

# 칼만필터링을 이용한 구간 속도 예측에 관한 연구

## A Study on Link Speed Forecasting using Kalman Filtering Algorithm

**이 영 인**

서울시립대 도시공학과 조교수

**최 찬 영**

서울시립대 교통공학과 대학원

### 목 차

<p>I. 서론</p> <p>II. 관련 연구 및 이론 고찰</p> <p style="padding-left: 20px;">1. 관련 연구 고찰</p> <p style="padding-left: 20px;">2. 이론적 고찰</p> <p>III. 연구 방법론 연구</p> <p style="padding-left: 20px;">1. 연구방법론의 설정</p> <p style="padding-left: 20px;">2. Historical Traffic Pattern의 구축</p>	<p>IV. 기존 예측기법의 결과 및 예측모형을 이용한 구간 속도예측</p> <p style="padding-left: 20px;">1. 기존 예측기법의 결과</p> <p style="padding-left: 20px;">2. 칼만필터링을 이용한 모형의 결과</p> <p style="padding-left: 20px;">3. 구간 속도예측 결과 및 분석</p> <p>V. 결론</p> <p>참고문헌</p>
--	---

### ABSTRACT

본 연구는 기존 구간 속도 예측기법의 고찰을 통하여 검지기에서 올라오는 교통제어변수를 이용하여 구간 속도 예측모형을 연구하는데 목적이 있다. 이를 위한 교통 제어변수로는 연속류 제어에서 통상적으로 사용되는 교통량, 점유율, 밀도, 속도 등을 사용한다. 공간적 범위로는 서울 올림픽대로의 17개의 영상 검지기 중 #3과 #16 검지기에서 올라오는 속도, 점유율, 교통량 자료를 토대로 1998년 6월 11일 오전 7시부터 11시까지의 4시간동안 예측을 실시하며 Historical Traffic Pattern과 시험차량, 자동차 번호판 조사를 통한 구간 실측조사 자료를 토대로 예측을 위한 자료를 구축한다.

기존의 예측기법인 시계열 분석, 신경망 이론, 평활법과 칼만필터링을 고찰하였고, 가장 좋은 예측력을 보여주는 기법은 칼만필터링 모형이었다. 이를 토대로 Case Study를 통해 여러 구간의 다주기 예측을 통해 단기간(short-term)의 구간 속도를 예측하고 각 해당 검지기별 실측자료를 통해 비교분석을 실시하였다.

결과적으로 도출된 칼만필터링 모형의 다주기 예측을 통한 구간 통행속도의 예측이 기존의 구간 통행속도 산출 방법보다 더 나은 예측력을 보여주고 있다.

## I. 서론

### 1. 연구의 배경과 목적

도로 이용자들에게 제공되는 교통정보 가운데 중요한 정보는 일정한 매체를 통해 운전자에게 전달되는 도로의 구간별 교통정보이다. 교통정보의 신뢰도 향상은 도로 구간을 구성하고 있는 구간의 속도를 보다 정확히 계산해 냄으로써 가능해진다.

기존의 검지기 자료를 가공하여 운전자 및 그 밖의 교통정보 이용자에게 보다 신뢰성이 높은 구

간 속도에 대한 정보를 제공하기 위한 방법으로는 과거(historic)의 구간 속도만으로 제시하기에는 어려움이 있기 때문에, 시간의 변화에 따른 장래의 최적 경로는 개별 구간에 대한 장래의 구간 속도를 예측해야만 가능하다. 그러므로, 장래 구간 속도 예측을 위한 적절한 모형의 개발이 시급하다고 하겠다.

따라서, 본 연구의 목적은 구간 속도를 예측하기 위한 각 기법들의 고찰을 통하여 구간 통행시간 예측과정을 도출하고 장래에 여행자들에게 실시간으로 주행 정보를 제공할 수 있는 가능성을 제시하고자 한다.

## 2. 연구의 내용

본 연구에서는 검지기의 위치특성 및 교통류 특성들을 고려한 구간 속도를 추정, 예측하여 구간 통행시간을 산출하는 과정을 연구하는 것을 목적으로 한다.

본 연구에서는 장래의 구간 속도 정보의 제공을 위해 시계열 분석, 신경망 이론, 평활법, 칼만필터링 기법 등의 고찰을 통해 예측기법간의 비교분석을 실시한다. 추후에는 예측기법간 비교, 분석을 통한 구간 속도의 예측과 현장자료를 이용한 구간 속도 및 통행시간 예측분석을 토대로 예측 기법 중 가장 불규칙적인 교통류의 변동에 대해 높은 예측력을 보이는 칼만필터링을 가지고 구간 속도를 예측하며 이를 토대로 여러 구간의 통행시간을 예측하고자 한다. 연구를 위한 공간적 범위로는 도시고속화도로인 서울 올림픽대로를 범위로 현재 설치되어있는 영상 검지기에서 올라오는 매분마다 차선별 교통량, 속도, 점유율을 가지고 자료를 구축한다. 또한, 시험차량 운행과 각 구간별 실측조사를 통해 통행시간 자료를 구축한다.

## II. 관련 연구 및 이론 고찰

### 1. 관련 연구 고찰

구간 속도 예측을 위한 기존 연구를 살펴보면, 통행시간 예측 연구는 분석구간을 몇 개의 구간으로 나누어 과거 각 구간을 주행하는데 걸린 시간이 현재에도 거의 동일하게 구현될 것이라는 가정 하에 이들 통행시간을 합산하여 추정하는 방식[1]이 연구되었는데 구간마다 검지기가 설치되어 있는 경우, 검지기로부터 관측되는 자료를 바탕으로 손쉽게 추정할 수 있는 장점이 있다. 이는 과거의 교통상황이 미래까지 지속되는 경우에 비교적 잘 맞는다고 할 수 있으나 실제로 변화가 많은 교통상황을 충분히 설명하지 못하는 단점이 있다. 이러한 단점을 보완하기 위해 보다 정밀한 예측기법의 적용에 관한 연구가 수행되었으며, 일반적으로 많이 사용하고 있는 시계열 분석기법을 적용한 경우와 최근 각광받고 있는 칼만필터링 기법, 신경망 이론 등을 이용한 통행시간 예측이 주류를 이루고 있다. 또한 최근에 이루어진 연구로서는 Box-Jenkins 유형의 시계열 자료의 분석을 들 수 있다.

칼만필터링에 관한 관련 연구 고찰을 살펴보면, 필터링(Filtering)이란 시계열에 있어서 의미가 있는 신호성분과 의미가 없는 잡음성분이 가산되어 있다고 생각하고 그 안의 잡음성분을 가급적 분리하여 의미 있는 신호성분만을 추출하는 것이다. 이때 신호가 잡음과 섞여 있을 경우 잡음을 약화시키면서 신호를 추출해 낼 수 있는 최적의 필터가 가지는 특징들로서는 어떤 것들이 있는지에 대한 의문이 생기게 되면서 필터링에 관한 연구가 시작되었다.

교통에서 칼만필터링은 상당한 정확성을 가지고 예측에 관하여 성공적으로 적용되어지고 있다[3]. 교통 부문에서의 칼만필터링은 주로 도시 간선도로망에서의 대기길이의 예측 및 O-D 매트릭스의 추정 등에서 사용되어져 왔으며 Iwao Okutani[2]는 연구의 목적에서 교통분야에 칼만필터링을 활용하는데 있으며, 관측된 링크의 교통량자료로부터 관측되지 않은 링크의 교통량을 예측, 추정하는 등 새로운 모델의 구현하였다.

### 2. 기존 기법의 이론적 고찰

#### 1) 시계열 분석

시계열(time series)은 시간대별 교통량이나 통행시간 등과 같이 특정 시점과 연계되어 있는 일련의 수치들로 이루어진 자료이며, 시계열 분석은 과거 시계열의 형태가 미래에도 같은 형태로 반복된다는 기본 가정 하에 각 관측치들 간의 상호관계를 밝히는 한편, 이를 바탕으로 모형을 설정하여 미래에 대해 예측하는 것이다. 시계열 분석의 가장 중요한 목적은 미래의 값을 예측하는 것

이며 이러한 예측은 교통분야 뿐만 아니라 다방면에 중요한 역할을 하고 있다.

시계열 모형을 이용한 예측은 시점  $t$ 까지의 시계열 데이터  $y_1, y_2, \dots, y_t$ 를 가지고  $k$ 시점 앞의 값  $y_{t+k}$ 를 예측하고자 하는 것으로 예측 범위에 따라서 전방 일단계예측(one step ahead forecast)과 전방 다단계예측(multi step ahead forecast) 등으로 구분할 수 있다.

예측에 적합한 ARIMA모형을 찾아내는 위해 다음과 같은 세 가지 단계인 식별(identification), 추정(estimate), 모형진단(diagnostic check)과정을 밟아야 한다.[7]

### 2) 신경망 이론(Artificial Neural Network)

본 연구에서 사용된 신경망 모형은 신경망 모형 중에서도 일반적으로 사용되고 있는 다층신경망(Multi-Layer Feedforward)을 사용하고 학습을 위한 학습 알고리즘으로는 각 입력패턴으로부터 네트워크가 계산한 출력값과 목표 값과의 오차를 최소화시키는 방향으로 네트워크의 연결강도를 조절하여 학습을 하는 역전파법(Backpropagation) 알고리즘을 사용하였다. 뉴런에서 출력값을 생성하는 전이함수로는 가장 일반화된 시그모이드(Sigmoid) 함수를 사용한다.

신경망 이론을 이용한 링크 통행속도를 추정 및 예측하는 네트워크의 구성은 다양한 경우를 실험을 통하여 네트워크를 결정하며, 입력층(input layer)과 출력층(output layer), 은닉층(hidden layer)으로 구성된 층간에는 완전연결(fully connected)의 형태로 갖추며, 이러한 구성은 다양한 구성들에 대한 평가를 통해 가장 유사한 결과치를 제공하는 것으로 구성한다.

### 3) 평활법(Smoothing)

평활화 기법은 Recursive Smoothing Algorithm을 이용하여 미래를 예측하는 것이다. 첫 번째로 단순이동평균법(Simple Moving Average)을 이용한 예측은 분석자의 이동평균할  $N$ 의 값을 시계열 패턴에 따라 사전에 정하며 만약, 새로운 시계열 관측값이 얻어지면 최근  $N$ 개의 시계열 관측값들 중 가장 오래된 관측값을 제외시키고 새로운 관측값을 포함시키게 된다. 단순이동평균법은 원시계열 자료의 산포가 불규칙하여 확률오차가 시계열에 많은 영향을 미친다고 판단되면  $N$ 을 큰 값을 사용해야 하는데 이는 확률오차에 의한 변동을 많이 평활시키는 효과를 가져오게 되므로 결국 수평에 가까운 예측선을 얻게 된다.

두 번째로 단순지수평활법(Simple Exponential Smoothing)을 이용한 예측은 이동평균법이 가지고 있는 자료보관상의 문제점과 최근  $N$ 개의 관측값에 대한 비중을 동일하게 놓고 예측을 한다는 단점을 보완한 정상 시계열 예측방법이다. 따라서 가장 최근의 구간 속도를 예측을 위한 구간 속도 계산에 비중있게 반영할 수 있는 점과 2개의 관측값만 가지면 예측을 할 수 있는 장점을 가지고 있다.

단순이동평균법(Simple Moving Average)과 단순지수평활법(Simple Exponential Smoothing)은 다음과 같다.

$$\hat{X}(t+1) = \frac{X(t) + X(t-1) + \dots + X(t-N+1)}{N}$$

$$\hat{X}(t+1) = \hat{X}(t) + \alpha(X(t) - \hat{X}(t))$$

여기서,  $\hat{X}(t)$  =  $t$ 시점에서의 평활화된 속도

$X(t)$  =  $t$ 시점에서의 원시 속도

$\alpha$  = 평활화 계수( $0 \leq \alpha \leq 1$ )

### 4) 칼만필터링(Kalman Filtering)

칼만필터링은 무작위 변동(random perturbation)을 발생시키는 동적 체계(dynamic system)에 적용되는 최적상태 예측과정으로써 이산적 실시간에 얻어진 잡음 섞인 정보로부터 동적 체계의 미지 상태에 대한 최적 예측을 위한 선형, 불편(unbiased), 최소오차분산(minimum error variance)의 특성을 지닌 반복적 알고리즘이다.

구간 속도와 같이 정상적이지만 불규칙성을 가지는 자료를 토대로 한 미래 구간 속도 예측에 적합한 예측기법이라 할 수 있다. 최근의 고도의 고성능 마이크로 프로세서의 발달로 칼만필터링은 매우 복잡한 실시간 처리 시스템에서도 점점 더 이용가치가 높아지고 있다. 칼만필터링의 가정은 기본적으로 아래의 가정을 만족하는 이산-선형시스템에서 상태변수를 추정하기 위해 만들어졌다. 따라서, 주어진 가정을 만족하지 않을 경우에는 적절한 과정을 통해 이산-선형의 형태로 수정하여 문제를 해결한다. 칼만필터링을 상태방정식과 관측방정식의 구성은 다음과 같다.

$$\text{state equation : } x_{k+1} = A_k x_k + w_k$$

$$\text{observation equation : } z_k = H_k x_k + v_k$$

여기서  $x_k$  : 시점  $k$ 에서의  $(n \times 1)$ 상태벡터

$A_k$  : 시점  $k$ 에서  $k+1$ 로의  $(n \times n)$ 전이행렬

- $w_k$  : 알려진 공분산을 가진  $(n \times 1)$ 의 백색순서(white sequence)로 구성 인자의 평균이 0이고 다른 변수와의 상관관계가 없는 벡터
- $z_k$  : 시점  $k$ 의  $(m \times 1)$ 관측벡터
- $H_k$  : 시점  $k$ 에서 관측 벡터와 상태 벡터를 연결시켜주는  $(m \times n)$ 벡터
- $v_k$  : 알려진 공분산을 가지고  $w_k$ 와 상관 관계가 없는  $(m \times 1)$ 관측오차

### III. 연구방법론 연구

#### 1. 연구 방법론의 설정

위의 관련 연구고찰과 기존 예측기법을 살펴볼 때 연구 방법론을 위한 예측기법으로는 구간 속도와 같이 정상적이지만 불규칙성을 가지는 자료에 적합한 칼만필터링을 통해 예측을 실시한다. 예측을 위한 공간적, 시간적 범위는 올림픽대교상의 검지기 #3과 #16의 자료를 토대로 1998년 6월 11일 (목) 오전 7시~11시까지 4시간 동안, 1분 간격의 검지기 속도를 예측한다.

기존 예측기법의 연구를 위해 아래와 같은 Historical Traffic Pattern의 구축한 후 기존 기법인 ARIMA 모형, 신경망 모형과 평활법을 가지고 1분 간격의 예측을 실시하며 각각의 예측 결과를 비교 분석한다. 또한, 칼만필터링을 통해 예측을 실시하고 기존 예측모형과 예측결과를 비교 분석한다. 칼만필터링 예측모형을 이용한 구간 속도의 예측과정은 다음의 과정을 통해 수행된다.

자료의 수집은 서울 올림픽대로의 공항방면 잠실대교에서 서울교까지의 8개 구간 중에서 반포대교에서 서울교 간의 검지기 #2, #4, #6의 1998년 6월 11일 자료를 통해 예측을 위한 검지기 자료를 통해 구축한다. 사례연구를 통한 구간 속도의 산출은 다음과 같은 과정을 통해 산출되어 각각의 검지기별 1분 간격의 예측값과 비교 분석한다.

검지기 #6(반포~동작대교 구간)에서 시점  $t$ 에서의 1분간격의 속도를 통해 통행시간  $k$ 를 산출한 뒤 다음 구간(동작~한강대교)에서 예측된  $(t+k)$ 시점에서 다주기 속도 예측을 통해 통행시간을 계산하고, 계산된 통행시간  $j$ 를 통해 다음 구간  $(t+k+j)$ 시점의 속도를 예측하여 반포~서울교 전 구간의 1분간격의 예측된 구간 속도를 산출한다. 1분 간격으로 예측된 구간 속도는 각 검지기별 해당 시점의 1분 간격 예측치와 비교분석을 실시한다. 기존 예측기법과 칼만필터링 모형의 예측을 위한 Historical Traffic Pattern은 다음과 같이 구축한다.

#### 2. Historical Traffic Pattern의 구축

위에서 언급한 기존 예측기법을 적용, 분석하기 위해 올림픽대로의 2개의 구간에 해당하는 검지기 #3과 #16의 과거 검지기 자료를 토대로 다음과 같은 Historical Traffic Pattern을 구축한다.

과거의 검지기 자료를 토대로, 결국 구하고자 하는 것은 Historical Link Travel Time Fluctuation Pattern이며 이 자료는 도출하고자 하는 모형에서의 실측치와 예측치 간의 시간차(time lag)를 감소시켜 줄 수 있을 것이다. Historical Traffic Pattern은 반드시 동일 올림픽대로 구간에 대해 장기간 동안 축적된 많은 양의 data를 통해 구축되어야 하며 날씨, 평일과 주말, 계절적인 교통류와 교통수요의 영향을 반영할 수 있는 Historical Traffic Pattern으로 구분되어야 한다. 특히, Historical Link Travel Time Fluctuation Pattern과 같은 Historical Traffic Pattern은 올림픽대로의 구간별 short-term prediction에 있어서 가장 중요한 요소중에 하나이다.

본 연구에서는 자료조사의 한계와 수집의 어려움으로 인해 다음과 같이 Historical Traffic Pattern 가정한후 이를 토대로 각 예측기법을 분석, 연구한다. 예측을 위한 검지기 자료로는 1998년 6월 11일 (목)의 07시부터 11시까지의 1분간격의 검지기 자료(검지기 #3, #16)를 기준으로 예측을 실시하고 Historical Traffic Pattern은 1998년 5월 28일 (목), 6월 9일 (화), 6월 10일 (수), 6월 11일 (목), 6월 18일 (목)의 자료를 가지고 동일 시간대, 4시간 동안의 각 검지기별(#3, #16) 1분 간격의 차로별 지점속여기서 구축된 Historical Traffic Pattern를 통해 시계열 분석에서는 Historical Traffic Pattern의 시계열 자료를 토대로 가장 적합한 시계열 모형을 각 검지기별로 찾아내는데 이용하며, 신경망 이론에서는 각 검지기별로 Historical Traffic Pattern을 가지고 신경망을 구축하며 칼만필터링에서는 상태벡터를 구성하는 요소가 된다. 또한, 평활법을 이용한 예측은 지수평활법에서 가장 예측력이 좋은 평활상수를 각 검지기별로 구한 후 이를 토대로 예측을 실시한다.

#### IV. 기존 예측기법의 결과 및 예측모형을 이용한 구간 속도예측

## 1. 기존 예측기법의 결과

### 1) 시계열 분석을 이용한 예측

각각의 Historical Traffic Pattern에서 검지기 속도 시계열자료를 토대로 예측을 위한 시계열 모형을 찾는다. 본 연구에서는 ARIMA모형을 이용하여 예측을 수행한다. 모형을 찾는 과정은 STATISTICA 통계 패키지를 이용하여 과정을 수행하였으며 검지기의 #3을 통해 모형의 식별, 모수의 추정 및 모형 진단 과정을 살펴보면 다음과 같다.

#### (1) 모형의 식별(model identification)

검지기 #3의 표본자기상관함수와 표본편자기상관함수를 살펴보면, 표본자기상관함수가 지속적으로 감소하고 있으므로 이 시계열은 정상성을 만족한다고 할 수 있다. 또, 시차가 커질수록 표본편자기상관함수가 지수적으로 감소하기 때문에 MA모형으로는 식별될 수 없으며 표본편자기함수의 그래프를 통해서 볼 때 시차 1에서는 상관이 크지만 시차 2이상일 때는 거의 상관이 없으므로 AR(1) 또는 AR(2) 모형으로 볼 수 있다.

#### (2) 모수의 추정(estimation)

각 검지기별 Historical Traffic Pattern의 적정 모형의 차수를 구한 결과 검지기 #3과 #16 모두 ARIMA(2,0,0)을 따른다. 시계열 모형식에서 검지기 #3의 모수 추정결과는 다음 [표 4-1]과 같다.

[표 4-1] 검지기 #3의 모수추정을 위한 STATISTICA 출력값

SINGLE-SERIES ARIMA RESULTS	
Variable: VAR1	<b>Model: (2, 0, 0)</b>
Estimation: Approximate Max. Likelihood Method (McLeod & Sales)	
No. Iterations: 10	
No. of obs.: 239	
Parameters (p/Ps=Autoregressive/seasonal, q/Qs=Moving average/seasonal)	
	p(1) p(2)
<b>Estimate:</b>	<b>.94674 .05286</b>
Std.Err.:	.06501 .06514

#### (3) 모형진단(diagnostic checking)

모형진단은 추정된 모형이 관찰된 시계열자료와 얼마나 잘 부합되는 지를 조사하는 과정이다. 모형진단 방법에는 잔차분석(residual analysis)와 과다적합화분석(overfitting analysis) 등이 있다.

잔차분석(residual analysis)방법에서 잔차가 실제값과 예측값의 차이이므로 모형의 식별이 올바르게 모수의 추정도 정확하다면 잔차 역시 백색잡음(white noise)과 같은 성질을 만족해야 한다. 따라서 잔차의 자기상관함수와 편자기상관함수의 그래프를 이용하여 잔차의 평균, 분포 그리고 독립성을 등을 살펴보아야 한다.

잔차에 대한 상관그램을 통해서 오차한계 내부에 존재하므로 평균이 0이고 독립적인 백색잡음이라 할 수 있다. 그러므로 도출된 본 모형은 유의함을 알 수 있다.

각 검지기별 도출된 ARIMA(2,0,0)의 모형식은 다음과 같다.

$$\text{검지기 \#3} : x_k = 0.94674 \times x_{k-1} + 0.05286 \times x_{k-2} + e_t$$

$$\text{검지기 \#16} : x_k = 0.97029 \times x_{k-1} + 0.02571 \times x_{k-2} + e_t$$

여기서,  $x_k$  : 시점( $k$ )의 속도

$x_{k-1}$  : 시점( $k-1$ )의 속도

$x_{k-2}$  : 시점( $k-2$ )의 속도

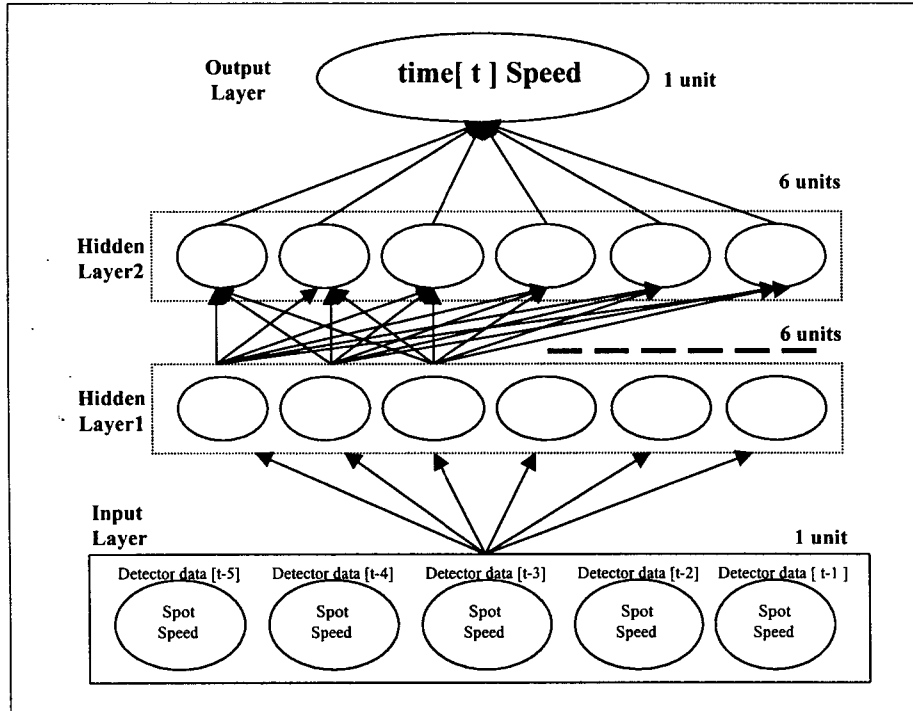
$e_t$  : 확률오차

### 2) 신경망 이론(Artificial Neural Network)을 이용한 예측

각 검지기별로 구축된 Historical Traffic Pattern을 통해 신경망 모형을 구축한다. 신경망의 구성은 다음 표와 같이 구성되며, 입력층은 1분후의 검지기 속도에 가장 큰 영향을 미치는 이전 5분

동안의 속도로 구성되고 출력층은 예측을 위한 다음 시점의 속도로 하여 두 개의 은닉층으로 구성하며 은닉층 unit의 수와 모멘텀 항(momentum term)<sup>1)</sup>의 값을 가지고 각 대안별 오차의 수렴과정을 거쳐 초기 값을 0.01로 한 Adaptive Learning Rate을 적용한 학습계수를 사용하여 신경망 모형을 구성하였다.

입력값을 검지기 #3과 #16의 속도자료를 실제 입력하여 6월 11일 오전 7시부터 11까지의 4시간 동안의 1분 간격의 속도를 예측을 실시한다. 다음 그림은 예측을 위한 신경망 모형의 구조를 도식화한 것이다. 다음의 [그림 4-1]은 신경망 모형의 구조를 보여주고 있으며 각 층간에는 완전연결(fully connected)되어 있다.



[그림 4-1] 신경망 모형의 구조

3) 평활법을 이용한 예측

각 검지기별 패턴데이터에서 지수평활예측에 있어서 가장 적합한 평활계수를 찾는다. 검지기 #3의 평활계수는 0.5이며, 검지기 #16의 평활계수는 0.9이다.

이를 토대로 6월 11일 오전 7시부터 11까지의 검지기 #3과 #16의 실제 관측치를 각 검지기별 평활계수를 사용하여 해당구간에 1분간격의 지점속도를 예측한다.

4) 각 예측기법별 예측결과 분석

시계열 분석, 신경망 모형과 평활법을 이용한 예측기법별 실측치와 예측치를 예측에러인 평균제곱오차(MSE), 평균절대상대오차(MARE), 등가계수(EC)<sup>2)</sup>를 가지고 비교 분석한 결과는 아래의 [표 4-2]와 같다.

1) 오차의 진동을 적게하고 수렴이 빨리 되도록 연결강도의 변화식에 첨가하는 항이다.

2) 다음과 같은 예측에러기준을 이용하여 비교한다.

$$e(t) = X(t) - \hat{X}(t) \text{ 일 때, } MARE = \frac{1}{m} \sum_{t=1}^m \frac{|e(t)|}{X(t)}, \quad MSE = \frac{1}{m} \sum_{t=1}^m e(t)^2$$


$$EC = 1 - \frac{\sqrt{\sum_{t=1}^m |e(t)|^2}}{\sqrt{\sum_{t=1}^m X(t)^2} + \sqrt{\sum_{t=1}^m \hat{X}(t)^2}}$$

※  $X(t)$ 는 observed value,  $\hat{X}(t)$ 는 predicted value을 나타낸다.


[표 4-2] 각 예측기법별 예측결과

Prediction method	no. of detector	MSE	MARE	EC
ARIMA(2,0,0)	detector#3	23.397	0.049	0.967
	detector #16	29.113	0.085	0.954
신경망 모형	detector#3	34.954	0.065	0.961
	detector #16	31.483	0.091	0.952
Exponential smoothing method	detector#3	26.180	0.049	0.966
	detector #16	28.847	0.085	0.955


위의 표에서 보는 것과 같이 ARIMA(2,0,0)모형이 가장 좋은 예측력을 보여줌을 알 수 있다. 다음의 [그림 4-2~7]은 시계열 분석, 신경망 모형 및 평활법을 이용한 예측에서 관측치와 예측치를 비교한 차트이다.




[그림 4-2] 검지기 #3의 ARIMA(2,0,0) 예측결과




[그림 4-3] 검지기 #3의 신경망 예측결과




[그림 4-4] 검지기 #3의 평활법 예측결과



[그림 4-5] 검지기 #16의 ARIMA(2,0,0) 예측결과



[그림 4-6] 검지기 #16의 신경망 예측결과



[그림 4-7] 검지기 #16의 평활법 예측결과


## 2. 칼만필터링을 이용한 모형의 결과

본 모형에서는 불규칙적인 교통류 상태의 반응에 가장 좋은 예측력을 보이는 칼만필터링을 가지고 예측을 실시하며, 위에서 언급했던 방법론으로 해당 검지기의 자료 및 주변 구간의 검지기 자료와 Historical Traffic Pattern 자료를 통해 상태 공간모형의 구축하여 보다 더 교통류 상태에 민감하게 반응할 수 있는 칼만필터링의 상태방정식과 관측방정식의 모형을 도출하고자 한다. 칼만필터링을 구성하는 상태방정식과 관측방정식은 다음과 같이 구성한다. 다음 상태에 대한 사전 예측치(priori estimate)는 예측을 위해 기존에 구축된 6월 11일 오전 7시~11시까지의 4시간 동안의 1분간격의 historical traffic pattern의 속도평균값으로, 초기 예측치에 대한 오차공분산은 historical traffic pattern의 속도자료의 분산을 초기값으로 설정한다. 위의 조건에 따라서 구축된 상태방정식과 관측방정식을 가지고 칼만필터링 알고리즘에 의해 검지기 #3과 #16의 속도 자료를 가지고 6월 11일 오전 7시부터 11까지의 4시간 동안의 1분 간격의 속도를 예측을 실시한다. 다음의 [표 4-3]은 기존 예측기법 중에서 가장 좋은 예측력을 보인 ARIMA 모형과 칼만필터링 모형을 예측된 예측결과의 비교를 보여 주고 있다. 모든 예측에러를 기준으로 비교할 때 칼만필터링 모형이 더 높은 예측력을 보여 주고 있다.

[표 4-3] 칼만필터링과 ARIMA(2,0,0) 모형의 예측력 비교


Prediction method	no. of detector	MSE	MARE	EC
ARIMA(2,0,0)	detector#3	23.391	0.049	0.967
	detector #16	29.118	0.086	0.954
칼만필터링 모형	detector#3	19.508	0.048	0.970
	detector #16	25.382	0.078	0.958

다음의 그림은 칼만필터링을 통한 예측결과를 실측치와 예측치를 서로 비교한 차트이다.



[그림 4-8] 검지기 #3의 칼만필터링 예측결과





[그림 4-9] 검지기 #16의 칼만필터링 예측결과

### 3. 구간 통행시간의 예측 결과 및 분석

위에서 도출된 칼만필터링 모형을 가지고 다주기 예측을 통해 여러 구간에 대한 구간 통행속도 및 구간 통행시간을 산출한다. 기존의 구간 통행속도 산출 방법인 현재 이전지점( $t-1$ )의 각 구간의 속도를 통해 계산된 대상 구간의 통행속도와 검지기 실측자료를 이용한 실제 통행속도의 실측치를 통해 각각 비교 분석한다.


구간 통행속도를 예측하기 위한 구간은 올림픽대로의 반포대교~서울교 구간으로 반포~동작, 동작~한강, 한강~서울교 구간으로 3 구간으로 구성되며 각 구간별 검지기는 #6, #4, #2의 자료를 이용한다. 검지기 #6(반포~동작대교 구간)에서 시점  $t$ 에서 예측된 속도를 통해 통행시간  $k$ 를 산출한 뒤 다음 구간(동작~한강대교)에서 모형에서 도출된 다주기 예측된  $(t+k)$ 시점에서 속도 예측을 통해 통행시간을 계산하고, 계산된 통행시간  $j$ 를 통해 다음 구간  $(t+k+j)$ 시점의 다주기 통행속도 예측을 통하여 반포~서울교 전 구간의 1분간격의 예측된 구간 통행시간을 산출한다. 1분 간격으로 예측된 구간 통행시간은 검지기 실측자료를 통해 조사된 구간 통행속도 자료와 비교분석을 실시한다. 또한 기존의 방법으로 구간 통행속도를 산정하고 동일하게 검지기 실측자료를 통해 조사된 구간 통행속도 자료와 비교분석을 실시한다. 산출된 두가지의 구간 통행속도를 각각 검지기 실측자료에 대해 MSE를 통해 비교 분석한다.

각 구간에 대한 예측모형은 위에서 가장 좋은 예측력을 보인 칼만필터링을 이용하여 다주기 예측을 실시하였으며 실측 검지기 자료에 대해 기존 구간 통행속도 산출방법과 다주기 예측을 통한 구간 통행속도 산출방법의 MSE를 이용한 예측력 비교는 다음 [표 4-4]이며 구간 통행속도의 결과는 [그림 4-10]과 같다.

표에서 처럼 기존 방법보다 다주기 예측을 통한 구간 통행속도 산출방법이 더 좋은 예측력을 보여줌을 볼 수 있다.

[표 4-4] 구간 통행속도 예측에 대한 MSE 비교결과

구간 통행속도 산출방법	반포~동작대교 구간 (#6)	동작~한강대교 구간 (#4)	한강~서울교 구간 (#2)
기존 방법을 이용한 구간 통행속도 산출	17.67	37.97	63.73
다주기 예측을 통한 구간 통행속도 산출	12.31	31.67	44.53



[그림 4-10] 반포~서울교 구간 통행속도 예측결과의 비교

## V. 결론

결과를 살펴보면 신경망을 제외한 시계열 분석, 칼만필터링 및 평활법 등 모두 MARE, MSE, EC 로 비교, 평가하여 볼 때, 모두 양호한 결과를 보여준다. 특히, 칼만필터링을 이용한 모형이 가장 좋은 결과를 보여 줌을 알 수 있다. 위의 연구를 토대로 교통류의 흐름이 정상적인 상태 일 때는 과거의 Historical Traffic Flow Pattern의 구축을 통한 정보의 이용이 필요하며, 통행시간 예측을 위한 알고리즘을 개발하는데 있어 본 연구에서 제안된 여러 검지기 자료를 이용한 예측이외에도 주변 구간의 교통류 상태를 반영할 수 있는 모형이 계속적으로 연구되어야 할 것이다.

본 모형의 다주기 예측을 통한 구간 통행속도의 예측이 기존 구간 통행 속도 예측보다 더 나은 예측력을 보여 주었으며, 구간 통행속도 예측에 있어서 더 나은 예측 결과를 얻기 위해서는 칼만 필터링 모형의 보완 작업과 다주기 예측에 대한 신뢰성 검정 작업이 요구되며 추후 연구과제로 예측을 위한 검지기의 속도를 2, 3차선의 평균 속도를 이용하여 구간 통행속도 예측을 실시하고 동일 검지기 자료에서 교통량과 점유율을 이용한 구간통행시간의 예측이 요구된다고 하겠다. 또한, 적용 구간의 범위를 확대하여 적용하는 것이 추후 연구로 진행해야 할 것이며 해당 구간의 기하구조, 진출입램프 및 검지기 설치위치와 검지기 간의 간격 등을 고려한 연구가 필요하다.

### 참고문헌

- [1] Iwasaki, Masato, A Short Term Prediction Of Traffic Fluctuations Using Pseudo-Traffic Patterns, ITS WORLD CONGRESS 96
- [2] Iwao Okutani, Yorgos J. Stephanedes, Dynamic Prediction Of Traffic Volume Through Kalman Filtering Theory, Transportation Research, 1984
- [3] Iwao Okutani, The Kalman Filtering Approaches In Some Transportation, And Traffic Problem Transportation & Traffic Theory, 1987
- [4] Mohinder S. Grewal, Angus P. Andrews, Kalman Filtering Theory and Practice, Prentice Hall, 1993.
- [5] D.J. Dailey, A Statistical Algorithm For Estimation Speed From Single Loop Volume And Occupancy Measurements, The Federal Highway Administration & Univ. Of Washington 1995
- [6] 이광훈, 신성일, 실시간 교통정보제공을 위한 여행시간 추정기법의 개발, 도로교통 안전협회, 1993
- [7] 김연형, 시계열분석과 예측, 자유아카데미, 서울, 1990