

Hybrid Neuro-Fuzzy Network를 이용한 실시간 주행속도 추정

황인식 · 이홍철

고려대학교 산업공학과

The Estimation of Link Travel Speed Using Hybrid Neuro-Fuzzy Networks

In-Shik Hwang · Hong-Chul Lee

In this paper we present a new approach to estimate link travel speed based on the hybrid neuro-fuzzy network. It combines the fuzzy ART algorithm for structure learning and the backpropagation algorithm for parameter adaptation. At first, the fuzzy ART algorithm partitions the input/output space using the training data set in order to construct initial neuro-fuzzy inference network. After the initial network topology is completed, a backpropagation learning scheme is applied to optimize parameters of fuzzy membership functions. An initial neuro-fuzzy network can be applicable to any other link where the probe car data are available. This can be realized by the network adaptation and add/modify module. In the network adaptation module, a CBR(Case-Based Reasoning) approach is used. Various experiments show that proposed methodology has better performance for estimating link travel speed comparing to the existing method.

1. 서론

국가 ITS를 위한 교통정보수집기술은 나날이 다양한 형태로 발전하고 있다. 국내에서 기 구축한 교통정보수집체계를 살펴 보면 연속류는 한국도로공사의 FTMS, 서울시의 올림픽대로 FTMS가 있으며, 단속류는 서울, 부산, 대구, 인천과 같은 대도시 전자신호시스템 운영을 위한 검지기체계와 국도 교통정보수집체계가 있다. 단속류의 경우는 연속류와 달리 구간별로 통행시간 변화가 크고, 같은 구간 내에서도 통행시간이 교통신호의 연동효과에 직접 영향을 받기 때문에, 정밀한 통행시간 계측이 어려운 특징이 있으며 단속류를 대상으로 개발된 기술은 연속류에서 어렵지 않게 응용할 수 있어 연속류보다 그 연구의 우선 순위가 있다고 하겠다. 단속류 도로의 통행시간계측을 위하여 매설한 루프검지기를 정보가 필요한 모든 링크에 매설할 수 없는 현실적인 한계가 있으며 AVI나 probe car 등 나날이 다양한 형태로 발전하고 있는 교통정보수집기술의 발전 추세로 볼 때 기존의 루프검지와 같은 특정 검지 방식에 국한하여 교통정보수집체계를 구축할 수는 없다. 따라서, 다양한 교통정보수집원으로 부터의 정보 합성기술(data fusion)은 필수적으로 연구 개발되어야 한다. 본 연구는 검지기 및

probe car에서 제공되는 교통 자료를 합성하여 링크의 실시간 통행 속도를 추정하는 자료합성 알고리즘을 개발하고 평가하는데 그 목적이 있다.

통행시간의 예측기술은 세계적으로 ITS에 대한 기술개발이 시작되면서 최근에 등장한 기술분야이며, 특히, 미국에서 ADVANCE 프로젝트가 수행되면서 이에 관한 연구가 활발히 진행중이다(Nagul and Virginia, 1933). 기존 연구를 검토해 보면, 크게 통계적 회귀식(Nagul and Virginia, 1933)을 응용한 것과 신경망이론(Nelson and Palacharla, 1993) 및 퍼지제어이론(Virginia, 1994)을 응용한 것 등 세 가지로 분류할 수 있다. ITS의 여러 분야에서 아직까지도 회귀식 이용과 같은 수학적 모델의 개발이 활발히 진행되고 있으나 회귀식을 이용한 경우 자료의 비선형 관계를 모델링 할 수 없으며 모델의 유연성이나 이식성의 문제라는 관점에서 실제 적용에 대한 의문점이 항상 제시되고 있다. 신경망의 경우는 학습대상 링크에 대하여는 정밀한 추정능력을 보이는 데 비해 타 링크로의 이식성에 문제가 있다. 퍼지이론의 경우 이식성에 있어서 여타 방법에 비하여 장점이 있으나 퍼지소속함수 및 퍼지규칙의 정의에 있어서 작성자의 임의성이 있어 신경망에 비하여 정밀한 추정능력을 기대하기 힘들다. Tarko(1993)와 Schofer(1994)는 ADVANCE 프로젝트에서 통계적 방법을 이용한 on-line data fusion algorithm을 제시하였

는데, 이는 자료 보정(calibration)과 이식성에서 문제가 있다. 또한, probe car 데이터가 동일 시간간격에 다수개가 필요하기 때문에 현실에 적용하기에도 문제가 있다. 신경망은 구조적으로 병렬처리를 할 수 있는 강점을 가지기 때문에, 통행시간을 추정하는데 다양한 제공원으로부터의 정보를 동시에 이용할 수 있는 장점이 있다. Roupail(1993)과 Nelson(1993)이 인공 신경망을 이용한 data fusion 방법론을 제시하였다. 일반적으로, 신경망이론은 학습대상 구간에서의 통행시간 예측력은 우수하나 타구간에 대한 이식성에는 심각한 문제점이 있다. 한편, 퍼지 제어방법을 이용한 연구도 있으나 이식성에서 신경망 이론보다 우수하지만, 추정의 정확성 측면에서는 상대적으로 열등한 것으로 보고되고 있다. 그러나 인공지능 기술을 이용한 모델의 개발이 현재로서는 수학 모델을 대치 할 유일한 방법으로 인식되고 있는 실정이다

본 논문에서는 신경망이 가지고 있는 이식성 문제를, 퍼지 제어이론이 가지고 있는 퍼지집합과 퍼지규칙 작성의 임의성 문제를 해결하기 위하여 결합모형인 hybrid neuro-fuzzy 기술 [8,9,10]을 적용하여 차량의 교차로(link)간 실시간 주행속도 추정 시스템의 개발에 관하여 기술한다. 시스템은 fuzzy ART 알고리즘을 이용하여 퍼지규칙을 도출하는 '퍼지규칙 학습부'와 신경망의 역전파 알고리즘을 이용한 '소속함수 조정부', 그리고 타 링크에서의 이식성을 고려하여 설계한 '기본규칙 추가/조정부' 및 '네트워크 적용부'의 이상 4개 서브 시스템으로 구성하였다. '퍼지규칙 학습부'는 입력데이터와 출력데이터를 이용하여 각각 input/output space를 형성한다. 이후 일련의 매핑 규칙을 적용하여 '퍼지규칙'을 도출한 후 '소속함수 조정부'에서는 입력데이터와 이전 단계에서 도출한 '퍼지규칙'을 이용하여 역전파 알고리즘을 적용하여 시스템이 최소의 에러를 내도록 소속함수 튜닝 작업을 수행한다. 또한, '기본규칙 추가/조정부'와 전문가 시스템의 사례기반 추론기법(CBR: Case-Based Reasoning)을 이용하여 개발한 '네트워크 적용부'에서는 missing rule의 추가 및 조정과 prob car 데이터를 이용하여 소속함수의 파라미터를 해당 링크에 적용시키는 작업을 수행하여 타 링크에서의 이식성을 갖게 한다.

2. 교차로 구간별 정보 유형 구분

구간통행시간 합성시 필요한 정보소스를 구간별로 시공도상에 표현하면 <그림 1>과 같이 4가지 타입으로 구분할 수 있다. 루프검지기는 해당 링크에 24시간 교통량과 점유율정보를 제공하지만 모든 도로에 검지기를 매설 할 수는 없는 현실적인 이유 때문에 검지기가 없는 링크가 항상 존재한다. 그리고 probe car에서 제공되는 실제주행속도 정보는 연속된 링크에 정보를 제공하지만 probe car의 대수가 충분하지 않아서 링크 별로 간헐적인 시간 간격으로밖에 정보를 제공하지 못한다. 이상과 같은 내용을 시공도상의 cell로 표현하여 정리하면 다

그림 1. 시공도상의 교차로 구간별 정보 유형 구분.

음과 같이 4가지 종류로 구분할 수 있다.

- Type1: 검지기 정보만 있는 cell
- Type2: 검지기 정보와 probe car 정보가 있는 cell
- Type3: probe car 정보만 있는 cell
- Type4: 정보소스가 없는 cell

해당 가로에서 검지기가 있는 구간의 경우 probe car의 정보가 추가될 때 정보를 보정하여 정밀도를 향상시킬 수 있다. Type2 cell의 경우 검지기 정보와 probe car 정보가 공존하므로 상관관계에 의하여 다음 시간대의 Type1 cell의 정보를 갱신한다. 구간3의 Type4 cell의 경우는 정보소스가 전혀 없지만 구간2와 구간4의 정보를 통하여 추정이 가능하며, Type3 cell이 존재할 경우 추정력이 향상된다. 이상의 모형을 효과적으로 처리하는 알고리즘은 연속되는 시간상에서 통행시간정보를 추정하는 중에 특정시점에 probe car가 통과할 경우 새로운 데이터를 수용하기 위하여 모형의 파라미터를 자동갱신하는 기능을 보유해야한다. 이러한 이유로 external reinforcement에 의하여 adaptive learning이 가능한 hybrid neuro-fuzzy model을 선정하여 적용한다.

3. Hybrid Neuro-Fuzzy Network 방법론

Neuro-fuzzy 시스템의 목적은 신경망과 퍼지로직을 결합하여 각각의 장점을 이용한다. 즉 시스템의 추론 메커니즘은 퍼지 추론을, 학습은 신경망을 이용함으로써 언어적인 데이터나 수치 데이터를 처리할 수 있고, 수치 데이터로부터 퍼지규칙 도출이 가능하다.

3.1 Hybrid Neuro-Fuzzy Network 의 구조

본 연구에서 적용한 hybrid neuro-fuzzy network의 구조는 <그림 2>와 같다. 일반적인 뉴로-퍼지 네트워크와 마찬가지로 총 5개의 layer로 구성되는데 1번째와 5번째 layer는 각각 입력노드와 출력노드들로 구성된다. 2번째 layer와 4번째 layer는 입/출력 언어변수에 대한 소속함수들을 나타내는 노드(term node)로 구




그림 2. Hybrid Neuro-Fuzzy Network 의 구조.

성된다. 가운데 위치한 3번째 layer는 규칙노드를 나타내는데, 노드 하나가 하나의 퍼지규칙을 의미한다. 따라서 만약 이 layer의 노드 개수가 5개라면 퍼지규칙이 5개라는 의미이다.

3.2 퍼지추론 네트워크 생성

링크의 주행 속도를 추정하기 위하여 필요한 입력은 교통량과 점유율로 2개이며, 출력은 주행속도 1개이다. 따라서 퍼지추론 네트워크의 기본 구조인 1번층과 5번층은 <그림 3>과 같이 정의된다.

입력 소속함수의 파라미터를 찾기 위하여 Fuzzy ART의 fast




그림 3. 1번층과 5번층의 구성.

learning 알고리즘을 사용한다. 이는 input space에 대한 퍼지 hyperbox를 구성하는 단계이다. 입력 벡터 각각에 대하여 다음 식에 의한 클러스터링 작업을 수행한다.

$$T_j(x') = \frac{|x' \wedge w_j|}{\alpha + |w_j|}, \quad j = 1, 2, \dots, N \quad (1)$$

$$T_j = \max\{T_j : j = 1, \dots, N\} \quad (2)$$

$$\frac{|x' \wedge w_j|}{|x'|} \geq \rho \quad (3)$$

x' : input vector
 w : weight vector
 T_j : choice functions

여기서, T_j 는 네트워크의 choice function이며, $\alpha \geq 0$ 인 상수이고, N 은 현재 규칙노드의 수, w_j 는 weight vector이다. 이때 resonance는 식 (3)을 만족할 때 발생한다. ρ 는 0과 1 사이의 실수로서 vigilance parameter를 의미한다. 출력값에 대한 퍼지 클러스터링 작업도 이와 같이 수행된다. 퍼지 클러스터링에 의하여 입력과 출력 각각에 대하여 hyperbox로 표현되는 퍼지 클러스터가 발생한다. 데이터 클러스터링에 의한 소속함수 정의 예를 <그림 4>에 보였는데 2개의 입력데이터(교통량, 점유율)를 이용하여 클러스터링을 한 후 소속함수를 정의하는 예이다.




그림 4. 입력값 클러스터링에 의한 소속함수 파라미터 결정.

위의 그림에서는 3개의 클러스터가 형성된 것을 보여주고 있으며, 각각의 영역 경계값을 u_{ij} 및 v_{ij} 값으로 사용한다. 이 경우 3개의 클러스터가 생성되었으므로 2번층의 구간노드는 3개가 된다. 이때 3번층의 규칙노드의 개수도 바로 입력 언어변수에 의해서 생성된 구간노드의 숫자와 일치하는데 따라서 규칙노드는 3개가 된다. 또한 출력데이터를 이용한 클러스터링 작업결과 2개의 클러스터가 생성되었다면 4번층의 출력 구간노드의 개수는 2개가 된다. 입/출력 노드와 각각의 구간노드간에는 모두 링크된다. 이런식으로 네트워크의 노드 구조가 확정되며 이를 <그림 5>에 보였다.




그림 5. 네트워크의 노드 구조 정의.

클러스터링 작업 후에는 생성된 클러스터를 구성하는 값들을 이용하여 소속함수를 정의한다. 다음 <그림 6>에 사다리꼴 소속함수의 원형을 보여준다.




그림 6. 사다리꼴 소속함수 원형.

3.3 조건/결론 매핑 절차

네트워크의 입력 및 출력부를 거쳐서 형성되는 input space와 output space를 일련의 규칙에 의거하여 매핑한다. 이는 퍼지규칙을 정의하는 작업과 동일한 작업이다. 일단 한번 조건/결론

매핑작업을 한 후에 결정된 네트워크 구조는 계속 유지된다. 입력과 출력데이터에 대한 두 개의 hyperbox가 형성된 다음에는 아래의 순서대로 매핑작업을 수행하여 퍼지규칙을 생성한다.

- STEP 1: 만약 규칙노드 I가 새로 추가되었다면, 출력 hyperbox에 매핑한다.
- STEP 2: 만약 STEP 1에 의하여 노드 I가 출력 hyperbox와 연결되지 않았다면, 다음 입력 벡터에 의한 퍼지 클러스터링을 수행한다. 그후 STEP 1을 수행한다.
- STEP 3: 구조의 변화가 없으면 작업을 마친다.

위에 설명한 '퍼지규칙 학습 단계들' 다음 <그림 7>에 보였다.

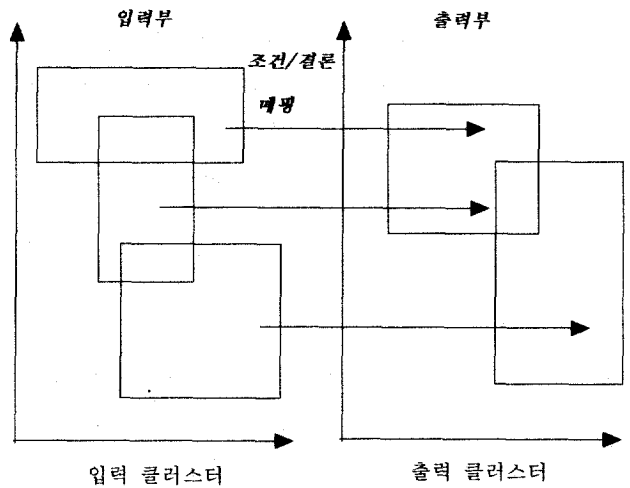


그림 7. 퍼지규칙 학습 프로세스.

3.4 소속함수 학습절차

퍼지규칙과 소속함수를 생성하여 일단의 퍼지시스템을 구성한 후에는 '퍼지규칙 학습부'에서 사용했던 입력데이터를 이용하여 시스템이 최적의 성능을 낼 수 있도록 퍼지 소속함수 조정 작업을 수행한다. 여기서는 기본적으로 신경망의 역전파 알고리즘을 이용한다. 시스템의 추정치와 실제 출력값에 의한 오차를 다음과 같이 식 (4)로 정의한다.

$$E = \frac{1}{2} [y(t) - \hat{y}(t)]^2 \quad (4)$$

여기서, $y(t)$ 는 실제 측정치이며, $\hat{y}(t)$ 는 추정값이다. 이후 네트워크의 각 층에 따라 역전파 시키면서 소속함수의 파라미터를 조정하는 데 자세한 절차는 참고문헌(LIN, 1996)을 참고하기 바람직하며 소속함수 조정의 핵심적인 절차는 다음과 같다.

3.4.1 5번층

Hyperbox 소속함수의 파라미터 v_i 를 갱신하기 위한 수식은

다음과 같다.

$$v_i^{(5)}(t+1) = v_i^{(5)}(t) + \eta [y(t) - \hat{y}(t)] \frac{z_i}{2 \sum z_i}$$

그리고 파라미터 u_i 를 갱신하기 위한 수식은 다음과 같다.

$$u_i^{(5)}(t+1) = u_i^{(5)}(t) + \eta [y(t) - \hat{y}(t)] \frac{z_i}{2 \sum z_i}$$

여기서, η 는 학습율이며, z_i 는 i 번째 출력 노드에 입력되는 값이다.

다음 층에 전파할 에러는 다음과 같다.

$$\delta^{(5)} = y(t) - \hat{y}(t)$$

3.4.2 4번층

4번층에서는 파라미터의 조정이 이루어지지 않으며 다만 에러에 대한 계산만이 이루어지는데 그 에러는 다음과 같이 계산된다.

$$\delta^{(4)} = \delta^{(5)} \frac{m_i \sum z_i - \sum m_i z_i}{(\sum z_i)^2}$$

여기서, m_i 는 출력 i 번째 term 노드의 중심을 의미한다.

3.4.3 3번층

4번층과 마찬가지로 단지 에러만 계산한다. 에러는 다음과 같다.

$$\delta^{(3)} = \frac{z_i^{(4)}}{z_{\max}} \delta^{(4)}$$

여기서, $z_{\max} = \max(j$ 번째 출력 term 노드의 입력값들)을 의미한다.

3.4.4 2번층

소속함수 파라미터에 대한 조정이 이루어진다. v_{ij} 는 다음과 같이 갱신한다.

$$v_{ij}^{(2)}(t+1) = v_{ij}^{(2)}(t) + \eta V \prod_{k \neq i} z_k^{(3)}$$

여기서, V 는 다음 식과 같다.

$$V = \begin{cases} r & \text{if } 0 \leq (x_i - v_{ij}^{(2)})r \leq 1 \\ 0 & \text{otherwise} \end{cases}$$

또한, 소속함수 파라미터 u_{ij} 는 다음과 같이 갱신한다.

여기서, U 는 다음 식과 같다.

$$U = \begin{cases} r & \text{if } 0 \leq (x_i - u_{ij}^{(2)})r \leq 1 \\ 0 & \text{otherwise} \end{cases}$$

3.5 기본규칙 추가/ 조정 절차

Hybrid neuro-fuzzy 네트워크 생성절차에 의하여 정의된 퍼지

규칙들은 학습 데이터의 특성이 충분히 반영되어 만들어진 클러스터와 클러스터의 생성 추이를 고려한 일련의 매핑규칙에 의거하여 만들었으므로 시스템 적용이 가능하다. 그러나 실제 상황에서는 학습 데이터에는 포함되지 않았던 구간에 해당하는 데이터가 입력될 수 있다. 또한, 조건/결론 매핑규칙에 의하여 구성된 퍼지규칙에 적용 할 수 없는 데이터가 입력되는 경우가 발생 할 수 있으므로 '기본규칙 추가/조정부'에서는 제안된 초기 네트워크를 조사하고, missing된 소속함수 구간을 '기본규칙 베이스'에 저장된 기본규칙들을 적절히 보장하여 초기 네트워크에 의하여 생성된 퍼지규칙들에 추가하는 작업을 수행한다. 기본 소속함수는 타 구역에 비하여 빈도 및 중요도가 낮거나 정의되지 않은 입력 구간을 처리하기 위하여 사용되었으며 입력과 출력 구간 간의 매핑에 의하여 모든 입력에 대한 퍼지추론을 가능하게 한다. 기본규칙의 예와 기본 소속함수 원형(prototype)의 예를 <그림 8>에 보였다.

기본규칙 예 : IF 교통량 = 상 그리고 점유율 = 상
THEN 속도 = 하
IF 교통량 = 중 그리고 점유율 = 중
THEN 속도 = 중
IF 교통량 = 하 그리고 점유율 = 하
THEN 속도 = 상




그림 8. 기본 소속함수 원형의 예.

3.6 네트워크 적용절차

생성된 기존의 네트워크를 타 링크에서 사용하기 위해서는 현재의 퍼지추론 네트워크를 대상 링크에 적용시키는 작업이 필요하며 '네트워크 적용부'가 이 일을 수행한다. 이 서비스 시스템은 속도 추정시스템의 타 링크에 대한 이식성(transportability)을 위하여 설계된 부분으로서 전문가시스템의 추론 기법중의 하나인 사례기반 추론 기법(CBR : Case-Based Reasoning)을 이용하여 개발되었다(Stephen, 1991; Reisbeck, 1989; Kristan, 1989). 사례기반 추론 방법이란 과거의 성공적인 사례를 기반으로 현재의 주어진 문제를 해결하는 방법론으로 전문가시스템 추론 엔진 개발에 주로 사용되는 기법이다. CBR의 자세한 프로시저는 참고문헌을 참고바라며 지면 관계상 본 논문에서는 생략한다.

네트워크 적용부에서는 probe car의 주행속도 데이터와 그 시점에서의 루프 검지기 데이터(교통량, 점유율)가 입력으로 사용되는데 수행되는 크게 '유사 링크 추출부'와 '네트워크 적용부'의 2가지로 구분된다. '유사 링크 추출부'는 실측 데이터를 이용하여 구축해 놓은 여러개의 속도 추정 네트워크에 현 링크에서 입수한 probe car 속도와 그 시점의 교통량 및 점유율 데이터를 입력하여 현재의 probe car 속도를 추정한다. 이렇게 추정한 속도와 실제 probe car 속도와의 차이가 가장 작은 네트워크를 유사 링크로 추출한다. 그 후 추출한 링크의 네트워크 구조를 일련의 네트워크 적용규칙을 적용하여 최종적인 속도 추정 네트워크를 구성한다. 이 네트워크는 최종적으로 소속함수 조정부에서 소속함수의 파라미터들을 조정한다. 추출된 유사 링크의 네트워크를 대상 링크에 적용시켜 적절한 성능을 얻기 위해서는 10여개 정도의 probe car 데이터가 필요한 것으로 실험결과 나타났다. 네트워크 적용절차가 이용되는 적용규칙에는 구조 적용규칙과 구간 적용규칙의 2가지가 있다. 구조 적용규칙은 퍼지 소속함수의 개수를 조정하는 적용규칙이며, 구간 적용규칙은 해당 소속함수의 범위를 조정하는 적용규칙이다. 입수한 교통량 입력데이터를 기준으로 대상 링크의 소속함수 개수를 조정하는 구조 적용규칙의 일부를 보면 다음과 같다.

- 규칙 1: IF {교통량 입력데이터 구간의 개수가 추출된 링크의 구간 개수와 일치한다}
THEN {교통량의 입력 구간을 정렬하고, 순위별로 추출링크의 소속함수 변수와 매핑한다}
- 규칙 2: IF {교통량 입력데이터 구간의 개수가 추출된 링크의 구간 개수보다 작다}
THEN {교통량의 입력 구간을 정렬하고, 중간 구간과 추출링크의 중간 구간과 매핑한다}
{missing되는 구간을 기본규칙베이스에서 기본 소속함수 원형으로 대체한다}
- 규칙 3: IF {교통량 입력데이터 구간의 개수가 추출된 링크의 구간 개수보다 많다}
THEN {교통량의 입력 구간을 정렬하고, 중간 구간과 추출링크의 중간 구간과 매핑한다}
{overlap되는 구간을 합쳐서 하나의 구간으로 대체한다}
{missing되는 구간을 기본규칙베이스에서 기본 소속함수 원형으로 대체한다}

4. 시스템 평가

본 연구에서 개발한 모형의 성능을 현장 실측자료를 통하여 다양한 방법으로 평가하였다. 현장자료의 수집은 남부순환로를 중심으로 이루어졌으며, 조사대상 교차로의 개수는 총 5개

로써 양방향 총 8개의 링크를 대상으로 하고 있다. 평가할 내용은 링크단위의 성능평가와 이식성평가이며 평가척도는 객관성을 위하여 평균제곱오차(RMS, Root Mean Square)를 성능척도로 사용하였다. 시스템평가를 위한 수행 단계는 다음과 같다.

- Step 1: 초기 네트워크 생성 데이터 입력
루프 검지기에서 수집된 교통량, 점유율 정보와 현장조사 실측 통행속도값 입력
- Step 2: 초기 네트워크 생성
네트워크 생성을 위한 입력데이터가 입력되면 준비된 데이터를 가지고 퍼지규칙과 소속함수를 생성한다.
- Step 3: 초기 네트워크로 속도 추정
생성된 네트워크를 이용하여 각 링크의 통행속도를 산출한다.
- Step 4: 파라미터의 최적화
Probe Car에서 수집된 정보로 파라미터를 자동 갱신한 후 네트워크를 조정한다.
- Step 5: 통행속도 추정
파라미터 최적화 후 조정된 네트워크에서 통행속도를 추정한다.

4.1 현장자료수집 및 분석

본 연구를 위한 현장자료의 수집은 현재 신신호검지기가 설치운영되고 있는 남부순환로를 중심으로 하였다. 조사대상 교차로 개수는 총 5개로써 양방향 총 8개의 링크 <그림 9>를 대상으로 하였다.

조사시간대는 06:00~10:00, 17:00~19:00로 선정하였다. 동일시간대에 측정한 현장자료는 링크간 통행속도와 probe car 자료이다. 다음 <표 1>에 개발된 시스템에 적용할 현장 자료로서 입수된 데이터의 일부는 다음과 같다.

4.2 속도 추정 성능 평가 결과

남부순환도로의 현장 실측자료를 이용하여 시스템의 속도 추정 능력을 평가하였다. 평가대상 항목으로는 도로에 매설된 검지기 정보로부터 단일링크에 대한 통행속도 추정 성능뿐만




그림 9. 조사 대상 지역.

표 1. 링크별 교통 자료 예

시간	29번(대기, EB, 100, 3차선)		통행속도(실측)	Probe Speed	통행속도(추정)
	교통량	점유율			
7:00:00	116	17	42.6	36.4	38.4
7:15:00	122	26	34.5		28.17
7:30:00	135	30	36.3	35.5	28.2
7:45:00	112	23	30.5	32.4	28.2
8:00:00	151	20	26.9		28.2
8:15:00	118	17	29.9		37.7
8:30:00	127	13	42.2		37.7
8:45:00	93	7	32.6		37.7
9:00:00	133	20	25.3	32.7	28.2
9:15:00	160	16	29.7		28.2
9:30:00	128	22	33.7	25	28.2
9:45:00	147	19	30.2		28.2
17:00:00	170	30	21.6		28.2
17:15:00	155	36	22.5	15.7	28.2
17:30:00	148	36	20.3	16.9	28.2
17:45:00	181	35	32.2	17.2	28.24
18:00:00	152	28	23.8		28.24
18:15:00	160	57	11.4	12.2	14.26
18:30:00	172	55	10.5	7.4	14.26
18:45:00	132	62	9.4		14.51

아니라 probe car에서 수집되는 통행속도 자료를 자동갱신 함으로써 추정되는 통행속도의 성능까지 평가한다. 평가기준은 현장조사 실측 통행속도와 기존의 통행속도 추정방법 중에서 계산 및 적용이 용이하고, 교통상태의 변화형태를 잘 반영하는 것으로 알려진 VPLUSKO 방법의 추정결과와 비교를 병행하여 평가한다. 또한, Hybrid neuro-fuzzy model을 이용한 링크 속도추정시스템은 다양한 패턴을 가지는 입력데이터의 실시간 처리 능력과 강한 이식성을 가져야 하므로 검지기 자료와 존재하는 링크로부터 얻을 수 있는 검지기 정보로 구축한 네트워크를 가지고 인접링크의 교통량, 점유율등을 사용하여 인접링크의 현장조사 실측치와의 비교를 통해 모형의 이식성을 평가한다.

검지기 정보를 얻을 수 있는 링크의 교통량, 점유율, 현장조사 실측자료를 입력하여 초기 네트워크를 생성한 후 초기 네트워크에서 추정된 통행속도를 실측값과 비교하여 단일 링크에 대한 통행속도 추정 성능을 평가하였다. 또한, probe car에서 제공되는 실제속도를 이용하여 파라미터를 자동갱신 함으로써 추정된 통행속도 결과값도 함께 비교하였다. 본 모형의 링크 추정속도 시스템은 이식성의 문제와 새로운 환경에서 상이한 패턴이 입수되었을 때, 퍼지 소속함수를 갱신하고, 시스템 상태를 update 하기 위해 probe car에서 제공되는 정보를 이용하여 파라미터를 자동 갱신하고 data를 합성한다. Probe car를 이용한 통행속도의 추정은 간헐적으로 수집되는 자료를 기반으로 probe car data가 있는 시간대의 검지기에서 수집되는 교통량, 점유율과 함께 probe car data를 파라미터 조정용 데이터로써 입력시켜 파라미터를 자동갱신하고, 네트워크를 조정한 후에 추정된 결과인데, 이를 현장조사 실측자료와 초기네트워크 생성 후 추정된 통행속도의 비교한 결과와 함께 <그림 10>에 보였다.

초기 네트워크를 이용하여 통행속도를 추정된 결과 현장 실측 통행속도 변화율은 어느 정도 잘 반영하고 있으나 현장 실

Comparison of Estimated Travel Speed(EB:Link3-4)




그림 10. Link 3-4의 추정속도와 실측값과의 비교.

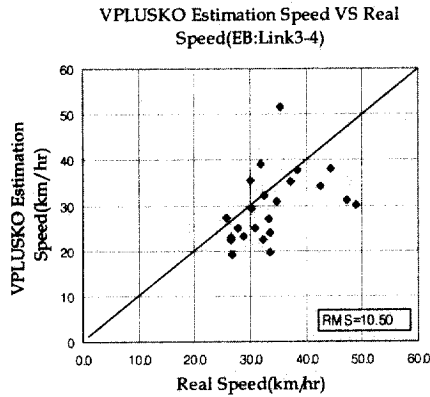
측 통행속도와 비교해 볼 때, neuro-fuzzy를 이용하여 통행속도를 추정하는 경우보다 통행속도 추정력이 떨어지는데, 좀더 세밀한 분석을 위해 추정값과 현장 실측치의 관계를 분석하였다. 초기 네트워크를 생성시켜 통행속도를 추정한 결과와 probe car data를 이용하여 통행속도를 추정한 결과중 현장조사 실측치와 비교해 볼 때, 둘 중 어떤 방법이 추정력이 우수한지를 객관적으로 분석하기 위해 평균제곱근 오차(RMS)를 사용하여 비교 분석하였고, 아울러 기존에 통행시간을 추정하는 방법중의 하나인 VPLUSKO 방법을 사용하여 추정된 통행속도 결과값도 비교를 병행하여 분석하였다. VPLUSKO는 일반적으로 교통량과 점유율의 비선형 관계를 선형으로 표현하여 혼잡 정도를 나타내기 위한 값으로 사용되는데, VPLUSKO는 Vol+K·Occ%로 구해지며, K값은 20을 사용한다. 통행속도를 추정하는 방법은 다음과 같다.

$$SMS = \frac{\alpha}{VPLUSKO}$$

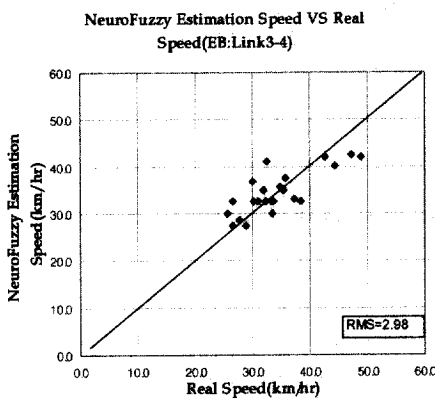
여기서, α 값은 VPLUSKO의 역수의 합을 자료수집 개수로 나눈 후 이것을 다시 일평균 통행속도로 나눈 결과로써 링크 별로 다른 값을 가진다. 초기 네트워크를 생성시켜 링크 통행속도를 추정하는 경우도 추정력이 있으나 다음 그림에서와 같이 neuro-fuzzy를 이용하여 통행속도를 추정된 결과가 현장조사 와 비교해 볼 때, error 오차가 VPLUSKO보다 작은 것으로 나타났으므로 기존의 통행속도 추정방법인 VPLUSKO방법보다 추정력이 우수하다고 결론지을 수 있다(<그림 11>).

4.3 이식성 평가

본 시스템의 개발 목적은 교통정보 자료의 합성 기능만이 아니라 퍼지제어이론이 갖고 있는 이식성과 확장성, 신경망의 합성 기능을 통해 타 링크에대한 확장성과 이식성을 고려하는 시스템을 개발하는데 그 목적이 있으므로 링크 통행속도 추정 시스템에서 링크의 이식성을 평가하였다. <그림 12>는 Eastbound Link 1-2의 검지기 자료와 현장조사 자료로 네트워크를 생성시키고 Eastbound Link 3-4의 검지기 자료를 입력하여 이식성을



(a) VPLUSKO의 적용시 평균제공근 오차



(b) Neuro-Fuzzy 적용시 평균제공근 오차

그림 11. VPLUSKO 와 Neuro-Fuzzy 적용시 평균제공근 오차.

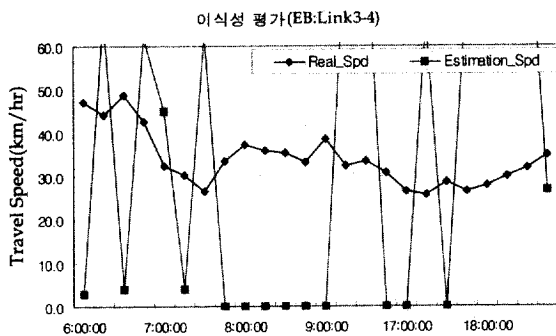


그림 12. 초기 네트워크의 추정속도 이식성 평가.

평가한 결과이다.

<그림 12>는 교통량, 점유율의 입력값을 통해 생성된 초기 네트워크에 인접 링크의 검지기 정보로 얻어지는 교통량, 점유율을 입력했을 때, 통행속도 추정결과를 그 링크의 현장조사 실측치와 비교한 것이다. 그림에서도 알 수 있듯이 초기 네트워크를 생성시켜 통행속도를 추정하는 것은 해당 링크의 통행속도가 0 km/hr를 나타내는 등 통행속도 실측값을 잘 반영




그림 13. Probe Car Data를 이용한 이식성 평가.

하지 못하고, 실측값과 현장값의 편차가 매우 심한 결과 초기 네트워크 생성 후 검지기 정보만으로는 이식성을 고려하지는 못하는 것으로 판단된다. 이식성의 평가를 위해서 Link 1-2의 교통량, 점유율과 현장조사 실측치를 입력하여 네트워크를 생성하고 Link 3-4의 probe car data를 이전 링크의 교통량과 점유율과 함께 파라미터 조정용 데이터로 입력하여 실제 주행속도를 자동 갱신시켜 네트워크를 조정 후 추정된 통행속도를 Link 3-4의 현장조사 실측값과 비교한 것을 <그림 13>에 보였다.

추정결과 그림에서도 알 수 있듯이 Probe car data를 사용하여 통행속도를 추정된 결과 안정된 추정력을 보이는 것으로 나타났다. 통행속도 데이터의 이식성을 판단하기 위해서는 루프 검지기 자료만으로는 해결할 수 없고 연속적이지만 간헐적인 시간으로 수집되는 probe car data를 사용하여 파라미터를 최적화함으로써 가능하기 때문에 이식성 평가는 probe car data를 사용하여 모형의 성능을 평가한다. Probe car data를 이용하여 다른 링크에 대한 이식성을 평가한 결과 현장조사 실측치에 비교해 우수한 추정력을 가졌다고 할 수 있다. 위의 Link 3-4 이외에 역방향 링크에서도 만족할 만한 이식성을 보였다.

5. 결론

본 연구에서는 hybrid neuro-fuzzy 기술을 이용하여 검지기 및 probe car에서 제공되는 교통 자료를 합성하여 실시간 통행시간을 예측하는 알고리즘을 개발하고 이를 시스템화하고 실측 데이터를 이용하여 평가하였다. 개발된 시스템은 두 개의 fuzzy ART 네트워크를 이용하여 퍼지 소속함수와 퍼지규칙을 도출한다. 그 후 입력데이터와 이전 단계에서 도출된 '퍼지규칙'을 이용하여 신경망의 역전파 알고리즘을 이용하여 시스템이 최적의 성능을 소속함수 튜닝 작업을 수행한다. 또한, '기본규칙 추가/조정부'와 '네트워크 적용부'에서는 missing rule의 추가 및 조정과 probe car data를 이용하여 소속함수의 파라미터를 해당 링크에 적용시키는 작업을 수행하여 타 링크에서의 이식성을 갖게 한다. 개발모형은 자료합성 과정에서 on-line adaptive learning 기능과 이식성이 가능하도록 hybrid neuro-fuzzy model과 전문가시스템의 사례기반 추론 기법을 이용하여 개발하였다.

개발모형은 현장자료를 사용하여 평가한 결과, 통행시간 추정 측면에서 검지기자료 이외에 probe car data를 활용함으로써 가능하였다.

인공지능 기술을 이용한 주행속도 추정 연구는 요즘 활발히 진행되고 있으나 본 논문에서는 neuro-fuzzy model 및 전문가시스템 기술의 개념(사례기반 추론)을 독창적으로 도입 적용하였다. 주행속도의 추정력에 대한 실험으로 대상 도로의 8개 모든 링크에 대하여 본 논문이 제시한 모델과 VPLUSKO와 비교한 결과 모두 우수한 결과를 보였으며, neuro-fuzzy 복합 모형은 노이즈에 둔감한 퍼지 기술의 장점을 그대로 계승하고 있는 바 Robustness의 측면에서도 강점이 있다 하겠다.

주행속도 추정의 이식문제 해결에 관한 연구는 거의 전무한 실정이나 본 논문에서는 학습 능력이 있는 neuro-fuzzy model과 사례기반추론 개념을 이용하여 이식성 문제를 해결하는 모델을 개발하였다. 이식성 문제에 있어서는 이식대상의 유사성과 교통량 등의 차이가 반드시 고려되어야 한다. 이식 대상의 유사성은 사례기반 추론 기술이 적용된 '유사 링크 추출부'가 작동하는 단계에서 고려되며 교통량과 점유율의 차이 등은 신경망의 역전파 알고리즘에 의한 적응 과정에서 고려되고 있다. 향후 연구과제로는 검지기과 probe car data에서 제공되는 정보 뿐 아니라 화상데이터나 콜센터 등에 접수되는 신고사항 등과 같이 온라인 및 오프라인의 정보소스도 고려해야 할 것이다.

참고문헌

- Kristan, J. H. (1989), *Case-Based Planning-Viewing Planning as a Memory Task*, Academic Press Inc.
- LIN, C. (1996), *A Fuzzy Adaptive Learning Control Network With On-Line Structure and Parameter Learning*, World Scientific Publishing Company.
- Nagul, M. R., and Virginia, P. S. (1993), *Travel Time and Loop Detector Output Analysis on Dundee Road Closed-Loop Signal System*, *Advance Working Paper Series*, June.
- Nauck, K. (1992), *A Neural Fuzzy Controller Learning by Fuzzy Error Propagation*, *NAFIPS*.
- Nauck, K. (1992), *Interpreting Changes in the Fuzzy Sets of a Self Adapting Neural Fuzzy Controller*, *2nd IFIS Workshop*.
- Nelson, P., and Palacharla, P. (1993), *A Neural Network Model for Datafusion in Advance*, *Transtech Pacific Rim Conference*, Seattle, Washington.
- Nelson, P., and Prasad, P. (1993), *A Neural Network Model for Data Fusion in Advance*, *Transtech Pacific Rim Conference*, Seattle, Washington.
- Reisbeck, C., and Schank, R. (1989), *Inside Case-Based Reasoning*, Lawrence Erlbaum Associated Inc, 9-12.
- Rouphail, N. M. (1993), *Travel Time Data Fusion in ADVANCE - A Preliminary Design Concept*, *Advance Working Paper Series*, Jan.
- Schofer, J. L., and Koppelman, F. S. (1994), *Use of Multiple Data Sources for Arterial Street Incident Detection*, *World Conference on Transportation Research*, Dec.
- Stephen, S. (1991), *Case-Based Reasoning : Research Paradigm*, *AI Magazine*, 42-55.
- Tarko, A., and Nagui, R. (1993), *Travel Time Data Fusion in Advance*, *Transtech Pacific Rim Conference*, Seattle, Washington.
- Virginia, P. S. (1994), *Fuzzy Reasoning Model for Converting Loop Detector Data into Travel Times*, *Advance Working Paper Series*.