

인공신경망을 활용한 V2I2V 통신 기반 차량 충돌방지 지원 서비스 개발

Development of V2I2V Communication-based Collision Prevention Support Service Using Artificial Neural Network

탁 세 현* · 강 경 표** · 이 동 훈***

* 주저자 : 한국교통연구원 부연구위원

** 공저자: 한국교통연구원 연구위원

*** 교신저자 : 한국교통연구원 부연구위원

Sehyun Tak* · Kyeongpyo Kang* · Donghoun Lee*

* The Korea Transport Institute

† Corresponding author : Donghoun Lee, donghoun.lee@koti.re.kr

Vol.18 No.5(2019)

October, 2019

pp.126~141

pISSN 1738-0774

eISSN 2384-1729

<https://doi.org/10.12815/kits.2019.18.5.126>

2019.18.5.126

Received 6 September 2019

Revised 24 September 2019

Accepted 25 September 2019

© 2019. The Korea Institute of Intelligent Transport Systems. All rights reserved.

요 약

차세대첨단교통시스템(C-ITS)의 우선 도입 서비스 항목 중 하나로 차량 충돌방지 지원 서비스가 고려되고 있다. 이에 인공신경망을 적용한 V2I2V 통신 기반의 후미추돌사고 예방 방법들이 몇몇 제시되었지만, 낮은 C-ITS 단말기 보급률 및 대용량 교통정보로 인한 지연 현상 등 한계로 인해 그 효과가 미미하다. 따라서 본 연구는 실시간 구간교통 정보를 활용한 인공신경망 기반 충돌 경고 서비스(ACWS, Artificial Neural Network-based Collision Warning Service)를 제안한다. 제안 서비스는 실시간 구간 교통정보를 반영해 인공신경망의 가중치를 갱신하고 구간 진입 차량에게 제공한다. 본 연구는 C-ITS 단말 보급률과 지연시간에 따른 제안 서비스의 성능 평가를 수행한다. 분석결과 C-ITS 단말 보급률이 높고 지연시간이 낮을수록 제안 서비스가 더 나은 성능을 나타내고, 같은 조건일 경우 고도화된 인공신경망을 적용한 서비스 성능이 더 뛰어난 것으로 확인된다.

핵심어 : 후미추돌사고, 차세대첨단교통시스템, 차량 충돌방지 지원 서비스, 인공신경망, V2I2V

ABSTRACT

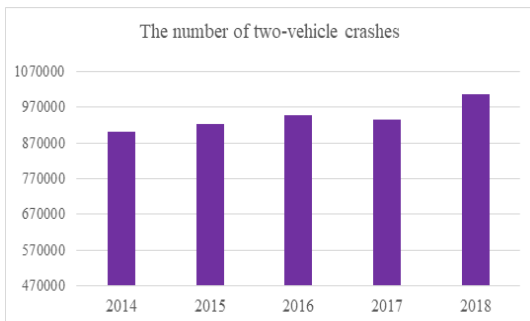
One of the Cooperative Intelligent Transportation System(C-ITS) priority services is collision prevention support service. Several studies have considered V2I2V communication-based collision prevention support services using Artificial Neural Networks(ANN). However, such services still show some issues due to a low penetration of C-ITS devices and large delay, particularly when loading massive traffic data into the server in the C-ITS center. This study proposes the Artificial Neural Network-based Collision Warning Service(ACWS), which allows upstream vehicle to update pre-determined weights involved in the ANN by using real-time sectional traffic information. This research evaluates the proposed service with respect to various penetration rates and delays. The evaluation result shows the performance of the ACWS increases as the penetration rate of the C-ITS devices in the vehicles increases or the delay decreases. Furthermore, it reveals a better performance is observed in more advanced ANN model-based ACWS for any given set of conditions.

Key words : Cooperative intelligent transportation system, Rear-end collision, Collision prevention support service, Vehicle-to-infrastructure-to-vehicle, Artificial neural network

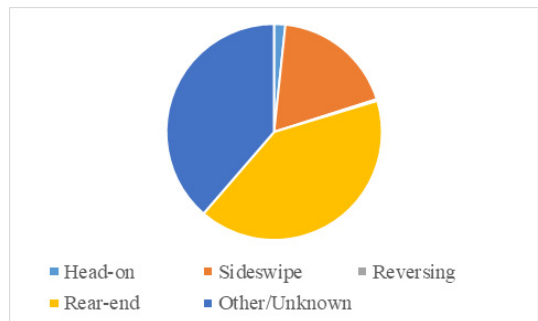
I. 서론

1. 연구 배경 및 목적

도로교통공단의 교통사고분석시스템(TAAS: Traffic Accident Analysis System)을 통해 최근 5년('14년~'18년) 동안 국내에서 발생한 차대차 교통사고 통계자료를 살펴보면(KoROAD, 2019), <Fig. 1>과 같이 차대차 교통사고 발생 건수가 지속적인 증가추세를 보이는 것을 확인할 수 있다. <Fig. 2>는 2018년도에 발생한 차대차 교통사고 발생 건수의 유형별 구성비를 나타낸다. 통계자료를 통해 후미추돌사고가 차대차 교통사고 발생빈도의 절반가량을 차지하는 것을 알 수 있다.



<Fig. 1> Annual motor vehicle accidents in South Korea (2014~2018)



<Fig. 2> Percentage of collision types in 2018

후미추돌사고를 야기하는 주된 원인은 안전거리 미확보 및 전방주시 태만 등 운전자 부주의로 보고된다(NHTSA, 2006). 이와 같은 후미추돌사고 위험을 획기적으로 경감시키기 위한 목적으로 차세대첨단교통시스템(C-ITS, Cooperative Intelligent Transportation System)의 우선 도입 서비스 항목 중 하나인 차량 충돌방지 지원 서비스가 고려되고 있다(ITSK, 2017). 해당 서비스는 하류부 통행 차량의 차량탑재장치(OBU, On-Board Unit)를 통해 V2V 또는 V2I2V 통신을 기반으로 기본안전메시지(BSM, Basic Safety Message) 브로드캐스팅하여 상류부 차량 운전자에게 충돌위험 알림·경고를 제공하여 사고위험에 즉각적으로 대응할 수 있도록 한다. 관련 서비스 성능검증 및 효과분석을 위해 서울, 제주, 광주, 울산을 대상지로 실증사업이 수행 중이며, 대전-세종지역에서는 시범사업을 시행 중이다. 그러나 현재 개발 진행 중인 대다수 서비스의 경우 돌발 발생 차량을 마주하는 선두 진입 차량의 첨단운전자보조시스템(ADAS, Advanced Driver Assistance System)에 의존해 돌발 감지 정보를 생성하기 때문에 ADAS의 성능이 해당 서비스 효과에 직접적인 영향을 미치고, 더 나아가 낮은 C-ITS 단말기 보급으로 인해 단기적으로 차량 충돌방지 지원 서비스에 의한 안전 효과를 기대하기 어려운 실정이다.

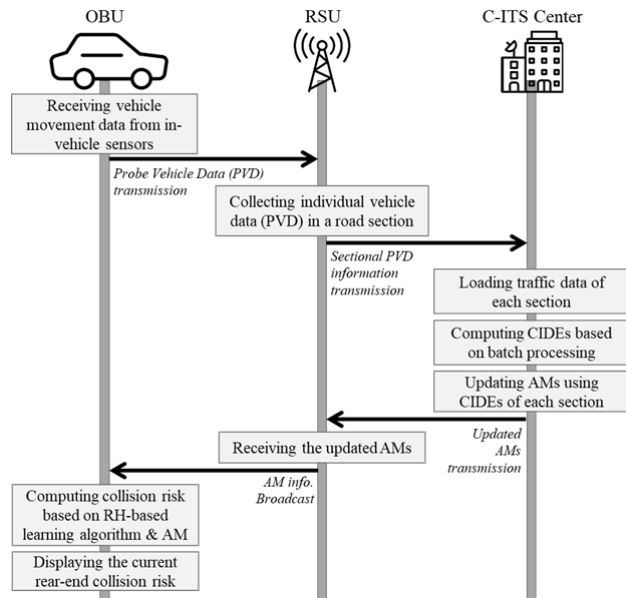
이를 고려해 국내·외 학계에서는 후미추돌위험 추정·예측 기법 고도화를 통해 ADAS의 성능 강화를 도모하여 운전자가 위험상황에 선제적으로 대응할 수 있도록 다양한 전방추돌경보시스템(FCWS, Forward Collision Warning System) 연구들을 수행해 왔다. 대표적인 사례로 인공지능기법 중 하나인 인공신경망(ANN, Artificial Neural Network)을 접목한 사례가 있다(Chang et al., 2010; Wei et al., 2011; Mon and Lin 2012; Kim et al., 2014). 그러나 종래의 연구들은 시공간적 교통 특성을 고려하지 않은 일반화된 학습정보를 바탕으로 운영되기 때문에 사고 등의 돌발 상황으로 인해 야기되는 새로운 교통상황에서의 충돌위험을 감지하는 데 한계가 있다. 이를

보완하기 위한 일환으로 일부 선행 연구들은 V2I2V 통신기반으로 실시간 구간교통 정보를 활용한 실시간 학습 알고리즘 개발을 통해 개별 주행차량의 후미추돌사고 위험도 식별 기능을 개선하여 적절한 시점¹⁾에 후미추돌위험 경고를 제공할 수 있는 방법론을 개발했다(Lee and Yeo 2015; Lee and Yeo 2016; Lee et al., 2017). 그러나 제안된 방법론들은 한정된 대역폭 아래 C-ITS 센터와 지속해서 통신을 유지해야 하고 C-ITS 센터에서는 대용량의 교통정보를 일제히 수신해야 함에 따라 필연적으로 지연시간이 발생하는 단점이 존재한다. 결과적으로 인공신경망의 가중치를 업데이트하는 데 이용되는 구간교통 정보량에 영향을 미치게 되어 후미추돌위험 경고 서비스 성능에 악영향을 끼친다. 따라서 본 연구에서는 가중치 업데이트에 영향을 미치는 지연시간과 C-ITS 단말기 보급률에 따른 서비스 성능 수준 식별하고 이를 개선하는 대체방안을 제시하여 보다 신뢰성 높은 인공신경망 기반의 후미추돌사고 위험 예측 알고리즘을 개발함으로써 운전자가 잠재적 추돌사고위험에 선제적으로 대응할 수 있도록 하는 지능화된 차량 추돌방지 지원 서비스를 제안하고자 한다.

II. 인공신경망 기반 차량 추돌방지 지원 서비스

1. 서비스 구성도

본 연구에서 제안하는 인공신경망 기반 차량 추돌방지 지원 서비스(ACWS, ANN-based Collision Warning Service)의 운영 주체는 차량 C-ITS 단말기(OBU, On-Board Unit), 노변기지국(RSU, RoadSide Unit) 및 C-ITS 센터로 구성된다.

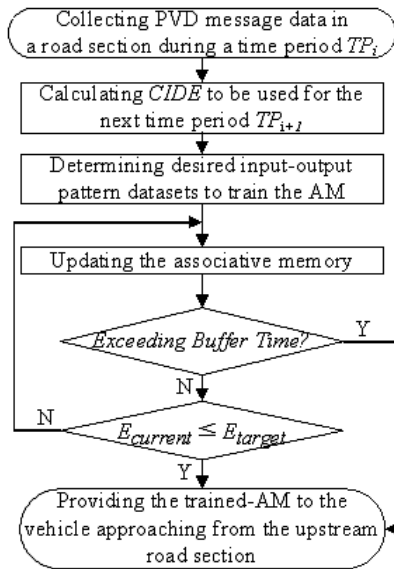


<Fig. 3> Operational flow of ACWS

1) (nuisance alarm) 가 (Seiler et al., 1998).
(missed alarm) (Abe and Richardson 2006; Jamson et al., 2008).

2) 실시간 구간 통행 정보 기반 학습 알고리즘

인공신경망을 활용한 시스템들의 성능에 기여 하는 중요 요소 중 하나로 초기 가중치를 고려할 수 있다. 초기 가중치는 인공신경망의 수렴속도에 결정적 역할을 하며 학습 정도에 따라서 인공신경망의 예측 성능에 영향을 미친다. 본 연구에서는 이 초기 가중치를 Associative Memory(AM)라 지칭한다(Lee et al., 2017). 잘 학습된 AM을 이용하기 위해서는 시공간적 교통특성을 반영한 실시간 교통정보가 필요하며, 실시간 구간 통행 특성을 반영하기 위한 AM의 학습 알고리즘은 <Fig. 5>과 같다.

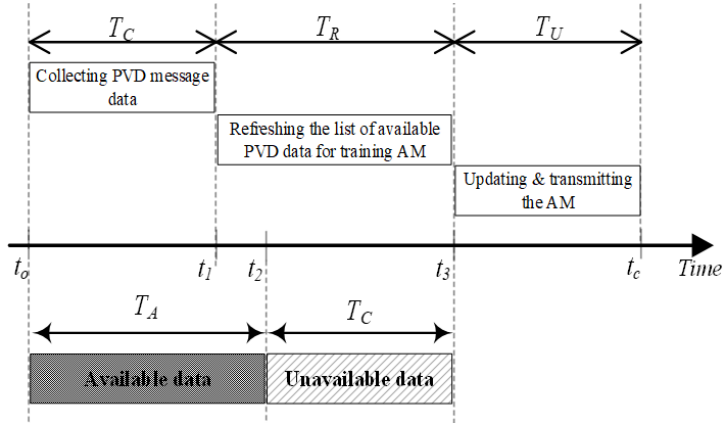


<Fig. 5> AM learning algorithm

특정 도로 구간의 배치주기(TP_i) 동안 수집된 PVD 메시지 데이터를 기반으로 차후 배치주기(TP_{i+1}) 동안 활용될 CIDE를 산출한다. 그 후 CIDE를 기반으로 AM 학습을 위한 입출력 패턴 데이터 세트를 구성하고 AM을 갱신(Updating)한다. 동시에 AM을 갱신하고 전송하는데 가용할 수 있는 최대 시간인 Buffer Time 초과 여부를 모니터링하고 Buffer Time을 초과할 경우 그 시점을 기준으로 학습이 완료된 AM을 특정 도로 구간에 진입하려고 하는 상류부 차량에게 제공하는 반면, Buffer Time을 초과하지 않는 경우 목표치 수렴 여부를 모니터링하여 AM을 지속해서 갱신하고 제공한다.

AM 학습 알고리즘 구현을 위한 교통정보 처리 흐름은 <Fig. 6>과 같이, 수집(Collecting), 새로 고침(Refreshing), 갱신 및 전송(Updating & Transmitting)하는 과정을 포함한다. 여기서, 수집은 통행 차량의 OBU로부터 전달받은 PVD 메시지 데이터를 도로 구간별로 취합하는 과정을 나타내고, 새로 고침은 구간별 통행 특성을 반영한 AM 학습을 위해 가용 PVD 데이터 목록을 재생성하는 과정을 의미하고, 갱신 및 전송은 AM 학습과 업데이트된 AM 정보를 구간별 OBU로 전달하는 과정을 지칭한다. 그러나 ACWS 특성상 한정된 대역폭 아래 C-ITS 센터와 RSU 간 지속적인 통신을 유지해야 하고, 특히 C-ITS 센터에서는 대용량의 교통정보를 일체히 수신해야 하므로 필연적으로 지연시간이 발생한다. 이 지연시간은 결과적으로 AM을 갱신할 때 가용 되는 교통 정보량에 영향을 미친다. 예를 들어 데이터 송수신 및 산출을 위한 배치 프로세스 주기가 $(t_c - t_b)$ 이고 갱신 및 전송에 요구되는 시간이 T_u 로 고정될 때 지연시간이 발생하지 않는다면, 지연시간 T_c

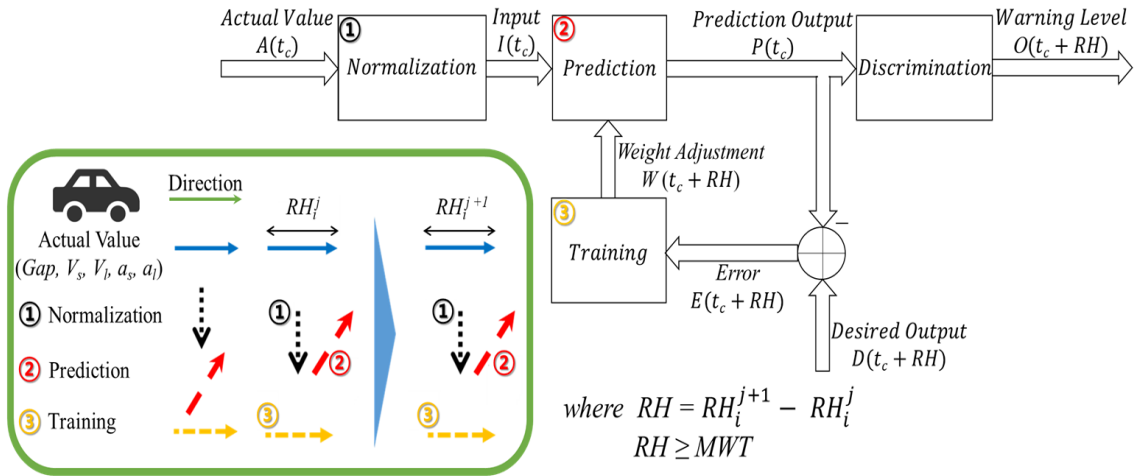
가 0이 되어 t_0 부터 t_3 동안 수집된 통행차량 주행정보를 활용해서 AM을 갱신할 수 있다. 반면에 지연시간 T_c 가 발생한다면 t_0 부터 t_2 동안 획득된 정보만을 가용할 수 있게 된다. 더 나아가 구간 통행 차량들의 OBU 장착 여부를 나타내는 보급률의 정도에 따라서 AM 갱신에 이용되는 학습 정보량에 영향을 미친다. 이에 따라 본 연구에서는 C-ITS 단말 보급률과 지연시간에 따른 ACWS의 성능 평가를 수행하고자 하며 구체적인 수치 연구(Numerical Study)는 IV. 성능 비교 결과 및 분석에서 다룬다.



<Fig. 6> Process of updating the AM in the ACWS

3) 차량 단말기 정보 및 구간 통행 정보 융합 기반 실시간 학습 방법

AM 학습 알고리즘을 통해 시공간적 교통 특성을 반영한 가중치 정보를 기반으로 구간 진입 차량은 차차 주행 상태별 추돌위험도를 산출하여 차량 내 내비게이션, HUD(Head-Up Display), 스마트폰 등 표출장치에 표출한다. 동시에 개별 차량 운전자의 주행행태에 최적화·개인화된 서비스를 제공하기 위한 목적으로 실시간 학습 알고리즘(Rolling Horizon(RH)-based Learning Algorithm)을 이용해 ACWS의 가중치 정보를 교정한다(Lee and Yeo, 2016). RH-based Learning Algorithm의 메커니즘은 <Fig. 7>과 같이 정규화(Normalization), 예측(Prediction), 판단(Discrimination), 학습(Training)으로 구분하여 나타낼 수 있다. 현재 시간이 t_c 라 할 때 ACWS의 물리적 입력값(Actual Value)으로 차간거리(Gap), 선행 차량의 속도(V_s, V_i) 및 가·감속도(a_s, a_i)를 포함한다. 정규화 기능은 개별 차량 단말기를 통해 추출된 입력변수들을 정규화하여 스케일링을 수행하고, 예측 기능은 정규화 기능을 통해 입수된 입력정보들과 초기 가중치로 활용될 AM 가중치 정보를 활용해 Δt 시간 이후의 후미추돌 경고 수준을 예측한다. 예측된 경고 수준을 기반으로 판단 기능을 통해 전방추돌 경고 제공 여부를 판단하여 표출한다. 이어서 Δt 시간 이후에 발생하는 주행정보를 기반으로 CIDE 유무를 판단해서 희망 출력(Desired Output)결과를 확인한다. 그 후 학습 기능을 통해 확인 결과와 이전에 예측한 결과 간의 오차를 기반으로 가중치 정보를 교정해 나간다. 여기서 사용된 Δt 를 Rolling Horizon(RH)이라 지칭한다. RH는 가중치 교정과 후미추돌 경고 수준을 예측하는 단위 주기 시간(Time Interval)을 나타낸다. <Fig. 7>에 나타난 것과 같이, i 번째 도로 구간의 j 번째 RH (RH_i^j)에서 획득되는 주행 정보를 바탕으로 정규화를 해서 입력 패턴 데이터를 생성하고, 생성된 데이터를 기반으로 예측한다. 이어서 $j-1$ 번째 RH에서 예측한 후미추돌 경고 수준과 현재 주행상황에서 CIDE 발생 여부를 고려해서 가중치를 교정한다. 이때 정확한 학습수행을 위한 필요조건으로 RH의 크기가 앞서 소개한 MWT 보다 크거나 같아야 한다. 그렇지 않을 경우 희망 출력결과를 알 수 없는 경우가 발생하기 때문에 교정해 나가는 것이 불가능하다.



<Fig. 7> Concept of operations for RH-based learning algorithm

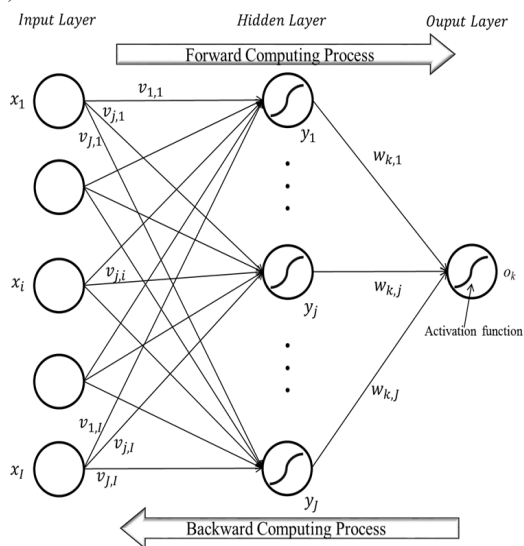
3. 인공신경망 활용 및 적용

본 연구에서 제안하는 ACWS에 적용되는 인공신경망(ANN, Artificial Neural Network) 모델은 특정 모델로 한정되지 않으나 그 적용 가능성과 이점 파악을 선제적으로 수행하기 위해서 지금까지도 널리 사용되고 있는 Feed-forward Neural Network와 Radial Basis Function Network(RBFN)를 채택했으며 해당 모델들의 구조를 <Fig. 8>과 같이 나타낼 수 있다. Fully Connected Network 유형의 Feed-forward Neural Network에 해당하는 모델로서 Multi-layer Perceptron Neural Network(MLPNN)를 선정했고 은닉층(Hidden Layer)의 개수에 따라 MLPNN with single hidden layer (MLPNN1)와 MLPNN with two hidden layers (MLPNN2)로 구분되며, 각각 MLPNN1-ACWS 및 MLPNN2-ACWS라 지칭한다. RBFN 기반의 ACWS는 RBFN-ACWS라 명명한다. ACWS에 적용되는 인공신경망 모델들의 입력층(Input Layer)에는 차간거리(Gap), 선행 차량의 속도(V_s, V_l) 및 가·감 속도(a_s, a_l)를 포함하여 5개의 변수를 입력층에 배치하고 출력층(Output Layer)은 단일 뉴런을 통해 후미추돌 위험을 예측해서 경고를 제공하도록 한다. 은닉층의 개수 선정의 경우 주어진 학습정보와 학습 알고리즘에 의거하여 최적 조합이 결정됨에 따라 IV. 성능 비교 결과 및 분석에서 구체적으로 다루고자 한다.

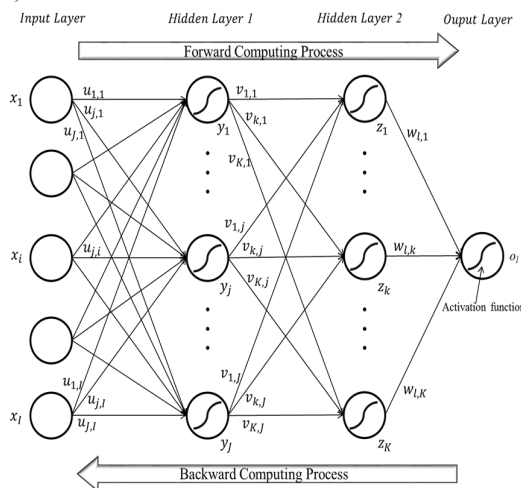
학습 알고리즘의 경우 일반적으로 Gradient Descent learning Rule을 기반으로 한 Steepest Learning Algorithm을 Momentum Method와 결합한 구조로 이용되는 Error Backpropagation 알고리즘이 MLPNN 학습에 활용이 되나, 수렴속도가 느린 단점이 있다(Wilamowski and Yu, 2010). 이를 보완하기 위해서 본 연구에서는 Feed-forward Neural Network 학습에 가장 효율적인 방법으로 알려진 Levenberg-Marquardt(LM) 방법을 이용한 Backpropagation 알고리즘을 적용한다(Hagan and Menhai, 1994). 해당 학습 방법은 Damping Parameter인 감쇠 상수(μ)를 이용해서 곡률계산 시 발산 가능성이 있는 Gauss-Newton 학습 방법의 단점을 보완했고 이에 따라 Error Backpropagation 알고리즘보다 빠르면서 Gauss-Newton 학습 방법보다 안정적인 효과를 나타낸다.

반면 RBFN의 경우 학습 속도 가속화를 위해 Extreme Learning Machine(ELM)을 활용한다(Huang and Siew, 2005). 해당 알고리즘은 Backpropagation 알고리즘을 기반으로 커널 함수(Kernel Function) 상의 중심(Center)과 폭(Width)을 순차적으로 학습하는 종래의 알고리즘들과 달리 선형최소자승 문제로 변환해서 근사해를 구하는 방식으로 가중치를 도출한다. 이에 따라 종래의 학습 알고리즘들과 비교했을 때 작게는 2배에서 크게는 1000배 이상 빠른 수렴속도를 보이는 특징을 나타낸다.

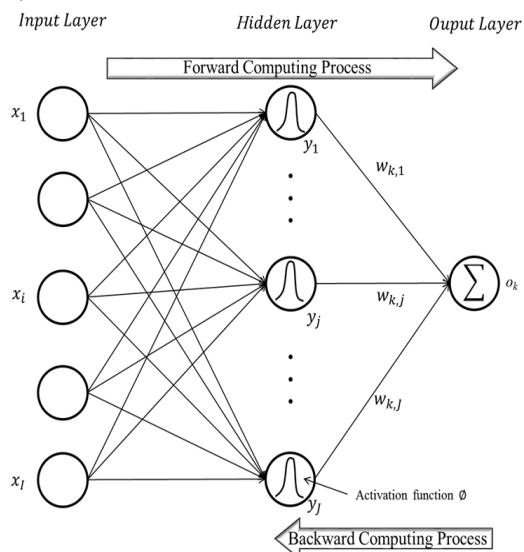
i) MLPNN1-ACWS



ii) MLPNN2-ACWS



iii) RBFN-ACWS



x_i = the general expression for the input value of the i^{th} input neuron

$w_{k,j}$ = the general expression for synaptic weight from j^{th} hidden neuron to the k^{th} output neuron

y_j = the general expression for the output signal of the j^{th} hidden neuron based on activation function

o_k = the general expression for the output signal of the k^{th} neuron at the output layer based on activation function

<Fig. 8> Topologies of ANN models used in the ACWS

1) MLPNN-ACWS: LM 기반 Backpropagation 알고리즘

$$w(t+1) = w(t) - [J_w^T(t) \cdot J_w(t) + \mu I]^{-1} \cdot J_w(t) e_{p,l}(t) \dots\dots\dots (1)$$

여기서,

$w(t)$ = t 번째 Epoch의 은닉층과 출력층 간의 가중치(Weight Matrix),

$J_w(t)$ = $w(t)$ 의 야코비안 행렬(Jacobian Matrix),

μ = 감쇠상수(Damping Parameter),

$e_{p,l}(t)$ = t 번째 Epoch의 학습 자료 p 번째 입출력 패턴 데이터에 대한 l 번째 뉴런의 에러(Training Error).

2) RBFN-ACWS: ELM 기반 학습

$$\| Y(c_j, \sigma_j, x_p) \hat{\beta} - T \| = \min_{\beta} \| Y(c_j, \sigma_j, x_p) \beta - T \|, \dots \dots \dots (2)$$

$$\text{where } j \in [1, J], p \in [1, P], \hat{\beta} = Y^\dagger T = (Y^T Y)^{-1} Y^T T \dots \dots \dots (3)$$

여기서,

$c_j = j$ 번째 은닉층 뉴런의 활성화 함수(Activation Function)인 Radial Basis Function의 중심(center),

$\sigma_j = j$ 번째 은닉층 뉴런의 활성화 함수인 Radial Basis Function의 중심(center),

$x_p = p$ 번째 입출력 패턴 데이터(Input-output pattern data),

$Y =$ 은닉층의 출력 행렬,

$\beta =$ 은닉층과 출력층 간의 가중치,

$T = x_p$ 별 목표값 행렬(Target Value Matrix),

$J =$ 은닉층 뉴런 수,

$P =$ 학습 자료 수(입출력 패턴 데이터 세트 수량),

$Y^\dagger = Y$ 의 무어 펜로즈 역행렬(Moore-Penrose Inverse).

$\hat{\beta} =$ 근사해 결과 가중치.

III. 성능 평가 방법

1. 사용 데이터

제안 서비스의 효과분석 및 평가를 위해 미국연방도로청에서 제공한 Next Generation SIMulation(NGSIM) 데이터를 사용한다. NGSIM 데이터는 캘리포니아 로스앤젤레스 US Highway 101 (US-101) 일부 구간의 대상지와 애머리빌 Interstate 80 (I-80) 일부 구간의 대상지에서 각각 오전, 오후 첨두 시간에 수집한 실제 교통상황 영상 자료를 기반으로 구간 통행 차량들의 움직임을 0.1초 단위로 추적하여 위치, 속도, 가속도, 차두거리 등 미시적 교통정보를 포함한다(Halkias and Colyar, 2006; Colyar and John, 2007). 그러나 원시데이터 상당 부분에 노이즈가 있는 관계로 본 연구에서는 이동평균필터(Moving Average Filter)를 이용해서 평활화한 데이터를 실제 교통상황으로 가정한다. 10분을 주기로 시간대별 통행 차량들에 대한 가·감속도 누적분포함수를 활용해 CIDE를 산출하여 위험 차량 추종 상황을 선별하여 사용하고 각각 대상지의 사례들은 <Table 1>과 <Table 2>와 같다.

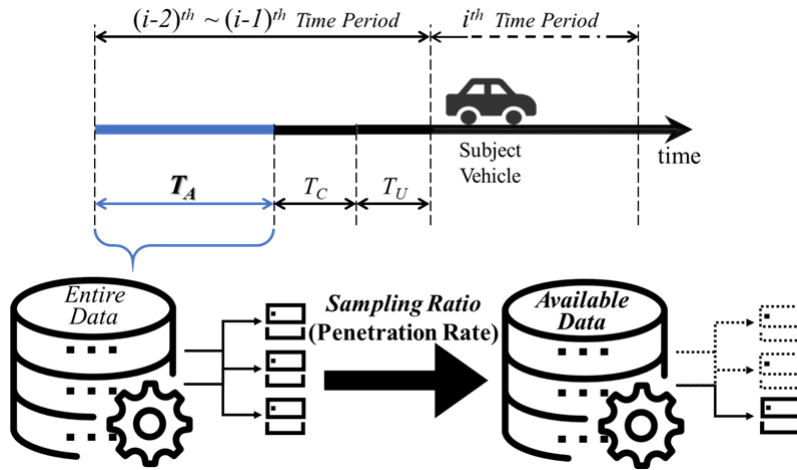
<Table 1> Study cases in the US-101 NGSIM data

| Time Period | 8:00~8:05 a.m. | 8:05~8:10 a.m. | 8:10~8:15 a.m. | 8:15~8:20 a.m. | 8:20~8:25 a.m. | 8:25~8:30 a.m. | 8:30~8:35 a.m. |
|-----------------|----------------|----------------|----------------|----------------|----------------|----------------|----------------|
| Number of Cases | 31 | 13 | 7 | 9 | 15 | 13 | 7 |

<Table 2> Study cases in the I-80 NGSIM data

| Time Period | 5:10~5:15 p.m. | 5:15~5:20 p.m. | 5:20~5:25 p.m. | 5:25~5:30 p.m. |
|-----------------|----------------|----------------|----------------|----------------|
| Number of Cases | 31 | 13 | 7 | 9 |

AM 학습 알고리즘에 가용할 수 있는 교통정보는 구간 통행차량들의 C-ITS 단말 보급률(Penetration Rate)에 영향을 받는다. 따라서 주어진 보급률 상황에 따라 변화하는 교통정보를 표현하기 위해 추출비(Sampling Ratio)를 정하여 무작위 추출(Random Sampling)을 수행하고 <Fig. 9>와 같이 나타낸다.



<Fig. 9> Representing available data in different penetration rates

2. 평가 방법


ACWS의 성능평가는 1.5초로 설정한 MWT를 기준으로 추돌경고 제공 시점의 정확도로 측정하며 이진 분류(Binary Classification)에 널리 활용되는 오차 행렬(Confusion Matrix)을 이용해 <Fig. 10>과 같이 분석을 수행한다.

<Confusion Matrix>

| | | Actual Class | |
|------------|----------|---------------------|---------------------|
| | | Positive | Negative |
| Prediction | Positive | True Positive (TP) | False Positive (FP) |
| | Negative | False Negative (FN) | True Negative (TN) |

Positive : need for collision warning in the current situation

Negative : no need for collision warning in the current situation



<Fig. 10> Method of performance measurement

오차 행렬 결과를 기반으로 정량적 수치 분석의 용이성 확보를 위해 이진 분류기 평가에 활용되는 AUC(Area Under the Receiver Operating Characteristic Curve) 값을 사용하고 AUC 값이 1에 가까워질수록 높은 성능을 나타낸다.

3. 파라미터 튜닝

공정한 성능 비교를 위해 ACWS에 적용되는 인공신경망 모델의 최적 네트워크 구조(Topology) 식별이 요구됨에 따라 유전 알고리즘(Genetic Algorithm)을 이용하며 변수 설정은 다음 <Table 3>과 같다.

<Table 3> Parameter setting for genetic algorithm

| | MLPNN1-ACWS | MLPNN2-ACWS | RBFN-ACWS |
|------------------|---------------|-------------|-----------|
| Population | | 1000 | |
| Generation | | 1000 | |
| Elitism | | 0.03 | |
| Crossover | | 0.8 | |
| Mutation | | 0.1 | |
| Hidden Neurons 1 | [10, 20] | [10, 20] | [10, 100] |
| Hidden Neurons 2 | | [10, 20] | |
| Fitness Function | Max AUC Value | | |

유전 알고리즘 결과를 통해 도출된 결과는 <Table 4>와 같으며 US-101의 경우 MLPNN1-ACWS는 15개, MLPNN2-ACWS는 13, 12개, RBFN-ACWS는 84개의 Hidden Neuron을 포함한다. I-80의 경우 MLPNN1-ACWS는 13개, MLPNN2-ACWS는 15, 16개, RBFN-ACWS는 77개의 Hidden Neuron을 포함할 때 최적의 성능을 보임에 따라 해당 결과를 토대로 성능 분석을 수행한다.

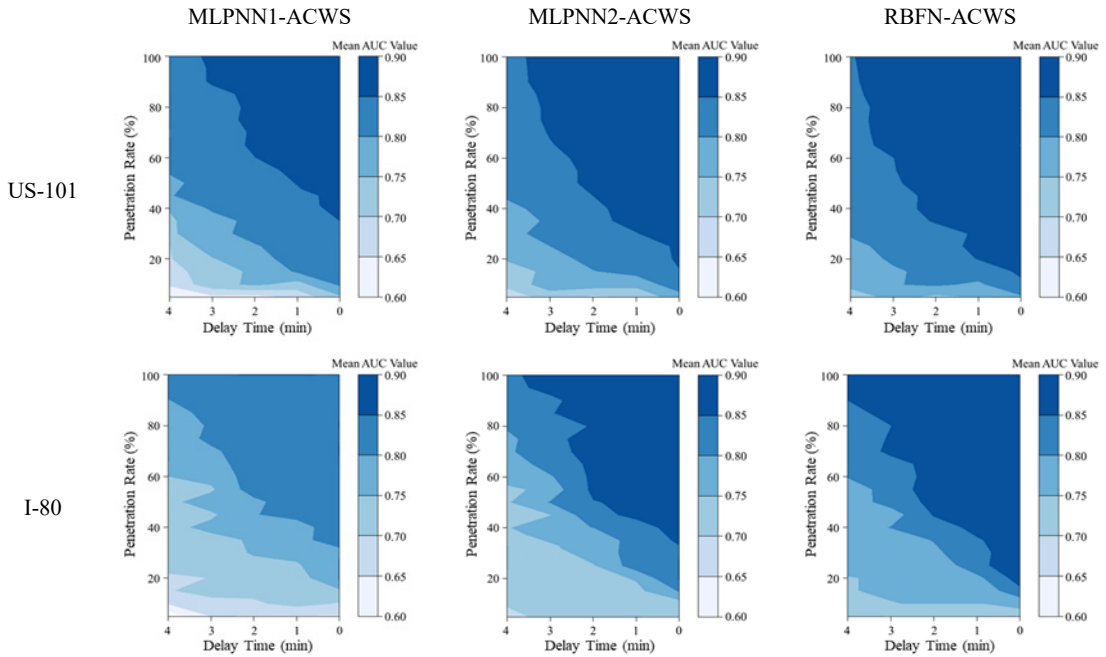
<Table 4> Optimal topologies of each ACWS

| | US-101 | I-80 |
|-------------|-----------|-----------|
| MLPNN1-ACWS | 5-15-1 | 5-13-1 |
| MLPNN2-ACWS | 5-13-12-1 | 5-15-16-1 |
| RBFN-ACWS | 5-84-1 | 5-77-1 |

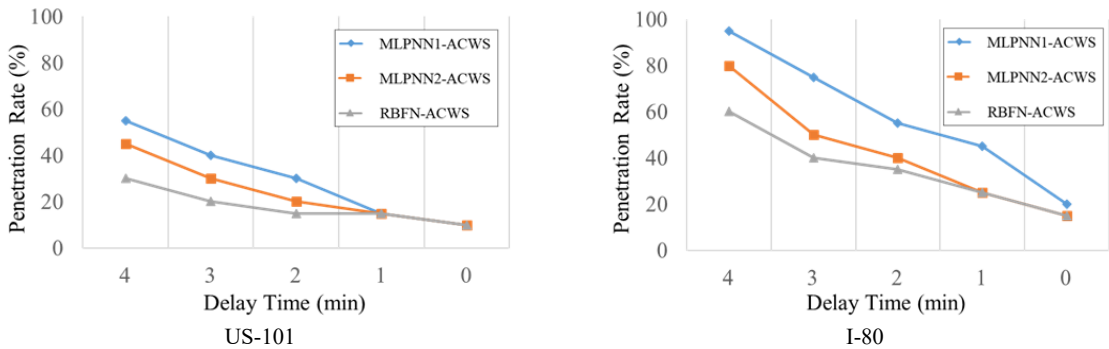
IV. 성능 비교 결과 및 분석

1. 성능 비교 검토

다양한 환경 아래 제안 서비스의 성능 수준을 파악하기 위해 통신환경과 C-ITS 단말 보급률 변화에 따른 ACWS의 성능 분석을 수행한다. <Fig. 11>는 지연시간(Delay Time)과 단말 보급률(Penetration Rate) 변화 별 평균 AUC 값의 등고선도(Contour Plot)를 나타낸다. US-101 대상지의 결과를 살펴보면 각 ACWS는 전반적으로 지연시간이 감소함에 따라 AUC 값의 크기가 증가하는 것을 알 수 있고 단말 보급률이 증가할수록 AUC 값이 커지는 경향을 발견할 수 있다. 같은 방법으로 I-80 대상지의 결과를 보면 알 수 있듯이 통신 지연시간이 짧아지고 구간 통행 차량들의 C-ITS 단말 이용률이 증가할 때 ACWS의 성능이 향상되는 것을 확인할 수 있다. 더 나아가 동일한 지연시간과 보급률을 나타낼 때 RBFN-ACWS, MLPNN2-ACWS, MLPNN1-ACWS 순으로 더 큰 AUC 값을 보인다.



<Fig. 11> Contour plots of mean AUC values in Delay Time–Penetration Rate plane



<Fig. 12> Performance comparison in boundary condition (mean AUC \geq 0.8)

이러한 배경 아래 각 ACWS 별로 목표 성능치를 만족하는 운영환경 조건을 조사했다. <Fig. 12>은 평균 AUC 값이 0.8보다 크거나 같은 상태를 만족하는 지연시간과 단말 보급률에 대한 경계부 조건(Boundary Condition)을 나타낸다. 좌측에 위치한 US-101 대상지를 살펴보면 보급률이 15%일 때 모든 ACWS들은 지연 시간이 1분보다 작거나 같은 상태이면 목표 성능을 만족한다. 그러나 지연시간이 2분으로 증가했을 때 MLPNN1-ACWS의 경우 30%에 달하는 단말 보급률을 필요로 하는 반면에 MLPNN2-ACWS나 RBFN-ACWS는 각각 20%와 15%의 단말 보급률만으로도 목표 성능을 달성할 수 있다. 동일한 방법으로 I-80 대상지 결과를 살펴보면 통신지연이 없을 때 MLPNN2-ACWS나 RBFN-ACWS는 15%에 해당하는 단말 보급률이 있어야 목표 성능을 만족하는 반면 MLPNN1-ACWS는 20%에 달하는 단말 보급률을 요구한다. 이러한 경향성은 지연시간이 증가할수록 입증하는 것을 확인할 수 있다.


2. 성능 차이 분석

주어진 운영환경 조건 아래 제안 서비스의 성능 수준이 ACWS에 적용되는 인공신경망 모델에 따라 상이한 것을 발견할 수 있었다. 이에 따라 고도화된 인공신경망 모델 적용이 서비스 성능개선에 얼마나 기여하는지 살펴보기 위해서 성능 차이 분석(Performance Gap Analysis)을 수행한다. 성능 차이 분석 수행을 위한 측정 도구로 Performance Improvement Ratio(PIR)를 활용하며 다음과 같이 구분하여 표현한다.

$$PIR1 = \left(\frac{AUC\ of\ MLPNN2 - ACWS}{AUC\ of\ MLPNN1 - ACWS} \right) \times 100\ (\%) \dots\dots\dots (4)$$

$$PIR2 = \left(\frac{AUC\ of\ RBFN - ACWS}{AUC\ of\ MLPNN1 - ACWS} \right) \times 100\ (\%) \dots\dots\dots (5)$$

식(4)와 (5)에 나타난 것과 같이 PIR1은 MLPNN1-ACWS 대비 MLPNN2-ACWS의 성능 개선도를 의미하고, PIR2는 MLPNN1-ACWS 대비 RBFN-ACWS의 성능 개선도를 나타낸다.




<Fig. 13> Example of performance gap analysis using PIR (Penetration Rate = 10% without Delay Time in the US-101 site)

해당 지수들을 기반으로 <Fig. 13>과 같은 분석을 수행한다. <Fig. 13>은 단말 보급률이 10%이고 지연시간이 없는 상황에서 US-101 대상지에 ACWS를 운영했을 때 발생한 PIR의 히스토그램(Histogram)과 누적분포함수(Cumulative Distribution Function)를 나타낸다. 결과를 통해 알 수 있듯이 주어진 운영환경 속에서 모든 사례가 0 이상의 PIR 값을 나타냄에 따라 MLPNN2-ACWS와 RBFN-ACWS가 MLPNN1-ACWS에 비해 좋은 성능을 보이는 것을 확인할 수 있다. 더불어 PIR1 대비 PIR2의 값이 과반수 이상 큰 양상을 보임에 따라서 더 나은 서비스 성능 개선을 RBFN-ACWS를 통해 얻을 수 있을 것으로 사료된다.

각 운영환경 조건에 따른 MLPNN2-ACWS와 RBFN-ACWS간 명확한 성능 차이를 살펴보기 위해 PIR2와 PIR1의 누적분포함수 간 면적의 차이(Performance Gap)를 <Fig. 14>와 같이 도출했다. 결과를 살펴보면 대상지 특성과 관계없이 운영환경이 같은 조건일 경우 고도화된 인공신경망 모델을 적용한 ACWS 성능이 더 뛰

어난 것으로 확인된다. 또한, 단말 보급률이 감소하고 지연시간이 증가할수록 Performance Gap이 증가하는 경향을 발견할 수 있다. 이는 운영환경이 악조건일수록 RBFN-ACWS가 MLPNN2-ACWS에 비해 더 나은 성능 개선을 보이는 것으로 해석된다. 따라서 악조건일수록 고도화된 인공신경망 모델을 제안 서비스에 적용하게 되면 보다 나은 성능 향상을 기대할 수 있을 것으로 판단된다.



<Fig. 14> Performance gap in various parameter combinations of penetration rate and delay time

V. 결론 및 향후 연구

본 연구에서는 인공신경망을 활용한 V2I2V 통신 기반 차량 추돌방지 지원 서비스 개발을 위한 목적으로 ACWS(Artificial Neural Network-based Collision Warning Service)를 제안했다. 제안 서비스는 실시간 구간 통행 정보 기반 학습 알고리즘(Associative Memory Learning Algorithm)을 통해 시공간적 교통 특성을 반영해 인공신경망의 가중치를 갱신한다. 더 나아가 차량 단말기 정보 및 구간 통행 정보 융합 기반 실시간 학습 방법(Rolling Horizon-based Learning Algorithm)을 적용해 개인화된 추돌방지 지원 서비스를 제공한다. ACWS의 적용 가능성과 이점 파악을 선제적으로 수행하기 위해서 인공신경망의 대표적인 모델인 Multi-layer Perceptron Neural Network(MLPNN)과 선진화 모델인 Radial Basis Function Network(RBFN)을 적용하여 효과분석을 수행했다. 효과분석을 위한 지표로 이진분류기 평가에 활용되는 AUC(Area Under the Receiver Operating Characteristic Curve) 값을 이용했고, 서로 다른 대상지의 적용 결과를 검토하기 위해 실제 발생한 교통상황 정보를 나타내는 미시적 교통데이터인 NGSIM(Next Generation SIMulation) 데이터를 사용했다. 또한, 다양한 C-ITS 운영환경 속의 개발 서비스 성능 분석을 위해 지연시간(Delay Time)과 C-ITS 단말 보급률(Penetration Rate)을 고려했다. 분석결과 제안 서비스는 지연시간이 감소하고 C-ITS 단말 보급률이 증가할수록 더 나은 성능을 보였다. 더불어 동일한 운영환경 조건 아래 고도화된 인공신경망 모델을 적용한 ACWS의 성능이 더 뛰어난 것을 발견했다. 더 나아가 C-ITS 단말 보급률이 감소하고 지연시간이 증가하는 악조건일수록 제안 서비스에 선진 모델을 적용하게 되면 보다 나은 성능 향상을 기대할 수 있다.

본 연구를 통해 C-ITS 서비스 개선을 위한 인공신경망 활용방안과 이를 기반으로 한 서비스를 개발했다. 그러나 여전히 한계점도 존재한다. 제안 서비스는 종래에 사용되어 왔던 차량 추돌방지 지원 알고리즘들에 해당되는 TTC(Time-to-Collision) 등과 같은 Perceptual Approach와 Berkeley 알고리즘 등과 같은 Stopping Distance-based Approach들과의 성능 평가를 통해 그 우수성을 확인할 필요가 있으므로 추후 연구에서는 관련

내용에 대한 연구를 수행하고자 한다. 이 밖에도 본 연구에서는 C-ITS 통신환경과 관련해서 지연시간만을 고려했다. 향후 연구에서는 패킷 전달률, 처리량, 대역폭 등에 의한 환경요소를 추가 고려할 필요가 있다. 또한, 탄력적 운영이 가능하도록 가변성 갱신주기를 고려한 실시간 구간 통행 정보 기반 학습 알고리즘 연구를 수행하고자 한다. 마지막으로 다양한 인공신경망 모델을 고려해서 제안 서비스의 성능개선이 필요할 것으로 판단된다.

ACKNOWLEDGEMENTS

본 연구는 국토교통부 교통물류연구사업의 연구비지원(19TLRP-B146733-02)에 의해 수행되었습니다.

REFERENCES

- Abe G. and Richardson J.(2006), "Alarm Timing, trust and Driver Expectation for Forward Collision Warning Systems," *Applied Ergonomics*, vol. 37, no. 5, pp.577-586.
- Chang B., Tsai H. and Young C.(2010), "Intelligent Data Fusion System for Predicting Vehicle Collision warning Using Vision/Sensing," *Expert Systems with Applications*, vol. 37, no. 3, pp.2493-2450.
- Colyar J. and John H.(2007), *US Highway 101 Dataset*, FHWA-HRT-07-030, 2007.
- Dingus T. A., Klauer S. G., Neale V. L., Petersen A., Lee S. E., Sudweeks J., Perez M. A., Hankey J., Ramsey D., Gupta S., Bucher C., Doerzaph Z. R., Jermeland J. and Knipling R. R.(2006), *The 100-Car Naturalistic Driving Study. Phase 2: Results of the 100-Car Field Experiment*, National Highway Traffic Safety Administration.
- Hagan M. T. and Menhai M. B.(1994), "Training Feedforward Networks with the Marquardt Algorithm," *IEEE Transactions on Neural Networks*, vol. 5, no. 6, pp.989-993.
- Halkias J. and Colyar J.(2006), *NGSIM Interstate 80 Freeway Dataset*, FHWA-HRT-06-137, 2006.
- Huang G. B. and Siew C. K.(2005), "Extreme Learning Machine with Randomly Assigned RBF Kernels," *International Journal of Information Technology*, vol. 11, no. 1, pp.16-24.
- Intelligent Transport Society of Korea(2017), *Standard of C-ITS Service Specification Part 1. Function and Performance Requirement Specification*.
- Jamson A. H., Lai F. C. and Carsten O. M.(2008), "Potential Benefits of An Adaptive Forward Collision Warning System," *Transportation Research Part C: Emerging Technologies*, vol. 16, no. 4, pp.471-484.
- Kim B., Choi B., An J., Hwang J. and Kim E.(2014), "Novel Collision Warning System Using Neural Networks," *Journal of Korean Institute of Intelligent Systems*, vol. 24, no. 4, pp.392-397.
- Klauer S. G., Dingus T. A., Neale V. L., Sudweeks J. D. and Ramsey D. J.(2006), *The Impact of Driver Inattention on Near-Crash/Crash Risk: An Analysis using the 100-car Naturalistic Driving Study Data*, Virginia Tech Transportation Institute.
- Kusano K. D. and Gabler H. C.(2012), "Safety Benefits of Forward Collision Warning, Brake Assist,

- and Autonomous Braking Systems in Rear-End Collisions,” *IEEE Transactions on Intelligent Transportation Systems*, vol. 13, no. 4, pp.1546-1555.
- Lee D. and Yeo H.(2015), “A Study on the Rear-End Collision Warning System by Considering Different Perception-Reaction Time Using Multi-Layer Perceptron Neural Network,” in *Proc. 2015 IEEE Intelligent Vehicles Symposium (IV)*, pp.24-30.
- Lee D. and Yeo H.(2016), “Real-Time Rear-End Collision-Warning System Using a Multilayer Perceptron Neural Network,” *IEEE Transactions on Intelligent Transportation Systems*, vol. 17, no. 11, pp.3087-3097.
- Lee D., Tak S., Park S. and Yeo H.(2017), “Real-Time Associative Memory -Based Rear-EndCollision Warning System,” *Transportation Research Record: Journal of the Transportation Research Board*, vol. 2621, no. 1, pp.1-9.
- Lee K. and Peng H.(2005), “Evaluation of Automotive Forward Collision Warning and Collision Avoidance Algorithms,” *Vehicle System Dynamics*, vol. 43, no. 10, pp.735-751.
- Mon Y. J. and Lin C. M.(2012), “Supervisory Recurrent Fuzzy Neural Network Control for Vehicle Collision Avoidance System Design,” *Neural Computing and Applications*, vol. 21, no. 8, pp.2163-2169.
- National Highway Traffic Safety Administration(2006), *The Impact of Driver Inattention on Near-Crash/Crash Risk: An Analysis Using the 100-Car Naturalistic Driving Study Data*.
- NYGÅRD, M.(1999), *A Method for Analysing Traffic Safety with Help of Speed Profiles*, Tampere University of Technology, Department of Civil Engineering.
- Road Traffic Authority (KoROAD),
http://taas.koroad.or.kr/sta/acs/exs/typical.do?menuId=WEB_KMP_OVT_UAS_PDS, 2019.08.19.
- Seiler P., Song B. and Hedrick J. K.(1998), “Development of a Collision Avoidance System,” *SAE Transactions*, pp.1334-1340.
- Smith D., Najm W. and Glassco R.(2002), “Feasibility of Driver Judgment as Basis for a Crash Avoidance Database,” *Transportation Research Record: Journal of the Transportation Research Board*, vol. 1784, no. 1, pp.9-16.
- Wada T., Doi S., Tsuru N., Isaji K. and Kaneko H.(2010), “Characterization of Expert Drivers’ Last-Second Braking and its Application to a Collision Avoidance System,” *IEEE Transactions on Intelligent Transportation Systems*, vol. 11, no. 2, pp.413-422.
- Wei Z., Xiang S., Xuan D. and Xu L.(2011), “An Adaptive Vehicle Rear-End Collision Warning Algorithm Based on Neural Network,” in *Proc. the International Conference on Information and management Engineering*, Berlin, pp.305-314.
- Wilamowski B. M. and Yu H.(2010), “Improved Computation for Levenberg-Marquardt Training,” *IEEE Transactions on Neural Networks*, vol. 21, no. 6, pp.930-937.