

(12) 특허협력조약에 의하여 공개된 국제출원

(19) 세계지식재산권기구
국제사무국

(43) 국제공개일
2022년 1월 6일 (06.01.2022)



(10) 국제공개번호
WO 2022/005122 A1

- (51) 국제특허분류:
G06N 20/00 (2019.01)
- (21) 국제출원번호: PCT/KR2021/008054
- (22) 국제출원일: 2021년 6월 27일 (27.06.2021)
- (25) 출원언어: 한국어
- (26) 공개언어: 한국어
- (30) 우선권정보:
10-2020-0081218 2020년 7월 1일 (01.07.2020) KR
- (71) 출원인: 계명대학교 산학협력단 (INDUSTRY ACADEMIC COOPERATION FOUNDATION KEIMYUNG UNIVERSITY) [KR/KR]; 42601 대구시 달서구 달구벌대로 1095 (신당동), Daegu (KR).
- (72) 발명자: 고병철 (KO, Byoung Chul); 42601 대구시 달서구 달구벌대로 1095 (신당동), Daegu (KR). 김상원 (KIM, Sangwon); 42601 대구시 달서구 달구벌대로 1095 (신당동), Daegu (KR).
- (74) 대리인: 김진우 (KIM, Keon Woo); 08507 서울시 금천구 가산디지털1로 168 A-317 (가산동, 우림라이온스밸리), Seoul (KR).
- (81) 지정국 (별도의 표시가 없는 한, 가능한 모든 종류의 국내 권리의 보호를 위하여): AE, AG, AL, AM, AO, AT,

AU, AZ, BA, BB, BG, BH, BN, BR, BW, BY, BZ, CA, CH, CL, CN, CO, CR, CU, CZ, DE, DJ, DK, DM, DO, DZ, EC, EE, EG, ES, FI, GB, GD, GE, GH, GM, GT, HN, HR, HU, ID, IL, IN, IR, IS, IT, JO, JP, KE, KG, KH, KN, KP, KW, KZ, LA, LC, LK, LR, LS, LU, LY, MA, MD, ME, MG, MK, MN, MW, MX, MY, MZ, NA, NG, NI, NO, NZ, OM, PA, PE, PG, PH, PL, PT, QA, RO, RS, RU, RW, SA, SC, SD, SE, SG, SK, SL, ST, SV, SY, TH, TJ, TM, TN, TR, TT, TZ, UA, UG, US, UZ, VC, VN, WS, ZA, ZM, ZW.


- (84) 지정국 (별도의 표시가 없는 한, 가능한 모든 종류의 국내 권리의 보호를 위하여): ARIPO (BW, GH, GM, KE, LR, LS, MW, MZ, NA, RW, SD, SL, ST, SZ, TZ, UG, ZM, ZW), 유라시아 (AM, AZ, BY, KG, KZ, RU, TJ, TM), 유럽 (AL, AT, BE, BG, CH, CY, CZ, DE, DK, EE, ES, FI, FR, GB, GR, HR, HU, IE, IS, IT, LT, LU, LV, MC, MK, MT, NL, NO, PL, PT, RO, RS, SE, SI, SK, SM, TR), OAPI (BF, BJ, CF, CG, CI, CM, GA, GN, GQ, GW, KM, ML, MR, NE, SN, TD, TG).

공개:

— 국제조사보고서와 함께 (조약 제21조(3))

(54) Title: DEVICE AND METHOD FOR LEARNING TIME SERIES DATA ON BASIS OF MULTILAYER RANDOM FOREST

(54) 발명의 명칭: 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치 및 방법



- 100 ... Device for learning time series data
110 ... Candidate detection unit
120 ... Tube generating unit
130 ... Sub-tube generating unit
140 ... Feature extraction unit
141 ... Static feature extraction module
142 ... Dynamic feature extraction module
150 ... Learning unit

(57) Abstract: According to a device and a method for learning time series data on the basis of multilayer random forests, presented in the present invention, candidate regions detected in learning data composed of time series images of a plurality of consecutive frames are connected to create a tube, features are extracted from sub-tubes obtained by dividing the tube, and learning is performed by inputting the feature extracted from each sub-tube into each layer of a time series multilayer random forest classifier including a plurality of layers, thus fast computation speed is provided due to reduced learning parameters that should be maintained and a simple decision-making process, and far more flexible operation is possible than in RNN-based models.

(57) 요약서: 본 발명에서 제안하고 있는 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치 및 방법에 따르면, 연속된 복수의 프레임의 시계열 영상으로 구성되는 학습 데이터에서 탐지된 후보 영역을 연결하여 튜브를 생성하고, 튜브를 분할한 서브-튜브로부터 특징을 추출하여, 복수의 레이어를 포함해 구성되는 시계열 다층 랜덤 포레스트 분류기에 각각의 서브-튜브로부터 추출된 특징을 각 레이어의 입력으로 하여 학습을 수행함으로써, 유지해야 할 학습 파라미터가 적고 단순한 의사결정 과정으로 인해 빠른 연산 속도를 제공하며, RNN 기반의 모델들보다 훨씬 유연하게 동작할 수 있다.

WO 2022/005122 A1

명세서

발명의 명칭: 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치 및 방법

기술분야

- [1] 본 발명은 시계열 데이터 학습 장치 및 방법에 관한 것으로서, 보다 구체적으로는 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치 및 방법에 관한 것이다.

배경기술

- [2] 최근 인공지능망 분야가 급속도로 발전하면서 높은 정확도뿐만 아니라, 다양한 정적/동적 데이터에 대해 학습 가능한 모델 개발에 관한 관심도 증가하고 있다. 초기 인공지능망 연구는 정적인 데이터에 대해 분류 정확도를 높이거나 수치적 회귀 모델을 활용한 연구가 대부분이었다면, 현재는 동적인 데이터의 연속적 변화나 시간의 흐름에 따른 데이터의 변화 특성을 분석하는 방법이 소개되고 있다.
- [3]
- [4] 특히, Recurrent Neural Network (RNN)로 대변되는 시계열 특성 분석 신경망 분야는, 음성인식이나 자연어처리, 동영상 분석과 같이 시간적 변화의 특성을 반영할 수 있는 연구 분야에서 뛰어난 성능을 보이며 주목받고 있다. RNN 분야의 잘 알려진 방법론인 LSTM(Long Short-Term Memory)은 기존 RNN의 단점인 기울기 소멸 (Vanishing gradient problem)을 극복하기 위해 cell-state 개념을 추가해 높은 성능을 달성했다. 각 cell 내부에 기억의 흐름을 제어하는 forget gate와 input gate를 두어 state가 반복되더라도 기울기 변화가 비교적 잘 전달되도록 구성했다.
- [5]
- [6] 하지만 LSTM은 cell 구조가 복잡해짐에 따라 연산에 많은 시간이 소요되는 단점이 발생하고, 이를 극복하기 위해 GRU(Gated Recurrent Unit)가 제안되었다. GRU는 LSTM의 cell-state 구조에서 내부 구조를 간소화하고 state 업데이트에 소요되는 연산을 줄여 보다 빠르게 동작할 수 있도록 설계되었다.
- [7]
- [8] 이같이, 복잡한 RNN을 효율적으로 동작시키는 다양한 방법이 제안되었지만, RNN 기반의 시계열 데이터 학습 기법은 여전히 일반적인 인공지능망 모델에 비해 수많은 학습 파라미터가 필요하며 방대한 연산이 수반되기 때문에 저사양의 실시간 시스템에 적용하기에 어려움이 있다.
- [9]
- [10] 한편, 본 발명과 관련된 선행기술로서, 공개특허 제10-2019-0114694호(발명의 명칭: 인공지능을 이용한 시계열 데이터 학습 및 분석 방법, 공개일자: 2019년

10월 10일) 등이 개시된 바 있다.

발명의 상세한 설명

기술적 과제

- [11] 본 발명은 기존에 제안된 방법들의 상기와 같은 문제점들을 해결하기 위해 제안된 것으로서, 연속된 복수의 프레임의 시계열 영상으로 구성되는 학습 데이터에서 탐지된 후보 영역을 연결하여 튜브를 생성하고, 튜브를 분할한 서브-튜브로부터 특징을 추출하여, 복수의 레이어를 포함해 구성되는 시계열 다층 랜덤 포레스트 분류기에 각각의 서브-튜브로부터 추출된 특징을 각 레이어의 입력으로 하여 학습을 수행함으로써, 유지해야 할 학습 파라미터가 적고 단순한 의사결정 과정으로 인해 빠른 연산 속도를 제공하며, RNN 기반의 모델들보다 훨씬 유연하게 동작할 수 있는, 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치 및 방법을 제공하는 것을 그 목적으로 한다.

기술적 해결방법

- [12] 상기한 목적을 달성하기 위한 본 발명의 특징에 따른 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치는,
- [13] 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치로서,
- [14] 연속된 복수의 프레임의 시계열 영상으로 구성되는 학습 데이터의 각 프레임에서 후보 영역을 탐지하는 후보 검출부;
- [15] 상기 학습 데이터의 연속된 복수의 프레임에서 탐지된 후보 영역을 연결하여 튜브를 생성하는 튜브 생성부;
- [16] 시간의 흐름에 따른 변화를 반영하기 위해, 상기 튜브를 미리 정해진 개수의 프레임으로 분할하여 서브-튜브를 생성하는 서브-튜브 생성부;
- [17] 상기 서브-튜브로부터 특징을 추출하는 특징 추출부; 및
- [18] 각 서브-튜브에 대응되는 복수의 레이어를 포함하여 구성되는 시계열 다층 랜덤 포레스트 분류기에, 상기 특징 추출부에서 각각의 서브-튜브로부터 추출된 특징을 각 서브-튜브에 대응되는 레이어의 입력으로 하여 상기 시계열 다층 랜덤 포레스트 분류기를 학습하는 학습부를 포함하는 것을 그 구성상의 특징으로 한다.
- [19]
- [20] 바람직하게는, 상기 서브-튜브 생성부는,
- [21] 상기 튜브를 5 프레임 크기의 서브-튜브로 분할하여 복수의 서브-튜브를 순차적으로 생성할 수 있다.
- [22]
- [23] 바람직하게는, 상기 특징 추출부는,
- [24] 상기 서브-튜브 생성부에서 생성된 서브-튜브 중 일부로부터 정적 특징을 추출하고, 나머지 일부로부터 동적 특징을 추출할 수 있다.
- [25]

- [26] 더욱 바람직하게는, 상기 특징 추출부는,
- [27] 상기 서브-튜브 생성부에서 생성된 n 개의 서브-튜브 중 앞의 $n-1$ 개의 서브-튜브로부터 정적 특징을 추출하는 정적 특징 추출 모듈; 및
- [28] 상기 서브-튜브 생성부에서 생성된 n 개의 서브-튜브 중 마지막 1개의 서브-튜브로부터 시공간적 특성을 반영하도록 동적 특징을 추출하는 동적 특징 추출 모듈을 포함할 수 있다.
- [29]
- [30] 더욱 바람직하게는, 상기 정적 특징 추출 모듈은,
- [31] 상기 정적 특징 추출을 위해, 서브-튜브의 각 프레임 영상을 입력으로 받아 인공신경망 기반의 ResNet을 적용하고, Element-wise mean을 이용해 특징을 추출할 수 있다.
- [32]
- [33] 더욱 바람직하게는, 상기 동적 특징 추출 모듈은,
- [34] 상기 동적 특징 추출을 위해, 서브-튜브에 대해 HooF(Histogram of optical Flow)를 이용해 특징을 추출할 수 있다.
- [35]
- [36] 바람직하게는, 상기 시계열 다층 랜덤 포레스트 분류기는,
- [37] 상기 서브-튜브 생성부에서 생성된 서브-튜브의 개수의 레이어로 구성될 수 있다.
- [38]
- [39] 더욱 바람직하게는, 상기 학습부는,
- [40] 첫 번째 서브-튜브에서 추출된 특징을 첫 번째 레이어에 입력하고, 첫 번째 레이어의 출력과 두 번째 서브-튜브에서 추출된 특징을 결합해 두 번째 레이어에 입력하며, 현재 레이어의 출력과 다음 서브-튜브에서 추출된 특징을 결합해 다음 레이어에 입력하며, 최종 레이어의 출력이 최종 출력값이 되도록, 상기 학습 데이터를 이용해 상기 시계열 다층 랜덤 포레스트 분류기를 학습할 수 있다.
- [41]
- [42] 또한, 상기한 목적을 달성하기 위한 본 발명의 특징에 따른 다층 랜덤 포레스트 기반의 시계열 데이터 학습 방법은,
- [43] 다층 랜덤 포레스트 기반의 시계열 데이터 학습 방법으로서,
- [44] (1) 연속된 복수의 프레임의 시계열 영상으로 구성되는 학습 데이터의 각 프레임에서 후보 영역을 탐지하는 단계;
- [45] (2) 상기 학습 데이터의 연속된 복수의 프레임에서 탐지된 후보 영역을 연결하여 튜브를 생성하는 단계;
- [46] (3) 시간의 흐름에 따른 변화를 반영하기 위해, 상기 튜브를 미리 정해진 개수의 프레임으로 분할하여 서브-튜브를 생성하는 단계;
- [47] (4) 상기 서브-튜브로부터 특징을 추출하는 단계; 및
- [48] (5) 각 서브-튜브에 대응되는 복수의 레이어를 포함하여 구성되는 시계열 다층

랜덤 포레스트 분류기에, 상기 단계 (4)에서 각각의 서브-튜브로부터 추출된 특징을 각 서브-튜브에 대응되는 레이어의 입력으로 하여 상기 시계열 다층 랜덤 포레스트 분류기를 학습하는 단계를 포함하는 것을 그 구성상의 특징으로 한다.

[49]

[50] 바람직하게는, 상기 단계 (3)에서는,

[51] 상기 튜브를 5 프레임 크기의 서브-튜브로 분할하여 복수의 서브-튜브를 순차적으로 생성할 수 있다.

[52]

[53] 바람직하게는, 상기 단계 (4)에서는,

[54] 상기 단계 (3)에서 생성된 서브-튜브 중 일부로부터 정적 특징을 추출하고, 나머지 일부로부터 동적 특징을 추출할 수 있다.

[55]

[56] 더욱 바람직하게는, 상기 단계 (4)는,

[57] (4-1) 상기 단계 (3)에서 생성된 n 개의 서브-튜브 중 앞의 $n-1$ 개의 서브-튜브로부터 정적 특징을 추출하는 단계; 및

[58] (4-2) 상기 단계 (3)에서 생성된 n 개의 서브-튜브 중 마지막 1개의 서브-튜브로부터 시공간적 특성을 반영하도록 동적 특징을 추출하는 단계를 포함할 수 있다.

[59]

[60] 더더욱 바람직하게는, 상기 단계 (4-1)에서는,

[61] 상기 정적 특징 추출을 위해, 서브-튜브의 각 프레임 영상을 입력으로 받아 인공신경망 기반의 ResNet을 적용하고, Element-wise mean을 이용해 특징을 추출할 수 있다.

[62]

[63] 더더욱 바람직하게는, 상기 단계 (4-2)에서는,

[64] 상기 동적 특징 추출을 위해, 서브-튜브에 대해 HooF(Histogram of optical Flow)를 이용해 특징을 추출할 수 있다.

[65]

[66] 바람직하게는, 상기 시계열 다층 랜덤 포레스트 분류기는,

[67] 상기 단계 (3)에서 생성된 서브-튜브의 개수의 레이어로 구성될 수 있다.

[68]

[69] 더욱 바람직하게는, 상기 단계 (5)에서는,

[70] 첫 번째 서브-튜브에서 추출된 특징을 첫 번째 레이어에 입력하고, 첫 번째 레이어의 출력과 두 번째 서브-튜브에서 추출된 특징을 결합해 두 번째 레이어에 입력하며, 현재 레이어의 출력과 다음 서브-튜브에서 추출된 특징을 결합해 다음 레이어에 입력하며, 최종 레이어의 출력이 최종 출력값이 되도록, 상기 학습 데이터를 이용해 상기 시계열 다층 랜덤 포레스트 분류기를 학습할 수 있다.

발명의 효과

- [71] 본 발명에서 제안하고 있는 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치 및 방법에 따르면, 연속된 복수의 프레임의 시계열 영상으로 구성되는 학습 데이터에서 탐지된 후보 영역을 연결하여 튜브를 생성하고, 튜브를 분할한 서브-튜브로부터 특징을 추출하여, 복수의 레이어를 포함해 구성되는 시계열 다층 랜덤 포레스트 분류기에 각각의 서브-튜브로부터 추출된 특징을 각 레이어의 입력으로 하여 학습을 수행함으로써, 유지해야 할 학습 파라미터가 적고 단순한 의사결정 과정으로 인해 빠른 연산 속도를 제공하며, RNN 기반의 모델들보다 훨씬 유연하게 동작할 수 있다.

도면의 간단한 설명

- [72] 도 1은 본 발명의 일실시예에 따른 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치의 구성을 도시한 도면.
- [73] 도 2는 본 발명의 일실시예에 따른 다층 랜덤 포레스트 기반의 시계열 데이터 학습 방법의 흐름을 도시한 도면.
- [74] 도 3은 본 발명의 일실시예에 따른 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치 및 방법에서, 튜브 및 서브-튜브를 생성하고 특징을 추출하는 구체적인 과정을 설명하기 위해 도시한 도면.
- [75] 도 4는 본 발명의 일실시예에 따른 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치 및 방법에서 제안하는, 시계열 다층 랜덤 포레스트 분류기를 설명하기 위해 도시한 도면.
- [76] 도 5는 본 발명의 일실시예에 따른 다층 랜덤 포레스트 기반의 시계열 데이터 학습 방법의 단계 S140의 세부적인 흐름을 도시한 도면.
- [77] 도 6은 본 발명의 일실시예에 따른 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치 및 방법을 산불 조기 감지에 적용하기 위해 정적 특징을 추출하는 과정을 도시한 도면.
- [78] 도 7은 본 발명의 일실시예에 따른 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치 및 방법을 산불 조기 감지에 적용하기 위해 동적 특징을 추출하는 과정을 도시한 도면.
- [79] 도 8은 본 발명의 일실시예에 따른 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치 및 방법의 성능 비교를 위해 수집한 데이터세트의 예를 도시한 도면.
- [80] 도 9는 본 발명의 일실시예에 따른 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치 및 방법의 성능 비교를 위한 학습 데이터의 통계를 나타낸 도면.
- [81] 도 10은 본 발명의 일실시예에 따른 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치 및 방법의 성능 비교를 위한 deep LSTM의 구성을 도시한 도면.
- [82] 도 11은 본 발명의 일실시예에 따른 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치 및 방법과 다른 RNN 방법들과의 성능 비교 결과를 나타낸 도면.
- [83] <부호의 설명>

- [84] 100: 본 발명의 특징에 따른 시계열 데이터 학습 장치
- [85] 110: 후보 검출부
- [86] 120: 튜브 생성부
- [87] 130: 서브-튜브 생성부
- [88] 140: 특징 추출부
- [89] 141: 정적 특징 추출 모듈
- [90] 142: 동적 특징 추출 모듈
- [91] 150: 학습부
- [92] S110: 학습 데이터의 각 프레임에서 후보 영역을 탐지하는 단계
- [93] S120: 연속된 복수의 프레임에서 탐지된 후보 영역을 연결하여 튜브를 생성하는 단계
- [94] S130: 튜브를 미리 정해진 개수의 프레임으로 분할하여 서브-튜브를 생성하는 단계
- [95] S140: 서브-튜브로부터 특징을 추출하는 단계
- [96] S141: n개의 서브-튜브 중 앞의 n-1개의 서브-튜브로부터 정적 특징을 추출하는 단계
- [97] S142: n개의 서브-튜브 중 마지막 1개의 서브-튜브로부터 동적 특징을 추출하는 단계
- [98] S150: 시계열 다층 랜덤 포레스트 분류기를 학습하는 단계

발명의 실시를 위한 최선의 형태

- [99] 이하, 첨부된 도면을 참조하여 본 발명이 속하는 기술분야에서 통상의 지식을 가진 자가 본 발명을 용이하게 실시할 수 있도록 바람직한 실시예를 상세히 설명한다. 다만, 본 발명의 바람직한 실시예를 상세하게 설명함에 있어, 관련된 공지 기능 또는 구성에 대한 구체적인 설명이 본 발명의 요지를 불필요하게 흐릴 수 있다고 판단되는 경우에는 그 상세한 설명을 생략한다. 또한, 유사한 기능 및 작용을 하는 부분에 대해서는 도면 전체에 걸쳐 동일한 부호를 사용한다.
- [100]
- [101] 덧붙여, 명세서 전체에서, 어떤 부분이 다른 부분과 ‘연결’되어 있다고 할 때, 이는 ‘직접적으로 연결’되어 있는 경우뿐만 아니라, 그 중간에 다른 소자를 사이에 두고 ‘간접적으로 연결’되어 있는 경우도 포함한다. 또한, 어떤 구성요소를 ‘포함’ 한다는 것은, 특별히 반대되는 기재가 없는 한 다른 구성요소를 제외하는 것이 아니라 다른 구성요소를 더 포함할 수 있다는 것을 의미한다.
- [102]
- [103] 도 1은 본 발명의 일실시예에 따른 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치(100)의 구성을 도시한 도면이다. 도 1에 도시된 바와 같이, 본 발명의 일실시예에 따른 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치(100)는,

연속된 복수의 프레임의 시계열 영상으로 구성되는 학습 데이터의 각 프레임에서 후보 영역을 탐지하는 후보 검출부(110), 학습 데이터의 연속된 복수의 프레임에서 탐지된 후보 영역을 연결하여 튜브를 생성하는 튜브 생성부(120), 시간의 흐름에 따른 변화를 반영하기 위해, 튜브를 미리 정해진 개수의 프레임으로 분할하여 서브-튜브를 생성하는 서브-튜브 생성부(130), 서브-튜브로부터 특징을 추출하는 특징 추출부(140), 및 각 서브-튜브에 대응되는 복수의 레이어를 포함하여 구성되는 시계열 다층 랜덤 포레스트 분류기에, 특징 추출부(140)에서 각각의 서브-튜브로부터 추출된 특징을 각 서브-튜브에 대응되는 레이어의 입력으로 하여 시계열 다층 랜덤 포레스트 분류기를 학습하는 학습부(150)를 포함하여 구성될 수 있고, 특징 추출부(140)는, 서브-튜브 생성부(130)에서 생성된 n 개의 서브-튜브 중 앞의 $n-1$ 개의 서브-튜브로부터 정적 특징을 추출하는 정적 특징 추출 모듈(141), 및 서브-튜브 생성부(130)에서 생성된 n 개의 서브-튜브 중 마지막 1개의 서브-튜브로부터 시공간적 특성을 반영하도록 동적 특징을 추출하는 동적 특징 추출 모듈(142)을 포함하여 구성될 수 있다.

[104]

[105] 도 2는 본 발명의 일실시예에 따른 다층 랜덤 포레스트 기반의 시계열 데이터 학습 방법의 흐름을 도시한 도면이다. 도 2에 도시된 바와 같이, 본 발명의 일실시예에 따른 다층 랜덤 포레스트 기반의 시계열 데이터 학습 방법은, 학습 데이터의 각 프레임에서 후보 영역을 탐지하는 단계(S110), 연속된 복수의 프레임에서 탐지된 후보 영역을 연결하여 튜브를 생성하는 단계(S120), 튜브를 미리 정해진 개수의 프레임으로 분할하여 서브-튜브를 생성하는 단계(S130), 서브-튜브로부터 특징을 추출하는 단계(S140) 및 시계열 다층 랜덤 포레스트 분류기를 학습하는 단계(S150)를 포함하여 구성될 수 있다.

[106]

[107] 본 발명의 일실시예에 따른 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치(100) 및 방법에서는, 기존의 시계열 데이터를 학습하는 대표적인 방법인 RNN이 가진 방대한 수의 파라미터 및 연산을 필요로 하는 한계점을 극복하기 위해, 효율적인 방법으로 시계열 데이터를 학습할 수 있는 시계열 다층 랜덤 포레스트(Time series Multilayered Random Forest, TMRF)를 제안한다. TMRF는 이진 결정 트리(Binary Decision Tree, BDT)를 연속되는 여러 계층의 시간적 지식 변형(temporal knowledge transforming) 모듈로 사용하는 앙상블 학습 기법이다. BDT는 유지해야 할 학습 파라미터가 적고 단순한 의사결정 과정으로 인해 빠른 연산 속도를 제공하기 때문에 RNN 기반의 모델들보다 훨씬 유연한 동작이 가능하다. 즉, 본 발명에서는, 역전파(back-propagation)를 사용하는 복잡한 인공신경망 대신, 단순한 구조의 BDT를 가지는 랜덤 포레스트(RF) 앙상블을 기반으로 하는 계층적 레이어 구조를 가진 TMRF를 제안하고, TMRF를 이용해 효율적으로 시계열 데이터를 학습하는 기법을 제안한다.

[108]

[109] 도 3은 본 발명의 일실시예에 따른 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치(100) 및 방법에서, 튜브 및 서브-튜브를 생성하고 특징을 추출하는 구체적인 과정을 설명하기 위해 도시한 도면이고, 도 4는 본 발명의 일실시예에 따른 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치(100) 및 방법에서 제안하는, 시계열 다층 랜덤 포레스트 분류기를 설명하기 위해 도시한 도면이다. 도 4에 도시된 바와 같이, 본 발명에서 제안하는 TMRF는, 여러 개의 랜덤 포레스트로 구성된 다층의 Main-stream 레이어와 각각의 Sub-stream 레이어를 배치한 형태를 가질 수 있다. 이때, RF 각 노드들의 학습 방법에 따라 RF 혹은 Conditional RF(CRF)로 분류될 수 있다. RF는 데이터의 여러 특징값을 분석해 최적의 경우를 고려하기 때문에 학습이 느리다는 단점이 있지만 그만큼 좋은 성능을 보일 수 있다. CRF는 랜덤하게 선택된 특징값만을 고려하기 때문에 학습이 빠르지만 항상 우수한 성능을 보장하지는 않는다. 하지만 특징의 분석법을 다르게 함으로써 모델이 가지는 다양성이 높아지는 효과를 얻을 수 있다. 따라서 본 발명에서는, 다양성을 높이기 위해 RF 및 CRF를 조합하여 레이어를 구성할 수 있다.

[110]

[111] 이하에서는, 도 2 내지 도 4를 참조하여, 본 발명의 일실시예에 따른 다층 랜덤 포레스트 기반의 시계열 데이터 학습 방법의 각 단계에 대해 상세히 설명하도록 한다.

[112]

[113] 본 발명은 다층 랜덤 포레스트 기반의 시계열 데이터 학습 방법에 관한 것으로서, 본 발명의 특징에 따른 다층 랜덤 포레스트 기반의 시계열 데이터 학습 방법은, 메모리 및 프로세서를 포함한 하드웨어에서 기록되는 소프트웨어로 구성될 수 있다. 예를 들어, 다층 랜덤 포레스트 기반의 시계열 데이터 학습 방법은, 개인용 컴퓨터, 노트북 컴퓨터, 서버 컴퓨터, PDA, 스마트폰, 태블릿 PC 등에 저장 및 구현될 수 있다. 이하에서는 설명의 편의를 위해, 각 단계를 수행하는 주체는 생략될 수 있다.

[114]

[115] 단계 S110에서는, 후보 검출부(110)가 연속된 복수의 프레임의 시계열 영상으로 구성되는 학습 데이터의 각 프레임에서 후보 영역을 탐지할 수 있다. 즉, 단계 S110에서는, 시공간 정보를 포함하는 동영상 등 각종 시계열 영상을 학습 데이터로 사용할 수 있으며, 예를 들어 산불 조기 감지를 위한 산불 영상, 연기 영상 등에 적용될 수 있다.

[116]

[117] 단계 S110에서는, 학습 데이터에 대해 짧은 시간 내에 최대한 많은 후보 영역을 검출할 수 있어야 하므로, 영상으로부터 후보 영역을 신속하게 검출할 수 있는 CNN(Convolutional Neural Network) 기반의 검출기를 이용해 후보 영역을 검출할

수 있다. 예를 들어, 산불 조기 감지에 적용되는 경우, 다양한 연기의 형태를 반영하기 위해서는 영상의 스케일 변화를 학습하는 딥러닝 모델의 적용이 요구되므로, 우수한 성능을 보이면서도 빠른 속도로 동작하는 YOLOv3를 검출기로 이용해 최적의 후보 영역을 검출할 수 있다.

[118]

[119] 단계 S120에서는, 튜브 생성부(120)가 학습 데이터의 연속된 복수의 프레임에서 탐지된 후보 영역을 연결하여 튜브를 생성할 수 있다. 단계 S120에서는, 학습 데이터에서 생성 가능한 모든 튜브를 추출할 수 있다.

[120]

[121] 예를 들어, 산불 조기 감지에 적용되는 경우, 단계 S110에서 검출된 후보 연기 영역의 시계열 데이터를 반영하기 위해 연속된 프레임으로부터 스모크-튜브(Smoke-tube)를 생성할 수 있다. 스모크-튜브는 검출된 후보 영역을 기준으로 일정한 수 만큼의 프레임에 대해 잘라낸 패치 영역을 이어서 구성할 수 있다.

[122]

[123] 단계 S130에서는, 서브-튜브 생성부(130)가 시간의 흐름에 따른 변화를 반영하기 위해, 튜브를 미리 정해진 개수의 프레임으로 분할하여 서브-튜브를 생성할 수 있다. 보다 구체적으로, 단계 S130에서는, 튜브를 5 프레임 크기의 서브-튜브로 분할하여 복수의 서브-튜브를 순차적으로 생성할 수 있다. 즉, 도 3에 도시된 바와 같이, 단계 S130에서는 튜브로부터 시간의 흐름에 따른 변화를 반영하기 위해, 단계 S120에서 생성된 스모크-튜브를 t_0 부터 t_4 까지 더 작은 단위의 5 프레임의 크기를 가지는 5개의 서브-튜브로 분할할 수 있다.

[124]

[125] 단계 S140에서는, 특징 추출부(140)가 서브-튜브로부터 특징을 추출할 수 있다. 보다 구체적으로, 단계 S140에서는, 단계 S130에서 생성된 서브-튜브 중 일부로부터 정적 특징을 추출하고, 나머지 일부로부터 동적 특징을 추출할 수 있다.

[126]

[127] 도 5는 본 발명의 일실시예에 따른 다층 랜덤 포레스트 기반의 시계열 데이터 학습 방법의 단계 S140의 세부적인 흐름을 도시한 도면이다. 도 5에 도시된 바와 같이, 본 발명의 일실시예에 따른 다층 랜덤 포레스트 기반의 시계열 데이터 학습 방법의 단계 S140은, n 개의 서브-튜브 중 앞의 $n-1$ 개의 서브-튜브로부터 정적 특징을 추출하는 단계(S141) 및 n 개의 서브-튜브 중 마지막 1개의 서브-튜브로부터 동적 특징을 추출하는 단계(S142)를 포함하여 구현될 수 있다.

[128]

[129] 단계 S141에서는, 정적 특징 추출 모듈(141)이, 단계 S130에서 생성된 n 개의 서브-튜브 중 앞의 $n-1$ 개의 서브-튜브로부터 정적 특징을 추출할 수 있다. 보다 구체적으로, 단계 S141에서는, 정적 특징 추출을 위해, 서브-튜브의 각 프레임

영상을 입력으로 받아 인공신경망 기반의 ResNet을 적용하고, Element-wise mean을 이용해 $1 \times N$ 차원의 특징을 추출할 수 있다. 예를 들어, 도 3에 도시된 바와 같이, 총 5개의 서브-튜브 중에서 일부인 앞의 4개의 서브-튜브($t_0 \sim t_3$)는 고품질의 영상 특징을 추출하기 위해 ResNet50으로부터 CNN 특징을 추출할 수 있다. 변환된 특징들을 정규화하기 위해 CNN 특징은 각 Tensor 값들의 평균을 취할 수 있다.

[130]

[131] 도 6은 본 발명의 일실시예에 따른 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치(100) 및 방법을 산불 조기 감지에 적용하기 위해 정적 특징을 추출하는 과정을 도시한 도면이다. 도 6에 도시된 바와 같이, 본 발명의 일실시예에 따른 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치(100) 및 방법을 산불 조기 감지에 적용하는 경우, 단계 S141에서는, 서브-튜브의 각 영상을 입력으로 받아 ResNet50을 적용할 수 있다. ResNet50은 마지막에 2개의 완전 연결(fully connected, FC) 레이어로 구성되며, 2개의 FC 레이어 별로 0.5의 드롭아웃(dropout 0.5)을 적용하여 차원의 수를 줄일 수 있다. 입력 영상의 크기가 $216 \times 216 \times 3$ 일 때 출력 벡터의 차원은 1024이 된다.

[132]

[133] 단계 S142에서는, 동적 특징 추출 모듈(142)이, 단계 S130에서 생성된 n 개의 서브-튜브 중 마지막 1개의 서브-튜브로부터 시공간적 특성을 반영하도록 동적 특징을 추출할 수 있다. 보다 구체적으로, 단계 S142에서는, 동적 특징 추출을 위해, 서브-튜브에 대해 HooF(Histogram of optical Flow)를 이용해 특징을 추출할 수 있다. 예를 들어, 도 3에 도시된 바와 같이, 총 5개의 서브-튜브 중에서 마지막 1개의 서브-튜브(t_4)는 HooF 특징을 추출할 수 있으며, 변환된 특징들을 정규화하기 위해 동적 특징은 객체의 변화를 효과적으로 반영하기 위해 bag-of-word (BoW)를 이용한 code word 형태로 변형될 수 있다.

[134]

[135] 도 7은 본 발명의 일실시예에 따른 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치(100) 및 방법을 산불 조기 감지에 적용하기 위해 동적 특징을 추출하는 과정을 도시한 도면이다. 도 7에 도시된 바와 같이, 본 발명의 일실시예에 따른 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치(100) 및 방법을 산불 조기 감지에 적용하는 경우, 단계 S142에서는, 프레임의 시간적 흐름에 따른 객체의 변화량을 각도(Angle)와 크기(Magnitude) 값으로 수치화할 수 있다. 즉, 검출된 객체의 각도와 크기 변화를 결합한 후 히스토그램으로 누적시켜 특징값을 구성할 수 있다.

[136]

[137] 단계 S150에서는, 학습부(150)가 각 서브-튜브에 대응되는 복수의 레이어를 포함하여 구성되는 시계열 다층 랜덤 포레스트 분류기에, 단계 S140에서 각각의 서브-튜브로부터 추출된 특징을 각 서브-튜브에 대응되는 레이어의 입력으로

하여 시계열 다층 랜덤 포레스트 분류기를 학습할 수 있다.

[138]

[139] 시계열 다층 랜덤 포레스트 분류기는, 단계 S130에서 생성된 서브-튜브의 개수의 레이어로 구성될 수 있는데, 단계 S150에서는, 첫 번째 서브-튜브에서 추출된 특징을 첫 번째 레이어에 입력하고, 첫 번째 레이어의 출력과 두 번째 서브-튜브에서 추출된 특징을 결합해 두 번째 레이어에 입력하며, 현재 레이어의 출력과 다음 서브-튜브에서 추출된 특징을 결합해 다음 레이어에 입력하며, 최종 레이어의 출력이 최종 출력값이 되도록, 학습 데이터를 이용해 시계열 다층 랜덤 포레스트 분류기를 학습할 수 있다.

[140]

[141] 즉, 도 4에 도시된 바와 같이, 첫 번째 서브-튜브(t_0)에서 추출된 특징을 첫 번째 레이어(L_1)에 입력하고, 두 번째 서브 튜브(t_1)에서 추출된 특징을 랜덤 포레스트로 분석한 결과를 첫 번째 레이어(L_1)의 출력과 결합해 새로운 특징을 생성하여, 두 번째 레이어(L_2)에 입력하게 된다. 같은 방식으로, n 번째 레이어(L^n)의 출력과 다음 서브-튜브(t_n)에서 추출된 특징을 결합한 새로운 특징을 다음 레이어(L^{n+1})에 입력해서, 최종 레이어까지 연쇄적으로 학습하게 된다. 도 4에 도시된 바와 같이, TMRF는 이전 레이어의 출력과 서브-튜브의 특징을 결합해 다음 레이어를 위한 새로운 특징을 생성하기 위해 연쇄층(concatenate layer)을 포함하여 구성될 수 있다. 이와 같이, 레이어가 반복되며 시간적 변화를 반영할 수 있으며 정확도를 높일 수 있다.

[142]

[143] 실험

[144]

[145] 본 발명의 일실시예에 따른 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치(100) 및 방법을 이용해 학습을 수행하고 다른 RNN 기법들과 비교하기 위해, 직접 산불 연기 데이터셋을 구축하고 분석하였다. 데이터셋은 다음 조건을 고려해 구성되었다. i) Youtube 등의 웹으로부터 산불 연기 및 유사 객체를 다수 포함, ii) 산불 연기 유사 객체는 구름, 산안개 등을 포함, iii) 동영상의 형식은 avi 또는 mp4, iv) 정지 영상의 경우 jpg로 구성되었으며, 이는 레이블링에 이용, v) 동영상은 25fps 이상, 영상으로 변환할 때는 10fps 이상, vi) 영상의 해상도는 640x480 이상의 해상도를 가짐.

[146]

[147] 도 8은 본 발명의 일실시예에 따른 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치(100) 및 방법의 성능 비교를 위해 수집한 데이터셋의 예를 도시한 도면이고, 도 9는 본 발명의 일실시예에 따른 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치(100) 및 방법의 성능 비교를 위한 학습 데이터의 통계를 나타낸 도면이다. 총 데이터는 18개의 동영상으로 구성되며 산불 동영상 9개와 비산불 동영상 9개로 구성하였다. 비산불 데이터셋은 공장 굴뚝 연기나 구름, 연무와

같이 연기와 비슷한 형태를 갖는 객체가 포함된다. 실험은 Intel i7-7700 및 NVIDIA GeForce GTX 1080 Ti에서 수행되었다.

[148]

[149] 비교실험을 위해 다음과 같이 7개의 방법으로 데이터셋을 학습하고 테스트를 수행하였다. ① One LSTM: 한 개의 레이어로 구성된 LSTM, ② deep LSTMs: 입력 영상별로 3개의 레이어로 구성된 LSTM, ③ one Bi-LSTM: 한 개의 레이어를 가지며 영상별 레이어는 양방향(bidirectional)으로 연결된 LSTM, ④ deep Bi-LSTM: 3개의 계층으로 연결된 양방향(bidirectional) LSTM, ⑤ One GRU: 한 개의 레이어로 구성된 GRU, ⑥ deep GRU: 3개의 레이어로 구성된 GRU, ⑦ 본 발명의 일실시예에 따른 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치(100) 및 방법에 따른 TMRF.

[150]

[151] 도 10은 본 발명의 일실시예에 따른 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치(100) 및 방법의 성능 비교를 위한 deep LSTM의 구성을 도시한 도면이다. 즉, 실험을 위해 사용된 ② deep LSTMs의 기본 구조는 도 10과 같다. ResNet50으로 동일한 스모크-튜브로부터 특징을 추출하고 각 LSTM 레이어에 입력하여 출력된 결과값을 결합하는 방법을 사용하였다.

[152]

[153] 도 11은 본 발명의 일실시예에 따른 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치(100) 및 방법과 다른 RNN 방법들과의 성능 비교 결과를 나타낸 도면이다. 도 11에 도시된 바와 같이, 본 발명의 일실시예에 따른 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치(100) 및 방법에 따른 TMRF는, 인공신경망 기반 방법들보다 정밀도(precision)에서 0.41~3.85%, 재현율(recall)에서 4.49~9.92%, F1-score에서 3.73~3.96% 낮은 수치를 보이긴 했으나, 검출된 후보 영역에 대해 비교적 높은 수준의 정확도를 보였으며, 연기와 비슷한 후보 영역들도 정확하게 비산불로 분류하는 것을 확인할 수 있었다. 또한, 처리 속도에서는 CPU만을 사용하더라도 다른 RNN 방법들보다 월등히 빠른 결과를 보였다.

[154]

[155] 전술한 바와 같이, 본 발명에서 제안하고 있는 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치(100) 및 방법에 따르면, 연속된 복수의 프레임의 시계열 영상으로 구성되는 학습 데이터에서 탐지된 후보 영역을 연결하여 튜브를 생성하고, 튜브를 분할한 서브-튜브로부터 특징을 추출하여, 복수의 레이어를 포함해 구성되는 시계열 다층 랜덤 포레스트 분류기에 각각의 서브-튜브로부터 추출된 특징을 각 레이어의 입력으로 하여 학습을 수행함으로써, 유지해야 할 학습 파라미터가 적고 단순한 의사결정 과정으로 인해 빠른 연산 속도를 제공하며, RNN 기반의 모델들보다 훨씬 유연하게 동작할 수 있다.

[156]

- [157] 이상 설명한 본 발명은 본 발명이 속한 기술분야에서 통상의 지식을 가진 자에 의하여 다양한 변형이나 응용이 가능하며, 본 발명에 따른 기술적 사상의 범위는 아래의 특허청구범위에 의하여 정해져야 할 것이다.

청구범위

- [청구항 1] 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치(100)로서,
연속된 복수의 프레임의 시계열 영상으로 구성되는 학습 데이터의 각 프레임에서 후보 영역을 탐지하는 후보 검출부(110);
상기 학습 데이터의 연속된 복수의 프레임에서 탐지된 후보 영역을 연결하여 튜브를 생성하는 튜브 생성부(120);
시간의 흐름에 따른 변화를 반영하기 위해, 상기 튜브를 미리 정해진 개수의 프레임으로 분할하여 서브-튜브를 생성하는 서브-튜브 생성부(130);
상기 서브-튜브로부터 특징을 추출하는 특징 추출부(140); 및
각 서브-튜브에 대응되는 복수의 레이어를 포함하여 구성되는 시계열 다층 랜덤 포레스트 분류기에, 상기 특징 추출부(140)에서 각각의 서브-튜브로부터 추출된 특징을 각 서브-튜브에 대응되는 레이어의 입력으로 하여 상기 시계열 다층 랜덤 포레스트 분류기를 학습하는 학습부(150)를 포함하는 것을 특징으로 하는, 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치(100).
- [청구항 2] 제1항에 있어서, 상기 서브-튜브 생성부(130)는,
상기 튜브를 5 프레임 크기의 서브-튜브로 분할하여 복수의 서브-튜브를 순차적으로 생성하는 것을 특징으로 하는, 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치(100).
- [청구항 3] 제1항에 있어서, 상기 특징 추출부(140)는,
상기 서브-튜브 생성부(130)에서 생성된 서브-튜브 중 일부로부터 정적 특징을 추출하고, 나머지 일부로부터 동적 특징을 추출하는 것을 특징으로 하는, 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치(100).
- [청구항 4] 제3항에 있어서, 상기 특징 추출부(140)는,
상기 서브-튜브 생성부(130)에서 생성된 n 개의 서브-튜브 중 앞의 $n-1$ 개의 서브-튜브로부터 정적 특징을 추출하는 정적 특징 추출 모듈(141); 및
상기 서브-튜브 생성부(130)에서 생성된 n 개의 서브-튜브 중 마지막 1개의 서브-튜브로부터 시공간적 특성을 반영하도록 동적 특징을 추출하는 동적 특징 추출 모듈(142)을 포함하는 것을 특징으로 하는, 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치(100).
- [청구항 5] 제4항에 있어서, 상기 정적 특징 추출 모듈(141)은,
상기 정적 특징 추출을 위해, 서브-튜브의 각 프레임 영상을 입력으로 받아 인공신경망 기반의 ResNet을 적용하고, Element-wise mean을 이용해 특징을 추출하는 것을 특징으로 하는, 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치(100).

- [청구항 6] 제4항에 있어서, 상기 동적 특징 추출 모듈(142)은, 상기 동적 특징 추출을 위해, 서브-튜브에 대해 HooF(Histogram of optical Flow)를 이용해 특징을 추출하는 것을 특징으로 하는, 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치(100).
- [청구항 7] 제1항에 있어서, 상기 시계열 다층 랜덤 포레스트 분류기는, 상기 서브-튜브 생성부(130)에서 생성된 서브-튜브의 개수의 레이어로 구성되는 것을 특징으로 하는, 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치(100).
- [청구항 8] 제7항에 있어서, 상기 학습부(150)는, 첫 번째 서브-튜브에서 추출된 특징을 첫 번째 레이어에 입력하고, 첫 번째 레이어의 출력과 두 번째 서브-튜브에서 추출된 특징을 결합해 두 번째 레이어에 입력하며, 현재 레이어의 출력과 다음 서브-튜브에서 추출된 특징을 결합해 다음 레이어에 입력하며, 최종 레이어의 출력이 최종 출력값이 되도록, 상기 학습 데이터를 이용해 상기 시계열 다층 랜덤 포레스트 분류기를 학습하는 것을 특징으로 하는, 다층 랜덤 포레스트 기반의 시계열 데이터 학습 장치(100).
- [청구항 9] 다층 랜덤 포레스트 기반의 시계열 데이터 학습 방법으로서,
 (1) 연속된 복수의 프레임의 시계열 영상으로 구성되는 학습 데이터의 각 프레임에서 후보 영역을 탐지하는 단계;
 (2) 상기 학습 데이터의 연속된 복수의 프레임에서 탐지된 후보 영역을 연결하여 튜브를 생성하는 단계;
 (3) 시간의 흐름에 따른 변화를 반영하기 위해, 상기 튜브를 미리 정해진 개수의 프레임으로 분할하여 서브-튜브를 생성하는 단계;
 (4) 상기 서브-튜브로부터 특징을 추출하는 단계; 및
 (5) 각 서브-튜브에 대응되는 복수의 레이어를 포함하여 구성되는 시계열 다층 랜덤 포레스트 분류기에, 상기 단계 (4)에서 각각의 서브-튜브로부터 추출된 특징을 각 서브-튜브에 대응되는 레이어의 입력으로 하여 상기 시계열 다층 랜덤포레스트 분류기를 학습하는 단계를 포함하는 것을 특징으로 하는, 다층 랜덤 포레스트 기반의 시계열 데이터 학습 방법.
- [청구항 10] 제9항에 있어서, 상기 단계 (3)에서는, 상기 튜브를 5 프레임 크기의 서브-튜브로 분할하여 복수의 서브-튜브를 순차적으로 생성하는 것을 특징으로 하는, 다층 랜덤 포레스트 기반의 시계열 데이터 학습 방법.
- [청구항 11] 제9항에 있어서, 상기 단계 (4)에서는, 상기 단계 (3)에서 생성된 서브-튜브 중 일부로부터 정적 특징을 추출하고, 나머지 일부로부터 동적 특징을 추출하는 것을 특징으로 하는, 다층 랜덤 포레스트 기반의 시계열 데이터 학습 방법.
- [청구항 12] 제11항에 있어서, 상기 단계 (4)는,

(4-1) 상기 단계 (3)에서 생성된 n 개의 서브-튜브 중 앞의 $n-1$ 개의 서브-튜브로부터 정적 특징을 추출하는 단계; 및
 (4-2) 상기 단계 (3)에서 생성된 n 개의 서브-튜브 중 마지막 1개의 서브-튜브로부터 시공간적 특성을 반영하도록 동적 특징을 추출하는 단계를 포함하는 것을 특징으로 하는, 다층 랜덤 포레스트 기반의 시계열 데이터 학습 방법.


[청구항 13] 제12항에 있어서, 상기 단계 (4-1)에서는, 상기 정적 특징 추출을 위해, 서브-튜브의 각 프레임 영상을 입력으로 받아 인공신경망 기반의 ResNet을 적용하고, Element-wise mean을 이용해 특징을 추출하는 것을 특징으로 하는, 다층 랜덤 포레스트 기반의 시계열 데이터 학습 방법.

[청구항 14] 제12항에 있어서, 상기 단계 (4-2)에서는, 상기 동적 특징 추출을 위해, 서브-튜브에 대해 HooF(Histogram of optical Flow)를 이용해 특징을 추출하는 것을 특징으로 하는, 다층 랜덤 포레스트 기반의 시계열 데이터 학습 방법.


[청구항 15] 제9항에 있어서, 상기 시계열 다층 랜덤 포레스트 분류기는, 상기 단계 (3)에서 생성된 서브-튜브의 개수의 레이어로 구성되는 것을 특징으로 하는, 다층 랜덤 포레스트 기반의 시계열 데이터 학습 방법.

[청구항 16] 제15항에 있어서, 상기 단계 (5)에서는, 첫 번째 서브-튜브에서 추출된 특징을 첫 번째 레이어에 입력하고, 첫 번째 레이어의 출력과 두 번째 서브-튜브에서 추출된 특징을 결합해 두 번째 레이어에 입력하며, 현재 레이어의 출력과 다음 서브-튜브에서 추출된 특징을 결합해 다음 레이어에 입력하며, 최종 레이어의 출력이 최종 출력값이 되도록, 상기 학습 데이터를 이용해 상기 시계열 다층 랜덤 포레스트 분류기를 학습하는 것을 특징으로 하는, 다층 랜덤 포레스트 기반의 시계열 데이터 학습 방법.


[도1]




[도2]




[도3]




[도4]




[도5]



[도6]



[도7]




[도8]



[도9]

연기 클립	프레임 수	비연기 클립	프레임 수
Fire_clip03	806	Chimney03	624
V_fire03	650	Cloud05	204
V_fire04	232	Cloud06	451
V_fire16	534	Industiral01	1401
V_fire24	985	MT_non10	533
V_fire38	751	Non_fire11	418
V_Mt_fire02	795	Non_fire12	266
V_Mt_fire03	1490	Non_fire28	551
V_Mt_fire06	609	Non_fire29	785
V_Mt_fire07	677	Non_fire31	501
V_Mt_fire08	469	Non_fire34	684
V_Mt_fire09	305	Non_smoke01	1444

[도10]



[도11]

Method	Precision (%)	Recall (%)	F1-score (%)	TPR* (%)	TNR* (%)	Proc. time (s/frame)
①	88.85	84.08	86.40	87.08	85.20	0.143 (GPU)
②	86.41	89.51	87.93	89.51	80.26	0.165 (GPU)
③	86.92	88.78	87.84	88.78	81.26	0.143 (GPU)
④	89.85	84.32	87.00	84.32	86.65	0.155 (GPU)
⑤	87.15	88.20	87.67	88.20	81.77	0.143 (GPU)
⑥	87.46	86.90	87.18	86.90	82.52	0.153 (GPU)
⑦	86.00	79.59	82.67	85.55	80.93	0.102 (CPU)

TPR* : True Positive rate (TP/FN)

TNR* : True Negative rate (TN/FP)

INTERNATIONAL SEARCH REPORT

International application No.

PCT/KR2021/008054

A. CLASSIFICATION OF SUBJECT MATTER G06N 20/00(2019.01)j According to International Patent Classification (IPC) or to both national classification and IPC		
B. FIELDS SEARCHED Minimum documentation searched (classification system followed by classification symbols) G06N 20/00(2019.01); A63B 69/00(2006.01); G06T 7/00(2006.01); G06T 7/20(2006.01) Documentation searched other than minimum documentation to the extent that such documents are included in the fields searched Korean utility models and applications for utility models: IPC as above Japanese utility models and applications for utility models: IPC as above Electronic data base consulted during the international search (name of data base and, where practicable, search terms used) eKOMPASS (KIPO internal) & keywords: 다층(multilayer), 랜덤 포레스트(random forest), 시계열(time series), 학습(learning), 프레임(frame), 후보(candidate), 탐지(detection), 튜브(tube), 서브-튜브(sub-tube), 특징(feature), 분류기(classifier)		
C. DOCUMENTS CONSIDERED TO BE RELEVANT		
Category*	Citation of document, with indication, where appropriate, of the relevant passages	Relevant to claim No.
A	JP 2008-284166 A (NIPPON HOSO KYOKAI <NHK>) 27 November 2008 (2008-11-27) See paragraphs [0084]-[0098]; and figure 7.	1-16
A	정미라 등. 경량 다층 랜덤 포레스트 기반의 빠른 동공 추적. 2019년 대한전자공학회 추계학술대회 논문집. vol. 42, no. 2, pp. 964-966, November 2019 (JEONG, Mira et al. Fast Pupil Tracking Base on Lightweight Multilayer Random Forests. Proceedings of Fall Annual Conference of IEIE, 2019.). See pages 964-965.	1-16
A	이동훈 등. 랜덤 포레스트를 이용한 머리 방향 인식. 한국정보과학회논문지: 소프트웨어 및 응용. vol. 40, no. 8, pp. 435-441, August 2013 (LEE, Dong Hoon et al. Head Pose Estimation Using Random Forests. Journal of KIISE: Software and Application.). See pages 435-440.	1-16
A	KO, Byoungchul et al. Wildfire smoke detection using temporospatial features and random forest classifier s. Optical Engineering 51(1), 017208, pp. 1-10, January 2012. See pages 1-10.	1-16
☒ Further documents are listed in the continuation of Box C. ☒ See patent family annex.		
* Special categories of cited documents: “A” document defining the general state of the art which is not considered to be of particular relevance “D” document cited by the applicant in the international application “E” earlier application or patent but published on or after the international filing date “L” document which may throw doubts on priority claim(s) or which is cited to establish the publication date of another citation or other special reason (as specified) “O” document referring to an oral disclosure, use, exhibition or other means “P” document published prior to the international filing date but later than the priority date claimed “T” later document published after the international filing date or priority date and not in conflict with the application but cited to understand the principle or theory underlying the invention “X” document of particular relevance; the claimed invention cannot be considered novel or cannot be considered to involve an inventive step when the document is taken alone “Y” document of particular relevance; the claimed invention cannot be considered to involve an inventive step when the document is combined with one or more other such documents, such combination being obvious to a person skilled in the art “&” document member of the same patent family		
Date of the actual completion of the international search 21 October 2021		Date of mailing of the international search report 21 October 2021
Name and mailing address of the ISA/KR Korean Intellectual Property Office Government Complex-Daejeon Building 4, 189 Cheongsaro, Seo-gu, Daejeon 35208 Facsimile No. +82-42-481-8578		Authorized officer Telephone No.

INTERNATIONAL SEARCH REPORT

International application No.

PCT/KR2021/008054

C. DOCUMENTS CONSIDERED TO BE RELEVANT

Category*	Citation of document, with indication, where appropriate, of the relevant passages	Relevant to claim No.
A	KR 10-1237089 B1 (INDUSTRY ACADEMIC COOPERATION FOUNDATION KEIMYUNG UNIVERSITY) 26 February 2013 (2013-02-26) See paragraphs [0046]-[0068]; and figures 2a-9.	1-16

INTERNATIONAL SEARCH REPORT
Information on patent family members

International application No.

PCT/KR2021/008054

Patent document cited in search report			Publication date (day/month/year)	Patent family member(s)			Publication date (day/month/year)
JP	2008-284166	A	27 November 2008	JP	4956273	B2	20 June 2012
KR	10-1237089	B1	26 February 2013	US	2013-0094699	A1	18 April 2013
				US	8565484	B2	22 October 2013

A. 발명이 속하는 기술분류(국제특허분류(IPC)) G06N 20/00(2019.01)i		
B. 조사된 분야 조사된 최소문헌(국제특허분류를 기재) G06N 20/00(2019.01); A63B 69/00(2006.01); G06T 7/00(2006.01); G06T 7/20(2006.01) 조사된 기술분야에 속하는 최소문헌 이외의 문헌 한국등록실용신안공보 및 한국공개실용신안공보: 조사된 최소문헌란에 기재된 IPC 일본등록실용신안공보 및 일본공개실용신안공보: 조사된 최소문헌란에 기재된 IPC 국제조사에 이용된 전산 데이터베이스(데이터베이스의 명칭 및 검색어(해당하는 경우)) eKOMPASS(특허청 내부 검색시스템) & 키워드: 다층(multilayer), 랜덤 포레스트(random forest), 시계열(time series), 학습(learning), 프레임(frame), 후보(candidate), 탐지(detection), 튜브(tube), 서브-튜브(sub-tube), 특징(feature), 분류기(classifier)		
C. 관련 문헌		
카테고리*	인용문헌명 및 관련 구절(해당하는 경우)의 기재	관련 청구항
A	JP 2008-284166 A (NIPPON HOSO KYOKAI <NHK>) 2008.11.27 단락 [0084]-[0098]; 및 도면 7	1-16
A	정미라 등, `경량 다층 랜덤 포레스트 기반의 빠른 동공 추적`, 2019년 대한전자공학회 추계학술대회 논문집, 제42권, 제2호, 페이지 964-966, 2019.11 페이지 964-965	1-16
A	이동훈 등, `랜덤 포레스트를 이용한 머리 방향 인식`, 한국정보과학회논문지: 소프트웨어 및 응용, 제40권, 제8호, 페이지 435-441, 2013.08 페이지 435-440	1-16
A	BYOUNGCHUL KO 등, `Wildfire smoke detection using temporospatial features and random forest classifiers`, Optical Engineering 51(1), 017208, pp. 1-10, 2012.01 페이지 1-10	1-16
A	KR 10-1237089 B1 (계명대학교 산학협력단) 2013.02.26 단락 [0046]-[0068]; 및 도면 2a-9	1-16
☐ 추가 문헌이 C(계속)에 기재되어 있습니다. ☒ 대응특허에 관한 별지를 참조하십시오.		
* 인용된 문헌의 특별 카테고리: “A” 특별히 관련이 없는 것으로 보이는 일반적인 기술수준을 정의한 문헌 “D” 본 국제출원에서 출원인이 인용한 문헌 “E” 국제출원일보다 빠른 출원일 또는 우선일을 가지나 국제출원일 이후에 공개된 선출원 또는 특허 문헌 “L” 우선권 주장에 의문을 제기하는 문헌 또는 다른 인용문헌의 공개일 또는 다른 특별한 이유(이유를 명시)를 밝히기 위하여 인용된 문헌 “O” 구두 개시, 사용, 전시 또는 기타 수단을 언급하고 있는 문헌 “P” 우선일 이후에 공개되었으나 국제출원일 이전에 공개된 문헌		
국제조사의 실제 완료일 2021년10월21일(21.10.2021)		국제조사보고서 발송일 2021년10월21일(21.10.2021)
ISA/KR의 명칭 및 우편주소 대한민국 특허청 (35208) 대전광역시 서구 청사로 189, 4동 (둔산동, 정부대전청사) 팩스 번호 +82-42-481-8578		심사관 양정록 전화번호 +82-42-481-5709

국 제 조 사 보 고 서
대응특허에 관한 정보

국제출원번호

PCT/KR2021/008054

국제조사보고서에서 인용된 특허문헌	공개일	대응특허문헌	공개일
JP 2008-284166 A	2008/11/27	JP 4956273 B2	2012/06/20
KR 10-1237089 B1	2013/02/26	US 2013-0094699 A1	2013/04/18
		US 8565484 B2	2013/10/22