



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2019-0109108
(43) 공개일자 2019년09월25일

(51) 국제특허분류(Int. Cl.)
G06N 3/08 (2006.01) G06N 3/04 (2006.01)
G06Q 40/04 (2012.01)
(52) CPC특허분류
G06N 3/08 (2013.01)
G06N 3/049 (2013.01)
(21) 출원번호 10-2018-0031064
(22) 출원일자 2018년03월16일
심사청구일자 2018년03월16일

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


전체 청구항 수 : 총 18 항

(54) 발명의 명칭 시계열 데이터의 변화를 예측하고 그 이유를 설명하는 인공지능 시스템

(57) 요약

시계열 데이터에 기초하여 시계열 데이터의 변화를 예측하고, 그 원인을 추출하여 보고서를 작성하는 시계열 데이터의 자동 분석 방법이 개시된다. 일 실시예에 따른 시계열 데이터의 자동 분석 방법은 시계열 데이터에 기초하여, 시계열 데이터의 변화를 예측하는 적어도 하나의 커널을 생성하고, 시계열 데이터에 대응하는 미리 정해진 템플릿에 기초하여, 적어도 하나의 커널을 설명하는 제1 정보를 생성하며, 시계열 데이터의 시간 구간에 대응하는 자료로부터, 상기 제1 정보의 원인으로 이용 가능한 제2 정보를 추출함으로써, 제1 정보 및 제2 정보에 기초하여, 시계열 데이터에 대한 보고서를 생성한다.

대표도



(52) CPC특허분류

G06Q 40/04 (2013.01)

이 발명을 지원한 국가연구개발사업

과제고유번호 2015M3D3A1A01064919199

부처명 과학기술정보통신부

연구관리전문기관 정보통신기술진흥센터

연구사업명 인공지능국가전략프로젝트

연구과제명 의사결정 이유를 설명할 수 있는 인간 수준의 학습·추론 프레임워크 개발

기 여 율 1/1

주관기관 울산과학기술원

연구기간 2017.07.01 ~ 2021.12.31

명세서

청구범위

청구항 1

다중 시계열 데이터에 기초하여, 상기 다중 시계열 데이터의 변화를 예측하는 복수의 커널들-상기 복수의 커널들 중 적어도 하나의 커널은 상기 다중 시계열 데이터의 공통 정보에 기초하여 결정됨-을 생성하는 단계;

상기 다중 시계열 데이터에 대응하는 미리 정해진 템플릿에 기초하여, 상기 적어도 하나의 커널을 설명하는 제1 정보를 생성하는 단계;

상기 다중 시계열 데이터의 시간 구간에 대응하는 자료로부터, 상기 제1 정보의 원인으로 이용 가능한 제2 정보를 추출하는 단계; 및

상기 제1 정보 및 상기 제2 정보에 기초하여, 상기 다중 시계열 데이터에 대한 보고서를 생성하는 단계를 포함하는,

시계열 데이터의 자동 분석 방법.

청구항 2

제1항에 있어서,

상기 복수의 커널들을 생성하는 단계는

가우시안 커널 분할 학습 기법을 이용하여, 상기 복수의 커널들을 생성하는 단계

를 포함하는,

시계열 데이터의 자동 분석 방법.

청구항 3

제1항에 있어서,

상기 복수의 커널들은

부드러운 변화를 예측하는 제1 커널, 짧은 주기의 변화를 예측하는 제2 커널, 및 상기 다중 시계열 데이터의 공통적 변화를 예측하는 제3 커널을 포함하는,

시계열 데이터의 자동 분석 방법.

청구항 4

제1항에 있어서,

상기 복수의 커널들을 생성하는 단계는

상기 다중 시계열 데이터의 상기 공통 정보를 추출하는 단계;

상기 공통 정보에 기초하여, 상기 다중 시계열 데이터 각각의 개별 정보를 추출하는 단계; 및

상기 개별 정보와 상기 공통 정보를 혼합하여 상기 시계열 데이터 변화를 예측하는 커널을 생성하는 단계를 포함하는,

시계열 데이터의 자동 분석 방법.

청구항 5

제1항에 있어서,

상기 제1 정보를 생성하는 단계는

상기 복수의 커널들에 기초하여, 상기 예측된 변화와 관련된 수치를 결정하는 단계;

상기 복수의 커널들에 기초하여, 상기 예측된 변화를 설명하는 텍스트를 결정하는 단계; 및

상기 수치 및 상기 텍스트를 상기 템플릿에 삽입함으로써, 상기 제1 정보를 생성하는 단계를 포함하는,

시계열 데이터의 자동 분석 방법.

청구항 6

제1항에 있어서,

상기 제2 정보를 추출하는 단계는

양방향 리커런트 신경망을 이용하여, 상기 자료 내 문장에 포함된 복수의 단어들 중 중요 단어를 선별하는 단계; 및

상기 양방향 리커런트 신경망을 이용하여, 상기 자료 내 복수의 문장들 중 중요 문장을 선별하는 단계

중 적어도 하나를 포함하는,

시계열 데이터의 자동 분석 방법.

청구항 7

제1항에 있어서,

상기 자료는 상기 시계열 데이터 내용을 포함하는 뉴스, 분기 보고서, 및 전문가 보고서 중 적어도 하나를 포함하는,

시계열 데이터의 자동 분석 방법.

청구항 8

제1항에 있어서,

상기 보고서를 생성하는 단계는

상기 제2 정보 중 상기 제1 정보의 결론에 부합하는 제3 정보를 추출하는 단계; 및

상기 제3 정보를 상기 제1 정보의 원인으로 설명하는 정보를 생성하는 단계

를 포함하는,

시계열 데이터의 자동 분석 방법.

청구항 9

제1항에 있어서,

상기 보고서를 생성하는 단계는

상기 제1 정보를 상기 복수의 커널들에 대응하여 분류하는 단계;

상기 제2 정보를 상기 복수의 커널들에 대응하여 분류하는 단계;

상기 복수의 커널들에 대응하여, 상기 제1 정보와 상기 제2 정보를 매칭하는 단계; 및

상기 매칭 결과에 기초하여, 상기 복수의 커널들 각각에 대응하여 예측된 결과 및 해당하는 결과의 원인을 설명하는 정보를 생성하는 단계

를 포함하는,

시계열 데이터의 자동 분석 방법.

청구항 10

제1항에 있어서,

하드웨어와 결합되어 제1항 내지 제9항 중 어느 하나의 항의 방법을 실행시키기 위하여 매체에 저장된 컴퓨터 프로그램.

청구항 11

시계열 데이터에 기초하여, 상기 시계열 데이터의 변화를 예측하는 적어도 하나의 커널을 생성하는 단계;

상기 시계열 데이터에 대응하는 미리 정해진 템플릿에 기초하여, 상기 적어도 하나의 커널을 설명하는 제1 정보를 생성하는 단계;

딥러닝 기법을 통하여 기 학습된 신경망을 이용하여, 상기 시계열 데이터의 시간 구간에 대응하는 자료로부터, 상기 제1 정보의 원인으로 이용 가능한 제2 정보를 추출하는 단계; 및

상기 제1 정보 및 상기 제2 정보에 기초하여, 상기 시계열 데이터에 대한 보고서를 생성하는 단계

를 포함하는,

시계열 데이터의 자동 분석 방법.

청구항 12

제11항에 있어서,

상기 적어도 하나의 커널을 생성하는 단계는

가우시안 커널 분할 학습 기법을 이용하여, 상기 적어도 하나의 커널을 생성하는 단계

를 포함하는,

시계열 데이터의 자동 분석 방법.

청구항 13

제11항에 있어서,

상기 제1 정보를 생성하는 단계는

상기 적어도 하나의 커널에 기초하여, 상기 예측된 변화와 관련된 수치를 결정하는 단계;

상기 적어도 하나의 커널에 기초하여, 상기 예측된 변화를 설명하는 텍스트를 결정하는 단계; 및
상기 수치 및 상기 텍스트를 상기 템플릿에 삽입함으로써, 상기 제1 정보를 생성하는 단계
를 포함하는,
시계열 데이터의 자동 분석 방법.

청구항 14

제11항에 있어서,
상기 제2 정보를 추출하는 단계는
양방향 리커런트 신경망을 이용하여, 상기 자료 내 문장에 포함된 복수의 단어들 중 중요 단어를 선별하는
단계; 및
상기 양방향 리커런트 신경망을 이용하여, 상기 자료 내 복수의 문장들 중 중요 문장을 선별하는 단계
중 적어도 하나를 포함하는,
시계열 데이터의 자동 분석 방법.

청구항 15

제11항에 있어서,
상기 자료는 상기 시계열 데이터 내용을 포함하는 뉴스, 분기 보고서, 및 전문가 보고서 중 적어도 하나를 포함
하는,
시계열 데이터의 자동 분석 방법.

청구항 16

제11항에 있어서,
상기 보고서를 생성하는 단계는
상기 제2 정보 중 상기 제1 정보의 결론에 부합하는 제3 정보를 추출하는 단계; 및
상기 제3 정보를 상기 제1 정보의 원인으로 설명하는 정보를 생성하는 단계
를 포함하는,
시계열 데이터의 자동 분석 방법.

청구항 17

제11항에 있어서,
상기 보고서를 생성하는 단계는
상기 적어도 하나의 커널은 복수의 커널들을 포함하고,
상기 보고서를 생성하는 단계는
상기 제1 정보를 상기 복수의 커널들에 대응하여 분류하는 단계;
상기 제2 정보를 상기 복수의 커널들에 대응하여 분류하는 단계;

상기 복수의 커널들에 대응하여, 상기 제1 정보와 상기 제2 정보를 매칭하는 단계; 및

상기 매칭 결과에 기초하여, 상기 복수의 커널들 각각에 대응하여 예측된 결과 및 해당하는 결과의 원인을 설명하는 정보를 생성하는 단계

를 포함하는,

시계열 데이터의 자동 분석 방법.

청구항 18

제11항에 있어서,

하드웨어와 결합되어 제11항 내지 제17항 중 어느 하나의 항의 방법을 실행시키기 위하여 매체에 저장된 컴퓨터 프로그램.

발명의 설명

기술 분야

[0001] 아래에서 설명할 실시예들은 시계열 데이터를 분석하는 인공지능 시스템에서 시계열 데이터의 분석 및 예측뿐만 아니라, 예측에 있어서 그 이유도 설명하는 인공지능 시스템에 대한 것이다.

배경 기술

[0003] 주식이나 환율 등 시계열 데이터의 분석은 복잡한 요소가 관여하기 때문에 어떤 요소가 영향을 주는지 정확히 찾아내기는 어렵다. 시계열 데이터를 분석하는 인공지능 시스템은 예를 들어 금융 데이터의 분석, 예측을 통하여 금융 자산을 투자하고 매도하는 데 중요하다. 금융 데이터의 변화를 정확하게 예측하는 것은 합리적인 금융 자산의 투자 운용을 가능하게 한다. 최근 인공지능 기술의 발전은 예측에 있어서 전통적인 통계적 분석에 비하여 뛰어난 예측 성능을 보이고 있다. 그러나, 현재 데이터 분석에 사용되는 인공지능 시스템은 개별적인 시계열 데이터의 예측에 초점을 맞추고 있어서 중요한 설명을 제공할 수 있는 전역적인 변화를 찾기 어렵고, 이런 인공지능 기술에 의한 예측은 그 변화의 이유를 설명하지 못한다는 점에서 한계점이 있다. 이러한 예측이 보다 신뢰성을 얻기 위해서는 비정형 변화를 보이는 시계열 데이터를 더욱 정확하게 예측하고, 예측만 하는 것이 아니라 이유의 변화에 대한 설명을 제공할 수 있어야 한다. 기존 단순 통계적인 기법 및 템플릿 기반 설명 기법은 예측성 및 설명성에서 이러한 한계가 존재한다.

발명의 내용

해결하려는 과제

[0005] 본 발명에서는 상기 종래 기술의 문제점을 감안하여, 인공지능으로 주식, 환율, 집값 등 시계열 데이터 변화를 예측하고, 그 이유를 같이 제공하는 기술을 제공함으로써, 기존의 예측 시스템보다 정확도와 신뢰도를 높일 수 있는 시계열 데이터 변화 예측 및 이유 설명 시스템을 제공하고자 한다.

과제의 해결 수단

[0007] 일 측에 따른 시계열 데이터 자동 분석 방법은 시계열 데이터에 기초하여, 상기 시계열 데이터의 변화를 예측하는 적어도 하나의 커널을 생성하는 단계, 상기 시계열 데이터에 대응하는 미리 정해진 템플릿에 기초하여, 상기 적어도 하나의 커널을 설명하는 제1 정보를 생성하는 단계, 상기 시계열 데이터의 시간 구간에 대응하는 자료로부터, 상기 제1 정보의 원인으로 이용 가능한 제2 정보를 추출하는 단계, 및 상기 제1 정보 및 상기 제2 정보에

기초하여, 상기 시계열 데이터에 대한 보고서를 생성하는 단계를 포함한다.

- [0008] 상기 적어도 하나의 커널을 생성하는 단계는 가우시안 커널 분할 학습 기법을 이용하여, 상기 적어도 하나의 커널을 생성하는 단계를 포함할 수 있다.
- [0009] 상기 시계열 데이터는 다중 시계열 데이터를 포함하고, 상기 적어도 하나의 커널은 부드러운 변화를 예측하는 제1 커널, 짧은 주기의 변화를 예측하는 제2 커널, 및 상기 다중 시계열 데이터의 공통적 변화를 예측하는 제3 커널을 포함할 수 있다.
- [0010] 상기 시계열 데이터는 다중 시계열 데이터를 포함하고, 상기 적어도 하나의 커널을 생성하는 단계는 상기 다중 시계열 데이터의 공통 정보를 추출하는 단계, 상기 공통 정보에 기초하여, 상기 다중 시계열 데이터 각각의 개별 정보를 추출하는 단계, 및 상기 개별 정보와 상기 공통 정보를 혼합하여 상기 시계열 데이터 변화를 예측하는 커널을 생성하는 단계를 포함할 수 있다.
- [0011] 상기 제1 정보를 생성하는 단계는 상기 적어도 하나의 커널에 기초하여, 상기 예측된 변화와 관련된 수치를 결정하는 단계, 상기 적어도 하나의 커널에 기초하여, 상기 예측된 변화를 설명하는 텍스트를 결정하는 단계, 및 상기 수치 및 상기 텍스트를 상기 템플릿에 삽입함으로써, 상기 제1 정보를 생성하는 단계를 포함할 수 있다.
- [0012] 상기 제2 정보를 추출하는 단계는 양방향 리커런트 신경망을 이용하여, 상기 자료 내 문장에 포함된 복수의 단어들 중 중요 단어를 선별하는 단계, 상기 양방향 리커런트 신경망을 이용하여, 상기 자료 내 복수의 문장들 중 중요 문장을 선별하는 단계 중 적어도 하나를 포함할 수 있다.
- [0013] 상기 자료는 상기 시계열 데이터 내용을 포함하는 뉴스, 분기 보고서, 및 전문가 보고서 중 적어도 하나를 포함할 수 있다.
- [0014] 상기 보고서를 생성하는 단계는 상기 제2 정보 중 상기 제1 정보의 결론에 부합하는 제3 정보를 추출하는 단계, 상기 제3 정보를 상기 제1 정보의 원인으로 설명하는 정보를 생성하는 단계를 포함할 수 있다.
- [0015] 상기 보고서를 생성하는 단계는 상기 적어도 하나의 커널은 복수의 커널들을 포함하고, 상기 보고서를 생성하는 단계는 상기 제1 정보를 상기 복수의 커널들에 대응하여 분류하는 단계, 상기 제2 정보를 상기 복수의 커널들에 대응하여 분류하는 단계, 상기 복수의 커널들에 대응하여, 상기 제1 정보와 상기 제2 정보를 매칭하는 단계, 상기 매칭 결과에 기초하여, 상기 복수의 커널들 각각에 대응하여 예측된 결과 및 해당하는 결과의 원인을 설명하는 정보를 생성하는 단계를 포함할 수 있다.

발명의 효과

- [0017] 본 발명에 따르면, 시계열 데이터 군의 공통적인 변화를 표현하는 원인과 개별적인 시계열 데이터의 변화 원인을 자동으로 조합할 수 있는 알고리즘을 제공함으로써, 빠르고 정확하게 전역적인 변화를 찾을 수 있다는 이점이 있다.
- [0018] 또한, 딥러닝 기반 설명 모델을 통해, 방대한 양의 뉴스 혹은 금융 보고서에서 변화에 대한 이유를 찾아서 설명을 제공할 수 있다.

도면의 간단한 설명

- [0020] 도 1은 일 실시예에 따른 시계열 데이터의 자동 분석 방법을 도시한 순서도.
- 도 2는 일 실시예에 따른 시계열 데이터의 자동 분석 방법 및 그 결과를 도시한 도면.
- 도 3은 일 실시예에 따른 관계형 커널 학습 과정 알고리즘을 도시한 도면.
- 도 4는 일 실시예에 따른 관계형 커널 학습 모델을 도시한 도면.
- 도 5은 일 실시예에 따른 양방향 리커런트 신경망을 도시한 도면.

발명을 실시하기 위한 구체적인 내용

- [0021] 이하에서, 첨부된 도면을 참조하여 실시예들을 상세하게 설명한다. 그러나, 실시예들에는 다양한 변경이 가해

질 수 있어서 특허출원의 권리 범위가 이러한 실시예들에 의해 제한되거나 한정되는 것은 아니다. 실시예들에 대한 모든 변경, 균등물 내지 대체물이 권리 범위에 포함되는 것으로 이해되어야 한다.

[0022] 실시예에서 사용한 용어는 단지 설명을 목적으로 사용된 것으로, 한정하려는 의도로 해석되어서는 안 된다. 단수의 표현은 문맥상 명백하게 다르게 뜻하지 않는 한, 복수의 표현을 포함한다. 본 명세서에서, "포함하다" 또는 "가지다" 등의 용어는 명세서 상에 기재된 특징, 숫자, 단계, 동작, 구성요소, 부품 또는 이들을 조합한 것이 존재함을 지정하려는 것이지, 하나 또는 그 이상의 다른 특징들이나 숫자, 단계, 동작, 구성요소, 부품 또는 이들을 조합한 것들의 존재 또는 부가 가능성을 미리 배제하지 않는 것으로 이해되어야 한다.

[0023] 다르게 정의되지 않는 한, 기술적이거나 과학적인 용어를 포함해서 여기서 사용되는 모든 용어들은 실시예가 속하는 기술 분야에서 통상의 지식을 가진 자에 의해 일반적으로 이해되는 것과 동일한 의미를 가지고 있다. 일반적으로 사용되는 사전에 정의되어 있는 것과 같은 용어들은 관련 기술의 문맥 상 가지는 의미와 일치하는 의미를 가지는 것으로 해석되어야 하며, 본 출원에서 명백하게 정의하지 않는 한, 이상적이거나 과도하게 형식적인 의미로 해석되지 않는다.

[0024] 또한, 첨부 도면을 참조하여 설명함에 있어, 도면 부호에 관계없이 동일한 구성 요소는 동일한 참조부호를 부여하고 이에 대한 중복되는 설명은 생략하기로 한다. 실시예를 설명함에 있어서 관련된 공지 기술에 대한 구체적인 설명이 실시예의 요지를 불필요하게 흐릴 수 있다고 판단되는 경우 그 상세한 설명을 생략한다.

[0025] 이하, 실시예들을 첨부된 도면을 참조하여 상세하게 설명한다.

[0027] 도 1은 일 실시예에 따른 시계열 데이터의 자동 분석 방법을 도시한 순서도이다.

[0028] 도 1을 참조하면, 일 실시예에 따른 시계열 데이터의 자동 분석 방법은 시계열 데이터의 예측에 관한 제1 정보를 생성하는 단계(100)와 제1 정보의 원인으로 이용 가능한 제2 정보를 획득하고, 제1 정보와 제2 정보를 기초로 시계열 데이터의 예측 및 그 예측의 원인을 설명하는 보고서를 생성하는 단계(150)를 포함한다. 최종 출력인 보고서는 기계 학습을 통한 시계열 데이터의 분석, 예측뿐만 아니라 그러한 분석, 예측에 대한 이유와 변화에 대한 설명을 포함한다.

[0029] 제1 정보를 생성하는 단계(100)는 시계열 데이터에 기초하여, 시계열 데이터의 변화를 예측하는 적어도 하나의 커널을 생성하는 단계 및 시계열 데이터에 대응하는 미리 정해진 템플릿에 기초하여, 적어도 하나의 커널을 설명하는 제1 정보를 생성하는 단계를 포함한다. 제1 정보는 수치 데이터, 및 수치 데이터를 설명하기 위한 글과 그래프를 포함하는 보고서일 수 있다.

[0030] 제2 정보 및 보고서를 생성하는 단계(150)는 시계열 데이터의 시간 구간에 대응하는 자료로부터, 제1 정보의 원인으로 이용 가능한 제2 정보를 추출하는 단계; 및 제1 정보와 제2 정보에 기초하여, 시계열 데이터에 대한 보고서를 생성하는 단계를 포함한다.

[0031] 제1 정보를 생성하는 단계(100)에서는 기계 학습을 통해 시계열 데이터를 예측하는 것을 목표로 할 수 있다. 제1 정보를 생성하는 단계(100)는 시계열 데이터를 수신하는 단계(105), 수신한 시계열 데이터를 전처리 하는 단계(110)를 포함할 수 있다. 시계열 데이터는 시간에 따라 변화하는 변수의 기록일 수 있다. 예를 들어, 시계열 데이터는 시간별 주식 가격, 시간별 환율의 변화, 시간별 국제유가를 포함할 수 있다. 시계열 데이터는 다중 시계열 데이터를 포함할 수 있다. 다중 시계열 데이터는 시간에 따라 변화하는 다수의 변수의 기록일 수 있다. 예를 들어 다중 시계열 데이터는 시간별 다수의 주식 가격, 시간별 다수의 환율의 변화를 포함할 수 있다. 시계열 데이터의 분석은 여러 가지 복합적인 요소가 영향을 미치기 때문에 예측에 영향을 주는 요소를 정확히 찾는 것이 어려울 수 있다. 다중 시계열 데이터의 변화를 고려하면 여러 종류의 다중 시계열 데이터에서 공통 특징과 차이점을 추출하여, 시계열 데이터의 보다 정확한 예측이 가능할 수 있다. 다중 시계열 데이터에서 공통 특징과 차이점을 추출하는 구체적인 방법은 후술한다.

[0032] 기계 학습은 미리 준비된 데이터를 이용하여 인식기(예를 들어, 뉴럴 네트워크)를 학습시키는 단계와 학습된 데이터를 이용하여 새로 입력되는 데이터를 처리하는 단계로 나뉠 수 있다. 시계열 데이터의 경우 특정 기간의 데이터를 포함하며, 입력되는 시계열 데이터의 기간 이후의 상황이 예측될 수 있다. 제1 정보를 생성하는 단계(100)는 전처리된 시계열 데이터를 기계 학습의 일 실시예에 해당하는 가우시안 커널 분할 학습하는 단계(120)를 포함할 수 있다. 학습 종료 조건(125)을 만족할 때까지 가우시안 커널 분할 학습을 할 수 있다. 학습이 완료되면 시계열 데이터의 변화를 예측하는 적어도 하나의 커널을 생성할 수 있다. 적어도 하나의 커널이 생성되

면, 미리 정해진 템플릿에 기초하여, 적어도 하나의 커널을 설명하는 제1 정보가 생성될 수 있다(135).

[0034] 제2 정보 및 보고서를 생성하는 단계(150)는 제2 정보를 생산하는 단계와 보고서를 생성하는 단계를 포함할 수 있다. 제2 정보를 생산하는 단계는 자료를 수신하는 단계(155), 수신한 자료를 전처리 하는 단계(160)를 포함할 수 있다. 자료는 시계열 데이터의 시간 구간에 대응하는 자료로, 시계열 데이터 내용을 포함하는 뉴스, 분기 보고서, 및 전문가 보고서 중 적어도 하나를 포함할 수 있다. 예를 들어 시계열 데이터의 시간 구간이 2018년 1월이라면, 그 시간 구간에 해당하는 뉴스, 분기 보고서, 전문가 보고서 등이 제2 정보를 추출하기 위해 입력 받는 자료일 수 있다. 전처리된 자료는 요약 딥러닝(170)을 통해 문서 읽기가 종료될 때까지(175) 자료를 요약하여 제1 정보의 원인으로 이용 가능한 제2 정보를 추출할 수 있다. 요약 딥러닝의 구체적인 방법에 대해서는 후술하겠다.

[0035] 보고서를 생성하는 단계에서는 제1 정보를 생성하는 단계(100)에서 생성된 제1 정보 및 제2 정보를 생산하는 단계에서 생성된 제2 정보에 기초하여 설명융합 딥러닝(180)을 통해 제2 정보 중 제1 정보의 결론에 부합하는 정보를 추출하고, 추출된 정보와 제1 정보를 사람이 이해할 수 있는 내용으로 수치적인 변화를 딥러닝을 통해 분석하여 자연스러운 문장을 생성하여 최종 보고서를 작성(185)할 수 있다. 딥러닝 기반 설명 모델은 방대한 양의 보고서를 처리 가능하기 때문에, 변화에 대한 이유를 정확하게 찾아서 설명을 제공할 수 있다. 다시 말해, 일 실시예에 따른 기계 학습 기법은 시계열 데이터를 분석, 예측하여 제1 정보를 생성하고, 시계열 데이터에 상응하는 자료를 요약하여 제2 정보를 생성하며, 제1 정보와 제2정보에 기초하여 시계열 데이터의 예측과 그 원인이 포함된 보고서를 자동으로 생성할 수 있다.

[0037] 도 2는 일 실시예에 따른 시계열 데이터의 자동 분석 방법 및 그 결과를 도시한 도면이다.

[0038] 도2를 참조하면, 특정 시간 구간에 따른 국제 유가 데이터를 시계열 데이터로 입력(210) 받을 수 있다. 국제 유가 데이터를 입력 받아 기계 학습(220)을 시킬 수 있다. 예를 들어, 기계 학습을 통해 국제 유가 데이터의 변화를 예측하는 적어도 하나의 커널을 생성할 수 있다. 도2의 예시에서는 세 개의 커널이 생성되었다. 생성된 커널을 종합하여 국제 유가의 변동 예측에 관한 제1 정보인, 국제 유가 변화에 대한 그래프가 출력(230)될 수 있다.

[0039] 다른 일 측에서 국제 유가 데이터와 동일한 시간 구간에 따른 뉴스, 보고서 등을 자료로 입력(260) 받을 수 있다. 입력 받은 자료로부터 딥러닝을 이용하여 주요 문장을 추출하여 제2 정보가 추출(270)될 수 있다. 예를 들어, 도 2에서는 “석유가격”, “미국 셰일 오일의 빠른 생산 증가”, “가속된 미국 원유 생산”, 및 “달러화 강세”가 제2 정보에 해당할 수 있다. 일 실시예에 따른 학습 기법은 제2 정보 중 제1 정보의 결론에 부합하는 제3 정보를 추출하고, 이를 제1 정보의 원인으로 결정하고, 제1 정보와 결합하여 자연스러운 문장이 되도록 딥러닝 후 최종 보고서를 생성(280)할 수 있다.

[0041] 제1 정보를 생성하는 단계(100)에서는 기계 학습을 통해 시계열 데이터를 예측하는 것을 목표로 할 수 있다. 시계열 데이터를 예측하기 위해 기계 학습의 일 실시예인 가우시안 커널 분할 학습 기법을 이용할 수 있다. 가우시안 커널 분할 학습을 서술하기 전에 가우시안 프로세스 및 구성 커널 학습에 대해 서술하겠다.

[0042] 가우시안 프로세스는 특정 모델을 가정하지 않고, 여러 개의 정규 분포를 겹쳐놓는 방식으로 함수를 예측하는 다중 가우시안(multivariate Gaussian)일 수 있다. 관측된 데이터 각각마다 해당 데이터 값을 중심으로 하는 커널 함수를 생성하고, 생성된 커널 함수들을 모두 더한 후 전체 데이터 개수로 나누는 방법일 수 있다. 커널 함수의 종류에 따라 추정 결과가 달라질 수 있다. 적당한 커널을 학습하는 것이 가우시안 프로세스에서 중요할 수 있다. 공분산 커널은 덧셈과 곱셈에 닫혀있을 수 있다. 이를 이용한 구성 커널 학습(Compositional Kernel Learning: CKL)을 통해 여러 기본 커널(base kernel)과 연산(operation)으로 구성된 보다 풍부한 커널을 얻을 수 있다.

[0044] 가우시안 프로세스는 연속 시계열 공간의 변수 중 유한한 변수를 선택하였을 경우 가우시안 분포로 표현할 수 있다고 가정하는 비변수적(non-parametric) 가우시안 모델일 수 있다. 다변량 가우시안 분포가 평균 벡터 μ 와

공분산 행렬 Σ 에 의해 구체화 될 때, 가우시안 프로세스는 그것의 평균 함수인 $\mu(x)=\mathbb{E}(f(x))$ 및 공분산 커널 함수 $k(x, x')=\text{Cov}(f(x), f(x'))$ 에 의해 구체화 될 수 있다. 유한 점 집합에 대한 두 함수는 $\mu_i=\mu(x_i)$ 와 $\Sigma_{ij}=k(x_i, x_j)$ 와 같은 다변량 가우스 분포에 대한 평균 벡터와 공분산 행렬에 대응될 수 있다. 가우시안 프로세스가 명시될 때, 주어진 데이터의 한계 가능성(marginal likelihood)를 계산할 수 있거나 기존 데이터가 주어진 새로운 점에 대한 예측 분포를 도출 할 수 있다. 가우시안 프로세스의 분포를 수학적식과 같이 평균 함수와 공분산 함수로 표기할 수 있다.

수학적식 1

$$f \sim \mathcal{GP}(\mu(x), k(x, x'))$$

공분산 커널 함수는 커널 함수를 정의 할 때 자유 파라미터인 하이퍼 파라미터를 가질 수 있다. 예를 들어, 제곱 지수 함수 $k(x, x') = \sigma^2 \exp(|x - x'|^2/\ell)$ 는 σ 와 ℓ 의 두 가지 하이퍼 파라미터를 가질 수 있다. $k(x, x'; \theta)$ 를 커널 함수로 정의할 수 있다. 벡터 θ 는 하이퍼 파라미터일 수 있다.

구성 커널 학습(Compositional Kernel Learning: CKL)을 통해 여러 베이스 커널과 연산(operation)으로 구성된 보다 풍부한 커널을 구성할 수 있다. 이론적으로, 양의 무한한 커널은 덧셈과 곱셈에 의해 닫혀있을 수 있다. 각 기본 커널은 선형성 또는 주기성과 같은 각 고유 한 특징을 나타낼 수 있다. 커널 연산에는 덧셈과 곱셈뿐만 아니라 갑작스런 구조 변화에 대처하기 위한 변경점(change-point) 및 변경 창 연산(change-window operation)이 포함될 수 있다.

구성 커널을 만들기 위해 표1과 같은 다섯 개의 기본 커널이 사용될 수 있다. 각 커널은 기능이 다른 특성을 인코딩하므로 새로운 데이터로 구조 및 추론의 일반화가 가능할 수 있다.

표 1

Base Kernels	Encoding Function
White Noise (WN)	Uncorrelated noise
Constant (C)	Constant functions
Linear (LIN)	Linear functions
Squared Exponential (SE)	Smooth functions
Periodic (PER)	Periodic functions

수학적식2처럼 여러 커널 함수를 합산하고 새로운 커널 함수를 만드는 추가할 수 있다.

수학적식 2

$$k'(x, x') = k_1(x, x') + k_2(x, x')$$

여러 독립 공분산 함수의 중첩이 가능할 수 있다. 예를 들어,

$$f_1 \sim \mathcal{GP}(\mu_1, k_1), f_2 \sim \mathcal{GP}(\mu_2, k_2) \text{ 이면 } f := f_1 + f_2 \sim \mathcal{GP}(\mu_1 + \mu_2, k_1 + k_2) \text{ 일 수 있다.}$$

평균을 알 수 없는 함수에 대한 한계화가 새로운 커널을 가진 제로 평균 가우시안 프로세스로 등가적으로 표현될 수 있으므로 Automatic Bayesian Covariance Discovery(ABCD)는 가우시안 프로세스에 대한 평균을 0으로 가정할 수 있다. 이 가정 하에서, 수학적식 3의 곱셈 연산이 가능할 수 있다.

수학식 3

$$k'(x, x') = k_1(x, x') \times k_2(x, x')$$

일반적으로 $f_1 \sim \mathcal{GP}(0, k_1), f_2 \sim \mathcal{GP}(0, k_2)$ 이면 $f := f_1 \times f_2 \sim \mathcal{GP}(0, k_1 \times k_2)$ 를 만족한다.

두 개의 커널 함수 k_1 과 k_2 가 주어지면 새로운 커널 함수는 수학식 4와 같이 표현될 수 있다.

수학식 4

$$k'(x, x') = \sigma(x)k_1(x, x')\sigma(x') + (1 - \sigma(x))k_2(x, x')(1 - \sigma(x'))$$

$\sigma(x)$ 는 0과 1 사이의 s자형 함수(sigmoidal function)이고 ℓ 은 변경점(change-point)일 수 있다. 변경점(change-point) 동작은 함수의 정의역(시간 축)을 양측으로 분할하고 각각의 면에서 상이한 커널 기능을 적용할 수 있다.

변경 창 연산(change-window operation)은 변경점 연산을 두 개의 다른 변경 지점 ℓ_1 과 ℓ_2 로 두 번 적용하여 행해질 수 있다. $\ell_1 < \ell_2$ 인 두 개의 sigmoidal 함수 $\sigma_1(x; \ell_1)$ 과 $\sigma_2(x; \ell_2)$ 가 주어지면 새로운 함수는 수학식5가 될 수 있고, 함수 f_1 을 윈도우 (ℓ_1, ℓ_2)에 적용할 수 있다.

수학식 5

$$f := \sigma_1(x)f_1(1 - \sigma_2(x)) + (1 - \sigma_1(x))f_2\sigma_2(x)$$

변경 창 작업 이후의 복합(composite) 커널 표현식은 다음과 같을 수 있다.

$$k'(x, x') = \sigma_1(x)(1 - \sigma_2(x))k_1(x, x')\sigma_1(x')(1 - \sigma_2(x')) + (1 - \sigma_1(x))\sigma_2(x)k_2(x, x')(1 - \sigma_1(x'))\sigma_2(x')$$

ABCD는 검색 문법(Search grammar)에 기초하여 복합(composite) 커널을 검색할 수 있다. 검색 문법을 이용하여 기본 커널과 함께 연산을 적용하여 현재 커널 표현식을 생성하는 방법을 구체화할 수 있다. 수학식 6은 규칙은 일반적인 검색 문법의 예일 수 있다.

수학식 6

$$\begin{array}{ll} \mathcal{S} \rightarrow \mathcal{S} + \mathcal{B} & \mathcal{S} \rightarrow \mathcal{S} \times \mathcal{B} \\ \mathcal{S} \rightarrow \text{CP}(\mathcal{S}, \mathcal{S}) & \mathcal{S} \rightarrow \text{CW}(\mathcal{S}, \mathcal{S}) \\ \mathcal{S} \rightarrow \mathcal{B} & \mathcal{S} \rightarrow \mathcal{C} \end{array}$$

$\mathcal{S}$ 는 커널 서브 표현식을 나타내고, $\mathcal{B}$ 와 $\mathcal{B}'$ 은 기본 커널일 수 있다. 예를 들어, 커널 표현식 $\mathcal{E} = \mathcal{K}_1 + \mathcal{K}_2 + \mathcal{K}_3$ 이 있다고 가정할 수 있다. $\mathcal{K}_i$ 는 더 이상 뗏셈으로 분리 할 수 없는 커널 표현식일 수 있다. 커널 서브 표현식 $\mathcal{S}$ 는 $\mathcal{K}_i$ 의 비어있지 않은 서브 세트의 합계가 될 수 있다. 부분 집합 $(\mathcal{K}_1 + \mathcal{K}_3)$ 에 곱셈 문법을 기본 커널 $\mathcal{B}_1$ 에 적용하면, 확장 된 커널 표현은 $\mathcal{E}' = \mathcal{K}_2 + (\mathcal{K}_1 + \mathcal{K}_3) \times \mathcal{B}_1$ 일 수 있다.

[0071] 데이터와 최대 검색 깊이(maximum search depth)가 주어지면 알고리즘은 구성 커널 $k(x, x'; \theta)$ 를 추출할 수 있다. 알고리즘은 백색 소음(WN) 커널에서 시작하여 검색 문법을 기반으로 커널 표현식을 확장하고, 확장된 커널의 하이퍼 파라미터를 최적화하며 데이터가 있는 커널을 평가하고 그 중에서 가장 적합한 커널을 선택할 수 있다. 이 절차를 반복하며 학습할 수 있다. 다음 이터레이션(iteration)은 이전 이터레이션(iteration)에서 선택된 가장 적합한 구성 커널로 시작될 수 있다. 공액 그라디언트 방법(conjugate gradient method)은 하이퍼 파라미터를 최적화 할 때 사용될 수 있다. 베이시안 정보 기준(Bayesian Information Criterion: BIC)은 모델 평가에 사용될 수 있다.

[0072] 자유 파라미터의 수가 $|M|$ 인 모델 M 의 베이시안 정보 기준(BIC)과 데이터 포인트의 수가 $|D|$ 인 데이터 D 의 관계는 수학적식 7 같을 수 있다.

수학적식 7

[0073]
$$\text{BIC}(\mathcal{M}) = -2 \log p(\mathcal{D}|\mathcal{M}) + |\mathcal{M}| \log |\mathcal{D}|$$

[0075] 이터레이션은 지정된 최대 검색 깊이에 도달 할 때까지 계속될 수 있다. 반복하는 동안 알고리즘은 출력에 가장 적합한 모델을 가지고 있을 수 있다.

[0076] 일 실시예에 따르면, 알고리즘의 작동 방식은 백색 소음(WN) 커널에서 시작한다고 가정할 수 있다. $\text{WN} \rightarrow \text{WN} + \text{SE}$, $\text{WN} \rightarrow \text{WN} + \text{LIN}$ 등과 같이 기본 커널을 사용하여 연산자를 적용할 수 있다. 확장된 커널을 사용하여 알고리즘은 확장된 각 커널의 하이퍼 파라미터를 최적화하여, 최적화 된 모든 커널을 획득할 수 있다. 최적화 된 것들을 비교하고 BIC 측면에서 최고의 커널을 선택할 수 있다. 이 절차는 특정 깊이의 검색을 충족 할 때까지 반복될 수 있다. 예를 들어, 이전 단계에서 선택한 최상의 커널이 $\text{WN} + \text{SE}$ 라고 가정할 수 있다. $\text{WN} + \text{SE} \rightarrow \text{WN} + \text{SE} \times \text{LIN}$ 등과 같이 커널 확장을 다시 적용할 수 있다. 이를 통해, 하이퍼 파라미터를 최적화하고 최상의 커널을 선택한 다음 다음 단계로 진행할 수 있다.

[0078] 다중 시계열 데이터가 입력되는 경우에는, 데이터 군에서 추출한 공유 정보와 개별 데이터에서 추출한 특징 정보를 혼합하여 시계열 데이터의 자동 분석 정확도를 더욱 향상시킬 수 있다. 예를 들어, 개별적인 시계열 데이터의 예측에 초점을 맞추면, 제공할 수 있는 전역적인(global) 변화를 찾기 어려울 수 있다. 다중 시계열 데이터의 공유 정보를 이용하면 전역적인 변화를 찾을 수 있다. 개별 시계열 데이터를 효율적으로 학습할 수 있는 스펙트럴 커널을 통해서 우선 학습하고, 시계열 데이터의 군에서 학습된 관계형 모델과 혼합하여 최적의 조합을 찾을 수 있는 관계형 커널 학습 알고리즘을 통해 기존의 개별 시계열 데이터 분석보다 정확한 예측이 가능할 수 있다. 스펙트럴 혼합 커널은 가우시안 과정의 공분산을 다른 주기를 갖는 스펙트럼의 혼합으로 표현하는 커널일 수 있다. 생성된 커널을 통해 시계열 데이터의 변화를 예측할 수 있다.

[0079] 다중 시계열 데이터의 관계형 커널 학습을 통해, 다중 시계열 데이터의 공통 정보를 추출하고, 공통 정보에 기초하여 다중 시계열 데이터 각각의 개별 정보를 추출하고, 개별 정보와 상기 공통 정보를 혼합하여 시계열 데이터 변화를 예측하는 커널을 생성할 수 있다. 학습에 의해 커널을 결정하면, 그 커널은 데이터의 분포를 제공할 수 있다. 예를 들어, 커널은 함수의 형태로 데이터의 분포를 제공할 수 있다.

[0081] 관계형 커널 학습은 수학적식 8 같은 일련의 커널을 학습하는 것을 목표로 할 수 있다.

수학적식 8

[0082]
$$\mathbf{K} = \{K_j = K_S + K_{d_j} | d_j \in \mathcal{D}, j = 1, \dots, M\}$$

[0083] K_S 는 M 개의 시퀀스 중 공유 커널이고, K_{d_j} 는 j 번째 시퀀스에 대한 특징 커널일 수 있다. 우리가 시계열 데이터를 나무에 비유하면, 공유 커널은 나무 기둥의 일반적인 모양을 나타낼 수 있고, 특징 커널은 작은 가지와 잎을 나타낼 수 있다. 이상적으로, 검색 문법은 하나의 공유 커널과 M 개의 특징 커널을 발견하기 위해 수행 될 수 있다. 검색 양을 줄이기 위해, 각 시계열에 대한 고유 한 커널은 광범위한 검색 문법을 따르지 않고 스펙트럼 혼합(SM) 커널을 사용할 수 있다. 스펙트럼 혼합 커널은 가우시안 과정의 공분산을 다른 주기를 갖는 스펙트럼의 혼합으로 표현하는 커널일 수 있다. 스펙트럼 혼합 커널은 수학식 9와 같을 수 있다.

수학식 9

$$k(\tau) = \sum_{q=1}^Q w_q \prod \exp\{-2\pi^2 \tau_p^2 v_q^{(p)}\} \cos(2\pi \tau_p \mu_q^{(p)})$$

[0084]

[0085] Q는 구성 요소의 수이며, $\tau = x-x'$ 는 P 차원 벡터일 수 있다. 스펙트럼 혼합 커널은 넓은 범위의 공분산 커널을 표현할 수 있기 때문에 선택될 수 있다.

[0087] 도 3은 일 실시예에 따른 관계형 커널 학습 과정 알고리즘을 도시한 도면이다.

[0088] 도 3를 참조하면, 관계형 커널 학습은 각 데이터 시퀀스에 대해 고유 한 커널을 사용하여 가우시안 프로세스 커널 구조를 구체화할 수 있다. 검색 문법은 각 깊이 s에 대한 복합(composite) 커널의 생성자 역할을 할 수 있다. 검색 공간의 각 커널에 대해 하이퍼 파라미터는 다음과 같이 구성될 수 있다. 공유 하이퍼 파라미터는 θ_S , 스케일 인자는 $\sigma_1, \dots, \sigma_M$ 이고, 특징 하이퍼 파라미터 $\theta_1, \dots, \theta_M$ 일 수 있다. 최적의 하이퍼 매개 변수는 커널 K에 대한 데이터의 최소 음의 로그 가능성(negative log likelihood)을 찾는 것에 기반하여 학습될 수 있다. 시계열 데이터 사이에서 가장 공통적인 구성 요소를 찾기 위함일 수 있다. 검색 문법은 공유 커널 K_S 에서 BIC 스코어에 의해 가장 좋은 공유 커널을 식별할 수 있다. 공유 커널에 대한 각 시계열 데이터의 가능성의 합계로 가장 좋은 공유 커널 가능성이 계산될 수 있다.

[0090] 도 4는 일 실시예에 따른 관계형 커널 학습 모델을 도시한 도면이다.

[0091] 도 4를 참조하면, 관계형 커널 학습 모델은 개별적인 데이터를 표현하는 특징 커널 및 관계형 데이터 K_{d_j} 를 표현하는 공유 커널 K_S 을 함께 학습할 수 있다.

[0093] 커널은 데이터의 분포를 제공할 수 있다. 데이터 분포를 제공하는 적어도 하나의 커널은 부드러운 변화를 예측하는 제1 커널에 의한 예측, 짧은 주기의 변화를 예측하는 제2 커널에 의한 예측, 및 다중 시계열 데이터의 공통적 변화를 예측하는 제3 커널에 의한 예측을 포함할 수 있다. 다중 시계열 데이터를 사용할 경우 관계형 커널 학습 모델을 통해 제3 커널을 생성할 수 있어, 정확하고 전역적인 예측을 할 수 있다. 유의미한 커널들의 예측을 종합하여 하나의 결론을 낼 수 있다. 예를 들어, 제1 커널 내지 제3커널이 유의미할 경우, 제1 커널 내지 제3커널의 공통점을 추출하여 하나의 결론을 낼 수 있다. 또는, 제1 커널 내지 제3커널의 중요도에 따라 계산하여 결론을 낼 수도 있다. 결론의 형태는 상기 적어도 하나의 커널에 기초하여, 예측된 변화와 관련된 수치, 및 텍스트를 포함할 수 있다. 상기 수치 및 상기 텍스트를 상기 템플릿에 삽입함으로써, 상기 제1 정보를 생성할 수 있다.

[0095] 일 실시예에 따르면, 시계열 데이터의 시간 구간에 대응하는 자료를 수신할 수 있다. 수신한 자료를 양방향 리커런트 신경망을 이용한 요약 딥러닝을 통해 제2 정보를 생성할 수 있다. 일 실시예에 따르면, 양방향 리커런트 신경망을 이용하여, 자료 내 문장에 포함된 복수의 단어들 중 중요 단어를 선별, 요약하거나, 자료 내 복수의 문장들 중 중요 문장을 선별, 요약하여 제2 정보를 생성할 수 있다. 설명 융합 딥러닝을 통해 생성된 제2

정보 중 제1 정보의 결론에 부합하는 제3 정보를 추출할 수 있다. 제3 정보를 제1 정보의 원인으로 설명하는 정보를 생성할 수 있다. 설명 융합 딥러닝을 통해, 생성된 제3정보와 제1 정보를 문법에 맞는 자연스러운 문장으로 구성된 보고서를 생성할 수 있다.

[0097] 도 6은 일 실시예에 따른 양방향 리커런트 신경망을 도시한 도면이다.

[0098] 도 6에 따르면, 리커런트 신경망은 시계열 특성을 반영한 모델일 수 있다. 리커런트 신경망은 입력 레이어, 히든 레이어, 출력 레이어를 포함할 수 있는데, 현재 히든 레이어의 값이 다음 출력값의 계산에 영향을 줄 수 있다. 리커런트 신경망은 히든 레이어의 노드가 방향을 가진 엣지로 연결돼 순환구조를 이루는(directed cycle) 인공신경망의 한 종류일 수 있다. 리커런트 신경망의 핵심은 노드간, 레이어간 최적 파라미터를 찾는 것일 수 있다. 리커런트 신경망을 양방향 리커런트 신경망으로 확장할 수 있다. 양방향 리커런트 신경망은 순서 데이터를 모델링할 때, 현재 순서 데이터가 전 데이터뿐만 아니라 후 데이터에 영향을 받을 수 있다. 단방향 리커런트 신경망이 전 데이터와 현재 데이터만 참조하는 것과는 달리, 양방향 리커런트 신경망은 전 데이터와 후 데이터 그리고 현재 데이터를 모두 참조할 수 있다. 양방향 리커런트 신경망을 이용해 요약 딥러닝과 설명 융합 딥러닝을 할 수 있다.

[0100] 다시 도 1을 참조하면, 요약 딥러닝을 수행하는 단계(170)에서 양방향 리커런트 신경망이 이용될 수 있다. 시계열 데이터의 시간 구간 내 뉴스나 분기 보고서 등을 입력 받아, 주요한 단어 또는 문장이 추출될 수 있다.

[0101] 이를 위하여, 학습 페이지에서 트레이닝 데이터에 해당하는 뉴스나 분기 보고서가 입력되면서, 주요한 단어 또는 문장에 태깅이 될 수 있다. 양방향 리커런트 신경망은 태깅된 단어 또는 문장에 따라 학습될 수 있다. 예를 들어, 트레이닝 데이터에 해당하는 뉴스나 분기 보고서로부터 태깅된 단어 또는 문장을 추출하도록 학습될 수 있다.

[0102] 일 실시예에 따르면, 양방향 리커런트 신경망에 문장 단위로 입력될 수 있다. 이 경우, 각 문장에 포함된 단어들 순차적으로 입력될 수 있다. 입력되는 단어들은 전처리를 거쳐 특징 벡터화 되어 입력될 수 있다. 전처리를 거쳐 생성되는 특징 벡터의 차원은 양방향 리커런트 신경망의 구조에 따라 미리 정해질 수 있다. 다른 실시예에 따르면, 양방향 리커런트 신경망에 문서 단위로 입력될 수 있다. 이 경우, 문서에 포함된 문장들이 순차적으로 입력되며, 입력되는 문장들은 전처리를 거쳐 특징 벡터화 될 수 있다.

[0103] 또한, 설명 융합 딥러닝을 수행하는 단계(180)에서도 리커런트 신경망이 이용될 수 있다. 단계(135)에서 생성된 제1 정보(예를 들어, 시계열 데이터의 예측된 변화에 대한 설명) 및 단계(170)에서 생성된 제2 정보(예를 들어, 해당하는 시간 구간 내 주요 이벤트들)가 조합되어 보고서가 자동으로 생성될 수 있다.

[0104] 일 예로, 제2 정보에 포함된 복수의 후보들 중 제1 정보의 결론에 부합되는 후보가 추출될 수 있다. 추출된 후보는 제1 정보와 결합되어 자연스러운 문장의 형태로 출력될 수 있다. 제1 정보는 현상으로, 제2 정보는 현상에 대한 원인으로 이용될 수 있다.

[0105] 다른 예로, 제1 정보에 포함된 현상들과 제2 정보에 포함된 원인들 각각이 단계(130)에 의한 커널들로 분류될 수 있다. 이 경우, 동일한 커널로 분류된 현상과 원인이 결합되어 자연스러운 문장의 형태로 출력될 수 있다.

[0106] 전술한 예시들의 동작을 위하여, 학습 페이지에서 트레이닝 데이터에 결론 정보 혹은 분류 정보가 태깅되어 입력될 수 있다.

[0107] 이상에서, 설명의 편의를 위하여, 인공신경망의 구조를 한정적으로 예시하여 설명하였으나, 실시예들은 시계열 데이터의 변화를 예측하고, 그 변화와 원인을 자동으로 설명하는 정보를 생성하기에 적합한 구조로 다양하게 변형될 수 있다.

[0109] 실시예에 따른 방법은 다양한 컴퓨터 수단을 통하여 수행될 수 있는 프로그램 명령 형태로 구현되어 컴퓨터 판독 가능 매체에 기록될 수 있다. 상기 컴퓨터 판독 가능 매체는 프로그램 명령, 데이터 파일, 데이터 구조 등을 단독으로 또는 조합하여 포함할 수 있다. 상기 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. 상기된 하드웨어 장치는 실시예의 동작을 수행하기 위해 하나 이상의 소프트웨어 모듈로서 작동하도록 구성될 수 있으며, 그 역도 마찬가지이다.


[0110] 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 하나 이상의 컴퓨터 판독 가능 기록 매체에 저장될 수 있다.

[0111] 이상과 같이 실시예들이 비록 한정된 도면에 의해 설명되었으나, 해당 기술분야에서 통상의 지식을 가진 자라면 상기를 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.


[0112] 그러므로, 다른 구현들, 다른 실시예들 및 특허청구범위와 균등한 것들도 후술하는 청구범위의 범위에 속한다.

도면

도면1



도면2



도면3

Algorithm Semi-Relational Kernel Learning


Require: data $D = \{d_1, \dots, d_M\}$, grammar G , maximum depth of search s

```

1: Initialization:  $K \leftarrow \emptyset$ 
2: for  $i \in 0 \dots s$  do
3:    $K_S \leftarrow \text{expand}(G)$ 
4:    $\Theta \leftarrow \emptyset$ 
5:   for  $k_S \in K_S$  do
6:     Initialize  $\theta^0 \leftarrow (\theta_S^0, \theta_1^0, \dots, \theta_M^0, \sigma_1^0, \dots, \sigma_M^0)$ 
7:      $k_j(\theta^0) \leftarrow k_S(\theta_S^0, \sigma_j^0) + k_{d_j}(\theta_j^0), j = 1 \dots M$ 
8:      $\theta^* \leftarrow \text{argmin} \sum_{j=1}^M -\log p(\mathcal{D}|k_j(\theta))$ 
9:      $\Theta \leftarrow \Theta \cup \{(k_S, \theta^*)\}$ 
10:  end for
11:   $(\hat{k}_S, \hat{\theta}) \leftarrow \text{argmin}_{(k_S, \theta) \in \Theta} \text{BIC}(k_S, \mathcal{D})$ 
12:   $K \leftarrow K \cup (\hat{k}_S, \hat{\theta}, \hat{\sigma})$ 
13: end for
14: return  $K$ 

```

도면4



도면5

