

☒ 응용논문

배차계획시스템을 위한 도시내 차량이동속도  
패턴인식 신경망 모델  
- A Neural Network Model to Recognize the Pattern of  
Intra-City Vehicle Travel Speeds for Truck Dispatching System -

홍 성 철\*,  
Hong, Sung-Chul  
박 양 병\*\*,  
Park, Yang-Byung

Abstract

The important issue for intra-city truck dispatching system is to measure and store actual travel speeds between customer locations. Travel speeds(and times) in nearly all metropolitan areas change drastically during the day because of congestion in certain parts of the city road network. We propose a back-propagation neural network model to recognize the pattern of intra-city vehicle travel speeds between locations that relieve much burden for the data collection and computer storage requirements. On a real-world study using the travel speed data[1] collected in Seoul, we evaluate performance of neural network model and compare with Park & Song model[2] that employs the least square method.

1. 서론

배차계획시스템(Truck Dispatching System)을 위해 중요한 기본 입력자료는 두 지점사이의 이동시간이다. 차량이동시간은 두 지점사이의 거리와 차량이동속도에 의해 결정된다. 대부분의 배차계획시스템에서는 차량의 이동속도를 항상 일정한 것으로 가정하고 있다. 만일 차량이동속도가 일정하면, 두 지점간 이동시간은 이동거리에 비례하게 된다. 그러나 도시는 도로망이 복잡하고 상습적인 교통체증이 존재하기 때문에 차량이동속도는 항상 일정할 수 없으며 차량이 이동하는 장소와 시점에 따라 달라진다[1].

이에 따라 도시내 서비스를 위한 배차계획시스템에서 일반적으로 차량속도를 일정하게 가정하는 해법이 사용되는데 이때 구해진 해는 그 유효성에 대해 심각한 의의가 제기될 수 있다. 특히, 고객의 방문시간대나 납기와 같은 시간적 제약조건이 존재할 때 해의 유효성은 더 크게 저하될 것이다. 왜냐하면, 일정하게 가정한 차량이동속도와 실제 속도와의 차이에 따라 실제 고객에 대한 방문시각이 배차계획해와 크게 차이가 날 수 있기 때문이다. 차량의 이동속도 변화를 고려한 차량일정문제 해법에 대한 연구는 최근 몇몇 학자들에 의해 시도되기 시작하였다. 대표적으로, 박양병[2], Ahn and Shin[7], Malandraki and Daskin[12] 등을 들 수 있다.

\* 경희대학교 공과대학 산업공학과 박사과정

\*\* 경희대학교 산업공학과

이동위치와 이동시점에 따라 변화하는 차량속도를 고려한 배차계획과 관련하여 제기되는 중요한 문제는 지점간 이동속도(또는 이동시간) 데이터베이스의 구축이다. 지점간 차량의 이동속도가 출발시간대에 따라 달라질 때, 차고지를 포함한  $N$ 개의 방문지점과  $M$ 개의 시간대가 존재하는 경우 총  $MN(N-1)$ 개의 지점간 이동속도 자료가 필요하게 된다. 가령,  $N=100$ 과  $M=100$ 의 경우 총 990,000개의 이동속도 자료가 필요하게 된다.

방문지점과 출발시간대의 수가 어느 한계이상으로 커지면, 엄청난 양의 자료를 수집하는 일과 이들 자료를 컴퓨터에 데이터베이스로 구축하는 일은 실제 거의 불가능하게 된다. 설령 데이터베이스의 구축이 가능하더라도 방대한 양의 자료로 인하여 컴퓨터의 작동이 매우 비효율적일 수 있다. 게다가, 방문지점들이 수시로 새롭게 추가되거나 변경되는 경우에는 그 지점들과 관련된 이동속도 자료의 수집 및 변경이 신속하게 이루어지기 어렵기 때문에 배차계획을 수립하는 데 문제가 발생한다.

Bodin et al.[8]은 차량일정해법들이 실제로 배차계획문제에 기대만큼 활발히 적용되지 못하고 있는 이유는 해법의 비효율성과 함께 엄청난 양의 지점간 차량이동속도(또는 이동시간) 자료요구 때문이라고 주장하고 있다. 따라서 배차계획시스템을 위해 방대한 양의 출발시각(또는 시간대)에 따른 지점간 이동속도의 자료수집 문제와 이들 자료의 컴퓨터저장 문제를 해결할 수 있는 방안에 대한 연구가 매우 절실히 요구된다.

이에 따른 도시내 차량이동속도 추정모델과 관련된 최근의 연구로써 황인식과 이홍철[5], 박양병과 홍성철[4] 등이 있다. 황인식, 이홍철의 교차로간 실시간 주행속도 추정시스템은 시간대와 구역구분을 아주 세부적으로 나누어 고려한 것으로 볼 수 있다. 이러한 경우 추정의 정확도는 높아질 수 있으나 이동속도 자료 수집 문제와 데이터베이스 구축문제는 여전히 남아 있게 된다. 박양병, 홍성철의 연구에서 제안된 Park and Song 모델과 신경망 모델인 NER는 Hill & Benton의 모델[9]보다 추정능력이 뛰어나고 자료수집 및 데이터베이스 구축문제 또한 해결할 수 있음을 입증하였다. 그러나, NER의 경우 동일구역내의 이동속도에 대한 추정능력이 상대적으로 떨어지는 문제점을 가지고 있었다.

따라서 본 논문에서는 도시내의 배차계획을 수립하는데 있어서 출발시각(또는 시간대)에 따라 변화하는 지점간 차량이동속도의 자료수집과 이들의 컴퓨터 데이터베이스 구축에 따른 부담을 덜어주는 한편 정확도에서의 문제점도 해결하기 위한 방안으로서, 새로운 백프로퍼게이션 신경망 모델을 구축하고 도시내 차량이동속도 패턴을 학습시킨다. 실험분석과정에서 서울시 정거속도조사자료를 이용하여 실제 사례를 구성한 후, 기존에 개발된 Park and Song 모델과 제안된 신경망 모델과의 성능을 비교·평가한다.

## 2. 차량이동속도 추정모델

도시내의 변화하는 차량이동속도를 추정하기 위해서 기존에 개발된 모델을 소개하고 차량이동속도 패턴인식을 위한 신경망 모델을 제안한다. 이들은 공통적으로 도시내 서비스 대상지역을 여러 개의 구역으로 나누어 고려하였고 하루동안 허용된 차량이동시간을 여러 개의 시간대로 분할하여 차량의 출발시각(또는 시간대)에 따른 평균이동속도를 추정한다.

배차계획시스템에서 이들 추정모델을 사용하면 필요한 이동속도 자료수집의 양과 컴퓨터 데이터베이스의 크기는 획기적으로 줄어들게 된다. 또한 방문지점들이 새롭게 추가되거나 변경되는 경우에도 새로운 이동속도 자료의 추가 없이 추정모델을 이용하여 간단히 새로운 지점과 기존 지점들 사이의 이동속도를 추정할 수 있게 된다. 이에 따라 배차계획을 수립하는데 필요한 지점간 이동속도 자료수집과 데이터베이스구축의 문제는 해결될 수 있으나, 추정된 이동속도의 정확성에 대한 문제가 제기된다. 아래에 두 추정모델을 설명한다.

### 2.1 Park and Song 추정모델 (P&S)

Park and Song[3]이 제안한 지점간 속도추정모델은 식 (1)과 같으며, 동일 또는 인접구역에 속한 지점간 평균이동속도만을 추정하는데 사용한다.

$$S_{ijT} = \alpha_i S_{iT} + (1 - \alpha_i) S_{jT}, \quad 0 \leq \alpha_i \leq 1 \quad (1)$$

위 식에서  $I$ 와  $J$ 는 각각  $i$ 와  $j$ 가 속한 구역이다.  $\alpha_i$ 는 거리가  $d_{ij}$ 인  $(i, j)$ 경로에서  $I$ 에 속한 거리의 비율을 나타낸다. 따라서  $1 - \alpha_i$ 는  $I$ 의 인접구역  $J$ 에 속한 거리의 비율을 나타낸다.  $I$ 와  $J$ 가 동일구역인 경우  $\alpha_i = 0.5$ 로 설정한다.  $T$ 는 지점  $i$ 의 출발시각이 속한 시간대이며  $T'$ 는  $J$ 의 진입시간대로서, 지점  $i$ 의 출발시각에  $\alpha_i d_{ij} / S_{ijT}$ 를 더한 시각의 시간대가 된다.

시간대  $L$ 때 구역  $Q$ 에서의 이동속도  $S_{QL}$ 을 구하기 위해서, 동일구역과 인접구역에 속한 지점들에 대해 지점간 이동속도 실측치  $R_{ijT}$ 와 식 1에 의해 추정된  $S_{ijT}$ 의 가중오차합을 최소화하는 가중최소자승법을 적용하여 구역 및 시간대별 평균차량이동속도를 구한다[3].

$$\text{Min } Z = \sum_{T=1}^D \sum_{i \in \zeta(I)} \sum_{j \in \zeta(I)} \sum_{\substack{j \in \zeta(J) \\ j \neq i}} W_{ijT} [R_{ijT} - \{\alpha_i S_{iT} + (1 - \alpha_i) S_{jT}\}]^2 \quad (2)$$

여기서  $\zeta(I)$ 는 구역  $I$ 를 포함한  $I$ 의 인접구역들의 집합을 의미한다.  $W_{ijT}$ 는 오차가중치이며,  $W_{ijT} = R_{ijT} / d_{ij}$ 를 사용한다. 이 식은 시간대  $T$ 에 지점  $i$ 를 출발하여  $j$ 까지의 이동시간의 역수로써, 더 짧은 이동시간을 가지는 지점들간의 오차에 대해 더 민감하게 작용하는 효과를 기대할 수 있다.

두 지점  $i$ 와  $j$ 가 동일 또는 인접구역에 속하지 않고 멀리 떨어져 있는 경우에는 구역 및 시간대별 이동속도를 이용하여  $S_{ijT}$ 를 다음과 같이 간단히 확장하여 추정할 수 있다.[4]

$$S_{ijT} = \sum_{b=0}^B \alpha_b S_{[I_b][T_b]}, \quad \sum_{b=0}^B \alpha_b = 1 \quad (3)$$

여기서  $b$ 는  $(i, j)$  경로상  $b$ 번째 통과구역에 속한 거리의 비율을 뜻한다.  $I_b$ 는  $b$ 번째 통과구역에 해당되는 구역을, 그리고  $T_b$ 는  $b$ 번째 통과구역의 경계선을 진입하는 시점의 시간대를 나타낸다.  $B$ 는  $(i, j)$  경로의 총 통과구역수로서, 동일구역일지라도 구역경계를 넘나드는 경우에는 구역수에 중복해서 가산한다.  $T_1 = T$ 로 간주한다.

추정에서 필요한 실측자료수가 증가할수록 구해진 구역 및 시간대별 이동속도의 정확도는 증가하며 구역과 시간대의 분할을 더욱 세분화하여  $D$ 와  $M$ 의 크기를 늘리면 지점간 이동속도에 대한 추정의 정확도는 증가할 것이다. 지점간 평균이동속도를 추정하기 위해 컴퓨터 데이터 베이스에 저장되는 자료수는  $DM$ 개가 되며  $\alpha_b$ 에 대한 자료저장이 추가로 필요하다.

### 2.2 백프로퍼게이션 신경망 모델 (BNN)

지점간 평균차량이동속도를 추정하는 문제는 함수 근사(function approximation) 또는 비선형 회귀(nonlinear regression)와 관련된 것으로 볼 수 있기 때문에, 신경망 모델[6]을 이용하여 접근

할 수 있다. 인공지능 모델링 기법인 신경망 모델은 현재 교통 및 수송분야에서 큰 관심을 얻고 있으며, 주로 교통량 예측, 차량이동거리 추정, 교통신호제어, 수송계획 등의 문제에 적용되어 왔다. 특히, 이 차량이동속도 추정에서 사용되는 백프로퍼게이션 신경망 모델(BNN)은 여러 신경망 모델들 중 가장 널리 이용되어온 모델이다.[11]




그림 1. 백프로퍼게이션 신경망 모델

그림 1에서와 같이 BNN은 각각 1개씩의 입력층, 은닉층, 출력층으로 구성되어 있으며, 입력층에서는 위치정보, 출발구역, 도착구역, 출발시간대 등의 4가지 종류의 입력을  $L$ 개의 요소들을 통해서 입력받고, 은닉층의  $K$ 개 요소에서 가중된 입력값을 합하여 그 결과를 출력층으로 전달한다. 출력은 지점간 평균이동속도이다. BNN은 이러한 네트워크의 구조를 통해 입력과 출력사이의 관계에 대한 학습을 수행하게 되고 이러한 구조의 표현방법, 즉 은닉층의 수 및 크기, 입.출력요소의 정의방법 등에 따라 다양한 모델로 구성될 수 있다.

BNN의 작동식은 다음과 같다.

$$F(I/\tilde{T}, \tilde{W}) = \sum_{h=1}^K T_h \sum_{l=1}^L I_l W_{lh} + T_0 B \quad (4)$$

위 식에서  $I_l$ 은 입력벡터  $I$ 에서  $l$ 번째 요소 값을, 그리고  $W_{lh}$ 는 은닉층 요소  $h$ 에 대해서  $l$ 번째 입력요소 값의 가중치를 나타낸다.  $B$ 는 은닉층의 편차를, 그리고  $T_h$ 와  $T_0$ 은 각각 출력에 대한 은닉층 요소  $h$ 와 편차  $B$ 의 가중치를 나타낸다. 그리고 각 층의 요소들에 대해 구해진 값의 평활화를 위해 다음과 같은 비선형 활성화 함수식을 사용한다.

$$f(x) = 1/[1 + \exp(-x)] \quad (5)$$

여기서  $x$ 는 BNN의 각 층에 따라 다른 의미를 갖는다. 즉 입력층의 경우는 각 입력요소의 정규화된 값을, 은닉층의 경우는 은닉층 기저(hidden basis) 함수값을, 그리고 출력층의 경우는  $F(I/\tilde{T}, \tilde{W})$ 를 의미한다.

BNN에서 학습의 정확도를 높이기 위해서는 P&S에서와 같이 가능한 많은 지점간 이동속도 자료가 필요하며, 학습을 위해 상당한 컴퓨터 실행시간이 소요될 것이다. 출발시각에 따른 지점간 이동속도를 추정하기 위해서는 학습과정 결과로 생성된 추정모듈 프로그램파일이 필요하다. 이 파일에 저장되는 자료수는  $L$ 를 입력 요소의 수,  $H$ 를 은닉 요소의 수라고 할 때  $(L+1)H$

개의 입력층 가중치와  $H+1$ 개의 은닉층 가중치의 합이 된다.

BNN은 입/출력 자료를 근거로 가중치를 학습하게 된다. 그리고 복잡하고 입/출력 자료의 비선형 관계를 효과적으로 표현하는 것으로 알려져 있다.

### 3. 실험분석

출발시각에 따라 변화하는 지점간 평균운행속도를 추정하기 위해 제안된 두가지 모델의 정확성을 비교 평가하는 실험을 수행하였다. 실험을 위해 서울시 일부에 대하여 그림 2와 같이 행정구역 단위로 10개 구역으로 나누어 전지역에 걸쳐 총 25개 지점을 선정하였다. 그리고 일일 차량운행시간을 다음과 같이 분할하였다: 8:00~10:00(시간대 1), 10:00~11:00(시간대 2), 11:00~13:00(시간대 3), 13:00~14:00(시간대 4), 14:00~17:00(시간대 5). 출발시각에 따른 지점간 이동속도는 서울시 교통관리사업소에서 수집한 서울시 승용차 속도조사자료[1]를 토대로 구하였다.

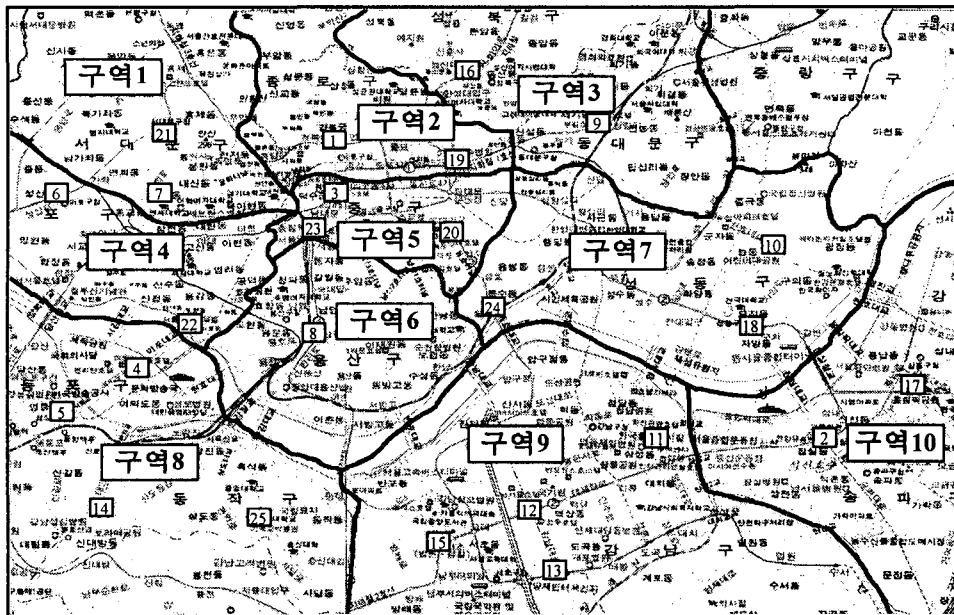


그림 2. 서울시 구역분할과 지점위치

BNN은 1개의 은닉층을 가지고 있으며 입력 요소는 15개, 은닉 요소는 10개, 출력요소는 1개로 구성되어 있다. BNN의 입력벡터 ( $\vec{I}$ )는 다음과 같이 정의하였다.

$$\vec{I} = ( X_i, Y_i, X_j, Y_j, [i], [j], T ) \tag{7}$$

여기서,  $(X_i, Y_i)$ 는 출발지점  $i$ 의 좌표이고,  $(X_j, Y_j)$ 는 도착지점  $j$ 의 좌표이다. 그리고  $[i]$ ,  $[j]$ 는 각각 출발지점  $i$ 와 도착지점  $j$ 가 속한 구역번호이며,  $T$ 는 출발시간대이다. 그리고 출력값은 지점간 평균이동속도이다.

입력벡터에서 출발구역, 도착구역 번호와 출발시간대는 2진수로 표현하였고 좌표값( $X_i, Y_i$ ,

$X_i, Y_j$ )은 10진수로 표현하였으나 [0.0 ~ 1.0] 사이의 값으로 정규화 하였다. 출발지점 및 도착지점의 좌표에 대한 입력은 구역(또는 지점)간 상대적인 위치정보를 간접적으로 학습시키기 위한 목적으로 사용되었다.

계산실험을 위해 Park & Song 모델(P&S)은 포트란언어로 프로그래밍 하였다. 그리고 BNN의 학습을 위해서 WinNN 0.97 소프트웨어를 사용하였다. WinNN 0.97은 인터넷 ftp 사이트 ftp://ftp.cc.monash.edu.au로부터 다운로드 받을 수 있다. WinNN 0.97은 모멘텀(momentum)이 존재하는 백프로퍼게이션 학습알고리즘[11]을 사용하고 있다. BNN의 모든 가중치의 초기값은 임의로 [-1.0, 1.0] 사이의 값을 할당하였으며, 입력층과 은닉층에서의 편차는 모두 -1로 설정하였다. BNN의 은닉층의 크기는 은닉요소의 수를 5개에서 10개까지 1개씩 늘려가면서 학습횟수를 1000회까지 실험한 결과 오차율이 가장 빠르게 수렴한 결과를 바탕으로 10개로 정하였다. 모멘텀과 학습계수의 초기값은 각각 0.1과 0.8을 사용하였으며, 학습과정이 진행됨에 따라 수렴하도록 변화시켰다.

제안된 추정모델의 정확도에 대하여 P&S와 비교.평가실험을 위해서 총 1480개의 지점간 이동속도 자료를 두 모델에 적용하였다. 이중 1355개는 분석자료로 추정모델 구축하는 데에 사용하였고 나머지 125개 자료는 예측자료로 사용하였다. 그러나 실제 P&S의 경우에는 구역 및 시간대별 이동속도를 구하는데 1115개의 자료만이 사용되었다. 이것은 P&S에서는 동일 및 인접구역에 속한 지점간 이동속도 자료만이 구역 및 시간대별 속도추정에 사용되기 때문이다. 따라서 P&S의 두지점이 서로 먼구역에 위치한 경우의 오차는 실제로는 모두 예측오차이다. 모든 실험은 IBM호환 PC(MMX 200MHz, 64M RAM)에서 수행되었다. 실험결과 얻어진 두 추정모델의 평균오차가 표 1에 정리되어 있다. 추정오차는 |실측치 - 추정치|의 값이다. 이것은 절대오차로써 추정속도오차의 크기를 비교하기 위해 사용하였고 오차율(%)은 |실측치 - 추정치|/실측치로써 실측치와 추정치 간에 상대적인 차이의 비율을 나타내었다. 이 오차율을 통하여 두 추정모델의 정확도의 차이를 보다 객관적으로 비교할 수 있다.

표1. 두가지 추정모델의 평균오차

(단위: km/h)

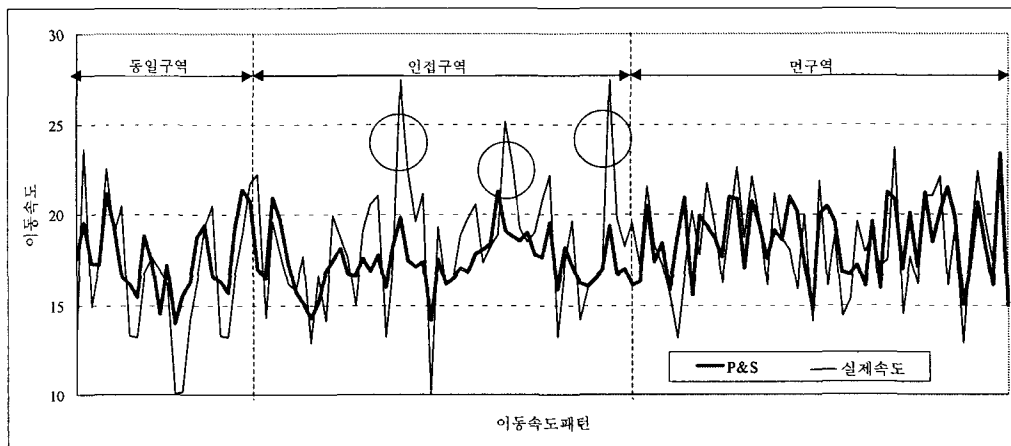
두지점의 위치	BNN		P&S		평균속도(19.33km/h)	
	분석자료	예측자료	분석자료	예측자료	분석자료	예측자료
동일구역내	2.04 (205)	2.19 (25)	2.46 (205)	2.48 (25)	3.29 (205)	3.71 (25)
	11.1%	15.5%	12.9%	16.2%	19.0%	26.0%
인접구역내	1.76 (910)	1.64 (50)	3.26 (910)	2.20 (50)	3.41 (910)	2.61 (50)
	9.3%	9.3%	15.7%	11.7%	17.8%	15.6%
먼구역내	1.35 (240)	1.95 (50)	1.97 (240)	1.90 (50)	2.44 (240)	2.36 (50)
	7.6%	10.5%	10.9%	10.8%	14.1%	13.7%
전 구역내	1.74 (1480)		2.84 (1480)		3.18 (1480)	
	9.4%		14.3%		17.3%	

\* 괄호안의 숫자는 사용된 자료수임.


표 1로부터, BNN의 전 구역내 지점간 이동속도 추정오차가 평균 1.74km/h로 P&S보다 전반적으로 우수한 결과를 나타냈으며 오차율에서도 5% 가량 더 정확한 결과를 나타냈다. 그러나 BNN과 P&S의 추정결과는 서울시 차량속도가 주로 15 ~ 50km/h범위에서 변화하고 이동구역과 이동시간대에 따라 그 변화차이가 대부분 5%의 에러율로써 유의하다는 사실[4]에 비추어 상당히 정확한 것을 알 수 있다. 한편, 두 추정모델을 도시내 배차계획시스템에 적용시 필요로 하는 컴퓨터 데이터베이스의 크기는 모두다 획기적으로 줄일 수 있다.

표 1에서 전체평균속도는 일반적으로 배차계획시스템에서처럼 평균속도(19.33km/h는 분석 자료에 대한 평균임)를 사용하는 경우에 발생하는 오차를 구한 것이다. 물론 데이터베이스에 소요되는 자료수는 1개이나 정확도가 크게 떨어지게 된다. 이러한 평균속도를 사용할 때 발생하는 오차를 100%로 할 때, 전체적으로 P&S는 89.6%, BNN은 54.9%의 추정오차를 갖게된다. BNN의 경우 거의 절반수준의 오차로 크게 줄일 수 있다. 위 표에서 인접구역 및 먼구역에 대하여 예측자료에 대한 오차가 분석자료보다 더 작게 나온 것은 임의로 선택된 예측자료가 분석자료에 비해 평균속도와와의 편차가 작음으로서 나타난 현상이라 볼 수 있다. 이것은 평균속도 (19.33km/h)에 대한 오차를 통해서도 간접적으로 알 수 있다.

두 추정모델의 예측결과를 그림 3을 통해 좀더 자세히 살펴보면, 실제이동속도패턴은 10km ~ 27.5km 사이에서 복잡하게 변화하고 있으며, 두 추정모델의 예측결과가 그 패턴을 따라 가고 있음을 확인할 수 있다. 특히, 인접구역에 대하여 표시된 부분을 보면 갑자기 크게 변화(noise)하는 패턴에 대해서 BNN이 P&S보다 우수한 결과를 나타냄을 알 수 있다. 이것은 신경망 모델이 수학적 모델에 비해 비선형이며 불규칙한 자료의 예측에 대해 장점을 가지고 있다는 사실을 그대로 나타내고 있는 것이다.

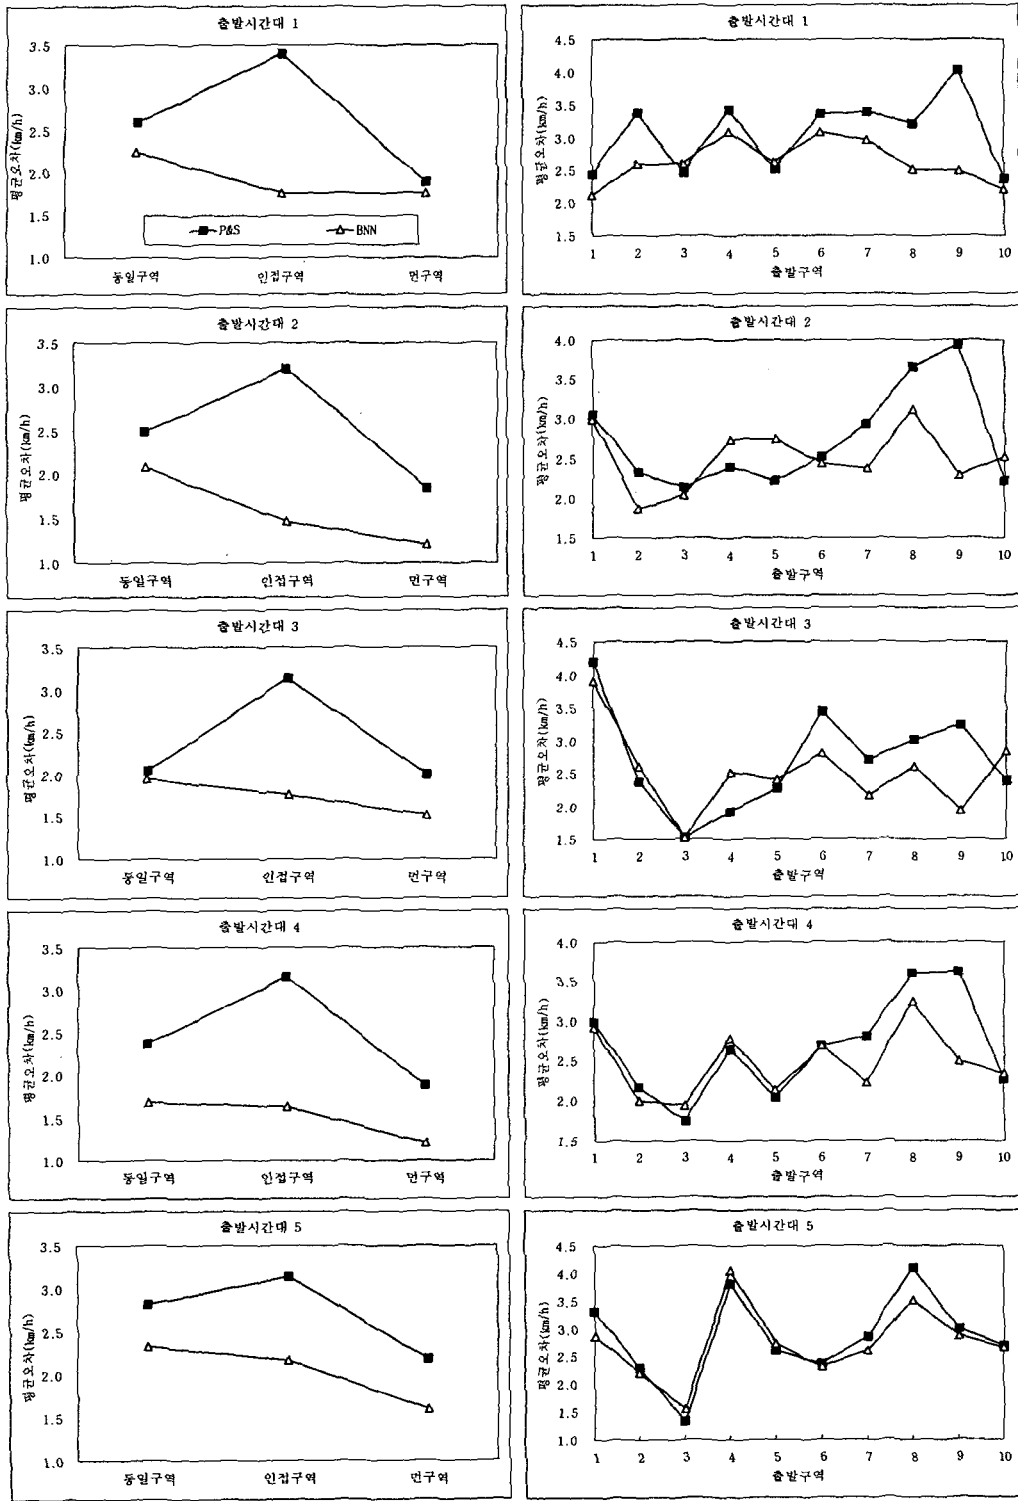


(a) P&S 모델의 추정결과



(b) BNN의 추정결과

그림 3 예측자료에 대한 두 모델의 추정결과



(a) 두 지점의 위치별 평균오차

(b) 출발구역별 평균오차

그림 4. 두 지점의 위치와 출발구역별 출발시간대에 대한 두 추정모델의 평균오차



그림 4는 두 지점의 위치와 출발구역별로 각각 5개의 출발시간대에 대한 두 추정모델의 평균오차를 그래프로 보여준다. 먼저, 두 지점의 위치별 평균오차를 살펴보면 모든 경우에서 BNN의 추정능력이 P&S보다 뛰어나다. 특히, 앞서 언급한 것과 같이 인접구역에 대해서 추정능력의 차이가 크게 나타났고 BNN의 경우, 모든 시간대에서 두지점의 위치가 멀수록 추정오차가 작아지는 경향을 나타냈다.

다음으로, 출발구역별 평균오차를 살펴보면 출발시간대에 따라서는 특별한 경향을 보이지 않으나, 모든 시간대에서 구역 6 ~ 10에서 BNN의 추정오차가 작게 나타났다. 그리고 두 모델이 모두 구역 1, 6, 7, 8, 9에서 추정오차가 상대적으로 크게 나타났는데 그림 3에 나타난 바와 같이 서울의 중심과 강남지역 등에 해당된다. 이들 구역들은 서울시 정기속도조사 자료를 분석해 본 결과 시간대별 속도변화가 평균이상으로 심한 곳이다.

#### 4. 결론

차량속도의 변화를 고려하는 도시내 배차계획과 관련하여 제기되는 중요한 문제는 지점간 이동속도(또는 이동시간)의 자료수집과 컴퓨터 데이터베이스의 구축이다. 이 문제를 해결하기 위한 방안으로서, 출발시간대에 따른 지점간 운행속도를 추정하는 신경망 모델을 제안하였다. 제안된 신경망 모델의 정확도를 평가하기 위해서 서울시내의 실제 차량속도 조사자료를 이용하여 자세한 계산실험을 수행하였다. 실험결과, 추정의 정확도 측면에서 거의 모든 경우 신경망 모델인 BNN의 결과가 우수하게 나타났다. 특히 갑자기 크게 변화하는 자료에 대하여도 우수한 추정능력을 보여 주었다. 두 모델에서 필요로 하는 데이터베이스의 자료수는 획기적으로 줄어들며, 서로 크기의 차가 거의 없다. 그러나, 신경망 모델을 학습시키는 데는 많은 시간과 노력이 필요하다.

결국, 배차계획시스템에서 도시내 지점간 차량이동속도를 추정하는 모델의 선택은 추정모델의 정확성과 사용의 용이성에 의해 결정된다고 말할 수 있다. 즉, 추정의 정확성 관점에서는 BNN이 그리고 사용의 용이성 관점에서는 P&S가 장점을 가지고 있다. 그러나 실제 배차계획시스템에서 본 추정모델들을 사용하기 위해서는 보다 정확하고 효과적인 이동속도 입력자료의 데이터베이스 구축이 필요하다. 이것은 GPS(Global Positioning System) 및 GIS(Geographic Information System)와의 연계를 통해서 얻어진 정확한 이동속도자료를 온라인으로 입력받음으로써 구현할 수 있을 것이다. 이러한 방법으로 얻어진 이동속도자료를 바탕으로 정확한 추정모델을 구축하여야 하고 구역구분 및 시간대 구분 또한 다양한 실험을 통하여 결정해야 할 것이다.

#### 참고문헌

- [1] 97 서울시 정기속도조사 결과, 서울특별시 교통관리사업소, 1997.
- [2] 박양병, "시간대 및 구역의존 차량이동속도를 고려하는 다목적차량일정문제: 일정계획해법과 전문가시스템", 대한산업공학회지, 제23권, 제4호, 1997.
- [3] 박양병, 송성현, "구역 및 시간의존 차량스케줄링문제: 차량속도 추정모델과 차량스케줄링해법", 대한산업공학회지, 제22권, 제3호, pp.517-532, 1996.
- [4] 박양병, 홍성철, "차량일정계획을 위한 도시내 차량이동속도 추정모델에 대한 연구", 산업공학, 제11권, 제1호, pp.75-84, 1998.
- [5] 황인석, 이홍철, "Hybrid Neuro-Fuzzy 기술을 이용한 교차로간 실시간 주행속도 추정시스템 개발", 대한산업공학회 '98추계학술대회 논문집, 고려대학교, 1998.

- [6] Alpaydin, E., Altinel, K. and Aras, N., "Parametric Distance Function vs. Nonparametric Neural Networks for Estimating Road Travel Distances", *European Journal of Operational Research*, Vol.92, pp.230-243, 1996.
- [7] Ahn, B. and Shin, J., "Vehicle-Routing with Time Windows and Time-Varying Congestion", *Journal of Operational Research Society*, Vol.42, No.5, pp.393-400, 1991.
- [8] Bodin, L., Golden, B., Assad A. and Ball M., "Routing and Scheduling of Vehicles and Crews, The State of the Art", *Computers and Operations Research*, Vol.10, pp.63-211, 1983.
- [9] Hill, V. and Benton, W., "Modeling Intra-City Time-Dependent Travel Speeds for Vehicle Scheduling Problems", *Journal of Operational Research Society*, Vol.43, No.4, pp.343-351, 1992.
- [10] Laporte, G., "The Vehicle Routing Problem: An Overview of Exact and Approximate Algorithms", *European Journal of Operational Research*, Vol.59, pp.345-358, 1992.
- [11] Laurene, F., *Fundamentals of Neural Networks: Architectures, Algorithms, and Applications*, Prentice-Hall, 1994.
- [12] Malandraki, C. and Daskin, M., "Time Dependent Vehicle Routing Problems: Formulation, Properties and Heuristic Algorithms", *Transportation Science*, Vol.26, No.3, pp.185-200, 1992.