^2 |
| Stop | 1.00 | 0.95 | 0.21 | 0.0022 | 0.0229 |
| | 0.39 | 4.19 | 0.38 | 0.0049 | 0.0110 |
| | 0.26 | 6.09 | 0.88 | -0.0025 | 0.0105 |
| Const | 0.11 | 7.33 | 1.15 | -0.0075 | 0.0113 |
| | 0.10 | 9.14 | 2.11 | -0.0109 | 0.0131 |
| | 0.14 | 11.28 | 1.73 | -0.0209 | 0.0181 |
| | 0.17 | 3.58 | 0.38 | -0.0660 | 0.0096 |
| Dec | 0.21 | 5.07 | 0.82 | -0.0695 | 0.0077 |
| | 0.42 | 4.78 | 1.52 | -0.1220 | 0.0236 |
| | 0.06 | 10.33 | 1.94 | -0.1097 | 0.0110 |
| | 0.14 | 7.84 | 2.66 | -0.2035 | 0.0673 |
| | 0.14 | 5.28 | 0.72 | 0.0662 | 0.0069 |
| Acc | 0.21 | 7.26 | 1.28 | 0.0561 | 0.0078 |
| | 0.42 | 5.71 | 1.16 | 0.0960 | 0.0186 |
| | 0.18 | 11.10 | 1.21 | 0.0593 | 0.0151 |
| | 0.06 | 7.51 | 2.15 | 0.1470 | 0.0618 |

또한 혼합 성분 비율 w 를 통해 각 모드 별 운항 특성을 살펴볼 수 있다. 예를 들어, 등속 운항하는 항공기의 경우 약 65% 가량 6 m/s 이하의 평균 속도로 운항하며, 평균 11.28 m/s의 속도로 등속 운항하는 경우는 약 14% 가량을 알 수 있다.

3.2 HMM을 이용한 모드 추정

3.1절에서 설명된 바와 같이 HMM 모형의 파라미터를 추정된 후, 파라미터 추정에 사용되지 않은 항공기에 대해 모드를 추정해 봄으로써 제안된 방법의 성능을 확인해 보았다. 제안된 방법의 성능을 검증하기 위해서는 한계치 기반의 모드 추정 방법과의 비교를 수행하였다[7, 8]. 한계치 기반의 방법은 각 모드 별로 여러 한계치를 설정하여 궤적에 따른 운항 모드를 추정하는 방법으로서, 각 모드 별 한계치는 다음과 같이 설정하였다.

- 1) Stop Mode: T 초 이상 1m/s 미만의 속도가 지속되는 경우
- 2) Deceleration Mode: T 초 이상 $-0.1m/s^2$ 보다 작은 가속도가 유지되는 경우
- 3) Acceleration Mode: T 초 이상 $0.1m/s^2$ 보다 큰 가속도가 유지되는 경우
- 4) Constant Speed Mode: 1)-3)에 해당하지 않는 경우

여기서 T 는 데이터의 노이즈에 따른 모드 추정 결과의 민감도를 감소시키기 위한 파라미터로서, 본 연구에서는 5초와 10초인 경우에 대하여 각각 비교를 수행하였다.

검증에는 Fig. 6와 Fig. 8에 나타나 있는 항공기의 궤적이 사용되었으며, Fig. 7과 Fig. 9에는 각 궤적에 대한 속도 및 가속도와 함께 모드 추정 결과가 나타나 있다. 모드 추정 결과는 제안된 방법(HMM)과 한계치 기반의 방법($T=5, T=10$)에 대해 모두 나타나 있으며, 제안된 방법에 대한 결과는 Fig. 6 및 Fig. 8에 궤적과 함께 표시되어 있다.

Fig. 6에 나타나 있는 항공기의 궤적은 군집된 궤적으로 알 수 있듯이 활주로 진입 전에 두 번의 정지가 일어난 것을 볼 수 있다. Fig. 7에 나타난 바와 같이 제안된 방법의 경우 이를 정확히 식별하였다. 하지만 한계치 기반의 방법은 그렇지 못한 것




Fig. 6 Mode inference results with aircraft ground trajectory 1




Fig. 8 Mode inference results with aircraft ground trajectory 2

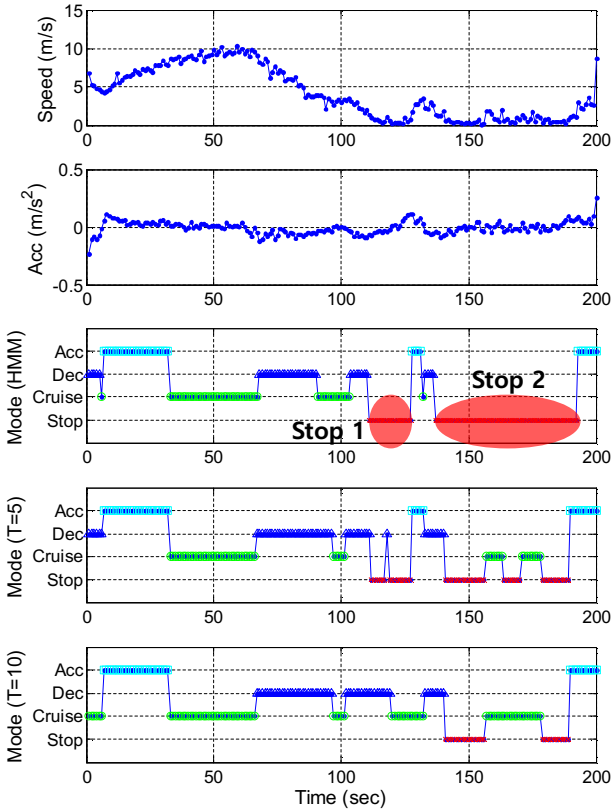


Fig. 7 Mode inference results with ASDE speed and acceleration data 1

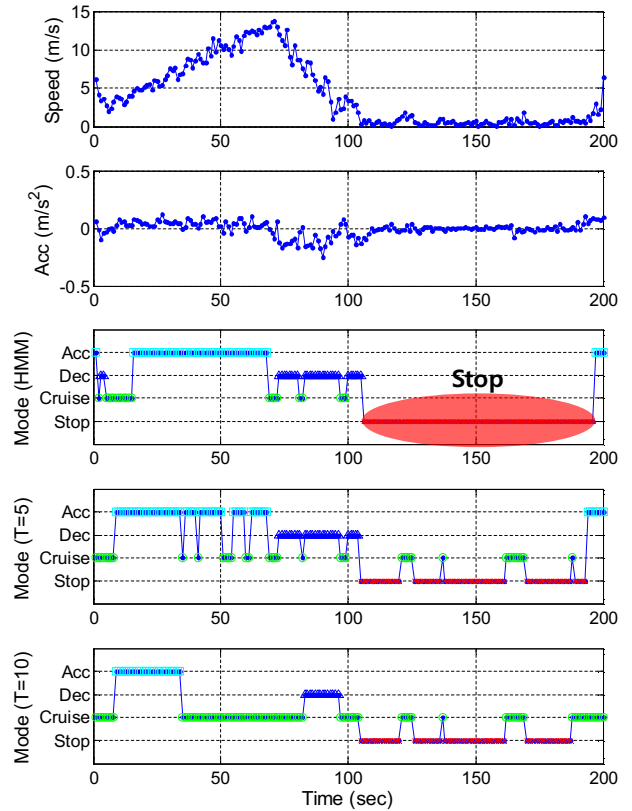


Fig. 9 Mode inference results with ASDE speed and acceleration data 2

을 볼 수 있는데, $T=10$ 으로 설정한 경우에는 첫 번째 짧은 정지 구간을 식별하지 못하였으며, 두 경우 모두 속도나 가속도 정보의 노이즈로 인해 정지 구간 중 감속 또는 등속 모드가 식별되었다.

Fig. 8에 나타나 있는 항공기의 궤적은 Fig. 9의 속도 정보와 Fig. 8에 군집된 궤적으로 볼 수 있듯

이 약 70초까지 가속한 후 약 100초까지 다시 감속하여 활주로 진입 전에 정지한 것을 볼 수 있다. Fig. 9에 나타난 바와 같이 제안된 방법의 경우 일부 구간을 제외하고는 이를 상대적으로 정확히 식별하였다. 한계치 기반의 방법은 $T=5$ 로 설정한 경우 가속도의 노이즈에 따라 가속 및 감속

구간 동안 모드 추정이 매우 민감한 것을 볼 수 있다. $T=10$ 으로 설정한 경우에는 약 40~80초 사이의 구간 동안 가속 및 감속 구간을 등속 구간으로 잘못 식별한 것을 볼 수 있다. 또한 Fig. 7의 결과와 동일하게 한계치 기반의 방법은 $T=5$ 인 경우와 $T=10$ 인 경우 모두 제안된 방법에 비하여 정지 구간에서의 모드 추정 정확도가 낮은 것을 볼 수 있다.

4. 결론

지속적으로 항공교통량이 증가함에 따라 항공기의 공중에서의 운항 뿐 아니라 출발 전 또는 이륙 후 공항 지상에서의 운항을 최적으로 관리하기 위한 방법이 활발히 연구되고 있다. 공항 지상에서의 항공기 운항은 조종사에 따른 자유도가 높기 때문에 그 특성의 분석이 매우 중요하다. 따라서 이러한 최적화 방법들이 성공적으로 이루어지기 위해서는 항공기의 지상에서의 운항에 대한 특성이 신중하게 분석되어야만 한다.

본 연구에서는 항공기의 지상 운항의 특성을 분석하기 위한 방법으로서, 공항 지상 감시 장비 데이터를 통해 항공기의 지상이동 운항모드를 추정하는 방법을 제안하였다. 제안된 방법에서는 항공기의 운항모드와 관측된 속도 및 가속도 정보를 확률 변수로 정의한 후, 항공기의 지상이동 과정을 은닉 마르코프 모형을 통해 모델링 하였다. 또한 실제 수집된 데이터를 통해 제안된 방법의 성능을 검증해 보았다.

추후 연구에서는 운항모드를 더욱 정밀하게 추정하기 위하여 다양한 관측 정보를 활용해 보아야 할 것이며, 운항모드를 더욱 세밀하게 구분하여 항공기의 지상 운항 특성을 더욱 면밀하게 분석해 보아야 할 것이다. 또한 공항 지상 감시 장비 데이터와 더불어 실제 항공기의 모드에 대한 관측 정보를 수집하여 제안된 방법에 대한 더욱 엄밀한 검증이 수행되어야 할 것이다.

후 기

본 연구는 국토교통부 연구과제인 ‘항공기 출발 및 도착 통합 관리 기술 연구’에 의해 연구비 지원을 받았으며, 이에 감사드립니다.

참고문헌

- [1] Erzberger, H., and Nedell, W., “Design of Automated System for Management of Arrival Traffic,” NASA TM-102201, 1989.
- [2] Schubert, M., “Arrival and Departure Traffic Management within the Terminal Area,” AIAA Guidance, Navigation, and Control Conference, San Diego, CA, 1996.
- [3] Feron, E., Hansman, R. J., Odoni, A. R., Cots, R. B., Delcaire, B., Feng, X., Hall, W. D., Idris, H. R., Muharremoglu, A., and Pujet, N., “The Departure Planner: A Conceptual Discussion,” International Center for Air Transportation reports, 1997.
- [4] Doble, N. A., Timmerman, J., Carniol, T., Klopfenstein, M., Tanino, M., and Sud, V., “Linking Traffic Management to the Airport Surface: Departure Flow Management and Beyond,” 8th USA/Europe Air Traffic Management R&D Seminar, CA, 2009.
- [5] Ravizza, S., Atkin, J. A. D., Maathuis, M. H., and Burke, E. K., “A Combined Statistical Approach and Ground Movement Model for Improving Taxi Time Estimations at Airports,” Journal of the Operational Research Society, No. 64, 2013, pp. 1347~1360.
- [6] Srivastava, A., “Improving Departure Taxi Time Predictions Using ASDE-X Surveillance Data,” Digital Avionics Systems Conference, Seattle, WA, 2011.
- [7] Gong, C., “Kinematic Airport Surface Trajectory Model Development,” 9th AIAA Aviation Technology, Integration, and Operations Conference, Hilton Head, SC, 2009.
- [8] Khadilkar, H., and Balakrishnan, H., “Estimation of Aircraft Taxi-out Fuel Burn using Flight Data Recorder Archives,” AIAA Guidance, Navigation, and Control Conference, Portland, OR, 2011.
- [9] Wood, Z., Kistler, M., Rathinam, S., and

Jung, Y., "A Simulator for Modeling Aircraft Surface Operations at Airports," AIAA Modeling and Simulation Technologies Conference, Chicago, IL, 2009.

[10] Rabiner, L. R., "A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition," Proceedings of the IEEE, Vol. 77, No. 2, pp. 257~286, 1989.

[11] Mannini, A., and Sabatini, A. M., "Machine Learning Methods for Classifying Human Physical Activity from On-Body Accelerometers," Sensors, Vol. 10, No. 2, pp. 1154~1175, 2010.

[12] Neogi, N. A., and Naseri, A., "Using Hidden Markov Models to Detect Mode Changes in Aircraft Flight Data for Conflict Resolution," 2006 IEEE International Conference on System, Man, and Cybernetics, Taipei, Taiwan, 2006.