(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2024-0036397
(43) 공개일자 2024년03월20일

(51) 국제특허분류(Int. Cl.)
G08G 1/01 (2006.01) *G06N 3/02* (2023.01)
(52) CPC특허분류
G08G 1/0108 (2013.01)
G06N 3/02 (2023.01)
(21) 출원번호 10-2022-0115196
(22) 출원일자 2022년09월13일
심사청구일자 2022년09월13일

(71) 출원인
울산과학기술원
울산광역시 울주군 언양읍 유니스트길 50
(72) 발명자
고성안
울산광역시 울주군 언양읍 유니스트길 50
이현욱
울산광역시 울주군 언양읍 유니스트길 50
(74) 대리인
특허법인 무한

전체 청구항 수 : 총 17 항

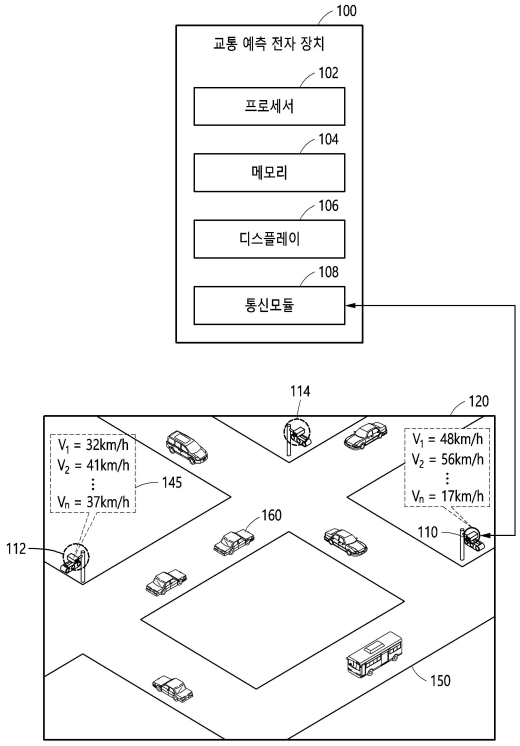
(54) 발명의 명칭 **교통 예측 방법 및 장치**

(57) 요 약

일 실시예에 따른 교통 예측 전자 장치는, 교통 정보를 나타내는 교통 데이터를 획득하는 데이터 획득부; 컴퓨터로 실행 가능한 명령어들(computer-executable instructions)이 저장된 메모리; 상기 메모리에 억세스(access)하여 상기 명령어들을 실행하는 프로세서; 및 상기 프로세서와 전기적으로 연결된 디스플레이를 포함하고, 상기

(뒷면에 계속)

대 표 도 - 도1



명령어들은, 상기 입력된 교통 데이터로부터 추출된 패턴(pattern)에 기초하여 대표 패턴 데이터를 생성하고, 임베딩 행렬(embedding matrix)로부터 획득된 복수의 기억된 패턴들(memorized patterns) 및 상기 생성된 대표 패턴 데이터 간의 거리 데이터를 획득하고, 상기 대표 패턴 데이터 및 상기 거리 데이터에 기초하여, 상기 복수의 기억된 패턴들 중 적어도 일부 패턴과 상기 대표 패턴 데이터의 교통 정보의 분포를 나타내는 대표 기억 정보(representative memory information)를 생성하고, 상기 생성된 대표 기억 정보에 예측 모델을 적용한 것(또는 결과)에 기초하여, 상기 교통 데이터를 수집한 시점(time point) 이후의 교통 흐름에 관한 출력 교통 데이터를 예측할 수 있다.

(52) CPC특허분류

G08G 1/0125 (2013.01)

이 발명을 지원한 국가연구개발사업

과제고유번호	1711162645
과제번호	2021R1A2C1004542
부처명	과학기술정보통신부
과제관리(전문)기관명	한국연구재단
연구사업명	개인기초연구(과기정통부)
연구과제명	교통 이벤트 발생시의 교통 데이터 분석 및 예측용 시각적 분석 시스템 개발
기 여 율	1/3
과제수행기관명	울산과학기술원
연구기간	2022.03.01 ~ 2023.02.28

이 발명을 지원한 국가연구개발사업

과제고유번호	1711152910
과제번호	2021-0-01198-002
부처명	과학기술정보통신부
과제관리(전문)기관명	정보통신기획평가원
연구사업명	ICTR&D혁신바우처지원사업(예타)
연구과제명	지능형 MOD (Mobility-on-demand) 운용을 위한 인공지능 기술 개발
기 여 율	1/3
과제수행기관명	(주)씨엘
연구기간	2022.01.01 ~ 2022.12.31

이 발명을 지원한 국가연구개발사업

과제고유번호	1711159771
과제번호	2017-0-01635-006
부처명	과학기술정보통신부
과제관리(전문)기관명	정보통신기획평가원
연구사업명	정보통신방송혁신인재양성
연구과제명	자가충전형 초소형 전국단위 위치추적 시스템 원천기술 개발
기 여 율	1/3
과제수행기관명	울산과학기술원
연구기간	2022.01.01 ~ 2022.12.31

명 세 서

청구범위

청구항 1

프로세서에 의하여 수행되는 교통 예측 방법에 있어서,

입력된 교통 데이터로부터 추출된 패턴(pattern)에 기초하여 대표 패턴 데이터를 생성하는 단계;

임베딩 행렬(embedding matrix)로부터 획득된 복수의 기억된 패턴들(memorized patterns) 및 상기 생성된 대표 패턴 데이터 간의 거리 데이터를 획득하는 단계;

상기 대표 패턴 데이터 및 상기 거리 데이터에 기초하여, 상기 복수의 기억된 패턴들 중 적어도 일부 패턴과 상기 대표 패턴 데이터의 교통 정보의 분포를 나타내는 대표 기억 정보(representative memory information)를 생성하는 단계; 및

상기 생성된 대표 기억 정보에 예측 모델을 적용한 것(또는 결과)에 기초하여, 상기 교통 데이터를 수집한 시점(time point) 이후의 교통 흐름에 관한 출력 교통 데이터를 예측하는 단계;

를 포함하는 교통 예측 방법.

청구항 2

제1항에 있어서,

상기 대표 패턴 데이터를 생성하는 단계는,

상기 입력된 교통 데이터를 미리 결정한(predetermined) 시간 간격(time period)을 기준으로 분할된 복수의 분할 패턴을 추출하는 단계;

상기 복수의 분할 패턴들 간의 유사도(similarity)를 획득하는 단계; 및

상기 획득된 유사도가 임계(threshold) 값 보다 큰 분할 패턴들에 기초하여, 클러스터링(clustering)을 통해 대상 분할 패턴들을 생성하는 단계;

를 포함하는 방법.

청구항 3

제1항에 있어서,

상기 대표 기억 정보를 생성하는 단계는,

상기 예측 모델의 복수의 히든 레이어(hidden layer) 중 적어도 하나의 레이어에 기초하여, 상기 임베딩 행렬들 중 상기 레이어에 해당하는 대상 임베딩 행렬을 선택하는 단계;

상기 대상 임베딩 행렬로부터 획득된 기억된 패턴들 중 각각과 상기 대표 패턴 데이터에 거리 함수(distance function)를 적용함으로써, 상기 기억된 패턴들과 상기 대표 패턴 데이터 간의 거리 데이터를 획득하는 단계;

상기 획득된 거리 데이터에 기초하여, 상기 기억된 패턴들 중 후보 패턴(candidate pattern)을 선택하는 단계;

상기 임베딩 행렬에 상기 후보 패턴을 적용하여 기억 컨텍스트(memory context) 데이터를 획득하는 단계; 및

상기 기억 컨텍스트 데이터 및 상기 거리 데이터에 기초하여, 상기 대표 기억 정보를 생성하는 단계;

를 포함하는 방법.

청구항 4

제3항에 있어서,

상기 후보 패턴을 선택하는 단계는,

상기 거리 데이터에 기초하여, 상기 기억된 패턴들 중 임계 값 보다 작은 거리 데이터를 포함하는 복수의 대상 후보 패턴들을 선택하는 단계

를 포함하는 방법.

청구항 5

제1항에 있어서,

상기 출력 교통 데이터를 예측하는 단계는,

상기 획득된 거리 데이터에 기초하여, 상기 복수의 기억된 패턴들 중에서 대상 기억된 패턴을 획득하는 단계;

상기 대상 기억된 패턴 및 상기 대표 패턴 데이터 과의 차이를 통해 노이즈(noise) 데이터를 획득하는 단계;

상기 입력된 교통 데이터를 수집한 시점에 관한 임베딩(embedding) 데이터를 획득하는 단계;

상기 임베딩 데이터, 상기 노이즈 데이터, 또는 학습 가능한 행렬(learnable matrix) 중 적어도 하나에 기초하여, 상기 예측 모델의 초기 히든 상태(initial hidden state) 데이터를 산출하는 단계; 및

상기 초기 히든 상태 데이터에 상기 예측 모델을 적용한 것에 기초하여, 교통 흐름에 관한 상기 출력 교통 데이터를 예측하는 단계

를 포함하는 방법.

청구항 6

제1항에 있어서,

상기 출력 교통 데이터를 예측하는 단계는,

상기 예측 모델의 복수의 히든 레이어(hidden layer)들에 대한 히든 상태(hidden state) 데이터를 획득하는 단계;

상기 복수의 히든 레이어들에 대한 출력 특징(output feature) 데이터를 산출하는 단계;

상기 예측 모델에 대한 에너지(energy) 데이터를 산출하는 단계;

상기 예측 모델의 전파 행렬(projection matrix)을 획득하는 단계; 및

상기 출력 특징 데이터, 상기 에너지 데이터, 또는 상기 전파 행렬 중 적어도 하나에 기초하여 상기 출력 교통 데이터를 예측하는 단계

를 포함하는 방법.

청구항 7

제6항에 있어서,

상기 출력 특징 데이터를 산출하는 단계는,

상기 대표 기억 정보 또는 상기 히든 상태 데이터 중 적어도 하나에 기초하여 어텐션 스코어(attention score) 데이터를 산출하는 단계;

상기 어텐션 스코어 데이터들에 기초하여, 상기 히든 레이어의 집중 행렬(attention matrix)을 획득하는 단계;

및

상기 집중 행렬 또는 상기 예측 모델의 학습 가능한 행렬(learnable matrix)들 중 적어도 하나에 기초하여 상기 출력 특징 데이터를 산출하는 단계

를 포함하는 방법.

청구항 8

제6항에 있어서,

상기 히든 상태 데이터를 획득하는 단계는,

상기 복수의 히든 레이어들 중에서, 상기 히든 상태 데이터가 포함된 제1 레이어를 획득하는 단계;

상기 복수의 히든 레이어들 중에서, 상기 제1 레이어의 이전 레이어를 나타내는 제2 레이어를 획득하는 단계;

상기 제2 레이어에 관한 대상 히든 상태 데이터를 획득하는 단계; 및

상기 출력 특징 데이터 또는 상기 대상 히든 상태 데이터 중 적어도 하나에 기초하여 상기 제1 레이어에 관한 히든 상태 데이터를 획득하는 단계

를 포함하는 방법.

청구항 9

하드웨어와 결합되어 제1항 내지 제8항 중 어느 하나의 항의 방법을 실행시키기 위하여 컴퓨터 판독 가능한 기록매체에 저장된 컴퓨터 프로그램.

청구항 10

교통 예측 전자 장치에 있어서,

교통 정보를 나타내는 교통 데이터를 획득하는 데이터 획득부;

컴퓨터로 실행 가능한 명령어들(computer-executable instructions)이 저장된 메모리;

상기 메모리에 억세스(access)하여 상기 명령어들을 실행하는 프로세서; 및

상기 프로세서와 전기적으로 연결된 디스플레이

를 포함하고,

상기 명령어들은,

상기 입력된 교통 데이터로부터 추출된 패턴(pattern)에 기초하여 대표 패턴 데이터를 생성하고,

임베딩 행렬(embedding matrix)로부터 획득된 복수의 기억된 패턴들(memorized patterns) 및 상기 생성된 대표 패턴 데이터 간의 거리 데이터를 획득하고,

상기 대표 패턴 데이터 및 상기 거리 데이터에 기초하여, 상기 복수의 기억된 패턴들 중 적어도 일부 패턴과 상기 대표 패턴 데이터의 교통 정보의 분포를 나타내는 대표 기억 정보(representative memory information)를 생성하고,

상기 생성된 대표 기억 정보에 예측 모델을 적용한 것(또는 결과)에 기초하여, 상기 교통 데이터를 수집한 시점(time point) 이후의 교통 흐름에 관한 출력 교통 데이터를 예측하는

교통 예측 전자 장치.

청구항 11

제10항에 있어서,

상기 프로세서는,

상기 입력된 교통 데이터를 미리 결정한(predetermined) 시간 간격(time period)을 기준으로 분할된 복수의 분할 패턴을 추출하고,

상기 복수의 분할 패턴들 간의 유사도(similarity)를 획득하고,

상기 획득된 유사도가 임계(threshold) 값 보다 큰 분할 패턴들에 기초하여, 클러스터링(clustering)을 통해 대상 분할 패턴들을 생성하는

교통 예측 전자 장치.

청구항 12

제10항에 있어서,

상기 프로세서는,

상기 예측 모델의 복수의 히든 레이어(hidden layer) 중 적어도 하나의 레이어에 기초하여, 상기 임베딩 행렬들 중 상기 레이어에 해당하는 대상 임베딩 행렬을 선택하고,

상기 대상 임베딩 행렬로부터 획득된 기억된 패턴들 중 각각과 상기 대표 패턴 데이터에 거리 함수(distance function)를 적용함으로써, 상기 기억된 패턴들과 상기 대표 패턴 데이터 간의 거리 데이터를 획득하고,

상기 획득된 거리 데이터에 기초하여, 상기 기억된 패턴들 중 후보 패턴(candidate pattern)을 선택하고,

상기 임베딩 행렬에 상기 후보 패턴을 적용하여 기억 컨텍스트(memory context) 데이터를 획득하고,

상기 기억 컨텍스트 데이터 및 상기 거리 데이터에 기초하여, 상기 대표 기억 정보를 생성하는

교통 예측 전자 장치.

청구항 13

제12항에 있어서,

상기 프로세서는,

상기 거리 데이터에 기초하여, 상기 기억된 패턴들 중 임계 값 보다 작은 거리 데이터를 포함하는 복수의 대상 후보 패턴들을 선택하는

교통 예측 전자 장치.

청구항 14

제10항에 있어서,

상기 프로세서는,

상기 획득된 거리 데이터에 기초하여, 상기 복수의 기억된 패턴들 중에서 대상 기억된 패턴을 획득하고,

상기 대상 기억된 패턴 및 상기 대표 패턴 데이터 과의 차이를 통해 노이즈(noise) 데이터를 획득하고,

상기 입력된 교통 데이터를 수집한 시점에 관한 임베딩(embedding) 데이터를 획득하고,

상기 임베딩 데이터, 상기 노이즈 데이터, 또는 학습 가능한 행렬(learnable matrix) 중 적어도 하나에 기초하여, 상기 예측 모델의 초기 히든 상태(initial hidden state) 데이터를 산출하고,

상기 초기 히든 상태 데이터에 상기 예측 모델을 적용한 것에 기초하여, 교통 흐름에 관한 상기 출력 교통 데이터를 예측하는

교통 예측 전자 장치.

청구항 15

제10항에 있어서,

상기 프로세서는,

상기 예측 모델의 복수의 히든 레이어(hidden layer)들에 대한 히든 상태(hidden state) 데이터를 획득하고,

상기 복수의 히든 레이어들에 대한 출력 특징(output feature) 데이터를 산출하고,

상기 예측 모델에 대한 에너지(energy) 데이터를 산출하고,

상기 예측 모델의 전파 행렬(projection matrix)을 획득하고,

상기 출력 특징 데이터, 상기 에너지 데이터, 또는 상기 전파 행렬 중 적어도 하나에 기초하여 상기 출력 교통 데이터를 예측하는

교통 예측 전자 장치.

청구항 16

제15항에 있어서,

상기 프로세서는,

상기 대표 기억 정보 또는 상기 히든 상태 데이터 중 적어도 하나에 기초하여 어텐션 스코어(attention score) 데이터를 산출하고,

상기 어텐션 스코어 데이터들에 기초하여, 상기 히든 레이어의 집중 행렬(attention matrix)을 획득하고,

상기 집중 행렬 또는 상기 예측 모델의 학습 가능한 행렬(learnable matrix)들 중 적어도 하나에 기초하여 상기 출력 특징 데이터를 산출하는

교통 예측 전자 장치.

청구항 17

제15항에 있어서,

상기 프로세서는,

상기 복수의 히든 레이어들 중에서, 상기 히든 상태 데이터가 포함된 제1 레이어를 획득하고,

상기 복수의 히든 레이어들 중에서, 상기 제1 레이어의 이전 레이어를 나타내는 제2 레이어를 획득하고,

상기 제2 레이어에 관한 대상 히든 상태 데이터를 획득하고,

상기 출력 특징 데이터 또는 상기 대상 히든 상태 데이터 중 적어도 하나에 기초하여 상기 제1 레이어에 관한 히든 상태 데이터를 획득하는

교통 예측 전자 장치.

발명의 설명

기 술 분 야

[0001] 이하, 패턴 데이터를 활용한 교통 예측 방법 및 장치에 관한 기술이 제공된다.

배 경 기 술

[0002] 교통 예측은 복잡한 도로 네트워크와 도로에서 발생되는 다양한 이벤트로 인한 급격한 속도 변화로 인해 어려운 문제로 인식된다. 교통 예측 문제를 해결하기 위해 도로의 시간-공간 종속성을 학습하는데 초점을 맞춘 여러 모델들이 제안되었다. 최근 교통 예측을 위해 교통 데이터를 다양한 형태의 데이터로 변환하여 예측 문제를 해결한다.

[0003] 위에서 설명한 배경기술은 발명자가 본원의 개시 내용을 도출하는 과정에서 보유하거나 습득한 것으로서, 반드시 본 출원 전에 일반 공중에 공개된 공지기술이라고 할 수는 없다.

발명의 내용

해결하려는 과제

과제의 해결 수단

[0004] 일 실시예에 따른 교통 예측 전자 장치는, 교통 정보를 나타내는 교통 데이터를 획득하는 데이터 획득부; 컴퓨터로 실행 가능한 명령어들(computer-executable instructions)이 저장된 메모리; 상기 메모리에 억세스(access)하여 상기 명령어들을 실행하는 프로세서; 및 상기 프로세서와 전기적으로 연결된 디스플레이를 포함하고, 상기 명령어들은, 상기 입력된 교통 데이터로부터 추출된 패턴(pattern)에 기초하여 대표 패턴 데이터를 생성하고, 임베딩 행렬(embedding matrix)로부터 획득된 복수의 기억된 패턴들(memorized patterns) 및 상기 생성된 대표 패턴 데이터 간의 거리 데이터를 획득하고, 상기 대표 패턴 데이터 및 상기 거리 데이터에 기초하여, 상기 복수의 기억된 패턴들 중 적어도 일부 패턴과 상기 대표 패턴 데이터의 교통 정보의 분포를 나타내는 대표 기억 정보(representative memory information)를 생성하고, 상기 생성된 대표 기억 정보에 예측 모델을 적용한 것(또는 결과)에 기초하여, 상기 교통 데이터를 수집한 시점(time point) 이후의 교통 흐름에 관한 출력 교통 데이터를 예측할 수 있다.

[0005] 상기 프로세서는, 상기 입력된 교통 데이터를 미리 결정한(predetermined) 시간 간격(time period)을 기준으로 분할된 복수의 분할 패턴을 추출하고, 상기 복수의 분할 패턴들 간의 유사도(similarity)를 획득하고, 상기 획득된 유사도가 임계(threshold) 값 보다 큰 분할 패턴들에 기초하여, 클러스터링(clustering)을 통해 대상 분할 패턴들을 생성할 수 있다.

[0006] 상기 프로세서는, 상기 예측 모델의 복수의 히든 레이어(hidden layer) 중 적어도 하나의 레이어에 기초하여, 상기 임베딩 행렬들 중 상기 레이어에 해당하는 대상 임베딩 행렬을 선택하고, 상기 대상 임베딩 행렬로부터 획득된 기억된 패턴들 중 각각과 상기 대표 패턴 데이터에 거리 함수(distance function)를 적용함으로써, 상기 기억된 패턴들과 상기 대표 패턴 데이터 간의 거리 데이터를 획득하고, 상기 획득된 거리 데이터에 기초하여, 상기 기억된 패턴들 중 후보 패턴(candidate pattern)을 선택하고, 상기 임베딩 행렬에 상기 후보 패턴을 적용하여 기억 컨텍스트(memory context) 데이터를 획득하고, 상기 기억 컨텍스트 데이터 및 상기 거리 데이터에 기초하여, 상기 대표 기억 정보를 생성할 수 있다.

[0007] 상기 프로세서는, 상기 거리 데이터에 기초하여, 상기 기억된 패턴들 중 임계 값 보다 작은 거리 데이터를 포함하는 복수의 대상 후보 패턴들을 선택할 수 있다.

[0008] 상기 프로세서는, 상기 획득된 거리 데이터에 기초하여, 상기 복수의 기억된 패턴들 중에서 대상 기억된 패턴을 획득하고, 상기 대상 기억된 패턴 및 상기 대표 패턴 데이터 과의 차이를 통해 노이즈(noise) 데이터를 획득하고, 상기 입력된 교통 데이터를 수집한 시점에 관한 임베딩(embedding) 데이터를 획득하고, 상기 임베딩 데이터, 상기 노이즈 데이터, 또는 학습 가능한 행렬(learnable matrix) 중 적어도 하나에 기초하여, 상기 예측 모델의 초기 히든 상태(initial hidden state) 데이터를 산출하고, 상기 초기 히든 상태 데이터에 상기 예측 모델을 적용한 것에 기초하여, 교통 흐름에 관한 상기 출력 교통 데이터를 예측할 수 있다.

[0009] 상기 프로세서는, 상기 예측 모델의 복수의 히든 레이어(hidden layer)들에 대한 히든 상태(hidden state) 데이

터를 획득하고, 상기 복수의 히든 레이어들에 대한 출력 특징(output feature) 데이터를 산출하고, 상기 예측 모델에 대한 에너지(energy) 데이터를 산출하고, 상기 예측 모델의 전파 행렬(projection matrix)을 획득하고, 상기 출력 특징 데이터, 상기 에너지 데이터, 또는 상기 전파 행렬 중 적어도 하나에 기초하여 상기 출력 교통 데이터를 예측할 수 있다.

[0010] 상기 프로세서는, 상기 대표 기억 정보 또는 상기 히든 상태 데이터 중 적어도 하나에 기초하여 어텐션 스코어(attention score) 데이터를 산출하고, 상기 어텐션 스코어 데이터들에 기초하여, 상기 히든 레이어의 집중 행렬(attention matrix)을 획득하고, 상기 집중 행렬 또는 상기 예측 모델의 학습 가능한 행렬(learnable matrix)들 중 적어도 하나에 기초하여 상기 출력 특징 데이터를 산출할 수 있다.

[0011] 상기 프로세서는, 상기 복수의 히든 레이어들 중에서, 상기 히든 상태 데이터가 포함된 제1 레이어를 획득하고, 상기 복수의 히든 레이어들 중에서, 상기 제1 레이어의 이전 레이어를 나타내는 제2 레이어를 획득하고, 상기 제2 레이어에 관한 대상 히든 상태 데이터를 획득하고, 상기 출력 특징 데이터 또는 상기 대상 히든 상태 데이터 중 적어도 하나에 기초하여 상기 제1 레이어에 관한 히든 상태 데이터를 획득할 수 있다.

도면의 간단한 설명

[0012] 도 1은 일 실시예에 따른 교통 예측 시스템 및 교통 예측 전자 장치를 도시한 도면이다.

도 2는 일 실시예에 따른 교통 데이터로부터 패턴을 추출하는 방법을 도시한 도면이다.

도 3은 일 실시예에 따른 대표 패턴 데이터를 추출하는 방법을 도시한 도면이다.

도 4는 일 실시예에 따른 교통 데이터로부터 추출한 패턴들의 분포를 설명하는 도면이다.

도 5는 일 실시예에 따른 대표 기억 정보를 생성하는 방법을 도시한 도면이다.

도 6은 일 실시예에 따른 예측 모델을 도시한 도면이다.

도 7은 일 실시예에 따른 예측 모델에서 GCMem(graph convolutional memory networks)을 도시한 도면이다.

발명을 실시하기 위한 구체적인 내용

[0013] 실시예들에 대한 특정한 구조적 또는 기능적 설명들은 단지 예시를 위한 목적으로 개시된 것으로서, 다양한 형태로 변경되어 구현될 수 있다. 따라서, 실제 구현되는 형태는 개시된 특정 실시예로만 한정되는 것이 아니며, 본 명세서의 범위는 실시예들로 설명한 기술적 사상에 포함되는 변경, 균등물, 또는 대체물을 포함한다.

[0014] 제1 또는 제2 등의 용어를 다양한 구성요소들을 설명하는데 사용될 수 있지만, 이런 용어들은 하나의 구성요소를 다른 구성요소로부터 구별하는 목적으로만 해석되어야 한다. 예를 들어, 제1 구성요소는 제2 구성요소로 명명될 수 있고, 유사하게 제2 구성요소는 제1 구성요소로도 명명될 수 있다.

[0015] 어떤 구성요소가 다른 구성요소에 "연결되어" 있다고 언급된 때에는, 그 다른 구성요소에 직접적으로 연결되어 있거나 또는 접속되어 있을 수도 있지만, 중간에 다른 구성요소가 존재할 수도 있다고 이해되어야 할 것이다.

[0016] 단수의 표현은 문맥상 명백하게 다르게 뜻하지 않는 한, 복수의 표현을 포함한다. 본 명세서에서, "포함하다" 또는 "가지다" 등의 용어는 설명된 특징, 숫자, 단계, 동작, 구성요소, 부분품 또는 이들을 조합한 것이 존재함으로 지정하려는 것이지, 하나 또는 그 이상의 다른 특징들이나 숫자, 단계, 동작, 구성요소, 부분품 또는 이들을 조합한 것들의 존재 또는 부가 가능성을 미리 배제하지 않는 것으로 이해되어야 한다.

[0017] 본 문서에서, "A 또는 B", "A 및 B 중 적어도 하나", "A 또는 B 중 적어도 하나", "A, B 또는 C", "A, B 및 C 중 적어도 하나", 및 "A, B, 또는 C 중 적어도 하나"와 같은 문구들 각각은 그 문구들 중 해당하는 문구에 함께 나열된 항목들 중 어느 하나, 또는 그들의 모든 가능한 조합을 포함할 수 있다.

[0018] 다르게 정의되지 않는 한, 기술적이거나 과학적인 용어를 포함해서 여기서 사용되는 모든 용어들은 해당 기술분야에서 통상의 지식을 가진 자에 의해 일반적으로 이해되는 것과 동일한 의미를 가진다. 일반적으로 사용되는 사전에 정의되어 있는 것과 같은 용어들은 관련 기술의 문맥상 가지는 의미와 일치하는 의미를 갖는 것으로 해석되어야 하며, 본 명세서에서 명백하게 정의하지 않는 한, 이상적이거나 과도하게 형식적인 의미로 해석되지 않는다.

[0019] 이하, 실시예들을 첨부된 도면들을 참조하여 상세하게 설명한다. 첨부 도면을 참조하여 설명함에 있어, 도면

부호에 관계없이 동일한 구성 요소는 동일한 참조 부호를 부여하고, 이에 대한 중복되는 설명은 생략하기로 한다.

[0020] 도 1은 일 실시예에 따른 교통 예측 시스템 및 교통 예측 전자 장치를 도시한 도면이다.

[0021] 일 실시예에 따른 전자 장치(100)(예: 교통 예측 전자 장치)는 교통 데이터(traffic data)를 이용하여 출력 교통 데이터를 예측할 수 있다. 교통 데이터는 도로(150)에 설치된 관측 장비에 기초하여 관측 시각 별로 관측 대상(160) 및/또는 도로(150)를 관측한 데이터를 나타낼 수 있다. 출력 교통 데이터는 교통 데이터를 관측한 시각 이후의 관측 대상(160)들의 교통량을 포함하는 데이터를 나타낼 수 있다.

[0022] 예를 들어, 전자 장치(100)는 프로세서(102), 메모리(104), 디스플레이(106), 및 통신 모듈(108)을 포함할 수 있다.

[0023] 도로 시스템(120)은 복수의 관측 장비들(110, 112, 및 114), 도로(150), 또는 관측 대상(160) 중 적어도 하나를 포함할 수 있다. 예를 들어, 관측 대상(160)은 도로를 주행하는 차량(vehicle)(예: 자동차(automobile) 또는 오토바이(motorcycle))를 포함할 수 있다.

[0024] 예를 들어, 관측 장비는 데이터 획득부 및 통신 모듈을 포함할 수 있다. 제1 관측 장비(110)는 도로(150)에 설치되어 데이터 획득부를 통해 교통 데이터를 획득할 수 있다. 예를 들어, 데이터 획득부는 도로(150) 바닥에 매설된 루프 코일(loop coil) 모듈 또는 레이저(laser) 모듈 중 적어도 하나의 모듈을 포함할 수 있다. 제1 관측 장비(110)는 관측 대상(160)과 관련된 교통 데이터를 측정할 수 있다. 교통 데이터는 관측 대상(160)의 속도, 도로(150)의 흐름(flow), 또는 관측 시간(time) 중 적어도 하나를 포함할 수 있다. 본 명세서에서는 설명의 편의를 위해, 도로(150)에 있는 신호등에 관측 장비가 장착되어 레이저 모듈에 의해 교통 데이터로서 주로 관측 대상(160)의 속도를 수집하는 예시를 설명한다.

[0025] 도 1에 도시된 예시에서 제2 관측 장비(112)에 의해 획득된 교통 데이터는 관측 대상의 속도 데이터(145)를 포함할 수 있다. 관측 대상의 속도 데이터(145)는 제2 관측 장비(112)에서 복수의 관측 대상(160)의 측정된 속도를 나타낼 수 있다. 관측 장비는 측정된 교통 데이터를 통신 모듈을 이용하여 전자 장치(100)로 송신할 수 있다. 구체적으로, 관측 장비의 통신 모듈은 유선 또는 무선 네트워크 중 적어도 하나의 네트워크에 의해 전자 장치(100)의 통신 모듈(108)과 통신할 수 있다.

[0026] 프로세서(102)는, 교통 데이터에 기초하여, 출력 교통 데이터를 획득할 수 있다. 프로세서(102)는 소프트웨어를 실행할 수 있고, 프로세서(102)에 연결된 적어도 하나의 다른 구성요소(예: 하드웨어 또는 소프트웨어 구성요소)를 제어할 수 있다. 프로세서(102)는 이외에도 다양한 데이터 처리 또는 연산을 수행할 수 있다. 예를 들어, 프로세서(102)는 제1 관측 장비(110)로부터 수신된 교통 데이터를 메모리(104)에 저장할 수 있다. 프로세서(102)는 후술하는 대표 기억 정보(representative memory information)에 예측 모델을 적용하는 방법을 이용하여 출력 교통 데이터를 결과 데이터로서 디스플레이(106)를 통해 출력할 수 있다.

[0027] 메모리(104)는 출력 교통 데이터를 예측하기 위해 요구되는 다양한 데이터 및/또는 정보를 임시적으로 및/또는 영구적으로 저장할 수 있다. 예를 들어, 메모리(104)는 교통 데이터, 대표 패턴, 대표 기억 정보, 예측 모델, 또는 출력 교통 데이터 중 적어도 하나를 저장할 수 있다.

[0028] 디스플레이(106)는 출력 교통 데이터를 사용자에게 시각적으로 제공할 수 있다. 예를 들어, 디스플레이(106)는 터치를 감지하도록 설정된 터치 센서, 또는 상기 터치에 의해 발생되는 힘의 세기를 측정하도록 설정된 압력 센서를 포함할 수 있다. 다만, 이로 한정하는 것은 아니고, 디스플레이(106)는, 예를 들면, 디스플레이, 홀로그램 장치, 또는 프로젝터 및 해당 장치를 제어하기 위한 제어 회로를 포함할 수 있다.

[0029] 통신 모듈(108)은 전자 장치(100)의 외부 장치(예: 제1 관측 장비(110))와 유선 및/또는 무선 통신을 수립할 수 있다. 통신 모듈(158)은 외부 장치로부터 교통 데이터를 수신할 수 있다

[0030] 도 2는 일 실시예에 따른 교통 데이터로부터 패턴을 추출하는 방법을 도시한 도면이다.

[0031] 일 실시예에 따른 전자 장치(예: 도 1의 전자 장치(100))는, 교통 데이터로부터 패턴 데이터(pattern data)(210)를 생성할 수 있다. 예를 들어, 교통 데이터는 복수의 관측 장비 중 적어도 하나의 관측 장비(예: 도 1의 제1 관측 장비(110))가 측정한 복수의 관측 대상의 속도들을 포함할 수 있다. 본 명세서에서는, 패턴 데이터(210) 및/또는 패턴(pattern)은 관측 장비가 관측 시각 별로 측정한 속도들의 일정한 형태 또는 변화하는 형태 중 적어도 하나를 포함하는 유형(type)을 포함하는 데이터를 나타낼 수 있다. 구체적으로, 본 명세서에서는 설명의 편의를 위해, 패턴 데이터(210)를 복수의 속도가 포함된 벡터(vector) 데이터의 형태로서 주로 설명

한다. 도 2에 도시된 그래프(200)에서 가로 축은 초 단위의 시간을 나타낼 수 있고, 세로 축은 km/h 단위의 속도를 나타낼 수 있다.

[0032] 전자 장치는, 관측 장비에 의해 측정된 속도들에 기초하여 패턴 데이터(210)를 생성할 수 있다. 전자 장치는, 생성된 패턴 데이터(210)를 미리 결정된(predetermined) 시간 간격(time interval)으로 분할 패턴 데이터(230)를 생성할 수 있다. 이하 도 3에서는, 분할 패턴 데이터(230)들 중 유사한 패턴들을 기초로 조합된 대표 패턴 데이터를 생성하는 방법을 후술한다.

[0033] 도 3은 일 실시예에 따른 대표 패턴 데이터를 추출하는 방법을 도시한 도면이다.

[0034] 일 실시예에 따른 전자 장치(예: 도 1의 전자 장치(100))는 유사 패턴 그룹(310)으로부터 조합된 대표 패턴 데이터(320)를 생성할 수 있다. 유사 패턴 그룹(310)은 교통 데이터로부터 추출된 패턴 데이터(예: 도 2의 패턴 데이터(210))들을 분할한 패턴 데이터(예: 도 2의 분할 패턴 데이터(230))들을 포함할 수 있다. 구체적으로, 유사 패턴 그룹(310)은 분할 패턴 데이터들 중 서로 유사한 패턴을 가지는 분할 패턴 데이터들의 그룹으로서, 복수의 분할 패턴 데이터들 중 서로에 대한 유사도가 임계(threshold) 값 보다 큰 분할 패턴들을 포함할 수 있다.

[0035] 분할 패턴 데이터들 간의 유사도는, 예를 들어, 코사인 유사도(cosine similarity), 유클리드 거리(Euclidean Distance), 또는 자카드 유사도(Jaccard similarity) 중 적어도 하나를 포함하는 수학적 척도일 수 있다. 본 명세서에서는, 설명의 편의를 위해, 코사인 유사도를 통해 분할 패턴 데이터들 간의 유사도를 획득하는 방법을 주로 설명하나, 이로 한정하는 것은 아니다. 전자 장치는, 복수의 분할 패턴 데이터들 중 제1 분할 패턴 데이터 및 제2 분할 패턴 데이터 간의 코사인 유사도를 계산할 수 있다. 예를 들어, 코사인 유사도는 시점(time point) 별로 제1 분할 패턴 데이터의 속도 및 제2 분할 패턴 데이터의 속도에 대해 계산될 수 있다. 여기서, 전자 장치는 제1 분할 패턴 데이터 및 제2 분할 패턴 데이터의 코사인 유사도의 절대값(absolute value)이 임계값 보다 큰 경우, 제1 분할 패턴 데이터 및 제2 분할 패턴 데이터를 유사 패턴 그룹(310)에 포함시킬 수 있다. 전자 장치는 유사 패턴 그룹(310)에 포함된 패턴 데이터들을 클러스터링(clustering)을 통해 대표 패턴 데이터(320)를 생성할 수 있다. 대표 패턴 데이터(320)는 유사 패턴 그룹(310)에 포함된 복수의 패턴 데이터들을 대표하는 패턴 데이터를 나타낼 수 있다. 전자 장치는 대표 패턴 데이터(320)에 기초하여 도 5에서 후술하는, 대표 기억 정보를 생성할 수 있다.

[0036] 도 4는 일 실시예에 따른 교통 데이터로부터 추출한 패턴들의 분포를 설명하는 도면이다.

[0037] 일 실시예에 따른 전자 장치(예: 도 1의 전자 장치(100))는 교통 데이터로부터 추출한 패턴들의 분포들을 획득할 수 있다. 전자 장치는 제1 분포(410) 및 제2 분포(430) 분포를 획득할 수 있다. 도 4에 도시된 그래프에서 가로 축은 유사도를 나타낼 수 있고, 세로 축은 패턴들의 수를 나타낼 수 있다.

[0038] 예를 들어, 제1 분포(410)는 초기 교통 데이터 분포를 나타낼 수 있다. 초기 교통 데이터 분포는 패턴 데이터(예: 도 2의 패턴 데이터(210))들을 분할한 분할 패턴(예: 도 2의 분할 패턴(230))들 간의 유사도에 따라 정렬한 분포를 나타낼 수 있다. 여기서, 유사 영역(420)은 유사 패턴 그룹(예: 도 3의 유사 패턴 그룹(310))에 포함된 패턴들을 포함하는 영역을 나타낼 수 있다. 전자 장치는, 유사 영역(420)에 속한 패턴 데이터들에 대하여, 클러스터링을 통해 대표 패턴 데이터를 생성하여 후술하는 제2 분포(430)를 생성할 수 있다.

[0039] 제2 분포(430)는 변환된 교통 데이터 분포를 나타낼 수 있다. 변환된 교통 데이터 분포는 초기 교통 데이터 분포에서 유사 영역(420)에 속한 패턴 데이터들을 제외한 패턴 데이터들 및 클러스터링을 통해 생성된 대표 패턴 데이터(예: 도 3의 대표 패턴 데이터(320))들을 포함하는 패턴 데이터들 간의 유사도에 따라 정렬한 분포를 나타낼 수 있다.

[0040] 도 5는 일 실시예에 따른 대표 기억 정보를 생성하는 방법을 도시한 도면이다.

[0041] 일 실시예에 따른 전자 장치(예: 도 1의 전자 장치(100))는 입력 패턴 데이터(510) 및 거리 데이터(530)에 기초하여, 복수의 기억된 패턴들(memorized patterns)(520) 중 적어도 일부 패턴인 후보 패턴들(candidate patterns)(540)과 입력 패턴 데이터(510)의 교통 정보의 분포를 나타내는 대표 기억 정보(570)를 생성할 수 있다. 예를 들어, 입력 패턴 데이터(510)는 기억된 패턴들(520)과 다른 패턴 데이터로서 도 6에서 후술하는 예측 모델의 입력 데이터를 나타낼 수 있다. 전자 장치는 기억된 패턴들(520)을 도 6에서 후술하는 예측 모델에 포함된 임베딩 행렬(embedding matrix)로부터 획득할 수 있다. 임베딩 행렬은 복수의 기억된 패턴들(520) 및 기억된 패턴들(520)에 상응하는 기억 컨텍스트 데이터(memory context)(550)를 포함할 수 있다. 기억된 패턴들

(520)은 도 3에서 설명된 동작에 의해 생성된 패턴을 포함할 수 있다.

[0042] 일 실시예에 따른 거리 데이터(530)(d_j)는 다음과 같이 계산될 수 있다:

[0043] [수학식 1]

[0044] $$d_j = g(X_i, p_j)$$

[0045] 여기서 i는 입력 패턴 데이터(510)의 인덱스를 나타내고, X_i는 i번째 입력 패턴 데이터(510)를 나타내고, j는 기억된 패턴들(520)에서 선택된 후보 패턴들(540)의 인덱스(index)를 나타낼 수 있다. 또한, p_j는 후보 패턴(예: 제1 후보 패턴(542) 내지 제3 후보 패턴(546))을 나타내고, d_j는 인덱스 j를 가지는 후보 패턴의 거리 데이터(530)를 나타내고, g는 거리 함수(distance function)를 나타낼 수 있다.

[0046] 전자 장치는 입력 패턴 데이터(510) 및 기억된 패턴들(520)에 기초하여, 기억된 패턴들(520) 중 각각과 입력 패턴 데이터(510)에 거리 함수를 적용함으로써 거리 데이터(530)들을 획득할 수 있다. 예를 들어, 전자 장치는 최근접 이웃 거리 함수(nearest neighbor distance function)를 거리 함수로 사용함으로써 거리 데이터(530)들을 획득할 수 있다. 거리 데이터(530)는 기억된 패턴들(520) 중 각각과 입력 패턴 데이터(510)의 유사한 정도(level)를 나타내는 척도(measure) 중 하나일 수 있다. 구체적으로, 거리 데이터(530)는, 기억된 패턴들(520) 중 각각과 입력 패턴 데이터(510) 간의 유사할 수록 작은 거리 점수(예: 거리 값)을 포함할 수 있다. 예시적으로 거리 점수는 패턴들 간에 거리 함수를 적용한 결과 값일 수 있다.

[0047] 전자 장치는 획득된 거리 데이터(530)들에 기초하여, 기억된 패턴들(520) 중 후보 패턴들(540)을 획득할 수 있다. 예를 들어, 전자 장치는 후보 패턴들의 미리 결정된 수에 기초하여 후보 패턴들(540)을 획득할 수 있다. 본 명세서에서는 설명의 편의를 위해 기억된 패턴들(520) 중 거리 데이터(530)가 최소인 3개의 패턴들을 후보 패턴들(540)로서 획득하는 예시를 주로 설명한다. 후보 패턴들(540)은 제1 후보 패턴(542), 제2 후보 패턴(544), 또는 제3 후보 패턴(546) 중 적어도 하나 이상의 패턴들을 포함할 수 있다. 제1 후보 패턴(542)은 기억들 패턴들(520) 중에서 입력 패턴 데이터(510)와 가장 유사한 패턴을 포함할 수 있다. 제2 후보 패턴(544)은 기억들 패턴들(520) 중에서 입력 패턴 데이터(510)와 두번째 유사한 패턴을 포함할 수 있다. 제3 후보 패턴(546)은 기억들 패턴들(520) 중에서 입력 패턴 데이터(510)와 세번째 유사한 패턴을 포함할 수 있다.

[0048] 일 실시예에 따르면, 기억 컨텍스트 데이터(550)($\mathbf{m}_j^l$)는 다음과 같이 계산될 수 있다:

[0049] [수학식 2]

[0050] $$\mathbf{m}_j^l = \mathbf{M}^l(p_j)$$

[0051] 여기서, l은 레이어를 나타내고, $\mathbf{M}^l$은 레이어 l의 임베딩 행렬을 나타내고, $\mathbf{m}_j^l$은 레이어 l에서 인덱스 j를 가지는 후보 패턴의 기억 컨텍스트 데이터(550)를 나타낼 수 있다.

[0052] 전자 장치는 임베딩 행렬에 기초하여, 후보 패턴들(540)의 기억 컨텍스트 데이터(550)를 획득할 수 있다. 예를 들어, 전자 장치는 후보 패턴들(540) 각각에 임베딩 행렬을 적용함으로써 기억 컨텍스트 데이터(550)를 획득할 수 있다. 기억 컨텍스트 데이터(550)는 후보 패턴들(540) 중 각각의 메모리 정보를 포함하는 벡터(vector) 데이터를 포함할 수 있다.

[0053] 일 실시예에 따르면, 대표 기억 정보(570)(M_i^l)는 다음과 같이 계산될 수 있다:

[0054] [수학식 3]

[0055] $$M_i^l = \sum_{j=1}^{k} \text{Softmax}(-d_j)\mathbf{m}_j^l$$

[0056] 여기서 k는 후보 패턴들(540)의 수를 나타내고, Softmax는 활성함수를 나타낼 수 있다. 또한, M_i^l은 레이어 l의 i 번째 입력 패턴 데이터(510)에 관한 대표 기억 정보(570)를 나타낼 수 있다.

[0057] 전자 장치는 거리 데이터(530) 및 후보 패턴들(540)의 기억 컨텍스트 데이터(550)에 기초하여, 후보 패턴들(540)과 입력 패턴 데이터(510)의 교통 정보의 분포를 나타내는 대표 기억 정보(570)를 생성할 수 있다. 예를 들어, 전자 장치는 거리 데이터(530)에 활성함수(activation function)를 적용하여 출력한 값과 기억 컨텍스트 데이터(550)에 기초하여 대표 기억 정보(570)를 생성할 수 있다. 전자 장치는 Softmax 함수를 활성함수로서 대표 기억 정보(570)를 생성할 수 있다. 다만, 도 5에서 Softmax 함수를 활성함수로서 설명하였으나 이로 한정하는 것은 아니다. 다른 예를 들어, 전자 장치는 ReLU(Rectified Linear Unit), Sigmoid, 또는 Tanh 함수 중 적어도 하나의 함수를 활성함수로서 거리 데이터(530)에 적용하여 출력한 값과 기억 컨텍스트 데이터(550)에 기초하여 대표 기억 정보(570)를 생성할 수 있다. 대표 기억 정보(570)는 입력 패턴 데이터(510) 및 후보 패턴들(540)과의 거리 데이터(530)에 기초하여 생성된 기억 컨텍스트 데이터(550)를 포함할 수 있다.

[0058] 전자 장치는 생성된 대표 기억 정보(570)에, 후술하는 예측 모델을 적용하여 입력 패턴 데이터(510)를 수집한 시점(time point) 이후의 교통 흐름에 관한 출력 교통 데이터를 예측할 수 있다. 예측 모델 및 출력 교통 데이터에 관한 설명은 하기 도 6 내지 도 7에서 후술한다.

[0059] 도 6은 일 실시예에 따른 예측 모델을 도시한 도면이다.

[0060] 일 실시예에 따른 전자 장치(예: 도 1의 전자 장치(100))는 예측 모델(600)을 포함할 수 있다. 예측 모델(600)은 인코더(encoder)(610) 및 디코더(decoder)(620)를 포함할 수 있다. 인코더(610) 및 디코더(620)는 복수의 GCMem(Graph Convolutional Memory networks)을 포함할 수 있다.

[0061] 전자 장치는 인코더(610)에서 초기 히든 상태 데이터(630)에 GCMem을 적용하여 히든 상태 데이터(hidden state data)를 계산할 수 있다. 전자 장치는 이전 레이어에 있는 GCMem의 히든 상태 데이터에 기초하여, 현재 레이어에 있는 GCMem의 히든 상태 데이터를 계산할 수 있다. 예를 들어, 히든 상태 데이터(660)는 GCMem의 출력 데이터를 나타낼 수 있다. 구체적으로, 히든 상태 데이터(660)는, 예측 모델(600)이 복수의 레이어를 포함하는 경우에 기초하여, 전자 장치가 다음 레이어에서 출력 값을 계산하기 위해 사용되는 데이터를 나타낼 수 있다. 초기 히든 상태 데이터(630)는 입력 패턴 데이터(510)와 제1 후보 패턴(614)의 차이를 포함할 수 있다. 예를 들어, 전자 장치는 노이즈 데이터, 학습 가능한 행렬, 및 임베딩 데이터에 기초하여 초기 히든 상태 데이터(630)를 계산할 수 있다. 노이즈 데이터는 입력 패턴 데이터(510) 및 제1 후보 패턴(614)의 차이를 통해 획득될 수 있다. 학습 가능한 행렬은 하기 도 7에서 후술한다. 임베딩 데이터는 입력 패턴 데이터(510)의 시간 정보를 포함할 수 있다. 제1 후보 패턴(614)은 후보 패턴들(540) 중 거리 데이터(예: 도 5의 거리 데이터(530))가 가장 작은 패턴을 나타낼 수 있다.

[0062] 일 실시예에 따르면, 초기 히든 상태 데이터(630)(h_i^0)는 다음과 같이 계산될 수 있다:

[0063] [수학식 4]

[0064] $$h_i^0 = emb(T) + W_n N_i$$

[0065] 여기서, $emb(T)$는 임베딩 데이터를 나타내고, N_i는 i 번째 입력 패턴 데이터(510)에 관한 노이즈 데이터를 나타내고, W_n은 도 7에서 후술하는 학습 가능한 행렬을 나타내고, h_i^0는 i 번째 입력 패턴 데이터(510)에 관한 초기 히든 상태 데이터(630)를 나타낼 수 있다. 또한, 노이즈 데이터인 N_i는 $N_i = X_i - p_1$에 기초하여

계산될 수 있다. 구체적으로, X_i 는 i 번째 입력 패턴 데이터(510)를 나타내고, p_1은 제1 후보 패턴(614)을 나타낼 수 있다.

[0066] 전자 장치는 획득된 초기 히든 상태 데이터(630)에 복수의 GCMem을 적용하여 레이어 '1'의 히든 상태 데이터(660)를 계산할 수 있다. 예를 들어, 전자 장치는 초기 히든 상태 데이터(630)를 첫번째 레이어에 있는 GCMem에 적용할 수 있다. 전자 장치는 레이어 '1-1'에서 계산된 히든 상태 데이터를 사용하여 레이어 '1'의 히든 상태 데이터(660)를 계산할 수 있다.

[0067] 일 실시예에 따르면, 히든 상태 데이터(660)는 다음과 같이 계산될 수 있다:

[0068] [수학식 5]

[0069] $$h^l = h^{l-1} + o^l$$

[0070] 여기서, h^{l-1} 은 레이어 $l-1$에 있는 GCMem(예: 도 6에 도시된 GCMem(650)에서 아래에 있는 GCMem에서 출력한 히든 상태 데이터를 나타내고, o^l 은 레이어 l의 출력 특징 데이터를 나타낼 수 있다. 참고로, 출력 특징 데이터를 획득하는 방법은 하기 도 7에서 후술한다. 또한, h^l 은 레이어 l에 있는 GCMem(650)에서 출력한 히든 상태 데이터(660)를 나타낼 수 있다. 히든 상태 데이터(660)를 계산하는 GCMem(650)은 하기 도 7에서 후술한다.

[0071] 디코더(720)는 GCMem(650), GRU Cell(740), 및 레이어-레벨 어텐션(layer-level attention)(655)을 포함할 수 있다. 전자 장치는 인코더(610)에서 출력한 히든 상태 데이터(660) 또는 디코더(720)에서의 출력 데이터(예: 복수의 시점 중 하나의 시점에 대한 출력 교통 데이터) 중 적어도 하나를 GRU Cell(740)에 적용할 수 있다. 예를 들어, GRU Cell(740)은 게이트 메커니즘(gate mechanism)이 적용된 순환 신경망(recurrent neural network, RNN)을 포함할 수 있다.

[0072] 전자 장치는 각 레이어에 있는 GCMem에서 획득한 히든 상태 데이터들에 레이어-레벨 어텐션(655)을 적용하여 출력 교통 데이터(670)를 예측할 수 있다. 예를 들어, 레이어-레벨 어텐션(655)은 기계 학습을 통해 생성된 복수의 인공 신경망 레이어들을 포함할 수 있다. 구체적으로, 전자 장치는 첫 번째 레이어에 있는 GCMem에서 입력 패턴 데이터(510)에 가까운 히든 상태 데이터를 획득할 수 있다. 이와 달리, 전자 장치는 레이어 '1'에 있는 GCMem에서는 메모리 정보(예: 도 5의 대표 기억 정보(570))를 반영한 히든 상태 데이터를 획득할 수 있다. 전자 장치는, 각 레이어의 GCMem에서 출력한 히든 상태 데이터들을 레이어-레벨 어텐션(655)에 적용하여, 각 레이어에서 획득한 히든 상태 데이터들을 반영한 출력 교통 데이터(670)를 획득할 수 있다.

[0073] 전자 장치는, 레이어-레벨 어텐션(655)에 기초하여, 입력 패턴 데이터(510)를 수집한 시점(time point) 이후의 교통 흐름에 관한 복수의 출력 교통 데이터(670)를 예측할 수 있다. 여기서, 출력 교통 데이터(670)는 복수의 속도를 포함할 수 있다. 예를 들어, 출력 교통 데이터(670)는 디코더(620)에서 시점(time point) 별로 예측하는 속도들을 포함할 수 있다. 다만, 출력 교통 데이터(670)를 이로 한정하는 것은 아니고, 복수의 속도 및 시간을 포함할 수 있다.

[0074] 일 실시예에 따르면, 출력 교통 데이터(670)는 다음과 같은 식에 기초하여 계산될 수 있다:

[0075] [수학식 6]

[0076] $$\hat{y}_i^t = \sum_{l}^{L} \alpha_{i,l} o_i^l W_{proj}$$

[0077] 여기서, L 은 예측 모델(600)의 레이어(layer) 개수를 나타내고, W_{proj} 은 예측 모델(600에서 최종 출력(예: 출력 교통 데이터(670))을 생성하기 위한 프로젝션 레이어(projection layer)를 나타낼 수 있다. 또한, $\alpha_{i,l}$은

i 번째 입력 패턴 데이터(510) 및 레이어 l에 있는 레이어-레벨 어텐션(655)의 어텐션 스코어를 나타내고, o_i^l은 i 번째 입력 패턴 데이터(510)에 관하여 레이어 l에 있는 GCMem(650)에서 획득한 출력 특징 데이터를 나타낼 수 있다. 참고로, 출력 특징 데이터(o_i^l)를 획득하는 방법은 하기 도 7에서 후술한다. $\hat{y}_i^t$는 i 번째 입력 패턴 데이터(510)에 대해, 복수의 출력 교통 데이터(670) 중 시점(time point) t의 출력 교통 데이터를 나타낼 수 있다.

[0078] 참고로, 레이어-레벨 어텐션(655)의 어텐션 스코어 $\alpha_{i,l}$은 다음과 같은 식에 기초하여 계산될 수 있다:

[0079] [수학식 7]

[0080] $$\alpha_{i,l} = \text{Softmax}(e_{i,l})$$

[0081] 여기서 $e_{i,l}$은 i 번째 입력 패턴 데이터(510) 및 레이어 l에 있는 레이어-레벨 어텐션(655)의 에너지(energy) 데이터를 나타낼 수 있다.

[0082] 참고로, 에너지 데이터($e_{i,l}$)은 다음과 같은 식에 기초하여 계산될 수 있다:

[0083] [수학식 8]

[0084] $$e_{i,l} = \frac{(h_i^{l-1})(M_i^l W^l)^\top}{\sqrt{d_h}}$$

[0085] 여기서, h_i^{l-1}은 i 번째 입력 패턴 데이터(510) 및 레이어 $l-1$의 히든 상태 데이터를 나타내고, M_i^l은 대표 기억 정보(예: 도 5의 대표 기억 정보(570))를 나타낼 수 있다. 또한, W^l은 학습 가능한 행렬을 나타내고, d_h는 예측 모델(600)에서 히든 사이즈(hidden size)를 나타낼 수 있다.

[0086] 도 7은 일 실시예에 따른 예측 모델에서 GCMem을 도시한 도면이다.

[0087] 일 실시예에 따른 전자 장치(예: 도 1의 전자 장치(100))는 레이어 'l-1' 의 히든 상태 데이터(704) 및 출력 특징 데이터(708)에 기초하여 레이어 'l' 의 히든 상태 데이터(660)를 계산할 수 있다. 레이어 'l-1' 의 히든 상태 데이터(704)는 레이어 'l-1' 의 GCMem(702)에 의해 계산된 히든 상태 데이터를 나타낼 수 있다.

[0088] GCMem(650)은 기계 학습을 통해 생성될 수 있다. 학습 알고리즘은, 예를 들어, 지도형 학습(supervised learning), 비지도형 학습(unsupervised learning), 준지도형 학습(semi-supervised learning) 또는 강화 학습(reinforcement learning)을 포함할 수 있으나, 전술한 예에 한정되지 않는다. GCMem(650), 복수의 인공 신경망 레이어들을 포함할 수 있다. 인공 신경망은 심층 신경망(DNN: deep neural network), CNN(convolutional neural network), RNN(recurrent neural network), RBM(restricted boltzmann machine), DBN(deep belief network), BRDNN(bidirectional recurrent deep neural network), 심층 Q-네트워크(deep Q-networks) 또는 상기 중 둘 이상의 조합 중 하나일 수 있으나, 전술한 예에 한정되지 않는다. 참고로 지도형 학습의 경우, 상술한 GCMem(650)은 트레이닝 입력(예를 들어, 트레이닝을 위한 패턴 데이터) 및 해당 트레이닝 입력에 매핑된 트레이닝 출력(예를 들어, 트레이닝을 위한 출력 교통 데이터)의 쌍을 포함하는 트레이닝 데이터에 기초하여 트레이닝될 수 있다. 예를 들어, GCMem(650)은 트레이닝 입력으로부터 트레이닝 출력을 출력하도록 트레이닝될 수 있다. 트레이닝 중의 GCMem(650)은 트레이닝 입력에 응답하여 임시 출력을 생성할 수 있고, 임시 출력 및 트레이닝 출력(예를 들어, 참값) 간의 손실이 최소화되도록 트레이닝될 수 있다. 트레이닝 과정 동안 기계 학습 모델의 파라미터(예를 들어, 뉴럴 네트워크에서 노드들/레이어들 간의 연결 가중치)가 손실에 따라 업데이트될 수 있다. 이러한 학습은, 예를 들어, GCMem(650)이 수행되는 전자 장치 자체에서 수행될 수 있고, 별도의 서버를 통해 수행될 수도 있다. 학습이 완료된 GCMem(650)은 메모리에 저장될 수 있다.

[0089] 전자 장치는 레이어 'l+1'의 대표 기억 정보(712), 제1 학습 가능한 행렬(learnable matrix)(722), 제2 학습 가능한 행렬(724), 인접 행렬(adjacency matrix)(726), 및 집중 행렬(attention matrix)(728)에 기초하여 출력 특징 데이터(708)를 계산할 수 있다. 예를 들어, 학습 가능한 행렬(예: 제1 학습 가능한 행렬(722) 및 제2 학습 가능한 행렬(724))은 학습 파라미터(parameter)들을 포함할 수 있다. 구체적으로, 학습 파라미터는 GCMem(650)의 학습 과정에서 생성되는 변수(variable)를 나타낼 수 있다.

[0090] 일 실시예에 따르면, 출력 특징 데이터(708)(o^l)는 다음과 같이 계산될 수 있다:

[0091] [수학식 9]

$$o^l = \sum_{i}^{h} \left(W_{A,i}^{l} M^{l+1} A + W_{\tilde{A},i}^{l} M^{l+1} \tilde{A} + W_{C,i}^{l} M^{l+1} C^{l} \right)$$

[0092]

[0093] 여기서, A 는 인접 행렬(726)을 나타내고, $\tilde{A}$ 은 제2 학습 가능한 행렬(724)을 나타내고, M^{l+1}은 레이어 $l+1$ 의 대표 기억 정보(712)를 나타낼 수 있다. 또한, C^l 은 레이어 l 의 집중 행렬(728)을 나타내고, W^l 은 제1 학습 가능한 행렬(722)을 나타낼 수 있다.

[0094] 참고로, W^l 은 레이어 l 에 있는 GCMem(650)의 학습 파라미터들을 포함할 수 있다. 구체적으로, i 번째 입력 패턴 데이터(510)에 기초하여, $W_{A,i}^{l}$ 은 인접 행렬(726)에 관한 학습 파라미터를 나타낼 수 있고, $W_{\tilde{A},i}^{l}$은 제2 학습 가능한 행렬(724)에 관한 학습 파라미터를 나타낼 수 있고, $W_{C,i}^{l}$은 집중 행렬(728)에 관한 학습 파라미터를 나타낼 수 있다.

[0095] 제1 학습 가능한 행렬(722)은 레이어 'l'에서 출력 특징 데이터(708)를 획득하기 위한 파라미터(parameter)를 나타낼 수 있다. 제2 학습 가능한 행렬(724)은 후술하는 인접 행렬(726)과 달리, 도로(예: 도 1의 도로(150))의 복수의 관측 장비들의 간접적인(indirect) 연결(connection) 관계를 이차원 배열로 나타내는 행렬을 포함할 수 있다. 예를 들어, 제2 학습 가능한 행렬(724)은, 제1 관측 장비(예: 도 1의 제1 관측 장비(110)) 및 제2 관측 장비(예: 도 1의 제2 관측 장비(112))의 간접적인 연결을 포함할 수 있다. 인접 행렬(726)은 도로에서 복수의 관측 장비들의 직접적인 연결 관계를 이차원 배열로 나타내는 행렬을 포함할 수 있다. 예를 들어, 전자 장치는 제1 관측 장비 및 제3 관측 장비(예: 도 1의 제3 관측 장비(114))는 직접 연결된 정보를 포함하는 인접 행렬(726)을 획득할 수 있다. 집중 행렬(728)은 레이어 'l'의 대표 기억 정보(710)에 기초하여 도로의 연결 관계를 이차원 배열로 나타내는 행렬을 포함할 수 있다. 구체적으로, 집중 행렬(728)은 입력 데이터의 패턴-레벨(pattern-level) 어텐션 스코어(attention score)들을 포함할 수 있다.

[0096] 일 실시예에 따르면, GCMem(650)에서 집중 행렬(728)의 i 번째 행(row) 및 j번째 열(column)에 있는 어텐션 스코어($\alpha_{i,j}^{l}$)는 다음과 같이 계산될 수 있다:

[0097] [수학식 10]

$$\alpha_{i,j}^{l} = \mathrm{Softmax}\left(\frac{h_i^{l-1} (M_j^l)^{\top}}{\sqrt{d_h}} \right)$$

[0098]

[0099] 여기서, h_i^{l-1} 은 i 번째 입력 패턴 데이터(510) 및 레이어 $l-1$ 의 히든 상태 데이터를 나타내고, M_j^l은 j번째 입력 패턴 데이터(510) 및 대표 기억 정보(예: 도 5의 대표 기억 정보(570))를 나타낼 수 있다.

[0100] 예를 들어, 레이어 '1'의 어텐션 스코어는 레이어 '1-1'의 히든 상태 데이터, 레이어 '1'의 대표 기억 정보(710), 및 히든 사이즈(hidden size)에 기초하여 계산될 수 있다. 여기서 히든 사이즈는 예측 모델(예: 도 6의 예측 모델(600))에서 히든 레이어의 개수를 포함할 수 있다.

[0101] 이상에서 설명된 실시예들은 하드웨어 구성요소, 소프트웨어 구성요소, 및/또는 하드웨어 구성요소 및 소프트웨어 구성요소의 조합으로 구현될 수 있다. 예를 들어, 실시예들에서 설명된 장치, 방법 및 구성요소는, 예를 들어, 프로세서, 콘트롤러, ALU(arithmetic logic unit), 디지털 신호 프로세서(digital signal processor), 마이크로컴퓨터, FPGA(field programmable gate array), PLU(programmable logic unit), 마이크로프로세서, 또는 명령(instruction)을 실행하고 응답할 수 있는 다른 어떠한 장치와 같이, 범용 컴퓨터 또는 특수 목적 컴퓨터를 이용하여 구현될 수 있다. 처리 장치는 운영 체제(OS) 및 상기 운영 체제 상에서 수행되는 소프트웨어 애플리케이션을 수행할 수 있다. 또한, 처리 장치는 소프트웨어의 실행에 응답하여, 데이터를 접근, 저장, 조작, 처리 및 생성할 수도 있다. 이해의 편의를 위하여, 처리 장치는 하나가 사용되는 것으로 설명된 경우도 있지만, 해당 기술분야에서 통상의 지식을 가진 자는, 처리 장치가 복수 개의 처리 요소(processing element) 및/또는 복수 유형의 처리 요소를 포함할 수 있음을 알 수 있다. 예를 들어, 처리 장치는 복수 개의 프로세서 또는 하나의 프로세서 및 하나의 컨트롤러를 포함할 수 있다. 또한, 병렬 프로세서(parallel processor)와 같은, 다른 처리 구성(processing configuration)도 가능하다.

[0102] 소프트웨어는 컴퓨터 프로그램(computer program), 코드(code), 명령(instruction), 또는 이들 중 하나 이상의 조합을 포함할 수 있으며, 원하는 대로 동작하도록 처리 장치를 구성하거나 독립적으로 또는 결합적으로(collectively) 처리 장치를 명령할 수 있다. 소프트웨어 및/또는 데이터는, 처리 장치에 의하여 해석되거나 처리 장치에 명령 또는 데이터를 제공하기 위하여, 어떤 유형의 기계, 구성요소(component), 물리적 장치, 가상 장치(virtual equipment), 컴퓨터 저장 매체 또는 장치, 또는 전송되는 신호 파(signal wave)에 영구적으로, 또는 일시적으로 구체화(embody)될 수 있다. 소프트웨어는 네트워크로 연결된 컴퓨터 시스템 상에 분산되어서, 분산된 방법으로 저장되거나 실행될 수도 있다. 소프트웨어 및 데이터는 컴퓨터 판독 가능 기록 매체에 저장될 수 있다.

[0103] 실시예에 따른 방법은 다양한 컴퓨터 수단을 통하여 수행될 수 있는 프로그램 명령 형태로 구현되어 컴퓨터 판독 가능 매체에 기록될 수 있다. 컴퓨터 판독 가능 매체는 프로그램 명령, 데이터 파일, 데이터 구조 등을 단독으로 또는 조합하여 포함할 수 있으며 매체에 기록되는 프로그램 명령은 실시예를 위하여 특별히 설계되고 구성된 것들이거나 컴퓨터 소프트웨어 당업자에게 공지되어 사용 가능한 것일 수도 있다. 컴퓨터 판독 가능 기록 매체의 예에는 하드 디스크, 플로피 디스크 및 자기 테이프와 같은 자기 매체(magnetic media), CD-ROM, DVD와 같은 광기록 매체(optical media), 플롭티컬 디스크(floptical disk)와 같은 자기-광 매체(magneto-optical media), 및 롬(ROM), 램(RAM), 플래시 메모리 등과 같은 프로그램 명령을 저장하고 수행하도록 특별히 구성된 하드웨어 장치가 포함된다. 프로그램 명령의 예에는 컴파일러에 의해 만들어지는 것과 같은 기계어 코드뿐만 아니라 인터프리터 등을 사용해서 컴퓨터에 의해서 실행될 수 있는 고급 언어 코드를 포함한다.

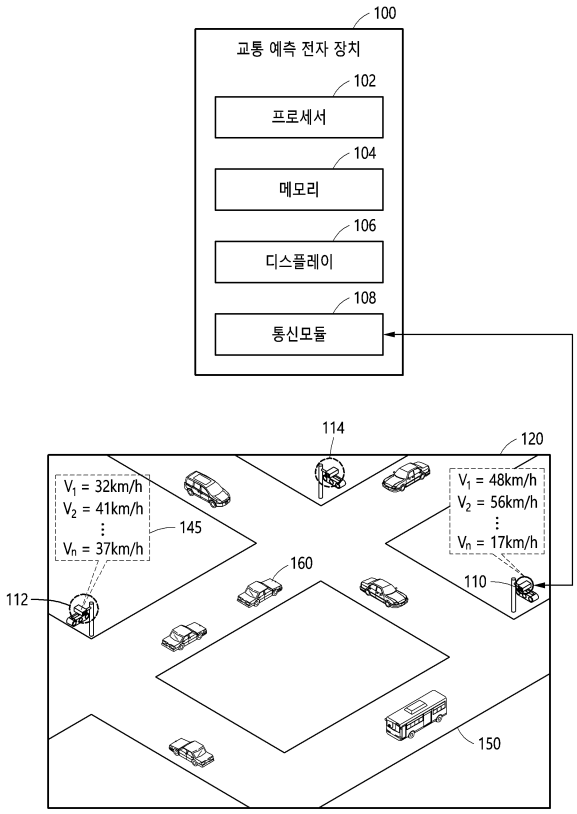
[0104] 위에서 설명한 하드웨어 장치는 실시예의 동작을 수행하기 위해 하나 또는 복수의 소프트웨어 모듈로서 작동하도록 구성될 수 있으며, 그 역도 마찬가지이다.

[0105] 이상과 같이 실시예들이 비록 한정된 도면에 의해 설명되었으나, 해당 기술분야에서 통상의 지식을 가진 자라면 이를 기초로 다양한 기술적 수정 및 변형을 적용할 수 있다. 예를 들어, 설명된 기술들이 설명된 방법과 다른 순서로 수행되거나, 및/또는 설명된 시스템, 구조, 장치, 회로 등의 구성요소들이 설명된 방법과 다른 형태로 결합 또는 조합되거나, 다른 구성요소 또는 균등물에 의하여 대치되거나 치환되더라도 적절한 결과가 달성될 수 있다.

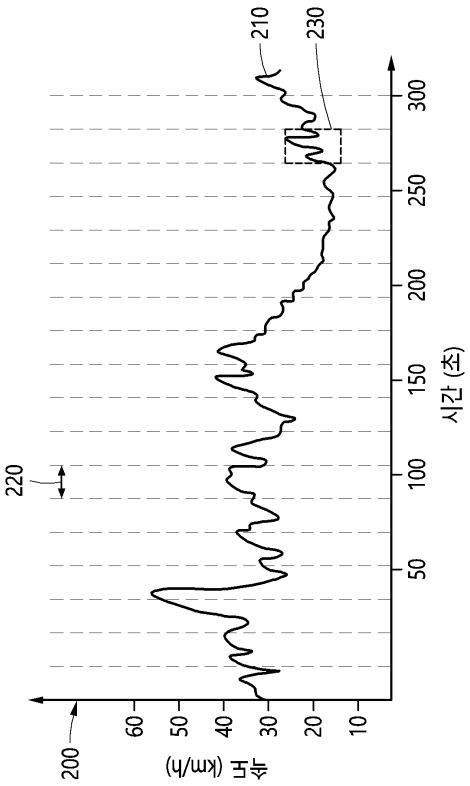
[0106] 그러므로, 다른 구현들, 다른 실시예들 및 특허청구범위와 균등한 것들도 후술하는 특허청구범위의 범위에 속한다.

도면

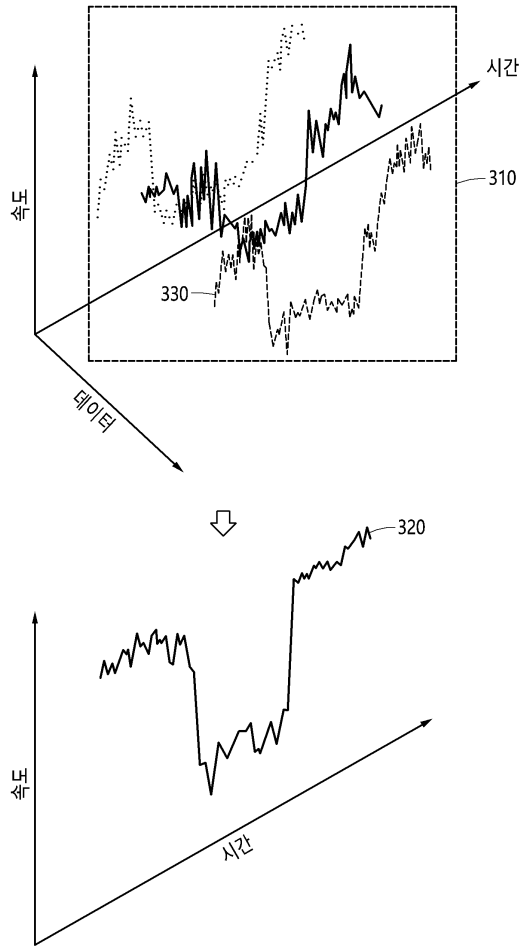
도면1


100
교통 예측 전자 장치
102
프로세서
104
메모리
106
디스플레이
108
통신모듈
114
120
V_1 = 32km/h
V_2 = 41km/h
V_n = 37km/h
145
V_1 = 48km/h
V_2 = 56km/h
V_n = 17km/h
160
110
112
150

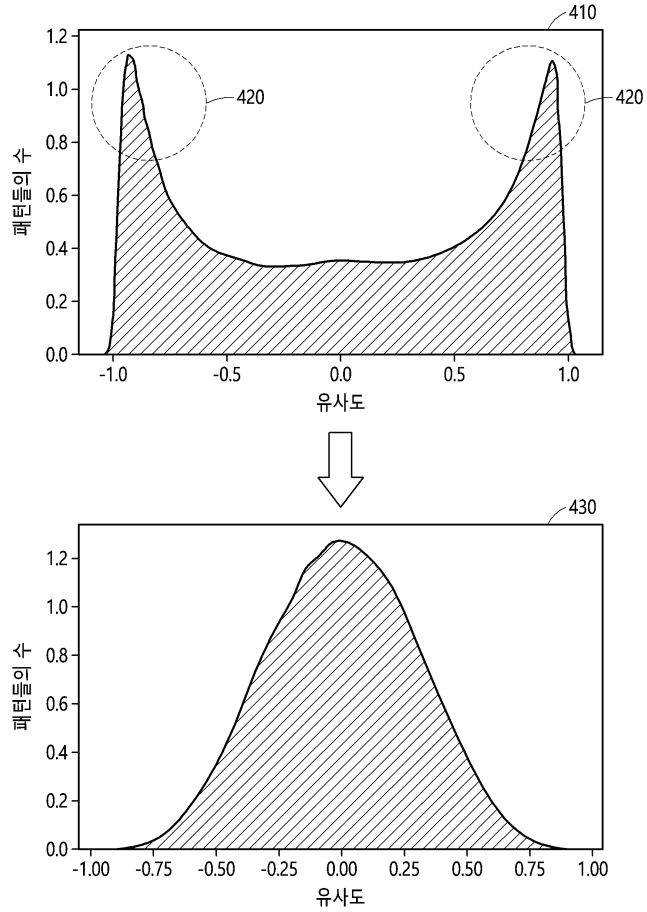
도면2



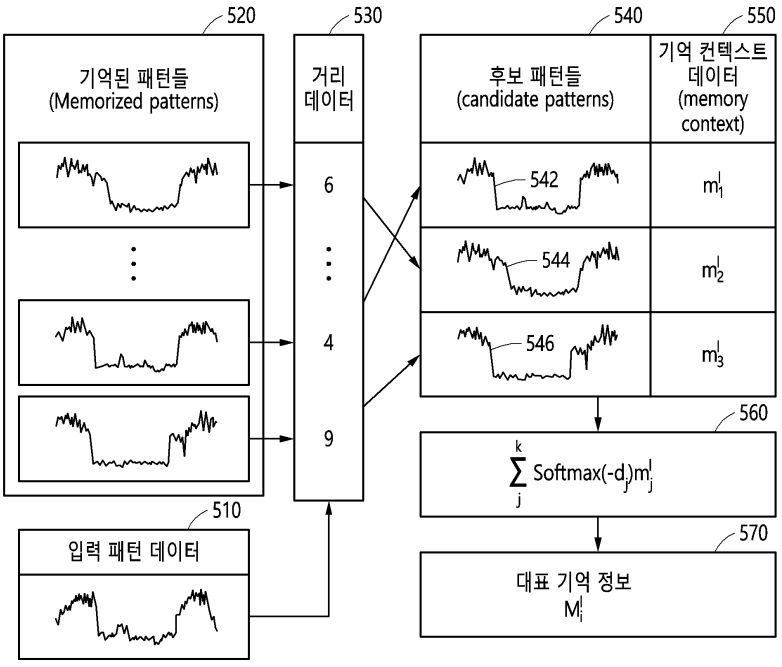
도면3



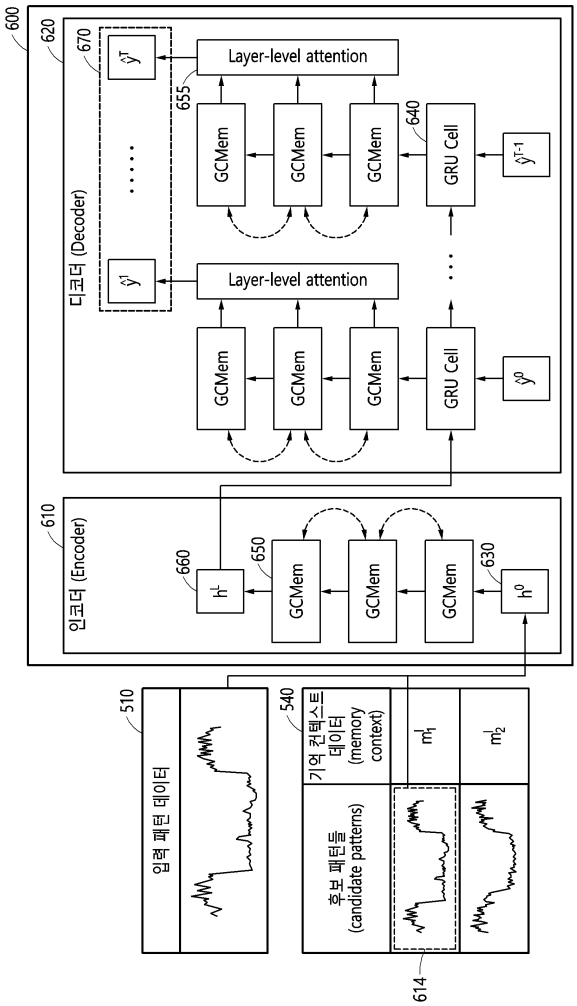
도면4


410
420
420
패턴들의 수
유사도
430
패턴들의 수
유사도

도면5


520
기억된 패턴들
(Memorized patterns)
530
거리
데이터
6
4
9
540
후보 패턴들
(candidate patterns)
550
기억 컨텍스트
데이터
(memory
context)
542
544
546
560
Softmax(-d_j)m_j
570
대표 기억 정보
510
입력 패턴 데이터

도면6


600
620
670
Layer-level attention
655
GCMem
640
GRU Cell
디코더 (Decoder)
610
인코더 (Encoder)
660
650
630
510
입력 패턴 데이터
540
기억 컨텍스트 데이터 (memory context)
후보 패턴들 (candidate patterns)
614

도면7

