

선별적 데이터 학습 기반의 베이지안 네트워크를 이용한 단기차량속도 예측

박성호¹ · 유영중² · 문상호² · 김영호^{3*}

A Short-Term Vehicle Speed Prediction using Bayesian Network Based Selective Data Learning

Seong-ho Park¹ · Young-jung Yu² · Sang-ho Moon² · Young-ho Kim^{3*}

¹Information Technology Center, Pusan National University, Pusan 46241, Korea

²Department of Computer Engineering, Busan University of Foreign Studies, Pusan 46234, Korea

^{3*}Department of Road Transport Research, The Korea Transport Institute, Sejong 30147, Korea

요 약

정확한 교통정보의 예측은 출발지로부터 목적지까지의 최적경로를 제공할 수 있으며, 이로 인해 시간과 비용의 절감 효과를 얻을 수 있다. 본 논문에서는 다양한 교통정보 예측 방법 중 확률 모델을 기반으로 교통정보를 예측하는 베이지안 네트워크 방법을 이용한다. 기존 연구에서는 베이지안 네트워크 예측 방법이 모든 시간대에서의 데이터를 학습에 사용하는 것과는 달리, 본 논문에서는 예측하고자 하는 시간대와 동일한 요일과 시간에 해당하는 데이터만을 선별적으로 학습에 사용한다. 서로 다른 두 가지 학습방법에 따른 예측 결과의 정확도는 일반적으로 많이 사용되는 MAPE(Mean Absolute Percentage Error)로 검증하였으며, 서울 시내 14개의 링크 구간에 대해 실험을 진행하였다. 실험결과는 본 논문에서 제안한 방법이 모든 시간대의 데이터를 학습에 사용한 방법에 비해 MAPE의 관점에서 더 높은 정확도를 가진 교통 예측 값을 계산할 수 있음을 보여준다.

ABSTRACT

The prediction of the accurate traffic information can provide an optimal route from the place of departure to a destination, therefore, this makes it possible to obtain a saving of time and money. To predict traffic information, we use a Bayesian network method based on probability model in this paper. Existing researches predicting the traffic information based on a Bayesian network generally used to study the data for all time. In this paper, however, only data corresponding to same time and day of the week to predict selectively will be used for learning. In fact, the experiment was carried out for 14 links zone in Seoul, also, the accuracy of the prediction results of the two different methods should be tested with MAPE (Mean Absolute Percentage Error) which is commonly used. In view of MAPE, experimental results show that the proposed method may calculate traffic prediction value with a higher accuracy than the method used to learn the data for all time zones.

키워드 : 단기교통예측, 도심 도로, 베이지안 네트워크, 선별적 데이터 학습

Key word : Short-term Vehicle Speed Prediction, Urban Road, Bayesian Network, Selective Data Learning

Received 10 August 2015, Revised 25 August 2015, Accepted 11 September 2015

* Corresponding Author Young-Ho Kim(E-mail:ykkim@koti.re.kr, Tel:+82-44-211-3164)

Department of Road Transport Research, The Korea Transport Institute, Sejong 30147, Korea

Open Access <http://dx.doi.org/10.6109/jkiice.2015.19.12.2779>

print ISSN: 2234-4772 online ISSN: 2288-4165

©This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.
Copyright © The Korea Institute of Information and Communication Engineering.

I. 서론

기상정보 예측 시스템은 시간별 및 지역별로 기상이 어떻게 변하는지를 알려줌으로서 일상 생활에서 사람들이 기상 변화에 대비할 수 있는 편리함을 제공해주고, 또한 산업체의 경우 효율적으로 작업을 수행할 수 있도록 하는 역할을 한다. 교통정보 예측 시스템도 기상정보 예측 시스템과 같이 중요한 의미를 가진다고 할 수 있다. 정확한 교통정보 예측시스템이 실생활에 활용이 용이하게 되면 각 개인의 차량이동에 소요되는 시간을 절약할 수 있을 뿐 아니라 산업적인 측면에서도 물류 비용을 개선할 수 있는 효과적인 방안이 될 수 있다.

거의 대부분의 차량에 네비게이션이 설치되어있는 오늘날의 상황에서, 차량 운전자는 대부분 출발지에서 목적지까지 최적경로를 통해 이동하는 것을 원할 것이다. 우리나라의 경우 1990년대부터 ITS(Intelligent Transport System) 구축 사업이 시작되어 2005년 국가 ITS 기본 계획 1단계가 마무리되면서 수도권, 광역시, 고속도로, 주요 도로 및 여러 지자체등을 중심으로 실시간 교통정보 수집을 위한 시스템이 구축되었으며, 이를 기반으로 실시간 교통 정보 서비스가 제공되고 있다 [1]. 현재 사용되고 있는 대부분의 네비게이션 시스템들은 실시간 정보를 기반으로 최적경로를 계산하거나, 실시간 교통정보와 과거의 누적된 교통정보 데이터를 기반으로 최적경로를 계산한다. 그러나 차량이 이동함에 따라 교통상황은 시시각각 변할 수 있으며, 이로인하여 차량 출발시에 계산된 최적경로는 운전중에 시간이 지남에 따라 더 이상 최적경로가 아닐 수 있다. 이러한 실시간 교통정보만을 이용해서 최적경로를 계산할 때의 문제점을 보완할 수 있는 방법이 미래의 교통상황을 예측하고 이를 기반으로 차량이동의 최적경로를 계산하는 것이다.

교통정보를 예측하기 위해 기존 연구에서 제안된 예측 모델들은 ARIMA(Autoregressive Inegrated Moving Average), 칼만 필터링, 인공 신경망, KNN(K-Nearest Neighbor), 베이지안 네트워크 등이 있다[2-9].

ARIMA 예측 모델은 일정한 특징을 가지는 교통정보 데이터에 시계열 모형인 ARIMA 모형을 적용한 것이고, 인공 신경망 모델은 뉴런의 학습을 통해 예측 값을 찾아가는 방법이다. 칼만 필터링 모형은 반복되는 단계에서 오차를 줄여주는 방향으로 예측 값을 계산하

는 방법으로 도로 네트워크의 크기가 커질 경우 계산량이 많아 실시간 예측에 어려움이 있다. KNN 방법은 최근에 예측을 위해 많이 사용되는 방법으로, 이전 데이터 중 현재 시점의 교통정보와 가장 유사한 정보를 검색해 그 값을 예측 값으로 사용하는 방법이다. 그리고 베이지안 네트워크 모델은 GMM(Gaussian Mixture Model)과 베イズ 규칙에 기반한 확률 계산을 통해 미래의 교통정보를 예측하는 방법이다. 지금까지 다양한 예측 모델들이 제안되었지만, 수시로 변하는 불규칙한 교통상황으로 인해 어느 하나의 모델이 확실히 우수하다고 확신하기는 어렵다.

본 논문에서는 확률에 기반한 베이지안 네트워크 모델을 사용하여 교통정보를 예측하는 방법을 제안한다. 베이지안 네트워크를 이용한 예측 모델은 2006년 Sun 등에 의해 처음 제안되었다[2]. 여기서는 예측하고자 하는 특정 링크와 상류 링크들을 베이지안 네트워크의 원 인노드로 구성하여 실험하였다. 이후 Yu등은 원인노드에 하류링크를 포함하고 실시간 교통정보를 교통정보 예측에 반영하는 방법을 제안하였다[4]. Sun등과 Yu등은 특정 링크의 교통정보 예측을 위해 해당 링크의 이전 모든 시간대에서의 데이터를 베이지안 네트워크 학습을 위해 사용하였다. 이들과 달리 본 논문에서는 예측 대상의 링크에 대해 예측하고자 하는 요일과 시간별로 이전 데이터를 선택적으로 구분하여 베이지안 네트워크 학습에 사용한다. 본 논문에서는 실험을 위해 서울 시내 도로 일부분의 2012년 10월 ~ 2014년 10월 까지의 5분 단위 속도 데이터를 사용하고, 이 데이터들 중에서 요일 및 시간을 기반으로 선택적으로 선별한 데이터를 베이지안 네트워크 학습을 위해 사용하였다.

본 논문의 구성은 다음과 같다. 2장에서는 베이지안 네트워크를 이용한 교통정보 예측 모델에 관해 기술하고, 본 논문에서 제안하는 학습 방법에 관해서는 3장에서 설명할 것이다. 4장에서는 본 논문에서 제안한 방법으로 예측된 예측 결과를 보여주고, MAPE의 관점에서 이전 방법과 비교하여 교통 예측의 정확성을 검증한다. 마지막으로 5장에서 결론을 맺는다.

II. 베이지안 네트워크 예측 모델

베이지안 네트워크는 독립변수들 사이의 조건부 확

를 기반으로 하며, 예측 결과를 얻기 위해서는 결합확률밀도함수가 요구된다. 본 논문에서는 서울 도심구간의 도로 네트워크를 사용하며, 각 링크당 상·하류 링크의 개수는 평균 4~5개 정도이다. 그리고 원인 노드로 선택된 각 링크들의 최근 교통정보는 20분 이전까지의 정보를 고려하였으므로 베이지안 네트워크를 구성하는 노드의 수는 대략 20~30개 정도가 된다. 독립변수들의 차수가 20차원 이상의 고차원으로 하나의 결합확률밀도함수로 모델링하기는 어렵기 때문에 가우시안 혼합 분포를 따르는 것으로 가정한다. 가우시안 혼합 분포 내의 정규 분포의 수는 사전 실험 결과 예측 결과에 큰 영향을 미치지 않는 것으로 측정되어 본 논문에서는 3개의 정규 분포로 가정하였다. 가우시안 혼합 분포의 결합확률밀도함수는 다음 식 1과 같다.

$$P(x|\Theta) = \sum_{k=1}^M \alpha_k p_k(x|\theta_k) \quad (1)$$

위 식에서 Θ 는 가우시안 혼합 분포의 파라미터 집합인 $(\alpha_k, \theta_k, k = 1, 2, 3)$ 을 나타낸다. α_k 는 각 요소의 가중치를, $\theta_k = (\mu_k, \Sigma_k)$ 은 각 요소의 평균과 공분산을 의미한다. 베이지안 네트워크 기반의 교통정보 예측을 위해서는 이전에 측정된 교통정보 데이터의 학습을 통해 식 1에서 요구되는 가중치, 평균 그리고 공분산 값들을 계산해야한다. 이를 위해 본 논문에서는 Sun등[2]과 Yu등[4]이 사용한 EM(Expectation Maximization) 알고리즘을 사용한다. 베이지안 네트워크의 추론 문제는 주어진 원인 노드들의 값들로 결과 노드의 값을 추정하는 것이다. 베이지안 네트워크의 결과 노드의 값은 원인 노드들에 대한 조건부 기댓값으로 계산할 수 있다. EM 알고리즘을 사용하여 학습한 결합확률밀도함수를 이용하여 결과 노드의 조건부 확률을 계산하는 방법은 다음 식 2와 같다.

$$P(Y|X) = \frac{P(Y, X)}{P(X)} \quad (2)$$

$$= \frac{\sum_{i=1}^M \alpha_i G(X; \mu_{iX}, \Sigma_{iXX}) G(Y; \mu_{iY|X}, \Sigma_{iY|X})}{\sum_{j=1}^M \alpha_j G(X; \mu_{jX}, \Sigma_{jXX})}$$

$$= \sum_{i=1}^M \beta_i G(Y; \mu_{iY|X}, \Sigma_{iY|X})$$

여기서,

$$\beta_i = \frac{\alpha_i G(X; \mu_{iX}, \Sigma_{iXX})}{\sum_{j=1}^M \alpha_j G(X; \mu_{jX}, \Sigma_{jXX})}$$

$$\mu_{iY|X} = \mu_{iY} - \Sigma_{iYX} \Sigma_{iXX}^{-1} (\mu_{iX} - X)$$

$$\Sigma_{iY|X} = \Sigma_{iYY} - \Sigma_{iYX} \Sigma_{iXX}^{-1} \Sigma_{iXY}$$

위 식에서 X 는 원인 노드를, Y 는 결과 노드를 의미한다. 식 2의 조건부 확률을 이용해 결과 노드의 값을 추론하는 식은 다음 식 3과 같다.

$$\hat{Y} = E[Y|X] \quad (3)$$

$$= \int Y P(Y|X) dY$$

$$= \sum_{i=1}^M \beta_i \int Y G(Y; \mu_{iY|X}, \Sigma_{iY|X}) dY$$

$$= \sum_{i=1}^M \beta_i \mu_{iY|X}$$

위 식에서 β_i 는 가우시안 혼합 분포의 파라미터 추출로 미리 계산해 놓을 수 있으며, $\mu_{iY|X}$ 을 계산하는데 필요한 평균과 공분산 값들도 이미 계산되어 있으므로 예측 값은 실시간에 계산된다.

III. 교통정보 데이터 학습

본 논문에서 사용하는 베이지안 네트워크를 이용한 차량 속도 예측 모델의 기본 골격은 2장에서 설명한 것과 같이 Su등[3]과 Yu등[5]이 사용한 방법과 기반으로 한다. 이 방법과 본 논문에서 제시하는 방법상의 차이는 가우시안 혼합 분포의 파라미터를 추출하기 위한 학습과정에서 주어진 이전 교통정보 데이터 중 무엇을 사용하는가에 있다.

일반적으로 단기 교통 예측은 1시간 이전의 예측을 의미하며, 보통 5분 단위의 예측이 많이 사용된다. 본 논문에서도 각 링크에 대해 15분, 30분, 45분, 60분 단위로 예측을 수행한다. 본 논문에서 사용한 이전 교통정보는 서울 도심에서 획득한 2012.10~2014.10월까지의 5분단위 차량 속도 데이터이다.

예측하고자 하는 링크를 P_t , 예측 단위 시간을 P_i 라 하자. 30분 후 예측을 할 경우 $P_i = 30$ 이 된다. 베이지안 네트워크 모델을 사용해서 예측을 하기 위해서는 2장에서 설명한 것과 같이 학습을 통해 가우시안 혼합 분포




Fig. 1 Prediction result for 60 minutes of the link 1010014300 (2014.4.20.)

의 파라미터들을 미리 추출해야한다. 이것을 위해 이전 방법들에서는 주어진 데이터의 모든 시간대를 학습에 이용하였으며, 결과적으로 P_t 와 P_t 에 대해 하나의 가우시안 혼합 분포 파라미터만이 추출된다. 추출된 파라미터를 G_{it} 라 하자. 학습과정을 통해 추출된 G_{it} 는 모든 시간대에서 링크 P_t 의 P_t 시간 후의 차량 속도 예측을 위해 사용된다. 즉 실제 예측이 수행되는 시간에 관계없이 P_t 의 P_t 후의 예측은 항상 G_{it} 를 사용한다.

본 논문에서 주목한 점은 실제 예측이 수행되는 시간대가 다르다면 예측을 위한 파라미터도 달라질 수 있다는 점이다. 이것을 위해 본 논문에서는 가우시안 혼합 분포의 파라미터 추출을 위한 학습을 요일과 시간별로 구분하여 수행한다. 차량 속도는 5분 간격으로 저장되기 때문에, 본 논문에서 제안한 방법에 따르면 링크 P_t 의 P_t 시간 후의 예측을 위한 가우시안 혼합 분포 파라미터 집합 $S_G = \{G_{it}^1, \dots, G_{it}^{2016}\}$ 을 학습을 통해 생성할 수 있다. 여기서 G_{it}^1 은 월요일 0시 0분, G_{it}^{2016} 은 일요일 23시 55분의 파라미터를 의미한다.

그림 1은 2014년 4월 20일 하루 동안의 60분 예측 결과를 보여주는 그림이다. 그림에서 REAL은 실제 측정된 속도, ACCUM은 누적 평균 속도, BN(all)은 이전 방법을 사용한 예측속도이고 BN(part)는 본 논문에서 제

안한 방법을 사용한 예측속도 결과이다. BN(all)의 그래프를 보면 누적 속도 평균처럼 큰 변화없이 잔잔한 흐름을 보이고 있음을 알 수 있다. 그에 반해 BN(part) 그래프는 각 시간대의 파라미터 값들이 반영되어 좀 더 다른 양상을 보여준다.

IV. 실험 결과

본 논문에서는 실험을 위해 서울 도심에서 2012.10 ~ 2014.10 까지 5분 단위로 측정된 차량 속도 데이터를 사용하였다. 총 14개의 링크에 대해 예측 단위 시간 15분, 30분, 45분, 60분으로 실험을 진행하였으며, 2014.4.20 ~ 2014.4.26 까지 일주일간의 예측 결과를 생성했다. 가우시안 혼합 분포 파라미터 생성을 위한 학습 데이터는 2012.11 ~ 2013.10까지의 1년간 데이터를 사용하였다. 그리고 예측 결과의 정확도는 일반적으로 많이 사용되는 MAPE를 사용해서 측정하였다.

표 1은 1년간의 데이터 전체를 가우시안 혼합 분포 파라미터를 생성하기 위해 학습에 사용한 이전 방법(BN(all))과 본 논문에서 제안한 요일, 시간별 데이터를 선별하여 학습에 사용한 경우(BN(part))의 15분, 30분, 45분, 60분 예측 결과에 대한 MAPE 값들을 보여준다.

Table. 1 MAPE of 15, 30, 45, 60 minutes prediction results for 14 links (2014.4.20 ~ 2014.4.26)

	BN(all)				BN(part)			
	15minute	30minute	45minute	60minute	15minute	30minute	45minute	60minute
1010005100	0.2012	0.2208	0.2277	0.2334	0.1997	0.2103	0.2152	0.2147
1010007100	0.3772	0.4169	0.4403	0.4685	0.3800	0.3979	0.4047	0.4043
1010011300	0.3134	0.3571	0.3814	0.4107	0.3343	0.3563	0.3574	0.3635
1010011600	0.2601	0.2829	0.3004	0.2945	0.2772	0.2899	0.3015	0.3058
1010012500	0.3696	0.3753	0.3773	0.3854	0.3822	0.3866	0.3914	0.3873
1010013400	0.3345	0.3555	0.3691	0.3762	0.3389	0.3509	0.3558	0.3603
1010013900	0.2156	0.2248	0.2324	0.2433	0.2221	0.2275	0.2278	0.2315
1010014100	0.2228	0.2576	0.2767	0.2838	0.2203	0.2396	0.2519	0.2555
1010014300	0.3529	0.4281	0.4825	0.5193	0.3528	0.3955	0.4358	0.4447
1010014700	0.3703	0.4742	0.5351	0.5668	0.3712	0.4522	0.4924	0.5098
1010015000	0.2154	0.2261	0.2298	0.2333	0.2196	0.2347	0.2327	0.2354
1010015700	0.2162	0.2469	0.2598	0.2675	0.2157	0.2379	0.2426	0.2440
1010016100	0.2160	0.2337	0.2411	0.2493	0.2177	0.2307	0.2318	0.2325
1010016900	0.3125	0.3723	0.4140	0.4575	0.2895	0.3323	0.3383	0.3383
Average	0.2841	0.3194	0.3405	0.3564	0.2872	0.3102	0.3200	0.3234

각 링크별로 보면 몇몇의 경우 BN(all)이 좋은 경우도 있지만 대부분의 경우 본 논문에서 제안한 방법이 더 좋은 MAPE 값을 보여주고 있음을 확인할 수 있다. 14개 링크의 MAPE 값들을 평균한 결과를 보면 15분 예측의 경우 BN(all)이 조금 나은 결과를 보이지만 나머지 예측 시간에 대해서는 본 논문에서 제안한 결과가 더 좋은 MAPE 값을 나타내고 있다.

V. 결 론

본 논문에서는 베이지안 네트워크 모델을 사용한 차량 속도 예측에 관한 방법을 제안하고 있다. Su등[2]과 Yu[4]등이 이전에 베이지안 네트워크 모델을 사용한 차량 속도 예측 방법을 제안하였지만, 이들은 가우시안 혼합 분포 파라미터 값들을 위한 학습 과정에서 실제 예측이 진행되는 요일과 시간을 고려하지 않고 이전 데이터 전체를 사용하였다. 따라서 이들은 실제 예측이 이루어지는 모든 시간대에서 동일한 학습데이터를 이용해 예측하였다. 그러나 교통정보는 링크, 요일, 시간에 따라 다른 특성을 가질 수 있으므로 본 논문에서는 학습과정에서 실제 예측이 수행되는 요일과 시간별로 다른 학습데이터를 생성하는 방법을 제안하였다. 서울 도심 14개의 링크에 대해 15분, 30분, 45분, 60분의 예

측 단위로 일주일간의 예측 결과를 실험한 결과 본 논문에서 제안한 방법이 일반적인 평가 방법인 MAPE의 관점에서 이전 방법에 비해 좀 더 나은 결과를 보임을 알 수 있었다.

본 논문에서 제안한 방법이 MAPE의 관점에서 이전 방법들에 비해 비교적 나은 결과를 보이지만 예측치와 실제 차량 속도와의 차이를 줄일 수 있는 좀 더 나은 방법에 대한 연구가 필요한 것으로 보인다. 현재는 단지 5분 간격의 차량속도만이 실시간으로 주어진다든가 고정하에 예측을 수행하지만, 기상이나 다양한 돌발 상황에 대한 정보가 주어진다면 지금보다 좀 더 나은 예측이 가능할 수도 있을 것으로 여겨진다. 또한 베이지안 네트워크 모델이 확률에 기반한 방법이므로 KNN 등과 같은 다른 기법과의 결합을 고려해 보는 것이 필요하다.

ACKNOWLEDGMENTS

This research was supported by a grant from Transportation & Logistics Research Program funded by Ministry of Land, Infrastructure and Transport Affairs of Korean government

REFERENCES

- [1] Cheol Oh, "A Study Toward Developing a Framework for Intelligent Transport Systems(ITS) Audit," *KOTI*, 2005.
- [2] Shiliang Sun, Changshui Zhang, Guoqiang Yu, "A Bayesian Network Approach to Traffic Flow," *IEEE Transaction on Intelligent Transportation Systems*, Vol. 7, No. 1, 2006.
- [3] Hironobu Kitaoka, Takahiro Shiga, Hiroko Mori etc., "Development of a Travel Time Prediction Method for the TOYAA G-BOOK Telematics Services," *R&D Review of Toyota CRDL*, Vol. 41, No. 4, 2007.
- [4] Y. Yu and M. G. Cho, "A Short-Term Prediction Model for Forecasting Traffic Information Using Bayesian Network," *Third 2008 International Conference on Convergence and Hybrid Information Technology*, pp. 247-253, 2008.
- [5] G. Q. Yu, J. M. Hu, C. S. Zhang, etc. "Short-Term Traffic Flow Forecasting based on Markov Chain Model," *Proc. IEEE Intelligent Vehicles Symp.*, Columbus, OH, 2003.
- [6] J.W.C van Lint, S.P. Hoogendoorn, and H.J. van Zuylen, "Robust and Adaptable Travel Time Prediction with Neural Networks," *Proc. 6th Annual Transport*, 2000.
- [7] Rui Wang, Hideki Nakamura, "Short term Prediction Works in Traffic Engineering: The State-Of-The-Art," *ITS World Congress*, 2002.
- [8] M. G. Cho, Y. Yu and S. Kim, "The System for Predicting the Traffic Flow with Real-Time Traffic Information," *Lecture Note in Computer Science*, Vol. 3980, 2006.
- [9] M. A. Rasyidi, J. Kim and K. R. Ryu, "Short-erm Prediction of Vehicle Speed on Main City Roads using the k-Nearest Neighbor Algorithm," *Journal of Intelligence and Information Systems*, Vol. 20, No. 1, pp. 121-131, 2014.



박성호(Seong-Ho Park)

1996년 부산대학교 전자계산학과 이학사
 1998년 부산대학교 대학원 전자계산학과 이학석사
 2002년 부산대학교 대학원 전자계산학과 이학박사
 2002년 9월 ~ 현재 부산대학교 정보전산원 교수
 ※관심분야 : 멀티미디어 통신, 컴퓨터 비전, 2D/3D 영상 및 비디오 처리



유영중(Young-Jung Yu)

1996년 부산대학교 전자계산학과 이학사
 1998년 부산대학교 전자계산학과 이학석사
 2002년 부산대학교 전자계산학과 이학박사
 2002년 ~ 현재 부산외국어대학교 컴퓨터공학과 교수
 ※관심분야 : 컴퓨터 애니메이션, 영상 처리, 알고리즘



문상호(Sang-Ho Moon)

한국기계연구원 정보지원실 연구원
 부산대학교 컴퓨터공학과 공학박사
 위덕대학교 컴퓨터공학부 조교수
 University of Central Oklahoma Visiting Scholar
 부산외국어대학교 컴퓨터공학과 교수
 ※관심분야 : DB, GIS, 디지털인문학, 정보시스템 감리



김영호(Young-Ho Kim)

1995년 서울대학교 토목공학과 공학사
 1997년 서울대학교 토목공학과 공학석사
 2002년 독일 뮌헨공과대학교 토목공학과 공학박사
 2005년 ~ 현재 한국교통연구원 도로교통본부 연구위원
 ※관심분야 : 교통정보처리, 교통운영