

(19) 대한민국특허청(KR)
(12) 공개특허공보(A)(11) 공개번호 10-2023-0057558
(43) 공개일자 2023년05월02일

- (51) 국제특허분류(Int. Cl.)
G06N 3/12 (2023.01) G06N 3/04 (2023.01)
G06N 3/08 (2023.01) G08G 1/065 (2006.01)
- (52) CPC특허분류
G06N 3/126 (2023.01)
G06N 3/04 (2023.01)
- (21) 출원번호 10-2021-0141448
(22) 출원일자 2021년10월22일
심사청구일자 2021년10월22일
- (71) 출원인
세종대학교산학협력단
서울특별시 광진구 능동로 209 (군자동, 세종대학교)
- (72) 발명자
최수미
서울특별시 광진구 능동로 209, 세종대학교 대양 AI센터 720호(군자동)
- 아불가셈
서울특별시 광진구 능동로 209, 세종대학교 대양 AI센터 433호(군자동)
- (74) 대리인
송인호, 윤형근, 최관락


전체 청구항 수 : 총 8 항

(54) 발명의 명칭 딥러닝을 이용한 단기 교통 흐름 예측 방법 및 그 장치

(57) 요약

딥러닝을 이용한 단기 교통 흐름 예측 방법 및 그 장치가 개시된다. 딥러닝을 이용한 단기 교통 흐름 예측 방법은, (a) 딥러닝 기반 모델의 네트워크 구조를 결정하는 단계; 및 (b) 데이터 셋을 상기 딥러닝 기반 모델에 적용하여 각 노드의 이동 시간을 예측하도록 학습하되, 상기 데이터 셋을 유전자로 변환한 후 유전자 알고리즘을 적용하여 가중치와 임계치를 도출한 후 상기 딥러닝 기반 모델에 적용하여 학습시켜 단기 교통 흐름 예측 결과를 출력하는 단계를 포함하되, 상기 (b) 단계는 목표값에 도달할때까지 반복수행될 수 있다.

대표도 - 도1



(52) CPC특허분류

G06N 3/08 (2023.01)

G08G 1/065 (2013.01)

이 발명을 지원한 국가연구개발사업

과제고유번호	1711125811
과제번호	2016-0-00312-006
부처명	과학기술정보통신부
과제관리(전문)기관명	정보통신기획평가원
연구사업명	정보통신방송혁신인재양성(R&D)
연구과제명	모바일 플랫폼 기반 엔터테인먼트 VR 기술 연구
기 여 율	1/1
과제수행기관명	세종대학교 산학협력단
연구기간	2021.01.01 ~ 2021.12.31

명세서

청구범위

청구항 1

(a) 딥러닝 기반 모델의 네트워크 구조를 결정하는 단계; 및

(b) 데이터 셋을 상기 딥러닝 기반 모델에 적용하여 각 노드의 이동 시간을 예측하도록 학습하되, 상기 데이터 셋을 유전자로 변환한 후 유전자 알고리즘을 적용하여 가중치와 임계치를 도출한 후 상기 딥러닝 기반 모델에 적용하여 학습시켜 단기 교통 흐름 예측 결과를 출력하는 단계를 포함하되,

상기 (b) 단계는 목표값에 도달할때까지 반복수행되는 것을 특징으로 하는 단기 교통 흐름 예측 방법.

청구항 2

제1 항에 있어서,

상기 데이터 셋은 복수의 경로, 기상 조건, 시간 및 요일 분류에 따른 속도 정보를 포함하되,

상기 요일 분류는 휴일 및 워킹 데이(working day)에 따라 적어도 서로 다른 4개의 범주로 분류되고,

상기 기상 조건은 비, 맑음, 흐림 및 안개 조건이며,

상기 시간 조건은 근무 시간 및 출 퇴근 시간인 것을 특징으로 하는 단기 교통 흐름 예측 방법.

청구항 3

제1 항에 있어서,

상기 딥러닝 기반 모델은 엘만 순환 신경망 기반 모델이되,

상기 데이터 셋은 유전자로 변환되되, 염색체는 상기 변환된 유전자와 상기 엘만 순환 신경망 기반 모델의 가중치 및 임계치를 포함하는 것을 특징으로 하는 단기 교통 흐름 예측 방법.

청구항 4

제3 항에 있어서,

상기 유전자 알고리즘은 현재 경로에서 예측된 속도와 관측된 속도의 차이가 최소가 되도록 유전자에 대한 적합도를 평가하는 것을 특징으로 하는 단기 교통 흐름 예측 방법.

청구항 5

제1 항 내지 제4 항 중 어느 하나의 항에 따른 방법을 수행하기 위한 프로그램 코드를 기록한 컴퓨터로 판독 가능한 기록매체.

청구항 6

적어도 하나의 명령어를 저장하는 메모리;

상기 메모리에 저장된 명령어를 실행하는 프로세서를 포함하되,

상기 프로세서에 의해 실행된 명령어는,

(a) 딥러닝 기반 모델의 네트워크 구조를 결정하는 단계; 및

(b) 데이터 셋을 상기 딥러닝 기반 모델에 적용하여 각 노드의 이동 시간을 예측하도록 학습하되, 상기 데이터 셋을 유전자로 변환한 후 유전자 알고리즘을 적용하여 가중치와 임계치를 도출한 후 상기 딥러닝 기반 모델에 적용하여 학습시켜 단기 교통 흐름 예측 결과를 출력하는 단계를 수행하되,

상기 (b) 단계는 목표값에 도달할때까지 반복수행되는 것을 특징으로 하는 단기 교통 흐름 예측 장치.

청구항 7

적어도 하나의 명령어를 저장하는 메모리;

상기 메모리에 저장된 명령어를 실행하는 프로세서를 포함하되,

상기 프로세서에 의해 실행된 명령어는,

(a) 딥러닝 기반 모델의 네트워크 구조를 결정하는 단계; 및

(b) 데이터 셋을 상기 딥러닝 기반 모델에 적용하여 각 노드의 이동 시간을 예측하도록 학습하되, 상기 데이터 셋을 유전자로 변환한 후 유전자 알고리즘을 적용하여 가중치와 임계치를 도출한 후 상기 딥러닝 기반 모델에 적용하여 학습시켜 단기 교통 흐름 예측 결과를 출력하는 단계를 수행하되,

상기 (b) 단계는 목표값에 도달할때까지 반복수행되는 것을 특징으로 하는 단기 교통 흐름 예측 장치.

청구항 8

제6 항에 있어서,

상기 유전자 알고리즘은 현재 경로에서 예측된 속도와 관측된 속도의 차이가 최소가 되도록 유전자에 대한 적합도를 평가하는 것을 특징으로 하는 단기 교통 흐름 예측 장치.

발명의 설명

기술 분야

[0001] 본 발명은 딥러닝을 이용한 단기 교통 흐름 예측 방법 및 그 장치에 관한 것이다.

배경 기술

[0003] 도시 거주 인구가 증가함에 따라 도시는 시민들의 교통 요구를 충족시키기 위해 점점 더 정교한 교통 시스템이 필요하다. 많은 도시에서 이 문제를 해결하지 못하면서 거리에서 개인 자동차의 사용이 증가하여 교통 혼잡 문제가 악화되고 있다. 대기오염, 이동시간 연장, 시민들의 불만 등 교통체증의 최종적인 영향을 감안할 때, 도시 거리의 교통 흐름 예측은 인기 있는 연구 주제가 되었다.

[0004] 종래의 교통 흐름 예측 방법은 과거 데이터를 기반으로 하거나 현재 교통 상황과 평균 속도, 교통량 측면에서 유사한 과거 사례를 비교하여 예측하는데 그치고 있다.

발명의 내용

해결하려는 과제

[0006] 본 발명은 딥러닝을 이용한 단기 교통 흐름 예측 방법 및 그 장치를 제공하기 위한 것이다.

[0007] 또한, 본 발명은 도로 네트워크뿐만 아니라, 날씨 및 요일 분류를 이용하여 정확한 교통 흐름을 예측할 수 있는 딥러닝을 이용한 단기 교통 흐름 예측 방법 및 그 장치를 제공하기 위한 것이다.

과제의 해결 수단

- [0009] 본 발명의 일 측면에 따르면, 딥러닝을 이용한 단기 교통 흐름 예측 방법이 제공된다.
- [0010] 본 발명의 일 실시예에 따르면, (a) 딥러닝 기반 모델의 네트워크 구조를 결정하는 단계; 및 (b) 데이터 셋을 상기 딥러닝 기반 모델에 적용하여 각 노드의 이동 시간을 예측하도록 학습하되, 상기 데이터 셋을 유전자로 변환한 후 유전자 알고리즘을 적용하여 가중치와 임계치를 도출한 후 상기 딥러닝 기반 모델에 적용하여 예측 결과를 출력하는 단계를 포함하되, 상기 (b) 단계는 목표값에 도달할때까지 반복수행되는 것을 특징으로 하는 단기 교통 흐름 예측 방법이 제공될 수 있다.
- [0011] 상기 데이터 셋은 복수의 경로, 기상 조건, 시간 및 요일 분류에 따른 속도 정보를 포함하되, 상기 요일 분류는 휴일 및 워킹 데이(working day)에 따라 적어도 서로 다른 4개의 범주로 분류되고, 상기 기상 조건은 비, 맑음, 흐림 및 안개 조건이며, 상기 시간 조건은 근무 시간 및 출 퇴근 시간일 수 있다.
- [0012] 상기 딥러닝 기반 모델은 엘만 순환 신경망 기반 모델이되, 상기 데이터 셋은 유전자로 변환되되, 염색체는 상기 변환된 유전자와 상기 엘만 순환 신경망 기반 모델의 가중치 및 임계치를 포함할 수 있다.
- [0013] 상기 유전자 알고리즘은 현재 경로에서 예측된 속도와 관측된 속도의 차이가 최소가 되도록 유전자에 대한 적합도를 평가할 수 있다.

- [0015] 본 발명의 다른 측면에 따르면, 딥러닝을 이용한 단기 교통 흐름 예측 장치가 제공된다.
- [0016] 본 발명의 일 실시예에 따르면, 적어도 하나의 명령어를 저장하는 메모리; 상기 메모리에 저장된 명령어를 실행하는 프로세서를 포함하되, 상기 프로세서에 의해 실행된 명령어는, (a) 딥러닝 기반 모델의 네트워크 구조를 결정하는 단계; 및 (b) 데이터 셋을 상기 딥러닝 기반 모델에 적용하여 각 노드의 이동 시간을 예측하도록 학습하되, 상기 데이터 셋을 유전자로 변환한 후 유전자 알고리즘을 적용하여 가중치와 임계치를 도출한 후 상기 딥러닝 기반 모델에 적용하여 예측 결과를 출력하는 단계를 수행하되, 상기 (b) 단계는 목표값에 도달할때까지 반복수행되는 것을 특징으로 하는 단기 교통 흐름 예측 장치가 제공될 수 있다.

발명의 효과

- [0018] 본 발명의 일 실시예에 따른 딥러닝을 이용한 단기 교통 흐름 예측 방법 및 그 장치를 제공함으로써, 도로 네트워크뿐만 아니라, 날씨 및 요일 분류를 이용하여 정확한 교통 흐름을 예측할 수 있다.

도면의 간단한 설명

- [0020] 도 1은 본 발명의 일 실시예에 따른 딥러닝을 이용한 단기 교통 흐름 예측 방법을 나타낸 순서도.
- 도 2는 본 발명의 일 실시예에 따른 요일 분류를 예시한 도면.
- 도 3은 본 발명의 일 실시예에 따른 기상 조건에 따른 평균 속도를 예시한 도면.
- 도 4는 본 발명의 일 실시예에 따른 요일별 평균 속도를 예시한 도면.
- 도 5는 본 발명의 일 실시예에 따른 요일 분류별 평균 속도를 예시한 도면.
- 도 6은 본 발명의 일 실시예에 따른 시간별 평균 속도를 예시한 도면.
- 도 7은 본 발명의 일 실시예에 따른 경로별 평균 속도를 예시한 도면.
- 도 8은 본 발명의 일 실시예에 따른 수정된 엘만 순환 신경망 모델을 예시한 도면.

도 9는 본 발명의 일 실시예에 따른 유전자 알고리즘을 이용하여 딥러닝 기반 모델을 최적화 방법을 예시한 도면.

도 10은 본 발명의 일 실시예에 따른 단기 교통 흐름 예측 장치의 내부 구성을 개략적으로 도시한 블록도.

발명을 실시하기 위한 구체적인 내용

- [0021] 본 명세서에서 사용되는 단수의 표현은 문맥상 명백하게 다르게 뜻하지 않는 한, 복수의 표현을 포함한다. 본 명세서에서, "구성된다" 또는 "포함한다" 등의 용어는 명세서상에 기재된 여러 구성 요소들, 또는 여러 단계들을 반드시 모두 포함하는 것으로 해석되지 않아야 하며, 그 중 일부 구성 요소들 또는 일부 단계들은 포함되지 않을 수도 있고, 또는 추가적인 구성 요소 또는 단계들을 더 포함할 수 있는 것으로 해석되어야 한다. 또한, 명세서에 기재된 "...부", "모듈" 등의 용어는 적어도 하나의 기능이나 동작을 처리하는 단위를 의미하며, 이는 하드웨어 또는 소프트웨어로 구현되거나 하드웨어와 소프트웨어의 결합으로 구현될 수 있다.
- [0022] 이하, 첨부된 도면들을 참조하여 본 발명의 실시예를 상세히 설명한다.
- [0024] 도 1은 본 발명의 일 실시예에 따른 딥러닝을 이용한 단기 교통 흐름 예측 방법을 나타낸 순서도이고, 도 2는 본 발명의 일 실시예에 따른 요일 분류를 예시한 도면이고, 도 3은 본 발명의 일 실시예에 따른 기상 조건에 따른 평균 속도를 예시한 도면이며, 도 4는 본 발명의 일 실시예에 따른 요일별 평균 속도를 예시한 도면이고, 도 5는 본 발명의 일 실시예에 따른 요일 분류별 평균 속도를 예시한 도면이고, 도 6은 본 발명의 일 실시예에 따른 시간별 평균 속도를 예시한 도면이고, 도 7은 본 발명의 일 실시예에 따른 경로별 평균 속도를 예시한 도면이고, 도 8은 본 발명의 일 실시예에 따른 수정된 엘만 순환 신경망 모델을 예시한 도면이고, 도 9는 본 발명의 일 실시예에 따른 유전자 알고리즘을 이용하여 딥러닝 기반 모델을 최적화 방법을 예시한 도면이다.
- [0025] 단계 110에서 교통 흐름 예측 장치(100)는 데이터 셋을 획득한다.
- [0026] 여기서, 데이터 셋은 대상 지역에 대한 도로 네트워크, 교통 정보, 시공간 정보, 기상 조건 및 요일 분류를 포함할 수 있다. 대상 지역에 대한 도로 네트워크(즉, 도로의 각 구간에 대한 노드 정보 및 이들의 연결 관계 등) 및 교통 정보는 서버(미도시)를 통해 주기적 또는 비주기적으로 획득될 수 있다. 물론, 도로 네트워크는 구글 지도 등을 이용하여 획득될 수도 있다.
- [0027] 기상 조건은 30분 단위로 획득되며, 비, 맑음, 흐림, 안개 등과 같이 4가지 범주로 획득될 수 있다. 또한, 주말 및 공휴일이 전달과 다음날 교통에 미치는 영향을 고려하여 모든 요일을 4개의 클래스로 구분하였다. 주말 및 공휴일은 성격에 관계 없이 모두 휴무일로 처리하였다. 도 2에는 요일에 따른 클래스를 도시한 일 예가 도시되어 있다. 도 2에서 보여지는 바와 같이, 월요일~ 목요일은 클래스 1로 분류하고, 금요일은 클래스 2로 분류하며, 토요일은 클래스 4로 분류하고, 일요일은 클래스 3으로 분류하였다.
- [0028] 상술한 바와 같이, 요일을 각기 다른 클래스로 분류하여 교통 흐름 예측에 이용하였다.
- [0029] 또한, 기상 조건에 따른 속도 정보를 획득할 수도 있다.
- [0030] 도 3은 기상 조건에 따른 평균 속도를 예시한 도면이다. 도 3에서 보여지는 바와 같이, 우천시에 평균 속도가 가장 낮으며 안개 낀 날에는 평균 속도가 높은 것을 알 수 있다. 또한, 요일별 평균 속도는 도 4에 도시된 바와 같다. 도 4에서 보여지는 바와 같이, 화요일에 가장 평균 속도가 가장 낮은 것을 알 수 있다. 또한, 휴일 유무에 따른 평균 속도는 도 5에 도시된 바와 같다. 도 5에서 보여지는 바와 같이, 클래스 III에서 평균 속도가 가장 낮은 것을 알 수 있다.
- [0031] 또한, 도 6은 하루 중 시간별 평균 속도를 예시한 도면으로, 17:00~20:30 사이에 트래픽이 가장 많았으며, 06:00 ~ 08:00 사이에 트래픽이 가장 적은 것을 알 수 있다.
- [0032] 또한, 도 7은 다양한 경로에 따른 평균 속도를 예시한 도면이다.
- [0033] 상술한 바와 같이, 본 발명의 일 실시예에 따른 교통 흐름 예측 장치(100)는 다양한 경로, 교통 정보, 시공간 정보, 기상 조건 및 요일 분류에 따른 속도 정보를 데이터 셋으로 획득할 수 있다.
- [0034] 단계 115에서 교통 흐름 예측 장치(100)는 데이터 셋을 딥러닝 기반 모델에 적용하여 각 노드의 이동 시간을 예측하도록 학습하되, 데이터 셋을 각각 유전자로 변환한 후 유전자 알고리즘을 적용하여 딥러닝 기반 모델의 가

중치와 임계치를 도출한 후 해당 딥러닝 기반 모델에 적용하여 최적화한 후 예측 결과를 출력한다.

[0035] 이에 대해 보다 상세히 설명하기로 한다.

[0036] 우선, 본 발명의 일 실시예에 따른 딥러닝 기반 모델은 엘만 순환 신경망 모델을 기반으로 한다. 수정된 엘만 순환 신경망 모델을 기반으로 하는 딥러닝 기반 모델은 도 8에 도시된 바와 같다. 수정된 엘만 순환 신경망 모델의 기본적인 구조에 대한 설명은 "Elman neural network for modeling and predictive control of delayed dynamic systems"에 상세히 설명되어 있으므로 이에 대한 설명은 생략하기로 한다. 수정된 엘만 순환 신경망 모델을 기반으로 하는 딥러닝 기반 모델에서 단기 교통 흐름을 예측하는 방법에 대해 보다 상세히 설명하기로 한다.

[0037] 예를 들어, 데이터 셋을 $S = \{(x_k, y_k) | k = 1, 2, \dots, n\}$ 라고 가정하기로 한다.

[0038] 이때, $x_k \in R^r$ 이고, $y_k \in R^s$ 이며, n 은 데이터 개수를 나타낸다. 여기서, x_k 는 입력을 나타내고, y_k 는 출력을 나타낸다.

[0039] 데이터 셋을 트레이닝 서버 셋과 테스트 서버 셋으로 분할한 후 정규화할 수 있다. 편의상 트레이닝 서버 셋을 $S_1 = \{(x_k, y_k) | k = 1, 2, \dots, q\}$ 이라 칭하기로 하며, 테스트 서버 셋을 $S_2 = \{(x_k, y_k) | k = q+1, q+2, \dots, n\}$ 라 칭하기로 한다.

[0040] 본 발명의 일 실시예에 따르면, Elman 순환 신경망 모델은 교통 시간을 예측하기 위해 사용된다. 엘만 순환 신경망 모델에서 입력 $(u(k - \tau))$ 을 위한 시그널은 순수 지연 시간을 통합한다. 여기서, 엘만 순환 신경망 모델의 네트워크 가중치는 종래 구조와 동일한 것을 가정하기로 한다.

[0041] 즉, Elman 순환 신경망 모델의 출력은 수학식 1과 같이 나타낼 수 있다.

수학식 1

$$y_{mod}(k) = \sum_{o=1}^r b_o + \sum_{i=0}^k W_i^{(2)} x_i(k)$$

[0042]

[0043] 여기서, $x_i(k)$ 는 다음 히든 노드의 출력 신호를 나타내며, $(i = 1, \dots, K)$ 이다. $x_0(k) = 1$ 이다. 또한, b_h 와 b_o 는 히든 노드와 출력 노드의 바이어스를 나타낸다.

[0044] 따라서, $x_i(k)$ 는 수학식 2와 같이 나타낼 수 있다.

수학식 2

$$X_i(k) = \varphi(Z_i(k))$$

[0045]

[0046] 여기서, 히든 노드 i 의 합계는 수학식 3과 같이 나타낼 수 있다.

수학식 3

$$z_i(k) = b_h + \sum_{i=0}^m w_{i,1}^1 u(k - \tau) + \sum_{j=1}^n w_{i,j+1}^{(1)} x_j(k - 1)$$

상술한 수학식 1 내지 수학식 3을 결합하면 본 발명의 일 실시예에 따른 엘만 순환 신경망 모델의 최종 방정식은 수학식 4와 같이 나타낼 수 있다.

수학식 4

$$y_{mod}(k) = \sum_{o=1}^r b_o + \sum_{h=1}^n w_h^{(2)} \varphi(b_h + \sum_{i=0}^m w_{i,1}^1 u(k - \tau) + \sum_{j=1}^n w_{i,j+1}^{(1)} x_j(k - 1))$$

상술한 바와 같이, 데이터 셋에 대한 엘만 순환 신경망 기반의 딥러닝 기반 모델의 최종 출력이 결정되면, 유전자 알고리즘을 이용하여 딥러닝 기반 모델을 최적화할 수 있다.

이를 위한 상세 구조는 도 9에 도시된 바와 같다.

엘만 순환 신경망 모델(딥러닝 기반 모델)의 네트워크 구조가 결정되면, 데이터 셋을 유전자로 변환한 후 유전자 알고리즘을 적용하여 엘만 순환 신경망 모델의 최적 가중치와 임계치를 도출할 수 있다.

이를 위해, 유전자 알고리즘은 염색체에 데이터 셋에 기반한 유전자뿐만 아니라, 엘만 순환 신경망 모델의 가중치와 임계치를 각각 유전자로 포함할 수 있다.

유전자 알고리즘을 이용하여 가중치와 임계치를 도출하는 과정에 대해 보다 상세히 설명하기로 한다.

유전자 알고리즘은 염색체 모집단을 무작위로 생성할 수 있다. 엘만 순환 신경망 모델의 초기 가중치와 임계치는 염색체의 모든 유전자로 구성될 수 있다.

수학식 5는 염색체의 부동소수점(floated-point) 코딩 길이를 나타낸다.

수학식 5

$$K = P * m + P + P * n + n + P * P$$

엘만 순환 신경망 모델의 초기 가중치와 임계치가 구성된 후 유전자 알고리즘은 각 염색체의 적합성 평가를 수행한다. 본 발명의 일 실시예에서는 수학식 6을 이용하여 각 염색체의 적합성 평가를 수행할 수 있다.

수학식 6

$$f = \frac{1}{N} \sum_{i=0}^N \sum_j^T (y_{j,i}^t - y_{j,i})^2$$

[0060] 여기서, N은 모집단의 염색체 수를 나타낸다. 또한, $y_{j,i}^t$ 와 $y_{j,i}$ 는 현재 경로에서 예측된 속도와 관찰된 속도를 나타낸다. 여기서, T는 속도가 예측되는 변수이므로, 1로 설정되는 신경망 출력의 양으로, 이 시점에 최소 적합도값이 결정될 수 있다. 전체 적합도 최소값보다 낮으면 전체 적합도 최소값이 갱신될 수 있다.

[0061] 유전자 알고리즘은 부모 집단을 선택, 교배 및 돌연변이 연산을 통해 차세대 집단을 생성할 수 있다.

[0062] 유전자 알고리즘은 각 염색체가 적합도를 계산한 후 여러 염색체로 새로운 개체군을 선택하고, 염색체 선택은 적합도 평가에 기반할 수 있다. 본 발명의 일 실시예에서는 적합도 값이 낮은 염색체를 선택하고 적합도 값이 높은 염색체는 버리며, 룰렛 휠 선택 조작은 수학적 7과 같이 적용될 수 있다.

수학적 7

[0063]

$$p_i = \frac{F_i}{\sum_{j=1}^N F_j}$$

[0064] 여기서, F_j 는 적합도값을 나타내고, p_i 는 염색체 i가 선택될 기회를 나타낸다.

[0065] 본 발명의 일 실시예에 따르면, 유전 알고리즘의 교차 연산을 위해 실수 교차 방법을 이용할 수 있다. 즉, j 위치에서 염색체 C_k 와 염색체 C_i 의 교차 연산은 수학적 8과 같이 나타낼 수 있다.

수학적 8

[0066]

$$\begin{aligned} C_{Kj} &= C_{Kj} (1 - r) + C_{ij} r, \\ C_{ij} &= C_{ij} (1 - r) + C_{Kj} r \end{aligned}$$

[0067] 여기서, C_{kj} 와 C_{lj} 는 엘만 순환 신경망 가중치 또는 임계치를 나타내는 염색체 j에서 k번째 및 j번째 값을 나타내고, r은 0에서 1까지의 수를 나타낸다.

[0068] 유전자 알고리즘은 돌연변이 작업을 통해 모집단을 다양화할 수 있다. 즉, i번째 염색체 (m_{ij}) 의 j번째 유전자 돌연변이는 수학적 9와 같이 나타낼 수 있다.

수학적 9

[0069]

$$m_{ij} = \begin{cases} m_{ij} + (m_{ij} - m_{max}) * f(g), & r \geq 0.5, \\ m_{ij} + (m_{min} - m_{ij}) * f(g), & r < 0.5 \end{cases}$$

[0071] 여기서, m_{min} 과 m_{max} 은 i번째 염색체의 j번째 유전자내의 가중치 또는 임계값의 최소값과 최대값을 나타내고, r은 랜덤값으로 0과 1 사이의 값일 수 있다. $f(g)$ 는 수학식 10과 같다.

수학식 10

[0072]

$$f(g) = r_1(1 - g/G)$$

[0073] 여기서, r_1 는 임의의 숫자를 나타내고, g는 현재 반복 횟수를 나타내며, G는 진화적 생성값을 나타낸다.

[0074] 유전자 알고리즘은 진화적 생성값이 최대값에 도달하면 최신 가중치 및 임계값을 추출하고, 그렇지 않으면 교배 및 돌연변이 연산이 반복될 수 있다.

[0075] 이와 같이, 데이터 셋은 각각 유전자로 변환한 후 유전자 알고리즘을 통해 선택, 교배 및 돌연변이 연산을 통해 통합되어 최적의 가중치와 임계값이 도출되어 수정된 엘만 순환 신경망 모델에 적용되어 학습이 반복될 수 있다.

[0076] 단계 120에서 교통 흐름 예측 장치(100)는 학습이 완료된 딥러닝 기반 모델에 단기 교통 흐름을 예측하고자 하는 타겟 지역에 대한 데이터 셋을 적용하여 단기 교통 흐름을 예측한다.

[0077] 상술한 바와 같이, 본 발명의 일 실시예에 따르면, 기상 조건, 시공간 정보, 요일 분류와 같은 데이터를 수정된 엘만 순환 신경망 모델을 통해 통합하여 단기 교통 흐름을 예측함으로써 예측 정밀도를 향상시킬 수 있는 이점이 있다.

[0079] 도 10은 본 발명의 일 실시예에 따른 단기 교통 흐름 예측 장치의 내부 구성을 개략적으로 도시한 블록도이다.

[0080] 도 10을 참조하면, 본 발명의 일 실시예에 따른 단기 교통 흐름 예측 장치(100)는 통신부(1005), 메모리(1010) 및 프로세서(1020)를 포함하여 구성된다.

[0081] 통신부(1005)는 통신망을 통해 다른 장치들(예를 들어, 서버 등)과 데이터를 송수신하기 위한 수단이다. 예를 들어, 통신부(1005)는 데이터 셋을 수집할 수 있다.

[0082] 메모리(1010)는 적어도 하나의 명령어를 저장한다.

[0083] 프로세서(1020)는 메모리(1010)에 저장된 명령어를 실행하기 위한 수단이다. 프로세서(1020)는 수정된 엘만 순환 신경망 기반 딥러닝 기반 모델을 가지며, 데이터 셋을 딥러닝 기반 모델에 적용하여 각 노드의 이동 시간을 예측하도록 학습하되, 상기 데이터 셋을 유전자로 변환한 후 유전자 알고리즘을 적용하여 가중치와 임계치를 도출한 후 상기 딥러닝 기반 모델에 적용하여 단기 교통 흐름 예측 결과를 출력하도록 제어할 수 있다.

[0084] 즉, 프로세서(1020)는 수정된 엘만 순환 신경망 기반의 딥러닝 기반 모델의 네트워크 구조를 결정하고, 유전자 알고리즘을 이용하여 해당 딥러닝 기반 모델의 가중치와 임계치를 최적화하도록 학습시킬 수 있다. 이와 같이, 프로세서(1020)는 데이터 셋 일부를 이용하여 학습된 딥러닝 기반 모델에 적용하여 단기 교통 흐름을 예측할 수 있다.

[0085] 이는 도 1에서 설명한 바와 동일하므로 중복되는 설명은 생략하기로 한다.

[0087] 본 발명의 실시 예에 따른 장치 및 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 있다. 컴퓨터 판독 가능 매체에 기록되는 프로그램 명령은 본 발명을 위하여 특별히 설계되고 구성된 것들이거나 컴퓨터 소프트웨어 분야 통상의 기술자에게 공지되어 사용 가능한 것일 수도 있다. 컴퓨터 판독 가능 기록 매체의 예에는 하드 디스크, 플로피 디스크 및 자기 테이프

와 같은 자기매체(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.

[0088] 상술한 하드웨어 장치는 본 발명의 동작을 수행하기 위해 하나 이상의 소프트웨어 모듈로서 작동하도록 구성될 수 있으며, 그 역도 마찬가지이다.


[0089] 이제까지 본 발명에 대하여 그 실시 예들을 중심으로 살펴보았다. 본 발명이 속하는 기술 분야에서 통상의 지식을 가진 자는 본 발명이 본 발명의 본질적인 특성에서 벗어나지 않는 범위에서 변형된 형태로 구현될 수 있음을 이해할 수 있을 것이다. 그러므로 개시된 실시 예들은 한정적인 관점이 아니라 설명적인 관점에서 고려되어야 한다. 본 발명의 범위는 전술한 설명이 아니라 특허청구범위에 나타나 있으며, 그와 동등한 범위 내에 있는 모든 차이점은 본 발명에 포함된 것으로 해석되어야 할 것이다.

부호의 설명

[0091] 100: 교통 흐름 예측 장치
1005: 통신부
1010: 메모리
1020: 프로세서

도면


도면1




도면2

Friday	Saturday	Sunday	Monday	Tuesday
↑	↑	↑	↑	↑
Class II	Class IV	Class III	Class I	Class I


도면3




도면4




도면5




도면6




도면7



도면8



도면9



도면10

