

■ 論 文 ■

인공신경망을 이용한 고속도로 기본구간 자유속도 추정모형개발

Development of Free Flow Speed Estimation Model by Artificial Neural Networks for Freeway Basic Sections

강진구

(한국토지공사 신도시사업1처)

김진태

(교통개발연구원 책임연구원)

장명순

(한양대학교 교통시스템공학과 교수)

김웅철

(인천대학교 토목환경시스템공학과 전임강사)

목 차

- | | |
|-------------------------|---------------------|
| I. 서론 | 1. 인공신경망 모형의 입력자료 |
| II. 기존문헌 고찰 | 2. 인공신경망 모형의 설계 |
| 1. 자유속도의 정의 | V. 모형의 검증 |
| 2. 자유속도에 영향을 미치는 도로설계요소 | 1. 기존모형과의 비교 |
| 3. 평면곡선부 주행행태에 관한 연구 | 2. 인공신경망 모형의 통계적 검증 |
| 4. 인공신경망 | VI. 결론 및 향후연구과제 |
| III. 연구방법 | 1. 결론 |
| 1. 자료수집 | 2. 향후연구과제 |
| 2. 자료분석 | 참고문헌 |
| IV. 모형개발 | |

Key Words : 고속도로, 설계요소, 속도추정모형, 인공신경망, 자유속도

요 약

교통량 등의 도로외적인 요인을 배제한 도로의 물리적 특성이 미치는 영향으로 인하여 운전자의 주행행태가 변하는 것을 자유속도의 예측을 통하여 파악할 수 있다. 또한, 예측된 자유속도는 도로설계의 적정성 평가와 교통류 시뮬레이션 프로그램의 차량속도 입력자료에 이용될 수 있다.

기존의 자유속도 예측모형들이 이용해오던 선형 및 다중회귀분석과 달리 본 연구에서는 비선형적인 특성의 표현이 가능하고 여러 가지 기술적인 용용에 통용되고 있는 인공신경망을 이용하여 자유속도를 예측하고자 하였다.

고속도로 기본구간 중 단곡선부를 대상으로 수집된 속도자료를 이용하여, 도로설계요소 중에서 평면·종단선형을 고려하고 횡단면 구성 요소의 일부를 반영한 결과 95% 신뢰수준에서 통계적으로 유의한 자유속도 예측모형을 개발 할 수 있었다.

모형의 곡선 시점·중점속도의 RMSE는 6.68, 10.06이고 R^2 는 0.77, 0.65로 기존에 개발되어있는 모형들과 비교하여 우수한 모형으로 분석되었다.

모형은 곡선 시점·중점에서의 속도특성을 곡선반경 등의 평면선형요소와 종단선형 요소별로 도출할 수 있으며, 연구결과는 현재 기본구간에 설계요소와 무관하게 일률 적용되는 자유속도를 도로설계요소와 관련하여 현실적으로 세분화하여 이용할 수 있는 근거를 제시하고, 나아가 설계일관성평가와 교통류 시뮬레이션에 적용할 수 있을 것으로 예상된다.

I. 서론

도로가 얼마나 잘 설계되어 있는지를 판단할 때 중요한 기준은 '도로가 그 기능에 적합한 서비스를 제공하는가' 하는 용량의 문제와 '도로를 주행함에 있어서 안전한 주행이 가능한가' 하는 안전성의 문제로 나누어 생각할 수 있을 것이다. 도로의 안전과 관련하여 종단선형, 평면선형 혹은 횡단면 구조와 같은 도로설계요소는 물리적 측면에서 차량주행의 특성을 제한하기만 할 뿐 아니라, 인간공학적인 측면에서도 운전자에게 영향을 미친다.

교통량 등의 도로외적인 요인을 배제한 도로의 물리적 특성이 운전자에 미치는 영향으로 인하여 운전자의 주행행태가 변하는 것은 자유속도를 관찰하여 파악할 수 있다. 도로설계요소와 속도변화와의 관계를 예측하려는 연구들은 국내·외로 많이 진행되어 왔고, 평면곡선부에 있어서 감속은 곡선반경과 곡선길이 그리고 인접 직선부의 길이 등과 관련이 있다는 연구결과들이 발표되어져 있다. 이런 연구결과들은 대부분의 경우 통계적인 접근을 통하여 자유속도를 종속변수로하고 도로설계요소들을 독립변수로 하는 회귀모형 결과를 제시하여 왔으나 선형회귀모형은 독립변수간의 독립성, 독립변수와 종속변수간의 관계를 선형으로 가정하는 등의 제약 조건으로 인한 한계성을 나타내는 단점이 있다. 선형회귀모형이 보이는 이러한 한계성을 극복하고자 인공신경망 모형을 응용한 연구가 이루어지고 있으며, 본 연구에서도 인공신경망 모형을 이용한 자유속도 예측을 통하여 연속성 있는 속도를 유지할 수 있도록 설계일관성을 향상시키는데 기여하고, 현재 기본구간의 설계특성과는 관계없이 일률적인 자유속도를 적용하는 교통류 시뮬레이션에도 도로설계요소에 따라서 변화하는 운전자의 자유속도의 선택행태를 반영할 수 있는 속도자료의 근간을 제공하고자 하였다.

본 연구의 세부 목적은 다음과 같다.

- 1) 도로설계요소가 운전자의 주행에 미치는 영향에 대하여 자유속도의 변화를 통하여 알아보고 자유속도 예측모형을 제시한다.
- 2) 인공신경망을 이용한 자유속도모형을 개발하며, 완성된 인공신경망 모형을 기준의 회귀모형들과 비교 분석한다.

본 연구의 범위는 도로설계요소 중에서 평면선형과

종단선형을 고려하고 횡단면 구성 요소의 일부를 반영하며 단곡선부를 중심으로 연구를 진행하였다. 연구대상도로는 고속도로에 국한하여 구간분류는 기본구간에 한하여 속도자료를 수집하였고 이를 통하여 직선구간에서 곡선구간으로 진행하는 차량의 자유속도의 변화를 예측하였다.

II. 기존문헌 고찰

1. 자유속도의 정의

자유속도에 관하여는 여러 가지 정의가 내려져 있는데, McShane(1990)은 '밀도가 0일 경우의 이론적인 속도'라고 정의하였고, 자유교통류에 대하여 '주위의 자동차에 영향을 전혀 받지 않고 주행할 수 있는 상태. 교통류 내에서 원하는 속도의 선택과 방향조작이 자유롭다.'고 하였다.

미국의 Transportation Research Board (TRB) (2000)에서는 '자유속도는 교통량이 낮은 도로에서 운전자가 제어시설에 영향을 받지 않은 희망속도로 주행할 때의 평균속도'로 정의하고 있고, 자유속도는 아니지만 유사한 의미로 통용되는 운행속도에 대하여 American Association of State Highway and Transportation Officials (AASHTO)(2001)는 '자유유리 상태에서의 차량의 속도'로 정의하고 있다. 결국, 자유속도는 교통관제 시설의 영향을 받지 않고, 교통류에 의해서도 영향을 받지 않으며 주어진 도로기하구조 상태에서 운전자가 자유롭게 주행하고자 하는 속도를 의미한다고 할 수 있다.

2. 자유속도에 영향을 미치는 도로설계요소

Highway Capacity Manual(HCM)(2000)에서 자유속도에 영향을 미치는 요인으로 제시하는 것은 아래와 같다.

- 1) 차로폭과 측방여유폭 : 차로폭이 3.6m에 미치지 못하면 운전자들은 다른 차량과 횡적으로 근접하여 운행하는 것을 감속으로써 보상받으려 한다. 측방여유폭도 같은 맥락에서 이해할 수 있으나 중앙쪽의 차로보다 외측차로가 근접운행의 영향을 더 많이 받는 것으로 나타났다
- 2) 차로수 : 차로가 증가하면 느린 차량군을 회피하

여 운행할 수 있는 기회가 많아지므로 평균주행 속도를 높이는 효과가 있다.

- 3) 입체교차로 밀도 : 입체교차로에서 일어나는 합류와 엇갈림 교통의 영향으로 입체교차로의 밀도가 증가할수록 자유속도는 감소한다.
- 4) 기타 : 중요한 물리적인 요인으로 결정된 설계속도는 속도에 영향을 미치는데, 특히 평면선형과 종단선형은 주어진 고속도로 구간에서 자유속도에 영향을 미친다. 만일, 고속도로가 중요한 평면 및 종단곡선의 특성을 가진다면 분석가는 현장의 실측을 통하여 자유속도를 측정하는 것이 좋다.

Fitzpatrick(2001)은 여러 가지 도로요인이 운전자의 행태에 미치는 영향을 85%속도에 대하여 다중회귀분석을 이용하여 분석하였으며 결과는 다음과 같다.

- 1) 선형과 횡단면 구성이 곡선구간과 직선구간에서의 속도분포를 25%정도 설명한다.
- 2) 직선구간에서는 거의 영향을 미치지 않고, 곡선구간에서는 약 40% 속도분포를 설명한다.
- 3) 속도제어시설은 53%까지 속도분포에 영향을 미치는 것으로 나타났다.
- 4) 직선구간에서는 제어시설만이 영향을 미치는 요인인 반면, 곡선구간에서는 제어시설에 더하여 편기각, 접근사설 등이 영향을 미치는 것으로 분석되었다.

Kyte(2000)는 환경적 요인인 날씨가 자유속도에 미치는 영향을 연구하여 다음과 같은 결론을 내렸다.

- 1) 가벼운 비 혹은 심한 비와 눈은 HCM에서 언급된 것보다 50%이상 영향을 미친다.
- 2) 심한 눈은 HCM에 언급된 것보다 20% 작은 영향을 미친다.
- 3) 강풍에 대한 고려가 필요하다.

Ottesen(2001)은 100kph 미만의 설계속도를 가지는 도로에서의 속도연속성위배를 조사하기 위한 평가도구의 개발에 관한 연구를 하였는데, 직선구간에서 곡선구간으로 진행하는 차량 운행속도의 감속 예측방법을 개발하였다.

평면곡선부에서 85%속도를 예측함에 있어서 회귀식을 도출한 결과는 <표 1>과 같고, 3차식, 지수식 등의

<표 1> Ottesen의 회귀식 산출결과

회귀식 형태	R ²	RMSE
직선식	0.80	5.2
역함수식	0.80	5.7
3차식	0.82	5.0
지수식	0.81	5.4

RMSE (Root Mean Square Error) : 관측값과 예측값의 차의 제곱을 자료수로 나눈 값의 제곱근

<표 2> 4차로 국도 평면곡선부에서의 85%속도특성

	직선부	곡선시점	곡선중점
최저속도	92	87	86
최고속도	110	109	106
평균속도	100	97	94

여러 가지 회귀모형 중 직선식이 모형의 적합성, 간편함, 실용성, 분포 측면에서의 비교를 통하여 가장 적합한 형태로 결정되었다.

연구결과로 곡률, 곡선길이, 편기각은 회귀식의 독립변수로써 통계적으로 유의한 것으로 나타났지만, 시거, 직선구간길이, 선행곡선의 곡률, 편구배, 도로폭, 총포장폭은 유의하지 않은 것으로 나타났다. 그리고, 85%속도는 degree of curve 4°(반경 5,729.58/4 = 1,432.39m) 이하에서는 곡선구간속도는 직선구간속도와 차이를 보이지 않았다.

고종대(2002)는 4차로 국도 평면곡선부에서 선형조건별로 곡선부 85%속도의 특성을 분석하고 주행속도를 추정하는 모형을 제시하였는데, 최저 85%속도가 발생하는 지점은 곡선부의 4/L지점과 곡선부 중앙지점으로 나타났으며, 곡선반경과 직선부 85%속도가 곡선부 85%속도에 중요한 영향을 미친다고 하였다. 국도에서의 85%속도의 특성은 <표 2>에 나타나있다.

3. 평면곡선부 주행행태에 관한 연구

희망속도로 직선구간을 주행한 운전자들은 곡선구간에 접근하기 전에 어느 정도 속도를 줄이게 되고, 곡선내에서 최저 속도까지 감속하였다가, 다시 가속하여 희망속도로 복귀하게 된다. 이점호(2000)는 곡선 내에서 주행하는 운전자들의 최저 자유속도가 나타나는 지점은 곡선시작지점(Point of Curve)이나 곡선중앙지점보다는 곡선시작지점과 곡선중앙지점 사이에서 나타나는 것으로 분석하였다. 속도가 가장 낮게 나타나는 곡선상의 위치에 대해서 최재성 모형(1998)은 곡선의 시작지점

으로, 미국의 Texas Transportation Institutes (TTI)(1996)의 연구결과에서는 곡선의 중앙부로 제시하고 있으며, 고종대(2002)는 곡선반경이 작을 경우(곡선부 중앙)와 곡선반경이 클 경우(곡선부 4/L)로 나누어서 제시하였다. 한편 최재성 모형(1998)과 Watanatada(1987)의 연구결과에 의하면 곡선상의 속도는 최저속도로 감소된 후, 운전자의 시거가 증가할 때까지 최저속도로 한동안 유지하다가 점차 증가하게 된다고 하였다.

Lamm(1987)은 미국 뉴욕에서 2차로 지방부도로의 연속성에 대한 연구를 진행하면서 261개 지점의 속도를 표본조사하여 회귀식을 도출하였으며 이때의 R^2 는 0.787, Standard Error of Estimate (SEE)는 3.259였다.

$$V_{85} = 58.656 - 1.135DC \quad (1)$$

여기서, V_{85} : 85% 속도(mph)

DC : Degree of Curve($^{\circ}$)

McFadden(2001)은 곡선부와 직선부의 속도자료를 토대로 평면곡선부에서의 감속, 차량의 속도에 영향을 미치는 매개변수를 조사하였고 이를 기준의 모형들에 적용하여서 설계일관성을 평가하고자 하였다. 실험구간은 <표 3>과 같이 선정되었다.

<표 3> McFadden의 자료수집구간 선정(1)

설계요소	제한값
곡선부이전 직선구간	150m이상
구배	5%이하
곡선길이	90~250m
차로폭	3.05~3.66m
곡률	1~1.5 $^{\circ}$
반경	150~1,800m
통행량	500~4,000vehicle/day

실험을 통하여 수집된 자료를 분석한 결과로 얻어진 다중회귀모형은 다음과 같다.

$$V_{85\text{redux}} = -14.90 + (0.144 \times V85@PC200) + (0.0153 \times LAPT) + \left(\frac{954.55}{R}\right) \quad (2)$$

$$V_{85\text{redux}} = -0.812 + (998.19/R) + (0.017 \times LAPT) \quad (3)$$

여기서,

$V_{85\text{redux}}$: 곡선부에서 감속(kph)

$V85@PC200$: 곡선시점으로부터 200m 전방의 85%속도(kph)

R : 곡선반경(m)

LAPT : 직선부 길이(m)

Ottesen(2001)의 연구에서 단순회귀와 다중회귀의 결과로 얻어진 식은 다음과 같다.

$$V_{85} = 103.66 - 1.95D \quad (4)$$

$$V_{85} = 102.44 - 1.57D + 0.012L - 0.01DL \quad (5)$$

$$V_{85} = 41.62 - 1.29D + 0.0049L - 0.12DL + 0.95V_t \quad (6)$$

여기서,

V_{85} : 85%속도(kph)

D : Degree of Curve($^{\circ}$)

L : 곡선장(m)

V_t : 직선부의 85%속도(kph)

4. 인공신경망

신경망에 관한 연구는 컴퓨터보다 우수한 인간의 두뇌의 신경세포 모델을 모방하는 연구로 전통적인 인공지능 기법으로 해결할 수 없었던 문제들의 해결 가능성을 보여주었다. Perceptron과 같이 하나의 조정층으로 구성된 신경망 모형들은 수학적인 분석을 통하여 XOR 함수와 같이 단순한 비선형 분리 문제를 풀 수 없다는 것을 밝힌 후 침체되었는데, 약 20년 후 Multi-layer Perceptron이 제안되면서 다시 활성화되었다. 특히 Parallel Distributed Processing(PDP)그룹에서 제안한 모델은 은닉층과 역전파(back-propagation) 학습알고리즘을 사용함으로써 선형분리 문제뿐만 아니라 여러 가지 문제점을 해결할 수 있는 계기가 되었다.

신경세포와 인공신경세포는 각각 뇌와 신경망에 있어 정보를 처리하는 기본단위이다. 먼저 하나의 신경세포는 자신과 연결된 많은 다른 신경세포들로부터 전기, 화학적 신호들을 시냅스를 통해 받아들여 종합한다. 그

리고 그 값이 역치(threshold)라고 부르는 신경세포 고유의 한계값보다 커지면 신경세포는 발화(fire)되어 다른 신경세포에 자신의 출력을 전달한다. 이 때, 신경세포 내에서의 정보전달은 전기적 펄스에 의해 이루어지며, 시냅스에서의 정보전달은 화학물질에 의해 이루어진다. 즉, 다른 신경세포들로부터 받아들인 신호들을 종합한 결과, 자신의 내부 전압이 역치 이상이 되면 그 신경세포는 발화되고, 전기적 펄스가 발생되어 출력선인 축색돌기를 통해 다른 신경세포로 전달되는 것이다.

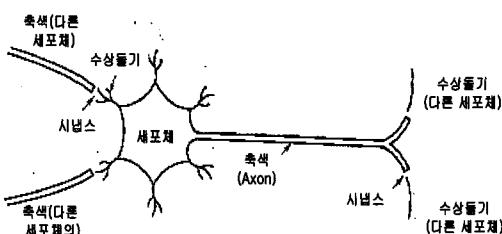
신경망의 특성은 〈표4〉와 같으며, 신경망은 학습방법, 신경망의 위상, 자료의 종류 등의 변화에 따라서 무수히 많은 종류가 존재하며 대표적인 예는 〈표 5〉와 같다.

이중 역전파 학습 알고리즘의 기본원리에 대하여 살펴보면 다음과 같다. 입력층의 각 Unit에 입력패턴을 주면, 이 신호는 각 Unit에서 변환되어 은닉층에 전달되고 최후에 결과층에서 신호를 출력하게 된다. 이 결과값과 기대값을 비교하여 차이를 줄여나가는 방향으로 연결강도를 조절하고, 상위층에서 역전파하여 하위층에서는 이를 근거로 다시 자기층의 연결강도를 조정해나가는 것이다.

〈그림 2〉는 인공신경망 모형을 나타낸 그림이며 화살표 방향으로 출력을 생산하게되며, 화살표 반대방향으로 학습이 이루어진다.

역전파 학습 알고리즘의 학습과정은 다음과 같다.

- 1) network의 상태를 결정하는 연결강도 W_{ji} , W_{kj} 와 offset θ_j , θ_k 를 각각 아주 작은 값의 임의수로 초기화한다. 일반적으로 $-0.5 \sim 0.5$ 사이



〈그림 1〉 뉴런의 기본구조

〈표 4〉 신경망의 특성

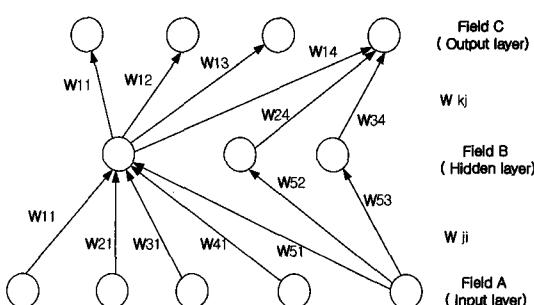
신경망의 특성	
1) 신경망은 프로그램되지 않는다.	
2) 신경망 구조는 정보를 분산된 형태로 코드화한다.	
3) 신경망은 병렬 분산처리된다.	

〈표 5〉 신경망의 대표적인 종류

구분		구분	
학습 방법	신경망 위상	중분류	세분류
감독 학습	feed-forward	linear	Hebian, Perceptron, Adaline, Higher Order, Functional Link
		MLP	Backprop, Cascade Correlation, Quickprop, RPROP
		RBF network	Orthogonal Least Square
		CMAC	
	Classification only		LVQ(Learning Vector Quantization), PNN(Probabilistic Neural Network)
	Regression Only		GNN(General Regression Neural Network)
비 감독 학습	BAM		
	Boltzman Machine		
	feed-back	Recurrent time series	Backpropagation through time, Elman, FIR, Jordan, Real-time recurrent network, Recurrent backpropagation, TDNN
	competitive		ARTMAP, Fuzzy ARTMAP, Gaussian ARTMAP, Counterpropagation, Neocognitron
비 학습	competitive	Vector Quantization	Grossberg, Kohonen, Conscience
		self-organizing MAP	Kohonen, GTM, Local Linear
		Adaptive resonance theory	ART1, ART2, ART2-A, ART3, Fuzzy ART
		DCL	
	Dimension Reduction		Hebbian, Oja, Sanger, Differential Hebbian
	Association		Linear autoassociator, BSB, Hopfield
	Hopfield		
	various networks for optimization		

의 값을 사용한다.

- 2) 학습패턴을 설정한다.
- 3) 학습패턴의 값을 입력층 Unit에 제시하여 출력되는 값 o_{pi} , 입력층과 중간층 사이의 연결강도 W_{ji} 와 중간층 j 의 offset θ_j 를 이용하여 중간층 Unit j 의 입력 net_{pj} 를 구한다. 다음으로 net_{pj} 와 Sigmoid 함수 f 를 이용하여 중간층 Unit j 의 출력 o_{pj} 를 구한다.



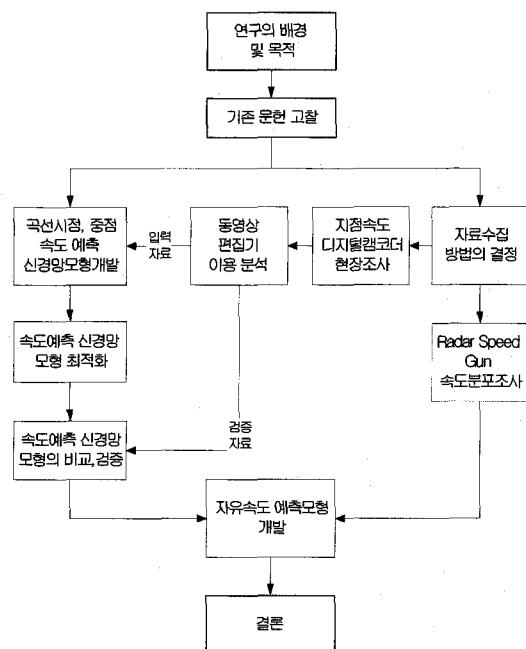
〈그림 2〉 인공신경망

- 4) 중간층 Unit의 출력 op_j , 중간층과 출력층 사이의 연결 강도 Wkj 와 출력층 Unit k의 Offset θ_k 를 이용하여 출력층 Unit k의 입력 $netpk$ 를 구한다. 다음 $netpk$ 와 시그모이드 함수 f 를 이용하여 출력층 Unit k의 출력 opk 를 구한다.
- 5) 학습패턴의 목표출력 tpk 와 실제 출력 opk 의 차로부터 출력층 Unit k에 연결된 연결강도와 출력층 Unit k의 Offset에 대한 오차 δpk 를 구한다.
- 6) 오차 δpk 와 중간층과 출력층간의 연결강도 Wkj 와 중간층의 출력 $netpj$ 로부터 중간층 Unit j에 연결된 연결강도와 중간층 Unit의 Offset에 대한 오차 δpj 를 구한다.
- 7) 5단계에서 구한 출력층 Unit k에서의 오차 δpk , 중간층 Unit j의 출력 opj , 정수 a 와의 곱을 더하여 중간층 Unit j와 출력층 Unit k에 연결된 연결강도 Wkj 를 수정한다. 또 오차 δpk 와 정수 b 와의 곱을 더하여 출력층 Unit k의 Offset θ_k 를 수정한다.
- 8) 중간층 Unit j의 오차 δpj , 입력층 Unit i의 출력 opi , 정수 a 와의 곱을 더하여 입력층 Unit i와 중간층 Unit j에 연결된 연결강도 Wji 를 수정한다. 또 오차 δpj 와 정수 b 와의 곱을 더하여 중간층 Unit j의 Offset θj 를 수정한다.
- 9) 다음패턴을 학습시킨다.
- 10) 모든 학습패턴에 대하여 전부 학습할 때까지 2 단계로 되돌아간다.
- 11) 학습의 반복중지 조건을 만족시키지 못하면 2 단계로 되돌아간다.
- 12) 종료

1) 한국도로공사 전자도면(dwf파일)

III 연구방법

연구의 전체적인 진행 방법을 제시하고, 자료의 수집 및 분석에 관하여 서술하고자 한다. 연구진행의 순서는 〈그림 3〉과 같다.



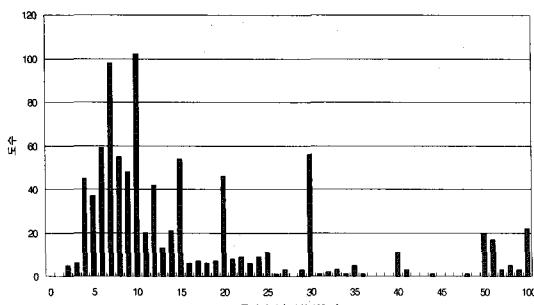
〈그림 3〉 연구진행의 순서도

1. 자료수집

본 연구의 조사지점은 전국 고속도로 총 연장 2,294km 중 무작위로 1,498km 구간(총 연장의 65%)을 선정하여 설계도면¹⁾을 토대로 781개의 평면곡선 구간의 자료가 수집되었으며, 확보한 도면의 평면곡선반경의 도수분포는 〈그림 4〉와 같다.

Ottessn(2001)의 연구결과는 ‘곡선반경이 1,432m 이상이면 직선구간의 속도와 곡선구간의 속도는 차이를 보이지 않는다.’고 하였다. 따라서 1,400m 이하의 구간을 연구대상으로 선정하고, 높은 도수를 보이는 곡선반경 400m에서 1,000m 사이를 조사대상으로 하였고, 이외의 속도자료수집지점의 제약조건은 〈표 6〉과 같다.

자유속도에 차량의 성능으로 인한 감속의 영향이 미치지 않도록 5% 이내의 종단구배를 가지는 지점으로 조



〈그림 4〉 곡선반경 도수분포 그래프

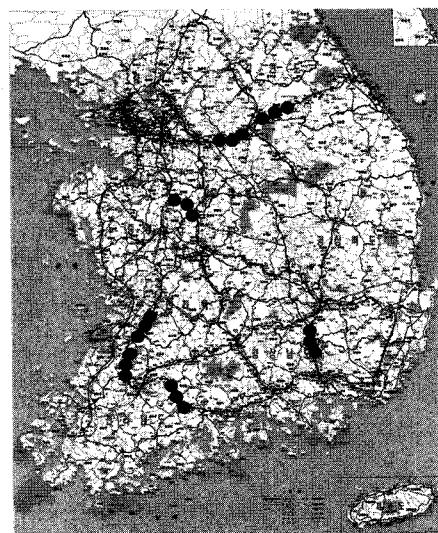
〈표 6〉 조사지점의 범위 및 특성

설계요소	조사지점의 범위 및 특성
곡선부이전 직선구간	150m이상
구배	5%이하
곡선길이	406~1,160m
곡선반경	400~1,000m
제한속도	100kph
제어시설	과속단속카메라 없음
유출입 램프로부터의 거리	1km이상

사지점을 한정하였고, 과속카메라 등의 속도제어시설이 감속을 유도하지 않도록 제어시설이 설치된 지점을 제외하였으며, 유·출입로에서의 운전자작업부하의 영향을 배제하기 위하여 유·출입로로부터 1km이상 떨어진 지점을 자료수집 대상지역으로 선정하였다. 직선부속도를 측정하기 위하여 150m이상의 직선구간 길이를 가지는 지점을 선택하였는데, 이는 McFadden(2001)의 연구 조건과 동일한 것이다. 제약조건을 충족하는 다수의 후보지점을 선정한 후에 현장답사를 통하여 자료의 취득이 용이한 3개 Set의 7개 지점, 총 21개 지점을 속도자료 수집 조사대상지점으로 선정하였으며, 도면을 확보한 고속도로 노선 중에서 경부선, 중부내륙선, 호남선, 영동선을 대상으로 하였다.

〈그림 5〉는 속도조사지점의 지도상의 위치를 표시한 것이고, 〈표 7〉은 조사지점의 설계요소를 나타낸 것이다.

연구에 사용된 자료는 직선구간과 곡선시점, 곡선중점의 지점속도를 측정하기 위한 자료와 곡선구간에서의 속도변화를 관찰하기 위한 속도자료로 구분된다. 지점속도의 수집방법은 자료수집구간의 직선구간과 곡선시점·곡선중점구간에서 디지털캠코더를 3대 설치하여 〈그림 6〉과 같이 동시에 촬영하였다. 직선구간은 곡선시점으로부터 100m 상류부 지점을 기준으로 하였으며, 고속도로상의 이정표지를 기준으로 walking measure를 이용하여



〈그림 5〉 조사지점의 위치

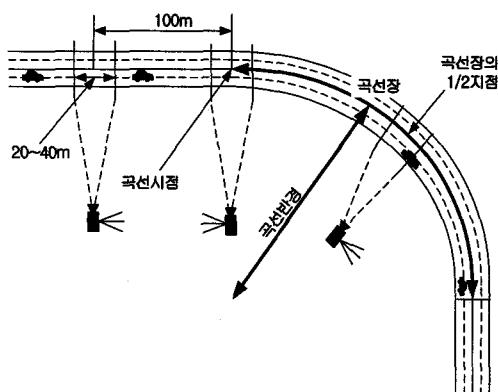
〈표 7〉 조사지점의 도로설계요소

지점	도로노선	지점(km)	제한속도(kph)	반경(m)	곡선장(m)	연구구간(%)	차로수(면)	종단구배(%)		
								직선구간	곡선시점	곡선중점
1	호남	145 (하)	100	400	358	7	2	-3.1	-2.34	-1.7
2	구파	23 (상)	100	500	528	6	2	0.53	0.53	2.8
3	경부	107 (상)	100	600	1,160	6	3	-0.01	-0.01	2.54
4	영동	58.5 (상)	100	700	1,114	5	2	2.35	2.1	-1.7
5	영동	95.5 (상)	100	750	506	5	2	-2.1	-2.22	-1.55
6	호남	220 (상)	100	900	476	4	2	2.5	2.5	2.34
7	호남	152 (상)	100	1,000	499	4	2	-3.35	-1.2	-1.4

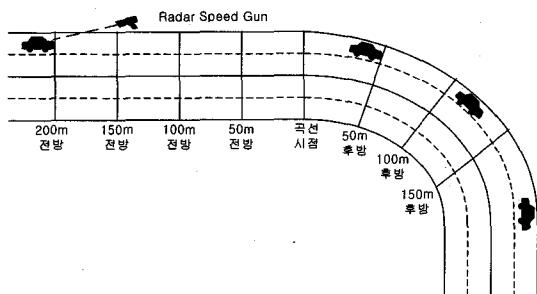
도면상의 곡선시점을 조사지점의 도로상에서 설정하였다. 곡선중점은 곡선시점으로부터 도면상의 곡선장의 1/2만큼을 동일하게 walking measure를 이용하여 찾았으며, 각 캠코더에서의 촬영구간은 곡선시점으로부터 100m 상류부지점, 곡선시점, 곡선중점을 기준으로 상류부와 하류부 양방향으로 대칭이 되도록 최소 20m, 최대 40m의 구간을 촬영하였다.

측정시 캠코더의 위치는 운전자들의 시야에 잘 노출되지 않는 곳으로 설정하였으며 촬영 시에는 촬영자는 자리를 피하여 운전자 시선유도로 인한 영향을 제거하였다.

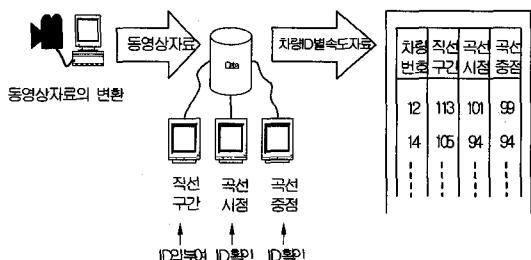
수집된 영상자료는 컴퓨터파일로 동영상 압축시킨 후



〈그림 6〉 지점속도 자료수집방법



〈그림 8〉 속도변화를 관찰하기 위한 자료수집방법



〈그림 7〉 속도자료의 변환과정

에 동영상편집기를 사용하여 초당 30프레임(=1/30sec)의 정지화면으로 변환하여 속도를 측정하였다. 동영상 파일로 저장된 녹화자료를 직선구간, 곡선시점, 곡선중점의 세 개의 화면으로 동시에 조사하면서 개별차량에 대한 번호를 부여하여 차량의 연속적인 속도를 수집하고자 하였으며, 이로 인하여 더욱 정확한 차량운행 행태를 알아내고자 하였다. 〈그림 7〉은 속도자료의 변환과정을 묘사한 것이다.

개별차량의 수집된 속도자료 중 5초 이상의 차두시간을 갖는 승용차량의 속도자료를 자유속도 자료로 분류하였는데, 이는 '차두거리(headway)가 5초 이상인 차량은 자유속도로 주행한다.'는 Fitzpatrick(2001)의 연구결과에 따른 것이다. 세 지점(직선구간, 곡선시점, 곡선중점)에서 707개 Set을 수집하여, 총 2121개(707×3) 자유속도자료를 수집하였다. 캠코더의 설치를 위해서, 조사구간은 반경 400m의 경우를 제외하고 절도부에서 조사가 진행되었다.

곡선구간에서의 속도변화를 관찰하기 위한 속도자료의 수집방법은 레이더 Speed Gun을 이용하여 〈그림 8〉과 같이 곡선시점으로부터 전방 200m부터 50m 간

격으로 곡선후방 150m까지 관측하였다. Speed Gun을 이용한 자료수집은 지점속도의 수집방법과 동일하게 차두거리가 5초 이상인 승용차량에 한하여 호남고속도로 하행 145km지점에서 8개 set의 총 322개의 속도자료가 수집되었다.

날씨는 자유속도에 영향을 미치는 인자로 특히 눈, 비의 경우 그 영향이 매우 큰 것으로 드러나 있다. 조사시의 기후는 눈, 비가 없고, 안개가 끼지 않으며, 강풍이 불지 않을 때를 기준으로 하였다. 또, 포장의 상태는 습윤하지 않은 상태를 기준으로 하였다.

2. 자료분석

직선구간과 곡선시점, 곡선중점에서 수집된 속도자료의 평균, 표준편차 등의 특성을 자료수집지점 곡선반경의 오름차순으로 정렬한 것은 〈표 8〉이다.

조사지점의 평균속도의 경우 직선구간은 99.46~113.37kph, 곡선시점은 93.17~103.87kph, 곡선중점은 91.26~106.64kph의 범위를 나타내었으며, 표준편자는 직선구간은 10.00~16.13kph, 곡선시점은 10.99~16.66kph, 곡선중점은 9.98~17.82kph의 범위를 나타내었다. 곡선시점과 곡선중점의 속도를 비교하여 보면, 호남고속도로 145km지점(1), 경부고속도로 107km지점(3), 영동고속도로 95.5km지점(5), 호남고속도로 152km지점(7)은 곡선시점이 직선구간이나 곡선중점구간보다 낮은 속도를 나타냈고, 구마고속도로 23km지점(2), 영동고속도로 58.5km지점(4), 호남고속도로 220km지점(6)은 곡선중점이 직선구간이나 곡선시점구간보다 낮은 속도를 나타냈다. 기하구조와 관련하여서는 종단구배 -2%를 기준으로 직선구간의 속도를 비교하여 보면, 종단구배 -2%이하인 호남고속도로 145km지점(1), 영동고속도로 95.5km지점

〈표 8〉 지점속도자료의 평균 및 표준편차 (단위:kph)

조사지점	자료수	조사구간	평균	표준편차	85%속도	15%속도	최고속도	최저속도	중위속도
1 89	89	직선	107.81	13.31	121.03	94.86	140.40	80.69	117.00
		곡선	95.28	11.09	104.52	82.24	120.00	72.00	88.77
		곡선	95.41	10.66	106.23	84.16	122.26	72.81	106.23
		차1	12.53	5.05					
		차2	-0.12	3.61					
2 125	125	직선	107.92	15.71	123.43	93.91	154.29	72.00	113.68
		곡선	98.7	12.23	112.50	87.10	135.00	69.23	93.10
		곡선	97.32	11.81	108.00	87.10	135.00	67.50	90.00
		차1	9.22	8.37					
		차2	1.38	5.65					
3 70	70	직선	105.64	10.00	115.71	95.29	129.60	85.26	108.00
		곡선	93.17	12.35	108.00	83.08	120.00	72.00	90.00
		곡선	98.33	9.98	108.00	90.00	120.00	72.00	98.182
		차1	12.47	10.45					
		차2	-5.16	9.51					
4 57	57	직선	99.46	16.13	112.90	82.45	137.9	64.16	98.18
		곡선	94.94	14.57	108.00	80.00	127.1	58.38	98.18
		곡선	91.26	11.4	105.40	80.00	120.00	60.00	90.00
		차1	4.52	6.15					
		차2	3.68	7.78					
5 71	71	직선	113.37	13.45	130.91	100.47	135.00	77.14	108.00
		곡선	103.79	12.39	116.76	90.00	127.06	75.79	96.00
		곡선	106.04	11.37	116.76	93.91	135.00	75.79	100.47
		차1	9.59	7.6					
		차2	-2.25	8.97					
6 143	143	직선	105.82	15.33	120.00	92.57	147.27	57.86	104.52
		곡선	99.85	16.66	113.68	86.40	144.00	63.53	98.18
		곡선	97.09	17.82	113.68	80.00	154.29	60.00	98.18
		차1	5.97	14.39					
		차2	2.76	17.76					
7 151	151	직선	109.46	12.13	123.43	98.18	144.00	80.00	100.47
		곡선	103.87	10.99	115.71	92.57	135.00	75.35	108.00
		곡선	106.64	10.49	115.71	95.29	135.00	81.00	104.52
		차1	5.59	4.28					
		차2	-2.77	5.01					

차1 = 직선부 속도 - 곡선시점의 속도

차2 = 곡선시점의 속도 - 곡선중점의 속도

(5), 호남고속도로 152km지점(7)의 경우, 직선구간 속도가 종단구배 -2%를 초과하는 나머지 지점의 직선 구간 속도보다 높게 나타났으며, 직선구간과 곡선구간에서의 속도차이는 반경에 반비례하여 감소하였다. 이는 운전자에게 주어지는 작업부하나 심리적인 불안감에 기인한 정상적인 운행행태이다.

국도의 속도자료(2장, 〈표 2〉참고)와 비교하면, 영동고속도로 58.5km지점(4)을 제외하고는 국도보다 5kph이상 높은 평균속도를 나타냈고, 모든 지점에서 국도의 최고속도 혹은 최저속도와 평균속도의 편차범위

〈표 9〉 지점속도자료의 분산분석 결과

조사지점	1	2	3	4	5	6	7
F_{value}	33.43	23.26	23.42	4.79	11.54	10.29	9.36
F^*_{value}	3.03	3.02	3.04	3.05	3.04	3.02	3.02
H_0	기각	기각	기각	기각	기각	기각	기각

보다 비슷하거나, 높은 표준편차를 보여서 고속도로의 자유속도의 분산이 국도의 분산보다 큰 경향을 나타내었다.

각 지점에서 나타난 속도자료의 통계적인 분석을 위하여 '직선구간에서 곡선구간으로 주행을 하면 감속을 한다.'는 가설의 검정을 위하여 아래와 같은 귀무가설과 대립가설을 수립하고 분산분석을 수행하였다. 통계프로그램인 Statistical Analysis System (SAS)을 이용하였고, 신뢰수준은 95%이며, 결과는 〈표 9〉와 같다.

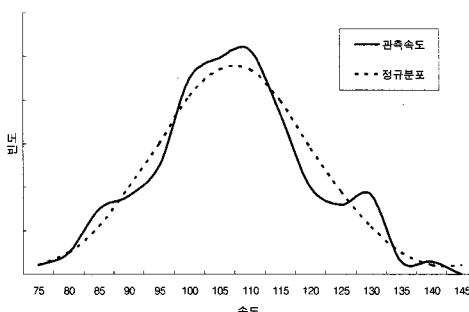
$$H_0 : \mu_{\text{직선구간}} = \mu_{\text{곡선시점}} = \mu_{\text{곡선중점}}$$

$$H_a : \text{적어도 한쌍의 } \mu_i \text{ 가 서로 다르다.}$$

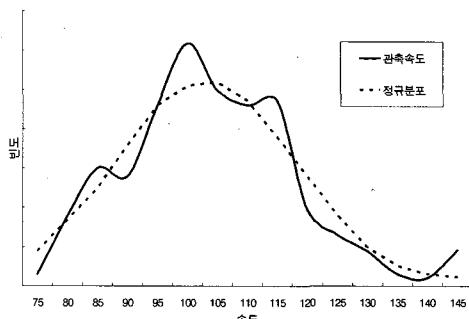
모든 조사지점에서 귀무가설을 기각하므로 세 지점에서의 속도는 차이가 있는 것으로 나타났다.

속도자료에서의 직선구간의 속도의 분포를 종단구배와 관련하여 종단구배 -2%이하인 구간과 그렇지 않은 구간으로 나누어 〈그림 9〉와 〈그림 10〉에 표현하였다.

종단구배 -2%를 기준으로 분류한 직선구간의 속도가 정규분포를 따르는지 알아보기 위하여 '속도분포는 정규분포이다.'는 귀무가설을 수립하고, χ^2 적합도 검정을 신뢰수준 95%로 실시하였으나 귀무가설이 기각되어 99%로 실시하였으며 그 결과는 〈표 10〉과 같다.



〈그림 9〉 종단구배 -2%이하인 구간의 속도분포



〈그림 10〉 종단구배 -2%이하가 아닌 구간의 속도분포

〈표 10〉 직선구간속도 자료의 적합도 검정 결과

구간	χ^2 -value	χ^{2*} -value	H_0
종단구배 -2% 이하 구간	15.53	18.48	기각불가
종단구배 -2% 초과 구간	17.53	18.48	기각불가

95%유의수준에서 귀무가설이 기각되는 것은 자료의 수가 부족하여 나타난 것으로 보여지며, 99%유의수준으로 검정한 결과 '속도분포는 정규분포다.'는 귀무가설을 기각하지 않으므로 속도분포는 정규분포를 따른다고 할 수 있다. 그리고 종단구배 -2%이하의 직선구간이 그렇지 않은 종단구배 특성을 가진 구간보다 더 높은 속도를 나타내는지에 대하여 검증하기 위하여 '종단구배 -2%이하인 구간과 종단구배 -2%이하가 아닌 구간의 직선부 속도평균은 차이가 없다.'는 귀무가설을 수립하고 신뢰수준 95%로 통계프로그램인 SAS를 이용하여 t -test를 실행하였고, 결과는 〈표 11〉과 같다.

종단구배 -2%이하인 구간과 -2%이하가 아닌 직선구간의 속도 평균은 차이가 없다는 귀무가설이 기각되므로 하향구배 2%를 기준으로 직선구간의 차량주행속도는 차이가 있는 것으로 나타났다.

자유속도의 변화를 관찰하기 위한 Radar Speed Gun 자료의 평균, 표준편차 등의 특성은 〈표 12〉와 같다.

속도분포자료의 평균속도는 95.3~106.45kph의 범위에서 곡선시점의 200m전방에서부터 후방으로 전

〈표 11〉 직선구간속도자료의 t -test 결과

구분	평균	표준 편차	F -value	$F^{*}-v$ alue	t -value	$t^{*}-v$ alue	H_0
종단구배 -2%이하	109.8	12.8					
	7	8					
종단구배 -2%초과	105.5	14.9	1.35	1.19	4.13	1.96	기각
	3	6					

〈표 12〉 속도분포자료의 특성 (단위:kph)

곡선시점 기준위치	200m 전방	150m 전방	100m 전방	50m 전방	0m	50m 후방	100m 후방	150m 후방
평균속도	106.45	106.40	101.95	99.05	98.26	95.27	95.07	95.30
표준편차	12.81	16.42	10.32	12.28	12.89	8.66	8.22	8.41
85%속도	121.45	114.90	112.00	107.45	110.45	103.00	108.10	104.00
15%속도	93.55	93.55	93.00	88.65	86.55	87.45	86.00	85.45
최고속도	138.00	167.00	131.00	141.00	133.00	120.00	113.00	112.00
최저속도	75.00	83.00	84.00	77.00	69.00	78.00	82.00	78.00
중위속도	101.00	95.00	95.00	103.00	89.00	93.00	90.00	98.00

〈표 13〉 속도분포자료의 적합도 검정 결과

곡선시점 기준위치	200m 전방	150m 전방	100m 전방	50m 전방	0m	50m 후방	100m 후방	105m 후방
χ^2	3.06	7.30	3.06	7.00	0.94	8.73	4.86	4.86
χ^{2*} (95%)	5.99	5.99	5.99	5.99	5.99	5.99	5.99	5.99
χ^{2*} (99%)	9.21	9.21	9.21	9.21	9.21	9.21	9.21	9.21

행하며 감소하는 경향을 나타냈고, 특히 100m전방과 50m후방에서 상대적으로 큰 감소폭을 보였다. 표준편자는 8.22~16.42kph의 범위를 나타냈고, 직선구간보다 곡선구간에서의 편차가 작은 것으로 나타났다.

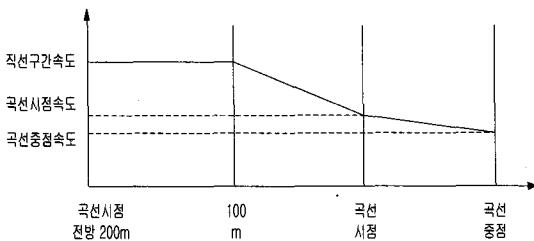
속도의 변화를 조사하기 위하여 레이더 Speed Gun으로 수집한 자료가 정규분포를 따르는지를 검증하기 위하여 '속도분포는 정규분포이다.'는 귀무가설을 수립하고, χ^2 적합도 검정을 신뢰수준 95%, 99%로 실시하였으며, 그 결과는 〈표 13〉과 같다.

95%유의수준에서는 150m전방, 50m전방, 50m후방에서 정규분포를 따르지 않는 것으로 나타났으나 이는 자료의 수가 부족함으로 인한 것으로 판단되어지며, 유의수준 99%에서 검증결과는 모든 위치에서 속도의

〈표 14〉 속도분포자료의 Duncan test 결과

곡선시점 기준위치	속도평균 (kph)	Duncan grouping		최소유의차
전방200m	106.45	A		R8 5.84
전방150m	106.40	A		R7 5.77
전방100m	101.95	A	B	R6 5.69
전방50m	99.05		B C	R5 5.59
0m	98.26		B C	R4 5.46
후방50m	95.27		C	R3 5.28
후방100m	95.06		C	R2 5.02
후방150m	95.30		C	

Ra : 속도평균을 내림차순 정리하여 계급차이가 a-1인경우의 최소유의차



〈그림 11〉 자유속도 예측모형의 구간분류

분포는 정규분포를 따르는 것으로 나타났다. 속도변화가 어떤 지점에서 유의한지를 알아보기 위하여 신뢰수준 95%의 Duncan's multiple range test를 SAS를 이용하여 실행하였으며 결과는 〈표 14〉와 같다.

분석결과 곡선시점 전방 200m에서 100m까지는 직선부의 속도를 유지하는 것으로 나타났으며 전방 50m 이후로는 통계적으로 유의성이 있는 속도평균의 변화가 없는 것으로 나타났다. 따라서 자유속도예측모형은 직선구간속도, 곡선시점속도, 곡선중점속도를 이용하여 〈그림 11〉과 같이 구간분류를 하였다.

IV 모형개발

McFadden(2001)은 선형회귀분석은 자료에 의하여 만족되지 못할 수도 있는 몇몇 가정들을 포함하고 있어서, 인공신경망을 이용하는 것보다는 효과적이지 못할 수 있다고 밝히고 있으며, 국내에서는 이종필(2002)이 신경망을 이용하여 지방부2차로도로의 주행 속도예측을 수행한 결과 기존 회귀모형에 비해 우수한 결과를 도출하는 것으로 밝힌 바 있다. 이에 본 연구에서는 역전파 학습알고리즘을 사용하는 인공신경망을 이용하여 자유속도 예측모형을 개발하고자 하였다.

1. 인공신경망 모형의 입력자료

입력자료는 기존 연구결과들을 바탕으로 선정하였다. 곡선반경과 곡선장은 Mclean(1978), Ottessn(2001) 등 대부분의 Speed-Profile 모형에서 이용되었으며, Fitzpatrick(2001)의 연구 결과에 의하면 횡단구성요소 또한 속도에 영향을 미치므로 차로수와 편구배를 입력인자로 선정하였고, 직선구간의 속도는 McFadden(2001)과 Ottessn(2001)의 연구결과를 참고하였다. 종단선형을 고려하기 위하여 직선구간과 곡선구간의 속도측정지점에서의 구배의 차이인자를 신

〈표 15〉 인공신경망 입력자료

입력 신경세포	1	2	3	4	5	6	7
구분	곡선반경	곡선장	편구배	차로수	구배차1	구배차2	직선부속도

구배차1 : 곡선시점 종단구배 - 직선부 종단구배

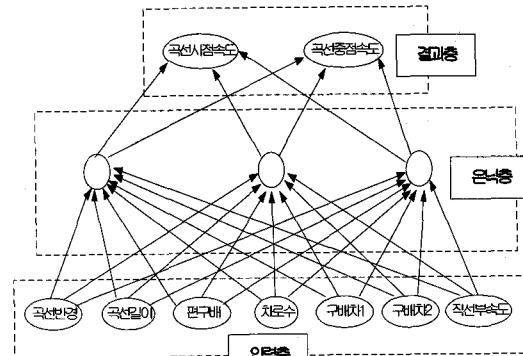
구배차2 : 곡선중점 종단구배 - 곡선시점 종단구배

경망의 입력인자로 선택하였다. 즉, 구배차이가 양의 값을 가지면 종단선형이 오목곡선(Sag curve)을, 음의 값을 가지면 볼록곡선(Crest curve)을 나타내며 그 값이 클수록 종단변화율이 큰 것을 나타낸다. 이처럼 구배의 차이를 모형의 입력값으로 사용하여 신경망을 학습시키면 종단선형이 평면선형과 복합될 때의 효과가 규명될 것으로 기대하였다.

결정된 인공신경망의 입력자료는 〈표 15〉와 같다.

2. 인공신경망 모형의 설계

신경망의 학습방법은 다층 Perceptron의 학습방법으로 사용되는 역전파 알고리즘을 채택하였다. 역전파 알고리즘은 최소자승 알고리즘의 비선형적인 확장으로 시그모이드함수를 전이함수로 이용하면 온너층의 학습



〈그림 12〉 인공신경망 모형

〈표 16〉 신경망의 구조와 학습방법

구분	값
입력 신경세포수(개)	7
온너층수(개)	1, 2, 3
온너층 신경세포수(개)	3, 6, 9
결과 신경세포수(개)	2
초기 가중치(weights)	0.45~0.55 난수발생
학습강도	0.15
옵셋	0.1
반복횟수	1,000회, 5,000회

〈표 17〉 신경망모형의 구조와 반복횟수에 따른 결과

대안 모형	온닉 총	온닉총 뉴런수	반복 횟수 (천회)	RMSE		%RMSE		퍼어슨 상관계수	
				곡선 시점	곡선 중점	곡선 시점	곡선 중점	곡선 시점	곡선 중점
1	1	3	1	7.01	10.33	0.07	0.11	0.82	0.68
			5	7.05	10.26	0.07	0.11	0.82	0.69
2	1	6	1	7.41	10.2	0.08	0.11	0.81	0.69
			5	7.15	10.23	0.08	0.11	0.82	0.68
3	1	9	1	7.43	10.31	0.08	0.11	0.8	0.68
			5	7.02	10.18	0.07	0.11	0.82	0.69
4	2	3	1	6.68	10.06	0.07	0.1	0.84	0.71
			5	6.9	10.31	0.07	0.11	0.83	0.69
5	2	6	1	6.91	10.91	0.07	0.11	0.84	0.68
			5	7.02	10.36	0.07	0.11	0.82	0.68
6	2	9	1	6.66	10.46	0.07	0.11	0.84	0.69
			5	7.17	10.42	0.08	0.11	0.81	0.68
7	3	3	1	6.82	10.46	0.07	0.11	0.83	0.7
			5	7.17	10.42	0.08	0.11	0.81	0.68
8	3	6	1	7.07	10.65	0.07	0.11	0.82	0.69
			5	6.81	10.01	0.07	0.1	0.83	0.71
9	3	9	1	12.69	13.81	0.13	0.14	0.26	0.4
			5	6.79	10.09	0.07	0.1	0.83	0.7

%RMSE (% Root Mean Square error) : RMSE를 관측값의 평균값으로 나눈 값

이 가능하며, 단층 퍼셉트론의 한계를 극복한 알고리즘으로 기술적인 응용분야에 널리 이용되고 있다. 본 연구에 이용한 신경망모형은 전산언어인 C++를 이용하여 프로그래밍 하였다.

인공신경망에 있어서 온닉총의 구조는 최적해를 구하는 과정에 있어서 대단히 중요한 영향을 미친다. Jacek(1992)은 온닉총의 크기를 결정하는 문제에 대해서는 결론지워진 해답이 없음을 밝히고 log2 M을 이용할 것을 권고하고 있으며, Laurene (1994)은 어떤 문제에 대해서 온닉총은 1개로도 충분하지만, 2개의 온닉총을 이용하면 더 쉽게 해결할 수 있음을 밝히고 있다. 온닉총은 신경망에서 매우 중요한 역할을 하고 있으나 그 설계의 최적화를 뒷받침하는 이론적 근거는 밝혀진 바가 없어서 흔히 신경망의 Black box로 불리우고 있다. 최근에는 유전자 알고리즘을 이용하여 인공신경망의 구조를 최적화하는 등의 노력이 취하여지고 있지만, 본 연구에서는 모형의 온닉총의 수와 온닉총의 신경세포 수를 다양하게 하여 구조를 변경하면서 반복실험하여 오차가 가장 작은 모형을 개발하고자 하였으며, 온닉총 수를 1, 2, 3으로 각 온닉총의 신경세포수를 3, 6, 9개로 변화시켜서 학습하였다.

학습강도도 신경망을 사용한 문제해결에서 효과와 신뢰도를 결정하는 중요한 인자의 하나다. Jacek(1992)은 학습강도가 크면 최적해로의 수렴의 속도는 빠르지만, 작을수록 최적해를 지나칠 위험이 줄어드는 관계가 있음을 제시하며 역전파 신경망모형에서 많은 기술적 논문들이 0.001~10의 범위에 해당하는 학습강도를 사용하여 성공적인 결론을 도출했음을 제시하였다. Jacobs (1988)는 0.1~0.8의 범위에 해당하는 학습강도를 사용하여 88~96%의 비율로 시뮬레이션에 성공하였다. 효과적인 학습강도의 결정을 위해서는 고정적인 학습강도를 사용하지 않고, 학습결과에 따라 변동하는 강도를 사용하는 Momentum 기법, delta-bar-delta 기법 등이 있으나 본 연구에서는 고정적인 학습강도 0.15를 사용하였다.

신경망의 학습에 큰 영향을 미치는 다른 인자로는 초기가중치가 있다. Laurene(1994)은 초기가중치가 과대할 경우 Sigmoid 함수가 매우 작은 값을 나타낼 우려가 있으므로 피하여야하고, 반대로 과소할 경우에는 학습에 많은 시간이 소요될 우려가 있음을 제시하고, -0.5~0.5(혹은 -1~1)의 범위에서 난수발생하여 사용하는 것이 일반적임을 밝히고 있다.

반복학습횟수는 많을수록 최적해에 근접할 가능성이 높은 반면, 신경망의 전역최적화점은 찾을 수 없으므로 무한히 반복학습할 수는 없다. 따라서, 오차의 범주를 설정하여 일정수준이하의 오차가 발생할 경우 학습을 중지시키는 방법과 고정적인 횟수를 부여하는 방법을 사용할 수 있는데, 본 연구에서는 고정적인 반복횟수 1,000회와 5,000회를 사용하였다.

신경망은 학습에 사용되는 자료의 특성에 따라서 모형화되어지므로, 학습에 사용되는 자료는 모집단의 특성을 잘 반영하여야 한다. 편향된 특성을 가진 자료를 사용하여 학습된 신경망은 왜곡된 결과를 산출할 수밖에 없을 것이다. 본 연구에서는 앞서 기술한 바와 같이 400~1400m의 곡선반경을 가지는 7개 지점의 781개의 자료를 이용하여 일반적인 고속도로의 특성을 학습시키고자 하였다. 학습에 사용되는 입력자료는 수집된 자료의 70%를 난수발생하여 선택, 이용하였고, 나머지 30%는 신경망모형의 검증단계에서 입력자료로 사용하였다.

〈그림 12〉는 신경망구조의 모형이고, 〈표 16〉은 신경망의 학습조건을 분류한 표이다.

신경망모형은 〈그림 12〉에서 점선으로 둘러싸인 부

분, 즉 은닉층에 해당하는 구조를 <표 16>에서와 같이 은닉층 수를 1, 2, 3으로 각 은닉층의 신경세포수를 3, 6, 9개로 변화시켜서 학습하였으며, 개별 구조마다 반복횟수를 1,000회, 5,000회로 설정하여 총 18개 ($3 \times 3 \times 2$) 구조 및 학습방법의 신경망 모형을 학습하여 모델링 하였다.

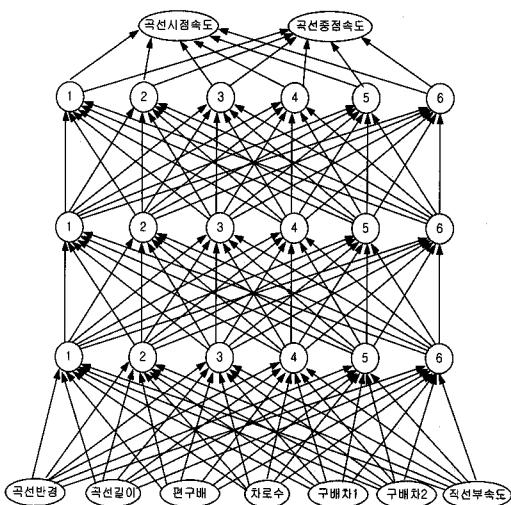
위와 같은 방법으로 학습된 신경망모형을 사용하여 검증을 위하여 남겨둔 수집된 자료의 30%에 해당하는 자료를 이용하여 얻은 결과는 <표 17>과 같다.

결과를 살펴보면 은닉층이 3개이고 각 은닉층의 신경세포수가 9개인 대안9 모형의 반복횟수가 1,000회

인 경우를 제외하면 모두 유사한 오차와 상관성을 나타내었다. 그 중에서 은닉층이 2개이고 각 은닉층의 신경세포수가 3개인 대안4 모형을 선택하여 1,000회 반복 학습한 모형이 곡선시점과 곡선중점에서의 모두 속도를 잘 표현하고 있으므로 이를 사용하여 현장관측속도와 모형예측속도를 비교하고자 하였다. 그러나 모형의 결과 출력 형태를 알아보기 위하여 다른 입력인자를 고정시키고 평면선형 입력만을 변화시킨 실험에서, 대안4 모형은 곡선반경이 감소하면 곡선에서의 속도가 오히려 증가하는 현실과 상반된 결과를 도출하여 자유속도 예측모형에 사용할 수 없었다. 여러 가지 대안을 위에 설

<표 18> 자유속도 예측모형 신경망의 구조

weight		목표층 신경세포					
		1	2	3	4	5	6
입력층	반경	0.647127	0.643977	0.77599	0.395323	0.532433	0.236831
	곡선장	-1.97265	0.265073	0.505231	-0.437853	1.00915	-0.10346
	편구배	-0.190557	0.219886	0.420791	0.0305375	1.34531	-0.139176
	차로수	-0.68388	0.16024	-0.181084	0.145041	-1.25804	0.149424
	구배차1	3.24493	-1.67506	-2.15223	-1.12818	-1.32164	-1.12899
	구배차2	-0.641947	-0.0998784	0.119563	-0.190854	1.37517	-0.11602
	직선부속도	4.00104	2.43436	2.44696	2.64574	3.601	2.06246
은닉 1 층	1	1.14679	1.40862	1.3234	1.36468	1.46694	1.18526
	2	0.610017	0.574906	0.630278	0.558123	0.575179	0.580056
	3	0.684899	0.600274	0.707864	0.6498	0.612663	0.723262
	4	0.594776	0.648727	0.587259	0.573754	0.662161	0.549973
	5	1.02182	0.804188	0.790233	0.849234	0.736989	0.979526
	6	0.434617	0.390593	0.367715	0.386219	0.39238	0.447907
은닉 2 층	1	-0.848987	-0.86894	-0.902357	-0.819981	-0.909842	-0.827102
	2	-0.910184	-0.891936	-0.909199	-0.842389	-0.875019	-0.930489
	3	-0.847686	-0.86848	-0.895138	-0.90945	-0.852293	-0.883432
	4	-0.878519	-0.851215	-0.868792	-0.898718	-0.875793	-0.867742
	5	-0.875847	-0.893629	-0.907627	-0.91021	-0.867203	-0.950006
	6	-0.855086	-0.87872	-0.906021	-0.822408	-0.834812	-0.865797
은닉 3 층			목표층 신경세포				
			곡선시점 속도			곡선중점 속도	
			1	-1.56144		-1.50154	
			2	-1.58081		-1.49726	
			3	-1.61785		-1.50892	
			4	-1.55019		-1.50713	
			5	-1.57581		-1.48864	
offset		6	-1.56409			-1.54434	
신경세포		1	2	3	4	5	6
은닉1층		-3.98521	-2.23939	-2.34419	-2.49004	-2.31373	-1.95499
은닉2층		-1.97924	-2.17471	-2.10034	-2.08479	-2.20244	-1.97627
은닉3층		0.116834	0.125856	0.162684	0.115241	0.113098	0.152063
		곡선시점 속도			곡선중점 속도		
결과총		1.25066			1.13206		



〈그림 13〉 자유속도 예측모형에 이용된 신경망 모형

〈표 19〉 자유속도 예측모형

구간	모형
직선구간 (~곡선시점 상류 100m)	- 종단구배 \leq -2% : 평균 109.87kph, 표준편차 12.88의 정규분포로 자유속도 발생 - 종단구배>-2% : 평균 105.53kph, 표준편차 14.96의 정규분포로 자유속도 발생
곡선시점 상류100m ~곡선시점	- 직선부 속도에서 곡선시점 속도로 감속
곡선시점	- 신경망 예측모형에 의한 속도산출
곡선시점 ~곡선중점	- 곡선시점 속도에서 곡선중점 속도로 감속
곡선중점	- 신경망 예측모형에 의한 속도산출

명한 방법과 같이 결과출력 형태를 조사한 결과, 은닉층이 3개이고 각 은닉층의 신경세포수가 6개이며 5,000회 반복학습한 대안8 모형이 비교적 현실을 잘 반영하고, 오차도 작으므로 선택하여 자유속도 예측모형에 이용하였다.

이 모형의 구조는 〈그림 13〉과 같으며 〈표 18〉은 선택된 자유속도 예측모형의 가중치 및 offset을 나타낸 것이다.

최종적으로 개발된 모형은 〈그림 11〉의 구간분류를 이용하여 〈표 19〉와 같은 형태를 나타낸다.

모형은 곡선구간으로 진입하는 차량은 운전자 시거상의 제약으로 인하여 진행방향의 평면선형에 대하여 확연하게 구분을 할 수 없다는 가정하에 선형과 관계없이 일정한 위치에서 감속을 한다는 것을 토대로 감속시점을 선정하였다. 감속의 비율은 속도의 변화를 세분하게 관찰하여야 하므로 조사차량을 이용하여도 한정된 표

본수를 얻을 수밖에 없다. 또한, Speed Gun이나 고정측정장치를 이용할 경우 조사지점의 수가 월등히 증가하여야 하므로 조사상의 어려움으로 인하여, 본 연구에서는 속도차에 비례하여 일정하게 감속하는 것으로 가정하였다.

V. 모형의 검증

1. 기존모형과의 비교

개발된 자유속도예측 신경망모형과 기존모형과의 비교를 위하여 앞서 소개한 McFadden(2001)의 모형과 Ottesen(2001)의 모형에 현장 수집된 직선부 속도자료 및 설계도면으로부터 확보한 도로설계요소를 독립변수로 입력한 결과를 산출하였고 이를 개발된 신경망 모형의 결과와 비교하였고 결과는 〈표 20〉과 같다.

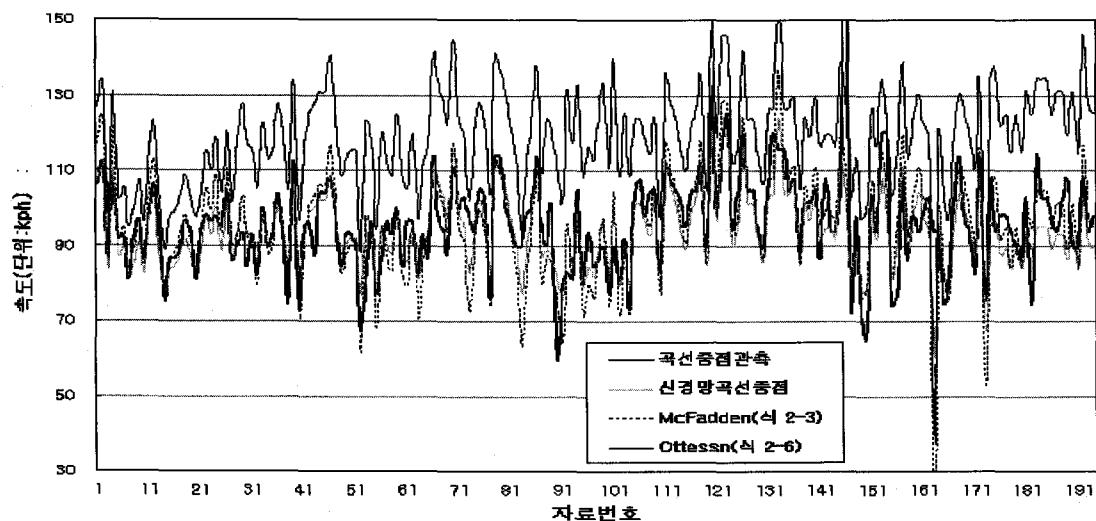
Lamm의 모형과 Ottessn의 모형은 그 연구범위가 지방부 2차로에 한정된 연구이기 때문에 4차로 이상의 고속도로의 속도를 예측하기에는 한계가 있는 것으로 판단되며, 특히 Ottessn 모형의 경우 직선구간속도를 회귀모형의 독립변수로 사용하지 않았을 경우에는 더욱 상이한 예측치를 나타냈다. 반면, McFadden 모형은 유사한 예측치를 나타내므로 신경망모형과 비교하여 〈그림 14〉에 나타내었으며, 자유속도예측 모형의 예측속도와 현장관측속도를 비교·표시한 그래프를 〈그림 15〉와 〈그림 16〉에 나타내었다.

〈표 20〉 모형과 관측치의 오차

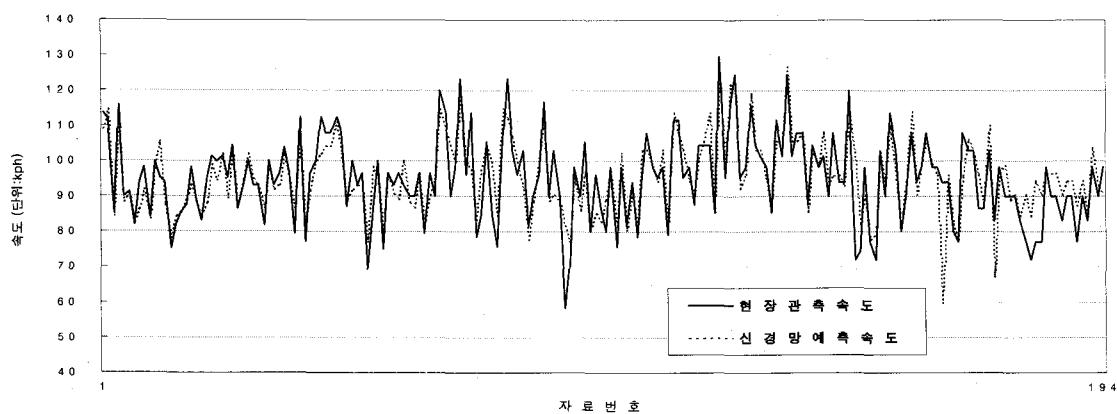
모형	RMSE	%RMSE	R ²
Lamm	22.89	0.24	0.27
McFadden(모형2)	11.84	0.12	0.58
Ottessn(모형2)	60.63	0.63	0.05
Ottessn(모형3)	25.66	0.27	0.23
제안모형(곡선시점)	6.79	0.07	0.77
제안모형(곡선중점)	10.09	0.1	0.65

2. 인공신경망 모형의 통계적 검증

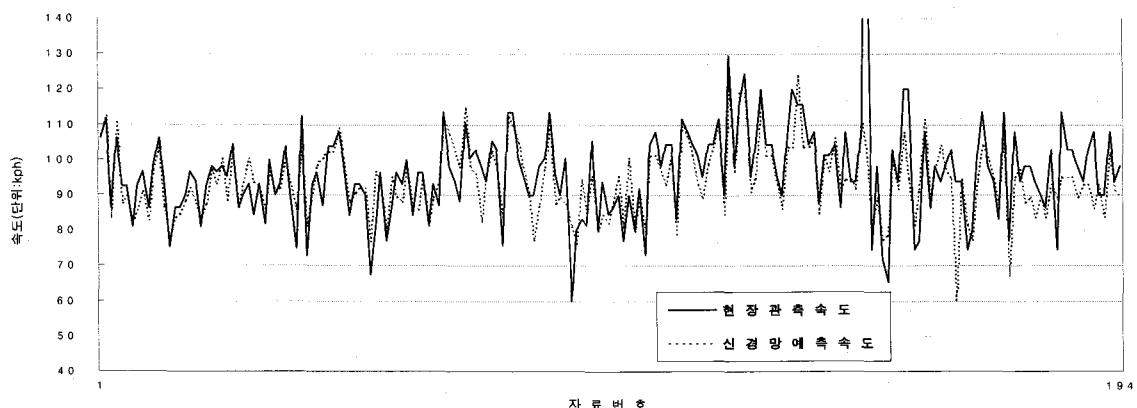
현장에서 수집된 자료와 모형을 통하여 산출된 자료의 차이를 검증하기 위하여 '현장관측속도와 모형의 예측속도는 같다.'는 귀무가설을 수립하였다. 적합도 검정을 위하여 신뢰수준 95%로 χ^2 -test를 실시하였으며, 결과는 〈표 21〉과 같다.



〈그림 14〉 기준 모형 및 개발된 신경망모형의 결과와 현장 수집 속도자료의 비교



〈그림 15〉 자유속도예측모형과 현장의 곡선시점속도의 비교



〈그림 16〉 자유속도예측모형과 현장의 곡선시점속도의 비교

〈표 21〉 χ^2 -test의 결과

분류	χ^2	χ^2*	H_0
값	316.07	434.93	채택

χ^2 적합도 검정결과 현장속도와 모형의 예측속도가 통계적으로 같은 것으로 분석되었다.

V. 결론 및 향후연구과제

1. 결론

역전파 알고리즘으로 학습하여 개발된 인공신경망모형을 이용하여 고속도로 기본구간에서의 자유속도를 예측하고자한 본 연구에서는 다음과 같은 결론을 얻었다.

- 현장관측속도와 모형예측속도를 비교·검증한 결과 95% 신뢰수준에서 유의하며, 기존모형과의 비교·평가결과 곡선시점속도의 RMSE는 6.68, R^2 는 0.77, 곡선중점속도의 RMSE는 10.06, R^2 는 0.65로 현장관측속도를 가장 잘 반영하는 것으로 분석되었다.
- 직선구간속도는 직선구간의 종단구배가 -2%이하 일 경우에 95%의 신뢰수준으로 더 높은 것으로 분석되었으며, 이때의 속도는 평균이 각각 109.87kph($\leq -2\%$)와 105.53kph($> -2\%$)이며 표준편차가 12.88kph, 14.96kph인 정규분포를 따른다.
- 기존의 연구결과들은 지방부 2차로 도로를 대상으로 했거나, 직선구간속도를 채택하지 않음으로 개별차량에 대한 속도예측에 상대적으로 큰 오차를 발생시키는 등 독립변수를 제한적으로 채택함으로 인하여, 고속도로 기본구간 4차로 이상을 대상으로 한 본 연구의 현장관측속도에 비하여 현장관측속도와 상당한 오차를 보이는 것으로 분석되었다.
- 개발된 자유속도 예측모형으로 곡선시점과 곡선 중점에서의 속도특성을 반경 등의 평면선형요소와 종단선형 요소별로 도출할 수 있었다.

연구결과는 현재 기본구간에 설계요소와는 관계없이 일률적으로 적용되고 있는 자유속도를 도로설계요소와 관련하여 더욱 현실적으로 세분화하여 이용할 수 있는 근거를 제시하였고, 나아가 설계일관성평가와 교통류시뮬레이션에 적용할 수 있을 것으로 예상된다.

2. 향후연구과제

본 연구에서 고려되지 않아서 제한적인 결과를 도출하게된 원인을 감소시키고, 더욱 신뢰성 있는 결과를 도출하기 위하여 향후 연구해야할 과제는 다음과 같다.

- 속도조사지점을 확충하는 것이 필요하다.

우선, 본 연구의 범위는 단곡선부에 한하였으나 향후 복합곡선, 배향곡선 등 연속 곡선부로의 연구가 추가적으로 필요할 것으로 생각된다.

둘째, 직선부와 곡선시점, 곡선중점으로 제한된 속도 측정지점을 확장하여 곡선종점이후로 연장하고, 더욱 연속적인 속도자료를 확보하기 위하여 속도조사지점을 확충하는 것이 바람직할 것이다.

셋째, 모집단인 전국고속도로의 특성을 더욱 정확히 반영하도록 신경망을 학습시키기 위해서는 평면선형뿐 아니라, 종단선형 및 곡선장, 편구배 등 입력자료에 해당하는 설계요소들에 대한 특성이 충분히 반영될 수 있도록 다양한 자료의 수집이 요구된다.

- 자유속도 예측모형의 정확도를 높이기 위하여 감속도와 자유속도의 회복에 대한 연구가 수행되어야 할 것이다.

3) 신경망 모형은 지역해에 고착될 위험이 있으므로 향후 유전자 알고리즘을 이용하여 신경망의 주요 인자인 초기가중치, 학습강도, 은닉층 및 은닉층 뉴런의 수를 설계하는 등 지역해 고착의 문제를 개선해야한다.

참고문헌

- 고종대·장명순·정준하(2002), "국도 4차로 곡선부에서 주행속도의 특성 및 모형", 대한교통학회지, 제20권 제7호, 대한교통학회, pp.95~105.
- 김태수(1992), "신경망 이론과 응용", 하이테크정보.
- 도철웅(1997), "교통공학원론(상)", 청문각.
- 이점호·이동민·최재성(2000), "평면곡선부의 속도 및 교통사고 영향분석연구", 대한교통학회지, 제18권 제1호, 대한교통학회, pp.35~43.
- 이종필·김성호(2002), "주행속도 예측을 위한 모형 개발 (2차로 지방부 도로 중심으로)", 대한교통학회지, 제20권 제1호, 대한교통학회, pp.131~139.
- 안상형(1994), "현대통계학", 학현사.

7. 장명순, 강재수(2002), "도로계획과 설계", 엔지니어즈.
8. 조인호(1996), "SAS 연습과 활용", 성안당.
9. 최재성(1998), "도로선형에 대한 설계일관성 평가 모형의 개발", 대한교통학회지, 제16권 제4호, 대한교통학회, pp.195~211.
10. American Association of State Highway and Transportation Officials (2001), "A Policy on Geometric Design of Highways and Streets".
11. Fitzpatrick K., P. Carlson, M. Brewer and M. Wooldridge (2001), "Design Factors That Affect Driver Speed on Suburban Streets", Transportation Research Record 1751, pp.18~25.
12. Freeman J. A. and D. M. Skapura(1991), "Neural Networks : Algorithms, Applications, and Programming Techniques", Addison-Wesley.
13. Hines W. W., D. C. Montgomery(1990), "Probability and Statistics in Engineering and Management Science", John Wiley & Sons.
14. Jacek M. Z.(1992), "Introduction to Artificial Neural Systems", PWS Publishing Company
15. Jacobs R. A.(1998), "Increased Rates of Convergence Through Learning Rate Adaptation", Neural Networks 1(4), pp.295~307.
16. Kyte M., Z. Khatib, P. Shannon and F. Kitchener (2000), "Effect of Environmental Factors on Free-Flow Speed", Transportation Research Circular Report No. E-C018.
17. Laurene F.(1994), "Fundamentals of Neural Networks Architectures, Algorithms, and Applications", Prentice hall.
18. Lamm R. and E. M. Choueiri(1987), "Recommendations for Evaluating Horizontal Design Consistency Based on Investigation in the State of New York", TRR 1122, pp.68~78.
19. McFadden J. and L. Elefteriadou(2001), "Evaluating Horizontal Alignment Design Consistency of Two-Lane Rural Highways", Transportation Research Record 1737, pp. 9~17.
20. McFadden J., W. Yang and S. R. Durrans (2001), "Application of Artificial Neural Networks to Predict Speeds on Two-lane Rural Highways", Transportation Research Record 1751, pp.9~17.
21. McShane W. R. and R. P. Roess(1990), "Traffic Engineering", Prentice hall.
22. Ottesen J. L. and R. A. Krammes(2001), "Speed -profile Model for a Design - Consistency Evaluation Procedure in the united States", Transportation Research Record 1701, pp.76~85.
23. Rao V. and H. Rao(1995), "C++ Neural Networks & Fuzzy Logic", Mis press.
24. Transportation Research Board, "Highway Capacity Manual: Special Report 209".

◆ 주 작 성 자 : 강진구

◆ 논문투고일 : 2003. 7. 15

논문심사일 : 2003. 9. 1 (1차)

2004. 4. 13 (2차)

2004. 5. 31 (3차)

심사판정일 : 2004. 5. 31

◆ 반론접수기한 : 2004. 10. 31