

RSU 통신 및 딥러닝 기반 최적화 차량 라우팅 시스템 설계

손수락*, 이병관*, 심손권**, 정이나***

A design of Optimized Vehicle Routing System(OVRS) based on RSU communication and deep learning

Su-Rak Son*, Byung-Kwan Lee*, Son-Kweon Sim**, Yi-Na Jeong***

요약 현재 자율주행 차량 시장은 3레벨 자율주행 차량의 상용화를 넘어 4레벨 자율주행 차량을 연구, 개발하고 있다. 4레벨 자율주행 차량에서 가장 주목되는 부분은 차량의 안정성이다. 3레벨과 다르게 4레벨의 자율주행 차량은 긴급상황을 차량이 직접 대처해야 하기 때문이다. 본 논문에서는 긴급상황에서의 즉각적인 반응보다는 차량의 목적지가 정해진 순간 사고 가능성이 가장 낮은 경로를 결정하는 Optimized Vehicle Routing System (OVRS)을 제안한다. OVRS는 RSU 통신으로 수집한 도로와 주변 차량 정보를 분석하여 도로의 위험성을 예측하여 주행 중인 차량이 더 안전하고 빠른 길로 주행할 수 있도록 경로를 설정한다. OVRS는 네트워크 라우팅 방식처럼 도로에 있는 RSU를 통하여 도로 상황에 따른 경로 안내를 실행하기 때문에 차량의 안정성을 더욱 높일 수 있다. 실험 결과, OVRS모듈 중 하나인 ASICM의 RPNN은 CNN보다 약 17%, LSTM보다 약 40% 더 좋은 연산 시간을 보였다. 그러나 해당 연구가 PC를 이용한 가상 환경에서 실행되었기 때문에, VPDM의 사고 가능성을 실제로 검증하지 못했다. 따라서 향후 사고 데이터 수집으로 인한 VPDM의 정확도 높은 실험과 실제 차량 및 RSU에서 실제 도로를 대상으로 한 실험이 진행되어야 한다.

Abstract Currently, The autonomous vehicle market is researching and developing four-level autonomous vehicles beyond the commercialization of three-level autonomous vehicles. Because unlike the level 3, the level 4 autonomous vehicle has to deal with an emergency directly, the most important aspect of a four-level autonomous vehicle is its stability. In this paper, we propose an Optimized Vehicle Routing System (OVRS) that determines the route with the lowest probability of an accident at the destination of the vehicle rather than an immediate response in an emergency. The OVRS analyzes road and surrounding vehicle information collected by The RSU communication to predict road hazards, and sets the route for the safer and faster road. The OVRS can improve the stability of the vehicle by executing the route guidance according to the road situation through the RSU on the road like the network routing method. As a result, the RPNN of the ASICM, one of the OVRS modules, was about 17% better than the CNN and 40% better than the LSTM. However, because the study was conducted in a virtual environment using a PC, the possibility of accident of the VPDM was not actually verified. Therefore, in the future, experiments with high accuracy on VPDM due to the collection of accident data and actual roads should be conducted in real vehicles and RSUs.

Key Words : Autonomous vehicles, driving directions, deep neural networks, road side units, road information

This Paper was supported by the National Research Foundation of Korea (NRF) grant funded by the Korea government (MSIT) (No. NRF-2018R1A2B6007710)

*Department of Software Engineering, Catholic kwandong University

**Department of Geography Education, Catholic kwandong University

***Corresponding Author : Department of Software Engineering, Catholic kwandong University (lupinus07@nate.com)

Received February 23, 2020

Revised April 09, 2020

Accepted April 09, 2020

1. 서론

차량이 주변 환경을 인식하고 동시에 차량의 주행을 제어하지만, 긴급상황같이 자율주행 모드 해제가 예상될 경우 언제든지 운전권을 운전자에게 이양해야 하는 3레벨 자율주행 차량은 곧 상용화 되고, 긴급상황을 스스로 대처하는 4레벨 자율주행 차량은 아직 연구되고 있다. 4레벨 자율주행 차량 연구의 가장 중요한 부분은 안전성이다. 차량의 안정성을 높이기 위해서 기존 연구는 차량 내부를 진단[1]하거나 주행 중 실시간으로 도로의 사고 가능성을 예측하거나 [2], 제한된 조건에서 보행자의 급격한 움직임을 피한다 [3]. 본 논문에서는 긴급상황에서의 즉각적인 반응보다는 차량의 목적지가 정해진 순간 사고 가능성이 가장 낮은 경로를 결정하는 Optimized Vehicle Routing System (OVRs)을 제안한다. OVRs는 RSU(Road Side Unit) 통신으로 수집한 도로와 주변 차량 정보를 분석하여 도로의 위험성을 예측하여 주행 중인 차량이 더 안전하고 빠른 길로 주행할 수 있도록 경로를 설정한다. OVRs는 네트워크 라우팅 방식처럼 도로에 있는 RSU를 통하여 도로 상황에 따른 경로 안내를 실행하기 때문에 차량의 안정성을 더욱 높일 수 있다. 본 논문의 2절은 해당 연구가 직, 간접적으로 영향을 받은 4레벨 자율주행 차량에 대한 연구들을 소개하고, 3절은 본 논문에서 제안하는 RSU 통신 및 딥러닝 기반 최적화 차량 라우팅 시스템에 대해 상세히 기술한다. 4절은 탑승객 탐지 및 공유 시스템의 유효성을 검증하기 위한 실험을 진행하고 5절에서는 해당 논문을 전체적으로 정리하고 향후 연구에 대해 설명한다.

2. 관련 연구

경북대학교에서는 WAVE 표준 기반의 상용 차량 통신 시스템을 이용하여 V2V(Vehicle-to-vehicle) 시나리오에서 발생할 수 있는 다양한 환경에 대한 전파 특성 분석을 진행하였다. 해당 연구에서 실측한 데이터 분석을 통하여 전반적인 차량 통신 시스템의 송수신 성능과 더불어 주행-정지 상태 교차, 차량에 의한 NLOS(Non-Line-of-Sight), 터널 주행 등 특정한 시나리오에서도 시스템 레벨의 전파 특성을 확인하였다 [4].

공주대학교에서는 데이터 전달에 참여하는 RSU의

수와 연속적인 데이터의 전달에 따른 RSU들의 에너지의 변화 양상을 확인할 방법을 제시하며 이를 실제 분석하였다. 수치적 분석의 결과로 확률 기반의 데이터 전달 방법은 기존의 방법에 비하여 상대적으로 적은 수의 RSU가 데이터 전달에 참여하며 이에 따라 모든 RSU의 평균 에너지 크기가 증가함이 확인되었다. 그리고 이러한 분석 결과를 바탕으로 유사 시스템의 실제 구현 시 고려해야 할 사항을 제시하였다 [5].

강원도립대학교에서는 도심 환경에서 통신두절 예방을 위한 RRPS(Priority Scheduling and Multi Path Routing Protocol)를 제안한다. RRPS는 밀집도에 따라 통신의 두절이 빈번하게 일어나는 도심 환경의 V2I 및 V2V 통신두절을 최소화하기 위하여, RSU의 관리 영역인 Start Line, End Line을 이용하여 End Line에 도달하기 전에 요청 메시지에 대한 우선순위를 적용하여 우선순위가 제일 높은 요청데이터를 먼저 처리할 수 있도록 하는 RRPS(RSU Request Priority Scheduling)알고리즘을 설계를 제안한다. 결과적으로 해당 연구에서 제안하는 RRPS는 RSU내에 정보를 요청한 차량의 메시지에 대하여 우선순위 스케줄링을 적용하여 V2I의 처리효율을 향상하고, 통신 두절을 예방하여 전송 성공확률을 향상하는 효과가 있다 [6].

이화여자대학교에서는 RSU와 OBU(On-Board Unit)로 구성된 V2I(Vehicle-to-Infrastructure) 환경에서 교통 데이터를 이용하여 SNC(systematic network coding) 기반 고신뢰도 데이터 전송 시스템을 제안했다. RSU에서 빠르게 이동하는 OBU로 데이터를 전송할 경우 RSU에서 데이터를 전달할 수 있는 시간은 OBU의 속도에 의하여 결정되기 때문에, 데이터의 최대 정보량은 시간에 따라 변하는 차량의 속도에 결정되는 특징이 있다. 따라서, 해당 연구에서는 OBU의 속도에 맞추어 최대의 정보량으로 전송하면서 데이터 디코딩 어려움을 감소시키기 위하여 회귀 분석 모델을 이용한 SNC 시스템을 제안하였고 실제로 수집된 교통 데이터를 이용하여 성능을 확인하였다 [7].

공주대학교에서는 각 RSU는 자신의 잔여 에너지값에 따라 통신 영역의 크기를 결정하도록 하며, 상대적으로 큰 전송 반경을 가지는 최소의 RSU를 데이터 전달 과정에 우선적으로 참여하도록 하여 데이터 전달 전송

지연값을 최대한 만족시키는 개선된 데이터 전달 방법을 제안했다. 결과적으로 통신 환경이 작은 RSU들은 데이터 전달 과정에서 배제되어 에너지 소비를 막을 수 있었다. 수치적 분석을 통하여 기존의 방법에 비하여 제안하는 방법은 요구하는 데이터 전달 지연값과 RSU의 에너지 소비 측면에서 더욱 효과적임을 확인하였다 [8].

한국 ITS학회에서는 V2I 통신환경 하에서 수집되는 개별 차량 정보를 활용하여 연동교차로의 교통상황에 대응할 수 있는 실시간 교통신호 제어 알고리즘을 개발하였다. 본 연구에서 개발된 알고리즘은 매 초 간격으로 V2I 통신환경에서 수집되는 차량 정보를 가공 처리하여 연동교차로 교통신호 제어에 필요한 현시 그룹 길이, 현시 길이, 현시 순서 등을 결정할 수 있다. 개발된 연동교차로 교통신호 제어 알고리즘의 효과 평가를 위해 미시 교통시뮬레이션 모형인VISSIM을 이용하였다. 다양한 교통조건 하에서 기존 정주기식 연동 교통신호 제어 방식과 개발된 알고리즘의 성능을 비교한 결과, 개발된 알고리즘의 성능이 우수한 것으로 확인되었다 [9].

충북대학교에서는 다수 RSU들을 유선망으로 연결하고 RSU들 사이의 협업을 통해 데이터를 전송하는 새로운 스케줄링 기법을 제안했다. 제안된 기법은 다중 RSU 협업전략을 통해 안전데이터와 비 안전데이터를 효율적인 전송하며 데드라인 실패율 및 평균 응답시간을 감소시킨다. 안전데이터가 발생할 때, 이전 RSU에서 데이터를 미리 전송하고 데드라인 수신율을 고려하여 우선순위를 부여한다. 비 안전데이터는 사용자의 요청에 따라 처리되는 요구기반 데이터이기 때문에 RSU에서 부하가 발생하면 데드라인 실패율이 방지하기 위한 기법을 제공한다 [10].

3. Overview

본 논문에서 제안하는 Optimized Vehicle Routing System(OVRS)은 RSU 통신으로 수집한 도로와 주변 차량 정보를 분석하여 도로의 위험성을 예측하여 주행 중인 차량이 더 안전하고 빠른 길로 주행할 수 있도록 경로를 설정한다. 그림 1은 OVRS의 전체적인 구성을 나타낸다.

Ambient Situation Information Collection

Module은 교통관제 센터로부터 현재 도로의 기울기, 포장 상태, 주변 RSU의 정보 등을 전달받고, 기상청으로부터 현재 위치의 날씨 정보를 전달받는다. 또한, Wi-Fi나 WAVE 통신을 이용하여 주변 차량으로부터 차량의 상태를 전달받는다.

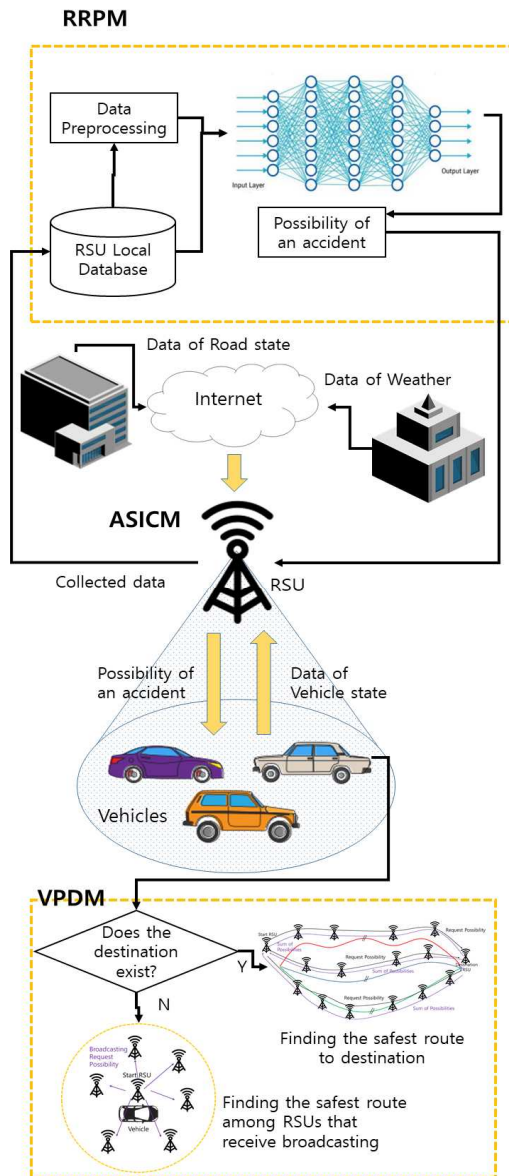


그림 1. OVRS의 구성도
Fig. 1. A Diagram of OVRS

Road Risk Prediction Module은 Ambient Situation Information Collection Module에서 수집한 정보와 딥 러닝 신경망 모델을 사용하여 현재 도로의 사고 가능성을 예측한다. 예측한 도로의 사고 가능성은 현재 RSU와 통신하고 있는 차량들에게 전송된다. 차량은 RSU의 분석 결과를 전송받고 차량 경로 설정에 사용할 수 있다. Vehicle Path Determination Module은 차량이 설정된 목적지가 존재하는지에 따라 통신할 RSU를 결정하고 RRP의 결과를 RSU에게 전송받아 최적의 경로를 결정한다.

3.1 Ambient Situation Information Collection Module 설계

Ambient Situation Information Collection Module (ASICM)은 RSU에서 동작하며, Wi-Fi 통신과 WAVE 통신을 기반으로 도로 정보와 도로 주변의 차량 데이터를 수집한다. ASICM에서 전달받는 정보는 크게 도로 내 차량 정보, 기상청의 현재 지역 날씨 정보, 교통관제 센터의 도로 정보 및 인접 RSU의 정보로 나눌 수 있다.

3.1.1. 도로 내 주변 차량 정보 수집

ASICM는 차량으로부터 현재 속도, 주변 차량과의 거리, 차량 자가 진단 모듈[1]을 사용한 차량의 상태를 전송한다. 통신 방식은 항상 Wi-Fi를 우선으로 하며, Wi-Fi가 동작하지 않는 곳에서는 WAVE 통신을 이용하여 차량 정보를 수집한다. 수집된 차량 정보는 RSU의 Local Database에 저장된다.

표 1. RSU에 저장되는 도로 정보
Table 1. Road information stored in the RSU

Name	Description
차량 속도	RSU 통신 범위 내의 차량 속도 평균
차량 수	RSU 통신 범위 내의 모든 차량 수
차간 거리	RSU 통신 범위 내의 차량 간 거리 평균
차량 상태	RSU 통신 범위 내의 차량 진단 상태 수치 데이터의 평균
도로의 기울기	RSU 통신 범위 내의 도로 기울기의 평균

도로의 곡률	RSU 통신 범위 내의 도로 곡률의 평균
도로의 마찰 계수	현재 도로의 마찰 계수
신호등 개수	RSU 통신 범위 내의 신호등 개수
교차로 여부	현재 교차로 수(5거리, 4거리, 3거리 등)
신호등 상태	신호등의 상태
현재 기온	기상청에서 전송받은 현재 기온
노면 온도	기온을 바탕으로 계산한 노면 온도
강수량	현재 날씨의 강수량
기상 상태	현재 기상 상태(안개, 눈, 비, 결빙 등)
시간	데이터를 수집한 시간

3.1.2. 도로 정보 및 날씨 정보 수집

ASICM은 인터넷을 사용하여 교통관제 센터와 기상청과 통신한다. 교통관제 센터에서 수집되는 도로 정보는 도로의 기울기, 도로의 차선 수, 도로의 곡률, 도로의 마찰 계수와 신호등 존재 여부, 신호등의 현재 신호다. 기상청에서 수집되는 날씨 정보는 현재 기온, 강수량, 기상 상태(폭우, 안개, 눈 등)이다. 수집된 도로 정보와 날씨 정보는 도로 정보와 마찬가지로 Local Database에 저장된다. 표 1은 ASICM이 RSU의 Local Database에 저장하는 정보를 보여준다.

3.2. Road Risk Prediction Module 설계

본 논문에서 제안하는 RRP은 ASICM에서 수집한 정보를 바탕으로 RSU 범위 내의 도로의 위험성을 예측한다. RRP은 딥러닝 신경망 모델(DNN)을 이용하여 도로의 위험을 예측한다. 딥러닝 모델을 사용하기 위하여 사용되는 데이터의 전처리과정과 DNN의 설계가 이루어져야 한다.

3.2.1. 데이터 전처리과정

데이터 전처리과정은 RSU의 Local Database의

데이터 중 수치화되지 않은 데이터를 수치화하는 과정이다. 표 2는 수치가 아닌 데이터를 수치화 데이터로 변경시키는 규칙을 나타낸다. 수치화된 데이터들은 RPNN의 입력으로 사용된다. 또한, RPNN의 입력 변수들의 폭이 크기 때문에 RPNN의 입력 값들은 -1~1 사이로 정규화한다.

표 2. 비정규 데이터의 정규화
Table 2. Normalization of Nonnormal Data

항목	저장 데이터	변환된 수치
신호등 상태	Green	1
	Yellow	0
	Red	-1
기상 상태	안개	-2
	눈	-4
	비	-3
	결빙	-6
	우박	-5
	이상 없음	0

3.2.2. RPNN 설계

RSU는 도로의 사고 가능성을 예측하기 위해 DNN을 기반으로 Risk Prediction Neural Network (RPNN)을 설계한다. RPNN을 사용하기 위하여 RPNN의 입력과 출력, 히든레이어를 정의하여 신경망 모델의 구조를 설계하고, 설계된 신경망 모델의 계산을 위하여 활성화 함수, 학습률, 초기 연결 강도와 학습 방법을 설정해야 한다.

3.2.2.1 RPNN의 구조 설계

RPNN은 적절한 입력레이어, 출력레이어 그리고 히든레이어를 사용해야 한다. 신경망 모델의 입력노드는 RSU에서 수집한 데이터다. RSU에서 수집한 데이터의 수는 14개(데이터 수집 시간 제외)이기 때문에 RPNN의 입력 벡터인 X 는 수식 1처럼 표현한다.

$$X = \{x_1, x_2, x_3, x_4, \dots, x_{14}\} \quad (1)$$

표 3은 x_n ($1 \leq n \leq 14$)에 해당하는 변수가 어떤 변수인지 나타낸다. RPNN의 출력 노드는 사고 유형 별 사고 발생 가능성을 나타낸다. 사고 유형은 신호 위반 사고, 차선 변경 사고, 중앙선 침범 사고, 교차로 회전 사고와 속도위반 사고로 구분하며, 각 노드는 -

1~1 값 사이의 출력값을 가진다. 따라서 RPNN의 출력 벡터 Y 는 수식 2처럼 표현한다.

$$Y = \{y_1, y_2, y_3, y_4, y_5\} \quad (2)$$

수식 2에서 y_1 의 출력값은 신호 위반으로 인한 사고의 가능성을, y_2 의 출력값은 차선 변경 시 사고의 가능성을, y_3 의 출력값은 중앙선 침범 시 사고의 가능성을, y_4 의 출력값은 교차로 회전 시 사고의 가능성을, y_5 의 출력값은 속도위반으로 인한 사고의 가능성을 의미한다. RPNN은 가장 사고 가능성이 큰 출력 노드를 출력으로 결정한다. 예를 들어 입력 벡터 {0.54, 0, 0.15, 0.98, -0.15, 0, 0.3, 0.1, 0, 0.14, 0.21, 0, 0}, 출력 벡터 {0, 0, 0, 0, 0}로 이루어진 훈련 데이터는 모든 상황이 정상인 입력에서는 모든 사고 가능성이 0으로 출력됨을 의미한다.

그림 2는 신경망 모델의 입력 값과 출력값의 예를 나타낸다.

RPNN의 히든레이어는 14개의 변수의 연관성을 충분히 계산하기 위하여 5개를 사용하고, 히든레이어의 노드 수는 25개를 사용한다. 히든레이어의 노드는 h_{nm} 으로 표현한다. 여기서 n 은 현재 히든레이어의 노드가 몇 번째 히든레이어에 속해있는지를 나타내며, m 은 현재 노드가 히든레이어의 몇 번째 노드인가를 나타낸다. 예를 들어 히든레이어의 노드 h_{13} 은 첫 번째 히든레이어의 세 번째 노드라는 뜻이다. 따라서 히든레이어 벡터 H 는 수식 3과 같이 표현된다.

$$H_n = \{h_{n1}, h_{n2}, h_{n3}, h_{n4}, \dots, h_{nm}\} \quad (3)$$

여기서 n 의 범위는 $1 \leq n \leq 5$ 이며, m 의 범위는 $1 \leq m \leq 25$ 이다.

RPNN의 연결 강도는 w_{bc}^a 의 형태로 표현한다. 여기서 a 는 연결 강도 w 가 몇 번째 연결 강도인지 나타낸다. b 는 현재 입력 중인 노드의 번호이며, c 는 출력할 노드의 번호이다. 예를 들어 연결 강도 w_{510}^1 은 첫 번째, 즉 입력 레이어와 첫 번째 히든레이어 사이에서 입력 레이어의 5번째 노드와 첫 번째 히든레이어의 10 번째 노드 사이의 연결 강도임을 의미한다. 연결 강도 벡터 W 는 수식 4와 같이 표현된다.

$$W^a = \{w_{11}^a, w_{12}^a, w_{13}^a, w_{14}^a, \dots, w_{bc}^a\} \quad (4)$$

표 3. RPNN의 입력으로 사용되는 변수들
Table 3. Variables used as input to RPNN

항목	변수명	범위
x_1	차량 속도	$0 \leq x_1 \leq 300$
x_2	차량 수	$0 \leq x_2$
x_3	차간 거리	$0.01 \leq x_3$
x_4	차량 상태	$0 \leq x_4 \leq 1$
x_5	도로의 기울기	$-20 \leq x_5 \leq 20$
x_6	도로의 곡률	$0.2 \leq x_6 \leq 0.8$
x_7	도로의 마찰 값	$0.2 \leq x_7 \leq 0.9$
x_8	신호등 개수	$0 \leq x_8 \leq 8$
x_9	교차로 여부	$0 \leq x_9 \leq 7$
x_{10}	신호등 상태	$x_{10} = 1, 0, -1$
x_{11}	현재 기온	$-30 \leq x_{11} \leq 40$
x_{12}	노면 온도	$-10 \leq x_{12} \leq 80$
x_{13}	강수량	$0 \leq x_{13} \leq 800$
x_{14}	기상 상태	$x_{14} = 0, -2, -3, -4, -5, -6$

3.2.2.2. RPNN의 학습

RPNN은 학습을 위하여 학습률과 초기 연결 강도를 먼저 설정해야 한다. 이때, 학습률은 α 로 표기하며, 0.3에서 20epoch 마다 1/10만큼 줄인다. 초기 연결 강도는 0.1로 설정한다.

RPNN은 단위 시간당 수집되는 데이터를 실시간으로 처리해야 하기 때문에 빠르고 정확하게 정보를 처리할 수 있는 활성화 함수를 사용해야 하며, 출력이 -1과 1사이에서 결정되어야 한다. 따라서 입력 레이어부터 마지막 히든레이어까지 활성화 함수는 정확한 결과를 보장하면서 Sigmoid함수보다 6배 빠른 Leaky Relu 함수를 사용하고, 마지막 히든레이어와 출력레이어 사이의 활성화 함수는 Leaky Relu 보다 계산 시간은 느리지만 -1과 1사이의 출력값을 가지는 tanh함수를 사용한다. 수식 5는 Leaky Relu함수를 나타내고, 수식 6은 tanh함수를 나타낸다.

$$LR(NEt) = \max(0.01NEt, NEt) \quad (5)$$

$$\tanh(NEt) = \frac{1 - e^{-NEt}}{1 + e^{-NEt}} \quad (6)$$

식 5와 6에서 NEt 은 현재 노드의 값을 뜻한다. 현재 노드의 값은 이전 레이어의 노드들과 연결강도의 가중치 합이다. 예를 들어 식 7은 세 번째 히든레이어의 첫 번째 노드의 가중치 합인 $NEt_{h_{31}}$ 을 계산한다.

$$NEt_{h_{31}} = \sum_{i=1}^{25} h_{2i} w_{i1}^3 \quad (7)$$

이런 방법으로 계산된 NEt 은 활성화 함수를 통하여 해당 노드의 출력값으로 결정된다.

RPNN의 학습 방법은 Back-Propagation학습 방법을 사용한다. Back-Propagation학습은 에러 E , 에러의 허용치 E_{max} 와 에러 신호 δ 를 사용한다. 에러 E 는 식 8을 통하여 계산된다.

$$E = \frac{1}{2} \sum_{i=1}^5 (d_i - \hat{y}_i)^2 \quad (8)$$

식 8에서 d_i 는 훈련 데이터의 결괏값을 의미하고, \hat{y}_i 는 i 번째 출력 노드의 결괏값을 의미한다.

만약 E 가 E_{max} 보다 작다면, 학습을 종료하고, E_{max} 보다 크다면 δ 를 사용하여 각 연결 강도를 수정

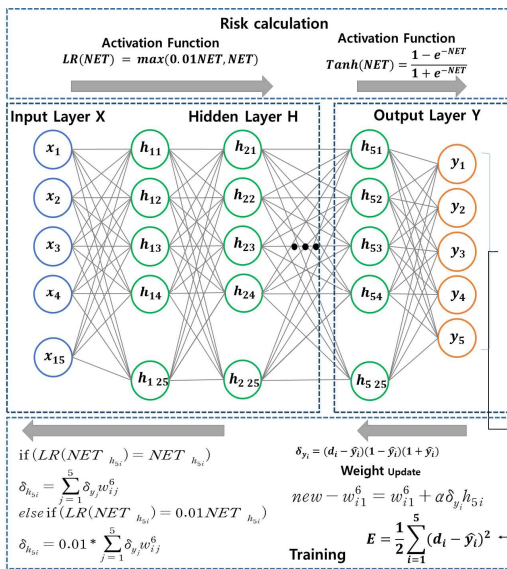


그림 2. RPNN의 상세한 구조
Fig. 2. A Detailed structure of RPNN

한다. 출력 레이어와 마지막 히든 레이어 사이의 δ 와 마지막 히든레이어와 입력레이어 사이의 δ 는 서로 다른 방식으로 계산되어야 한다.

우선 출력 레이어와 마지막 히든레이어 사이의 에러 신호 값인 δ_{y_i} 는 식 9와 같이 계산된다.

$$\delta_{y_i} = \frac{d}{dx} E^* \frac{d}{dx} \tanh(x) \quad (9)$$

식 9에서 E 를 미분하면, $(d_i - \hat{y}_i)$ 가 되고, $\frac{d}{dx} \tanh(x)$ 를 미분하면, $(1 - \hat{y}_i)(1 + \hat{y}_i)$ 가 되기 때문에 식 9를 정리하면 식 10과 같이 표현할 수 있다. 여기서 i 는 출력 노드의 번호를 뜻한다.

$$\delta_{y_i} = (d_i - \hat{y}_i)(1 - \hat{y}_i)(1 + \hat{y}_i) \quad (10)$$

다음으로 마지막 히든레이어부터 입력 레이어까지의 δ 를 계산해야 한다. 식 11는 마지막 히든레이어와 네 번째 히든레이어 사이의 에러 신호 값인 $\delta_{h_{5i}}$ 를 나타낸다.

$$\text{if}(LR(NETh_{5i}) = NETh_{5i}) \quad (11)$$

$$\delta_{h_{5i}} = \sum_{j=1}^5 \delta_{y_j} w_{ij}^6$$

$$\text{else if}(LR(NETh_{5i}) = 0.01NETh_{5i})$$

$$\delta_{h_{5i}} = 0.01 * \sum_{j=1}^5 \delta_{y_j} w_{ij}^6$$

여기서 i 는 마지막 히든레이어의 노드 번호다. δ_{h_4} 부터 δ_{h_1} 은 모두 식 11과 같은 방식으로 계산한다. 모든 δ 가 계산되면, 연결 강도 w 를 수정한다. 예를 들어 식 12는 δ_{y_i} 를 이용하여 출력 레이어의 첫 번째 노드와 마지막 히든레이어의 노드 사이의 연결 강도를 수정하는 것을 보여준다.

$$\text{new} - w_{i1}^6 = w_{i1}^6 + \alpha \delta_{y_i} h_{5i} \quad (12)$$

여기서 i 는 출력 레이어의 첫 번째 노드에 연결된 히든레이어의 노드 번호다. 나머지 연결 강도 $w^5 \sim w^1$ 도 식 12와 같은 방식으로 변경된다.

3.3. Vehicle Path Determination Module 설계

RSU가 도로별 사고 가능성을 분석하면, 차량은

RSU의 데이터를 활용하여 차량이 현재 진행할 수 있는 최적의 경로를 선택한다. Vehicle Path Determination Module(VPDM)은 차량이 주행할 때 목적지가 설정되어있는지를 확인하고, 통신할 RSU를 결정한다. VPDM은 RSU로부터 RRP의 결과를 전달 받아 차량이 가장 안전하고 신속한 경로를 탐색할 수 있도록 한다. 차량이 목적지를 설정하고 주행 중이면, VPDM은 다음과 같이 동작한다.

첫째, VPDM은 차량이 목적지까지 주행할 수 있는 3가지 경로를 선택한다. 3가지 경로는 목적지까지 도달하는 최단 거리의 경로, 고속도로를 통과하지 않고 무료도로 주행하는 경로, 단순한 차량 혼잡도를 적용한 최소시간경로이다.

둘째, VPDM은 차량과 가장 가까운 RSU를 통하여 이 세 가지 경로에서 정보를 수집하고 있는 RSU에게 사고 가능성을 요청한다. 차량과 가장 가까운 RSU는 해당 경로에 따라 주변 RSU로 사고 예측결과를 재귀적으로 요청하면서 요청에 대한 응답을 누적한다. 만약 목적지까지 요청이 전송되었다면, 누적된 결과를 해당 경로의 위험성으로 저장한다.

셋째, 해당 경로에 존재하는 RSU는 RSU 사이의 통신을 사용하여 도로의 위치와 사고 위험성을 차량의 VPDM으로 전송한다.

넷째, VPDM은 각 경로의 사고 위험성을 비교하여 가장 사고 위험성이 낮은 도로로 주행 경로를 설정한다.

그림3은 차량이 목적지를 설정하고 주행 중일 경우, 세 가지 경로로부터 사고 위험성을 전달받아 경로를 선택하는 예를 보여준다.

차량이 목적지를 설정하지 않고 주행 중이면, VPDM은 다음과 같이 동작한다.

첫째, 현재 차량과 가장 가까운 RSU는 흡을 10으로 설정하고 주변으로 사고 가능성 전송 요청을 방송한다.

둘째, 방송을 수신한 RSU의 개수를 저장하고, 목적지가 설정되었을 때와 마찬가지로 흡 개수만큼 도로 RSU의 결과를 저장한다.

셋째, 저장한 사고 위험성을 비교하여 위험성이 가장 낮은 경로로 주행하도록 차량의 경로를 설정한다.

4. 실험

본 논문은 OVRs의 유효성을 판단하기 위하여 가상 환경의 기상데이터를 사용하여 ASICM과 VPDM에 대한 실험을 진행한다. ASICM의 경우 실시간성을 검증하기 위하여 다른 딥러닝 모델을 학습시키고 RSU에서 도로를 기반으로 사고 가능성을 예측했을 때 RPNN과 다른 딥러닝 모델의 연산 시간을 측정한다.

표 4. 가상환경 사양
Table 4. Virtual environment specification

Part Name	specification
CPU	Intel i5-7500 3.40Ghz
RAM	8GB
GPU	GTX 1050
SSD	125GB

그림 3은 도로 정보 수에 따른 딥러닝 모델들의 작동 시간을 나타낸다. 해당 실험은 딥러닝 모델의 학습 시간은 고려되지 않았으며, RPNN은 같은 입력 벡터와 출력 벡터를 사용하여 설계된 CNN, LSTM과 비교되었다.




그림 3. 도로 상태 수에 따른 딥러닝 모델들의 연산 시간
Fig. 3. A computation time of deep learning models according to the number of road states

실험 결과, CNN의 평균 연산 시간은 약 988ms, LSTM의 평균 연산 시간은 약 1185ms, RPNN의 평균 연산 시간은 약 842ms로 측정되었다. RPNN은 CNN보다 약 17%, LSTM보다 약 40% 빠른 연산 시간을 가졌다. 특히 데이터가 증가할수록 LSTM의 연산 시간은 크게 증가하고, CNN은 전반적으로 RPNN보다 높은 연산 시간을 가지기 때문에 실시간성을 확보하면서 도로 상황을 종합하여 사고 가능성을 예측하는 것은 RPNN이 적합하다.

5. 결론

본 논문에서는 긴급상황에서의 즉각적인 반응보다는 차량의 목적지가 정해진 순간 사고 가능성이 가장 낮은 경로를 결정하는 Optimized Vehicle Routing System (OVRs)을 제안했다. OVRs는 세 가지 모듈로 구성된다. 첫 번째로 Ambient Situation Information Collection Module(ASICM)은 Wi-Fi와 WAVE를 이용하여 도로 주변 정보를 수집하고, 교통관계 센터와 기상청에서 주변 정보를 수집한다. 두 번째로 Road Risk Prediction Module(RPMM)은 ASICM에서 수집한 정보를 분석하여 도로의 사고 가능성을 예측하고 위험도를 측정한다. 마지막으로 Vehicle Path Determination Module(VPDM)은 차량의 상태에 따라 RSU와 통신하며 최적의 경로를 찾는다. OVRs모듈 중 하나인 ASICM의 RPNN은 CNN보다 약 17%, LSTM보다 약 40% 더 좋은 성능을 보였다. 향후 OVRs는 실제 차량에서 테스트되어야 한다. 또한, OVRs의 실시간성은 검증되었으나 정확도에 대한 실험이 이루어지지 않았다. 따라서 향후 실제 차량에 OVRs를 적용시킨 후 안전한 환경에서 정확도에 대한 실험이 이루어져야 할 것이다.

REFERENCES

- [1] YiNa Jeong, SuRak Son, ByungKwan Lee, "The Lightweight Autonomous Vehicle Self-Diagnosis (LAVS) Using Machine Learning Based on Sensors and Multi-Protocol IoT Gateway", Sensor, Vol. 19, No. 11, June, 2019.
- [2] Byeongjoon Noh, Wonjun No, Jaehong Lee, David Lee, "Vision-Based Potential Pedestrian Risk Analysis on Unsignalized Crosswalk Using Data Mining Techniques", Applied Sciences, Vol. 10, No. 3, February, 2020.
- [3] Dario Vangi, Carlo Cialdai, Michelangelo-Santo Gulino, Kjell Gunnar Robbersmyr, "Vehicle Accident Databases: Correctness Checks for Accident Kinematic Data", Designs, Vol. 2, No. 1, January, 2018.
- [4] Jhihoon Joo, Odongo Steven Eyobu, Ji Hun

- Kim, Hong-Jong Jeong, Dong Seog Han, "Analysis of Radio Propagation Characteristics for V2V Scenarios in WAVE Standard Based Vehicular Communication System", The Journal of Korean Institute of Communications and Information Sciences, Vol. 42 No. 6, pp. 1175-1184, 2017
- [5] Bongsue Suh, "Performance Analysis of RSUs in Probability-Based Data Delivery Strategy for Energy-Constrained V2I Systems". The Journal of Korean Institute of Information Technology, Vol. 16 No.11, pp. 69-76, 2018
- [6] Seok-Gyu Park, Heui-Hak Ahn, Yi-Na Jeong, "Preventing Communication Disruption in the Urban Environment Using RRPS (RSU Request Priority Scheduling)", Journal of Korea Institute of Information, Electronics, and Communication Technology, Vol.9 No.6, pp. 584-590, 2016
- [7] Jungmin Kwon, Hyunggon Park, "Data Driven Reliable Dissemination Strategy Based Systematic Network Coding in V2I Networks", The Journal of Korean Institute of Communications and Information Sciences, Vol.45 No.2, pp. 327-336, 2020
- [8] Bongsue Suh, "Variable Transmission Distance-Based Data Delivery Strategy to Support Near-Optimal Delivery Delay for V2I Systems", The Journal of Korean Institute of Information Technology, Vol.17 No.12, pp. 93-100, 2019
- [9] Eum Han, Ilsoo Yun, Sang Soo Lee, Kitae Jang, Byungkyu Park, "Development of Real-time Traffic Signal Control Strategy for Coordinated Signalized Intersections under V2I Communication Environment", The Journal of The Korea Institute of Intelligent Transportation Systems, Vol.17, No.3, pp. 59-71, 2018
- [10] Kyoung Soo Bok, Seung Wan Hong, Jae Hog Cha, Jong Tae Lim, Jaesoo Yoo, "Cooperative RSU Scheduling for Efficient Data Dissemination in VANET Environments", JOURNAL OF THE KOREA CONTENTS ASSOCIATION, Vol.13 No.10, pp. 27-36, 2013

저자약력

손 수 략(Su-Rak Son)

[정회원]



- 2018년 2월 : 가톨릭관동대학교 컴퓨터학과(공학사)
- 2019년 8월 : 가톨릭관동대학교 컴퓨터학과(공학석사)
- 2019년 8월 ~ 현재 : 가톨릭관동대학교 컴퓨터학과(공학박사 재학)

〈관심분야〉 빅데이터, 네트워크, 프로그래밍 언어

이 병 관(Byung-Kwan Lee)

[정회원]



- 1979년 2월 : 부산대학교 기계설계학과(공학사)
- 1986년 2월 : 중앙대학교 전자계산학과(이학석사)
- 1990년 2월 : 중앙대학교 전자계산학과(공학박사)
- 1988년 3월 ~ 현재 : 가톨릭관동대학교 소프트웨어학과 교수

〈관심분야〉 네트워크보안, 빅데이터, 데이터마이닝, 사물인터넷

심 손 권(Son-Kweon Sim)

[비회원]



- 1996년 : 관동대학교 전자계산공학과 졸업(공학사)
- 1998년 : 관동대학교 공학석사
- 2003년 : 관동대학교 공학박사

〈관심분야〉 시스템 프로그래밍, 답러닝, 빅데이터, 인공지능

정 이 나(Yi-na Jeong)

[정회원]



- 2011년 2월 : 가톨릭관동대학교 컴퓨터학과(공학사)
- 2013년 8월 : 가톨릭관동대학교 컴퓨터학과(공학석사)
- 2018년 8월 : 가톨릭관동대학교 컴퓨터학과(공학박사)
- 2017년 3월 ~ 현재 : 가톨릭관동대학교 컴퓨터학과 초빙교수

〈관심분야〉 빅데이터, 네트워크, 프로그래밍 언어