

k-NN 알고리즘을 활용한 단기 교통상황 예측: 서울시 도시고속도로 사례

김형주¹ · 박신형² · 장기태^{1*}

¹한국과학기술원 조천식 녹색교통대학원, ²계명대학교 도시학부 교통공학전공

Short-term Traffic States Prediction Using k-Nearest Neighbor Algorithm: Focused on Urban Expressway in Seoul

KIM, Hyungjoo¹ · PARK, Shin Hyoung² · JANG, Kitae^{1*}

¹The Cho Chun Shik Graduate School for Green Transportation, KAIST, Daejeon 34141, Korea

²Department of Transportation Engineering, Keimyung University, Daegu 42601, Korea

*Corresponding author: kitae.jang@kaist.ac.kr

Abstract

This study evaluates potential sources of errors in k-NN(k-nearest neighbor) algorithm such as procedures, variables, and input data. Previous research has been thoroughly reviewed for understanding fundamentals of k-NN algorithm that has been widely used for short-term traffic states prediction. The framework of this algorithm commonly includes historical data smoothing, pattern database, similarity measure, k-value, and prediction horizon. The outcomes of this study suggests that: i) historical data smoothing is recommended to reduce random noise of measured traffic data; ii) the historical database should contain traffic state information on both normal and event conditions; and iii) trial and error method can improve the prediction accuracy by better searching for the optimum input time series and k-value. The study results also demonstrates that predicted error increases with the duration of prediction horizon and rapidly changing traffic states.

Keywords: event condition, historical data, k-nearest neighbor, short-term prediction, real-time data

초록

본 연구는 실시간 자료를 기반으로 k-NN을 활용한 단기 교통상황 예측 시 각 단계별 세부절차 및 변수결정, 입력자료 구축 등의 각 단계별 잠재적 예측오차에 대한 원인분석 및 시사점 도출을 목적으로 한다. 다양한 단기 예측모형에 대한 선행연구 검토를 통하여 k-NN 모형의 유용성을 검토하였고 이에 대한 적용가능성을 분석하였다. 본 연구의 k-NN 모형은 이력자료 평활화 및 패턴DB 구축의 입력자료 부분, 실시간 자료와 과거 이력자료와의 유사성 측정 및 k 근접 이웃 결정 등의 k-NN 알고리즘 부분, 그리고 예측 시간간격에 따른 출력결과 부분 등으로 구성되며 올림픽대로 김포방향 한강대교 남단~여의상류IC 구간을 대상으로 분석을 실시하였다. 교통자료의 불규칙 잡음으로 인하여 정확한 패턴매칭을 위해서 이력자료의 평활화를 실시하였으며, 이력자료 패턴 DB는 일반 및 이벤트 상황으로 구분하여 활용하였다. 최적의 시계열 자료 및 k 근접이웃 결정을 위해서 시행착오 방법을 적용하였으며, 단기 교통상황 예측 시 예측 시간간격이 증가할수록 예측오차가 증가하는 패턴, 그리고 교통상태가 급변하는 시점에서 예측오차가

증가함을 알 수 있었다. 본 연구의 k-NN 모형에 대한 각 단계별 예측오차에 대한 원인을 분석하여 개선방향을 제시함으로써 향후 신뢰성 있는 단기 교통상황예측 정보제공 및 시스템에 활용이 가능할 것으로 판단된다.

주요어: 이벤트 상황, 이력자료, k-최대근접이웃, 단기예측, 실시간자료

서론

1. 연구의 배경 및 목적

현재 대도시권에서는 교통 혼잡으로 인하여 막대한 사회·경제적 비용이 발생하고 있지만 기존의 교통운영관리 시스템에서는 이에 대한 적절한 대응이 이루어지지 못하고 있다. 이를 해결하기 위해서 최근 실시간 교통정보 제공을 통하여 기존 도로시설의 운영효율을 극대화하기 위해 노력하고 있다. 하지만 실시간 교통정보의 경우 현재 시점 이전의 교통자료를 이용하여 정보를 제공하기 때문에 운전자가 실제 경험하는 통행시간 정보와의 차이를 가지는 한계가 존재한다. 이로 인해 교통정보에 대한 운전자들의 신뢰성이 저하되고 있어 보다 정확한 예측정보 제공에 대한 필요성이 증대되고 있다. 교통 선진국인 미국, 영국 등에서는 이미 교통예측정보 제공시스템이 공공 및 민간분야에서 활발하게 구축되어 운영 중에 있는데, 이를 통해 제공되는 단기 예측정보는 운전자들에게 최적의 경로선택을 유도하여 교통량이 집중되는 혼잡한 교통류를 시공간적으로 분산시키는 장점을 가진다.

교통상황예측 모형은 크게 통계적 방법과 시뮬레이션 방법으로 나눌 수 있다.¹⁾ 통계적 방법은 이력자료 및 단기 자료를 이용하여 예측정보를 생성하는 반면, 시뮬레이션 방법은 교통량, 밀도, 속도 등의 교통류 특성자료를 활용한다. 이 중 단기 교통상황예측에 우수한 예측력을 가지는 통계적 방법이 시뮬레이션 방법에 비해서 널리 활용되고 있다. 통계적 방법의 경우 일반적으로 회귀모형, 칼만필터, ANN(Artificial Neural Network), 그리고 k-NN(k-Nearest Neighbors) 알고리즘 등이 사용된다. 회귀모형은 일반적(stationary) 상황의 단기예측에는 적합하지만 교통상황이 변화(transition)되는 상황은 반영하지 못하는 단점을 가진다. 칼만필터는 예측시 수행속도가 빠른 장점이 있지만, 이력자료가 아닌 현재시점의 자료만을 활용하여 예측을 실시하기 때문에 예측의 정확도 향상에 어려움이 따른다. ANN의 경우 학습과정이 복잡하고 정확한 예측결과를 도출하기 위한 연산시간이 상대적으로 길다는 단점이 존재한다. 반면 k-NN의 경우, 단순한 유사도기반 자료매칭으로 모형이 간단하고 연산시간이 짧아 단기 교통상황예측에 장점을 가진다. 특히 복잡한 비선형 문제에 있어 우수한 예측력을 가지고 있으며, 유고 및 정체로 인한 교통현상의 반영이 가능한 장점이 있어, 현재 도로공사와 서울시 등에서 k-NN을 이용하여 통행시간을 예측하기 위한 검토가 진행되고 있다.

2. 연구의 내용 및 방법

본 연구에서는 먼저 통계적 방법의 일환인 k-NN을 활용한 다양한 연구 사례를 검토한다. 다양한 단기 예측 모형에 대한 선행연구 검토를 통하여 k-NN 모형의 유용성을 검토하고 이에 대한 적용가능성을 분석한다. 이어서 실시간 자료를 기반으로 k-NN을 활용한 단기 교통상황 예측 시 각 단계별 세부절차 및 변수결정, 입력자료 구축 등을 통하여 각 단계별 잠재적 예측오차에 대한 원인을 분석하고 시사점을 도출한다. 마지막으로 결론에서는 본 연구의 성과 및 한계, 그리고 향후 연구방향을 제시한다.

선행연구 고찰

1) Guin A., Laval J., Chilukuri B. R. (2013), Freeway Travel-time Estimation and Forecasting, GDOT Research Project 10-01: TO 02-60, School of Civil and Environmental Engineering Georgia Institute of Technology.

1. 국내외 선행연구 고찰

Data-driven 방식의 단기 교통상황예측은 회귀모형, 칼만필터, ANN, k-NN 등의 통계적 방법을 이용하여 다양한 연구가 수행되었다.

Kwon et al.(2000)의 연구에서는 단계적 변수선택(stepwise variable selection method)을 활용한 회귀분석을 통해서 통행시간을 예측하였다. 분석결과 단기예측에는 현재의 교통상태를, 반대로 장기예측에는 과거이력 자료를 활용하는 것이 효율적인 것으로 판단하였다. MAPPE(Mean Absolute Percentage Prediction Errors) 분석 결과, 약 14.1%의 오차율을 보였고, MSPE(Mean Squared Prediction Error)는 116.75초의 오차를 보였다. Zhang et al.(2003), Rice et al.(2004)의 연구에서는 TVC(time-varying coefficient)를 활용한 단순회귀모형을 적용하여 통행시간을 예측하였다. 분석결과 각각 MAPE 11-14%, RMSE는 약 10분의 오차를 보였다.

Chen et al.(2001)의 연구에서는 프로브차량 자료 기반 칼만필터를 활용하여 실시간 링크 및 경로통행시간 예측을 실시하였다. 분석결과 일반적 교통상태에서는 경로통행시간 예측의 정확도가 높게 분석되었다. 이는 프로브차량 대수의 변동성에 기인한 것으로 링크통행시간 예측 시 변동성이 상대적으로 높은 데 따른 결과로 판단하였다. Shalaby et al.(2004)의 연구에서는 Automatic Vehicle Location(AVL) and Automatic Passenger Counting(APC) 자료 기반 칼만필터를 활용하여 실시간 버스 출발 및 도착시간을 예측하였다. 일반 상황과 이벤트 상황으로 시나리오를 구분하여 VISSIM을 활용한 시뮬레이션 기반 알고리즘 성능평가를 실시하였다. 일반상황 및 이벤트 상황에서 칼만필터가 각각 9.7%, 12.3%의 오차율로 이력자료 평균모형 및 회귀모형에 비해 높은 정확도를 가졌다.

Innamaa(2005)의 연구에서는 ANN 알고리즘 기반 고속도로 통행시간 예측을 실시하였다. 일반 및 정체교통류, 링크길이, 시계열자료 길이 등으로 각각 구분하여 링크의 통행시간 예측 정확도를 비교하였다. 정체 시 통행시간 예측결과 오차율이 일반교통류 상태보다 높게 도출되었다. 이 결과를 근거로 ANN을 통한 단기 예측 시 training에 가중치를 두는 방법론에 대한 연구 필요성을 제시하였다. van Lint(2006)의 연구에서는 SSNN(state-space neural network)을 활용하여 고속도로 단기 통행시간 예측을 실시하였다. SSNN 기법은 통행시간 정보수집→필터링→이력자료 기반 예측 등의 절차를 포함하는 것으로 정의하였으며, 회귀모형, 칼만필터 등의 선행연구의 예측오차율을 함께 비교하여 예측의 정확도를 평가하였다.

Clark(2003)의 연구에서는 교통모수인 교통량, 속도, 그리고 점유율의 예측을 위해 패턴매칭의 일환인 k-NN 알고리즘을 적용하였다. 분석대상 도로는 M25 고속도로 링크구간이며, 집계간격의 경우 10분 단위, 그리고 이력자료의 경우 1주일을 사용하였다. k-NN의 파라미터인 시계열개수(4개) 및 k개수(8-10개)를 적용하였으며, 요일별 예측오차를 도출하였다. 예측의 정확도는 MAPE 및 RMSE를 적용하였으며, ARIMA 모형 보다 높은 정확도를 보였다.

Lam et al.(2006) 연구에서는 k-NN 기반 단기 교통량 예측을 실시하였다. ATC(Annual Traffic Census) 87개 지점 검지자료를 기반으로 예측을 실시하였으며, 분석결과 검증에 위해 GML(Gaussian Maximum Likelihood) 모형과 비교하였다. 단기 교통량 예측시 k-NN의 경우 MAPE 약 5%로 GML에 비해 높은 예측력을 보였다. 또한 k-NN 알고리즘이 GML에 비해서 교통정체로 인한 갑작스러운 변화에 보다 빠르게 반응하는 결과를 보였다.

Lim et al.(2009) 연구에서는 통행시간 예측의 정확도를 증대시키기 위해서 Data fusion에 기반한 k-NN 알고리즘을 제안하였다. Data fusion의 경우 예측시간 간격에 따라 실제 차량이 경험하는 통행시간 정보를 제공받지 못해서 발생하는 time-lag를 줄이기 위한 방법으로 k-NN 기반 통행시간 예측 시 지점 교통정보도 함께 활용하는 것으로 정의하였다. 교통류 상태를 자유속도, 정체증가 시, 정체감소 시 등으로 나누어 분석을 실시하였으며, 분석결과 약 11%의 오차율을 보였다.

2. 선행연구와의 차별성

선행연구검토에서 확인할 수 있듯이 단기 교통상황예측을 위한 다양한 연구가 진행되었으나 회귀모형의 경우 분석구간에 따른 다수의 모형개발이 필요하며, 특히 혼잡시 예측의 정확도가 낮은 단점을 가진다. 칼만필터의 경우 현재 시점의 자료만 활용하기 때문에 예측의 정확도가 낮으며, ANN은 학습과정이 복잡해 연산시간이 길어지는 한계를 가진다. 반면, 패턴매칭 기반 k-NN의 경우 이러한 문제점을 해결할 수 있으며, 패턴매칭을 위한 이력자료가 충분할 경우 타 모형에 비해 정확도가 우수한 장점을 가진다(Smith et al., 2002). 하지만 기존 선행연구에서 알 수 있듯이 k-NN 기반 단기 교통상황 예측 시 각 단계별로 발생할 수 있는 예측오차에 대한 원인분석 및 단계별 세부절차, 입력자료 구축 등의 정립에 한계를 보였다. 이에 본 연구에서는 단기 교통상황 예측 시 각 단계별 잠재적 예측오차에 대한 원인을 분석하고 시사점을 도출하여 도시화 고속도로에서의 교통예측에 적용가능한지 평가하고자 한다.

연구방법론

1. k-NN 기본 구조 및 세부절차

k-NN 모형은 최근접 접근법으로 관찰치와 기존의 객체들(neighbors)간의 유사도(distance)를 비교하여 관찰치와 가장 유사한 k개의 객체들을 찾아내는 방법이다(Altman, 1992). 단기 교통상황 예측 시 k-NN 모형은 현재 교통상황과 유사한 교통상황이 과거에도 존재한다는 가정에서 출발한다. 실시간 교통상황 자료와 가장 유사한 이력자료를 찾아 향후 교통상황을 예측하는 방법으로 Figure 1과 같다. 입력자료, k-NN 알고리즘, 그리고 출력결과 등으로 크게 나눌 수 있으며, 패턴매칭 시 중요하게 작용하는 입력 자료에는 과거 이력자료의 평활화 및 패턴DB 구축 등이 포함된다. k-NN 알고리즘에는 실시간 자료와 과거 이력자료의 유사성 기반 패턴매칭으로 유클리디안 거리를 사용한다.

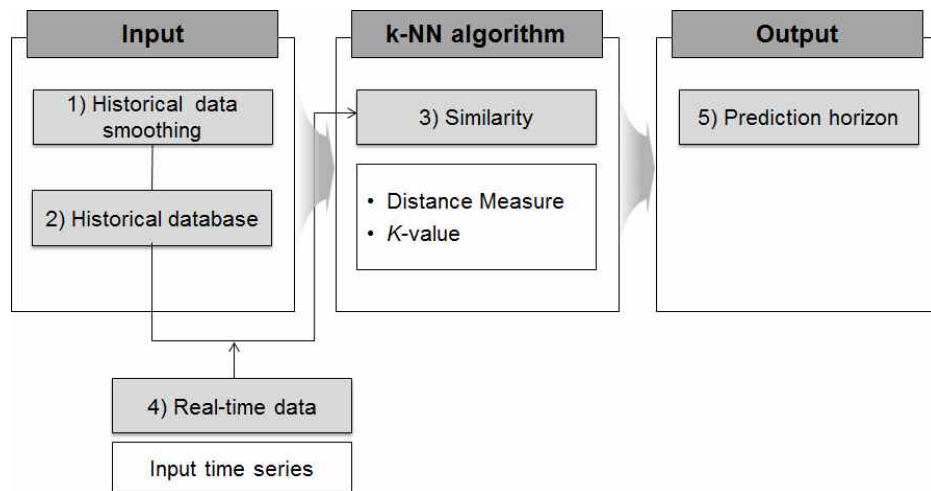


Figure 1. Framework of k-NN algorithm

2. 이력자료 평활화 및 패턴DB 구축

교통자료는 확률적(stochastic) 특성으로 인하여 측정값의 불규칙 잡음(random noise)이 발생한다. 잡음은 측정된 교통자료에 무작위의 오류 또는 분산이 존재하는 것을 말하는 것으로, k-NN 모형 기반 단기예측 시 시계열 속도패턴 도출(true trend of speed profile)을 통한 정확한 패턴매칭이 필요하다. 본 연구에서는 5 step 시간간격의 이력자료 평활화 작업(smoothing process)을 Equation 1과 같이 실시한다. 5 step 시간간격의 시계열 자료 평활화를 통해서 이력자료에 포함된 불규칙 잡음을 제거한다.

$$\frac{1}{5} \sum_{i=-2}^{i=2} V_i^h, \text{ f or all sample} \tag{1}$$

V^h : Historical speed data

이력자료의 경우 일반상황과 불꽃축제와 같은 특정 이벤트 상황으로 구분하여 패턴DB를 구축한다. 본 연구에서는 일반 및 이벤트 상황의 교통패턴의 차이점을 실제 교통자료를 통해서 증명하며, 불꽃축제의 단기 교통상황 예측 시 과거 불꽃축제 이벤트 상황을 포함하여 이를 활용한 경우 예측의 정확도가 증가됨을 보인다.

3. 유사도 측정 및 k 근접이웃 결정

k-NN 모형은 실시간 자료와 이력자료의 패턴매칭 시 유사성에 기반하여 적합한 후보군을 탐색한다. 본 연구에서는 실시간 자료와 가장 유사한 과거 이력자료 탐색 시 일자별로 탐색하여 유클리디안 거리를 계산한다. 짧은 연산시간을 기반으로 출·퇴근 시간, 또는 유고 및 사고 등으로 인한 이벤트 상황 시에 급변하는 교통상태 변화에 적합한 유클리디안 거리를 적용한다.

$$\text{Min} \sqrt{\sum_{i=1}^n (V_i^c - V_i^h)^2}, \text{ f or all sample} \tag{2}$$

V^c : Current speed data
 V^h : Historical speed data




Figure 2. Pattern matching based on euclidean distance

실시간 자료와 가장 유사한 이력자료의 패턴매칭 시 시계열자료 개수 및 k개의 근접이웃 결정이 필요하다. 이에 본 연구에서는 시행착오 방법(trial and error)을 통하여 최적의 시계열 자료 및 k개의 근접이웃을 결정한다.

4. k-NN 기반 단기 교통상황 예측 및 평가

k개의 근접이웃 결정을 통하여 단기 교통상황 예측 시 예측 시간간격에 따라 결과를 도출한다. 본 연구에서는 5-25분까지의 예측시간 간격에 따른 오차율을 비교한다. 유사성 기반 이력자료의 k 근접이웃의 개수에 따라 예측시간 간격에 따른 결과를 도출하며, Equation 3과 같다. 예측결과의 평가지표는 MAPE(Mean Absolute Percentage Error)를 사용하며, 산출방법은 Equation 4와 같다.

$$\hat{V}(t+j) = \frac{1}{k} \sum_{i=1}^{i=k} V_i^h(t+j) \tag{3}$$

\hat{V} : Predicted travel speed
 V^h : Historical speed data
 k : k - nearest neighbor
 j : Prediction horizon

$$MAPE (\%) = \frac{1}{n} \sum_{i=1}^n \left| \frac{V_i^a - \widehat{V}}{V_i^a} \right| \times 100 \quad (4)$$

V_i^a : Actual travel speed
 \widehat{V} : Predicted travel speed

결론 및 향후 연구과제

1. 분석구간 설정 및 입력자료 구성

본 연구에서는 불꽃축제일의 단기 교통상황예측을 위해서 올림픽대로 김포방향 한강대교 남단-여의상류IC 구간을 대상으로 분석을 실시하며 해당지역은 Figure 3과 같다. 단기 교통상황 예측 시 패턴매칭에 활용되는 이력자료는 2013년 7월 1일~9월 30일까지 3개월 및 과거 불꽃축제 이력자료 3일을 사용하였으며, 실시간 자료는 2013년 10월 5일(불꽃축제일)에 수집된 데이터로 분석을 실시하였다. 장기적인 패턴변화 및 계절적 변동 최소화, 그리고 연산시간을 고려하여 과거 이력자료는 3개월치의 자료를 활용하였다.

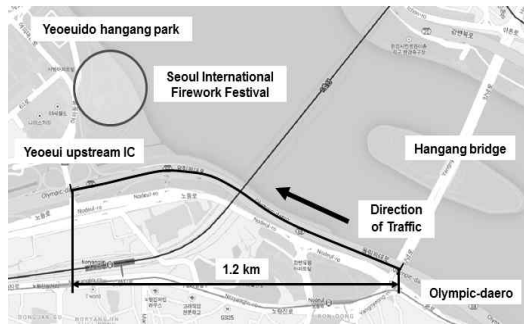


Figure 3. Case study: urban expressway in Seoul

2. k-NN 기반 단기 교통상황 예측 평가

먼저 k-NN 기본 구조의 입력 자료 부분에서 과거 이력자료 평활화 전·후 결과는 Figure 4와 같다. 이력자료 평활화 작업을 통해서 불규칙 잡음이 제거되어 실시간 자료와의 패턴매칭 시, 보다 정확한 패턴매칭이 가능한 장점을 가진다.




Figure 4. Historical speed data smoothing

불꽃축제일의 단기 교통상황 예측을 위해서 이력자료 에 과거 불꽃축제 교통패턴을 포함시켰다. 불꽃축제일의 교통패턴은 같은 요일의 일반적인 교통패턴과는 다른 패턴을 가지는 것을 알 수 있다(Figure 5, 6 참조). 시공도(time-space diagram) 분석을 통해서 일반상황의 경우 한남대교를 중심으로 출퇴근 정체가 발생하는 것을 알 수 있으며, 반대로 불꽃축제일의 경우 여의상류 IC(이벤트 장소)를 기준으로 정체가 발생하고 있다. 또한 불꽃축제가 종료되고 차량이 늦은 시간까지 빠져나가는 정체로 일반상황의 교통패턴과는 다른 패턴을 가지는 것

을 알 수 있다. 이는 k-NN 기반 단기 예측 시 현재 교통상황과 유사한 교통상황이 과거에도 존재한다는 가정에서 출발하므로 과거자료에 유사자료가 없을 시 정확도가 떨어진다. 그러므로 이벤트 상황과 같은 특별한 경우는 반드시 포함하여 이력자료를 구축할 필요가 있다.

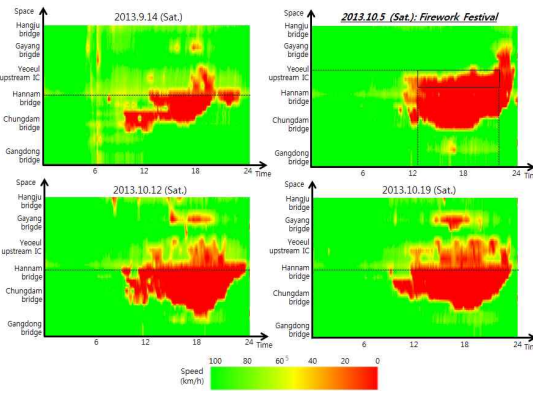


Figure 5. Spatiotemporal speed contours between normal and event condition

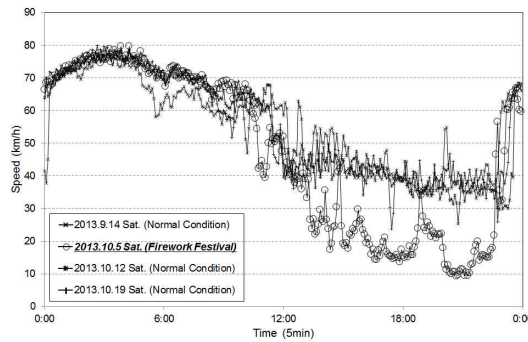


Figure 6. Comparison of speed profile between normal and event condition

최적의 시계열자료 개수 및 k개의 근접이웃 결정은 시행착오 방법을 통하여 결정하였다. 시계열 자료 3개, k 근접이웃 9개일 때 최소오차율을 보였으며 그 결과는 Figure 7과 같다. 시계열 자료 및 k 근접이웃 개수의 경우 연구자의 주관에 따라 임의로 결정될 경우 실제 예측결과에 상당한 예측오차를 발생시키는 원인으로 작용함을 알 수 있다. 해당 분석구간의 단기예측시 한번의 최적의 시계열 자료 및 k 근접이웃 개수 선정으로 활용이 가능하다.




Figure 7. Optimal input time series and k-value

k-NN 기반 단기 교통상황 예측은 5-25분까지의 예측시간 간격에 따른 오차율을 비교하였다. MAPE 분석 결과 t+1의 경우 7.45%의 오차율로 우수한 예측력을 보였지만 예측시간 간격이 증가할수록 예측 오차율이 증

가하는 패턴을 보였다. 또한 단기예측 시 교통상태가 급변하는 시점에서 예측의 오차가 급격히 증가함을 알 수 있었다(Figure 8 참조). 이는 예측시간 간격이 증가함에 따라 향후 교통정체가 발생하는 정보를 사전에 취득하지 못해서 발생하는 time-lag가 원인으로 작용하는 것으로 판단된다.

Table 1. MAPE result by prediction horizon

Prediction horizon	MAPE (%)
t+1	7.45
t+2	10.55
t+3	13.76
t+4	16.12
t+5	17.98

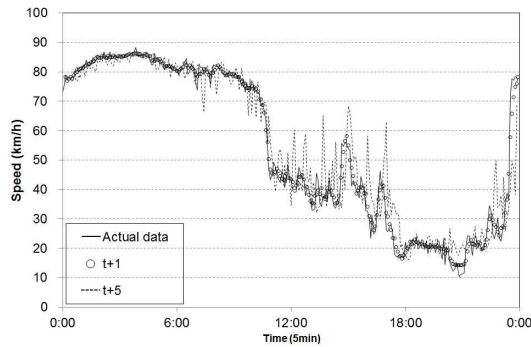


Figure 8. Actual predicted result by prediction horizon

결론

1. 연구의 의의 및 결론

본 연구는 실시간 자료를 기반으로 k-NN을 활용한 단기 교통상황 예측 시 각 단계별 세부절차 및 변수결정, 입력자료 구축 등의 각 단계별 잠재적 예측오차에 대한 원인분석 및 시사점 도출을 목적으로 한다. 다양한 단기 예측모형에 대한 선행연구 검토를 통하여 k-NN 모형의 유용성을 검토하였고 이에 대한 적용가능성을 분석하였다. 본 연구의 k-NN 모형은 이력자료 평활화 및 패턴DB 구축의 입력자료 부분, 실시간 자료와 과거 이력자료와의 유사성 측정 및 k 근접이웃 결정 등의 k-NN 알고리즘 부분, 그리고 예측 시간간격에 따른 출력결과 부분 등으로 구성되며 이를 적용한 주요 결과는 다음과 같다.

첫째, 교통자료의 확률적 특성으로 측정값의 무작위 오류 또는 분산이 존재하므로 k-NN을 활용한 단기예측 시 정확한 패턴매칭을 위해서 이력자료 평활화가 필요하다. 또한 이력자료의 경우 일반상황 및 이벤트 상황 등으로 구분한 패턴DB 구축을 통하여 각 상태에 따른 단기예측시 활용이 필요하다. 실제 교통자료 분석을 통해서 일반 및 이벤트 상황의 교통패턴의 차이점이 발생하는 것을 확인할 수 있었다.

둘째, k-NN 모형은 실시간 자료와 이력자료의 패턴의 유사성에 기반하여 적합한 후보군을 탐색하는 것으로 최적의 시계열 자료 및 k 근접이웃 개수 선정이 필요하다. 이에 본 연구에서는 시행착오 방법을 통해서 최적의 시계열 자료 및 k개의 근접이웃을 결정하였다. 이는 분석구간의 단기예측시 한번의 최적의 시계열 자료 및 k 근접이웃 개수 선정으로 단기 교통상황예측시 연산시간을 최소화할 수 있는 장점을 가진다.

셋째, k-NN을 활용한 단기 교통상황 예측 시 예측 시간간격이 증가할수록 예측오차가 증가하는 패턴을 보였으며, 교통상태가 급변하는 시점에서도 예측오차가 증가함을 알 수 있었다.

본 연구의 k-NN 모형에 대한 각 단계별 예측오차에 대한 원인분석으로 향후 신뢰성 있는 단기 교통상황예측 정보제공 및 시스템에 활용이 가능할 것으로 판단된다.

2. 향후연구과제

k-NN 모형 기반 단기예측 시 예측시간 간격이 증가함에 따라 예측오차가 급격히 증가하는 경우 향후 교통 정체가 발생하는 정보를 사전에 취득하지 못해서 발생하는 time-lag가 원인으로 작용하므로 이를 해결할 수 있는 대안으로 근접 상·하류부의 교통정보를 단기예측 시 추가적으로 활용하는 방법에 대한 연구도 필요할 것으로 판단된다.

ACKNOWLEDGEMENT

This research was supported by a grant (12 Transportation System - Intelligence 01) from the Implementation of More Efficient Transportation System program, funded by Ministry of Land, Transport and Maritime Affairs of the Korean Government.

알림: 본 논문은 2015 한국 ITS학회 춘계학술대회 (2015. 4. 23)에서 발표된 내용을 수정·보완하여 작성된 것입니다.

REFERENCES

- Altman N. S. (1992), An Introduction to Kernel and Nearest-Neighbor Nonparametric Regression, *American Stat.*, 46(3), 175-185.
- Chen M., Chien S. I. J. (2001), Dynamic Freeway Travel-time Prediction With Probe Vehicle Data: Link Based Versus Path Based, *Transp. Res. Rec.*, 1768(1), 157-161.
- Chien S., Ding Y., Wei C. (2002), Dynamic Bus Arrival Time Prediction With Artificial Neural Network, *J. Transp. Eng.*, 128(5), 429-438.
- Clark S. (2003), Traffic Predicting Using Multivariate Nonparametric Regression, *J. Transp. Eng.*, 129(2), 161-168.
- Guin A., Laval J., Chilukuri B. R. (2013), Freeway Travel-time Estimation and Forecasting, School of Civil and Environmental Engineering Georgia Institute of Technology, GDOT Research Project 10-01; TO 02-60.
- Innamaa S. (2005), Short-term Prediction of Travel Time Using Neural Networks on an Interurban Highway, *Transp.*, 32(6), 649-669.
- Kwon J., Coifman B., Bickel P. (2000), Day-to-day Travel-time Trends and Travel-time Prediction From Loop-detector Data, *Transp. Res. Rec.*, 1717(1), 120-129.
- Lam W. H. K., Tang Y. F., Chan K. S., Tam M. L. (2006), Short-term Hourly Traffic Forecasts Using Hong Kong Annual Traffic Census, *Transp.*, 33(3), 291-310.
- Lam W. H. K., Tang Y. F., Tam M. L. (2006), Comparison of Two Non-parametric Models for Daily Traffic Forecasting in Hong Kong, *J. Forecasting*, 25(3), 173-192.
- Lim S., Lee C. (2011), Data Fusion Algorithm Improves Travel Time Predictions, *IET Intell. Transp. Syst.*, 5(4), 302-309.
- Rice J., van Zwet E. (2004), A Simple and Effective Method for Predicting Travel-times on Freeways, *IEEE Intell. Transp. Syst.*, 5(3), 200-207.
- Shalaby A., Farhan A. (2004), Prediction Model of Bus Arrival and Departure Times Using AVL and APC data, *J. Public*

- Transp., 7(1), 41-61.
- Smith B., Williams B., Oswald K. (2002), Comparison of Parametric and Non Parametric Models for Traffic Flow Forecasting, *Transp. Res. C*, 10(4), 303-321.
- van Lint J. W. C. (2006), Reliable real-time framework for short-term freeway travel-time prediction, *J. Transp. Eng.*, 132(12), 921-932.
- van Lint J. W. C., Hoogendoorn S. P., van Zuylen H. J. (2005), Accurate Freeway Travel-time Prediction With State-space Neural Networks Under Missing Data, *Transp. Res. C*, 13(5), 347-369.
- Zhang X., Rice J. A. (2003), Short-term Travel-time Prediction, *Transp. Res. C*, 11(3), 187-210.