

■ 論 文 ■

高速道路 實時間 交通量 豫測을 위한 人工神經網 입출력 요소分析

I/O factors of neural networks for
forecasting real-time traffic volume of freeway

조 중 래

(명지대학교 교통공학과 교수)

김 현 주

((주)한국 벤 선임연구원)

목 차

- | | |
|----------------|-----------------|
| I. 서론 | IV. 학습 및 test과정 |
| II. 모형 | V. 분석결과 |
| 1. 신경망 이론 | 1. 모형A |
| 2. 교통량 예측모형 | 2. 모형B |
| III. 자료 | 3. 모형C |
| 1. 자료의 종류 및 특성 | VI. 결론 |
| 2. 자료의 필터링 | 참고문헌 |

요 약

인공신경망을 이용하여 고속도로 교통량을 예측함에 있어, 입력요소에 따른 예측력의 차이를 분석하였다. 입력요소의 차이는 크게 공간적 지점의 차이와 시간적 시점의 차이로 구분하였다. 우선 공간적 지점에 관한 입력요소로는 두 가지 경우를 가정하였는 바, 그 하나는 상류지점의 교통량만을 입력요소로 사용한 경우이며, 나머지는 목표지점에 대한 상·하류지점의 교통량을 입력요소로 사용한 경우이다. 시간적 시점의 관점에서는 단일시점과 다중시점으로 입력요소를 구분하였다.

경부고속도로 FTMS자료를 이용하여 분석한 사례연구의 결과, 미래 시점의 교통량을 예측할 때 모형의 입력요소로 상류지점의 교통량만을 단독으로 사용했을 때보다 상·하류지점의 자료를 사용했을 때 예측력은 훨씬 높아지는 것으로 분석되었다.

I. 서론

지난 1970년대 이후 지금까지 우리나라 교통문제에 대한 사회적 정책기조는 크게 세 가지로 대별될 수 있다. 1980년대 중반까지의 시설공급정책, 1980년대 말부터 1990년대 초에 이르는 수요조절정책, 그리고 1990년대 중반이후 본격적으로 검토되고 있는 첨단교통관리체계를 중심으로 한 교통운영정책이 그것이다. 이중 과학적 기술의 진보, 특히 통신기술의 괄목할 만한 발전을 기반으로 추진되고있는 첨단교통 및 운영관리기법은 고비용구조에 따른 공급정책의 한계와, 사회적 생산성을 약화시킬 수도 있다는 수요조절정책의 한계를 극복할 수 있다는 점에서 당분간 우리나라 교통정책의 주요정책기조로 자리매김 할 것으로 판단된다. 때문에 교통부문의 연구개발방향도 이와 동일한 궤를 따라 변화될 것이며, 이러한 경향의 하나로 최근 보다 정확하고 효율적인 교통정보의 '생산'과 '공급'에 관련된 기술개발에 대한 연구수요가 급증하고 있다.

다양한 종류의 교통정보 중 통행자의 노선선택과 그에 따른 가로망 체계의 효율성 제고의 측면에서 무엇보다도 중요한 것은 실시간 및 단기에측 교통량 혹은 통행시간 관련 정보이다. 이러한 점에서, 최근 5년여 동안 실시간 교통량 예측을 위한 많은 기법들이 개발되고 연구결과 등이 발표되어 왔는 바, 신경망이론은 실시간 교통량 혹은 통행시간 예측을 위하여 많이 적용되어온 기법 중의 하나이다.

그간 신경의학연구분야에서 기원한 신경망이론은 '밝혀지지 않은 시스템(Unknown System)'에 대한 비선형적 예측가능성 때문에 최근 교통분야에서의 이용이 급격히 확대되고 있다. 교통분야에서는 <표 1>에서 보여지듯이 운전자 행태, 파라미터 추정, 도로 포장, 유고감지, 교통패턴 분석, 화물운영, 해상교통 등에 적용되어 왔다. 대표적인 것으로 운전자 경로선택을 주제로 통계적 로짓 모형과 신경망을 비교 분석한 연구가 있고(Dougherty, M. and M. Joint, 1992), ATIS 분야에서 교통정보가 운전자 행태에 어떤 영향을 미치며 운전자들이 교통정보를 어떻게 받아들이고 사용하며, 이로 인한 교통망 전체에 미치는 영향을 파악하기 위해 시도된 연구도 있다(Yang, H., et. al,

1993). 또한 고속도로 교통류의 거시적 모형 수립에도 적용되었으며(Zang, H. and S.G. Ritchie, 1993), 교통량 조사로부터 실시간 O-D교통량 확인에도 신경망이 이용되었다(Yang, H., T. Akiyama and T. Sasaki, 1992).그러나 이렇게 다양한 분야에서 적용되고 있는 신경망이론은 입력과 출력간의 인과관계를 설명하지 못한다는 측면에서 이론적인 한계를 가지며, 바로 이것이 신경망이론이 그 예측력의 우월성에도 불구하고 전통적 회귀분석모형에 비하여 이론적 타월성을 확보하지 못하는 이유이다. 또한 이러한 신경망 이론의 한계로 인하여 교통분야에 있어서의 신경망 이론에 관한 기존의 대부분의 연구들이 단순히 이론의 적용가능성의 고찰이나 학습방법 및 결과에 관한 분석, 그리고 예측결과에 대한 타 모형과의 비교분석에 그 초점을 두어 왔을 뿐, 연구대상 시스템의 구조적 이해를 위하여 보다 중요한 입출력요소의 상관관계를 분석하고자 하는 연구노력은 거의 없었다고 해도 과언이 아니다.

이러한 점에서 본 연구에서는 교통정보 예측에 기본적으로 필요한 실시간 교통량을 예측하는 데 있어 입력요소의 형태가 출력의 결과, 즉 예측력에 어떻게 영향을 미치게 되고 따라서 어떠한 입력요소가 가장

<표 1> 인공신경망 이론의 교통분야에의 적용

관련 분야	논문 수
운전자 행태	12
파라미터 추정	7
포장 유지	6
차량 감지 / 분류	5
교통패턴 분석	5
화물 운영	4
교통량 예측	4
교통정책 / 경제	2
항공교통	2
해상교통	2
잠수함 1	
Metro 운영	1
교통제어	1

자료 : Dougherty, M., A Review of Neural Networks Applied To Transport, Transportation Research, vol.3, No.4, pp.247 ~ 260, 1995.

적절한지를 분석해 보고자 하였다. 먼저 미래 교통량에 영향을 줄 수 있는 여러 가지 요인(상류지점의 교통량, 속도, 점유율, 하류지점의 교통량)을 선정하여 다양한 입출력요소를 갖는 예측모형을 수립하였고, 이 모형들의 학습 및 test 결과를 통해 입력요소의 적

절성을 평가하고 가장 높은 예측력을 갖는 모형을 판단하였다.

이를 위하여 지금까지 개발된 다양한 신경망 모형 중에서 다층선행신경망(MLF:Multi Layer Feedforward)을 사용하였으며, 학습 알고리즘은 모형을 통해 추정된 추정치와 실제 관찰치의 오차를 최소화하는 기법인 역전파법(Backpropagation)을 사용하였다. 입출력 자료로는 경부고속도로 상행 50.3Km~60Km 구간 사이에 설치된 FTMS의 검지기 자료를 사용하였다¹⁾.

Ⅱ장에서는 입출력 요소에 따른 다양한 형태의 모형들과 각 모형의 특성이 설명되었고, Ⅲ장에서는 사용된 자료의 종류 및 특성, 자료의 필터링 과정이 설명되었다. Ⅳ장에서는 모형들의 학습 및 test 과정이 설명되었고, Ⅴ장에서는 학습 및 test 결과를 위주로 입력요소의 적합성에 대한 상대비교와 모형들의 예측력을 분석하였다.

II. 모형

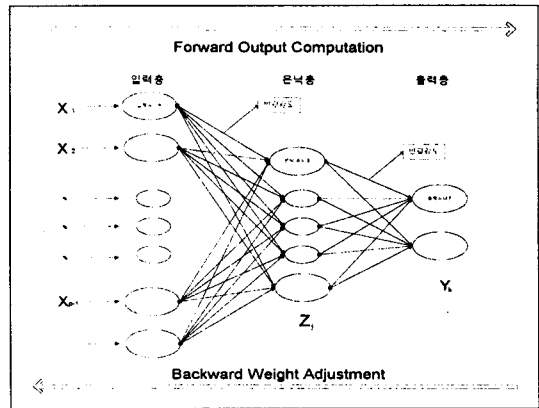
1. 신경망 이론

다층선행신경망(이하 MLF로 표현)은 하나 이상의 은닉층을 가진 인공신경망으로 여러 개의 유닛가 모여서 각각 입력층, 은닉층, 출력층을 형성하고 있고, 각층 사이의 유닛간 연결은 한방향으로만 되어 있으며, 각 층안에서 유닛간 연결은 존재하지 않는다.

MLF의 진행과정을 살펴보면 다음과 같다. 입력층에서는 단순히 입력신호만을 받고 그것을 은닉층의 각 유닛으로 분산시키면 은닉층의 유닛들이 입력층과 은닉층 사이의 연결강도가 곱해진 입력신호를 받아들인다. 그러면 입력신호와 은닉유닛 안의 임계값과의 차이를 비선형함수인 전이함수를 통해 변환하고, 그 변환된 값이 같은 원리로 출력층으로 분산되어져 출력유닛안에서 은닉층에서와 동일한 과정을

거쳐 결과치를 출력하는 것이다.

여기서 출력된 결과치와 목표값과의 차이가 네트워크의 오차가 되는데 이 오차가 출력층에서 은닉층으로 은닉층에서 입력층으로 전달되면서 각 층간의 연결강도가 변하고 변한 연결강도로 네트워크가 잠시 고정된다. 그런 다음 반복해서 결과치를 도출하는 과정을 거친 후 결국에는 결과치와 목표값과의 차이가 사용자가 지정한 최소값 이하가 되도록 네트워크의 연결강도를 조정하게 되는 역전파법 학습알고리즘을 이용하여 학습을 하게 된다. 학습을 통해서 네트워크가 비교적 정확한 결과치를 출력하게 될 때 학습에 사용되지 않은 자료를 네트워크에 입력함으로써 결과값을 예측할 수 있게 된다. 일반적인 MLF 모형의 구조는 다음과 같다.



〈그림 1〉 다층선행신경망(MLF)의 구조


2. 교통량 예측 모형

본 장에서는 한 지점의 미래 시점의 교통량을 예측하기 위해 크게 3가지 형태로 나눠서 예측 모형을 구성하였다. 먼저 모형A는 상류지점의 위치와 입력요소의 시점, 그리고 입력변수의 변화가 목표지점 교통량 예측에 어떠한 영향을 미치는지를 분석하고자 하는 것으로, 상류지점의 자료만을 이용하여 교통량을

1) 본 대상지역은 안성~오산 사이의 지역으로 합류/분류 분기가 없는 지역이다. 본 연구의 목적은 일차적으로 인공신경망을 통하여 고속도로 교통량을 예측함에 있어 상·하류의 어떤 지점의 어떤 시점의 교통량이 목표지점의 교통량 예측에 중요한 영향을 미치는가를 비교 분석하고자 하는 것으로, 동일한 기준에서 보다 객관인 분석을 위하여 충격요인이 적은 단순교통류를 갖는 지역을 분석 대상지역으로 선정하였다.

예측하게 되는 모형A는 사용된 자료의 종류에 따라 5가지의 하위모형으로 세분화된다. 하류지점의 교통량이 목표지점의 교통량 예측에 어떠한 영향을 미치게 되는가를 분석하기 위하여 설정된 모형 B는 상류 지점과 하류지점의 자료를 동시에 이용하여 교통량을 예측한다는 점에서 모형A와 구별된다. 목표지점 교통량의 예측시점의 문제, 즉 출력요소의 시점의 문제를 다루는 모형C는 상류지점의 자료만을 사용한다는 데서 모형A와 같지만 예측시점이 단일시점이 아닌 복수시점이라는 데서 그 차이가 있다.

이러한 모형들을 구성하기 위하여 본 연구에서는 경부고속도로 상행선 차량감지시스템의 자료를 이용하였는 바, 입출력 요소로 사용된 자료의 교통류 흐름상의 공간적 위치관계는 <그림 2>와 같다.



<그림 2> 차량감지시스템의 위치

1) 모형A

모형A는 상류지점의 자료만을 이용해서 목표지점의 미래 한 시점의 교통량을 예측하는 것으로 입력요소의 공간적 지점은 모두 상류에 속하며 크게 단일지점, 다중지점으로 나뉘지고, 입력자료의 시점 역시 단일시점과 다중시점으로 나뉜다. 또한 교통량만을 입력요소로 하는 모형과 교통량, 속도, 점유율을 포함하는 모형으로 구분된다.

먼저 모형A1은 목표지점의 이전 시점의 교통량을 이용해서 목표지점의 미래시점의 교통량을 예측하는 것으로, 시계열 자료의 특성을 이용하여 추세를 반영하도록 모형을 구성한 것이고, 모형A2는 목표지점의 상류지점의 교통량을 입력요소로 하는 것으로, 바로 인접한 상류지점의 상태가 목표지점에 영향을 끼칠 것이라는 가정 하에서 구성된 모형이다. 모형A3은 목표지점의 상류 4개 지점의 과거 시점의 교통량을 입력 요소로 하는 모형인데, 인접한 한 지점의 과거 시

점들의 교통량을 입력요소로 했을 때와 비교하기 위해 여러 상류지점의 과거 한 시점의 교통량을 입력 요소로 사용하였다.

<표 2> 모형A의 입출력 특성

입출력요소	INPUT 요소				OUTPUT 요소		비 고
	상류 지점	하류 지점	단일 시점	다중 시점	단일 시점	다중 시점	
모형구분	A1	목표지점과 동일			√	√	
모형A	A2	√			√	√	
	A3	√			√	√	
	A4	√			√	√	
	A5	√		√		√	입력자료는 속도 교통량 점유율

<표 3> 모형A의 입출력요소

구 분	입 력 요 소	출 력 요 소	
목표지점 P _t 목표지점 t	A1	V(P _{A,t-1}), V(P _{A,t-2}), V(P _{A,t-3})	V(P _{t,t})
	A2	V(P _{A,t-1}), V(P _{A,t-2}), V(P _{A,t-3})	V(P _{t,t})
	A3	V(P _{A,t-1}), V(P _{B,t-2}), V(P _{C,t-3}), V(P _{D,t-4})	V(P _{t,t})
	A4	V(P _{A,t-1}), V(P _{B,t-2}), V(P _{C,t-4}), V(P _{D,t-5})	V(P _{t,t})
	A5	V(P _{A,t-1}), S(P _{A,t-1}), OCC(P _{A,t-1})	V(P _{t,t})

* V(P_{A,t-1}) : P_A 지점의 t-1 시점의 교통량
 S(P_{A,t-1}) : P_A 지점의 t-1 시점의 속도
 OCC(P_{A,t-1}) : P_A 지점의 t-1 시점의 점유율

모형A4는 상류 4개 지점의 과거 한 시점의 교통량을 입력요소로 한다는 측면에서는 모형A3과 같지만, 모형A3이 상류지점들과 목표지점간의 거리를 고려하지 않고 동일한 시간간격을 적용한 반면 모형A4는 각각의 상류지점에서 목표지점까지의 거리를 통행속도를 고려하여 통행시간을 산출한 후 이에 대응되는 과거 시점의 자료를 사용한다는 것이 다르다.

모형A5에서는, 위 4개의 모형들이 모두 교통량만을 입력요소로 사용하는 것과 달리, 감지기에서 관측되는 자료 중 평균 차종길이를 제외한 나머지 모든 자료를 입력요소로 사용하였다. 이는 교통량과 점유율, 속도간의 상관관계를 이용하여 목표 교통량을 예측하려는 의도로 구성되어졌다. 이 모형에서는 상류 한 개 지점의 과거 한 시점의 값만을 입력요소로 한다.

2) 모형B

모형B는 고속도로 상에서 하류 지점에 사고가 발생했을 경우 이로 인한 충격파가 상류 교통류에 영향을 미치듯이 상·하류의 교통상태가 목표지점의 교통류에 영향을 미칠 것이라는 가정 하에서 구성된 것이다.

모형B 중에서 모형B1(a)와 B1(b)는 모형A 중, 상류 한 지점의 교통량을 입력요소로 하는 모형인 A2를 재구성한 것이며, 모형B2(a)와 B2(b)는 상류 여러 지점의 교통량을 입력요소로 하는 모형인 A3을 재구성한 것이다. 이 가운데 모형B1(b)과 B2(b)는 상·하류지점의 교통량을 입력요소로 하며, B1(a)와 B2(a)는 모형A에서와 같이 상류지점의 교통량만을 입력요소로 하는 바, 이들은 각각 모형B1(b)과 B2(b)에 대한 참조모형으로서 구성되었다.

〈표 4〉 모형B의 입출력 특성

모형구분	입출력요소	INPUT 요소				OUTPUT 요소		비 고
		상류 지점	하류 지점	단일 시점	다중 시점	단일 시점	다중 시점	
모형B	B1(a)	√				√	√	참조모형(A2)
	B1(b)	√	√			√	√	비교모형
	B2(a)	√				√	√	참조모형(A3)
	B2(b)	√	√			√	√	비교모형

〈표 5〉 모형B의 입출력요소

구 분	입 력 요소			출 력 요소
목표지점 _A	BI(a)	V(P _{B,t-1}), V(P _{B,t-2}), V(P _{B,t-3})		V(P _{A,t})
목표지점 _t	BI(b)	V(P _{B,t-1}), V(P _{B,t-2}), V(P _{B,t-3}), V(P _{X,t-1})		V(P _{A,t})
	E2(a)	V(P _{B,t-1}), V(P _{C,t-2}), V(P _{B,t-3})		V(P _{A,t})
	E2(b)	V(P _{B,t-1}), V(P _{C,t-2}), V(P _{B,t-3}), V(P _{X,t-1})		V(P _{A,t})

3) 모형C

모형A와 B가 한 지점의 미래 단일 시점의 교통량을 예측하는 것인 데 비해, 모형C는 상류지점의 교통량을 이용하여 목표지점의 미래 여러 시점의 교통량을 예측하는 모형이다. 입력요소의 구성에 있어 상류지점의 교통량을 사용한다는 점에서는 모형A와 같으나, 예측 시점이 미래 한 시점이 아닌 2~3개 시점이라는 것이 다르다. C1은 모형A2를 재구성한 것이며 C2는 모형A3을 재구성한 것으로, t 및 t+1시점의 교통량을 예측하도록 구성하였다.

〈표 6〉 모형C의 입출력 특성

모형구분	입출력요소	INPUT 요소				OUTPUT 요소		비 고
		상류 지점	하류 지점	단일 시점	다중 시점	단일 시점	다중 시점	
모형C	C1	√				√	√	참조모형(A2)
	C2	√				√	√	참조모형(A3)

〈표 7〉 모형C의 입출력요소


구 분	입 력 요소			출 력 요소
목표지점 _{Px}	C1	V(P _{A,t-1}), V(P _{A,t-2}), V(P _{A,t-3})		V(P _{X,t}), V(P _{X,t+1})
목표지점 _{t+1}	C2	V(P _{A,t-1}), V(P _{B,t-2}), V(P _{C,t-3}), V(P _{B,t-4})		V(P _{X,t}), V(P _{X,t+1})

III. 자료

1. 자료의 종류 및 특성

고속도로구간의 교통량 예측을 위한 신경망의 입력요소를 분석하기 위하여, 본 연구에서는 경부고속도로 교통관리시스템(FTMS)의 차량감지시스템을 통해 얻어진 실측자료를 이용하였다. 이는 서울을 기점으로 하여 50.3Km, 52.1Km, 56.1Km, 57.8Km 및 60Km 지점에 설치된 5개 지점의 차량감지시스템으로부터 구하여진 것으로, 이 구간은 오산IC와 안성IC 사이로 램프에서의 합류나 분류가 없는 편도 4차선의 고속도로 기본구간에 속한다. 감지시스템을 통한 얻어진 자료는 30초 동안의 교통량[대/30초], 점유율[%], 평균지점속도[m/s] 및 평균차량길이[Cm]인데, 본 연구에서는 교통량, 평균지점속도, 그리고 점유율만을 사용하였다.

자료의 관측시간대는 기상상태가 양호한 96년 9월 10일 오후 10시부터 9월 11일 오전 6시 사이이다. 자료가 수집된 시간대가 이와 같이 심야에서 새벽에 걸쳐 있기 때문에 교통량은 적고, 속도가 높은 자유교통류 상태로 볼 수 있다. 자료전체의 V/C는 0.06~0.83(고속도로 기본구간의 용량을 2200vph로 설정했을 경우), 평균지점속도는 99~133kph 정도이다. 본 연구에서는 30초 간격으로 얻어지는 원자료를 1분 간격으로 재구성하여 사용하였는데, 사용된 총 자료량은 477개로 이중 학습에 사용된 것은 300개(오후 10시~오전 3시)이고, test에 사용된 것은 177개(오전 3시~오전 6시)이다.



〈그림 3〉 자료 수집 구간

2. 자료의 필터링

관측된 자료를 보면, 교통량이 적고 속도가 높으며 교통량과 점유율이 특정한 추세를 나타내는 자료가 있는가 하면, 어떤 자료는 매우 변동이 심한 것도 있는데 이는 이들 데이터가 한 지점당 8개씩 설치된 차량감지시스템 자료의 평균값을 사용함에 있어서 한 차선당 2개씩 설치된 8개의 차량감지시스템에서 부분적으로 잘못 감지되거나 또는 루프의 단락으로 인해 잘못된 값(noise)이 도출되었기 때문인 것으로 판단된다. 한 예로 루프의 단락이 생기면 차량감지시스템은 차량이 감지구간에 도착하지 않고 근처에만 있어도 그것을 인식해서 값을 도출하기 때문에 그 값은 정상값에 비해 매우 큰 값을 나타내게 된다. 이런 이유로 본 연구에서는 이들 실측 자료의 Filtering 작업을 수행한 후 모형에 적용하였다. 이 작업을 통하여 8개의 차량감지시스템 가운데 한 차선의 차량감지시스템 2개가 모두 잘못된 경우의 자료들은 제거하였고, 2개의 차량감지시스템중 보통 1개의 차량감지시스템이 잘못된 경우가 많은데 이 자료들은 다른 1개의 정상적인 차량감지시스템 자료값을 이용하여 보정하였다. 이는 속도까지 측정가능한 차량감지시스템의 경우, 두 차량감지시스템간의 간격이 4.5m로 매우 짧아 그 구간에서 교통류의 변화가 없어서 동일한 차선에 설

치된 앞, 뒤 차량감지시스템의 자료값 역시 거의 차이가 없기 때문이다. 속도의 경우는 차선당 한 개씩 밖에 값이 도출되지 않아서 교통량, 점유율과 같은 방식으로는 보정이 되지 않으므로 일반적으로 1차선에서 4차선으로 갈수록 평균속도가 조금씩 낮아지는 추세를 반영하여 값을 보정하였다. <그림 4>는 본 연구에서 사용된 오후 10시~오전 6시 까지 477개 시점의 원자료와 필터링 후의 자료를 도시한 것이다.


IV. 학습 및 test과정

Ⅱ 절에서 도출된 11개의 신경망 모형을 신경망이론을 모형화한 상용 package인 Nworks Professional Ⅱ를 이용하여 학습시켰다. Nworks Professional Ⅱ는 파일형태로 입출력되며, 프로그램 내부에서 사용자가 정의하는 대로 입력층, 은닉층, 출력층이 구성되고 연결강도(weight)와 임계치(threshold)를 설정하고 전이함수(transfer function)와 학습 반복횟수를 정의하면 설정된 값들로 입력패턴을 받아들여 학습을 시키는 프로그램이다.

MLF 모형의 예측력은 입력된 자료에 대해 은닉층 수, 은닉 유닛 수, 전이함수 형태, 학습 반복횟수, 초기 연결강도, 학습계수, 모멘텀계수, 임계치 등의 모형구조를 어떻게 설정하느냐에 따라 달라지는데 특히 은닉 유닛 수와 학습 반복횟수가 결정적인 역할을 하게 된다.

따라서 본 연구에서는 각 모형마다 다른 모든 조건들이 동일할 때에 은닉층 수, 은닉 유닛 수, 전이함수 형태, 학습 반복횟수, 초기 연결강도, 학습계수, 모멘텀계수, 임계치가 변함에 따라 변하는 예측력을 실험하여 예측력을 최대로 하는 즉, 오차를 최소화하는 동시에 과적합화(overfitting)되지 않는 모형구조를 각 모형마다 실험을 통해 설정하여 사용하였다.

학습계수의 탐색 과정은 학습 패턴수나 학습의 진행상황에 따라 학습계수를 자동적으로 선택하여 학습의 효율화를 얻는 방법이다. 즉, 여러 개의 학습계수를 미리 준비하여 오차의 제곱을 구하고, 그 값이 최소가 되는 학습계수를 선택하여 연결강도와 임계치를 수정하는 방법이다.



<그림 4> 속도자료의 FILTERING 전(위)과 후(아래)

이는 학습계수가 학습에 있어서 결정적인 역할을 하는 값으로 학습계수에 따라 모형의 예측력은 큰 폭으로 변하게 되는데, 학습계수가 너무 크면 모형이 전역최소점(Global Minimum)에 도달하지 못하고 지역최소점(Local Minimum)에 빠지는 경우가 생길 수 있고 학습계수가 너무 작으면 학습시간이 길어지는 단점이 있으므로 이를 위해 적절한 학습계수를 찾기 위한 과정을 거치는 것이다. 학습계수가 너무 작을 경우 수렴에 도달할 때까지 걸리는 시간이 너무 길어지는 것을 막기 위한 값으로 적절하게 설정해야 한다.

모멘텀계수는 학습계수처럼 모형의 예측력에 큰 영향을 끼치지 않는 반면 역전과법에서 연결강도와 임계치의 수정량이 출력층에 의한 오차의 기여도에 따라 구해지는데 비해 모멘텀계수를 이용하게 되면 이전의 수정량도 고려하여 수정량을 결정하게 된다. 이 방법은 엄밀히 말하자면 최급하강법은 아니지만 오차로부터 구해진 수정량에 의한 오버 시프트를 억제하여 학습의 고속화에 유효한 것으로 알려져 있다. 임계값의 탐색 과정도 위와 동일한 목적으로 이뤄졌으며 모형이 예측력을 최대로 하는 임계값을 찾는 것이 목표이다.

위의 과정을 거쳐서 각 모형별로 가장 높은 예측력을 갖는 구조를 <표 9>와 같이 설정한 후, 학습에 사용되지 않은 data set 177개를 이용하여 모형의 예측

력을 test 하는 test를 실시하였다. 이는 학습의 경우는 알려진 입력과 출력값을 가지고 그 모형이 지정된 출력값을 출력하도록 여러 가지 계수를 바꾸는 작업을 하는 과정인데 비해, 학습을 통해 이미 설정된 모형구조를 가지고 입력값만을 입력해서 원하는 출력값에 얼마만큼의 정확도를 가지고 도달할 수 있는지를 알아보는 과정이다.

<표 9> 예측모형별 적용계수

		은닉층수	은닉유닛수	전이함수형태	초기연결강도	학습계수	모멘텀계수	임계치
모형A	A1	1	9	sigmoid	-0.05~0.05	0.3	0.5	0
	A2	1	9	sigmoid	-0.05~0.05	0.9	0.2	0
	A3	1	12	sigmoid	-0.05~0.05	0.9	0.2	0
	A4	1	12	sigmoid	-0.05~0.05	0.9	0.2	0
	A5	1	12	sigmoid	-0.05~0.05	0.9	0.2	0
모형B	B1(a)	1	9	sigmoid	-0.05~0.05	0.9	0.2	0
	B1(b)	1	12	sigmoid	-0.05~0.05	0.9	0.2	0
	B2(a)	1	9	sigmoid	-0.05~0.05	0.9	0.2	0
	B2(b)	1	12	sigmoid	-0.05~0.05	0.9	0.2	0
모형C	C1	1	9	sigmoid	-0.05~0.05	0.9	0.2	0
	C2	1	9	sigmoid	-0.05~0.05	0.9	0.2	0

<표 8> 학습계수(α), 모멘텀계수(β) 및 은닉유닛 수에 따른 학습결과(학습횟수에 동일하게 적용한 경우)

	α	β	α	β	α	β	α	β	α	β
	0.3	0.5	0.9	0.2	0.25	0.4	0.3	0.2	0.9	0.5
은닉층 1										
12,12,1	0.165	0.169	0.167	0.177	0.174					
12,9,1	0.170	0.165	0.166	0.166	0.179					
12,7,1	0.167	0.197	0.178	0.194	0.184					
은닉층 2										
12,10,10,1	0.176	0.173	0.174	0.179	0.164					
12,10,7,1	0.167	0.167	0.166	0.169	0.173					
12,10,4,1	0.166	0.166	0.168	0.170	0.169					
12,7,10,1	0.175	0.175	0.169	0.200	0.163					
12,7,7,1	0.177	0.177	0.176	0.179	0.163					
12,7,4,1	0.176	0.176	0.167	0.167	0.167					

* (12, 12, 1) : (입력유닛 12, 은닉유닛 12, 출력유닛 1)
 (0.3, 0.5) : 학습계수(α) 0.3, 모멘텀계수(β) 0.5
 (0.9, 0.2) : 학습계수(α) 0.9, 모멘텀계수(β) 0.2
 (0.25, 0.4) : 학습계수(α) 0.25, 모멘텀계수(β) 0.4
 (0.3, 0.2) : 학습계수(α) 0.3, 모멘텀계수(β) 0.2
 (0.9, 0.5) : 학습계수(α) 0.9, 모멘텀계수(β) 0.5
 임계값은 사전실험을 통하여 모든 경우에 0으로 설정하였음.

V. 분석결과

본장에서는 IV장에서 도출된 교통량 모형들의 학습 및 TEST결과를 비교·분석하였다. 모형들을 비교하는 척도로는 MARE(Mean Absolute Relative Error), RMS(Root Mean Square), %RMS, MAE(Mean Absolute Error), R^2 를 사용했다. 절대적인 지표인 RMS만으로는 모형간의 상대적인 비교가 정확하지 않았기 때문에 RMS와 %RMS를 중복되게 사용하였다. 사용된 비교척도의 정의는 다음과 같다.

$$MARE = \frac{1}{N} \sum_t \frac{|X(t) - \hat{X}(t)|}{\bar{X}(t)}$$

$$RMS = \sqrt{\frac{1}{N} \sum_t (X(t) - \hat{X}(t))^2}$$

$$\%RMS = \frac{\sqrt{\frac{1}{N} \sum_t (X(t) - \hat{X}(t))^2}}{\bar{X}(t)}$$

$$MAE = \frac{1}{N} \sum_t |X(t) - \hat{X}(t)|$$

1. 모형A

모형A의 학습 및 TEST 결과를 위에서 제시된 비교척도를 이용하여 분석했을 때 5개 모형들의 예측력은 목표지점의 과거 시점들의 교통량 자료를 입력값으로 하는 A1 모형의 예측력이 다소 떨어지고, 상류 한지점의 과거시점들의 교통량 자료를 입력값으로 하는 A2 모형의 예측력이 매우 높은 것을 제외하면 나머지 모형들은 크게 차이가 나지 않으며, 학습과 TEST에 있어서 같은 경향을 나타냈다.

우선 단일 지점의 자료를 이용하는 A1과 A5의 학습결과를 비교해 보면 MARE, RMS, %RMS, MAE, R2 등 모든 적합도 지표에서 모형A1의 적합도가 모형A5의 적합도 보다 높은 것으로 나타났다. 이는 목표지점의 과거시점들의 교통량 자료보다도 인접한 상류 한 지점의 교통량, 속도, 점유율이 목표 교통량 예측에 더 중요한 변수로 작용할 수 있음을 나타낸다. TEST 결과도 학습과 마찬가지로 A5가 높은 예측력을 나타냈다.

한편, 상류 한 지점의 연속된 과거 여러시점의 교통량 자료를 이용하는 모형A2와 연속된 여러 상류지점의 연속된 과거 여러시점의 교통량 자료를 이용하는 A3의 1 학습결과를 비교하여 보면 MARE에서는 큰 차이를 보이지 않으나 특히 RMS, %RMS 및 MAE에서는 모형A2가 모형A3에 비하여 우월한 것으로 분석되었는 바, 이것은 한 지점에 대한 시계열적 모형이 교통류의 특성이 시간의 경과에 따라 하류 지점으로 이동하여 가는 현상을 반영한 모형에 비하여 높은 예측력을 갖는다는 사실을 의미한다.

또한 상류 여러 지점의 과거 시점의 자료를 사용하는 모형A3와 모형A4는 MARE 등 모든 지표에서 큰 차이를 보이지 않고 있다. 모형A4가 감지기간 사이의 거리를 고려한 연속된 시점의 교통량 자료를 입력했음에도 감지기 사이의 거리를 고려하지 않은 모형A3와 별차이가 없다는 것은 감지기사이의 간격이 멀지 않았기 때문으로 볼 수 있는데, 만약 이는 감지기 간격이 현재보다 멀어질 경우 거리를 고려한 모형의 예측력이 더 커질 것으로 예상된다.

<그림 5> 및 <그림 6>에서 보듯이 학습과정의 경우 관찰치와 신경망 예측치가 매우 유사하게 나타나고

있으며, TEST의 경우도 어느 정도 같은 추세를 반영하고 있다.


위의 결과로 볼 때 한 지점의 교통량에 큰 영향을 끼치는 요인은 인접 상류 한 지점의 과거 여러시점의 시계열적 교통량임을 알 수 있으며, 일반화될 수는 없으나 모형A5의 결과로 볼 때, 속도 및 점유율은 그리 큰 영향을 미치지 못한다고 할 수 있다.

<표 10> 모형A의 학습결과


	MARE	RMS	%RMS	MAE	R ²
A1	0.22	783	300	594	0.49
A2	0.15	457	175	355	0.78
A3	0.16	529	203	410	0.72
A4	0.16	561	216	422	0.69
A5	0.17	568	215	433	0.69

<표 11> 모형A의 TEST결과

	MARE	RMS	%RMS	MAE	R ²
A1	0.30	671	315	526	0.51
A2	0.21	430	202	343	0.81
A3	0.20	478	224	376	0.78
A4	0.22	456	213	360	0.79
A5	0.21	540	255	415	0.76



<그림 5> 모형A의 학습결과(모형A2)



<그림 6> 모형A의 TEST결과(모형A2)

2. 모형B

모형B는 크게 상류지점의 교통량만을 이용하여

목표지점의 교통량을 예측하는 모형과, 상·하류 양지점의 자료를 이용하여 예측하는 두가지 형태의 하위모형으로 구성된다. 이러한 모형구성의 목적은 목표지점의 교통량 예측을 위하여 상·하류 양지점의 자료를 모두 사용했을 경우와 모형A처럼 상류의 자료만을 사용했을 경우의 예측력을 비교하기 위함이다. 전체적으로 볼 때 학습의 경우에 있어서는 큰 차이를 보이지 않으나, TEST 결과에 있어서는 상·하류지점을 모두 사용한 경우인 B1(b) 및 B2(b) 모형이 상류의 자료만을 사용한 모형보다 예측력이 높은 것으로 분석되었다. 한편 B1(a) 및 B2(a) 모형의 경우, 자료의 입출력값만 다르고 A2 및 A3 모형과 각각 입출력 형태가 같은데도 모형 A2 및 A3보다 매우 높은 예측력을 보이고 있는 바, 이는 입출력 형태가 같다고 하더라도 지점의 위치가 다를 경우 그 결과에는 편차가 발생할 수 있다는 것을 의미한다.

우선 학습에 있어서는 A2 모형을 재구성한 B1(a), A3모형을 재구성한 B2(a), 그리고 상류지점 뿐만 아니라 하류지점의 영향을 감안한 B1(b) 및 B2(b) 모형 등 4개의 모형의 학습결과가 MARE는 0.13으로 동일하고 RMS 등 나머지 지표에서도 유사하게 나타났다. 그러나 TEST의 경우에 있어서는 상·하류 양지점의 교통량을 입력요소로 하는 모형의 예측력이 상류의 교통량만을 입력요소로 하는 모형보다 그 예측력이 높은 것으로 분석되었다. 특히, 모형B1(a)와 모형B1(b)를 비교하면, MARE, RMS, %RMS 및 R² 등 모든 지표상에서 상·하류 모형이 상류모형에 비하여 2배의 예측력을 나타내고 있다.

<그림 7> 및 <그림 8>을 보면 학습과정의 경우 모형A보다도 높은 정확도로 거의 같은 값을 나타내고 있으며, TEST 역시 높은 예측결과를 나타내고 있다.


위의 결과로 볼 때 교통량 예측시 모형의 입출력자료로 상류지점의 교통량만을 단독으로 사용했을 때보다 상하류지점의 자료를 사용했을 때 예측력은 훨씬 높아진다고 볼 수 있다. 이는 교통량이 단순히 상류 지점에만 영향을 받는 것이 아닌 하류지점의 상태에도 영향을 받으리라고 가정했던 가정을 뒷받침해 준다고 볼 수 있다.

<표 12> 모형B의 학습결과


	MARE	RMS	%RMS	MAE	R ²
B1(a)	0.13	4.03	155	3.11	0.84
B1(b)	0.13	4.05	157	3.09	0.83
B2(a)	0.13	3.98	154	3.09	0.84
B2(b)	0.13	4.04	157	3.15	0.84

<표 13> 모형B의 test결과

	MARE	RMS	%RMS	MAE	R ²
B1(a)	0.28	6.85	321	5.16	0.45
B1(b)	0.14	3.85	180	2.77	0.81
B2(a)	0.16	3.91	182	2.89	0.82
B2(b)	0.16	3.90	181	2.92	0.83



<그림 7> 모형B의 학습결과(모형B2(b))



<그림 8> 모형B의 TEST결과(모형B2(b))

3. 모형C

모형C1 및 C2는 모형A 중에서 학습 및 TEST 결과로 볼 때 비교적 높은 예측력을 나타낸 A2 및 A3를 각각 재구성한 것이다. 모형C1의 입력요소는 모형A1의 입력요소와 동일하나 출력요소는 모형A1의 경우 t시점의 교통량만을 출력요소로 하는 데에 비하여 모형C1에서는 t 및 t+1시점의 교통량을 출력요소로 하며, C2와 A3의 관계도 이와 동일하다.

<표 10> 및 <표 14>에서 볼 때, 모형C1, C2의 학습결과를 보면 MARE, %RMS, MAE 및 R²에서는 A2

및 A3 등 한 시점만을 예측한 경우보다 다소 예측력이 떨어지는데 반하여 RMS에서는 현저한 차이는 없으나 오히려 우수한 예측력을 나타내고 있어 전체적으로 볼 때, 한 시점만을 예측하는 모형과 두 개의 시점을 예측하는 모형의 학습상에서의 큰 차이는 보이지 않고 있다 하겠다. 그러나 <표 11> 및 <표 15>의 TEST의 결과를 보면, 단일 시점을 예측할 때보다 두 개의 시점을 예측할 때 그 예측력이 현저하게 감소하는 것으로 나타났다.


한편 두 개의 시점을 예측한 C1, C2 모형의 학습결과에서 특이한 현상을 도출했는데 그것은 이제까지 모형A와 학습결과의 분석에서 모형A3보다 A2가 전반적으로 좋은 결과를 나타낸 데 비해 t, t+1 을 예측한 경우 모형A3에 대응하는 C2가 모형A2에 대응하는 C1보다 높은 예측력을 나타낸 것이다. 이는 모형A2가 인접한 상류 한 지점의 교통량만을 입력요소로 하는 경우이고, 모형A3는 상류 4개 지점의 교통량을 입력요소로 하는 모형으로, 목표지점의 t 시점에 절대적으로 큰 영향을 미치는 요소는 가장 인접한 상류지점의 교통량이지만, 그 이후 시점인 t+1 시점에 영향을 미치는 요소는 가장 가까운 상류지점 뿐 아니라 연속적으로 위치한 상류 여러 지점의 교통량이라는 사실을 의미한다.

<표 14> 모형C의 학습결과

	MARE	RMS	%RMS	MAE	R ²
C1	0.18	430	21.4	558	0.70
C2	0.18	427	20.2	546	0.76

<표 15> 모형C의 TEST결과

	MARE	RMS	%RMS	MAE	R ²
C1	0.20	530	31.8	678	0.52
C2	0.22	545	32.2	684	0.51



<그림 9> 모형C의 학습결과(모형C1, t+1)

<그림 9>에서는 모형C1의 t+1 시점에 대한 학습결과를 제시하였는데 모형A나 B 보다는 정확도가 다소 떨어지지만 비교적 관측치의 추세를 신경망이 잘 반영하고 있음을 알 수 있다.

VI. 결론

본 연구에서는 고속도로 상의 한 지점의 교통량을 예측함에 있어 신경망의 다양한 입력요소가 출력에 미치는 영향을 분석하였다. 본 연구를 통하여 도출된 결과를 요약하면 다음과 같다.

첫째, 고속도로 상에서 미래 시점의 교통량에 가장 큰 영향을 미치는 것은 인접한 상류 지점의 과거 시점의 교통량임이 확인되었다. 또한 일반화하여 이야기하기는 어려우나 모형A5에서 보듯이 상류지점의 속도나 점유율은 목표지점인 하류지점의 교통량 예측에 그리 큰 영향을 못 미치는 것으로 나타났는 바, 그 이유 중의 하나는 교통류의 특성상 입력요소로 사용된 교통량, 속도 및 점유율의 상관관계가 높기 때문이라고 해석될 수 있을 것이다.

둘째, 미래 시점의 교통량을 예측할 때 모형의 입력출력자료로 상류지점의 교통량만을 단독으로 사용했을 때보다 상하류지점의 자료를 사용했을 때 예측력은 훨씬 높아진다고 볼 수 있다. 이는 교통량이 단순히 상류지점에만 영향을 받는 것이 아닌 하류지점의 상태에도 영향을 받으리라고 가정했던 사실을 잘 뒷받침해 준다고 볼 수 있다.

셋째, 미래 한 시점 뿐 아니라 미래 여러 시점까지 예측했을 때도 한시점을 예측했을 때와 비슷한 정확도로 예측이 가능함이 확인되었다. 또한 미래의 t 시점에 절대적으로 큰 영향을 미치는 자료는 가장 인접한 상류지점의 교통량이지만, 그 이후 시점인 t+1 시점에 영향을 미치는 요인은 가장 가까운 상류지점 뿐 아니라 상류 여러 지점의 값들이라는 판단을 내릴 수 있다.

본 연구에서는 자료수집의 어려움으로 고속도로 기본구간에서 유고 상태가 없는 경우를 가정하였다. 그러나, 현실적으로는 유고가 발생한 경우나, JC 및 IC를 포함한 구간에 대한 교통량예측의 필요성이 더

크다고 볼 수 있는 바 이에 대한 연구가 계속되어야 할 것이며, 나아가, 본 연구에서는 다루어지지 못하였으나 교통량 예측을 위한 신경망의 입출력 연결구조에 관한 연구도 예측력 향상을 위하여 매우 필요한 과제라 생각된다.

참고문헌

1. Chang, G.L. and C.C. Su, "Predicting Intersection Queue With Neural Network Models", *Transportation Research*, vol.3, No.3, pp.175~191, 1995.
2. Dougherty, M. and M. Joint, "A Behaviourial Model of Driver Route Choice Using Neural Networks", *International Conference on Artificial Intelligence Applications in Transportation Engineering*, June 20-24, 1992.
3. Dougherty, M., "A Review of Neural Networks Applied To Transport", *Transportation Research*, vol.3, No.4, pp.247~260, 1995.
4. Fausett, L., *Fundamentals of Neural Networks*, Prentice Hall, Englewood Cliffs, 1993.
5. Hajek, J. and B. Hurdal, "A Comparison of Rule-based and Neural Network-based Solutions for a Structured Selection Problem", *Transportation Research Board 72nd Annual Meeting* January 10-14, 1993.
6. Kalaba, R., M. Kim and J.E. Moore II, "Linear Programming and Simple Associative Memories", *Applied Mathematics and Computation* 40, pp.203~214, 1990.
7. Kohonen, T., *Self-Organization and Associative Memory*, Springer - Verlag, 1989.
8. Moore II, J. E., M. Kim, J. G. Seo, Y. Wu and R. Kalaba, "Linear Programming, Recurrent Associative Memories, and Feed-Forward Neural Networks", *Computers and Mathematics with Applications*, June, 1991.
9. Smith, M., *Neural Networks For Statistical Modeling*, Van Nostrand Reinhold, 1993.
10. Wei, C.H. and P.M. Schonfeld, "An Artificial Neural Network Approach for Estimating Multiperiod Travel Times in Transportation Networks", *Transportation Research Board 72nd Annual Meeting* January 10-14, 1993.
11. Yang, H., R. Kitamura, P.P. Jovanis, K. Vaughn, M.A. Aty and P.DVG. Reddy, "Exploration of Driver Route Choice with Advanced Traveler Information Using Neural Network Concepts", *Transportation Research Board 72nd Annual Meeting* January 10-14, 1993.
12. Yang, H., T. Akiyama and T. Sasaki, "A Neural Network Approach to the Identification of Real Time Origin-Destination Flows From Traffic Counts", *International Conference on Artificial Intelligence Applications in Transportation Engineering*, June 20-24, 1992.
13. Zang, H. and S.G. Ritchie, "Macroscopic Modelling of Freeway Traffic Using an Artificial Neural Network", *Transportation Research Board 72nd Annual Meeting* January 10-14, 1993.