

■ 論 文 ■

신호교차로 대기행렬 예측을 위한 인공신경망의 학습자료 구성분석

Training Sample of Artificial Neural Networks
for Predicting Signalized Intersection Queue Length

한 종 학

(인천발전연구원 책임연구원)

김 성 호

(한양대학교 교통공학과 교수)

최 병 국

(인천발전연구원 연구위원)

목 차

- | | |
|-----------------------|----------------------|
| I. 서론 | 2. 인공신경망의 구조 |
| II. 분석자료의 수집 및 적정성 판단 | 3. 학습자료구성과 모형의 오차수렴성 |
| 1. 자료수집 | 4. 학습자료구성과 모형의 예측력 |
| 2. 자료의 적정성 판단 | 5. 모형의 통계적 검증 |
| III. 인공신경망의 학습자료 구성분석 | IV. 결론 및 향후 연구과제 |
| 1. 학습자료의 선정(모형A, 모형B) | 참고문헌 |

요 약

본 연구에서는 도시부도로 신호교차로의 대기행렬을 단기(one cycle ahead)예측함에 있어 단일검지체계에 기반을 둔 한 지점의 시계열적 패턴을 갖는 검지자료(detection data)를 학습자료로 구성할 경우와 통합차량검지체계하에 기반을 둔 시공간적 상관관계를 갖는 검지자료를 학습자료로 이용할 경우를 가정하여 이에 대한 인공신경망의 학습능력과 예측능력을 비교하였다.

연구결과는 도시부도로 신호교차로상에서 차량군(platoon)의 이동에 따라 발생하는 시공간적인 상관관계를 갖는 교통류변수 「상류유입교통량(k-1)→통행시간(k-1)→대기행렬(k)→유출교통량(k)→대기행렬(k+1)」를 인공신경망의 학습자료로 구성할 경우, 교통류 패턴의 학습능력이 뛰어난 것으로 밝혀졌다.

1. 서론

현재까지 교통관리체계에서 이용되고 있는 교통정보는 정적(static)정보이거나 과거이력(historical)정보 또는 실시간(real-time)정보에 근간을 두고 있다. 여기서 실시간정보는 과거의 어떤 교통흐름이 현재의 어느 시점까지는 참값으로 믿어진다고 할 때, 과거와 그 어느시점 간의 시간간격 이내라면 실시간이라 한다는 가정이 깔려있기 때문에 엄격하게 말하면 과거이력정보에 속한다고 할 수 있다. 다시 말하면 다양한 차량검지기(Vehicle Detector)의 수집정보를 가공처리·분석하는 단계와 이를 근거로 수립된 교통운영전략의 구현단계와의 시간차이(gap)가 발생한다는 것이다. 이를 극복하기 위한 방안으로 교통정보를 교통운영전략구현에 앞서 미리 예측(predictive)하고 수시로 변화하는 교통상황에 능동적으로 대처하는 과정이 필요한 것이다. 그러나 현실적으로 <표 1>에서 보는 바와 같이 아직까지 교통시스템에서는 이러한 예측교통정보가 활발하게 이용되지는 못하고 있다.

Bin Ran과 최기주(1999)는 첨단교통정보체계(ATIS)의 구현을 위한 단기(near-term) 및 중기(mid-term)

교통예측모형에 대해서 1)동적통행배정(Dynamic Traffic Assignment)모형, 2)통계적(Statistical)모형, 3)시뮬레이션(Simulation)모형, 4)휴리스틱(Heuristic)모형 등 크게 네가지로 구분하였다. 여기에서 인공신경망(Artificial Neural Networks)을 이용한 교통정보 예측모형은 휴리스틱모형의 한 부류로서 구분하고 있다.

Nelson et. al.(1991)은 인공신경망모형을 종래의 통계적분석방법과 비교하여 <표 2>에서와 같이 제시하였는데 정확도가 같다면 컴퓨터 연산속도(CPU)가 상대적 유리할 뿐만 아니라 기존의 분석방법에서 제시할 수 없었던 출력값에 대한 입력변수들의 설정에 유연성(flexible)이 있다고 제시하였다.

Dougherty, M.(1995)은 인공신경망의 교통분야 적용사례를 연구하였는데 인공신경망은 운전자행태, 파라메터 추정, 도로포장, 유도감지, 교통패턴분석, 교통량예측, 교통제어, 화물운영, 해상교통 등에 다양하게 적용되어 왔다.

교통량예측(Prediction of Traffic flow)에 관한 기존의 연구는 예측시간간격(time scale)에 따라 장기예측(Long-term prediction, a few months or year), 단기예측(Short-term prediction, a few minutes), 초단기예측(Very-short-term prediction, a few seconds to a minute)으로 구분되어 교차로 교통류의 동적변화(flow dynamics)에 대한 연구와 결부되어 진행되었다. 특히 인공신경망을 이용한 대기행렬예측에 관한 기존연구는 Gang-Len Chang(1994)이 3초의 초단기 예측시간간격으로 시뮬레이션을 통해서 교차로 접근로의 차로별 대기행렬길이를 예측하는 연구가 있었다. 엄지태(KAIST, 1994)는 외곽 교차로들과 특정내부 교차로와의 교통패턴들로부터 특정내부 교차로의 각 방향별 교통량의 단기예측이 가능한지를 연구하였고, 서울첨단신호체계연구(1995)에서는 상류부 검지기로부터 개별차량의 점유시간을 측정하여, 이들을 누적점유시간으로 변화하여 그때의 대기행렬길이를 일대일 대응시켜서 도출된 회귀

<표 1> Type of Currently available Multi-modal Information

Facility classification	Information Type			
	Static	Historical	Real-Time	Predictive
Highway				
Freeway	√	√	√	
Toll Road	√	√		
Primary Arterial	√			
Local Street	√			
Other				
Bus	√		√*	√*
Subway	√			
Other Rapid Transit	√			
Ride Sharing	√			
Railway	√			
Transit Terminal	√			
Airline	√		√	√
Airline Terminal	√			

주 : *) Available only when dynamic Bus Information System (BIS) is installed.
 자료 : Bin Ran·choi, Kee Choo(1999)

<표 2> 통계적분석방법과 인공신경망모형의 비교


분석방법	Effort (person hour)	Computer Runtime(hour)	Idealized parameters
기존통계적방법	54	234	None
인공신경망모형	6	5	yes

자료 : Nelson et. al.(1991)

식을 이용하여 대기행렬을 예측하는 알고리즘을 개발하였다.

기존연구를 종합해 보면 교통량예측모형에 대한 연구는 정적 또는 동적 선형모형을 이용한 단기(3분~15분)도착교통량을 추정하는 연구¹⁾와 분석적 또는 필터링방법에 의해 대기행렬길이를 추정하는 분야로 크게 분류되어 연구²⁾가 진행되었으며, 루프검지기예를 든 교통량, 점유율, 속도를 이용하였기 때문에 두 교차로간 교통류의 시공간적 전개과정에 근거한 접근로 대기행렬의 주기별 변화현상을 실제 현장자료에 근거한 연구는 제시되지 못하였다. 또한 지능형교통체계(ITS)의 도입이 가속화되면서 교통인프라의 핵심분야라 할 수 있는 차량검지체계의 발달은 향후 더욱 가속화되어 영상검지기, RFID검지기³⁾와 루프검지기가 통합된 차량검지체계(Integrative Vehicle Detection Systems)가 도시부 네트워크에 광범위하게 설치될 경우 다량으로 수집되는 교통수집정보를 어떻게 학습자료로 구성하여 활용할 것인가에 대한 기존의 연구노력은 거의 없었다.

따라서 본 연구에서는 도시부도로 신호교차로의 대기행렬을 단기(one cycle ahead)예측함에 있어 단일검지체계(영상검지기)에서 수집할 수 있는 신호교차로 '대기행렬의 시계열적자료'를 학습자료로 이용한 인공지능망의 예측력과 통합차량검지체계(루프, 영상, RFID)에서 수집할 수 있는 '인접교차로와의 시공간적 상관관계를 갖는 자료'를 학습자료로 이용한 인공지능망의 예측력을 비교하였다. 향후, 본 연구의 결과는 교통량의 방향별 분포가 심하게 다르거나, 앞막힘현상(spillback)에 의해 인접한 다른 교차로 접근로의 교통류까지 악영향을 끼치는 도시부 신호교차로에 대해서 대기행렬을 관리(Queue Management)하거나, 신호제어 변수인 오프셋(offset)을 조절해줄 수 있으며, 이를 통해 차량군의 연동효과를 증진시킬 수 있는 신호제어전략의 기본자료를 제공할 수 있을 것으로 판단된다.



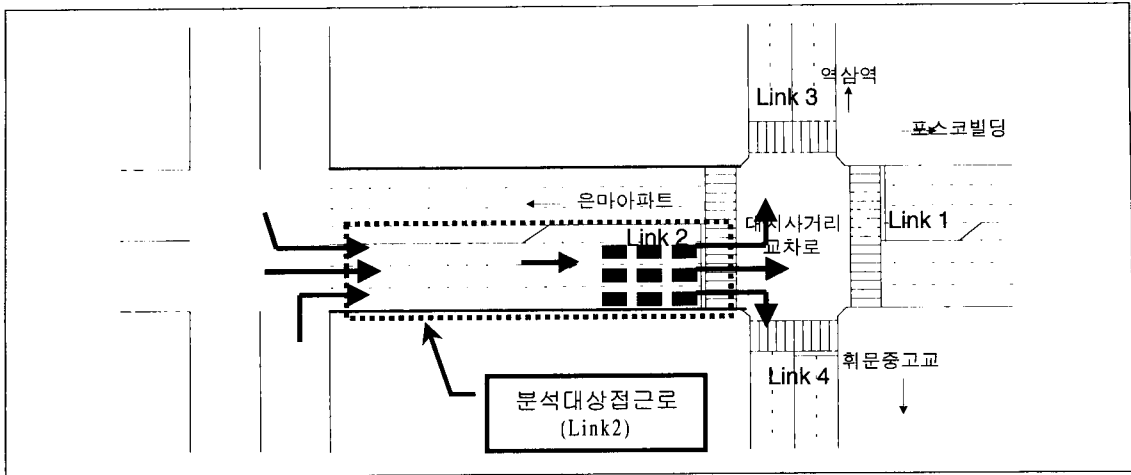
〈그림 1〉 본 연구의 기대효과

II. 분석자료의 수집 및 적정성 판단

1. 자료수집

신호교차로 대기행렬 예측을 위한 인공지능망의 학습자료구성과 관련하여 본 연구는 연구결과의 현실성을 높이기 위해 시뮬레이션 자료를 이용하지 않고, 서울 강남구 대치사거리의 현장실측자료(1997. 6)를 이용

1) UTCS-2(FHWA, 1973; Kreer,1975), ASCOT(SRI,1973), ASCOT-RTOP(CMT,1976), UTCS-3(Kreer,1976), Nicholson and Swann(1971), Gazis and Knap(1971), Smith(1974), Polhemus(1976), Stephanedes, Michalopoulos and Plum(1981), Iwa Okltani and Yorgos(1984)
 2) UTOPIA(Mauro,1989), Baras and Levine(1977), Baras, Levine, and Lin(1978, 1979), SCOOT(Hunt et al.,1982; Bretherton and Brown, 1990; Robertson and Bretherton, 1991), PRODYN(Henry et al.,1990), Michalopoulos, Stephanopoulos, and Pisharody(1980), and Stephanopoulos, Michalopoulos, and Stephanopoulos(1979).
 3) 주행중인 차량과의 Radio Frequency를 이용한 통신방식을 통한 정보통신시스템을 통칭하며, RFID시스템을 이용하여 주행 중인 차량의 관련정보를 수집하고 이를 가공/처리하여 이를 다시 주행 중인 차량에 필요한 정보로서 제공하거나 기타 여러가지 목적으로 활용하기 위해 구축된 체계이다.



〈그림 2〉 자료수집구간

〈표 3〉 자료수집내용

조사방법	검지체계	수집교통정보
비디오 자료수집	영상검지기	-대기행렬
현장조사자 자료수집	루프검지기 RFID	-구간통행시간 -유출교통량 -상류유입교통량

〈표 4〉 분석대상교차로의 신호현시순서

현시순서	$\phi 1$	$\phi 2$	$\phi 3$	$\phi 4$	주기
현시방법					130초
현시시간	13초	59초	29초	29초	


하였다. 조사자료는 현장조사 대상지가 통합차량검지 체계가 구축되어 있지 않아 〈표 3〉과 같이 조사원으로 하여금 차량검지기의 역할을 대신하여 관련 정보를 조사하도록 하였다.

따라서 조사원에게는 기준시간으로 미리 맞춰진 stopwatch와 계수기 그리고 비디오카메라를 제공하여 분석 접근로의 녹색시간 시작시점을 기준으로 130초의 단위 시간(주기)으로 4시간(08:00~12:00)동안의 지속적인 조사를 통하여 111개 주기의 자료를 획득하였다.


2. 자료의 적정성 판단

4시간 동안 주기(130초)단위로 조사된 자료를 인공 신경망의 학습자료로 이용하기에 앞서서 수집자료의 주기별 분포특성을 통해서 적정성을 판단하였다. 그

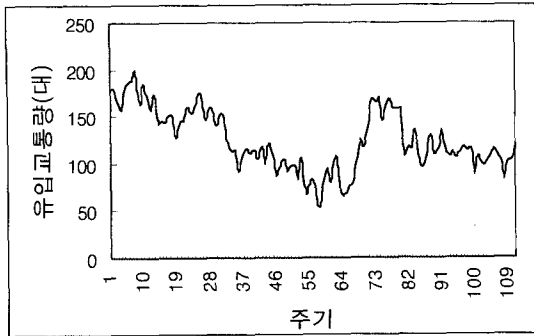
결과, 〈그림 3〉, 〈그림 4〉, 〈그림 5〉, 〈그림 6〉에 보는 바와 같이 접근로의 대기행렬이 클 경우 구간통행시간이 큰 값을 가지며, 상류교차로(upstream node)로부터 유입교통량이 많을 경우, 접근로의 대기행렬은 역시 큰 값을 가지는 분포를 나타내고 있음을 보여준다. 한편, 접근로 유출교통량은 분석 대상 교차로가 고정신호로 운영되고 있으므로 일정한 유출교통량을 나타내고 있다.




〈그림 3〉 주기별 대기행렬 분포(link2)



〈그림 4〉 주기별 유출교통량분포(link2)



〈그림 5〉 주기별 상류유입교통량(link2)



〈그림 6〉 주기별 통행시간분포(link2)

III. 인공신경망의 학습자료 구성분석

1. 학습자료의 선정

1) 학습자료선정을 위한 기본가정

- 교차로의 대기행렬((approach maximum stationary queue length($k+1$))은 해당 접근로의 전(前) 주기(cycle) 대기행렬(approach maximum stationary queue length($k, k-1, k-2, k-3, \dots$))의 시계열자료(time-series data)와 직·간접적인 어떤 미지의 패턴(unknown pattern)을 가지고 있으며, 또한 해당지점뿐만 아니라 상류교차로의 유입교통량(upstream feed-in flow), 링크통행시간(link travel time), 유출교통량(departure volume)과도 미지의 패턴을 가진다. 이러한 단속교통류의 변수간 특성은 인공신경망 학습입출력자료의 자기조직화(self-organization)에 의해서 숨겨진 규칙(hidden regularity)를 찾아낼 수 있다.
- 교차로 접근로의 midblock유입교통량, 차선변경(lane change), 신호제어변수(offset) 등은 분석에서 제외하였다. 그 이유는 언급된 변수들의 영향

은 상류부유입교통량, 통행시간, 유출교통량, 접근로 대기행렬길이의 시계열데이터 등의 교통류변수에 의해 반영될 수 있다고 판단하였다.

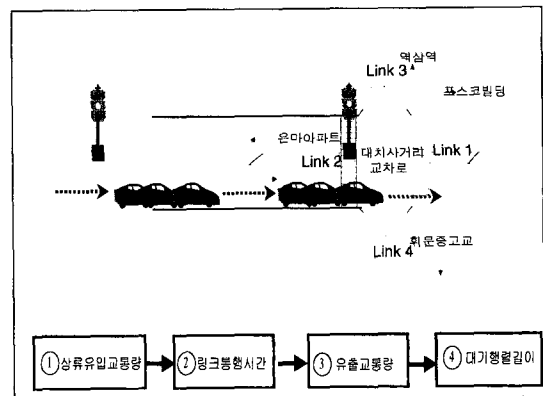
- 본 논문의 예측시간단위는 130초이며, 대기행렬길이 측정시점은 대기행렬이 최대가 되는 매주기 녹색시작시점으로 한다. 따라서 접근로의 대기행렬 길이는 130초 전에 예측이 가능하며, 녹색시작시점이 130초 범위내에만 존재한다면 실시간 신호 제어에 적용시 비주기적(acyclic)상황에 대해서도 예측이 가능하다고 판단된다.

2) 모형A

모형A는 침투시간계수(PHF) 산정 시 교통량집계 단위시간이 15분 간격이라는 점을 착안하여 15분간의 교통상황을 학습자료에 반영하기 위해서 매 주기 녹색시작시점 때 최대정지대기행렬의 시계열 자료 7개를 입력학습패턴에 두고, 8번째 주기의 최대정지대기행렬을 목적학습패턴에 두어 〈표 5〉와 같이 총 53개의 학습자료를 구성하였다.

3) 모형B

모형B는 신호교차로가 있는 도시부도로의 단속교통류상에서 차량군의 이동에 따라 생성되는 교통류변수간에는 시공간적 상관관계가 있다는 점을 착안하였다. 〈그림 7〉에서 보는 바와 같이 차량군의 이동을 시공간적으로 살펴보면 상류부교차로에서 유입한 차량은 링크통행시간을 거친 후 하류부 교차로 정지선을 통과하거나 대기한 후 녹색신호시 교차로를 통과하며, 주어진 녹색시간 동안 통과를 못한 차량은 다음



〈그림 7〉 단속교통류상의 차량이동에 따라 생성되는 교통류변수

<표 5> 8개 주기의 대기행렬(Q)의 시계열데이터를 이용한 학습자료구성(모형A)

No	<입력 학습패턴>							<목적 학습패턴>
	1	2	3	4	5	6	7	
1	Q1	Q2	Q3	Q4	Q5	Q6	Q7	Q8
2	Q2	Q3	Q4	Q5	Q6	Q7	Q8	Q9
3	Q3	Q4	Q5	Q6	Q7	Q8	Q9	Q10
4	Q4	Q5	Q6	Q7	Q8	Q9	Q10	Q11
.
.
53	Q53	Q54	Q55	Q56	Q57	Q58	Q59	Q60

<표 6> 시공간적 상관관계자료를 이용한 학습자료구성(모형B)

No	<입력 학습패턴>			<목적 학습패턴>	
	1	2	3	4	
1	Q2	T1	U_IN1	D_OUT2	Q3
2	Q3	T2	U_IN2	D_OUT3	Q4
3	Q4	T3	U_IN3	D_OUT4	Q5
4	Q5	T4	U_IN4	D_OUT5	Q6
.
.
58	Q59	T58	U_IN58	D_OUT59	Q60

주 : Q) 대기행렬, T) 통행시간, U_IN) 상류유입교통량, D_OUT) 유출교통량
 예 : Q2) 2번째 주기의 대기행렬, T1) 1번째 주기의 통행시간, U_IN1) 1번째 주기의 상류유입교통량, D_OUT2) 2번째 주기의 유출교통량, Q3) 3번째 주기의 대기행렬

주기까지 대기하는 상황이 발생된다. 이러한 일련의 과정을 학습자료로 구성하면 <표 6>과 같다.

2. 인공신경망의 구조

신호교차로 대기행렬 예측을 위한 인공신경망의 학습속도와 예측력은 앞서 구축된 학습자료의 구성 방식의 인공신경망의 은닉층수, 은닉층 유니트수, 전이함수(transfer function)형태, 학습반복횟수, 초기연결강도, 학습계수, 모멘텀계수 등에 따라 달라진다.

여기서 학습계수(learning rate)는 모형의 학습속도와 예측력에 큰 폭으로 영향을 미치는 변수로서 학습계수가 너무 크면 모형이 전역최소점에 도달하지

못하고 지역최소점에 빠질 가능성이 많고, 학습계수가 너무 작으면 학습속도가 떨어지는 상황이 발생한다. 모멘텀(momentum)계수는 학습계수가 너무 작을 경우 수렴하는 데 걸리는 시간을 단축시켜 주는 역할을 한다. 전이함수는 유니트의 입력과 연결강도의 가중합을 0과 1(단극성) 또는 -1과 1사이(양극성)의 새로운 값으로 출력해 주는 함수이다. 은닉층수와 은닉층 유니트수는 분석가가 주관적으로 결정하며 그 타당성은 실험을 통하여 증명하는 수 밖에 없다. 본 연구에서는 여러번의 시행착오를 반복하여 은닉층의 수는 1개와 2개의 경우로 나누고, 은닉층의 유니트수는 10개, 12개, 15개로 나누었다. 학습반복횟수는 30,000번, 60,000번, 90,000번으로 나누어 학습자료의 수렴정도를 판정하였다. 학습계수(α)는 0.4, 0.7, 0.9로, 모멘텀계수(β)는 0.5, 0.7, 0.9로 나누었고, 전이함수는 단극성 시그모이드(unipolar sigmoid)함수를 선택하였으며, 초기연결강도는 난수(random number)에 의해 결정되도록 하였다.

본 연구에서는 학습능력이 뛰어난 모형을 찾기 위해 인공신경망의 구조와 관련된 변수의 범위에 따라 45개의 대안을 설정하여 각 대안별로 수렴성을 살펴 보았다.

3. 학습자료구성과 모형의 오차수렴성

모형의 오차수렴성은 15분 동안 매 주기 녹색신호 시작시점의 최대정지대기행렬의 시계열자료를 이용하는 모형A의 학습자료구성보다 상류유입교통량(k-1), 통행시간(k-1), 대기행렬(k), 유출교통량(k)와 대기행렬(k+1)을 이용한 모형B의 학습자료구성이 RMSE(Root Mean Square Error)의 수렴성(convergence)이 좋은 것으로 나타났다(<그림 8>,<그림 9>). 즉, 두 교차로간 차량군의 이동에 따라 발생하는 시공간적 상관관계자료가 신호교차로 대기행렬길이의 변화패턴을 인지하는 모형B의 수렴속도를 빠르게 하였다.

이러한 결과로 볼 때, 통합검지체계에 의한 도시부 도로의 교통운영전략 수립시 다양한 유형의 차량검지기(loop, 영상검지기, RFID 등)를 교통류 변화패턴을 빠르게 인지할 수 있도록 배치(disposition)시키는 것이 하나의 고려사항이 될 수 있음을 간접적으로 암시한다.

<표 7> 인공신경망 구조에 따른 대안설정

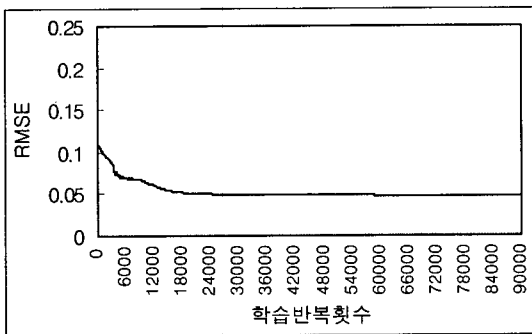
은닉층수	은닉층units	학습계수(α)	모멘텀계수(β)	학습반복 횟수*	전이함수	대안번호
1	10	0.4	0.5	90,000	sigmoid	01
			0.7	90,000	sigmoid	02
			0.9	90,000	sigmoid	03
		0.7	0.5	90,000	sigmoid	04
			0.7	90,000	sigmoid	05
			0.9	90,000	sigmoid	06
		0.9	0.5	90,000	sigmoid	07
			0.7	90,000	sigmoid	08
			0.9	90,000	sigmoid	09
	15	0.4	0.5	90,000	sigmoid	10
			0.7	90,000	sigmoid	11
			0.9	90,000	sigmoid	12
		0.7	0.5	90,000	sigmoid	13
			0.7	90,000	sigmoid	14
			0.9	90,000	sigmoid	15
		0.9	0.5	90,000	sigmoid	16
			0.7	90,000	sigmoid	17
			0.9	90,000	sigmoid	18
2	10-10	0.4	0.5	90,000	sigmoid	19
			0.7	90,000	sigmoid	20
			0.9	90,000	sigmoid	21
		0.7	0.5	90,000	sigmoid	22
			0.7	90,000	sigmoid	23
			0.9	90,000	sigmoid	24
		0.9	0.5	90,000	sigmoid	25
			0.7	90,000	sigmoid	26
			0.9	90,000	sigmoid	27
	12-12	0.4	0.5	90,000	sigmoid	28
			0.7	90,000	sigmoid	29
			0.9	90,000	sigmoid	30
		0.7	0.5	90,000	sigmoid	31
			0.7	90,000	sigmoid	32
			0.9	90,000	sigmoid	33
		0.9	0.5	90,000	sigmoid	34
			0.7	90,000	sigmoid	35
			0.9	90,000	sigmoid	36
	15-15	0.4	0.5	90,000	sigmoid	37
			0.7	90,000	sigmoid	38
			0.9	90,000	sigmoid	39
		0.7	0.5	90,000	sigmoid	40
			0.7	90,000	sigmoid	41
			0.9	90,000	sigmoid	42
		0.9	0.5	90,000	sigmoid	43
			0.7	90,000	sigmoid	44
			0.9	90,000	sigmoid	45

주 : *) 학습반복횟수는 30,000번, 60,000번, 90,000번 iteration할 때 마다 RMSE의 수렴성을 검증하고 더 이상 수렴이 되지 않는다고 판단되면 학습반복과정을 정지하였음.


4. 학습자료구성과 모형의 예측력

일단 학습이 이루어진 후, 인공지능망은 자신이 경험했던 것들과 다른 형태의 입력에 대해서도 반응을 나타낸다. 즉, 학습단계에서 RMSE가 최소값으로 수렴된다면 예측단계에서도 RMSE가 최소값으로 수렴되어 예측력이 우수한 결과를 제공하게 된다. 그러나 만일 부분학습(partial learning)에 의해서 구축된

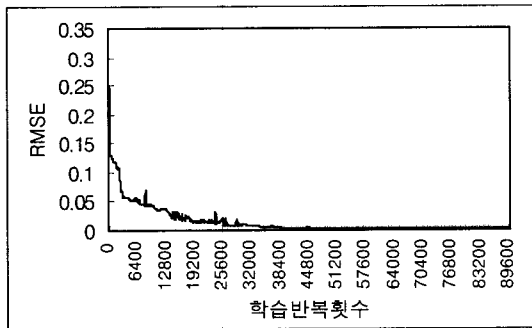
인공신경망은 모든 패턴을 일반화시키지 못하기 때문에 예측단계에서 만족할 만한 결과를 제공하여 주지 못하게 된다. 본 연구에서는 자료수집과정을 통해서 111개 주기의 현장실측자료를 획득하였다. 이 가운데에서 전반부 60개 주기의 자료(대기행렬, 상류유입교통량, 통행시간, 유출교통량)는 학습과정에 이용하였고, 후반부 51개 주기의 자료는 예측력을 판단하는 자료로 활용하였다.




〈그림 8〉모형A의 RMSE 수렴성




〈그림 11〉모형B의 관측값과 예측값 비교(대안04), RMSE = 9.241




〈그림 9〉모형B의 RMSE 수렴성



〈그림 12〉모형B의 관측값과 학습값 비교(대안29), RMSE = 1.802



〈그림 10〉모형B의 관측값과 학습값 비교 (대안04) RMSE = 6.672



〈그림 13〉모형B의 관측값과 예측값 비교 (대안29), RMSE = 25.411

〈표 8〉모형별 분석결과(대안별 RMSE값)

대안	모형A		모형B	
	학습	예측	학습	예측
01*	8.862	16.497	6.043	15.073
02*	9.211	22.215	6.761	15.283
03	6.870	25.050	8.904	16.621
04*	7.071	20.220	6.672	9.241
05	6.680	19.727	7.739	13.349
06	9.008	22.247	14.701	19.668
07	6.404	21.671	8.096	11.455
08	7.001	21.347	8.307	11.290
09	13.513	21.801	21.948	15.655
10*	8.919	20.570	7.960	13.113
11*	6.925	19.924	5.849	11.615
12*	16.885	16.610	11.662	16.334
13*	7.976	21.121	6.042	13.885
14*	9.257	21.208	7.078	13.048
15*	15.129	21.620	9.773	19.931
16*	6.134	15.052	5.545	11.931
17	6.284	22.190	6.375	20.148
18	6.907	21.203	14.812	29.330
19*	*5.041	17.083	2.923	20.807
20*	5.652	15.053	2.802	26.656
21*	11.134	14.767	4.961	13.630
22*	6.805	17.934	1.469	16.754
23*	6.856	18.106	1.867	15.584
24*	10.012	12.823	3.154	17.084
25*	6.062	13.185	1.725	19.380
26*	8.474	19.484	1.374	14.941
27	6.059	23.268	14.090	20.424
28*	5.934	23.015	3.096	13.940
29*	5.879	12.030	1.802	25.411
30*	10.42	23.009	1.682	16.464
31*	5.592	14.503	1.311	16.234
32*	7.954	16.139	1.547	14.405
33*	5.241	23.440	2.962	14.884
34	-	-	-	-
35	-	-	-	-
36	-	-	-	-
37*	5.089	13.508	3.191	20.309
38*	5.873	14.752	1.441	17.470
39*	9.103	17.174	1.525	17.220
40*	6.009	19.740	1.368	10.564
41*	6.407	13.560	5.849	12.359
42*	10.170	19.501	1.357	10.415
43	-	-	-	-
44	-	-	-	-
45	-	-	-	-

주 : 대안34, 35, 36, 43, 44, 45는 학습과정에서 RMSE값이 발산(divergent)함.
 *) 모형B의 대안이 모형A의 대안보다 학습 및 예측능력이 좋은 경우임.

모형의 학습능력과 예측능력은 〈표 8〉에서 보는 바와 같이 39개 대안(대안34, 35, 36, 43, 44, 45는 제외됨) 가운데, 30개 대안(76.9%)에서 모형 B의 학습능력과 예측능력이 모형A보다는 좋은 것으로 나타났다. 그러나 60개 주기 동안 교통패턴들로 학습시킨 인공신경망으로 51개 주기동안의 교통패턴을 일반화시키는데는 다소 미흡하였다. 즉, 조사대상 지점의 교통패턴들에 대한 완전한 학습과정이 이루어지기 위해서는 모든 가능한 패턴들의 전형적인 표본(sample)들이 학습자료에 포함되어야 한다. 그러나 본 연구에서는 현장자료수집의 어려움으로 인해 60개 주기의 자료로 구성된 학습자료에 분석대상 교차로에서 발생하는 다양한 교통패턴들이 포함되지 못하였다.

5. 모형의 통계적 검정

예측력이 우수한 모형(오차가 최소화된 인공신경망 모형)이 과연 통계적으로 타당성을 가지는지에 대해서 검정하였다. 이를 위해서 모형A와 모형B에 대해 두 모집단(여기서는 51개 주기의 관측값 집단과 예측값 집단)간의 '평균값의 차이에 대한 검정'과 두 모집단 분포의 '적합도검정'을 위한 χ^2 검정을 하였다. 통계적검정은 학습RMSE가 최소값으로 도출된 모형A(대안19), 모형B(대안31)와 예측RMSE가 최소값으로 도출된 모형A(대안29)와 모형B(대안04)에 대해서 수행하였다. 그 결과는 〈표 9〉와 같다.

통계적검정 결과, 관측값과 예측값간의 평균값은 95%의 신뢰도를 가지고 유의(significant)하지 않음을

〈표 9〉 모형별 통계적검정 결과

구분		(학습) RMSE	(예측) RMSE	검정통계량		P_value(유의도 α)	
				Z_value	X^2	Z-test ($\alpha=0.05$)	χ^2 검정 ($\alpha=0.01$)
모형B	대안04	6.672	9.241	0.143	71.272	0.357	0.026
	대안31	1.313	16.234	0.093	314.850	0.407	0.000
모형A	대안19	5.041	17.083	0.071	448.750	0.429	0.000
	대안29	5.897	12.030	0.191	127.715	0.309	0.000

알 수 있다. 즉, 51개 주기동안 관측대기행렬길이의 평균값은 예측대기행렬길이의 평균값과 5%의 오차를 허용하는 범위에서 동일한 값을 가진다고 할 수 있다. 반면 예측값과 관측값의 적합도(goodness of fit)는 모형B의 대안04의 경우를 제외한 나머지 대안은 99%의 신뢰도를 가지고 대안이 적합성정도가 매우 유의하다는 결과를 얻었다. 즉, 51개 주기동안 대기행렬길이의 관측값과 예측값의 적합도검정에서 시공간적 인과관계자료를 이용한 모형B가 시계열자료를 이용한 모형A보다 좋은결과를 얻었다.

IV. 결론 및 향후 연구과제

본 연구에서는 도시부도로 신호교차로에서 통합차량검지체계에 의한 시공간적 상관관계를 갖는 수집정보와 단일검지체계에 의한 한 지점의 과거 인접 주기(cycle)간의 시계열패턴을 갖는 수집정보를 각각 인공신경망의 학습자료로 구성하여 다음 주기(one cycle ahead)의 대기행렬을 예측력을 비교하였다.

본 연구를 통하여 도출된 결과는 다음과 같다.

첫째, 도시부도로 신호교차로상에서는 차량이동에 따라 시공간적인 상관관계를 갖는 교통류변수를 인공신경망의 학습자료로 구성할 경우, 교통류 패턴의 학습능력이 뛰어났다. 이러한 결과를 통해 볼 때 교통운영전략 수립시 차량검지기를 시공간적 상관관계를 가진 교통정보를 수집하도록 배치(disposition)시키는 것이 요구된다.

둘째, 도시부도로 신호교차로상에 발생하는 교통류 변수간의 상관관계에 대한 완전한 학습이 이루어지기 위해서는 발생가능한 모든 패턴들의 전형적인 표본(sample)들이 학습자료에 포함되어야 한다. 본 연구

의 경우 학습자료 구성시 분석대상 교차로에서 발생되는 다양한 교통패턴들을 모두 포함시키지 못한 부분학습(partial learning)으로 인하여 모든 패턴을 일반화시키지는 못하였다. 이는 본 연구가 학습자료의 구성을 현장자료수집에 의한 현실적 한계점에서 비롯되었다고 판단된다.

본 연구의 한계점 및 향후 연구과제는 다음과 같다.

첫째, 인공신경망모형의 일반화능력을 향상시키기 위한 일련의 작업이다. 이를 위해서는 실제 통합차량검지체계에 수집되는 자료를 이용하여 인공신경망의 학습과정이 요구된다.

둘째, 인공신경망의 특징 중에 하나가 무수한 대안(alternative)에 대한 Test를 통해서 최적대안을 찾아내는 작업이다. 본 연구에서는 이 부분이 충분하지 못하였다. 예를 들면, 15분 동안의 학습자료를 이용하여 모형을 구축하는 것이 타당한 것인가와 입력층 변수의 선정시 신호제어전략변수, Midblock의 유출입교통량 등에 대한 고려가 미반영되었으므로 이 부분에 대한 추가적인 연구가 필요하다.

셋째, 본 연구에서는 신호교차로의 한 접근로에 대한 대기행렬(교통량)의 예측으로 마무리되었지만 향후 각 방향별 접근로의 이동류별 대기행렬(교통량)의 예측이 가능하다면 실제 예측교통량에 의한 예측신호시간과 실제신호시간과의 차량당평균지체값의 비교검토가 가능하리라 판단된다.

마지막으로 신경망구조의 각 뉴런층을 연결하는 연결가중치(weight)를 유전자알고리즘(Genetic Algorithm)의 염색체 또는 유전형으로 표현하여 문제의 최적해

를 찾는 유전자알고리즘과 인공신경망의 모형구조(입력층, 은닉층, 출력층)을 결합하는 연구도 가능하다고 판단된다.

참고문헌

1. 도로교통안전관리공단(1997), "시가지도로 교통정보 수집 및 활용체계 개발에 관한 연구".
2. 엄지태(1993), "신경망을 이용한 교통수요예측", 한국과학기술원 석사학위논문.
3. 이상원(1993), "학습하는 기계신경망", Ohm사, 한솔기획.
4. 변완희(1998), "첨단교통시스템설계", 디자인그룹 에이블.
5. 조중래 · 김현주(1998), "고속도로 실시간 교통량 예측을 위한 인공신경망 입출력 요소분석", 대한교통학회지, 제16권 제4호, 1998년 12월호, pp.21~31.
6. 한중화(1997), "인공신경망을 이용한 신호교차로 대기행렬예측모형에 관한 연구", 한양대학교 대학원 석사학위논문.
7. Bin Ran · Choi, kee choo(1999), "Using Traffic Prediction Models for Providing Predictive Traveler Information: Reviews & Prospects", Journal of Korean Society of Transportation Vol.17 No1, pp.141~157.
8. Branston D.(1978), "A Comparison of Observed and Estimated Queue Lengths at Oversaturated Traffic Signals", Traffic Engineering & Control 19(7), pp.522~527.
9. Chang G.L. and Su C.C.(1995), "Prediction Intersection Queue with Neural Network Models", Transpn. Recs. C. Vol. 3, pp.175~191.
10. Dougherty, M.(1995), "A Review of Neural Networks applied to Transport". Transpn. Recs. C. Vol 3. No. 4 pp.247~260.
11. Nelson, M. M. and Illingworth, W. T.(1991), "A practical Guide To Neural Nets", Addison Wesley, New York.
12. Papageorgiou M.(ed.)(1991), "Concise Encyclopedia of Traffic & Transportation Systems", BPCO Wheattons Ltd, Great Britain.
13. Patterson D. W.(1995), "Artificial Neural Networks Theory & Applications" Prentice Hall.
14. Wasserman(1993), "Neural Computing", Van Nostrand Reinhold.