

■ 論 文 ■

웨이브렛 변환과 RBF 신경망을 이용한 경로통행시간 예측모형 개발 -시내버스 노선운행시간을 중심으로-

Development of path travel time forecasting model using wavelet transformation and RBF neural network

신승원

(상명대학교 인공지능기술연구소)

노정현

(한양대학교 도시공학과 교수)

목 차

- | | |
|---|--|
| I. 서론
II. 웨이브렛과 신경망 모형 소개
1. 자료수집 방법
2. 웨이브렛 변환
3. 신경망 예측모형 | III. 패턴분석 및 통행시간 예측
1. 통행시간 패턴 분석
2. 예측모형 정립 및 통행시간 예측
IV. 결론 및 토의
참고문헌
부록 : WT-RBFN 예측결과 |
|---|--|
-

요 약

본 연구에서는 도시 가로망에서의 구간 통행시간을 예측하기 위하여 time-frequency 분석의 일종인 웨이브렛 변환과 RBF신경망 모형을 이용한 예측모형을 개발하였다.

웨이브렛 변환을 이용한 시계열 자료 분석을 통해서 통행시간에 내재되어 있는 다양한 패턴의 특징을 추출함으로써 오전/오후의 첨두현상, 신호교차로의 현시주기 등 주기적으로 발생되는 요인들에 의해서 통행시간 시계열 자료의 패턴에 나타나는 규칙성을 분석해내었다. 분석된 패턴정보에 대한 규명은 카오스 이론을 근간으로 한 시간지연좌표를 이용하여 시계열 자료의 규칙성을 시각적으로 판별하여 예측모형 구축에 활용하도록 하였다.

또, RBF 신경망을 이용하여 예측범위의 공간적/시간적 확대에 따른 모형 구축에 소요되는 시간을 최소화하도록 하였으며, 시내버스 노선의 정류장간 운행시간 예측을 통해서 기존 연구에서 제기되었던 현실세계의 단순화, 다단계 예측시 정확성 등의 문제를 해결하였다.

예측실험결과 웨이브렛 변환을 데이터의 전처리 과정에 삽입하여 링크 통행시간의 패턴정보 예측에 활용할 경우, 기존의 예측모형에 비해서 훨씬 정확한 예측이 가능한 것으로 나타났으며, RBF 신경망은 짧은 학습시간에도 불구하고 역전파 신경망보다 우수한 예측력을 갖고 있는 것으로 밝혀졌다.

I. 서론

ITS의 일환으로 구축되는 대부분의 교통정보시스템은 실시간 자료수집과정과 장래 교통상황을 예측하는 과정을 포함한다. 실시간 교통정보 수집과정에서는 10분 이내의 이산간격 단위로 통행량이나 통행시간과 같은 실시간 현장정보(detected data)와 교통전문가들의 경험적 지식(anecdotal evidence)을 수집하며, 예측단계는 자료수집단계에서 수집된 정보를 토대로 최종 교통정보를 산출하기 위한 장래 통행패턴을 제시하는 역할을 한다. 이처럼 예측은 원시 수집정보와 통행자에게 최종적으로 제공되는 교통정보의 중간 매개체로서 교통정보의 신뢰도를 결정짓는 매우 정교한 기술을 요하는 단계라 하겠다.

그러나, 대도시에서 구간이나 경로 통행시간을 짧은 이산간격 단위로 예측하는 일은 쉽지 않다. 그 이유는 계측간격이 짧을수록 통행시간이나 통행량과 같은 교통변수는 주변 교통여건의 변화에 민감하게 반응하여 패턴이 불규칙하게 나타나기 때문이다. 또 다른 이유는 통행자가 원하는 정보를 산출하기 위해서는 광범위한 교통망에 대한 예측이 필요하기 때문에 정확한 예측력과 계산량(computation time)을 극복할 수 있는 모형이 필요하기 때문이다. 마지막으로, 단일 링크나 단일 교차로에 대한 예측이 아닌 전체 도시 교통망에 대한 예측을 실현하기 위해서는 많은 경험과 효율적인 시스템의 운영이 요구된다.

이처럼 교통에서 예측을 실현시키기 위해서는 여러 문제를 극복해야 할뿐더러 설령 이러한 문제를 해결하였다고 하더라도, 예측이 전체 시스템 향상에 기여하지 못하는 경우가 빈번히 발생하기도 한다.

이러한 여건 속에서도 예측에 대한 연구는 국내외에서 계속 진행되었으며 최근에 들어 예측분야에 변화를 가져오는 새로운 패러다임이 등장하였다. 즉, 확률론에 근거한 ARIMA나 Box-Jenkins, Kalman Filtering 등의 예측모형에서 신경망과 퍼지이론과 같은 인공지능기법과 카오스 이론을 동반하는 예측모형 개발이 이루어 진 것이다^{1,2,3,4)}.

최근 수년간에 걸쳐 신경망과 퍼지모형의 적용은 정확성, 다양한 정보의 활용, 불규칙성에 대한 새로운 패러다임 등 실험적인 측면에서 매우 성공적인 성과

를 거두었다. 정확한 패턴인식이 가능한 신경망과 다양한 정보를 응용할 수 있는 퍼지이론은 패턴이 불규칙하고 비선형 특징을 지니기 때문에 예측이 불가능할 것이라는 교통변수를 예측함으로써 기존 예측모형의 한계를 극복할 수 있게 하였다. 즉, 기존의 분석으로는 쉽게 무시되어온 잠재된 패턴에 대한 규칙을 밝혀낼 수 있게 된 것이다. 또, 선행 연구¹⁾에서 밝혀진 바와 같이 신경망 모형은 타예측모형에 비해서 비선형 패턴 특성을 띠는 시스템의 예측에 매우 적합한 것으로 밝혀진바 있으며 교통의 통행패턴 역시 비선형 또는 카오스계의 특성을 지닌 것으로 알려져 있다.

본 연구에서는 패턴분석을 통하여 시계열 자료에 내재되어 있는 규칙성을 규명하고, 규명된 패턴정보를 바탕으로 예측모형을 개발하기 위하여 time-frequency 분석의 일종인 웨이브렛 변환(wavelet transform)과 학습시간이 비교적 짧으면서 다른 신경망 모형과 비슷한 예측력을 갖고 있는 RBF 신경망(Radial Basis Function Neural Network, 이하 RBFN이라 함)을 사용한다.

또한 지금까지 연구를 보면, 하나의 링크를 대상으로 한 통행시간이나 통행량을 예측하는 단순한 상황에 국한되어 현실 문제를 지나치게 단순화시키는 경향이 있다. 이렇게 문제를 단순화하여 실험할 경우에 실제 현장에서 부딪히는 문제들을 놓치기 쉽고 모의 실험 결과에 대한 신뢰도가 현저하게 떨어지는 문제점이 발생한다. 현실문제의 단순화 중에서 가장 큰 문제점은 지금까지 예측모형 평가시 단일시점(one-step-ahead) 예측결과를 이용했다는 점이다.

단일시점 예측은 현재시점에서 바로 다음시점을 예측하는 기법으로서, 동적 경로안내시스템과 같이 여행경로를 동적으로 결정하기 위해서는 현재 위치 및 현재 시점에서 각 링크의 예상 주행시간을 해당 경로를 여행하게 될 미래시점을 기준으로 예측해야 하므로 만약 5분 단위로 정보가 갱신되고 현재 A지점에서 B지점까지 20분이 소요된다면 four-step ahead의 예측이 이루어져야만 한다.

따라서, 장래 경로시간의 추정과 같이 예측의 공간범위가 증가하게 되면 예측시간도 그만큼 증가되기 때문에 앞서 언급한 바와 같이 단일 링크나 교차로를 대상으로 하는 실험에는 one-step ahead 예측이 적합하지만, 여러 개의 링크와 교차로를 대상으로 상호정보가 복합

적으로 요구되는 실험에는 부적합하다. 본 연구에서는 이와 같은 문제를 해결하기 위하여 서울시 시내버스의 노선운행시간 데이터를 활용하여 여러 개의 링크로 구성된 각 구간 통행시간을 예측하는 실험을 하도록 한다.

II. 통행패턴분석 방법 및 예측모형

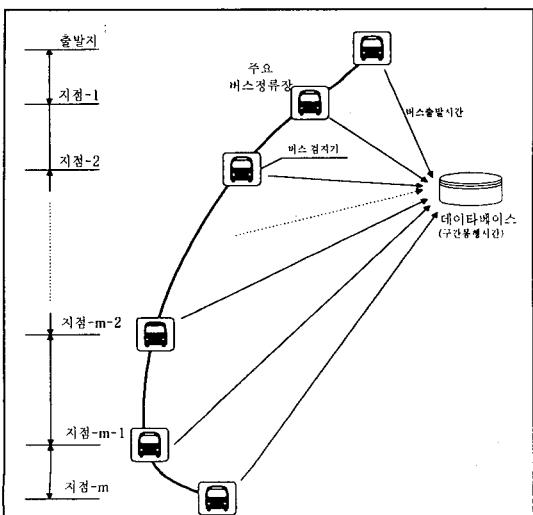
1. 자료 수집 방법

본 연구를 위해서 사용된 자료는 한국타코시스템에서 버스노선을 따라 설치한 타코시스템으로부터 수집된 15개 지점의 버스출발시간과 도착시간을 이용하였다. 연구의 목적상 계측간격을 5분단위, 8개구간으로 변환하여 사용하였다.

총 4개월의 시계열 자료중에서 통행패턴 분석과 모형정립에 3개월간의 자료를 이용하고 예측실험에 1개 월간의 자료를 사용하도록 한다. 또, 3개 버스 노선중에서 일치되는 구간만을 선정하여 5분 단위의 구간통행시간 시계열 자료를 구축하였으며, 각 구간별 평균 통행시간은 <표 1>과 같다.

<표 1> 각 구간별 평균 통행시간

s1	s2	s3	s4	s5	s6	s7	s8
5.2	9.5	14.2	17.8	19.2	24.3	27.4	31.1



<그림 1> 구간통행시간 계측과정(m=15)

<그림 1>은 본 연구에 활용된 시계열 자료의 계측 과정을 개략적으로 보여주고 있다.

2. 웨이브렛 변환

교통계는 정태적인 특성보다는 동태적인 특징을 갖고 있으며 계측간격이 짧을수록 심한 불규칙파동이 나타나게 된다. 즉, 패턴양상을 찾기 어려울 정도로 불규칙성이 심하기 때문에 흔히 무작위(random) 또는 노이즈(noise)로 해석되는 패턴이 잠재되어 있다. 이와 같은 패턴은 예측모형으로도 예측이 불가능할뿐더러 오히려 예측력을 약화시키는 원인이 된다⁵⁾. 본 연구에서는 시계열 자료 패턴에 포함되어 있는 이러한 미세한 값들이 예측에 큰 영향을 끼친다고 판단하여 이들의 특성을 분석하는 방법으로 웨이브렛 이론을 적용하고자 한다.

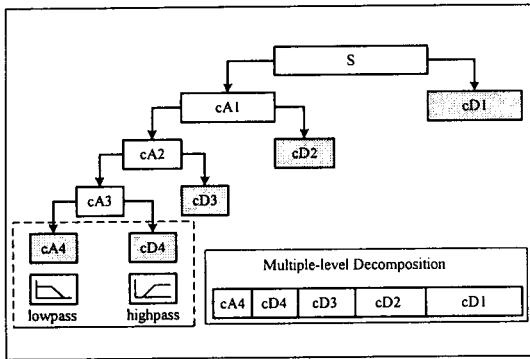
웨이브렛 이론의 배경은 주어진 신호를 직교성을 가지고 있는 웨이브렛들을 적용하여 분해할 수 있다는 것이다. 이는 분석하고자 하는 신호 $x(t)$ 를 그 특성에 따라 완전하게 표현할 수 있음을 의미하며, 직교벡터공간에서의 웨이브렛을 변화시킴에 따라서 다양한 크기와 해상도로 $x(t)$ 에 포함되어 있는 성분들을 나타낼 수 있게 된다. 이러한 원리로부터 다중해상도 신호분할 알고리듬이 수립되었으며, 이는 신호의 성분을 단계별로 더욱 세밀하게 표현하는 웨이브렛을 만들어서 적용하는 과정을 거치게 된다. 즉, 2^j 만큼 확장된 식(1)에 있는 이산 웨이브렛 함수 $\Psi_2^j(t)$ 를 시간축에서 2^{jn} 만큼 천이시키고, $\sqrt{2^j}$ 로 정규화 함으로써

$$\sqrt{2^j} \Psi_2^j (t-2^{jn}) \quad (1)$$

의 정규직교 웨이브렛이 구성된다^{6,7,8)}.

다중해상도 웨이브렛 변환(multiresolution wavelet transformation, 이하 MRWT)은 웨이브렛 함수를 정규직교기저에서 적용함으로써 주어진 신호의 특성을 분해하여 나타내는 알고리듬이다. 즉, j 를 0부터 $-J$ 까지 적용하여, 해석하고자하는 신호의 근사(approximation) 성분 $A(j)$ 와 세부(detail) 성분 $D(j)$ 로 나누어 나가는 것이다. 나누어진 성분들은 단계적으로 연속되는 더욱 세밀한 크기와 해상도를 갖게 되는데, 이

는 j 값의 변화에 따라서 세부성분은 감소되고, 근사성분들은 계속 유지된다고 볼 수 있는 것이다. 그리고, 이러한 과정을 주파수영역의 관점에서 보면, 근사성분은 저역필터를 통과한 신호들이 되고, 세부성분은 고역필터를 통과한 신호들로 나타나게 됨을 알 수 있다. <그림 2>에 MRWT를 적용하였을 때 신호가 분해되는 과정이 도식적으로 나타나 있다.



<그림 2> MRWT를 이용한 신호의 분할 과정

$$\phi(n) = \sum_{k=0}^N g(k) \phi(2n - k) \quad (2)$$

$$\Psi(n) = \sum_{k=0}^N h(k) \phi(2n - k)$$

식(2)에서 $g(n)$ 과 $h(n)$ 은 scaling과 웨이브렛 필터계수를 나타낸다(<그림 3>). 이때 주어진 이산 신호 $x(n)$ 을 $j=0$ 일 때의 scaling 함수에 적용하면,

$$x(n) = \sum_{k=0}^N a^k \phi(n-k) \quad (3)$$

가 된다. 그리고 식(3)의 $x(n)$ 을 다시 $j=1$ 일 경우에 적용하면

$$x(n) = A_{2^j}[x(n)] + D_{2^j}[x(n)] \quad (4)$$

으로 표현된다. 이때 $A_{2^j}[x(n)]$ 은 $j=1$ 일 때의 근사성분을 나타내며, $D_{2^j}[x(n)]$ 은 $j=1$ 일 때의 세부성분으로서 원래의 신호 $x(n)$ 과 근사신호 $A_{2^j}[x(n)]$ 과의 차이라고 할 수 있다. 또한, 근사신호 $A_{2^j}[x(n)]$ 과 세부신호 $D_{2^j}[x(n)]$ 은 아래와 같이 전개 될 수도 있다. 즉,

$$A_{2^j}[x(n)] = \sum_{k=0}^N a_{2^j}(k) \phi_2(n - 2k) \quad (5)$$

$$D_{2^j}[x(n)] = \sum_{k=0}^N d_{2^j}(k) \Psi_2(n - 2k)$$

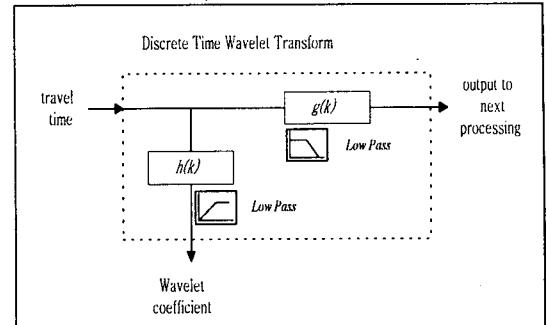
로서 $\phi_2(n - 2k)$ 와 $\Psi_2(n - 2k)$ 는 $j=1$ 일 때의 scaling 수열과 분석 웨이브렛을 의미한다. 결국, j 값이 변화함에 따른 주어진 신호 $x(n)$ 의 분해과정은 $j = \log_2 N$ (N 은 $x(n)$ 의 데이터 수) 일 때까지 반복되며,

$$A_{2^{j-1}}[x(n)] = A_{2^j}[x(n)] + D_{2^j}[x(n)] \quad (6)$$

$$= \sum_{k=0}^N d_{2^j}(k) \Psi_{2^j}(n - 2^{j-1}k)$$

로 나타낼 수 있다.

이때 $a_{2^j}(n) = g(n) * a_{2^{j-1}}(n)$ 이고, $d_{2^j}(n) = g(n) * a_{2^{j-1}}(n)$ 으로 정의된다. 이상에 언급된 내용을 요약하면, 웨이브렛 변환은 주어진 신호를 각 scale에서 근사 및 세부성분으로 분해하는 과정이다. scale j 에서의 세부성분은 scale $(j-1)$ 에서의 근사신호와 웨이브렛 필터계수 $h(n)$ 을 상승적분함으로서 구할 수 있고, scale j 에서의 근사성분은 scale $(j-1)$ 에서의 근사신호와 scale 필터계수 $g(n)$ 을 상승적분 함으로서 계산되어진다^{4,5,6)}.



<그림 3> 이산웨이브렛을 이용한 패턴분석과정

본 실험에서는 기저 웨이브렛 함수로서 Daubechies 함수를 사용하였다. 수집된 통행시간 시계열 자료에 대하여 MRWT를 적용하였으며, 이때 신호의 분활은 네 단계로 나누어서 실시하였다. 즉, 최초의 자료는 저역통과필터를 통과한 근사신호(cA1)와 고역통과필터를 통과한 세부신호(cD1)로 분활된다. 그리고, cA1

은 다시 차단주파수가 변경된 저역, 고역통과필터를 거쳐서 cA2와 cD2로 분할되며, 이러한 과정을 반복 실행하여 4개 대역의 신호들로 나타나게 된다. 결국, 앞서 언급된 네 종류의 웨이브렛 함수를 이용한 통행시간 패턴의 웨이브렛 변환을 통해 분할된 신호들은 고역필터를 통과한 cD1, cD2, cD3, cD4의 값들과 저역필터를 통과한 cA1, cA2, cA3, cA4으로 저장되었다. 본 연구에서는 분할되어진 detail성분인 cD1~cD4 값들과 approximation성분인 cA4을 이용하여 통행시간 예측을 위하여 사용되게 된다.

MRWT를 위한 프로그램은 Matlab 4.2c1과 웨이브렛 Toolbox를 사용하였다.

2. 신경망 예측모형

본 연구에서 제안하고자 하는 예측모형은 RBFN을 이용한 방법이나 지금까지 RBFN과 여타 신경망 모형과 예측력의 비교평가 모형이 충분히 다루어 지고 있지 않았기 때문에 역전파 신경망(Backpropagation Neural Network, 이하 BPN이라 함)의 예측실험을 병행하여 예측결과를 비교하여 모형 검증을 실시하도록 한다.

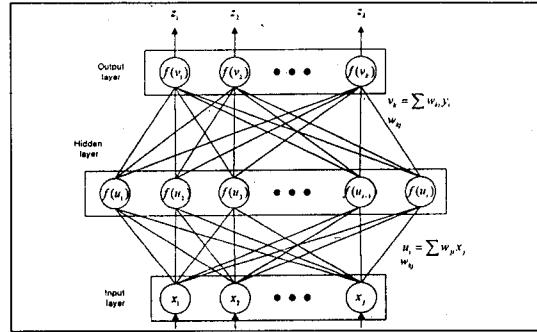
본 연구에서 신경망 모형은 MATLAB의 신경망 Toolbox와 C 프로그램을 이용하여 프로그램하였다.

1) 역전파 신경망(BPN)

BPN은 일반화된 델타규칙을 학습알고리듬으로 사용하는 신경망으로 입력층의 각 뉴런에 입력패턴을 주면, 이 신호는 각 뉴런에서 변환되어 중간층에 전달되고, 마지막으로 출력층 뉴런에서 신호를 출력하게 된다. 이 출력값과 기대값을 비교하여 오차를 감소시키는 방향으로 연결강도를 조절하게 된다. 즉, 오차가 상위층에서 하위층으로 역전파되어 오차를 발생시키는 정도에 따라서 뉴런간의 연결강도를 조정하게 된다⁹⁾.

그러나 BPN은 최소자승오차를 최소화하기 위하여 weight decay 알고리듬을 이용하여 연결강도를 조절해 나가기 때문에 일반 직렬형 컴퓨터에서는 학습시간이 매우 오래 걸린다는 난점을 지니고 있다.

BPN의 은닉층과 출력층 뉴런에서 활성화되어 출력되는 값은 다음 식과 같다.



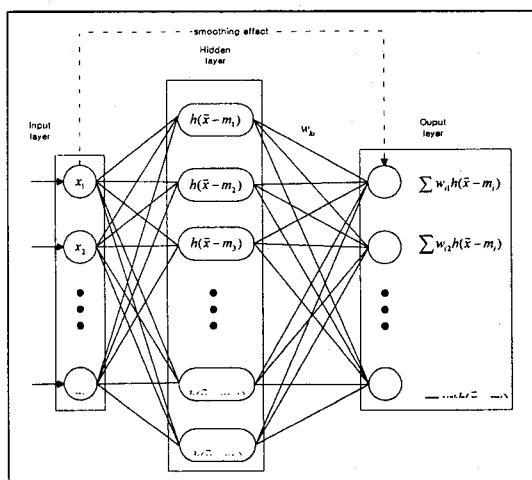
〈그림 4〉 BPN(입력뉴런 j, 은닉뉴런 i, 출력뉴런 k)

$$y_i = \sum_{j=0}^N w_{ij} x_j + \sum_{j=0}^N b_i \quad (7)$$

여기서, y_i 는 i 뉴런의 출력값, x_j 는 입력값, w_{ij} 는 i 뉴런과 j 뉴런과의 연결강도를, b_i 는 i 뉴런의 모멘텀 항을 각각 의미한다.

2) RBF 신경망(RBFN)

RBFN은 입력층과 은닉층이 선형으로 연결되어 있기 때문에 수학적으로는 은닉층과 출력층만으로 구성된 단층 신경망이라고 볼 수 있다. 이처럼 RBFN의 구조가 간결하기 때문에 수학적 표현이 명료하고, 여타의 신경망이 학습알고리듬으로 사용하는 weight decay 방법과 같은 반복적이고 시간소모적인 방법 대신에 역행렬법(Inverse Matrix)을 이용할 수 있기 때문에 연산속도가 매우 빠른 장점을 갖고 있다^{10,11)}.



〈그림 5〉 RBFN(파선은 smoothing effect : λ_i)

<그림 5>는 가장 일반적인 RBFN의 구조를 도식화 한 것이다. 입력층은 단지 은닉층으로 입력패턴을 전달하는 역할만을 하기 때문에, 모든 연결강도값은 1이다. 은닉층의 활성화함수는 RBF(Radial Basis Function)를 이용하고 은닉층 뉴런의 활성화값과 연결강도 w_j 를 곱하여 선형적으로 합한 값을 최종적으로 출력하게 된다.

$$f(\vec{x}_i) = \sum_{j=1}^m w_j h(|\vec{x}_i - \vec{m}_j|) \quad (8)$$

여기서, h (hidden layer 활성화 함수)는 RBF함수를, \vec{m}_j 는 RBF의 중심을, w_j 는 연결강도를 각각 의미한다. RBFN에서 활성화 함수로 사용하는 h 는 중심 m_j 에서 멀어질수록 단조증거나 또는 단조감소하는 특징을 갖는다. 이같은 RBF로는 Gaussian function, Multiquadratic function, Cauchy function 등이 있다.

Gaussian function

$$h(\vec{x}, \vec{m}) = \exp\left(-\frac{(\vec{x} - \vec{m})^2}{\beta_j^2}\right) \quad (9)$$

Multiquadric function

$$h(\vec{x}, \vec{m}) = \frac{c_j}{\sqrt{(\vec{x} - \vec{m})^2 + c_j^2}}$$

RBFN의 학습은 BPN의 학습원리와 마찬가지로, 예측오차의 합을 최소화하는 연결강도를 찾는 방법을 사용한다. 즉 \hat{C} 를 최소화하는 최적 연결강도값을 찾는다.

$$\hat{C} = \sum_{i=1}^N (y_i - f(\vec{x}_i))^2 + \lambda \sum_{j=1}^m w_j \quad (10)$$

위 오차함수 \hat{C} 의 첫 번째 부분(합계부분)은 근사추정의 총오차값을 최소화하기 위한 조건을 의미한다. 두 번째 부분 ($\lambda \sum_{j=1}^m w_j$)은 지나친 overfitting현상을 없애기 위한 조건이다. 이때, λ 을 Smoothing effect라고 하며, 이 값이 1에 가까울수록 패턴변화에 민감하게 학습하게 되고, 0에 가까울수록 근사적인 학습이 이루어지게 된다¹⁰⁾.

본 연구의 예측결과에 대한 검증은 평균제곱오차

(MSE:Mean Square Error), 평균절대상대오차(MAPE:Mean Absolute Percentage Error)를 평가항목(MOE:Measure of Effectiveness)으로 활용한다.

$$MSE = \frac{1}{N} \sum_t (x(t) - \hat{x}(t))^2$$

$$MAPE = \frac{1}{N} \left(\sum_t \frac{|x(t) - \hat{x}(t)|}{x(t)} \times 100 \right)$$

x : 목표값 \hat{x} : 모형 예측값

III. 패턴분석 및 통행시간 예측

1. 연구의 전제조건

본 논문에서는 다음과 같은 기본 가정하에 예측실험을 실시하도록 한다.

첫째, 노선버스의 운행정보를 기반으로 실험을 하였기 때문에 예측에 활용된 정보는 버스가 운행되는 05:00부터 22:00까지의 시간대를 그 대상으로 한다. 또, 요일은 배차간격이 길어지는 공휴일과 토요일은 제외한다.

둘째, 버스의 배차간격은 최소 3분에서 최대 10분으로 편차가 심하기 때문에 3개의 노선에서 얻어지는 정보를 5분 단위의 시계열 데이터로 변환하여 활용한다.

셋째, 일반적인 교통상황에서의 구간통행시간 예측으로 유고상황은 제외하도록 한다.

넷째, 버스의 고장, 사고로 인한 회차정보는 제외한다.

다섯째, 패턴분석으로 분류된 백색잡음은 예측에서 제외하도록 한다.

여섯째, 구축된 시계열 데이터를 통해서 예측실험을 할 경우에는 현재 실시간으로 정보가 수집되고 있는 것으로 설정하고 예측하도록 한다. 따라서, 구간통행시간의 예측은 5분 단위로 생성되는 교통정보를 근간으로 한다.

2. 통행시간 패턴 분석

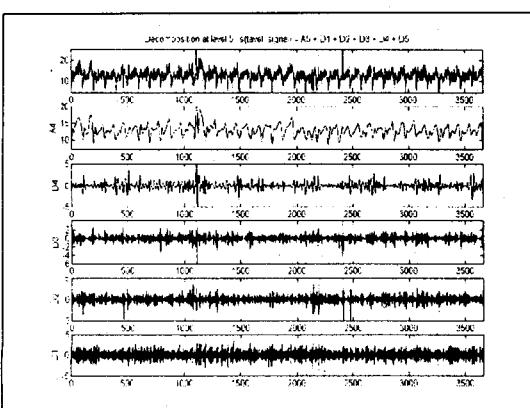
링크의 통행시간 및 구간 통행시간은 매크로하게는 도시민의 1일 생활패턴, 기후, 도로의 연장길이 등

에 영향을 받고 마이크로한 관점에서는 신호등의 주기 및 연동여부, 차량특성, 운전자의 행태, 도로주변 시설물 등에 영향을 받는다. 따라서, 1일동안 구간통행시간을 일정간격으로 계속 측정하게 되면 도시통행 특성인 오전/오후 첨두현상을 골격과 주기적인 불규칙 패턴을 관찰할 수 있게 된다.

지금까지 통행시간 및 통행량에 대한 교통패턴에 대한 연구는 매크로한 관점에서 이루어져 왔기 때문에 통행시간에 미치는 마이크로한 요인들은 불규칙한 랜덤현상으로 치부되어 왔다. 그러나 불규칙 패턴을 유발하는 요인들 역시 일정한 패턴을 갖고 발생할 수 있음을 간과하고서는 정확한 예측은 불가능하다. 즉, 신호등의 주기가 연동이 된 경우에 신호주기에 따라 링크 통행시간은 일정시간의 편차를 갖고 변하게 되는 것이다.

따라서, 본 연구에서는 웨이브렛 기법을 이용하여 규칙적인 통행패턴을 찾아내고, 패턴의 주기별로 예측하는 방법을 이용하고자 시계열 자료를 이산 웨이브렛 변환을 통해서 cA4, cD1, cD2, cD3, cD4 등 5개의 신호패턴을 분류하였다. 이때 각 신호패턴은 통행시간속에 용해되어 있던 특성을 의미하게 된다. 즉, 1일을 주기로 변하는 통행패턴, 시간주기로 발생하는 패턴, 신호등 주기에 따라 변하는 패턴에 이르기 규칙적인 패턴과 관측시의 오차 및 이상적인 현상으로 발생되는 예측이 불가능한 백색잡음을 찾아 내게 된다.

〈그림 6〉은 본 연구에서 실험대상으로 사용하고 있는 8개 구간중에 s1구간 통행시간 자료를 패턴분류한 결과이다.



〈그림 6〉 통행시간의 이산웨이브렛변환 해석결과

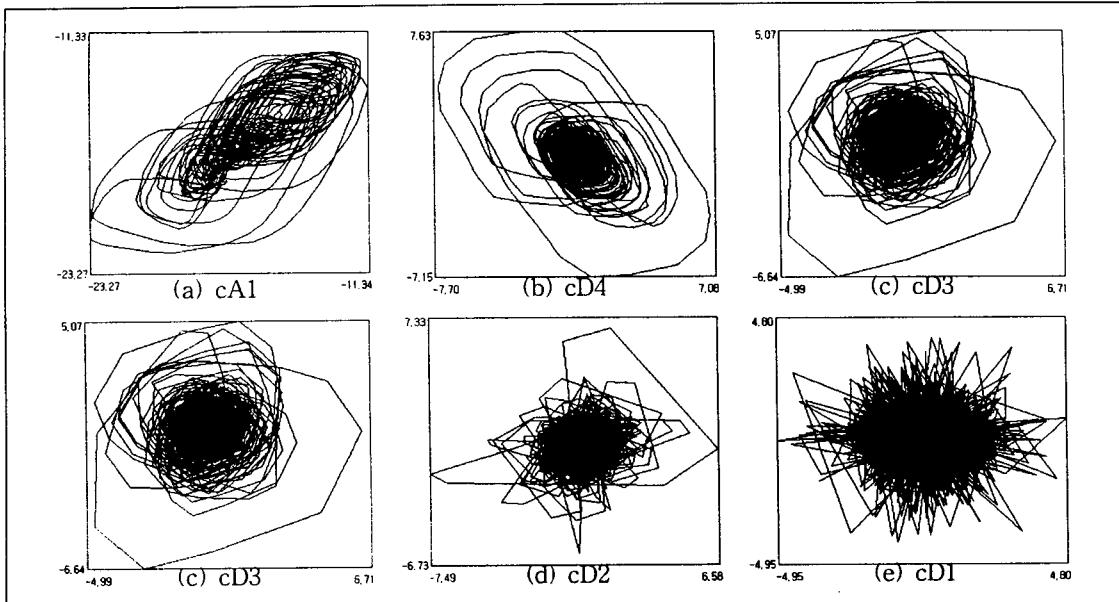
Daubechies 웨이브렛을 이용하여 수집된 통행시간 시계열 자료에 대하여 MRWT를 적용하여 네 단계의 패턴분류를 실시하였다. 이 결과 고역필터를 통과한 cD1, cD2, cD3, cD4 신호와 저역필터를 통과한 cA1, cA2, cA3, cA4 신호로 구분된다. 이 8개 신호중에서 원시신호는 cA4, cD1, cD2, cD3, cD4 등 5개의 신호로 구성된다.

위 MRWT로 구분된 신호의 특징을 분석하기 위하여 5개의 신호에 대한 기초통계분석과 카오스이론을 이용한 시간지연좌표를 이용하였다. 〈그림 7〉은 각각의 신호들이 갖고 있는 규칙성을 카오스이론의 시간지연좌표로 구성한 결과이다.

시간지연좌표는 Takens¹²⁾가 1980년에 제시한 비선형 시스템의 특성을 판별하는 방법으로 1차원의 시계열자료를 고차원에 투영함으로써 내재되어 있는 패턴 변화를 살펴볼 수 있다. 만약, 시계열자료가 자기발전적(autonomous)계의 특성을 갖고 있는 경우에는 카오스에서 끌개와 끌개 주위에 궤도가 형성되는 것을 관측할 수 있다. 하지만, 무작위적인 패턴변화를 보이는 경우에는 방사형식으로 뭉쳐있는 형상을 보이게 된다^{12,13)}.

〈그림 7〉의 (a)~(e)는 cA1, cD4, cD3, cD2, cD1을 차례로 시간지연 좌표에 투영한 결과들로 cA1, cD4, cD3는 주기적인 패턴변화와 반복성이 나타난 반면 cD2, cD1의 경우에는 단순히 중심에 패턴이 밀집하고 있는 것을 볼 수 있다. 즉, cD2, cD1은 통행시간 시계열자료에 내포되어 있는 백색잡음으로 정의 내릴 수 있다.

또, cD1과 cD2의 자기상관분석 결과 〈표 2〉에서 보는 바와 같이 cA4, cD4, cD3는 0.8이상의 높은 상관도를 보이는 반면, cD1과 cD2는 -0.176653으로 거의 자기상관이 없는 것으로 분석된다. 즉, cA4, cD4, cD3은 자기발전적인 계의 특성을 나타내는 계로 판단되고 cD1과 cD2신호는 랜덤워크(random walk)의 특성으로 분석된다. 따라서, 본 연구에서는 cD1과 cD2는 예측이 불가능한 백색잡음으로 제외한 cA1, cD4, cD3 세 개의 패턴에 대한 예측모형을 정립하여 예측모형을 구성하도록 하였다.



〈그림 7〉 각 패턴 시간지연좌표 구성결과

〈표 2〉 분해 신호의 자기상관분석 결과

분해 신호	자기상관도	평균	분산
cA4	0.993016	16.4005	3.615
cD4	0.959000	0.0007	1.198
cD3	0.815556	0.0006	0.699
cD2+cD1	-0.176531	0.0000	1.823

3. 예측모형 정립과 통행시간 예측

본 연구에서는 웨이브렛을 이용한 예측모형의 적합성을 평가하기 위하여 세가지 모형을 이용한 예측실험을 실시한다. 즉, 1)기존 예측시 가장 활발히 사용되어 온 BPN, 2)RBFN 그리고 마지막으로 3)웨이브렛 변환을 이용한 전처리 과정이 포함된 웨이브렛 변환-RBF 신경망(이하, WT-RBFN이라 함)을 이용하여 실험하도록 한다.

이 세가지 형태의 예측모형을 이용하여 버스노선 운행시간을 예측하는 실험을 토대로 본 논문에서 제안하고자 하는 웨이브렛 변환기법의 적용이 예측력에 미치는 효과와 RBFN신경망의 유효성을 검증하고자 한다.

1) 모형정립

(1) BPN 예측모형

BPN 예측모형의 정립을 위해서는 은닉층 뉴런 수와 입력값으로 적합한 과거시차를 결정해야 한다. 본 연구에서는 가장 보편적으로 사용되는 최적모형 탐색 알고리듬 중에서 Non-Contributing Units Method⁹⁾를 이용하여 초기에 설정된 뉴런수에서 불필요한 뉴런을 제거하도록 한다. 그리고, 모형 입력값은 미래시차와 과거시차간의 자기상관도를 측정하여 상관도가 높은 시점을 입력값으로 사용한다.

〈표 3〉은 BPN은 Pruning 알고리듬에 의해서 정립된 모형구조를 보여주고 있으며, 〈표 4〉는 이때 입력뉴런의 입력값으로 사용된 입력시차를 의미한다.

〈표 3〉 Pruning과정으로 정립된 BFN 구조

구분	초기 신경망 구조	정립된 신경망 구조
입력유니트 × 은닉유니트	15×15	입력유니트 : 1~6 제거 은닉유니트 : 3개 제거
연결강도	완전연결	완전연결(fully connected)

(2) RBF 신경망 예측모형

RBFN 정립시 가장 중요한 점은 BPN과 마찬가지로 은닉층의 뉴런수의 결정과 은닉층에 사용되는 활성함수의 중심값 결정이다. RBFN의 입력값은 BPN과 동일한 방법을 이용하여 결정하며, 중심값은 가장

〈표 4〉 구간별 예측모형의 입력값으로 사용된 시차

구간 상관도	s1	s2	s3	s4	s5	s6	s7	s8
1	1	1	1	1	1	1	1	1
2	2	2	2	2	2	2	2	2
3	3	3	3	3	3	3	3	3
4	4	4	4	4	4	4	4	4
5	5	5	96	5	5	96	5	5
6	97	6	97	6	6	97	97	7
7	98	98	98	7	98	98	98	98
8	99	99	99	99	99	99	99	99
9	100	100	100	100	100	100	100	100

위의 수치는 원시차를 t 라고 할 때, $t-k$ 의 과거시점값을 나타내는 k 값을 의미함.

널리 활용되고 있는 패턴분류 알고리듬인 k-means 알고리듬¹⁴⁾을 사용하도록 한다..

또, RBFN은 시계열자료의 패턴의 정형성에 따라 연결강도를 조정할 때 신경망 학습시 불규칙 정도에 따라 λ (smooth effect)값을 조정하여 학습속도를 향상 시킨다. 여기서는 Ridge regression¹⁰⁾을 이용하여 λ 을 결정하였으며, 〈표 5〉에서 제시한 바와 같이 거의 0에 가까운 값을 나타내고 있는 것으로 보아 통행시간 시계열 패턴이 매우 불규칙함을 알 수 있다.

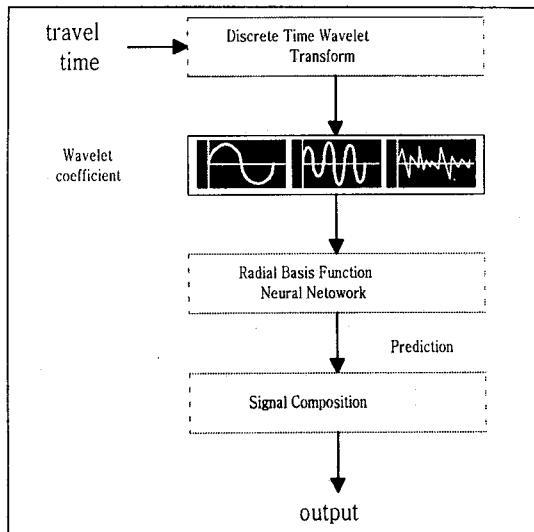
〈표 5〉 은닉 유니트수와 smoothing effect 값

구간	s1	s2	s3	s4
은닉층 유니트수	41	44	44	46
λ (10^{-6})	1,188	0.4991	0.03193	0.5556
구간	s5	s6	s7	s8
은닉층 유니트수	44	68	55	67
λ (10^{-6})	1,028	0.03024	0.6885	0.8509

(3) WT-RBFN 예측모형

WT-RBFN의 예측과정은 〈그림 8〉과 같이 먼저 원시계열자료의 패턴을 특성별로 분리한 다음에 분리된 신호의 가중치에 적합한 신경망모형을 정립하고, 정립된 모형으로 장래 통행시간의 가중치를 예측한 후에 각각의 예측결과를 합성하여 원상태의 시계열자료로 변환한다. 이같이 웨이브렛의 계수값을 이용한 시스템의 장래 변화를 예측하고자 하는 연구가 최근 웨이브렛에 대한 연구와 아울러 진행되고 있다^{15,16)}.

각 이산웨이브렛의 가중치에 대해서 정립된 신경망모형의 구조는 〈표 6〉과 같다.



〈그림 8〉 WT-RBFN 예측과정도

〈표 6〉 WT-RBFN 신경망 예측모형 은닉층 뉴런수와 smoothing effect 계수

구간	은닉층 유니트수							
	s1	s2	s3	s4	s5	s6	s7	s8
cA4	14	14	18	17	19	16	20	19
cD4	26	28	25	27	27	24	29	28
cD3	32	37	38	38	34	39	40	42
구분	λ (smoothing effect coefficient)							
	s1	s2	s3	s4	s5	s6	s7	s8
cA4	4,449 3E-01	8,014 7E-01	9,831 9E-02	7,829 0E-02	6,344 4E-01	9,651 2E-01	9,293 1E-01	4,126 6E-01
cD4	3,236 1E-04	3,035 4E-04	3,473 1E-04	7,761 8E-03	6,490 7E-05	5,812 5E-04	3,730 5E-05	8,266 8E-04
cD3	1,456 7E-06	8,091 8E-07	6,731 1E-07	1,494 2E-06	9,862 5E-07	5,494 1E-07	1,929 9E-06	8,156 0E-06

〈표 7〉 예측모형의 입력값으로 이용한 과거시차

구간 순위	s1	s2	s3	s4	s5	s6	s7	s8
cA4	1	1	1	1	1	1	1	1
	1	1	1	1	1	1	1	1
	2	2	2	2	2	2	2	2
	3	3	3	3	3	3	3	3
	4	4	4	4	4	4	4	4
cD4	1	1	1	1	1	1	1	1
	2	2	2	2	2	2	2	2
	3	3	3	3	8	8	3	3
	4	11	11	11	9	9	9	9
	5	12	12	12	10	10	10	10
	6	13	13	13	11	11	11	11
cD3	1	1	1	1	1	1	1	1
	2	2	2	2	2	2	2	2
	3	4	4	4	4	4	4	4
	4	5	5	5	5	5	5	5
	5	6	6	6	6	6	6	6
	6	7	7	7	7	7	7	7
	7	12	12	8	8	11	12	8

2) 예측결과 및 비교

세가지 예측모형을 이용한 예측결과는 〈표 8〉~〈표 10〉과 〈그림 9〉, 〈그림 10〉에 제시한 바와 같이 WT-RBFN, RBFN, BPN의 순으로 예측이 우수한 것으로 나타났다. 이중에서 본 연구에서 제시하고 있는 WT-RBFN의 예측결과의 경우, 예측구간이 s1에서 s8로 점점 길어질수록 BPN과 RBFN의 결과와 비교해 볼 때 훨씬 우수한 예측력을 갖는 것으로 나타났다. 즉, 기존 모형이 one-step-ahead 방식의 예측실험을 통해서 개발되었기 때문에 장기적인 예측에서는 매우 취약한 결과를 보인 반면, 본 연구에서 제안한 WT-RBFN의 경우에는 패턴분류와 패턴분석을 토대로 예측함으로써 예측시차가 길어지는 경우에도 오차의 발생폭이 적게 발생하는 결과를 보이고 있다.

〈표 8〉 역전파 신경망 예측오차

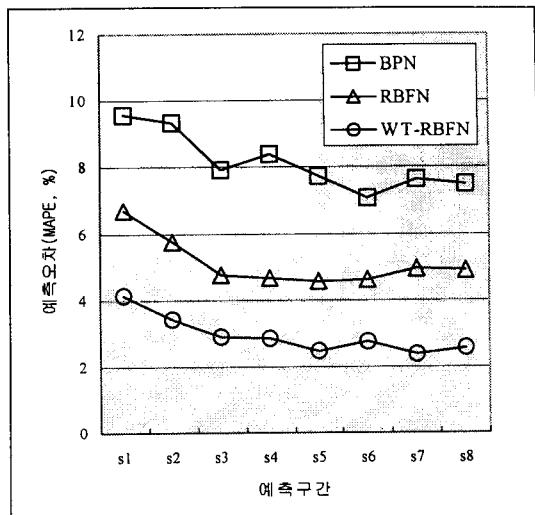
항목	s1	s2	s3	s4	s5	s6	s7	s8
MSE	4.631	17.128	23.950	40.790	49.983	57.824	95.348	138.38
MAPE	9.579	9.231	7.921	8.399	7.7169	7.0533	7.6537	7.5088

〈표 9〉 RBF 신경망 예측오차

항목	s1	s2	s3	s4	s5	s6	s7	s8
MSE	1.798	4.173	5.985	8.274	11.574	18.332	27.741	41.545
MAPE	6.685	5.731	4.751	4.656	4.541	4.588	4.9118	4.8899

〈표 10〉 WT-RBF 신경망 예측오차

항목	s1	s2	s3	s4	s5	s6	s7	s8
MSE	0.616	1.495	2.375	3.083	3.447	6.009	6.533	11.247
MAPE	4.139	3.430	2.913	2.824	2.461	2.735	2.395	2.580



〈그림 10〉 모형별 예측오차의 변화(MAPE)

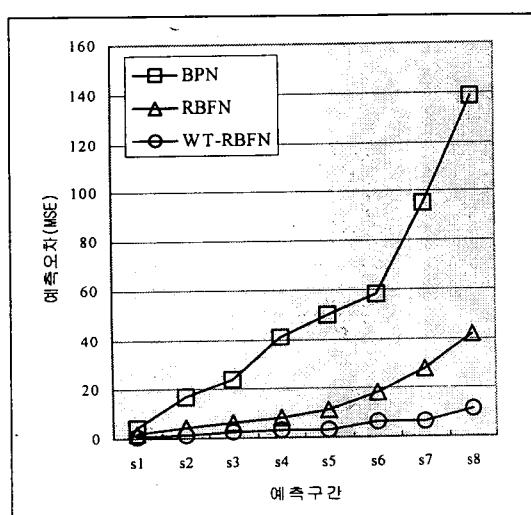
또, MAPE의 경우에 예측구간이 확장되어 갈수록 상대백분율 오차는 세 모형에서 모두 감소하는 것으로 분석되었다. 즉, 예측구간이 길어질수록 전체 통행시간에 비해서 예측모형의 오차는 감소된다는 것이다 (WT-RBF의 예측치와 관측치의 비교는 부록참조).

그 원인은 전체 통행시간이 길어지게 되면 불규칙한 통행패턴이 점차 안정적인 통행패턴으로 발전되기 때문인 것으로 판단된다.

III. 결론 및 토의

시계열예측은 과거의 통행패턴이 미래에도 지속된다는 가정을 전제로 한다. 즉, 시계열자료로부터 예측모형이 과거의 규칙적인 패턴변화를 학습할 수 있을 때에만 정확한 예측이 가능하다¹⁷⁾. 그러나, 도시내 통행시간의 경우에는 매우 불규칙한 패턴변화를 보이고 있어 기존의 예측방법을 적용할 경우에는 예측오차가 크게 발생하며, 예측구간이 확장되는 현실세계에서는 활용성이 크게 떨어지는 문제점이 지적된다.

본 연구에서는 WT와 신경망을 이용하여 경로통행시간이나 버스노선통행시간을 예측하기 위한 모형을 제안하였으며, 제안된 모형에 대한 적합성 평가결과 기존에 신경망 모형을 이용한 경우보다 훨씬 향상된 예측력을 보였다. BPN이 s8구간에서 MAPE가 7.5%,



〈그림 9〉 모형별 예측오차의 변화(MSE)

RBFN이 4.9%의 오차율을 보인 반면 WT-RBF 신경망은 2.5%로서 BPN보다는 3배, RBFN보다는 2배가량의 정확하였다.

위 실험결과 기존의 신경망 모형을 이용한 링크기반 예측모형이 안고 있는 극단기예측 문제를 다소 해결할 수 있을 것으로 판단되며, 현실세계의 적응성도 함께 향상시킬 수 있을 것으로 판단된다.

또, 예측구간의 길이가 길어질수록 절대오차(MSE)는 커지지만 통행시간에 대한 상대적인 오차(MAPE)는 줄어드는 것을 알 수 있었다. 이는 경로길이의 증가와 함께 통행시간이 길어질수록 불규칙한 패턴변화의 값이 전체 통행시간에 미치는 영향이 적어지기 때문인 것으로 판단된다.

본 연구에서 제안한 예측모형을 교통분야 전반에 걸쳐 적용가능한 모형으로 발전시키기 위해서는 여전히 여러 문제가 지적된다. 이를 살펴보면 다음과 같다.

첫째로는 버스노선통행시간은 각 구간의 통행시간을 예측한 것을 합한 것이 통행자의 기종점간 소요되는 통행시간이 되나, 일반적인 경로에서는 단순히 링크통행시간의 합이 바로 경로통행시간이 될 수 없다. 즉, 교차로에서의 지체와 같은 추가적인 정보가 필요하다.

둘째는 본 연구에서의 버스노선통행시간은 갑작스런 고장이나 사고에 의한 정상적인 패턴에서 벗어나는 유고사항은 고려하지 않았다. 따라서 신경망 예측모형보다 직관적 예측방법에 대한 부가적인 연구가 이루어져야 하며 이 경우에는 단순히 통행시간 자료뿐만 아니라 교통상황을 판단할 수 있는 사고정도, 도로공사, 기상조건, 교통량 등 다양한 정보가 필요하게 된다.

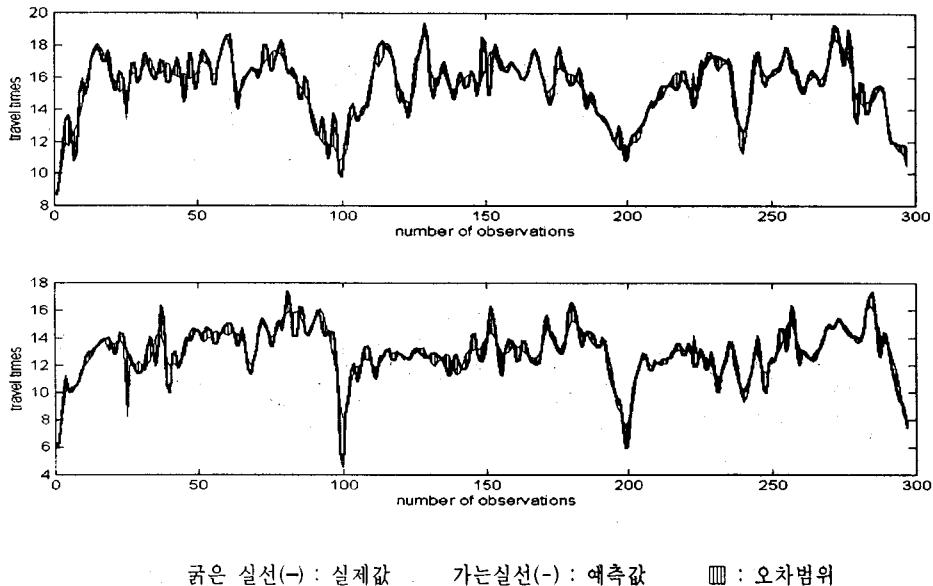
마지막으로 모형 구조의 정립시 비선형 계의 특성을 보이는 시계열자료의 분석을 이용한 방법이 필요하다. 본 연구에서 사용한 모형정립 방법은 반복실험과 직관적 방법을 이용하였으나, 최근 비선형 시스템에 대한 연구에 바탕을 둔 모형정립이 이루어 진다면 보다 단순하면서도 정확한 예측모형을 구축할 수 있을 것으로 판단된다.

참고문헌

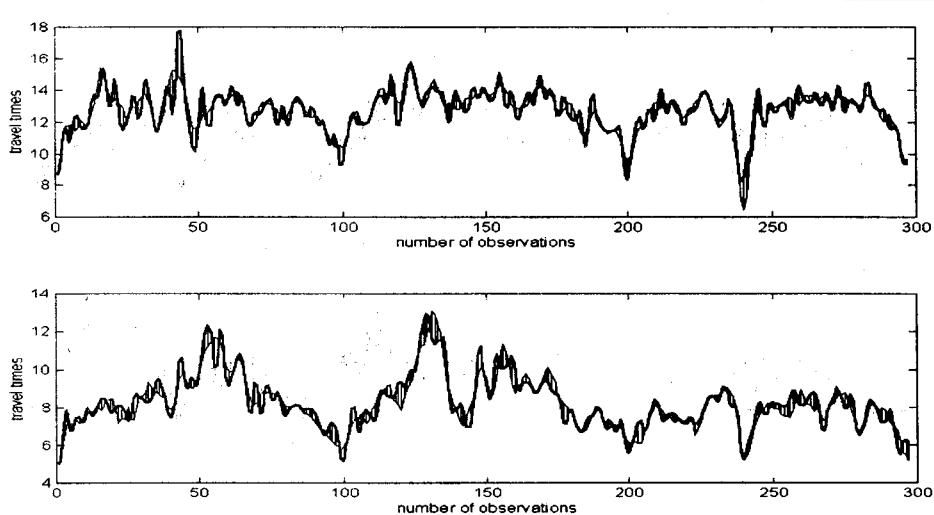
- Sang.Y. Yun, Sung. Nam-Kung, Seung W. Shin, Jung H. Roh, and Jong U. Choi, "A Performance Evaluation of Neural Network Models in traffic Volume Forecasting," Journal of Mathematical and Computer Modelling, Vol.27 (1998), pp.293~310.
- Kalaputapu R., Demetsky M.j., "Modeling Schedule Deviations of uses Using Automatic Vehicle-Location Data and Artificial Neural Networks", Transportation Research Record 1497, 1995.
- Masters, Timothy, "Neural, Novel & Hybrid Algorithms for Time Series Prediction," John Wiley & Sons, 1995.
- Wan, E., "Modeling Nonlinear Dynamics with Neural Networks : Example in Time Series Prediction," In Proceedings of the Fifth Workshop on Neural Networks, FNN93, pp.327~332, 1993.
- A. N. Edmonds et al, "Simultaneous Prediction of Multiple Financial Estimation," Proceedings of IEEE International Conference on Neural Networks, Vol 1, 1994.
- Charles K. Chui, Wavelets : A Tutorial in Theory and Applications, Harcourt Brace Jovanovich Publisher, 1992.
- M. Misiti, Y. Misiti, G. Oppenheim, J. Poggi, Wavelet Toolbox User's Guide, Math Works, Inc., 1996.
- C. Sidney Burrus, Ramesh A. Gopinath, Introduction to Wavelets and Wavelet Transforms : A Primer, 1997, Prentic-Hall,Inc.
- L. Fausett, Fundamental of Neural Networks : Architectures, Algorithms, and Applications, Prentice Hall, 1994.
- Mark J.L.Orr, Introduction to Radial Basis Function Networks, Centre for Cognitive Science, 1996.
- Byungkyu, P., Carroll J. M., & Thomas, U., "Short-Term Freeway Traffic volume Forecasting Using Radial Basis Function Neural

- Network," In Preceeding on TRB 77th Annual Meeting, 1997.
- 12. F. Takens, in *Dynamical Systems and Turbulence*, Warwick, 1980, edited by D. Rand and L. S. Young, Lecture Notes in Mathematics 898 (Springer, Berlin, 1981), p.366.
 - 13. Mathew B. Kennel , Reggie Brown & Henry D. I. Abarbanel, "Determining embedding dimension for phase-space reconstruction using a geometrical construction," American Physical Society, 1991.
 - 14. J. MacQueen, "Some Methods for Classification and Analysis of Multivariate Data," Proc. of the 5th Berkeley Symposium on Probability and Statistics, University of California Press, Berkeley, 1967.
 - 15. F. Tsui, M. Sun, "A Wavelet Based Neural Network for Prediction of ICP Signal," Preprint of the EMBS International Conference95, 1995.
 - 16. Sathyanarayan S. Rao & B. Kumthekar, "Recurrent Wavelet Networks," IEEE Trans. on Neural Networks, 1994.
 - 17. S. Makridakis, The Art and Science of Forecasting, International Journal of Forecasting, pp.15~39, 1986.

부록 : WT-RBFN 예측결과

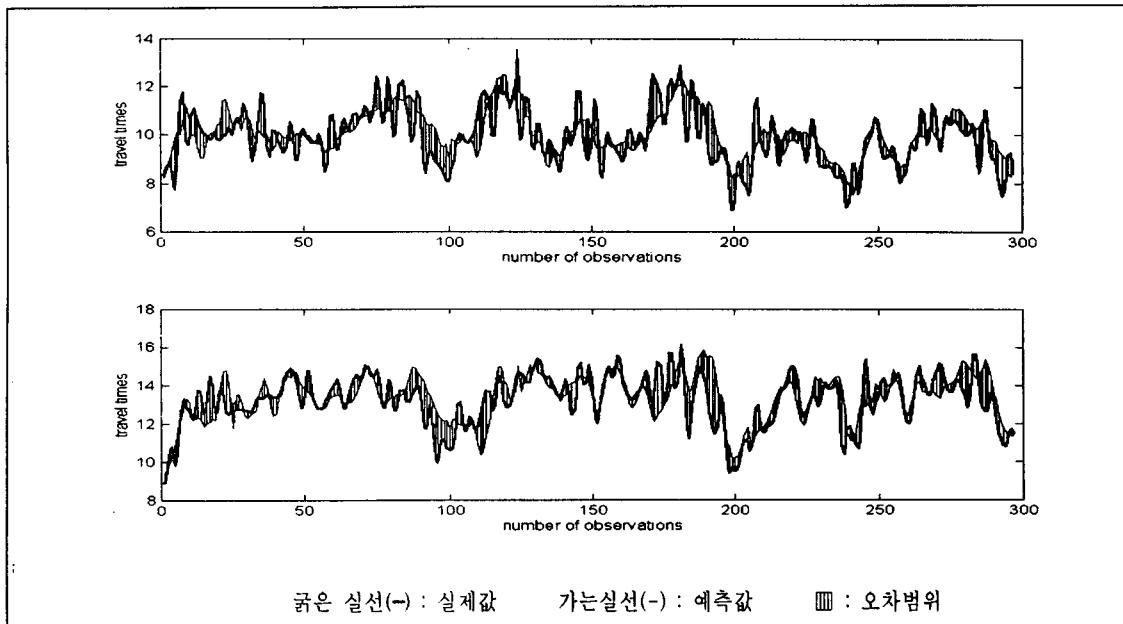


〈그림 A〉 RBF 신경망을 이용하여 WT로 분리한 패턴의 예측결과(상:s1, 하:s2)

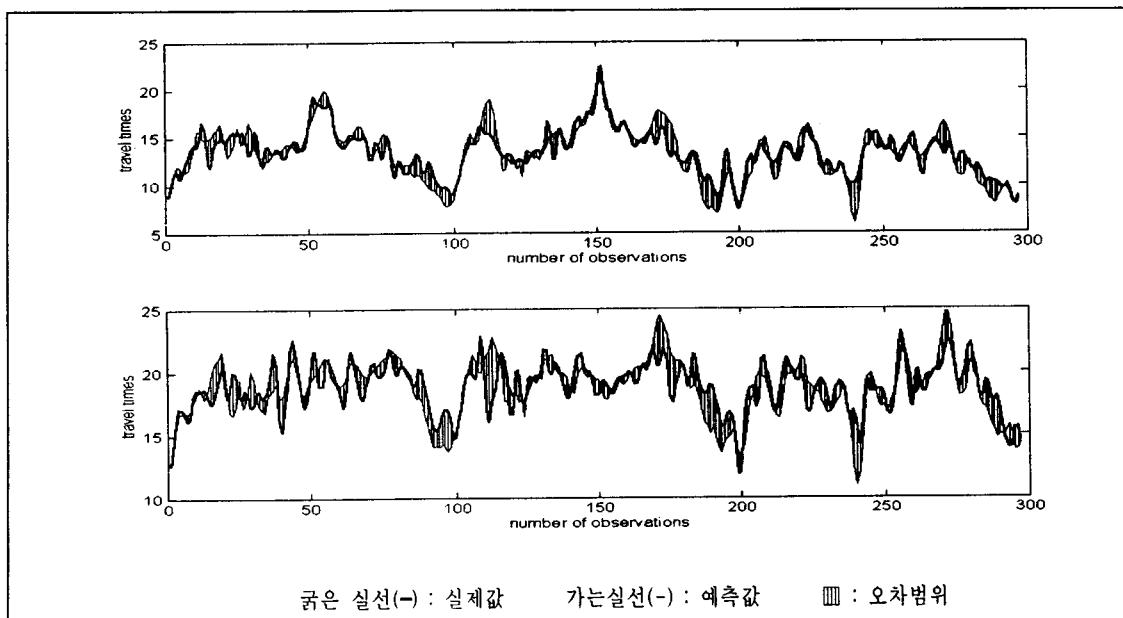


굵은 실선(—) : 실제값 가는실선(-) : 예측값 ■ : 오차범위

〈그림 B〉 RBF 신경망을 이용하여 WT로 분리한 패턴의 예측결과(상:s3, 하:s4)



〈그림 C〉 RBF 신경망을 이용하여 WT로 분리한 패턴의 예측결과(상:s5, 하:s6)



〈그림 D〉 RBF 신경망을 이용하여 WT로 분리한 패턴의 예측결과(상:s7, 하:s8)