

## Wavelet 변환과 신경망을 이용한 시계열 데이터 예측력의 향상\*

신승원\* · 최종욱\*\* · 노정현\*\*\*

Enhancement of Forecasting Accuracy in Time-Series Data, Based on  
Wavelet Transformation and Neural Network Training<sup>\*</sup>

Seung-Won Shin\* · Jong-Uk Choi\*\* · Jeong-Hyun Rho\*\*\*

### Abstract

Travel time forecasting, especially public bus travel time forecasting in urban areas, is a difficult and complex problem which requires a prohibitively large computation time and years of experience. As the network of target area grows with addition of streets and lanes, computational burden of the forecasting systems exponentially increases. Even though the travel time between two neighboring intersections is known a priori, it is still difficult, if not impossible, to compute the travel time between every two intersections. For the reason, previous approaches frequently have oversimplified the transportation network to show feasibilities of the problem solving algorithms.

In this paper, forecasting of the travel time between every two intersections is attempted based on travel time data between two neighboring intersections. The time stamps data of public buses which recorded arrival time at predetermined bus stops was extensively collected and forecast. At first, the time stamp data was categorized to eliminate white noise, uncontrollable in forecasting, based on wavelet conversion. Then, the radial basis neural networks was applied to remaining data, which showed relatively accurate results. The success of the attempt was confirmed by the drastically reduced relative error when the nodes between the target intersections increases. In general, as the number of the nodes between target intersections increases, the relative error shows the tendency of sharp increase.

The experimental results of the novel approaches, based on wavelet conversion and neural network learning mechanism, showed the forecasting methodology is very promising.

주제어 : 웨이브렛 변환, RBF 신경망, 통행시간 예측,

\* 본 연구는 한국과학재단(과제번호 KOSEF/95-0600-10-01-3)의 지원에 의해 수행되었음.

\*\* 상명대학교 AIT 연구소 연구원

\*\*\* 상명대학교 정보통신학부

\*\*\*\* 한양대학교 도시공학과

## 1. 서 론

도시 가로망의 통행시간 예측은 최근 전세계적으로 확산되고 있는 첨단도로교통체계 구축을 위해서 선행되어야 하는 핵심기술이다. 특히, 교통수요가 도로의 처리용량을 초과함으로써 발생되는 지체현상이 뚜렷한 대도시에서는 통행시간을 지리적인 거리에 비례하는 결정론적 수식만으로는 예측할 수 없기 때문에 비선형계의 불규칙성, 불안전성의 성질을 분석하여 이를 예측에 활용하고자 하는 새로운 기술개발이 필요하다.

최근 통행시간이나 통행량 예측모형에 대한 연구를 살펴보면 확률에 기반을 둔 ARIMA나 Box-Jenkins 보다는 신경망 이론이나 페지이론을 응용한 모형 개발이 활발히 이루어져지고 있다. 이와 같은 추이는 과거에 통행패턴의 불규칙성을 무작위한 것으로 간주해 버리고 결정론적인 특징만을 예측에 활용하려고 했기 때문이다. 하지만, 통행패턴의 불규칙함은 결정론적 함수로 분석할 수 없는 교통상황의 돌발변수들에 의해서 발생되는 것이므로 시계열 자료에 내포되어 있는 정보가 분석 가능하다면 보다 우수한 예측모형 개발이 가능하다.

또, 지금까지 단일링크 교통량이나 통행시간의 예측시 신경망 모형이 여타 확률모형보다 우수한 예측결과를 나타내고 있음이 증명되었으나 (Sang Y. Yun, 1998), 단일링크를 대상으로 개발된 예측모형을 현장에 적용하기에는 해결해야 될 문제가 있다. 첫 번째로는 예측정보를 필요로 할 때, 모든 도로망에 대한 예측정보가 동일한 미래시점상의 정보가 아니라는 점이다. 즉, 최소 시간경로로 진행하고자 한다면 경로를 구성하는 각 링크마다 운전자가 경험하게 되는 통행시간의 시점이 서로 상이하기 때문에 one-step ahead

방식의 예측을 multi-step ahead 방식의 예측이 가능하도록 해야 한다.

두 번째로는 도시가로망의 통행시간은 단순히 링크통행시간의 합으로 경로통행시간을 추정할 수 없다. 즉, 링크와 링크간의 교차로에 의한 지체시간 등을 모두 고려한 통행시간을 예측하기 위해서는 경로를 대상으로 한 예측모형이 필요하다.

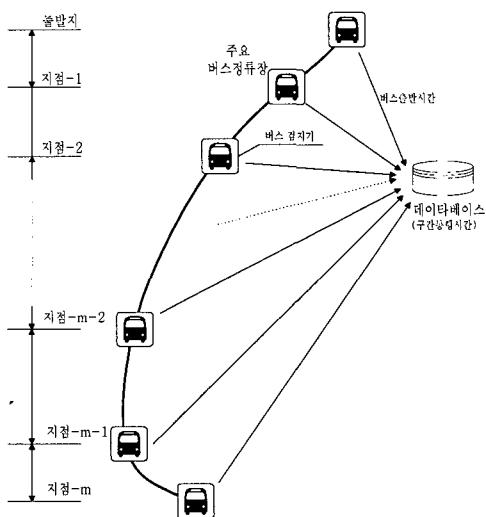
따라서, 본 연구에서는 먼저 Time-Frequency 분석의 일종인 웨이브렛 변환을 이용하여 통행시간 패턴을 분해하고, 분해된 각 패턴별의 특성을 규명하도록 하였다. 이때, 분해된 시계열 자료의 특징은 Takens의 time-delay 그레프[2]를 이용하였다. 그리고, 예측모형은 학습시간이 적게 소요되면서 역전파 신경망(BPN)이나 리커런트 신경망 모형과 유사한 예측력을 갖고 있는 RBF(Radial Basis Function) 신경망을 이용하여 모형화하였다.

## 2. 연구방법

### 2.1. 계측자료

본 연구를 위해서 사용된 자료는 버스노선을 따라 설치된 Tacho 시스템으로부터 수집된 15개 지점의 버스출발시간과 도착시간을 이용하였다. 연구의 목적상 계측간격을 10분단위, 8개구간으로 변환하여 사용하였다.

총 4개월간의 관측자료중에서 3개월의 관측자료는 교통계의 해석과 분석에 활용하고 1개월의 자료는 예측실험에 사용하였다. [그림 1]은 본 연구에 활용된 시계열 자료의 계측과정을 개략적으로 보여주고 있다.

(그림 1) 구간통행시간 계측과정 ( $m = 15$ )

## 2.2. 웨이브렛변환

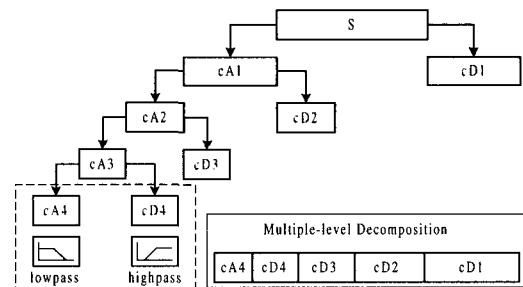
교통계는 정태적인 특성보다는 동태적인 특징을 갖고 있기 때문에 계측간격이 짧을수록 심한 불규칙파동이 심화된다. 즉, 전체적인 패턴양상을 찾기 어려울 정도로 불규칙성이 심하기 때문에 흔히 무작위(random) 또는 노이즈(noise)로 해석되는 패턴이 발생된다. 이와 같은 패턴은 예측모형으로도 예측이 불가능할뿐더러 오히려 예측력을 약화시키는 원인이 된다. 따라서, 해석 가능한 패턴과 그렇지 못한 패턴을 분석해 내기 위해서 웨이브렛을 이용하도록 한다.

웨이브렛 이론의 배경은 주어진 신호를 직교성을 가지고 있는 웨이브렛들을 적용하여 분해 할 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 알고리즘이 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  $2^{-j}n$  만큼 천이 시키고,  $\sqrt{2^{-j}}$ 로 정규화함으로써

$$\sqrt{2^{-j}} \psi_{2^j}(t - 2^{-j}n) \quad \text{식 1.}$$

의 정규직교 웨이브렛이 구성된다 (Charles K. Chui, 1992).



(그림 2) MRWT를 이용한 신호의 분할 과정.

다중해상도 웨이브렛 변환(multiresolution wavelet transformation, 이하 MRWT)은 웨이브렛 함수를 정규직교기저에서 적용함으로써 주어진 신호의 특성을 분해하여 나타내는 알고리즘이다. 즉,  $j$ 를 0부터  $-J$  까지 적용하여, 해석하고자 하는 신호의 approximation성분  $A(j)$ 와 detail 성분  $D(j)$ 로 나누어 나가는 것이다. 나누어진 성분들은 단계적으로 연속되는 더욱 세밀한 크기와 해상도를 갖게 되는데, 이는  $j$ 값의 변화에 따라서 detail성분은 감소되고, approximation 성분들은 계속 유지된다고 볼 수 있는 것이다. 그리고,

이러한 과정을 주파수영역의 관점에서 보면, approximation성분은 저역필터를 통과한 신호들이 되고, detail성분은 고역필터를 통과한 신호들로 나타나게 됨을 알 수 있다. [그림 2]에 MRWT를 적용하였을 때 신호가 분해되는 과정이 도식적으로 나타나 있다 (M. Misiti, 1996).

$$\begin{aligned}\phi(n) &= \sum_{k=0}^N g(k) \phi(2n-k) \\ \Psi(n) &= \sum_{k=0}^N h(k) \phi(2n-k)\end{aligned}\quad \text{식 2.}$$

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

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

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

$$x(n) = A_{2^1}[x(n)] + D_{2^1}[x(n)] \quad \text{식 4.}$$

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

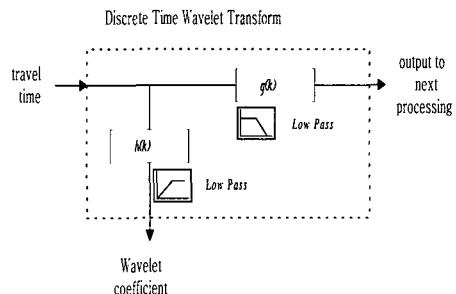
$$\begin{aligned}A_{2^1}[x(n)] &= \sum_{k=0}^N a_{2^1}(k) \phi_{2^1}(n-2^1 k) \\ D_{2^1}[x(n)] &= \sum_{k=0}^N d_{2^1}(k) \Psi_{2^1}(n-2^1 k)\end{aligned}\quad \text{식 5.}$$

로서,  $\phi_{2^1}(n-2^1 k)$ 과  $\Psi_{2^1}(n-2^1 k)$ 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 때 까지 반복되며,

$$\begin{aligned}A_{2^{j-1}}[x(n)] &= A_{2^j}[x(n)] + D_{2^j}[x(n)] \\ &= \sum_{k=0}^N a_{2^j}(k) \phi_{2^j}(n-2^j k) \\ &\quad + \sum_{k=0}^N d_{2^j}(k) \Psi_{2^j}(n-2^j k)\end{aligned}\quad \text{식 6.}$$

로 나타낼 수 있다.

이때  $a_{2^j}(n) = g(n) * a_{2^{j-1}}(n)$  이고,  $d_{2^j}(n) = h(n) * a_{2^{j-1}}(n)$  으로 정의된다. 이 상에 언급된 내용을 요약하면, 웨이브렛 변환은 주어진 신호를 각 scale에서 approximation과 detail성분으로 분해하는 과정이다. Scale  $j$ 에서의 detail성분은 scale  $(j-1)$ 에서의 approximation 신호와 웨이브렛 필터계수  $h(n)$ 을 상승적분함으로서 구할 수 있고, scale  $j$ 에서의 approximation 성분은 scale  $(j-1)$ 에서의 approximation 신호와 scale 필터계수  $g(n)$ 을 상승적분 함으로서 계산되어진다 (M. Misiti, 1996; Sidney C. Burrus, 1997).



[그림 3] 이산웨이브렛을 이용한 패턴분석과정

본 실험에서는 기저 웨이브렛 함수로서 Daubechies함수를 사용하였다. 수집된 통행시간 시계열 자료에 대하여 MRWT를 적용하였으며, 이때 신호의 분할은 네 단계로 나누어서 실시하였다. 즉, 최초의 자료는 저역통과필터를 통과한 approximation신호(a1)와 고역통과필터를 통과한 detail신호(d1)로 분할된다. 그리고, a1은 다시 차단주파수가 변경된 저역, 고역통과필터를 거쳐서 a2와 d2로 분할되며, 이러한 과정을 반복실행하여 4개 대역의 신호들로 나타나게 된다. 결국, 앞서 언급된 네 종류의 웨이브렛 함수를 이용한 통행시간 패턴의 웨이브렛 변환을 통해 분할된 신호들은 고역필터를 통과한 d1, d2, d3, d4의 값들과 저역필터를 통과한 a1, a2, a3, a4으로 저장되었다. 본 연구에서는 분할되어진 detail 성분인 d1~d4 값들과 approximation성분인 a4을 이용하여 통행시간 예측을 위하여 사용되게 된다.

MRWT를 위한 프로그램은 Matlab 4.2c1과 웨이브렛 Toolbox를 사용하였다.

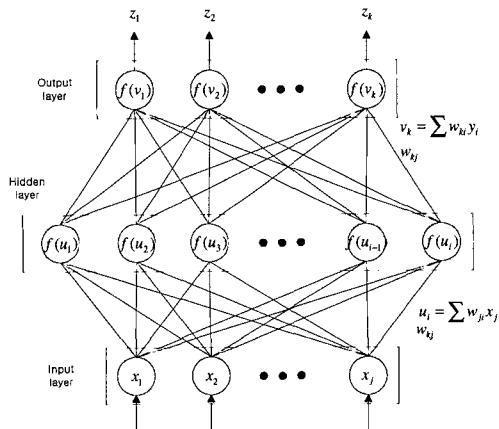
### 2.3 신경망 예측모형

본 연구에서 예측모형은 RBF 신경망(Radial Basis Function Neural Network, 이하 RBFN이라 함)을 이용하여 예측모형을 구성하도록 한다. 또, 예측모형의 적합성을 검증하기 위하여 BPN(Backpropagation Neural Network, 이하 BPN이라 함)의 예측모형을 이용한 예측실험을 같이 실시하도록 한다. 신경망 모형의 예측실험은 Matlab 신경망 Toolbox를 이용하였다.

#### 2.3.1 역전파 신경망(BPN)

BPN은 일반화된 델타규칙을 학습알고리듬으

로 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 된다(L. Fausett, 1994).



(그림 4) BPN (입력뉴런 j, 은닉뉴런 i, 출력뉴런 k)

그러나 BPN은 Least Square Error를 최소화하기 위하여 Weight Decay 알고리듬을 이용하여 연결강도를 조절해 나가기 때문에 일반 직렬형 컴퓨터에서는 학습시간이 매우 오래 걸린다는 단점이 있다.

BPN의 은닉층과 출력층 뉴런에서 활성화되어 출력되는 값은 다음 식과 같다.

$$y_i = \sum_{j=0}^n w_{ij}x_j + \sum_{j=0}^n b_i \quad \text{식 7.}$$

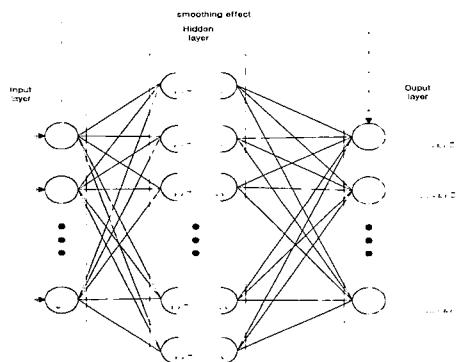
여기서,  $y_i$ 는  $i$  뉴런의 출력값,  $x_j$ 는 입력값,  $w_{ij}$ 는  $i$  뉴런과  $j$  뉴런과의 연결강도를,  $b_i$ 는

$i$  뉴런의 모멘텀항을 각각 의미한다.

### 2.3.2 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 역행렬 방법을 이용할 수 있기 때문에 연산속도가 매우 빠른 강점을 갖고 있다 (Chen, S., 1991).

[그림 5]는 일반적인 RBFN의 구조를 도식화 한 것이다. 입력층은 단지 은닉층으로 입력패턴을 전달하는 역할만을 하기 때문에, 모든 연결 강도값은 1로 고정되어 있다. 은닉층의 활성화 함수는 RBF(대표적으로 가우스함수가 있음)를 이용하고 은닉층 뉴런의 활성화값과 연결강도  $w_j$ 를 곱하여 선형적으로 합한 값을 최종적으로 출력하게 된다.



(그림 5) RBFN (파선은 smoothing effect :  $\lambda_i$ )

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

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

Gaussian function

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

Multiquadric function

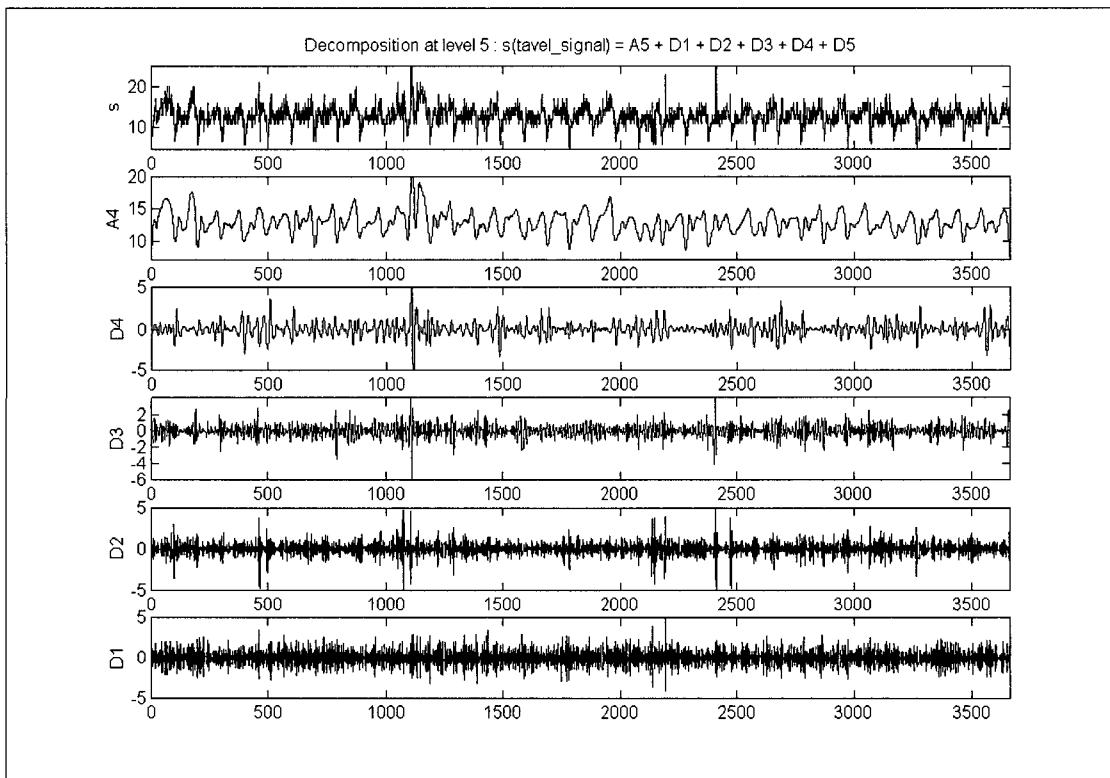
$$h(\vec{x}, \vec{m}) = \frac{c_j}{\sqrt{(x_i - m_j)^2 + c_j^2}}$$

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

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

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 조건을 의미한다. 이때,  $\lambda$ 값이 1에 가까울수록 패턴을 정확하게 학습시키고, 0에 가까울수록 완만한 형태의 추정이 이루어 진다 (Chen, S., 1991).

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



(그림 6) 통행시간 이산웨이브렛변환 해석결과

### 3. 연구결과

#### 3.1. 통행시간 패턴 분석결과

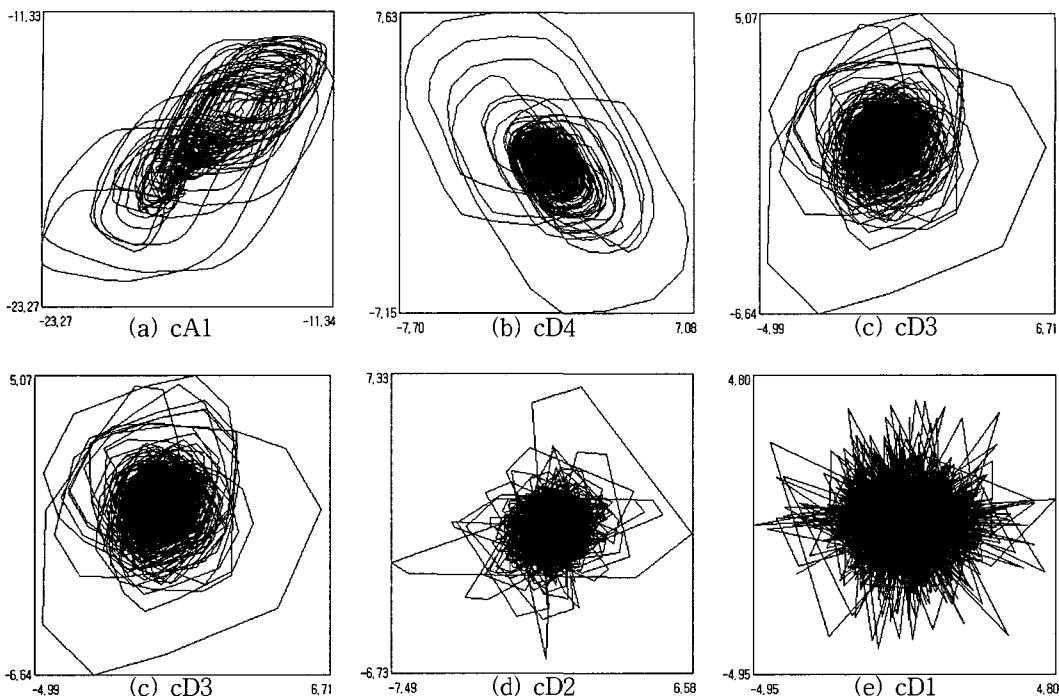
통행시간 시계열 자료를 이산웨이브렛변환을 통해서  $cA4$ ,  $cD1$ ,  $cD2$ ,  $cD3$ ,  $cD4$  등 5개의 신호를 분류해 내었다. 각 신호들은 통행시간속에 융해되어 있던 특징들을 의미한다. 즉, 1일의 통행패턴과 더 세밀한 주기를 갖는 패턴 그리고 백색잡음으로 예측이 불가능한 패턴들로 구성되어 있다.

각 신호별로 예측모형을 구성하기 전에 신호의 패턴이 규칙성을 갖고 있는지 분석하는 과정이

필요하다.

[그림 6]은 이산웨이브렛변환으로 분해된 5개의 패턴 신호로, 8개 구간의 통행시간 중에서 첫 번째 구간  $s1$ 을 분해한 결과이다. 그리고, [그림 7]은 각각의 신호들이 갖고 있는 규칙성을 카오스이론의 시간지연좌표로 구성한 결과이다.

시간지연좌표는 Takens가 1980년에 제시한 비선형 시스템의 특성을 판별하는 방법으로 1차원의 계측 시계열자료를 고차원에 투영함으로써 내재되어 있는 패턴변화를 살펴볼 수 있다. 만약, 시계열자료가 자기발전적인 (autonomous) 계의 변화를 갖고 있다면 카오스에서 흔히 일컫는 프랙탈을 관측할 수 있다. 하지만, 무작위적인



(그림 7) 각 패턴 시간지연좌표 구성결과

패턴변화를 보이는 경우에는 방사형식으로 뭉쳐 있는 형상을 보이게 된다 (Takens, F., 1980).

[그림 7]의 (a)~(e)는 cA1, cD4, cD3, cD2, cD1을 차례로 시간지연좌표에서 관찰한 것이다.

cA1, cD4, cD3는 주기적인 패턴변화와 중심점이 나타난 반면 cD2, cD1의 경우에는 가운데를 중심으로 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 1>과 같이 cA4, cD4, cD3는 0.8이상의 높은 상관도를 보이는 반면, cD1과 cD2는 -0.176653으로 거의 자기상관이 없는 것으로 분석되었다. 따라서, 본 연구에서는 cD1과 cD2는 예측이 불가능한 백색잡음으로 제외한 cA1, cD4, cD3 세 개의

패턴에 대한 예측모형을 정립하여 예측모형을 구성하도록 하였다.

&lt;표 1&gt; 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

### 3.2. 신경망 모형 예측결과

본 연구에서는 웨이브렛을 이용한 예측모형의 적합성을 평가하기 위하여 세가지 모형을 이용한 예측실험을 하였다. 즉, 기존 예측시 가장 활

발히 사용되어 온 BPN, 그리고 RBFN, 마지막으로 웨이브렛 변환을 이용한 전처리 과정이 포함된 웨이브렛-RBF 신경망 (이하, WT-RBFN이라 함) 등이다.

이 세가지 형태의 예측모형을 이용하여 버스 노선 운행시간을 예측하는 실험을 토대로 본 논문에서 제시한 WT-RBFN 모형의 유효성을 검증하고자 한다.

### 3.2.1. 모형정립

#### (1) BPN 예측모형

BPN 예측모형의 정립을 위해서는 은닉층 뉴런수와 입력값으로 적합한 과거시차를 결정해야 한다. 본 연구에서는 가장 보편적으로 사용되는 Pruning 알고리듬 중에서 Non-Contributing Units Method를 이용하여 초기에 설정된 뉴런수에서 불필요한 뉴런을 제거하고, 입력값은 미래시차와 과거시차간의 자기상관도를 측정하여 상관도가 높은 시점을 입력값으로 사용하였다.

<표 2>는 BPN은 Pruning 알고리듬에 의해서 정립된 모형구조를 보여주고 있으며, <표 3>은 이 때 입력뉴런의 입력값으로 사용된 입력시차를 의미한다.

<표 2> Pruning과정으로 정립된 BFN 구조

구 분	초기 신경망 구조	정립된 신경망 구조
입력유니트 × 은닉유니트	$15 \times 15$	$9 \times 12$ 입력유니트 : 1~6 제거 은닉유니트 : 3개 제거
연결강도	완전연결	완전연결 (fully connected)

<표 3> 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

주 : 위의 수치는 원시차를  $t$ 라고 할 때,  $t-k$ 의 과거 시점값을 나타내는  $k$  값을 의미함.

#### (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 결정하였으며, 중심값은 가장 일반적인 패턴분류 알고리듬인 k-means 알고리듬 (J. MacQueen, 1967)을 사용하였다.

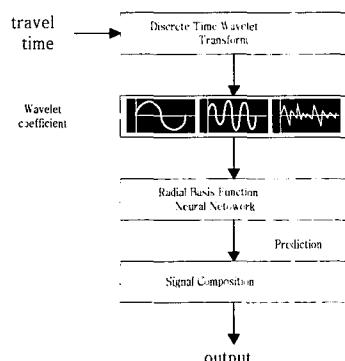
또, RBFN은 시계열자료의 패턴의 정형성에 따라 연결강도를 조정할 때 smoothing effect를 주는  $\lambda$  값을 이용하여 학습속도를 향상시킨다.

<표 4> 은닉 유니트수와 smoothing effect 값

구 간	s1	s2	s3	s4
은닉층 유니트수	41	44	44	46
$\lambda$ ( $10^{-6}$ )	1.188	0.4991	0.03.193	0.5556
구 간	s5	s6	s7	s8
은닉층 유니트수	44	68	55	67
$\lambda$ ( $10^{-6}$ )	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 (F.Tsui, 1995; Sathyaranayanan S. Rao, 1994).



[그림 8] WT-RBFN 예측과정도

〈표 5〉 WT-RBF 신경망 예측모형 은닉층뉴런수 와 smoothing effect 계수

구분	은닉층 유닛수							
	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	$\lambda$ (smoothing effect coefficient)							
	s1	s2	s3	s4	s5	s6	s7	s8
cA4	4.44 93E- 01	8.01 47E- 01	9.83 19E- 02	7.82 90E- 02	6.34 44E- 01	9.65 12E- 01	9.29 31E- 01	4.12 66E- 01
cD4	3.23 61E- 04	3.03 54E- 04	3.47 31E- 04	7.76 18E- 03	6.49 07E- 05	5.81 25E- 04	3.73 05E- 05	8.26 68E- 04
cD3	1.45 67E- 06	8.09 18E- 07	6.73 11E- 07	1.49 42E- 06	9.86 25E- 07	5.49 41E- 07	1.92 99E- 07	8.15 60E- 06

각 이산웨이브렛의 가중치에 대해서 정립된 신경망모형의 구조는 <표 5>과 같다.

〈표 6〉 예측모형의 입력값으로 이용한 과거시차

구간	s1	s2	s3	s4	s5	s6	s7	s8
cA4	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	8	11	12

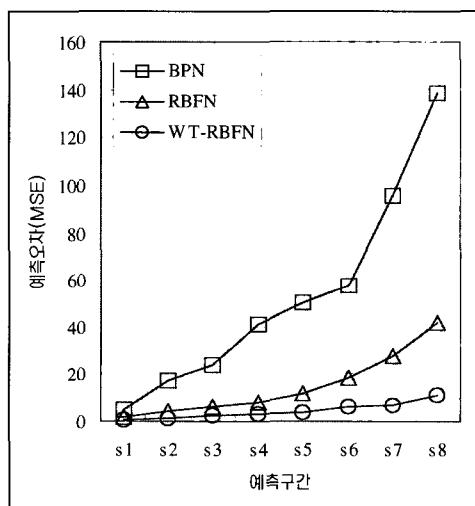
### 3.3. 예측결과 및 비교

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 경우에는 예측구간이 s1에서 s8로 점점 증가해 갈수록 BPN과 RBFN에 비해서 월등히 우수한 예측력을 갖는 것으로 평가된다.

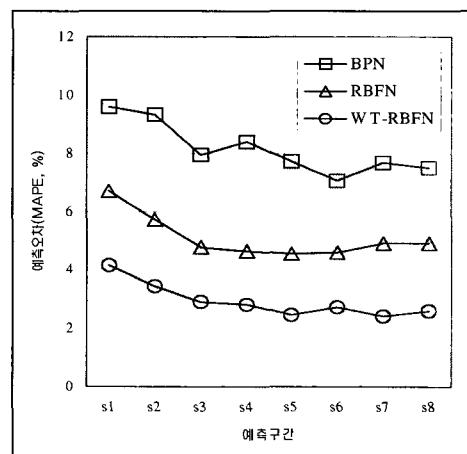
또, 본 실험에서 평가기준으로 활용한 MAPE의 경우에 예측구간이 확장되어 갈수록 상대적 백분율 오차는 세 모형에서 모두 감소하는 것으로 분석되었다.

〈표 7〉 역전파 신경망 예측오차

항 목	s1	s2	s3	s4	s5	s6	s7	s8
BPN	MSE	4.63	17.13	23.95	40.79	49.98	57.82	95.35
	MAPE	9.58	9.23	7.92	8.40	7.72	7.05	7.65
RBFN	MSE	1.80	4.17	5.99	8.27	11.57	18.33	27.74
	MAPE	6.69	5.73	4.75	4.66	4.54	4.59	4.912
WT-RBFN	MSE	0.62	1.50	2.38	3.09	3.45	6.01	6.53
	MAPE	4.14	3.43	2.91	2.82	2.46	2.74	2.40



(그림 9) 모형별 예측오차의 변화 (MSE)



(그림 10) 모형별 예측오차의 변화 (MAPE)

#### 4. 결론 및 토의

시계열예측은 과거의 통행패턴이 미래에도 지속된다는 가정을 전제로 한다. 즉, 시계열자료로부터 예측모형이 과거의 규칙적인 패턴변화를 학습할 수 있을 때에만 정확한 예측이 가능하다. 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%, 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.

그러나, 본 예측모형이 교통분야에서 다루는 다양한 해법으로 발전되기 위해서는 아직 해결해야 할 문제점이 있다.

첫째, 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.

둘째, 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.

셋째, 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.

### 참 고 문 헌

- Charles K. Chui, *Wavelets : A Tutorial in Theory and Applications*, Harcourt Brace Jovanovich Publisher, 1992.
- Chen, S., C.F.N. Cowan, and P.M. Grant, "Orthogonal least squares Learning Algorithm for Radial Basis Function Networks," *IEEE Transactions on Neural Networks*, Vol.2, No.2, 302~309, 1991.
- F. Tsui, and M. Sun, "A Wavelet Based Neural Network for Prediction of ICP S Signal," Preprint of the EMBS International Conference 95, 1995.
- 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.
- L. Fausett, *Fundamental of Neural Networks : Architectures, Algorithms, and Applications*, Prentice Hall, 1994.
- M. Misiti, Y. Misiti, G. Oppenheim, and J. Poggi, *Wavelet Toolbox User's Guide*, Math Works, Inc., 1996.
- Mark J.L. Orr, *Introduction to Radial Basis Function Networks*, Centre for Cognitive Science, 1996.
- 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), 293~310.
- Sathyaranayanan S. Rao, and B. Kumthekar, "Recurrent Wavelet Networks," *IEEE Trans. on Neural Networks*, 1994.
- Sidney C. Burrus, and Ramesh A. Gopinath, *Introduction to Wavelets and Wavelet Transforms : A Primer*, Prentic-Hall, Inc, 1997.
- Takens, F., "Detecting Strange Attractors in Turbulence," In D. A. Rand and L.S. Young (Eds.), *Lecture Notes in Mathematics*, Springer-Verlag, 1980, 366~381.
- Wasserman, *Advanced Methods in Neuran Computing*, New York: Van Nostrand Reinhold, 155~161, 33~35, 1993.