

차량 궤적 데이터를 활용한 도심부 간선도로의 돌발상황 검지

Incident Detection for Urban Arterial Road by Adopting Car Navigation Data

김 태 욱*
(Tae-uk Kim)

배 상 훈**
(Sang-hoon Bae)

정 희 진***
(Heejin Jung)

요 약

도로상에서 발생하는 교통 혼잡비용은 지역 간 도로 보다는 도심부 내에서 비증 있게 발생하며, 이는 전체 혼잡비용의 약 63.39%를 차지하고 있다. 따라서, 교통혼잡비용의 절감을 위해서는 도심부의 교통 혼잡을 해소하는 것이 중요하다. 도심부의 교통 혼잡은 반복정체와 비반복정체로 구분되며, 비반복 정체를 신속하고 정확하게 검지하는 것이 교통 혼잡의 해소에 있어 무엇보다 중요하다. 그러나 돌발상황 검지에 관한 연구는 대부분 연속류를 대상으로 수행되어 왔다. 도심부 단속류 도로의 경우, 신호 교차로·주정차 차량 등 다양한 변수가 존재하기 때문에 연속류에 적용되는 돌발상황 검지 알고리즘을 수정없이 적용하기에 무리가 있다. 따라서 본 연구에서는 도심부 단속류 도로를 대상으로 수집된 GPS 기반의 차량궤적 데이터에 인공신경망을 적용하여 돌발상황검지 모형을 구축하였다.

제안된 모형의 정확도 검증 결과, 돌발상황 검지율 46.15%, 오보율 25.00%가 도출되었다. 이러한 결과는 단속류를 대상으로 하는 초기 연구 결과로서 의미가 있다. 또한 내비게이션 장치와 같은 차량 궤적 데이터만을 활용하여 비반복정체를 검지 할 수 있는 가능성을 제시 했다는 것에 의미를 찾을 수 있을 것이다.

핵심어 : 돌발상황 검지, 인공신경망, 도심부 단속류 도로, 데이터 전처리, GPS 데이터

ABSTRACT

Traffic congestion cost is more likely to occur in the inner city than interregional road, and it accounts for about 63.39% of the whole. Therefore, it is important to mitigate traffic congestion of the inner city. Traffic congestion in the urban could be divided into Recurrent congestion and Non-recurrent congestion. Quick and accurate detection of Non-recurrent congestion is also important in order to relieve traffic congestion. The existing studies about incident detection have been variously conducted, however it was limited to Uninterrupted Traffic Flow Facilities such as freeway. Moreover study of incident detection on the interrupted Traffic Flow Facilities is still inadequate due to complex geometric structure such as traffic signals and intersections. Therefore, in this study, incident detection model was constructed using by Artificial Neural Network to aim at urban arterial road that is interrupted traffic flow facility.

In the result of the reliability assessment, the detection rate were 46.15% and false alarm rate were 25.00%. These results have a meaning as a result of the initial study aimed at interrupted traffic flow. Furthermore, it demonstrates the possibility that Non-recurrent congestion can be detected by using car navigation data such as car navigator system device.

Key words : Incident detection, Artificial Neural Network, Interrupted Traffic Flow, Pre-processing, GPS data

* 주저자 : 부경대학교 공간정보시스템공학과 석사
** 공저자 및 교신저자 : 부경대학교 공간정보시스템공학과 교수
*** 공저자 : 부경대학교 공간정보연구소 전임연구원
† 논문접수일 : 2014년 03월 27일
‡ 논문심사일 : 2014년 06월 110일
‡ 게재확정일 : 2014년 06월 24일

I. 서론

1. 연구 배경 및 목적

우리나라의 자동차 등록 대수는 2012년 기준 1887만대로 최근 10년간 평균 약 3.08%의 증가율을 보이고 있으며, 도로교통 혼잡비용 또한 증가하고 있는 실정이다. 2010년 기준 도로교통 혼잡비용은 28.5조원을 기록하였으며, 최근 10년간 3.25%의 증가율을 보이고 있다. 교통 혼잡비용은 도심부 내에서 발생하는 혼잡비용이 전체의 63.39%를 차지하고 있으며, 전년대비 2.5% 증가하고 있다[1]. 교통혼잡에 의해 발생하는 정체는 반복정체와 비반복정체로 구분된다. 반복정체는 첨두시(Peak hour)와 특정 구간에 주기적으로 발생하는 특징이 있기 때문에 예측이 가능하며 교통 정보의 제공·관리 및 운영을 통해 교통혼잡 완화가 가능하다. 반면 비반복정체는 불규칙하게 발생하여 예측이 불가능하기 때문에 이로 인한 교통혼잡을 해소하는데 많은 어려움이 따른다. 이러한 예측 불가능한 비반복정체는 유고(incidents)에 의해 발생된다. 유고는 교통사고 뿐만 아니라 차량고장, 자연재해, 도로 시설의 유지 및 보수 작업, 도로의 행사 및 집회, 불법 주·정차 차량 등으로 인해 발생하는 혼잡을 말한다.

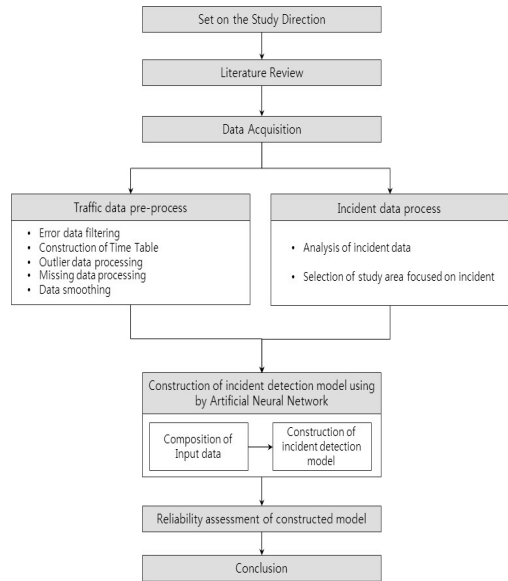
돌발상황 검지에 관한 연구는 오래 전부터 다양하게 개발되어 왔다. 그러나 대부분 고속도로와 같은 연속류를 대상으로 연구가 수행되어 왔다. 연속류 도로의 경우 상대적으로 일시적인 용량 감소의 변화가 적고 기존의 교통류 이론이나 확률론적 방법론 등을 적용하여 정확도 높은 검지가 가능하다.

그러나 도심부 단속류 도로는 신호교차로, 불법주정차 차량과 같은 다양한 요인으로 인해 돌발상황과 유사한 정체현상이 빈번하게 발생하고 매우 넓고 복잡한 도로망 전체에 대하여 유고검지를 해야 하는 어려움이 있다. 따라서 지금까지 개발된 돌발상황 검지 알고리즘을 도심부 도로망에 적용하기 위해서는 많은 비용이 필요할 뿐만 아니라 연속류와 같은 성능을 기대하기 어렵다.

최근 차량 내비게이션 시스템과 근거리 통신 시

스템의 보급으로 Urban Traffic Information System (UTIS)와 같은 프로브 차량을 이용한 데이터수집체계의 구축이 확대되고 있다. 프로브 차량을 이용한 데이터 수집체계는 차량에 설치된 GPS 단말기를 이용하여 차량의 궤적정보를 수집한다. 수집 데이터는 도로망 전체에 대한 데이터 수집이 가능하다는 장점이 있는 반면 통행시간 및 통행속도만 수집되어 기존의 교통량, 밀도 기반의 알고리즘에 적용할 수 없다는 한계가 있다.

따라서 본 연구에서는 GPS 기반의 차량 궤적 데이터 기반 속도 데이터를 활용하여 도심부 단속류 도로의 돌발상황 검지 모형을 구축하고자 하였다. 이를 위한 검지 모형의 틀은 인공지능망을 활용하였다.



〈그림 1〉 연구수행절차
(Fig 1) Flow of Study

2. 연구수행 방법

유고검지 알고리즘 고찰 및 문헌고찰을 통해 기존 연구의 문제점을 분석하였다. 또한 수집된 교통 데이터 및 유고 데이터를 전처리 하였다. 전처리된 교통 데이터와 유고 데이터의 분석을 통해 돌발상황 검지에 필요한 변수를 도출하였고 인공지능망을 구축하여 결론을 도출하였다.

II. 문헌고찰

1. 연속류 도로의 돌발상황 검지

Jian Lu(2012)는 연속류 도로를 대상으로 하이브리드 모형인 PLSNN을 기반으로 하여 유고 검지 기법에서 새로운 방법의 활용과 증명을 수행하였다[2]. 수집된 교통 데이터 변수는 교통량 · 속도 · 점유율을 활용하였으며, 도로의 상류부 및 하류부에서 나타나는 교통류 차이를 파악하였다.

또한, Jian Lu(2012)는 Landwehr(2005)가 개발한 확률적 논리 규칙 학습 체계인 nFOIL을 활용하여 고속도로를 대상으로 새로운 유고 검지 방법을 제시하였다[3]. 기존 유고 검지 방법 중 Neural Network와 Support Vector Machines(SVM)을 선택하여 비교하였으며, 다양한 데이터를 적용하여 정확성을 검증하였다. 연구 결과, Neural Network와 nFOIL의 유고 검지율 및 오보율에 있어서 높은 정확도를 보였다. nFOIL의 장점으로는 모형이 이해하기 쉽고, 데이터 구조를 처리하는데 강력한 기능이 있었지만 시간이 오래 걸린다는 단점이 있었다.

허민국(2010)은 과거의 교통패턴과 실시간 교통 데이터와의 차이값을 이용하여 돌발상황을 판정하는 알고리즘을 개발하였다. 이를 위해 패턴데이터를 구축하고, 교통패턴자료의 가중이동평균과 표준편차 값 및 실시간 속도데이터를 표준정규화한 Standard Normal Distribution(SND) 값을 이용하였다. 또한 교통 데이터 변수는 교통량 · 속도 · 점유율을 활용하였으며, 돌발상황 검지 모형을 구축하기 쉽고, 다른 도로로의 이식성이 높은 장점이 있다.

김상구(2008)는 교통량에 따라 돌발상황 교통류를 3가지로 분류하여 각각의 특성을 분석하였다. 이를 기반으로 속도 기준 수정 교통량-점유율 관계도를 통해 돌발상황 검지 알고리즘을 제시하였다. 또한 교통량 · 속도를 교통 데이터 변수로 활용하였다.

홍남관(2007)은 패턴데이터를 구축하여 퍼지론에 적용한 유고 검지 모형을 구축하였다. 퍼지 시스템의 결과 값인 유고 확률과 교통패턴 시스템의 결과

값인 교통 패턴 차이 값을 이용하였다. 교통 데이터 변수로써 교통량 · 점유율 · 속도를 활용하였다. 연구 결과, 퍼지논리만 사용한 모형에 비해 유고 검지율은 5% 낮아졌으나, 오검지율은 18% 낮아지는 향상된 결과를 도출하였다.

장세봉(2001)은 인공신경망 중 BP 알고리즘을 활용하여 고속도로를 대상으로 유고 검지 알고리즘을 구축하였다. 활용된 교통 데이터는 교통량 · 점유율 · 속도이며, 시물레이션을 통해 유고를 발생시켜 학습률을 구축하였다. 시물레이션 검증 결과, 검지율은 69.2~100% , 오보율은 10%로 나타났다.

2. 단속류 도로의 돌발상황 검지

Faisal Ahmed(2012)는 신호 교차로 링크에서 발생된 유고의 시간 간격별 유고 상태를 검지하기 위해 임계값을 기반으로 도심부 유고 검지 모형을 개발하였다. 또한 다양한 시나리오를 설정하여 NETSIM 시물레이션을 통해 분석 및 실험을 통해 회귀 모형을 도출하였다. 연구 결과, 검지율은 23~87%, 오보율은 0~20%로 나타났다.

Dia(2011)는 시물레이션을 통한 루프검지기에서 수집된 데이터와 프로브 차량 데이터를 이용하여 간선도로에서 활용 가능한 유고검지법을 Neural Network를 통해 증명하였다. 시물레이션에서 교통 데이터 변수는 교통량을 활용하였으며, Neural Network의 학습을 위한 입력 데이터 값은 유고의 위치 · 유고 지속 시간 · 유고 강도 등을 활용하였다. 연구 결과, 검지율은 59~86%, 오보율은 0.36~0.5%로 나타났다.

Huiying(2011)은 간선도로에서 발생하는 유고를 검지하기 위해서 Learning vector quantization(LVQ) 신경망과 데이터 합성 기술을 적용하였다. 이를 위해 루프 검지기로부터 수집된 정보와 프로브 차량으로부터 수집된 GPS 정보를 입력 변수로 활용하였다. 활용된 교통 데이터 변수로써, 속도 · 점유율을 활용하였으며, 데이터 시간 간격을 30초 단위로 설정하였다. 연구에서는 간선도로에 설치된 루프 검지기로부터 상류부 · 중류부 · 하류부의 공간적

교통 변수의 차이를 활용하였으며, VISSIM을 사용하여 시뮬레이션을 수행하였다. 연구 결과, 데이터 합성기술과 LVQ 신경망의 검지율이 BP 신경망의 검지율보다 높게 나타났다. 여기서 LVQ 신경망의 검지율은 96.67%, 오보율은 3.45%로 나타났다.

Zhang(2006)은 간선도로에서 유고상황을 검지할 수 있는 Transport Systems Centre arterial roads (TSC_ar) 알고리즘을 개발하였다. 해당 알고리즘은 Bayesian Network와 Automated Incident Detection(AID) system을 기반으로 개발되었으며, 상류부와 하류부에서 수집되는 교통 데이터를 활용하여 검지하였다. 교통 변수는 교통량과 점유율을 활용하였다. 시뮬레이션을 활용한 실험 결과, 개발된 알고리즘의 유고 검지율은 88%, 오보율은 0.62%로 도출되었다.

모무기(2011)는 단속류 도로에서 유고상황을 감지하기 위해 라틴방격분석을 활용하였다. 이를 위해 수집된 교통 데이터를 1분 단위로 설정하였으며, 연구에서는 교통량 · 속도 · 점유율을 교통 데이터 변수로써 각각 활용하였다. 연구 결과, 유고 검지율이 가장 높은 결과는 55.6%로 나타났으며, 유고 오보율이 가장 낮은 결과는 16.7%로 나타났다.

3. 시사점 및 기존 연구와의 차별성

대부분 기존 연구는 연속류 도로를 대상으로 수행되어 왔다. 최근에 단속류 도로를 대상으로 하는 돌발상황 검지에 관한 연구가 일부 수행된 경우가 있으나, 국내의 경우에는 극히 미비한 실정이다. 또한 단속류 도로에 관한 돌발상황 검지 연구를 살펴보면, 연속류 도로에 비해 연구 기법의 다양성이 부족하다. 그리고 검지율 · 오보율 · 유고 지속시간 등의 정확도 검증 부분에 있어, 연속류 도로에 비해 상대적으로 저조하다는 것을 알 수 있다. 또한 기존의 단속류에 적용된 알고리즘의 정확도 검증 시, 실제 데이터를 활용하지 않고 시뮬레이션을 통한 검증이 대부분이었다. 따라서 실제 데이터를 통한 검증과 다양한 단속류 도로를 대상으로 한 연구가 필요할 것으로 판단된다.

본 연구와 기존 연구의 차별성은 첫째, 도심부 내 단속류 도로를 주행한 프로브 차량을 통해 수집된 데이터를 활용하여 광범위한 도로에의 적용이 가능하다. 둘째, 기존 돌발상황 검지 알고리즘들은 속도 · 점유율 · 교통량 등 다양한 교통 데이터 변수가 필요하나, 본 연구는 속도 데이터만을 활용하였다. 셋째, 인공신경망을 통해 구축된 돌발상황 검지 모형의 검증에 실측 데이터를 활용하였다.

III. 수집 데이터 가공 및 분석

1. 연구 범위

본 연구의 공간적 범위는 서울특별시 강남구로 설정하였다. 속도 및 유고 데이터의 수집 기간은 2013년 6월 1개월이며, 주말 및 공휴일을 제외한 평일을 대상으로 하였다.

내용적 범위는 전처리 과정을 통해 구축된 교통 정보를 기반으로 강남구 내 교통정보 수집 현황을 분석하였다. 이후 패턴데이터를 구축하였으며, 돌발상황 발생에 따른 교통류 변화를 분석하였다. 이를 바탕으로 인공신경망의 Input 데이터를 선정하고 돌발상황 검지 모형의 구축 및 검증을 수행하였다.

2. 차량 궤적 데이터 수집

본 연구에서는 강남구 내에 주행한 차량의 내비게이션에서 수집된 차량 궤적 데이터를 활용하였다. 일 평균 약 3,500대의 차량에서 수집하였으며, 차량ID, 링크 진입 시간, 링크 ID, 속도 등으로 구성되어 있다. 여기서 속도 정보는 내비게이션 기기의 GPS 위치 데이터를 통한 링크 진입시간 및 진출시간과 링크 길이를 통하여 ‘링크기반 통행 속도’가 산출된다.

수집 차량 궤적 데이터는 ‘국가 표준 노드링크’를 활용하여 각 링크의 시간별 5분 단위 대표속도를 산출하고, 전처리 과정을 수행하였다. 수집 프로브 차량 속도의 평균과 표준편차를 활용하여 이상치를 제거한 후, ‘가중이동평균법’을 적용하여 결측 처리

하였다. 또한 Haan(2001)에서 제시한 기법을 적용하여 평활화 과정을 수행하였으며, 식 (1)과 같다.

$$V_{smoothed}(t) = \frac{1}{h} \sum_{s=-h}^h K\left(\frac{s}{h}\right)v(t+s)$$

$$K(x) = \begin{cases} \frac{h^2-1}{h^2}(1-x^2)^2, & x^2 < 0 \\ 0, & \text{others} \end{cases} \quad (1)$$

여기서, $V_{smoothed}$ 는 평활화한 속도, K 는 시간 t 를 기준으로 속도 산출 시의 가중치, 변수 h 는 일반적으로 4로 설정한다.

3. 교통정보 수집현황 분석


본 연구의 데이터 수집원인 프로브 차량은 강남구 내에 불규칙적으로 분포되어 있으나 일반적으로 교통량이 많은 지역에서 수집율이 높은 특징이 있다. 그러므로 수집율이 높은 지역과 낮은 지역에 따라 정보의 신뢰성이 달라진다. 따라서 본 연구에서는 가공한 교통정보를 바탕으로, 강남구 링크 별 수집 교통정보 중 신뢰성 있는 링크를 연구 대상으로 선정하기 위해서 교통정보 수집율을 분석하였다.

분석 결과는 <표 1>과 같다. 강남구 내 단속류 도로의 링크 수는 총 1,481개이며, 이 중 923개의 링크에서 수집되었다. 따라서 도심부 전체 도로망 대비 교통정보가 수집되는 비율을 나타내는 Network Coverage는 62.32%로 나타났다.

또한 링크별 시간대를 기준으로 수집율을 분석하였다. 즉, 데이터의 시간 단위는 5분이므로 하루 동안의 시간 단위는 288개이며, 19일 간 총 5,472개의 시간 단위를 기준으로 각 링크 별 19일간 수집된 데이터의 비율을 산출하였다. 결과는 <그림 2>, <표 2> 와 같다. 본 연구에서는 데이터의 수집율이 높은

<표 1> 강남구 링크의 Network Coverage
<Table 1> Network coverage of links

Number of entire road links	1,550
Number of urban road links	1,481
Number of data collected links	923
Network coverage(%)	62.32%



<그림 2> 각 링크 별 시간 수집률
<Fig 2> Data collection rate based on time by each link

<표 2> 각 링크 별 시간 수집률
<Table 2> Data collection rate based on time by each link

Collection rate	Number of links	Rate(%)
Over 40%	16	1.73
30% ~ 40%	77	8.34
20% ~ 30%	108	11.70
10% ~ 20%	147	15.93
Under 10%	575	62.30
Aggregate	923	100.00

간선도로를 대상으로 연구를 수행하였다.

4. 패턴데이터 구축

패턴데이터의 구축을 통해 정상적인 교통류 및 반복정체구간을 파악함과 동시에 돌발상황 발생 시 변화하는 교통류와의 차이를 분석 하여 돌발상황 검지에 활용하고자 하였다. 이를 위해, 수집 돌발상황 데이터를 활용하여 돌발상황이 발생한 링크와 발생 및 종료 시간의 교통 정보를 제외하여 구축하였다. 또한 교통정보의 수집율이 낮은 시간대인 00시 부터 06시까지의 교통정보는 제외하였다.

5. 돌발상황 데이터 분석

전처리를 통해 구축한 교통정보 및 패턴데이터와 수집 돌발상황 데이터를 기반으로 돌발상황 발생에 따른 교통류의 변화를 분석하였다. 이를 위해

2013년 6월 중 평일 기간 중 강남구 내에 발생한 12건의 돌발상황을 추출하였다. 각 돌발상황의 발생 시간 및 위치는 <표 3> 과 같다.

<표 3> 돌발상황 정보 예시
(Table 3) Example of incident information

Day	Incident start time	Incident end time	Incident location
3	14 : 35	15 : 35	Gangnam-Daero
5	14 : 30	15 : 30	Gangnam-Daero
7	20 : 00	21 : 00	Youngdong-Daero
7	20 : 45	21 : 15	Teheran-Ro
10	14 : 35	15 : 35	Yeonju-Ro
12	12 : 25	13 : 25	Youngdong-Daero
12	13 : 30	14 : 30	Dosan-Daero
12	15 : 20	15 : 50	Youngdong-Daero
13	09 : 45	10 : 15	Nambusoonthan-Ro
14	17 : 40	18 : 40	Youngdong-Daero
14	21 : 20	22 : 20	Teheran-Ro
20	11 : 50	12 : 50	Gangnam-Daero


연속류 도로는 일관성 있는 교통 패턴을 보이나, 도심부 단속류 도로는 다양한 변수로 인해 연속류 도로에 비해 뚜렷한 교통 패턴을 보이지 않는다. 즉, 단속류 도로에서는 돌발상황이 발생하지 않더라도 교통 흐름이 불안정한 상태가 많이 발견되었다. 돌발상황 발생 시에도 이와 마찬가지로 돌발상황의 발생 지점 · 시간 · 유형 등에 따라 다양한 교통 패턴을 보였다.

이에 본 연구에서는 수집 교통 정보와 추출한 12건의 돌발상황 데이터를 매칭하여 돌발상황이 발생함에 따라 나타나는 다양한 교통 패턴을 분석하였다.

먼저, 돌발상황이 발생함에 따라 해당 지점의 구간 속도가 급격하게 저하 되는 특징이 있다.


<그림 3>은 2013년 6월 3일 강남대로에서 발생한 돌발상황에 따른 교통류 변화를 나타낸 것이다. 실선은 해당 링크 · 시간대의 속도 데이터이며 점선은 패턴 데이터이다. 그림에서 나타나는 것과 같이 돌발상황이 발생함에 따라 속도가 급격하게 저하되며, 기존의 교통류와는 상이한 형태가 나타남을 알 수 있다.

또한 본 연구에서는 돌발상황 발생에 따른 상 ·



<그림 3> 돌발상황 발생에 따른 관측 속도데이터와 패턴 데이터의 차이

<Fig 3> Difference of Observed speed and Pattern speed



<그림 4> 상 · 중 · 하류부의 패턴데이터와 속도 데이터의 차이

<Fig 4> Errors of Up stream, Middle stream and Down stream compared to Pattern data

하류부의 구간 통행 속도 차이를 분석하기 위하여 패턴데이터를 활용하였다. 교차로와 신호등이 존재하는 단속류의 특성 상 링크 간 상이한 교통 패턴이 있을 수 있다. 즉, 상류부와 하류부의 속도 차이가 나더라도, 돌발상황과 관계없이 나타나는 해당 도로의 특성일 가능성이 있다. 따라서 상류부와 하류부의 패턴데이터와의 차이를 활용하여 비교 및 분석함으로써 해당 시점의 소통 상황을 반영할 수 있는 장점이 있다. <그림 4>는 상 · 중 · 하류부의 속도 데이터와 패턴데이터의 차이 값으로써, 0보다 작은 값은 기존 패턴데이터보다 낮은 속도를 의미한다. 또한 돌발상황이 발생하였을 경우, 상류부의 속도가 저하되는데 반해 하류부의 속도는 상 · 중류부에 비해 높은 것을 알 수 있다. 여기서, 중류부는 돌발상황이 발생한 링크이며, 상 · 하류부는 중류부의 각 인접링크를 말한다.

그러나 도심부 단속류 도로에서는 신호체계와 다양한 변수로 인해 교통류가 불안정한 특징이 있다. 따라서 돌발상황이 발생하더라도 위에서 분석한 교통류의 뚜렷한 특징들이 나타나지 않는 경우가 존재한다. 그러므로 본 연구에서는 질적 변수 및 양적 변수에 관계없이 모두 분석이 가능하며, 입력 변수들 간 비선형 조합이 가능한 인공신경망을 활용하여 돌발상황 검지 모형을 구축하고자 하였다.

IV. 인공신경망을 활용한 돌발상황 검지 모형 구축

도심부 도로는 고속도로와 같은 연속류 도로와 달리 신호교차로 및 다양한 변수가 존재한다. 앞서 분석한 바와 같이 돌발상황이 발생할 경우, 돌발상황을 검지하기 위한 교통류의 특징이 뚜렷하게 나타나는 경우와 그렇지 않은 경우가 존재하므로, 연속류 도로에 적용되는 일반적인 방법이나 알고리즘을 통해서 돌발상황을 검지하기에 어려움이 있다. 따라서 본 연구에서는 복잡하고 비선형적인 입력 변수들간의 패턴 분석이 가능한 인공신경망을 활용하였다.

1. 인공신경망 적용을 위한 데이터 구성

돌발상황 발생에 따라 변화하는 교통류의 분석을 통한 특징과 기존 연구에 적용된 변수를 기반으로 인공신경망의 입력 데이터를 구성하였다.

첫 번째 변수는 돌발상황 발생 시 중류부에서 패턴데이터에 비해 속도가 저하되는 특징을 이용하기 위해 패턴데이터와의 속도 차이로 정의하였다. 두 번째 활용 변수는 McMaster 알고리즘에서 중류부와 하류부의 교통류 변화율 적용하였다. 본 연구에서는 ‘공간적 속도 변화율’로 정의하였다. 또한 California 알고리즘 구조를 확장 및 통합한 APID 알고리즘의 입력 변수로 활용하고 있는 ‘시간적 속도 차이율’을 세 번째 입력 변수로 설정하였다. 네 번째 변수는 ‘시간적 속도 차이율’과 유사하다. 돌발상황 발생시, 구간 통행 속도가 급격히 저하되는

〈표 4〉 인공신경망 구축을 위한 변수 설정
 〈Table 4〉 Variables for constructing Artificial Neural Network

Definition	Calculation method
Variation of Observed speed data and Pattern data	$SPD(i,t) - PTTN(i,t)$
Fraction of variation of avg speed depending on Space	$\frac{SPD(i+1,t) - SPD(i,t)}{SPD(i+1,t)}$
Fraction of variation of avg speed depending on Time	$\frac{SPD(i,t-1) - SPD(i,t)}{SPD(i,t-1)}$
Variation of Speed	$SPD(i,t) - SPD(i,t-1)$
Difference value between errors of Up-stream and Down-stream compared to Pattern data	$(SPD(i-1,t) - PTTN(i-1,t)) - (SPD(i+1,t) - PTTN(i+1,t))$
Variation of number of Probe vehicle	-
Link length	-
Number of lane	-
Number of crosswalk signal	-

특징을 활용하기 위해 중류부의 5분전 속도와의 차이를 산출하여 적용하였다. 다섯 번째 변수는 상류부의 속도와 하류부의 속도 차이를 활용하였다. 상류부와 하류부는 중류부에 의해 공간적 거리 차이가 있으므로 패턴데이터를 이용하여 속도 차이를 산출하였다. 여섯 번째 변수로는 돌발상황 발생으로 인해 본 연구에서 설정한 5분 단위 시간 내에 프로브 차량이 링크를 통과하지 못하는 경우가 발생하는 점을 반영하기 위해 수집 프로브 차량 대수 차이를 설정 하였다. 추가적으로 도로의 기하구조를 입력변수로 활용하였으며, 이러한 변수는 <표 4>와 같다.

2. 돌발상황 검지 모형 구축

본 연구에서는 인공신경망 중 가장 널리 활용되고 있는 Back Propagation(BP) 알고리즘을 채택하였다. 이를 위해 Matlab 7.1을 활용하였다.

인공신경망 학습에는 Hidden Layer의 수와 Neuron의 수가 학습 성과에 많은 영향을 미친다. 따라서 Hidden Layer 수와 Neuron 수를 달리 변화시켜 최적 모형을 구축하고자 하였다. Hidden Layer의 수는 1부터 3개 까지 변화시켰고 Neuron의 수는 1부터

23개 까지 변화를 주었다. 또한 각 학습 과정을 30 회씩 반복하였다.

돌발상황 검지 모형을 구축하기 위해 12개의 돌발상황 데이터를 활용하였다. 이 중 Input Data 10개와 Test Data 2개를 랜덤으로 선택하도록 하여 5가지의 시나리오를 구성하였다. 이러한 학습 과정을 통해 도출된 최적 모형은 Hidden Layer 수 2개와 Neuron 수 16개로 선정되었다.

Target Data는 해당 Input Data의 링크 별 · 시간대 별 돌발상황 여부 데이터 이며, 0은 정상, 1은 돌발상황으로 설정하였다.

3. 테스트 결과

구축된 최적 돌발상황 검지 모형에서 각각 2013년 6월 5일, 2013년 6월 10일에 발생한 돌발상황 데이터를 대상으로 돌발상황 검지를 테스트 하였다. 테스트에 대한 결과는 <그림 5>, <그림 6>과 같다.


결과를 살펴보면, Target values는 실제 돌발상황이 발생한 데이터이며, Estimates values는 시간대에 따른 구간 통행 속도의 변화에 따라 인공신경망 모형이 돌발상황을 검지한 결과이다. 또한 검지율과 오검지율을 고려하여 임계값(Threshold)을 0.25로 설정하였으며, 이를 통해 최종 판정 값은 Judgement value로 나타내었다. 인공신경망의 특성 상, 0 부터 1 사이 범위로 표현되었으며, 1은 돌발상황을 나타내며 0은 정상상태를 나타낸다.

4. 신뢰성 검증


구축된 모형의 신뢰성 검증을 위한 지표로 검지율과 오보율을 선정하였다. 검지율은 돌발상황 총 발생건수에 대한 실제 돌발상황 발생 건수에 대한 비율이며, 오보율은 돌발상황으로 판정한 건수에 대한 오보건수의 비율이다[10]. 이러한 신뢰성 검증을 위한 지표는 다음 식 (2), (3)과 같다.

$$\text{돌발상황 검지율} = \frac{\text{실제 돌발상황 검지 건수}}{\text{총 돌발상황 발생 건수}} \times 100 \quad (2)$$

$$\text{돌발상황 오보율} = \frac{\text{오보 건수}}{\text{총 돌발상황 판정 건수}} \times 100 \quad (3)$$



<그림 5> Case 1(6월 5일)의 테스트 결과
<Fig 5> Test result of Case 1 (June 5)



<그림 6> Case 2(6월 10일)의 테스트 결과
<Fig 6> Test result of Case 2 (June 10)

신뢰성 검증 결과, Case 1의 경우, 돌발상황 검지율 46.15%, 오보율 25.00%가 도출되었다. Case 2의 경우, 돌발상황 검지율 38.46%, 오보율 16.67%가 도출되었다.

Case 1과 Case 2 모두 검지율은 기존의 연속류 도로의 돌발상황 검지율에 비해 저조한 결과가 나타났다. 그러나 도심부 도로의 특성 및 학습된 공간적 범위와는 다른 구간을 대상으로 수행한 결과와 실측데이터를 활용한 점을 감안하면 긍정적인 결과라 사료된다.

V. 결론 및 향후연구과제

본 연구는 도심부 간선도로를 대상으로 돌발상황 검지 모형을 구축하고자 하였다. 이를 위해 강남구를 대상으로 프로브 차량을 통한 속도 데이터를 활용하였다. 데이터의 전처리 및 가공을 통해 활용 가능한 교통 정보를 구축하였다. 또한 교통 정보와 돌발상황 데이터를 매칭하여, 도심부 단속류 도로에서 돌발상황이 발생할 경우 변화하는 소통상황의 특징을 분석하였다. 분석 결과, 돌발상황이 발생한 중류부 지점에서 급격한 속도 저하 및 패턴데이터와의 차이를 확인할 수 있었고, 상류부 및 하류부와

교통류가 변화하는 것을 알 수 있었다. 이러한 분석 결과를 토대로 본 연구에서는 인공지능망에 활용하기 위한 **Input Data**를 구성하였으며, 구축된 학습망을 통해 최적 모형을 선정하였다.

구축된 모형의 실험 결과를 기반으로 신뢰성 검증을 수행하였다. 신뢰성 검증 결과, 돌발상황 검지율과 오보율에 있어 **Case 1**의 경우 46.15%, 25.00%, **Case 2**의 경우 38.46%, 오보율 16.67%가 각각 도출되었다. 이러한 신뢰성 검증 결과는 수집 데이터의 특성에 의한 차이로 사료된다. **Case 1, 2** 모두 돌발상황이 발생함에 따라 중류부의 패턴 데이터에 비해 낮은 통행속도가 나타났지만, 상류부의 통행속도는 **Case 2**에 비해 **Case 1**이 뚜렷하게 낮아진 것이 관측되었다.

전반적인 신뢰성 검증 결과는 연속류 도로를 대상으로 수행한 돌발상황 검지 연구에 비해 양호한 결과가 도출되었다고 할 수 없다. 그러나 본 연구를 통해 강조할 수 있는 사항은 다음과 같다.

첫째, 본 연구는 교통 혼잡 및 유고 상황이 빈번한 도심지 단속류 도로를 대상으로 돌발상황을 검지하였다. 단속류 도로는 신호 교차로와 다양한 변수가 존재하기 때문에 교통류가 불안정한 특징이 있다. 따라서 연속류 도로에 비해 상대적으로 검지율이 낮지만 프로브 차량으로부터의 속도 자료에 근거한 활용도 제고 차원에서 의미가 있다고 사료된다. 또한 기존 연속류에 적용되고 있는 알고리즘에서 활용하는 교통량·점유율 등의 MOE에서 탈피하여 GPS를 장착한 프로브 차량을 활용하였다. 이를 통해 링크에 일정 수집율 이상의 데이터가 확보 된다면, 전체 네트워크에서 돌발상황 검지가 가능하다.

둘째, 본 연구에서 돌발상황 검지율 및 오보율의 테스트 구간은 인공지능망이 학습된 구간과는 다른 구간이다. 이는 기하구조와 교통류의 특성이 다른 구간을 대상으로 테스트를 수행했기 때문이며, 이러한 점을 고려하면 비교적 나쁘지 않은 결과라 할 수 있다.

셋째, 국내·외 기존 단속류 대상의 연구는 대부분 시뮬레이션을 통해 신뢰성 검증을 수행하여 높

은 검지율을 도출하였다. 그러나 본 연구는 실측 데이터를 활용하였으므로, 보다 진실보한 긍정적인 결과라고 판단된다.

그러나 본 연구는 강남구 내 교통정보 수집율이 비교적 높은 간선도로만을 대상으로 돌발상황 검지를 수행하였다. 간선도로에 비해 더 복잡한 기하구조 및 다양한 변수가 있는 집산도로나 국지도로에의 적용과 검증이 필요할 것이다. 그리고 도심부 교통류의 특성은 첨두/비첨두시에 따라 많은 차이가 있다. 이러한 특성은 돌발상황 검지의 성능에도 영향을 미칠 것으로 예상되므로 이를 구분한 검증이나 추가적인 연구가 필요하다.

또한 돌발상황 검지 모형의 현장 적용성을 향상시키기 위한 방안의 강구가 필요하다. 각 도로마다 교통정보 수집율이 상이했으며, 수집율이 낮은 도로는 돌발상황을 검지하기에 다소 무리 있었다. 이를 위해 광범위한 데이터를 바탕으로 한 검지 모형의 구축이 필요하며, 임계값의 적절한 유동성과 다양한 변수를 반영하여 향상된 검지율과 오검지율을 보이는 모형 연구가 수반되어야 할 것이다.

REFERENCES

- [1] <http://www.index.go.kr/>
- [2] Jian Lu, Shuyan Chen, Wei Wang, Henk van Zuylen, "A hybrid model of partial least squares and neural network for traffic incident detection," *Journal Expert Systems with Applications: An International Journal archive*, vol. 39 no. 5, pp.4775-4784, April. 2012.
- [3] Jian Lu, Shuyan Chen, Wei Wang, Bin Ran, "Automatic traffic incident detection based on nFOIL," *Expert Systems with Applications*, vol. 39, no. 7, pp.6547-6556, June. 2012.
- [4] M. G. Heo, C. G. No, W. G. Kim, B. S. Son, "Development of an Incident Detection Algorithm by Using Traffic Flow Pattern," *Journal of Korean Society of Transportation*, vol. 28, no. 6, pp.7-15, Dec. 2010.

- [5] S. G. Kim, Y. C. Kim, "Development and Evaluation of Automatic Incident Detection Algorithm using Modified Flow-Occupancy Diagram," *Journal of Korean Society of Transportation*, vol. 26, no. 4, pp.229-239, Aug. 2008.
- [6] N. K. Hong, J. C. Woo, Y. K. Yang, "A Study on Incident Detection Model using Fuzzy Logic and Traffic Pattern," *Journal of Korea Spatial Information Society*, vol. 9, no. 1, pp.79-90, Jun. 2007.
- [7] Faisal Ahmed, Yaser E.Hawas, "A threshold-Based Real-Time Incident Detection System for Urban Traffic Networks," *Transport Research Arena-Europe*, vol 48, pp.1713-1722, Athens, Greece, April, 2012.
- [8] Hussein Dia, Kim Thomas, "Development and evaluation of arterial incident detection models using fusion of simulated probe vehicle and loop detector data," *Information Fusion*, vol. 12, no. 1, pp.20-27, Jan. 2011.
- [9] Huiying WEN, Jun LUO, "Traffic incident detection for urban arterial road based on data fusion and learning vector quantization," *American Society of Civil Engineers, ICTIS 2011*, pp.971-978, Wuhan, China, Jun, 2011.
- [10] M. K. Mo, H. J. Kim, B. S. Son, D. H. Kim, "Development of Incident Detection Method for Interrupted Traffic Flow by Using Latin Square Analysis," *Korean society of civil engineers*, vol. 31, no. 5D, pp.623-631, Sep. 2011.
- [11] S. B. Lee, Y. H. Kim, "Development of a Fuzzy-Genetic Algorithm-based Incident Detection Model with Self-adaptation Capability," *Journal of Korean Society of Transportation*, vol. 22, no. 4, pp.159-173, Aug. 2004.
- [12] B. Y. Ryu, "Development of models for measuring efficiency and CO2 emissions, and methodology for the environmental impact assessment of ITS service," *Doctorate Thesis, Pukyong national university*, 2013.
- [13] T. U. Kim, "Incident Detection of Urban Arterial Road using by Artificial Neural Network," *Master Thesis, Pukyong national university*, 2014.
- [14] Haan. P.D, Keller. M, "Real-world driving cycles for emission measurement: ARTEMIS and Swiss cycles" *Final Report*, March, 2001.
- [15] S. B. Jang, "A Basic Study on Neural Network Incident Detection using INTRAS data," *Thesis, Young Dong university*, 2001.
- [16] Kun Zhang, Michael A.P. Taylor, "Effective arterial road incident detection: A Bayesian network based algorithm," *Transportation Research Part C: Emerging Technologies*, vol. 14 no. 6, pp.403-417, Dec. 2006.

저자소개




김 태 옥 (Kim, Tae-Uk)

2014년 : 부경대학교 대학원 공간정보시스템공학과 석사 (ITS전공)

현 재 : 한국교통연구원 물류정책·기술본부 연구원

e-mail : tukim0403@gmail.com



배 상 훈 (Bae, Sanghoon)

1995년 : 미국 Virginia Tech. 박사

2002년 : 한국교통연구원 ITS 팀장

현 재 : 부경대학교 교수(공간정보시스템공학과)

e-mail : sbae@pknu.ac.kr



정 희 진 (Jung, Heejin)

2012년 미국 Virginia Tech. 박사

현 재 : 부경대학교 공간정보연구소 전임연구원

e-mail : hjjung1974@gmail.com