

확률과정기법을 이용한 링크통행시간 예측

이 승 재 · 소 경 숙

(서울시립대학교 건축공학과 교수 · 교통개발연구원 연구원)

Link Travel Estimation using the Stochastic Process

Lee, Seung Jae · So, Kyung Sook

ABSTRACT

This paper has been developed in the framework of the combined modal choice and traffic assignment (Lee et al 1999). In order to enhance realism of travel times, this paper has been used stochastic process techniques for the short-term travel time prediction. The stochastic process techniques have been compared favorably with other short-term prediction techniques such as Kalman Filtering, Neural Network, and ARIMA models. The mean and variance of the travel time used in the stochastic process have been obtained from the real travel time data in Kangnam-Ku district using ROTIS's Probe car and Beacon. It has been classified using discriminant analysis. The results show that the stochastic process predicts short-term prediction well and easily adopts to apply for the large scale networks.

I. 서론

최근 들어, 교통정보를 제공하는데 있어서 정보제공의 신뢰도를 높이기 위한 통행 시간 추정 및 예측에 관한 연구가 활발히 진행되고 있다. 이에 관련된 여러 가지 예측 기법들 중 최근에 주로 사용되는 것으로는 시계열 분석, 칼만 필터링 기법, 인공신경망 이론 등이 있다. 그러나 이러한 기법들의 정확성에 대해서는 아직 검증되지 않은 상태이기 때문에 다른 방법들의 적용가능성을 남겨두고 있다. 본 연구에서는 링크 통행시간을 예측하는 하나의 기법으로써 확률과정(stochastic process) 방법을 적용해 보았으며, 또한 기존의 여러가지 예측기법들 중에서 칼만필터링 기법과 그 예측결과를 비교해 보았다.

정확한 교통정보를 제공해주기 위해서는 각 링크에 대해서 정확한 비용값을 입력해주는 것이 매우 중요하다고 할 수 있다. 확률과정은 기존의 단기예측기법들과 비교해 볼 때, 적용이 단순할 뿐만 아니라, 서울시와 같은 대규모 네트워크에 대하여 실시간으로 데이터를 수집하는 것이 어려운 현실에서 과거 데이터들을 확률적으로 이용함으로써 시간변화에 따른 특성을 반영해 주는 하나의 대안이 될 수 있다.

본 연구에서는 가상 네트워크가 아닌 실제 서울시 수치지도를 기반으로 구축한 현실적인 네트워크를 대상으로 확률과정과 칼만필터링의 두 가지 예측기법을 적용해 보았다.

II 확률과정(Stochastic Process)

1. 확률과정(Stochastic Process)의 정의 및 표현

확률과정(stochastic process or random process)은 “연관성이 있는 또는 첨자가 붙어 $\{X_t : t \in T\}$ 있는 확률변수들의 집합”으로 정의된다. 즉, “가 확률과정이다” X_t 라고 할 때 이는 집합 T 에 있는 모든 t 에 대해서 가 확률변 X_t 수임을 나타내고 있다. 대부분의 경우 첨자 t 는 시간을 나타내므로 이를 “시점 t 에서의 시스템의 상태”를 표현하는 것으로 해석된다. 확률과정은 매개변수집합(parameter set) T 가 연속형인지 이산형인지에 따라서 표현방법이 달라지고, 또한 상태공간(state space) E 가 연속형 또는 이산형인지에 따라 달라진다. 상태공간 E 는 확률변수들이 취할 수 있는 모든 가능한 값들의 집합을 나타낸다. 매개변수집합과 상태공간의 형태에 따라 확률과정의 유형을 다음 <표 1>과 같이 네 가지로 분류할 수 있다.

<표 1> 확률과정의 유형

구분		매개변수집합(parameter set)	
		연속형	이산형
상태공간	연속형	유형 1	유형 2
	이산형	유형 3	유형 4

매개변수는 시간의 의미일 수도 있고 거리의 의미일 수도 있다. 본 연구에서 매개변수 t 는 시간의 의미를 나타내는 것으로 한다. 즉, 시간변화에 따른 속도변화를 확률과정을 이용하여 예측하고자 한다.

$$\{X_1, X_2, X_3, \dots, X_{10}\}$$

2. 확률과정의 특성

$$F(X_1, X_2, X_3, \dots, X_{10}) = P_r[X_1 \leq x_1, \dots, X_{10} \leq x_{10}]$$

이라고 하는 확률변수 집합이 주어졌을 때, 이에 대한 확률적 정보는 이들의 결합분포 함수를 통해 구할 수 있다.

예를 들어 $\{X_1, X_2, X_3, \dots, X_{10}\}$ 이 서로 독립이고 동일분포를 가진다고 하면 (i, i, d), $F(x) = P_r[X_1 \leq x]$ 만 가지고서 에 대한 모든 것을 알 수 있게 된다.

$$F(X_1, X_2, X_3, \dots, X_{10}) = P_r[X_1 \leq x_1, \dots, X_{10} \leq x_{10}]$$

즉,

$$\begin{aligned} &= P_r[X_1 \leq x_1] \cdots P_r[X_{10} \leq x_{10}] \\ &= F(x_1) \cdots F(x_{10}) \end{aligned}$$

이와 같은 구조의 확률과정은 동일한 실험을 독립적으로 반복 시행하는 경우에 흔히 나타난다.

(1) Markov process

일반적인 확률과정은 너무 범위가 넓어 실제 시스템의 모델로는 적당하지 않다. 그래서 수학적으로도 잘 맞으면서 그렇게 복잡하지 않은 확률과정들만을 대상으로 할 필요가 있다. 1907년 러시아의 수학자 A. A. Markov가 소개한 마코프성질 (Markov property)은 복잡하지 않으면서 여러 시스템을 잘 나타내는 것으로 알려졌다. 이것은 상태공간이 이산(discrete)형인 확률과정을 주 대상으로 한다.

$\{X_t : t \in T\}$ 를 이산형 상태공간의 확률과정이라 하고 T 는 실수집합이다. 따라서 T 는 $\{t : 0 \leq t < \infty\}$ 일수도 있고 $\{1, 2, \dots\}$ 일수도 있으며 $\{t : 28 \leq t \leq 54\}$ 일 수도 있다. $\{X_t : t \in T\}$ 를 알기 위해서는 T 의 모든 값 $t_1, t_2, \dots, t_n$ 에 대하여 $P_r[X_{t_1} \leq x_1, \dots, X_{t_n} \leq x_n]$ 을 또한 알아야 한다..


$\{X_t : t \in T\}$ 를 이산형 상태공간의 확률과정이라 하였으므로, 위의 결합확률분포 대신 밀도함수 $P_r[X_{t_1} = k_1, \dots, X_{t_n} = k_n]$ 을 알아도 된다.

이산상태의 확률과정에서 다음의 마코프 성질을 만족하면 이때의 확률과정을 마코프 과정이라고 한다.

[마코프 성질]

상태공간의 모든 $k_1, \dots, k_n, k_{n+1}$ 에 대하여, $t_1 \leq t_2 \leq \dots \leq t_{n+1}$ 이 T 의 원소이고 $n=0, 1, 2, \dots$ 일때,

$P_r[X_{t_{n+1}} = k_{n+1} | X_{t_n} = k_n, \dots, X_{t_1} = k_1]$ 은 시점 $t_1, \dots, t_n$ 에서의 상태를 알고 있다는 조건 하에서 시점 t_{n+1} 의 상태가 k_{n+1} 일 확률을 나타내고 있다. 여기서 시점 t_n 을 현재라고 보면, $t_1, \dots, t_{n-1}$ 은 과거가 되고 t_{n+1} 은 미래가 된다. Markov 성질에 의하면, 미래는 현재가 주어저 있는 조건하에서 과거와는 독립이라는 것을 알 수 있다. 따라서 markov process에서는 현재 상태만 알고 있으면, 과거의 상태들이 어떠했는가는 추가정보는 미래에 대한 판단에 전혀 필요가 없다는 것이다. 이와 같이 그 전시간대의 상태를 무시하고 t 시간대에서 $t+1$ 시간대로 상태변화를 나타내는 확률을 1단계 전이확률이라 한다. Markov chain의 1단계 전이확률을 구하기 위한 확률 과정식은 <그림 1>과 같이 표현될 수 있다.



$$P_{ij} = \Pr[M(t+1)=j | M(t)=i]$$

여기서, M_t : t 시간대의 상태

M_{t+1} : $t+1$ 시간대의 상태

p_{ij} : t 시간대의 상태가 i 이면서 $t+1$ 시간

태의 상태가 j 일 확률(1단계 전이확률)

(2) 이산시간 markov chain 의 전이확률(transition probability)

상태공간 뿐만 아니라 매개변수집합 T 도 이산형인 경우 markov chain은 $\{X_1, X_2, \dots\}$ 와 같은 형태를 가진다.

이때, 확률 $P_r[X_{t+1} = j | X_t = i]$ 를 전이확률(transition probability)이라고 한다.

특히, $p_{ij} = P_r[X_{t+1} = j | X_t = i]$ 를 1단계 전이확률(one-step transition probability)이라고 한다. 또한 1단계 전이확률에서는 $X_t = i$ 인 조건하에서 X_{t+1} 은 반드시 어떤 값을 가져야 하므로 모든 i 에 대하여 $\sum_j p_{ij} = 1$ 이 성립한다.

1단계 전이확률을 행렬로 표현하면 다음과 같이 나타내어질 수 있다.

$$P = (p_{ij}) = \begin{pmatrix} p_{00} & p_{01} & \dots & p_{0n} \\ p_{10} & p_{11} & \dots & p_{1n} \\ \vdots & \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \vdots \\ p_{n0} & p_{n1} & \dots & p_{nn} \end{pmatrix}$$

3. 확률과정(Stochastic Process)식의 도출

특정 일에 대하여 선택확률(choice probability) $p^t(h, k)$ 의 실제 값을 구하기가 어렵다. 따라서, 확률과정에서는 전날 며칠동안의 가능한 상태(states)집합을 전제한다.

t 시간대에 상태가 F^t 일 확률 $P_r[F^t]$ 은 이론적으로 선택확률을 이용하여

다음과 같이 구할 수 있다.

$$P_r[F^t] = P_r[F^t / p^t(h, k) \quad \forall h, k] \quad (1)$$

여기서, $p^t(h, k)$ 는 선택확률(choice probability)이다. 만일, 통행자들이 매일 독립적으로 그들의 선택을 재고한다고 하면, 시스템의 상태는 하나의 multinomial random variable이 된다.

즉, 식 (1)은 다음과 같이 다시 표현할 수 있다.

$$P_r[F^t] = \prod_{hk} (p^t(h, k) \cdot F_{hk}^t / F_{hk}^t!) \quad (2)$$

여기서, $C^{t-1}, C^{t-2}, \dots$ 는 각각 현시점 t 를 기준으로 $t-1, t-2, \dots$ 시점에서의 링크통행시간을 나타낸다.

통행자가 노선이나 출발시간대를 선택할 때 주로 과거의 링크통행시간을 이용한다고 하면, $i=1, 2, \dots$ (연속일에 대하여)

$$p^t(h, k) = p^t(h, k)(C^{t-1}, C^{t-2}, \dots) \quad (3)$$

이 되고, limited memory 전제하에서 통행자가 영향을 받는 과거 시점이 한정된다고 볼 때,

$$p^t(h, k) = p^t(h, k)(C^{t-1}, i=1, \dots, m) \quad (4)$$

이 된다. 즉, 통행자는 현시점을 기준으로 m 일 전시간대 까지만의 기억을 참고한다.

이와 같이 통행자가 과거 m 시간대의 상태에 영향을 받는다고 할 때, 현재상태가 나타날 확률은 다음과 같다.


$$\begin{aligned} P_r[F^t / F^{t-1}, \dots, F^{t-m}] \\ = P_r[F^t / p^t(h, k) \cdot C^{t-1} (i=1, \dots, m)] \\ \cdot [P_r(C^{t-1} / F^{t-1})], \dots, [P_r(C^{t-m} / F^{t-m})] \end{aligned}$$

이것은 이른바 m -dependent Markov chain system 이다.

4. 확률과정을 이용한 통행시간예측

본 연구에서는 최적경로탐색에 이용되는 비용함수를 구성하기 위하여 확률과정(stochastic process 또는 random process)를 적용하고자 한다. 확률과정을 이용하여 개별 링크들에 대한 5분 뒤 통행시간을 예측한다.

다음 < 그림 2 >는 확률과정(stochastic process) 방법을 이용한 링크통행시간 예측과정을 개략적으로 표현한 것이다.



<그림 2> 확률과정의 적용과정

(1) 표본데이터

본 연구에서는 강남구 주요 5개 교통축(논현로, 봉은사로, 언주로, 영동대로, 테헤란로)의 45개 링크에 대한 시간대별(AM. 7-9시) 속도데이터를 표본데이터로 구성하였다. 각 링크의 시간대별 통행속도에 대한 분포도를 구성한 후 분포가 비슷한 링크들을 그룹화 시킨다. 그룹화의 기준은 속도의 평균값을 사용하도록 한다. 다음 < 표 1 >

은 평균을 기준으로 세 개의 그룹으로 분류한 결과이다. 각 그룹의 평균속도는 각각 23.02, 42.32, 60.42로 그룹간의 속도차가 현저하게 나타나는 것을 알 수 있다. 또한 각 그룹에 해당되는 링크개수는 12개, 21개, 12개씩으로 나타났다.

<표 2> 그룹별 평균 및 링크번호

구 분	평균속도 (km/hr)	해당링크(링크번호)
그룹1	23.02	1, 10, 12, 13, 17, 18, 20, 30, 39, 42, 44, 45(총12개)
그룹2	42.32	2, 3, 7, 8, 9, 11, 14, 15, 16, 21, 24, 25, 27, 28, 29, 31, 33, 34, 36, 37, 38(총 21개)
그룹3	60.42	4, 5, 6, 19, 22, 23, 26, 32, 35, 40, 41, 43(총 12개)

<표 3> 각 그룹의 시간대별 속도데이터의 평균과 표준편차

시간대	평균			표준편차		
	Group 1	Group 2	Group 3	Group 1	Group 2	Group 3
7:05	31	46	64	8	7	10
7:10	31	45	63	9	6	10
7:15	29	44	65	7	7	10
7:20	28	45	64	6	7	10
7:25	30	45	63	7	8	10
7:30	29	45	63	6	7	9
7:35	28	44	65	6	7	10
7:40	27	44	63	6	6	9
7:45	25	44	62	4	6	9
7:50	24	43	60	4	6	9
7:55	23	43	60	5	6	10
8:00	21	43	60	6	6	10
8:05	20	42	59	6	6	11

8:10	21	42	59	7	6	10
8:15	20	42	61	8	6	10
8:20	20	41	59	8	8	10
8:25	19	41	58	7	8	10
8:30	19	41	61	7	8	9
8:35	19	41	59	7	7	12
8:40	19	41	62	6	7	9
8:45	18	40	60	7	8	9
8:50	18	39	60	8	8	10
8:55	18	36	59	8	10	9
9:00	17	38	59	8	10	9

(2) 정규확률 변량 발생

본 연구에서는 전체 네트워크에 대한 링크별 속도데이터를 구하기가 어렵기 때문에 표본데이터의 평균과 분산을 이용하여 정규확률 변량을 발생시켜 그 데이터를 사용하도록 하였다. 각 링크의 시간대별 통행시간 함수는 정규분포를 따르는 확률변량이라 전제하였다.

정규분포변량을 생성하는 방법에는 일반적으로 다음의 세가지 (1) 균일확률변량을 이용한 이론적 근사방법 (2) Box-Muller 변환법 (3) 극좌표 방법이 있는데, 본 논문에서는 그중 첫 번째 방법을 이용하고자한다. 이 방법은 계산상의 복잡한 알고리즘을 배제하는 매우 효율적인 방법으로 개념은 표본크기의 증가에 따라 확률변수의 합이 정규분포를 따른다는 중심극한정리로부터 나온 것이다. 예를 들어, $X_1, X_2, \dots, X_n$ 이 $-1/2$ 과 $1/2$ 사이의 독립인 균일분포 확

률변수 일 때 변수 $Y = \sum_{i=1}^n X_i$ 은 대략적으로 평균이 0이고, 분산이 $n/12$ 인 정규분포를 따르게 된다. 따라서 $n=12$ 일 때

$Y = \sum_{i=1}^n X_i$ 는 평균이 0이고, 분산이 1인

표준정규분포에 근사함을 알 수 있다.


또는 균일분포함수가 $U(0, 1)$ 인 경우에는

$Y = \sum_{i=1}^n X_i - \frac{n}{2}$ 이 평균이 0, 분산이 $\frac{n}{12}$ 인

정규분포를 따르므로, $n=12$ 일때는

$Y = \sum_{i=1}^n X_i - 6$ 이 표준정규분포를 따르게 된다.

본 연구에서는 균일분포함수가 $U(0, 1)$ 인 경우에 대해 적용하도록 하였다. 표준정규분포 확률변량 생성방법을 이용하여 각 링크의 시간대별 통행시간을 도출하는 알고리즘은 다음 <그림 3>과 같다.



<그림 3> 정규분포 확률변량 발생 알고리즘

여기서, μ , σ 는 각각 해당링크의 시간대별 통행시간의 평균과 표준편차이다. μ , σ 는 시간대와 그룹에 대한 변수이다. 즉,

$\mu = \mu(t, g)$, $\sigma = \sigma(t, g)$ 로 표현할 수 있다. t 는 7-9시까지 5분 간격의 24개 time slice로 구성되고, g 는 차선수에 따라 3개의 그룹(1 or 2 or 3)으로 구성된다.

(3) Stochastic Process 적용

위에서 구축된 링크의 속도데이터를 이용하여 각 그룹별 시간변화에 따른 전이확률을 계산한다. < 표 4 >는 7시 5분에서 7시 10분으로의 전이 확률 계산과정을 예로 든 것이다.

<표 4> 시간변화에 따른 전이확률 계산

7:05 (v(t))	7:10 (v(t+1))	속도변화량(k)
27	27	0
34	33	-1
31	30	-1
22	22	0
29	31	+2
20	20	0
26	24	-2
48	48	0
26	24	-2
41	41	0
40	41	+1

등 급	속도변화 량 (k)	링크개 수(n)	전이확률	
			확률 (p(k))	누적확률 (P(k))
1	-2	2	0.1818	0.1818
2	-1	2	0.1818	0.3636
3	0	5	0.4546	0.8182
4	+1	1	0.0909	0.9091
5	+2	1	0.0909	1.0000

일반적인 1단계 전이확률 공식은 다음과 같다.

$$p_{ij} = p(v_a(t+1) = j | v_a(t) = i) \quad (6)$$

여기서, $v_a(t)$ 는 링크 a의 t 시간대에서의 속도, $v_a(t+1)$ 은 링크 a의 (t+1) 시간대에서의 속도, 또한 i와 j는 매개변수 k를 사용하여 다음과 같이 표현할 수 있다.

$$j = i + k \quad (7)$$

k는 전이시간에 따른 속도차로써, (... , -2, -1, 0, +1, +2, ...)으로 나타내도록 한다. 이 관계식에 따라 <식 6>은 다음과 같이 속도차에 대한 확률로 다시 표현할 수 있다.

$$p_{ij,k} = p(v_a(t+1) = i + k | v_a(t) = i) \quad (8)$$

개별 링크들의 각 표본수를 N, 그 중 $v_a(t+1) - v_a(t) = k$ 인 개수를 n이라 하면,

$$p_{ij,k} = \frac{n}{N} \quad (9)$$

각 그룹별로 속도변화량을 통계량으로 하는 전이확률을 구한 뒤, 발생시킨 0-1 사이의 난수와 매칭 시키기 위해서 누적확률을 다시 구하도록 한다.

$$p_{ij,k} = \sum_k p(k) \quad (10)$$

각 링크들에 대하여 발생시킨 난수(random number)가 누적확률과 비교하여, 어느 등급에 포함되느냐에 따라 해당 등급의 속도변화량을 현재의 속도에 더하여 다음 시간대의 속도를 계산한다.

$$v_a(t+1) = v_a(t) + k \quad (11)$$

여기서, $v_a(t)$ 는 t시간대에 링크 a의 속도, $v_a(t+1)$ 은 t+1 시간대의 링크a의 속도 예측값, k는 전이시간에 대한 속도변화량

마지막으로, 각 링크의 구간거리를 지금까지 과정(stochastic process)을 통해 도출된 전이속도 ($v(t+1)$)로 나눈 통행시간 값이 링크의 비용값이 된다.

$$T_a(t+1) = \frac{L_a}{v_a(t+1)} \quad (12)$$

여기서, $T_a(t+1)$ 은 $(t+1)$ 시간대에 링크 a 의 통행시간, L_a 는 링크 a 의 구간거리

III 비교 및 평가

본 연구에서 구축한 시스템 평가는 통행 시간 예측기법 및 네트워크 수준(level)에 따른 경로탐색 결과를 비교하는 방법으로 이루어졌다. 사용된 통행시간 예측기법은 칼만 필터링 기법과 확률과정 방법이며, 두 가지 방법 모두 5분 뒤 통행시간을 예측하였다. 네트워크 수준은 네 가지(전체 네트워크, 2차선이상도로, 3차선이상도로, 28개 주요 교통축)로 구분하였다.

먼저, 최적경로 탐색의 정확성을 평가하기 위해 서울시 내의 임의의 기·종점을 선정하여 4가지 네트워크를 대상으로 각 예측기법에 따라 알고리즘을 적용하였다.

또한, 교차로에서의 회전 적합성 평가를 위해 좌회전 금지구간이 많은 종로지역을 대상으로 평가를 실행하였다. 회전 적합성 평가를 통해서는 본 연구에서 구축한 네트워크의 검증이 동시에 이루어진다.

1. 예측기법의 평가

본 연구에서는 예측기법별 통행시간예측력의 정확성을 비교/평가해 보기 위해서 강남구 두 지점을 기·종점으로 8가지 평가조건에 따라 최적경로탐색알고리즘을 적용해 보았다. 평가조건은 다음의 <표 5>에서 나타난 바와 같다. 예측기법은 칼만필터링과 확률과정이 이용되었으며, 네트워크는 서울시 전체 네트워크, 2차로 이상 네트워크, 3

차로 이상 네트워크, 28개 주요 교통축의 4가지로 구분되어 적용되었다.

<표 5> 비교/평가 조건

구 분	Kalman Filtering	전체 네트워크	①
		2차로 이상 네트워크	②
		3차로 이상 네트워크	③
		28개 주요 교통축	④
	Stochastic Process	전체 네트워크	⑤
		2차로 이상 네트워크	⑥
		3차로 이상 네트워크	⑦
		28개 주요 교통축	⑧

평가 대상지는 다음의 <그림 4>에서 보여주는 바와 같이 기점(서초역), 종점(도산공원)을 포함하는 강남구 일대를 중심으로 한다.



<그림 4> 평가대상지

(2) 평가 결과


1) 전체 네트워크

<그림 5>는 전체 네트워크에 대한 최단 경로를 표현한 것이다. 또한 <그림 6~7>은 확률과정과 칼만 필터링 기법을 적용했을 경우(즉, 조건 ①과 ②)의 최적경로결과를 표현한 것이다. 그림에서 나타나는 바와

같이, 칼만 필터링 기법이 확률과정 기법에 비해 제시된 최단경로에 근접하는 것을 볼 수 있다.



<그림 5> 전체 네트워크에서의 최단경로



<그림 6> 칼만필터링 기법을 이용한 최적경로탐색



<그림 7> 확률과정방법을 이용한 최적경로탐색


2) 2차로 이상 네트워크

<그림 8>은 2차로이상 네트워크에 대한 최단경로를 표현한 것이다. 또한 <그림 9~


10>은 확률과정과 칼만 필터링 기법을 적용했을 경우(즉, 조건 ③과 ④)의 최적경로 결과를 표현한 것이다. 2차로 이상 네트워크에서도 마찬가지로, 칼만 필터링 기법이 확률과정 기법에 비해 제시된 최단경로에 근접하는 것을 볼 수 있다.



<그림 8> 2차로이상 네트워크에서의 최단경로탐색



<그림 9> 칼만필터링 기법을 이용한 최적경로탐색




<그림 10> 확률과정방법을 최적경로탐색

3) 3차로 이상 네트워크


<그림 11>은 3차로 이상 네트워크에 대한 최단경로를 표현한 것이다. 또한 <그림 12~13>은 확률과정과 칼만 필터링 기법을 적용했을 경우(즉, 조건 ③과 ④)의 최적경로결과를 표현한 것이다. 3차로 이상 네트워크에서는 두 가지 기법 모두 최단경로에 비슷한 결과를 나타내고 있다.



<그림 11> 3차로이상 네트워크에서의 최단경로



<그림 12> 칼만필터링 기법을 이용한 최적경로탐색




<그림 13> 확률과정방법을 이용한 최적경로탐색

4) 28개 주요 교통축 네트워크


<그림 14>는 28개 주요교통축 네트워크에 대한 최단경로를 표현한 것이다. 또한 <그림 15~16>은 확률과정과 칼만 필터링 기법을 적용했을 경우(즉, 조건 ③과 ④)의 최적경로결과를 표현한 것이다. 해당 네트워크에서는 두 가지 기법 모두 최단경로에 비슷한 결과를 나타내고 있다.



<그림 14> 28개 주요 교통축에서의 최단경로



〈그림 15〉 칼만필터링 기법을 이용한 최적경로탐색



〈그림 16〉 확률과정방법을 이용한 최적경로탐색

IV 결론 및 향후 연구과제

본 연구에서는 통행시간예측 방법으로 확률과정(stochastic process) 이론을 적용하고자 하였다. 이 방법은 기존의 단기 통행시간 예측기법들과 비교해 볼 때, 적용이 간단하면서도 다른 기법들과 유사한 결과를 도출할 수 있다는 점에서 높이 평가될 수 있다. 확률과정의 여러 가지 모형들 중에서 본 논문에서는 markov process의 1단계 전이확률을 이용하여 현 시점에서 다음 시점의 통행시간을 예측하고자 하였다. 칼만 필터링 기법과 확률과정(stochastic process) 방법에 의해 예측된 통행시간을 이용한 경로탐색 결과를 통해 각 예측방법을 비교하였다.

경로탐색은 서울시를 기반으로 구축된 4가지 종류(서울시 전체 주요 간선도로 네트워크, 2차로 이상 네트워크, 3차선 이상 네트워크, 28개 주요 교통축)의 네트워크를 대상으로 이루어졌다. 경로탐색 결과, 칼만 필터링 기법이 확률과정에 비해 예측력이 좀더 정확한 것으로 나타났다.

본 연구에서는 확률과정방법을 적용하는데 있어 해당링크의 이전정보만을 이용한 전이확률을 구하였다. 전이확률을 계산하는데 있어 이전 링크(upstream link)들의 정보를 포함시킴으로써 예측의 정확성을 높일 수 있을 것이다. 본 연구에서는 단기예측기법으로써 확률과정 이론의 적용가능성을 살펴보고자 한 것이기 때문에 이는 향후 연구과제로 남겨두기로 한다.

<참고 문헌>

1. 김동욱, 혼잡한 고속도로 교통량의 실시간 교통우회전략에 관한 연구, 한양대학교 환경대학원, 1998.
2. 남궁성, 전문가시스템을 이용한 최적경로탐색 시스템(X-PATH)의 개발, 한양대학교 대학원, 1996.
3. 소경숙, GIS를 이용한 교통정보 제공 시스템 개발에 관한 연구, 서울시립대학교 대학원, 2001.
4. 최기주, U턴을 고려한 도시가로망, 교통학회, 1996.
5. A. Bruce Clarke & Ralph L. Disney, 확률과정론, 1997, 청문각.
6. Byron S. Gottfried, Elements of stochastic process simulation, 1984.
7. DAVID WATLING, Asymmetric

- probability and stochastic process models of traffic assignment, TRB, Vol.30, NO.5, pp.339-357, 1996.
8. ENNIO CASCETTA, A day-to-day and within-day dynamic stochastic assignment model, TR. Vol. 25A. No.5, pp.277-291, 1991.
9. M. Hadi Baaj, Suleiman A. Ashur, Miguel Chaparrofarina, and K. David Pijawka, Design of Routing Networks Using Geographic Information Systems: Applications to Solid and Hazardous Waste Transportation Planning.
10. P.H.L.Bovy and E.Stern, "Route choice: Wayfinding in Transport Networks", KLUWER ACADEMIC PUBLISHERS, 1990 .