



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2024-0156898
(43) 공개일자 2024년10월31일

(51) 국제특허분류(Int. Cl.)
H04L 27/00 (2006.01) G06N 3/044 (2023.01)
G06N 3/0464 (2023.01) G06N 3/048 (2023.01)
(52) CPC특허분류
H04L 27/0012 (2013.01)
G06N 3/044 (2023.01)
(21) 출원번호 10-2023-0053636
(22) 출원일자 2023년04월24일
심사청구일자 2023년04월24일

(71) 출원인
세종대학교산학협력단
서울특별시 광진구 능동로 209 (군자동, 세종대학교)
(72) 발명자
이병무
서울특별시 송파구 송파대로 567 잠실주공아파트
502-602
토 트루용 안
서울특별시 광진구 능동로32길 106-13, 101호
(74) 대리인
김현승


전체 청구항 수 : 총 20 항

(54) 발명의 명칭 낮은 복잡도의 딥 러닝 기반 자동 변조 분류

(57) 요약

하드웨어 프로세서와, 메모리 디바이스를 포함하는 컴퓨터 시스템이 제공되는데, 메모리 디바이스에는 DL-AMC를 위한 신경망 모델을 구현하기 위해 하드웨어 프로세서에 의해 실행가능한 컴퓨터 프로그램 명령어가 저장되고, 신경망 모델은, 미지의 변조 타입을 갖는 입력 신호에 대해 임계 값을 산출하고 임계 값에 기반하여 입력 신호의 잡음제거를 수행하여 잡음제거된 신호를 생성하는 임계 잡음제거기(Threshold Denoiser: TD)와, 잡음제거된 신호를 처리하여 입력 신호의 변조 타입을 복수의 사전결정된 변조 타입 중 하나로 분류하는 순환 신경망(Recurrent Neural Network: RNN) 기반 분류기를 포함한다.

대표도



(52) CPC특허분류

G06N 3/0464 (2023.01)

G06N 3/048 (2023.01)

이 발명을 지원한 국가연구개발사업

과제고유번호	1711188561
과제번호	2023R1A2C1002656
부처명	과학기술정보통신부
과제관리(전문)기관명	한국연구재단
연구사업명	개인기초연구(과기정통부)
연구과제명	초고밀도 Massive IoT 연결성 확보를 위한 지능형 거대 다중 안테나 핵심 기술 연구
기 여 율	50/100
과제수행기관명	세종대학교
연구기간	2023.03.01 ~ 2024.02.29

이 발명을 지원한 국가연구개발사업

과제고유번호	1711179335
과제번호	00156345
부처명	과학기술정보통신부
과제관리(전문)기관명	정보통신기획평가원
연구사업명	정보통신방송혁신인재양성(R&D)
연구과제명	ICT혁신인재4.0(세종대학교)
기 여 율	50/100
과제수행기관명	세종대학교산학협력단
연구기간	2023.01.01 ~ 2023.12.31

명세서

청구범위

청구항 1

딥 러닝(Deep Learning: DL) 기반 자동 변조 분류(Automatic Modulation Classification: AMC)를 위한 방법으로서,

상기 DL 기반 AMC를 위한 신경망 모델을 구동하는 단계를 포함하되, 상기 신경망 모델은 임계 잡음제거기(Threshold Denoiser: TD)와, 순환 신경망(Recurrent Neural Network: RNN) 기반 분류기를 포함하고, 상기 신경망 모델을 구동하는 단계는,

상기 TD를 사용함으로써, 미지의 변조 타입을 갖는 입력 신호에 대해 임계 값(threshold value)을 산출하는 단계와,

상기 TD를 사용함으로써, 상기 임계 값에 기반하여 상기 입력 신호의 잡음제거(denoising)를 수행하여 잡음제거된 신호를 생성하는 단계와,

상기 RNN 기반 분류기를 사용함으로써, 상기 잡음제거된 신호를 처리하여 상기 입력 신호의 상기 변조 타입을 복수의 사전결정된 변조 타입 중 하나로 분류하는 단계를 포함하는,

방법.

청구항 2

제1항에 있어서,

상기 RNN 기반 분류기는 상기 잡음제거된 신호로부터 맥락 정보(context information)를 획득하는 게이팅 층(gating layer)과, 상기 획득된 맥락 정보에 기반하여 상기 입력 신호의 상기 변조 타입의 상기 분류를 수행하는 분류 층을 포함하는,

방법.

청구항 3

제1항에 있어서,

상기 잡음제거는 절대 값(absolute value)이 상기 임계 값보다 작은 제로 근접 값(near-zero value)을 제로(zero)로 설정하는 잡음제거 함수에 따라 상기 입력 신호의 특징(feature)을 잡음제거된 특징으로 변환하는 것을 포함하는,

방법.

청구항 4

제1항에 있어서,

상기 TD는 제1 합성곱 컴포넌트 및 임계 잡음제거 컴포넌트를 포함하고, 상기 제1 합성곱 컴포넌트는 상기 입력 신호의 특징 표현을 출력하고, 상기 임계 잡음제거 컴포넌트는 사전결정된 범위 내의 스케일링 인자(scaling factor)를 산출하고 상기 스케일링 인자에 기반하여 상기 특징 표현의 스케일링된 평균 값(scaled average value)을 계산하고 상기 스케일링된 평균 값에 기반하여 상기 임계 값을 판정하는 자동 임계 학습 하위 신경망(sub-neural network)을 포함하는,

방법.

청구항 5

제4항에 있어서,

상기 임계 잡음제거 컴포넌트는 상기 임계 값에 기반하여 상기 특징 표현을 잡음제거된 특징 표현으로

변환하는,
방법.

청구항 6

제5항에 있어서,
상기 특징 표현을 변환하는 것은,
상기 특징 표현의 요소의 절대 값이 상기 임계 값 이하인 경우, 상기 잡음제거된 특징 표현의 대응하는 요소를 제로로 설정하는 것과,
상기 절대 값이 상기 임계 값보다 큰 경우, 상기 잡음제거된 특징 표현의 상기 대응하는 요소를 상기 절대 값과 상기 임계 값 간의 차이 및 상기 특징 표현의 상기 요소의 부호(sign)의 곱으로 설정하는 것을 포함하는,
방법.

청구항 7

제5항에 있어서,
상기 TD는 제2 합성곱 컴포넌트를 더 포함하고, 상기 제2 합성곱 컴포넌트는 상기 잡음제거된 특징 표현을 처리하여 상기 잡음제거된 신호를 생성하는,
방법.

청구항 8

제4항에 있어서,
상기 자동 임계 학습 하위 신경망은 전역 평균 풀링(Global Average Pooling: GAP) 층 및 일련의 후속 층을 포함하고, 상기 GAP 층은 상기 특징 표현의 각각의 요소의 절대 값을 평균화된 특징(averaged feature)으로 처리하고, 상기 평균화된 특징은 상기 일련의 후속 층에 전달되고, 상기 일련의 후속 층은,
상기 사전결정된 범위 내의 상기 스케일링된 인자를 출력하도록 활성화 함수를 갖는 전 연결(Fully Connected: FC) 층과,
상기 스케일링된 평균 값을 상기 평균화된 특징에 상기 스케일링 인자가 곱해진 것과 같도록 계산하고 상기 스케일링된 평균 값에 기반하여 상기 임계 값을 판정하는 임계 판정 층을 포함하는,
방법.

청구항 9

제4항에 있어서,
상기 임계 값은 상기 스케일링된 평균 값에 실증적으로 정해진 값(empirically determined value)이 곱해진 것으로서 판정되는,
방법.

청구항 10

컴퓨터 프로세서에 의해 실행되는 경우 상기 컴퓨터 프로세서로 하여금 제1항 내지 제9항 중 어느 한 항에 기재된 방법을 수행하게 하는 컴퓨터 실행가능 명령어가 저장된 컴퓨터 판독가능 저장 매체.

청구항 11

컴퓨터 시스템으로서,
하드웨어 프로세서와,
딥 러닝(Deep Learning: DL) 기반 자동 변조 분류(Automatic Modulation Classification: AMC)를 위한 신경망 모델을 구현하기 위해 상기 하드웨어 프로세서에 의해 실행가능한 컴퓨터 프로그램 명령어가 저장된 메모리 디

바이스를 포함하되, 상기 신경망 모델은,

미지의 변조 타입을 갖는 입력 신호에 대해 임계 값(threshold value)을 산출하고 상기 임계 값에 기반하여 상기 입력 신호의 잡음제거(denoising)를 수행하여 잡음제거된 신호를 생성하는 임계 잡음제거기(Threshold Denoiser: TD)와,

상기 잡음제거된 신호를 처리하여 상기 입력 신호의 상기 변조 타입을 복수의 사전결정된 변조 타입 중 하나로 분류하는 순환 신경망(Recurrent Neural Network: RNN) 기반 분류기를 포함하는,

컴퓨터 시스템.

청구항 12

제11항에 있어서,

상기 RNN 기반 분류기는 상기 잡음제거된 신호로부터 맥락 정보(context information)를 획득하는 게이팅 층(gating layer)과, 상기 획득된 맥락 정보에 기반하여 상기 입력 신호의 상기 변조 타입의 상기 분류를 수행하는 분류 층을 포함하는,

컴퓨터 시스템.

청구항 13

제11항에 있어서,

상기 잡음제거는 절대 값(absolute value)이 상기 임계 값보다 작은 제로 근접 값(near-zero value)을 제로(zero)로 설정하는 잡음제거 함수에 따라 상기 입력 신호의 특징(feature)을 잡음제거된 특징으로 변환하는 것을 포함하는,

컴퓨터 시스템.

청구항 14

제11항에 있어서,

상기 TD는 제1 합성곱 컴포넌트 및 임계 잡음제거 컴포넌트를 포함하고, 상기 제1 합성곱 컴포넌트는 상기 입력 신호의 특징 표현을 출력하고, 상기 임계 잡음제거 컴포넌트는 사전결정된 범위 내의 스케일링 인자(scaling factor)를 산출하고 상기 스케일링 인자에 기반하여 상기 특징 표현의 스케일링된 평균 값(scaled average value)을 계산하고 상기 스케일링된 평균 값에 기반하여 상기 임계 값을 판정하는 자동 임계 학습 하위 신경망(sub-neural network)을 포함하는,

컴퓨터 시스템.

청구항 15

제14항에 있어서,

상기 임계 잡음제거 컴포넌트는 상기 임계 값에 기반하여 상기 특징 표현을 잡음제거된 특징 표현으로 변환하는,

컴퓨터 시스템.

청구항 16

제15항에 있어서,

상기 특징 표현을 변환하는 것은,

상기 특징 표현의 요소의 절대 값이 상기 임계 값 이하인 경우, 상기 잡음제거된 특징 표현의 대응하는 요소를 제로로 설정하는 것과,

상기 절대 값이 상기 임계 값보다 큰 경우, 상기 잡음제거된 특징 표현의 상기 대응하는 요소를 상기 절대 값과 상기 임계 값 간의 차이 및 상기 특징 표현의 상기 요소의 부호(sign)의 곱으로 설정하는 것을 포함하는,

컴퓨터 시스템.

청구항 17

제15항에 있어서,

상기 TD는 제2 합성곱 컴포넌트를 더 포함하고, 상기 제2 합성곱 컴포넌트는 상기 잡음제거된 특징 표현을 처리하여 상기 잡음제거된 신호를 생성하는,

컴퓨터 시스템.

청구항 18

제14항에 있어서,

상기 자동 임계 학습 하위 신경망은 전역 평균 풀링(Global Average Pooling: GAP) 층 및 일련의 후속 층을 포함하고, 상기 GAP 층은 상기 특징 표현의 각각의 요소의 절대 값을 평균화된 특징(averaged feature)으로 처리하고, 상기 평균화된 특징은 상기 일련의 후속 층에 전달되고, 상기 일련의 후속 층은,

상기 사전결정된 범위 내의 상기 스케일링된 인자를 출력하도록 활성화 함수를 갖는 전 연결(Fully Connected: FC) 층과,

상기 스케일링된 평균 값을 상기 평균화된 특징에 상기 스케일링 인자가 곱해진 것과 같도록 계산하고 상기 스케일링된 평균 값에 기반하여 상기 임계 값을 판정하는 임계 판정 층을 포함하는,

컴퓨터 시스템.

청구항 19

제14항에 있어서,

상기 임계 값은 상기 스케일링된 평균 값에 실증적으로 정해진 값(empirically determined value)이 곱해진 것으로서 판정되는,

컴퓨터 시스템.

청구항 20

제11항 내지 제19항 중 어느 한 항에 기재된 컴퓨터 시스템을 포함하는 무선 통신 디바이스.

발명의 설명

기술 분야

[0001] 본 개시는 딥 러닝(Deep Learning: DL) 기반 자동 변조 분류(Automatic Modulation Classification: AMC)에 관한 것으로서, 더욱 구체적으로, 무선 통신 시스템, 예컨대, 6세대(6th Generation: 6G) 무선 통신 시스템을 위한 낮은 복잡도의 AMC에 관련된다.

배경 기술

[0002] 자동 변조 분류(Automatic Modulation Classification: AMC)는 비협력적 통신 환경(non-cooperative communication environment)에서 신호를 분석하는 기술로서, 복조 전에 여러 종류의 신호 변조를 분류하기 위해 사용된다. 기존의 AMC 방안은 주로 우도(likelihood) 기반 및 특징(feature) 기반이라는 두 가지 카테고리로 분류되는데, 전자는 정확도가 높은 반면 계산상 복잡하다. 최근에는 합성곱 신경망(Convolutional Neural Network: CNN), 순환 신경망(Recurrent Neural Network: RNN), 또는 다른 종류의 신경망, 또는 이들의 조합을 사용하여 대량의 샘플 신호로부터 특징을 자동적으로 추출함으로써 높은 분류 성능을 효율적으로 달성하는 딥 러닝(Deep Learning: DL) 기반 AMC(이는 본 문서에서 DL-AMC로 약칭될 수 있음) 방안에 대해 많은 연구가 진행되고 있다.

[0003] 예를 들어, J. Xu, C. Luo, G. Parr, and Y. Luo, "A spatiotemporal multi-channel learning framework for automatic modulation recognition," IEEE Wireless Communications Letters, vol. 9, no. 10, pp. 1629-

1632, 2020은 2차원 합성곱, 1차원 합성곱 및 장단기 메모리(Long Short-Term Memory: LSTM)를 갖는 구조를 제시하는데, 이는 다채널 합성곱 장단기 심층 신경망(Multi-channel Convolutional Long short-term Deep Neural Network: MCLDNN)으로 칭해진다. 이 모델은 신호의 동상(in-phase) 성분, 신호의 직교(quadrature) 성분, 그리고 양자 모두(이들 성분은 신호의 복소 값 표현의 실수 성분 및 허수 성분에 각각 대응하고, 각각 I 성분 및 Q 성분으로, 또는 I 신호 및 Q 신호로 지칭될 수 있음)로부터 시공간적(spatiotemporal) 특징을 추출하여 이를 융합한다. 또한, MCLDNN을 기반으로, F. Zhang, C. Luo, J. Xu, and Y. Luo, "An efficient deep learning model for automatic modulation recognition based on parameter estimation and transformation," IEEE Communications Letters, vol. 25, no. 10, pp. 3287-3290, 2021은 파라미터 추정 및 변환(Parameter Estimation and Transformation: PET), 2차원 합성곱 계층 및 게이트형 순환 유닛(Gated Recurrent Unit: GRU)을 통합한 낮은 복잡도의 경량 구조를 도입하는데, 이는 PET 기반 CNN-GRU 심층 신경망(PET-based CNN-GRU Deep Neural Network: PET-CGDNN)으로 알려져 있다. 이 모델은 MCLDNN보다 적은 크기로 MCLDNN과 비슷한 성능을 보인다. 나아가, T. Huynh-The, C.-H. Hua, Q.-V. Pham, and D.-S. Kim, "MCNet: An efficient CNN architecture for robust automatic modulation classification," IEEE Communications Letters, vol. 24, no. 4, pp. 811-815, 2020에서 제안된 MCNet은 잔차 연결(residual connection) 및 비대칭 합성곱 커널(kernel)과 함께 다수의 합성곱 블록에 기반하는 강인한 구조이다. 한편, X. Fu, G. Gui, Y. Wang, T. Ohtsuki, B. Adebisi, H. Gacanin, and F. Adachi, "Lightweight automatic modulation classification based on decentralized learning," IEEE Transactions on Cognitive Communications and Networking, vol. 8, no. 1, pp. 57-70, 2022은 계산상 복잡도를 낮춘 분리가능 CNN(Separable CNN: S-CNN)을 제안한다.

[0004]

현재, 5세대(5th Generation: 5G) 무선 통신 시스템을 넘어서는 차세대 무선 통신 시스템의 연구 및 개발이 널리 이루어지고 있다. 특히, 6G 시스템은 수신기가 여러 소스로부터 신호를 수신하는 기술을 기반으로 구현될 수 공산이 큰바, AMC의 적용이 유력하다. 6G 네트워크의 몇몇 핵심 성과 지표(Key Performance Indicator: KPI)가 이미 제시되었다. 예컨대, 6G 네트워크의 초저지연시간(ultra-low latency)은 0.1ms 이하이며, 변조 분류의 측면에서 적절한 지연시간은 (그러한 지연시간 규범보다 90% 이상 낮은) 0.01ms 이하로 기대된다.

발명의 내용

해결하려는 과제

[0005]

딥 러닝(Deep Learning: DL) 기반 자동 변조 분류(Automatic Modulation Classification: AMC)가 본 문서에 개시된다.

과제의 해결 수단

[0006]

예에서, 컴퓨터 시스템은 하드웨어 프로세서(hardware processor)와, 메모리 디바이스(memory device)를 포함하되, 메모리 디바이스에는 DL-AMC를 위한 신경망 모델(neural network model)을 구현하기 위해 하드웨어 프로세서에 의해 실행가능한 컴퓨터 프로그램 명령어가 저장되고, 신경망 모델은, 미지의 변조 타입(modulation type)을 갖는 입력 신호에 대해 임계 값(threshold value)를 산출하고 임계 값에 기반하여 입력 신호의 잡음제거(denoising)를 수행하여 잡음제거된 신호를 생성하는 임계 잡음제거기(Threshold Denoiser: TD)와, 잡음제거된 신호를 처리하여 입력 신호의 변조 타입을 복수의 사전결정된 변조 타입 중 하나로 분류하는 순환 신경망(Recurrent Neural Network: RNN) 기반 분류기를 포함한다.

[0007]

전술된 개요는 상세한 설명에서 추가로 후술되는 몇몇 양상을 단순화된 형태로 소개하기 위해 제공된다. 이 개요는 청구된 주제(subject matter)의 중요 특징 또는 필수적 특징을 식별하도록 의도되지 않고, 청구된 주제의 범위를 정하는 데 사용되도록 의도되지도 않는다. 나아가, 청구된 주제는 본 명세서에서 논의되는 임의의 또는 모든 이점을 제공하는 구현에 한정되지 않는다.

발명의 효과

[0008]

본 개시에 따르면, 달라지는 잡음 조건 하에서 일반화(generalization) 능력이 향상된 DL 기반 AMC 기술이 제공된다.

[0009]

본 개시에 따른 DL 기반 AMC는 보다 용이하게, 예컨대, 보다 감소된 계산상 복잡도로써 실시간으로, 실제 통신 시스템에 직접 적용될 수 있다.

[0010]

본 개시에 따르면, 추론에 소요되는 시간이 적으면서도 높은 정확도를 달성하여 차세대 무선 통신 시스템에 적

합한 DL 기반 AMC 모델이 제공된다.

도면의 간단한 설명

- [0011] 도 1은 DL-AMC를 위한 예시적인 신경망 모델이 구현된 수신기의 예를 보여준다.
- 도 2는 도 1의 신경망 모델의 예를 보여준다.
- 도 3은 도 2의 TD의 예를 보여준다.
- 도 4a는 도 3의 제1 합성곱 컴포넌트의 예를 보여주고, 도 4b는 도 3의 제2 합성곱 컴포넌트의 예를 보여준다.
- 도 5는 도 3의 자동 임계 학습 하위 신경망의 예를 보여준다.
- 도 6은 도 2의 RNN 기반 분류기의 예를 보여준다.
- 도 7은 예시적인 신경망 모델에 대한 실험의 결과를 설명하기 위한 도면이다.
- 도 8은 도 1의 신경망 모델이 구현되고 구동되는 예시적인 컴퓨터 시스템의 개략도이다.
- 도 9는 DL-AMC를 위한 신경망 모델을 구동하는 프로세스의 예를 보여준다.

발명을 실시하기 위한 구체적인 내용

- [0012] 본 개시에서 사용되는 다양한 용어는 본 문서에서의 기능을 고려하여 상용 용어의 용어법으로부터 선택되는데, 이는 당업자의 의도, 준례, 또는 새로운 기술의 출현에 따라서 달리 인식될 수 있다. 특정한 사례에서, 몇몇 용어에는 상세한 설명에서 개진된 바와 같이 의미가 주어질 수 있다. 따라서, 본 문서에서 사용되는 용어는, 단순히 그 명칭에 의해서가 아니라, 본 개시의 맥락에서 그 용어가 갖는 의미와 일관되게 정의되어야 한다.
- [0013] 본 문서에서 용어 "포함하다", "가지다" 등은 이후에 열거된 요소, 예컨대, 어떤 특징, 숫자, 단계, 동작, 구성 요소, 정보 또는 이들의 조합의 존재를 명시하는 경우에 사용된다. 달리 표시되지 않는 한, 이런 용어 및 이의 변형은 다른 요소의 존재 또는 추가를 배제하도록 의도되지 않는다.
- [0014] 본 문서에서 사용되는 바와 같이, 용어 "제1", "제2" 등은 몇 개의 서로 닮은 요소를 식별하도록 의도된다. 달리 기재되지 않는 한, 그러한 용어는 이들 요소의 또는 이들의 사용의 특정한 순서와 같은 한정을 부과하도록 의도된 것이 아니라, 단지 여러 요소를 따로따로 지칭하기 위해 사용된다. 예를 들면, 어떤 요소가 일례에서 용어 "제1"로써 참조될 수 있는 한편 동일한 요소가 다른 예에서 "제2" 또는 "제3"과 같은 상이한 서수로써 참조될 수 있다. 그러한 예에서, 이들 용어는 본 개시의 범위를 한정하지 않는 것이다. 또한, 여러 요소의 리스트에서 용어 "및/또는"을 사용하는 것은 열거된 항목 중 임의의 하나 또는 복수 개를 비롯하여 이들 항목의 모든 가능한 조합을 포함한다. 나아가, 단수 형태의 표현은 명확하게 달리 사용되지 않는 한, 복수 형태의 의미를 포함한다.
- [0015] 첨부된 도면을 참조하여 본 개시의 소정의 예가 이제 상세히 기술될 것이다. 다만, 본 개시는 많은 상이한 형태로 체현될 수 있으며, 본 문서에 개진된 예에 한정되는 것으로 해석되어서는 안 된다. 오히려, 이들 예는 본 개시의 범위의 더 나은 이해를 제공하기 위해서 주어지는 것이다.
- [0016] 도면에 묘사된 개별 특징 중 몇몇은 서로 독립적으로 구현되거나 조합되어 구현될 수 있음이 고려된다. 다양한 예의 이들 특징 및 다른 특징은 첨부된 도면과 함께 이하의 상세한 설명으로부터 명백하게 될 것이다.
- [0017] 본 개시의 다양한 예는 미지의 신호의 변조 타입(이는 변조 모드(modulation mode)로 지칭될 수도 있음)을 분류하는 DL-AMC를 위한 신경망 모델을 제시한다. 제시된 모델은 임계 잡음제거기(Threshold Denoiser: TD)를 순환 신경망(Recurrent Neural Network: RNN)과 조합하여 변조 인식을 가능하게 하며, 이는 TDRNN 모델로 지칭될 수 있다. 즉, 이 모델에서, TD는 미가공(raw) I/Q 신호의 잡음을 자동적으로 제거하고, RNN은 변조 분류를 위해 그것의 입력으로서 잡음제거된 신호를 수신한다. 잡음 전력을 줄이기 위해, TD는 입력된 신호로부터 잡음 및 다른 중요하지 않은 특징을 추출하고 제거할 수 있다. 자동적으로 학습된 임계(threshold)가 그러한 잡음제거를 위해 사용될 수 있다. TDRNN 모델은 전반적인 정확도가 우수할 뿐만 아니라, 기존의 AMC 기술에 비해 더 적은 복잡도로 더 적은 추론 시간(예컨대, 6G 네트워크와 같은 통신 환경에서 요구되는 사항에 부합하는 추론 시간)을 달성한다. 이는 다양한 배경 잡음, 예컨대, 주파수 선택적 페이딩(frequency selective fading), 국소 오실레이터 오프셋(local oscillator offset), 도플러 오프셋(doppler offset), 가산성 백색 가우스 잡음(Additive White Gaussian Noise: AWGN), 임펄스성 잡음(impulsive noise), 동일 채널 간섭(co-channel interference), 인접 채널

널 간섭(adjacent channel interference) 등으로 인한 난제에 대처하여 더욱 정확하고 더욱 신속한 변조 분류를 가능하게 한다.

[0018] 문제 서술

[0019] 무선 통신 시스템에서 변조는 기저대역 신호(baseband signal)의 특성에 따라서 반송파 신호(carrier signal) (예컨대, 고주파 또는 무선 주파수(Radio Frequency: RF) 신호)의 속성을 바꾸는 과정이다. 무선 통신 시스템 내에서 서로 떨어져 위치된 송신기 및 수신기 간의 정보의 정확한 전송을 제공하기 위해, 전형적으로 변조 과정에서 신호의 특성은 통신 채널의 특성과 매칭된다. 수신기에 의해 수신된 신호 $y(t)$ 는 다음과 같이 주어진다.

수학식 1

[0020]
$$y(t) = h(t) * X(t) + n$$

[0021] 여기서 $h(t)$ 는 채널의 임펄스 응답(impulse response)이고, $X(t)$ 는 잡음 없는(noise-free) 송신된 신호이고, n 은 평균이 0이고 분산이 σ^2 인 AWGN이다.

[0022] 통신 채널 임펄스 응답은 다음과 같이 기술된다.

수학식 2

[0023]
$$h(t) = a * \delta(t - t_d)$$

[0024] 여기서 a 는 해당 신호의 진폭이고, δ 는 임펄스 함수(impulse function)이고, t 는 시간 간격(time interval)이고, t_d 는 채널의 다중 경로 지연(multi-path delay)이다.

[0025] 개괄적으로, AMC는 다중 클래스 분류 내지 M-클래스 인식 작업인데, 여기서 M개의 클래스는 수신된 신호 $y(t)$ 에 의해 제공되는 정보에 기반하여 송신 신호 $X(t)$ 의 변조의 여러 가능한 타입을 나타낸다. 따라서, 변조 분류는 수신된 신호의 특성을 식별하고 변조의 정확한 타입을 판정하는 것이라고 할 수 있다. 변조 분류를 위한 다양한 알고리즘은 그것들의 분류 모델의 정확도 및 연산 스피드에 기반하여 평가될 수 있다.

[0026] 시스템 모델

[0027] 논의를 위해, 통신 환경(예컨대, 복수의 무인 비행체(Unmanned Aerial Vehicle: UAV)(가령, 드론(drone)) 각각이 각자의 서빙 셀(serving cell) 내의 사용자를 서빙하되, 해당 UAV로부터 송신되는 신호가 다른 UAV의 서빙 셀 내의 사용자에게 간섭 신호로서 작용하는 다중 UAV 기반 네트워크를 포함하는 비협력적 통신 환경)에서 AWGN 및 간섭이 있는 무선 채널을 통하여 송신기에 의해 디지털 변조 신호가 송신되는 예가 고려된다. 그러한 환경 내에 도 1의 예시적인 수신기(100)가 배치될 수 있다. 이 예에서, 변조의 타입뿐만 아니라 심볼 레이트(symbol rate) 등에 대한 어떤 사전 정보도 수신기(100)에 제공되지 않는다. 그러한 신호가 수신기(100)에 의해 검출되면, 수신기(100)의 전처리부(110)는 이 신호의 전처리(예컨대, 하향변환(down-conversion), 대역통과 필터링(bandpass filtering) 및 디지털화(digitization))를 수행하여 기저대역 신호를 생성할 수 있다. 생성된 기저대역 신호는 복조기(120)에, 그리고 신경망 모델(170)이 구현된 자동 변조 분류부(150)에도 제공될 수 있다. 그러면, 자동 변조 분류부(150)는 신경망 모델(170)을 구동하여 해당 신호의 변조의 타입을 식별할 수 있다. 복조기(120)는 식별된 변조 타입에 따라 기저대역 신호를 처리하여 복조된 시퀀스(demodulated sequence)를 생성할 수 있다.

[0028] 이 예에서, 신경망 모델(170)은 정확한 변조 타입 판정을 가능하게 하는 DL 기반 AMC를 위한 모델인데, 그러한 DL-AMC는 다음과 같이 표현될 수 있다.

수학식 3

$$\hat{y} = \operatorname{argmax}_f(y|X; W)$$

[0029]

[0030]

여기서 $\hat{y}$ 는 DL-AMC를 위한 신경망 모델(170)에 의해 출력되는 예측된 변조 타입(predicted modulation type)이고, y 는 실제 변조 타입(truth modulation type)이고, W 는 신경망 모델(170)의 가중치(weight)이다. 특히, 아래에서 논의되는 바와 같이, 신경망 모델(170)은 정확도가 높으면서도 복잡도가 낮은 경량의 구조를 달성할 수 있다.

[0031]

도 2는 신경망 모델(170)의 예를 보여준다. 도시된 예에서, 신경망 모델(170)은 임계 잡음제거기(Threshold Denoiser: TD)(210) 및 순환 신경망(Recurrent Neural Network: RNN) 기반 분류기(220)를 포함한다.

[0032]

TD(210)는 미지의 변조 타입을 갖는 입력 신호에 대해 임계 값(threshold value)을 산출하고, 산출된 임계 값에 기반하여 입력 신호를 잡음제거된 신호(denoised signal)로 처리할 수 있다.

[0033]

RNN 기반 분류기(220)는 잡음제거된 신호를 처리하여 입력 신호의 변조 타입을 복수의 사전결정된 변조 타입 중 하나로 분류할 수 있다. 예로서, 도 2에 묘사된 바와 같이, RNN 기반 분류기(220)는 잡음제거된 신호로부터 맥락 정보(context information)를 획득하는 게이팅 층(gating layer)(221)(예컨대, GRU 층 또는 LSTM 층을 포함함) 및 획득된 맥락 정보에 기반하여 입력 신호의 변조 타입을 전술된 바와 같이 분류하는 분류 층(222)(예컨대, 전 연결(Fully Connected: FC) 층을 포함하는데, FC 층은 밀집 층(dense layer)이라고 지칭되기도 함)을 포함할 수 있다.

[0034]

옵션으로, 도 2에 도시된 바와 같이, 신경망 모델(170)은 재형상화 층(reshape layer)(215)를 더 포함할 수 있다. RNN 기반 분류기(220)(예컨대, 게이팅 층(221))에는 TD(210)로부터 출력된 잡음제거된 신호가 재형상화 층(215)에 의해 재형상화된 후에 입력될 수 있다. 예를 들어, TD(210)는 후술되는 바와 같이 합성곱 층을 포함하는 스테이지(stage)일 수 있고, 합성곱의 입력 데이터는 물론 그것의 출력 데이터는 4차원(four-dimensional)(4D) 텐서(tensor)로써 나타내어질 수 있는(예컨대, 텐서 데이터의 각 차원은 배치 크기(batch size), 폭(width), 높이(height) 및 특징 맵(feature map)에 해당할 수 있음) 한편, RNN 기반 분류기(220)의 입력 데이터는 3차원(three-dimensional)(3D) 텐서로써 나타내어질 수 있다(예컨대, 이 텐서 데이터의 각 차원은 배치 크기, 시간스텝(time step) 및 입력 차원수(dimensionality)에 해당할 수 있음). 이에 따라, 재형상화 층(215)은 TD(210)로부터 출력된 4D 텐서 데이터를 3D 텐서 데이터로 재구성하여 RNN 기반 분류기(220)에 제공할 수 있다.

[0035]

TD의 예시적인 구성

[0036]

도 3은 TD(210)의 예를 보여준다. 도시된 예에서, TD(210)는 배치 정규화(Batch Normalization: BN) 층(310), 제1 합성곱 컴포넌트(320), 제2 합성곱 컴포넌트(330) 및 임계 잡음제거 컴포넌트(340)를 포함한다.

[0037]

BN 층(310)은 입력 신호를 정규화하고, 정규화된 입력 신호를 제1 합성곱 컴포넌트(320)에 제공할 수 있다. 그러한 BN은 TD(210)의 일반화 능력을 개선할 수 있다. BN에 있어서, 배치(batch) 단위 간 데이터 분포의 차이가 평균 및 분산으로써 완화되므로, 모델(170)의 양호한 비선형 표현력을 보장할 수 있다.

[0038]

제1 합성곱 컴포넌트(320)는 정규화된 입력 신호를 처리하여 입력 신호의 특징 표현(feature representation)(예컨대, 특징 맵(feature map))을 출력할 수 있다.

[0039]

임계 잡음제거 컴포넌트(340)는 임계 값에 기반하여 입력 신호의 특징 표현을 잡음제거된 특징 표현으로 변환할 수 있다. 몇몇 예에서, 임계 잡음제거 컴포넌트(340)는 잡음제거 함수에 따라 입력 신호의 특징을 잡음제거된 특징으로 변환할 수 있는데, 잡음제거 함수는 절대 값(absolute value)이 임계 값보다 작은 제로 근접 값(near-zero value)을 제로(zero)(즉, 0)로 설정하고, 임계 값보다 큰 양수의 범위에 걸쳐 증가하는 한편, 절대 값이 임계 값보다 큰 음수의 범위에 걸쳐 감소하는 함수로 정의될 수 있다.

[0040]

또한, 도 3에 묘사된 바와 같이, 임계 잡음제거 컴포넌트(340)는 자동 임계 학습 하위 신경망(sub-neural network)(342)을 포함하는데, 이러한 하위 망(342)은 사전결정된 범위 내의 스케일링 인자(scaling factor)를 산출하고, 스케일링 인자에 기반하여 입력 신호의 특징 표현의 스케일링된 평균 값(scaled average value)을 계산하고, 계산된 스케일링된 평균 값에 기반하여 임계 값을 판정할 수 있다. 잡음제거 함수의 예 및 자동 임계

학습 하위 신경망(342)의 예시적인 구성과 함께, 임계 잡음제거 컴포넌트(340)의 예시적인 동작에 대해 아래에서 더욱 상세히 논의될 것이다.

[0041] 제2 합성곱 컴포넌트(330)는 잡음제거된 특징 표현을 처리하여 잡음제거된 신호(예컨대, 잡음제거된 특징 맵으로부터 도출된 추가적인 특징 맵의 시퀀스)를 생성할 수 있다.

[0042] 몇몇 예에서, 제1 합성곱 컴포넌트(320)는, 도 4a에 도시된 바와 같이, 제1 합성곱 층(401)(이는 2차원(two-dimensional)(2D) 합성곱 층일 수 있고, 본 문서에서 "Conv1"으로 표기될 수도 있음)을 포함할 수 있고, 제1 합성곱 층(401)의 활성화 함수(activation function)는 정류된 선형 유닛(Rectified Linear Unit: ReLU) 함수일 수 있다. 또한, 몇몇 예에서, 제2 합성곱 컴포넌트(330)는, 도 4b에 도시된 바와 같이, 제2 합성곱 층(402)(이는 2D 합성곱 층일 수 있고, 본 문서에서 "Conv2"로 표기될 수도 있음)에 이어서, 제3 합성곱 층(403)(이는 2D 합성곱 층일 수 있고, 본 문서에서 "Conv3"로 표기될 수도 있음)을 포함할 수 있고, 제2 합성곱 층(402) 및 제3 합성곱 층(403) 각각의 활성화 함수 역시 ReLU 함수일 수 있다. 예로서, 아래에서 표 1에 기술된 바와 같이, 제 1 내지 제3 합성곱 층(401, 402, 403) 각각은 다음과 같이 동일한 크기의 하나 이상의 합성곱 필터(즉, 커널)를 가질 수 있다: 제1 합성곱 층(401)은 각각 크기가 2x3인 16개의 필터를 가질 수 있음; 제2 합성곱 층(402)은 각각 크기가 2x3인 32개의 필터를 가질 수 있음; 그리고 제3 합성곱 층(403)은 각각 크기가 2x3인 64개의 필터를 가질 수 있음.

[0043] 잡음제거 동작의 예

[0044] 앞서 언급된 바와 같이, 임계 잡음제거 컴포넌트(340)는 잡음제거 함수를 사용하여 입력 신호의 잡음과 관련된(특히, 제로 근접 값을 갖는) 특징 성분을 제거할 수 있다. 몇몇 예에서, 잡음제거 함수는 다음과 같이 주어질 수 있다.

수학식 4

$$y_i = \begin{cases} 0 & , if |x| \leq \tau \\ Sgn(x)(|x| - \tau) & , if |x| > \tau \end{cases}$$

[0045]

[0046] 여기서 x 는 입력 신호의 특징이고 y_i 는 출력되는 잡음제거된 특징이고, τ 는 임계 값이고, $Sgn(x)$ 는 입력 신호의 부호 함수(sign function)(이는 시그넘 함수(signum function)로도 칭해짐)이다. 부호 함수는 다음과 같이 표현될 수 있다.

수학식 5

$$Sgn(x) := \begin{cases} 1, & if x > 0 \\ 0, & if x = 0 \\ -1, & if x < 0 \end{cases}$$

[0047]

[0048] 수학식 4 및 5로부터 알 수 있는 바와 같이, 입력 신호의 특징 표현을 잡음제거된 특징 표현으로 변환하는 것은 (i) 입력 신호의 특징 표현의 요소(element)의 절대 값이 임계 값 이하인 경우, 잡음제거된 특징 표현의 대응하는 요소를 제로로 설정하는 것(즉, $|x| \leq \tau$ 인 경우 $y_i=0$), 그리고 (ii) 입력 신호의 특징 표현의 요소의 절대 값이 임계 값보다 큰 경우, 잡음제거된 특징 표현의 대응하는 요소를 입력 신호의 특징 표현의 요소의 절대 값과 임계 값 간의 차이 및 입력 신호의 특징 표현의 요소의 부호(sign)의 곱으로 설정하는 것(즉, $|x| > \tau$ 인 경우 $y_i=Sgn(x)(|x| - \tau)$)을 수반할 수 있다.

[0049] 나아가, 임계 값은 (예컨대, 다양한 변조 타입에 대해 상이할 수 있는 레벨의 잡음을 포함한 훈련용 샘플 신호를 통해 이들 샘플 신호 및 그것들의 적절한 임계 값의 관계를 학습한) 자동 임계 학습 하위 신경망(342)에 의해 판정될 수 있다. 예를 들어, 도 5에 도시된 바와 같이, 자동 임계 학습 하위 신경망(342)은 전역 평균 풀링(Global Average Pooling: GAP) 층(501)에 이어서, ReLU 활성화 함수를 가진 선행 FC 층(502)에 이어서, 개재(intervening) BN 층(503)에 이어서, 시그모이드(sigmoid) 활성화 함수를 가진 후속 FC 층(504)에 이어서, 임

계 판정 층(505)을 포함할 수 있다. 구체적으로, GAP 층(501)은 입력 신호의 특징 표현의 각각의 요소의 절대 값을 평균화된 특징(averaged feature)으로 처리할 수 있는데, 그러한 평균화된 특징은 선행 FC 층(502)뿐만 아니라 임계 판정 층(505)에도 제공될 수 있다. 선행 FC(502) 층의 출력은 개재 BN 층(503)에 의해 정규화되고 이후에 후속 FC 층(504)에 입력될 수 있다. 후속 FC 층(504)은 시그모이드 활성화 함수에 따라 0과 1 사이라는 사전결정된 범위 내의 스케일링된 인자를 출력할 수 있다. 그러면, 다음 식에 의해 주어진 바와 같이, 임계 판정 층(505)은 스케일링된 평균 값을 GAP 층(501)으로부터 제공된 평균화된 특징 $\bar{y}$ 에 스케일링 인자가 곱해진 것과 같도록 계산할 수 있다.

수학식 6

$$\beta = \alpha * \bar{y}$$

여기서 β 는 스케일링된 평균 값이고, α 는 스케일링 인자이고, $\bar{y}$ 는 평균화된 특징이다.

나아가, 임계 판정 층(505)은 스케일링된 평균 값에 기반하여 임계 값을 판정할 수 있다. 예를 들어, 임계 값은 다음 식과 같이 판정될 수 있다.

수학식 7

$$\tau = \beta * (1 + \rho)$$

여기서 ρ 는 신경망 모델(170)에 대한 실험의 결과로부터 실증적으로 정해진(empirically determined) 조정 파라미터이다. 예시적인 실험에서, 지정된 범위의 레벨의 신호 대 잡음비(Signal-to-Noise Ratio: SNR)를 갖는 다수의 샘플 신호의 세트에 대해 신경망 모델(170)을 구동하여 샘플 신호의 변조 타입이 분류되는데, 조정 파라미터 ρ 의 여러 값에 대해 그러한 분류된 변조 타입의 정확도가 측정될 수 있고, 측정된 정확도에 기반하여, 예컨대, 신경망 모델(170)에 의해 달성되는 정확도가 향상되도록, 조정 파라미터 ρ 가 설정될 수 있다. 다시 말해, 측정된 정확도에 대한 조정 파라미터 ρ 의 영향을 감안하여, 예컨대, ρ 는 1이라는 값으로(즉, $(1 + \rho)$ 는 2라는 값으로) 정해질 수 있다.

RNN 기반 분류기의 예시적인 구성

도 6은 RNN 기반 분류기(220)의 예를 보여준다. 도시된 예에서, RNN 기반 분류기(220)의 케이팅 층(221)은 GRU 층(621)을 포함하고, RNN 기반 분류기(220)의 분류 층(222)은 FC 층(622)을 포함한다.

GRU 층(621)은 잡음제거된 신호를 시퀀스 단위로 입력 받고, GRU 층(621)의 은닉 유닛에서의 연산을 통해 맥락 정보를 나타내는 은닉 상태의 시퀀스(가령, 입력 시퀀스와 동일하거나 상이한 길이를 가짐)를 산출할 수 있다. 예로서, 표 1에 기술된 바와 같이, GRU 층(621)은 64개의 은닉 유닛을 가질 수 있다.

FC 층(622)은 GRU 층(621)에 의해 출력된 은닉 상태에 기반하여 M-클래스 분류를 수행할 수 있다. 예로서, 표 1에서 볼 수 있듯이, FC 층(622)은 소프트맥스(softmax) 활성화 함수를 가질 수 있고, 출력 크기가 11(즉, M=11)일 수 있다.

신경망 모델에 대한 실험

실험을 위해, 신경망 모델(170)은 표 1에 예시된 바와 같이 구성된다. 편의상, 신경망 모델(170)의 이러한 구현은 타겟 TDRNN 모델로 지칭된다.

표 1

층	입력 크기	출력 크기	세부사항
입력	2 x 128 x 1	-	-
BN	2 x 128 x 1	2 x 128 x 1	-
Conv1	2 x 128 x 1	2 x 128 x 16	활성화: ReLU, 커널: 2x3, 필터: 16
자동 임계 학습	2 x 128 x 16	2 x 128 x 16	-
Conv2	2 x 128 x 16	2 x 128 x 32	활성화: ReLU, 커널: 2x3, 필터: 32
Conv3	2 x 128 x 32	2 x 126 x 64	활성화: ReLU, 커널: 2x3, 필터: 64
재형상화	1 x 126 x 64	126 x 64	-
GRU	126 x 64	64	은닉 유닛: 64
밀집	64	11	활성화: Softmax

이와 관련하여, 표 2는 GRU 층(621)이 은닉 유닛의 수(용어 "GRU" 뒤의 괄호 안에 기재됨)가 신경망 모델(170)의 정확도 레벨, 파라미터 수 및 추론 시간에 어떤 영향이 있는지를 보여준다. 표 2에서 이해될 수 있는 바와 같이, 은닉 유닛의 수는 평균적인 분류 정확도 및 파라미터의 수와 직접적인 상관관계가 있고 추론 시간에는 반비례한다. 은닉 유닛의 수의 증가는 사용되는 파라미터의 수의 증가를 나타낸다. 적용된 파라미터 수의 증가는 시스템이 입력 데이터의 더 복잡한 패턴을 학습할 수 있게 하여, 더 높은 정확도로 이어진다. 다만, 이는 계산 복잡도 및 시간 소모의 증가를 야기한다. 타겟 TDRNN에서 GRU 층(621)은 특정한(가령, 6G 네트워크의) 요구사항을 만족하는 추론 시간과 함께 상대적으로 높은 63.5%의 평균 정확도를 갖는 64개의 은닉 유닛을 갖도록 선정되었다.

표 2

모델	평균 정확도 (%)	파라미터 수	샘플 당 추론 시간 (ms)
GRU(16)	47.7	20,269	0.0065
GRU(32)	59.3	25,917	0.0068
GRU(64)	63.5	41,821	0.0073
GRU(128)	64.2	92,061	0.0095
GRU(256)	66.1	266,269	0.017

손실 함수는 다음 식에 주어진 바와 같이 카테고리 크로스 엔트로피(Category Cross Entropy: CCE) 함수로서 설정된다.

수학식 8

$$L_{CCE} = \sum_{i=1}^S Y_t \log(Y_p)$$

수학식 9

$$Y_p = f_{Softmax}(x_i)$$

여기서 Y_t 는 정답(ground truth)의 원핫 인코딩 벡터(one-hot encoding vector)이고, x_i 는 타겟 TDRNN 모델의 제i 출력이고, Y_p 는 예측된 벡터이고, S는 출력 크기를 나타낸다.

타겟 TDRNN 모델에 대한 실험을 위해 RadioML 2016.10A 데이터세트가 사용된다. 이 데이터세트는 8개의 디지털 변조 타입 및 3개의 아날로그 변조 타입에 대해 -20dB부터 18dB까지 20개의 SNR 레벨에 걸쳐 생성된 220,000개의 샘플 신호를 포함하며, 각각의 SNR 레벨마다 변조 타입당 1,000개의 신호로 구분된다.

이 실험에 있어서, 타겟 TDRNN 모델은 RadioML 2016.10A 데이터세트로 훈련되는데, 이 데이터세트에서 70%의 신

호가 훈련을 위해 사용되고 30%의 신호가 테스트를 위해 사용되도록 무작위로 선택된다. 또한, 전술된 하이퍼파라미터 외에도, 훈련 과정의 에포크(epoch)의 수는 500으로, 학습률(learning rate)은 0.001으로, 그리고 배치 크기(batch size)는 1024로 설정된다. 이 훈련에서 과적합(overfitting)의 방지를 위해 조기 중단(early stopping)이 적용된다. 훈련 데이터셋으로 타겟 TDRNN 모델이 훈련되고, 테스트 손실이 개선되지 않을 때까지 아담 최적화기(Adam optimizer)로써 타겟 TDRNN 모델의 가중치가 갱신된다.

[0070] 또한, 이 실험을 위해 조정 파라미터 ρ 의 값은 1로 설정된다.

[0071] 도 7은 타겟 TDRNN 모델의 분류 정확도를 기존의 AMC를 위한 모델인 MCLDNN, PET-CGDNN, MCNet 및 S-CNN과 비교한 결과를 보여준다. 이들 모델은 모두 RadioML 2016.10A 데이터셋을 사용하여 훈련되었다. 도 7에서 각 모델의 분류 정확도의 최대값이 "[*.*)"의 포맷으로 해당 모델의 명칭 뒤에 덧붙여졌다. 더 나아가, 아래 표는 타겟 TDRNN 모델의 복잡도를 다른 모델과 비교한 결과를 보여준다.

표 3

모델	샘플 당 추론 시간 (ms)	파라미터 수	평균 정확도 (%)
MCLDNN	0.16	406,199	60.49
PET-CGDNN	0.063	71,871	59.65
MCnet	0.021	90,763	58.1
S-CNN	0.009	104,395	47.82
타겟 TDRNN	0.007	41,821	63.6

[0073] 표 3에서 볼 수 있는 바와 같이, 타겟 TDRNN은 상당히 적은 수의 파라미터로, 그리고 훨씬 짧은 추론 시간으로 우수한 평균 정확도를 달성한다. 구체적으로, 타겟 TDRNN의 평균 정확도는 MCLDNN 및 PET-CGDNN에 비해 거의 3% 내지 4%만큼 높고 MCNet에 비해 약 6%만큼, 그리고 S-CNN에 비해 약 16%만큼 높다. 계산 복잡도의 측면에서, 타겟 TDRNN은 가장 적은 수의 파라미터를 갖는 반면, 이에 비해 MCNet, PET-CGDNN 및 S-CNN은 2배가량의 파라미터를 갖고 MCLDNN은 대략 10배의 파라미터를 갖는다. 샘플 당 추론 시간은 타겟 TDRNN이 가장 빠르고, S-CNN이 그 뒤를 잇는다. MCNet, PET-CGDNN 및 MCLDNN은 샘플 당 추론 시간이 타겟 TDRNN에 비해 각각 3배, 9배 및 23배 정도이다. 더욱이, 6G 네트워크의 요구사항과 관련하여, 샘플 당 추론 시간이 0.01ms보다 적은 것은 타겟 TDRNN과 S-CNN인데, 타겟 TDRNN이 S-CNN에 비해 더 적은 수의 파라미터로 더 높은 정확도를 달성한다. 요컨대, TDRNN은 매우 낮은 복잡도로, 종래의 모델에 비해 개선된 시스템 성능을 달성하고 6G 네트워크 요구사항을 충족시킬 수 있다.

[0074] 예시적인 컴퓨터 시스템

[0075] 도 8은 신경망 모델(170)이 구현되고 구동되는 컴퓨터 시스템(800)의 예를 보여준다. 예시적인 컴퓨터 시스템(800)은 버스를 통해 서로 통신가능하게 커플링된 하드웨어 프로세서(810), 메모리 디바이스(820) 및 통신 인터페이스(830)를 포함한다. 몇몇 예에서, 컴퓨터 시스템(800)은 수신기(100)와 같은 무선 통신 디바이스 내에 구현되거나 이를 포함할 수 있다.

[0076] 도시된 예에서, 하드웨어 프로세서(810)는 컴퓨터 시스템(800)의 전반적인 동작을 제어한다. 예를 들어, 하드웨어 프로세서(810)는 DL-AMC와 관련하여 본 문서에 기술된 동작 중 전부 또는 일부를 수행할 수 있다.

[0077] 도시된 예에서, 메모리 디바이스(820)는 다양한 정보를 저장한다. 예를 들어, 메모리 디바이스(820)는 DL-AMC를 위한 신경망 모델(170)을 구현하고/거나 구동하는 데에서 사용되고/거나 산출되는 정보, 예컨대, 컴퓨터 시스템(800)의 동작 중에 사용되는 데이터 및/또는 컴퓨터 시스템(800) (가령, 하드웨어 프로세서(810))에 의해 실행되는 명령어의 세트를 비일시적(non-transitory) 형태로 저장할 수 있다.

[0078] 도시된 예에서, 통신 인터페이스(830)는 컴퓨터 시스템(800)로 하여금 외부의 개체(가령, 외부의 무선 통신 디바이스, 다른 컴퓨터 시스템, 또는 통신 능력이 있는 임의의 디바이스)에 데이터를 송신하고 이로부터 데이터를 수신하기 위해 네트워크(가령, UAV 기반 네트워크)를 액세스할 수 있게 한다.

[0079] 예시적인 DL-AMC 프로세스

[0080] 이제, 도 9를 참조하여, DL-AMC를 위한 신경망 모델을 구동하는 예시적인 프로세스(900)가 설명된다. 이 신경망 모델(가령, 신경망 모델(170))은 TD 및 RNN 기반 분류기를 포함한다. 예를 들어, 프로세스(900)는 신경망 모델(170)이 구현된 컴퓨터 시스템(가령, 컴퓨터 시스템(900))에 의해 수행될 수 있다. 프로세스(900)의 다른 예시

적인 흐름이 또한 고려된다. 예를 들어, 프로세스(900)는 도시되지 않은 추가적인 동작을 또한 포함할 수 있고/거나, 도 9와 관련하여 예시된 동작 중 일부를 포함하나 전부를 포함하지는 않을 수 있다.

- [0081] 동작(910)에서, 신경망 모델의 TD를 사용함으로써, 미지의 변조 타입을 갖는 입력 신호에 대해 임계 값이 산출된다.
- [0082] 동작(920)에서, 신경망 모델의 TD를 사용함으로써, 임계 값에 기반하여 입력 신호의 잡음제거가 수행된다.
- [0083] 동작(930)에서, 신경망 모델의 RNN 기반 분류기를 사용함으로써, 잡음제거된 입력 신호를 처리하여 입력 신호의 변조 타입이 분류된다.
- [0084] 추가 예
- [0085] 다음은 DL-AMC에 관련된 다양한 예이다.
- [0086] 예 1에서, 딥 러닝(Deep Learning: DL) 기반 자동 변조 분류(Automatic Modulation Classification: AMC)를 위한 방법은, 위 DL 기반 AMC를 위한 신경망 모델을 구동하는 단계를 포함하되, 위 신경망 모델은 임계 잡음제거기(Threshold Denoiser: TD)와, 순환 신경망(Recurrent Neural Network: RNN) 기반 분류기를 포함하고, 위 신경망 모델을 구동하는 단계는, 위 TD를 사용함으로써, 미지의 변조 타입을 갖는 입력 신호에 대해 임계 값(threshold value)을 산출하는 단계와, 위 TD를 사용함으로써, 위 임계 값에 기반하여 위 입력 신호의 잡음제거(denoising)를 수행하여 잡음제거된 신호를 생성하는 단계와, 위 RNN 기반 분류기를 사용함으로써, 위 잡음제거된 신호를 처리하여 위 입력 신호의 위 변조 타입을 복수의 사전결정된 변조 타입 중 하나로 분류하는 단계를 포함한다.
- [0087] 예 2는 예 1의 주제를 포함하는데, 위 잡음제거는 절대 값(absolute value)이 위 임계 값보다 작은 제로 근접 값(near-zero value)을 제로(zero)로 설정하는 잡음제거 함수에 따라 위 입력 신호의 특징(feature)을 잡음제거된 특징으로 변환하는 것을 포함한다.
- [0088] 예 3은 예 2의 주제를 포함하는데, 위 잡음제거 함수는 위 임계 값보다 큰 양수의 범위에 걸쳐 증가하고 절대 값이 위 임계 값보다 큰 음수의 범위에 걸쳐 감소한다.
- [0089] 예 4는 예 1 내지 예 3 중 임의의 것의 주제를 포함하는데, 위 TD는 제1 합성곱 컴포넌트 및 임계 잡음제거 컴포넌트를 포함하고, 위 제1 합성곱 컴포넌트는 위 입력 신호의 특징 표현을 출력하고, 위 임계 잡음제거 컴포넌트는 사전결정된 범위 내의 스케일링 인자(scaling factor)를 산출하고 위 스케일링 인자에 기반하여 위 특징 표현의 스케일링된 평균 값(scaled average value)을 계산하고 위 스케일링된 평균 값에 기반하여 위 임계 값을 판정하는 자동 임계 학습 하위 신경망(sub-neural network)을 포함한다.
- [0090] 예 5는 예 4의 주제를 포함하는데, 위 임계 잡음제거 컴포넌트는 절대 값이 위 임계 값보다 작은 제로 근접 값을 제로로 설정하는 잡음제거 함수에 따라 위 특징 표현의 요소(element)를 잡음제거된 특징으로 변환한다.
- [0091] 예 6은 예 5의 주제를 포함하는데, 위 잡음제거 함수는 위 임계 값보다 큰 양수의 범위에 걸쳐 증가하고 절대 값이 위 임계 값보다 큰 음수의 범위에 걸쳐 감소한다.
- [0092] 예 7은 예 4의 주제를 포함하는데, 위 임계 잡음제거 컴포넌트는 위 임계 값에 기반하여 위 특징 표현을 잡음제거된 특징 표현으로 변환한다.
- [0093] 예 8은 예 7의 주제를 포함하는데, 위 특징 표현을 변환하는 것은, 위 특징 표현의 요소의 절대 값이 위 임계 값 이하인 경우, 위 잡음제거된 특징 표현의 대응하는 요소를 제로로 설정하는 것과, 위 절대 값이 위 임계 값보다 큰 경우, 위 잡음제거된 특징 표현의 위 대응하는 요소를 위 절대 값과 위 임계 값 간의 차이 및 위 특징 표현의 위 요소의 부호(sign)의 곱으로 설정하는 것을 포함한다.
- [0094] 예 9는 예 7 또는 예 8의 주제를 포함하는데, 위 TD는 제2 합성곱 컴포넌트를 더 포함하고, 위 제2 합성곱 컴포넌트는 위 잡음제거된 특징 표현을 처리하여 위 잡음제거된 신호를 생성한다.
- [0095] 예 10은 예 9의 주제를 포함하는데, 위 제1 합성곱 컴포넌트는 정류된 선형 유닛(Rectified Linear Unit: ReLU) 활성화 함수를 가진 제1 합성곱 층을 포함하되, 위 제1 합성곱 층은 각각 크기가 2x3인 16개의 필터를 갖고, 위 제2 합성곱 컴포넌트는 ReLU 활성화 함수를 가진 제2 합성곱 층에 이어서, ReLU 활성화 함수를 가진 제3 합성곱 층을 포함하되, 위 제2 합성곱 층은 각각 크기가 2x3인 32개의 필터를 갖고, 위 제3 합성곱 층은 각각 크기가 2x3인 64개의 필터를 갖는다.

- [0096] 예 11은 예 10의 주제를 포함하는데, 위 TD는 위 입력 신호를 정규화하고 위 정규화된 입력 신호를 위 제1 합성곱 층에 제공하는 배치 정규화(Batch Normalization: BN) 층을 더 포함한다.
- [0097] 예 12는 예 4 내지 예 11 중 임의의 것의 주제를 포함하는데, 위 자동 임계 학습 하위 신경망은 전역 평균 풀링(Global Average Pooling: GAP) 층 및 일련의 후속 층을 포함하고, 위 GAP 층은 위 특징 표현의 각각의 요소의 절대 값을 평균화된 특징(averaged feature)으로 처리하고, 위 평균화된 특징은 위 일련의 후속 층에 전달되고, 위 일련의 후속 층은, 위 사전결정된 범위 내의 위 스케일링된 인자를 출력하도록 활성화 함수를 갖는 전 연결(Fully Connected: FC) 층과, 위 스케일링된 평균 값을 위 평균화된 특징에 위 스케일링 인자가 곱해진 것과 같도록 계산하고 위 스케일링된 평균 값에 기반하여 위 임계 값을 판정하는 임계 판정 층을 포함한다.
- [0098] 예 13은 예 4 내지 예 11 중 임의의 것의 주제를 포함하는데, 위 자동 임계 학습 하위 신경망은 전역 평균 풀링(Global Average Pooling: GAP) 층에 이어서, ReLU 활성화 함수를 가진 선행 전 연결(Fully Connected: FC) 층에 이어서, 개재(intervening) 배치 정규화(Batch Normalization: BN) 층에 이어서, 시그모이드(sigmoid) 활성화 함수를 가진 후속 FC 층에 이어서, 임계 판정 층을 포함하되, 위 GAP 층은 위 특징 표현의 각각의 요소의 절대 값을 평균화된 특징으로 처리하고, 위 평균화된 특징은 위 선행 FC 층 및 위 임계 판정 층 양자 모두에 제공되고, 위 후속 FC 층은 위 사전결정된 범위 내의 위 스케일링된 인자를 출력하되, 위 사전결정된 범위는 0과 1 사이이고, 위 임계 판정 층은 위 스케일링된 평균 값을 위 평균화된 특징에 위 스케일링 인자가 곱해진 것과 같도록 계산하고 위 스케일링된 평균 값에 기반하여 위 임계 값을 판정한다.
- [0099] 예 14는 예 4 내지 예 13 중 임의의 것의 주제를 포함하는데, 위 임계 값은 위 스케일링된 평균 값에 실증적으로 정해진 값(empirically determined value)이 곱해진 것으로서 판정된다.
- [0100] 예 15는 예 14의 주제를 포함하는데, 위 실증적으로 정해진 값은 샘플 신호의 세트에 대해 위 신경망 모델을 구동하여 위 세트 내의 위 샘플 신호의 변조 타입을 분류함으로써 수행된 실험에서 위 신경망 모델에 의해 달성된 분류 정확도에 기반하여 설정되고, 위 세트 내의 위 샘플 신호는 지정된 범위의 레벨의 신호 대 잡음비(Signal-to-Noise Ratio: SNR)를 갖는 다수의 샘플 신호를 포함하고, 위 분류 정확도는 위 세트 내의 위 샘플 신호의 위 분류된 변조 타입의 측정된 정확도이다.
- [0101] 예 16은 예 1 내지 예 15 중 임의의 것의 주제를 포함하는데, 위 RNN 기반 분류기는 위 잡음제거된 신호로부터 맥락 정보를 획득하는 게이팅 층과, 위 획득된 맥락 정보에 기반하여 위 입력 신호의 위 변조 타입의 위 분류를 수행하는 분류 층을 포함한다.
- [0102] 예 17은 예 16의 주제를 포함하는데, 위 게이팅 층은 게이트형 순환 유닛(Gated Recurrent Unit: GRU) 층을 포함한다.
- [0103] 예 18은 예 17의 주제를 포함하는데, 위 GRU 층은 64개의 은닉 유닛을 갖는다.
- [0104] 예 19는 예 16 내지 예 18 중 임의의 것의 주제를 포함하는데, 위 분류 층은 소프트맥스(softmax) 활성화 함수를 가진 최종 전 연결(Fully Connected: FC) 층을 포함한다.
- [0105] 예 20은 예 19의 주제를 포함하는데, 위 최종 FC 층은 출력 크기가 11이다.
- [0106] 예 21에서, 컴퓨터 시스템은, 하드웨어 프로세서와, 딥 러닝(Deep Learning: DL) 기반 자동 변조 분류(Automatic Modulation Classification: AMC)를 위한 신경망 모델을 구현하기 위해 위 하드웨어 프로세서에 의해 실행가능한 컴퓨터 프로그램 명령어가 저장된 메모리 디바이스를 포함하되, 위 신경망 모델은, 미지의 변조 타입을 갖는 입력 신호에 대해 임계 값(threshold value)을 산출하고 위 임계 값에 기반하여 위 입력 신호의 잡음제거(denoising)를 수행하여 잡음제거된 신호를 생성하는 임계 잡음제거기(Threshold Denoiser: TD)와, 위 잡음제거된 신호를 처리하여 위 입력 신호의 위 변조 타입을 복수의 사전결정된 변조 타입 중 하나로 분류하는 순환 신경망(Recurrent Neural Network: RNN) 기반 분류기를 포함한다.
- [0107] 예 22는 예 21의 주제를 포함하는데, 위 잡음제거는 절대 값(absolute value)이 위 임계 값보다 작은 제로 근접 값(near-zero value)을 제로(zero)로 설정하는 잡음제거 함수에 따라 위 입력 신호의 특징(feature)을 잡음제거된 특징으로 변환하는 것을 포함한다.
- [0108] 예 23은 예 22의 주제를 포함하는데, 위 잡음제거 함수는 위 임계 값보다 큰 양수의 범위에 걸쳐 증가하고 절대 값이 위 임계 값보다 큰 음수의 범위에 걸쳐 감소한다.
- [0109] 예 24는 예 21 내지 예 23 중 임의의 것의 주제를 포함하는데, 위 TD는 제1 합성곱 컴포넌트 및 임계 잡음제거

컴포넌트를 포함하고, 위 제1 합성곱 컴포넌트는 위 입력 신호의 특징 표현을 출력하고, 위 임계 잡음제거 컴포넌트는 사전결정된 범위 내의 스케일링 인자(scaling factor)를 산출하고 위 스케일링 인자에 기반하여 위 특징 표현의 스케일링된 평균 값(scaled average value)을 계산하고 위 스케일링된 평균 값에 기반하여 위 임계 값을 판정하는 자동 임계 학습 하위 신경망(sub-neural network)을 포함한다.

- [0110] 예 25는 예 24의 주제를 포함하는데, 위 임계 잡음제거 컴포넌트는 절대 값이 위 임계 값보다 작은 제로 근접 값을 제로로 설정하는 잡음제거 함수에 따라 위 특징 표현의 요소(element)를 잡음제거된 특징으로 변환한다.
- [0111] 예 26은 예 25의 주제를 포함하는데, 위 잡음제거 함수는 위 임계 값보다 큰 양수의 범위에 걸쳐 증가하고 절대 값이 위 임계 값보다 큰 음수의 범위에 걸쳐 감소한다.
- [0112] 예 27은 예 24의 주제를 포함하는데, 위 임계 잡음제거 컴포넌트는 위 임계 값에 기반하여 위 특징 표현을 잡음제거된 특징 표현으로 변환한다.
- [0113] 예 28은 예 27의 주제를 포함하는데, 위 특징 표현을 변환하는 것은, 위 특징 표현의 요소의 절대 값이 위 임계 값 이하인 경우, 위 잡음제거된 특징 표현의 대응하는 요소를 제로로 설정하는 것과, 위 절대 값이 위 임계 값보다 큰 경우, 위 잡음제거된 특징 표현의 위 대응하는 요소를 위 절대 값과 위 임계 값 간의 차이 및 위 특징 표현의 위 요소의 부호(sign)의 곱으로 설정하는 것을 포함한다.
- [0114] 예 29는 예 27 또는 예 28의 주제를 포함하는데, 위 TD는 제2 합성곱 컴포넌트를 더 포함하고, 위 제2 합성곱 컴포넌트는 위 잡음제거된 특징 표현을 처리하여 위 잡음제거된 신호를 생성한다.
- [0115] 예 30은 예 29의 주제를 포함하는데, 위 제1 합성곱 컴포넌트는 정류된 선형 유닛(Rectified Linear Unit: ReLU) 활성화 함수를 가진 제1 합성곱 층을 포함하되, 위 제1 합성곱 층은 각각 크기가 2x3인 16개의 필터를 갖고, 위 제2 합성곱 컴포넌트는 ReLU 활성화 함수를 가진 제2 합성곱 층에 이어서, ReLU 활성화 함수를 가진 제3 합성곱 층을 포함하되, 위 제2 합성곱 층은 각각 크기가 2x3인 32개의 필터를 갖고, 위 제3 합성곱 층은 각각 크기가 2x3인 64개의 필터를 갖는다.
- [0116] 예 31은 예 30의 주제를 포함하는데, 위 TD는 위 입력 신호를 정규화하고 위 정규화된 입력 신호를 위 제1 합성곱 층에 제공하는 배치 정규화(Batch Normalization: BN) 층을 더 포함한다.
- [0117] 예 32는 예 24 내지 예 31 중 임의의 것의 주제를 포함하는데, 위 자동 임계 학습 하위 신경망은 전역 평균 풀링(Global Average Pooling: GAP) 층 및 일련의 후속 층을 포함하고, 위 GAP 층은 위 특징 표현의 각각의 요소의 절대 값을 평균화된 특징(averaged feature)으로 처리하고, 위 평균화된 특징은 위 일련의 후속 층에 전달되고, 위 일련의 후속 층은, 위 사전결정된 범위 내의 위 스케일링된 인자를 출력하도록 활성화 함수를 갖는 전연결(Fully Connected: FC) 층과, 위 스케일링된 평균 값을 위 평균화된 특징에 위 스케일링 인자가 곱해진 것과 같도록 계산하고 위 스케일링된 평균 값에 기반하여 위 임계 값을 판정하는 임계 판정 층을 포함한다.
- [0118] 예 33은 예 24 내지 예 31 중 임의의 것의 주제를 포함하는데, 위 자동 임계 학습 하위 신경망은 전역 평균 풀링(Global Average Pooling: GAP) 층에 이어서, ReLU 활성화 함수를 가진 선행 전연결(Fully Connected: FC) 층에 이어서, 개재(intervening) 배치 정규화(Batch Normalization: BN) 층에 이어서, 시그모이드(sigmoid) 활성화 함수를 가진 후속 FC 층에 이어서, 임계 판정 층을 포함하되, 위 GAP 층은 위 특징 표현의 각각의 요소의 절대 값을 평균화된 특징으로 처리하고, 위 평균화된 특징은 위 선행 FC 층 및 위 임계 판정 층 양자 모두에 제공되고, 위 후속 FC 층은 위 사전결정된 범위 내의 위 스케일링된 인자를 출력하되, 위 사전결정된 범위는 0과 1 사이이고, 위 임계 판정 층은 위 스케일링된 평균 값을 위 평균화된 특징에 위 스케일링 인자가 곱해진 것과 같도록 계산하고 위 스케일링된 평균 값에 기반하여 위 임계 값을 판정한다.
- [0119] 예 34는 예 24 내지 예 33 중 임의의 것의 주제를 포함하는데, 위 임계 값은 위 스케일링된 평균 값에 실증적으로 정해진 값(empirically determined value)이 곱해진 것으로서 판정된다.
- [0120] 예 35는 예 34의 주제를 포함하는데, 위 실증적으로 정해진 값은 샘플 신호의 세트에 대해 위 신경망 모델을 구동하여 위 세트 내의 위 샘플 신호의 변조 타입을 분류함으로써 수행된 실험에서 위 신경망 모델에 의해 달성된 분류 정확도에 기반하여 설정되고, 위 세트 내의 위 샘플 신호는 지정된 범위의 레벨의 신호 대 잡음비(Signal-to-Noise Ratio: SNR)를 갖는 다수의 샘플 신호를 포함하고, 위 분류 정확도는 위 세트 내의 위 샘플 신호의 위 분류된 변조 타입의 측정된 정확도이다.
- [0121] 예 36은 예 21 내지 예 35 중 임의의 것의 주제를 포함하는데, 위 RNN 기반 분류기는 위 잡음제거된 신호로부터 맥락 정보를 획득하는 게이팅 층과, 위 획득된 맥락 정보에 기반하여 위 입력 신호의 위 변조 타입의 위 분류를

수행하는 분류 층을 포함한다.

- [0122] 예 37은 예 36의 주제를 포함하는데, 위 게이팅 층은 게이트형 순환 유닛(Gated Recurrent Unit: GRU) 층을 포함한다.
- [0123] 예 38은 예 37의 주제를 포함하는데, 위 GRU 층은 64개의 은닉 유닛을 갖는다.
- [0124] 예 39는 예 36 내지 예 38 중 임의의 것의 주제를 포함하는데, 위 분류 층은 소프트맥스(softmax) 활성화 함수를 가진 최종 전 연결(Fully Connected: FC) 층을 포함한다.
- [0125] 예 40은 예 39의 주제를 포함하는데, 위 최종 FC 층은 출력 크기가 11이다.
- [0126] 예 41에서, 컴퓨터 프로세서에 의해 실행되는 경우 위 컴퓨터 프로세서로 하여금 예 1 내지 예 20 중 임의의 것에 기재된 방법을 수행하게 하는 컴퓨터 실행가능 명령어가 저장된 컴퓨터 판독가능 저장 매체가 제공된다.
- [0127] 예 42에서, 예 21 내지 예 40 중 임의의 것에 기재된 컴퓨터 시스템을 포함하는 무선 통신 디바이스가 제공된다.
- [0128] 특정한 예에서, 본 문서에서 언급된 장치, 디바이스, 시스템, 머신 등은 임의의 적합한 유형은 컴퓨팅 장치이거나, 이를 포함하거나, 이에 구현될 수 있다. 컴퓨팅 장치는 프로세서 및 프로세서에 의해 판독가능한 컴퓨터 판독가능 저장 매체를 포함할 수 있다. 프로세서는 컴퓨터 판독가능 저장 매체 내에 저장된 하나 이상의 명령어를 실행할 수 있다. 프로세서는 또한 컴퓨터 판독가능 저장 매체 내에 저장된 다른 정보를 판독할 수 있다. 추가로, 프로세서는 컴퓨터 판독가능 저장 매체 내에 새로운 정보를 저장할 수 있고 컴퓨터 판독가능 저장 매체 내에 저장된 어떤 정보를 갱신할 수 있다. 프로세서는, 예컨대, 중앙 처리 유닛(Central Processing Unit: CPU), 디지털 신호 프로세서(Digital Signal Processor: DSP), 그래픽 처리 유닛(Graphics Processing Unit: GPU), 프로세서 코어(processor core), 마이크로프로세서(microprocessor), 마이크로제어기(microcontroller), 필드 프로그램가능 게이트 어레이(Field-Programmable Gate Array: FPGA), 애플리케이션 특정 집적 회로(Application Specific Integrated Circuit: ASIC), 다른 하드웨어 및 로직 회로, 또는 이의 임의의 적합한 조합을 포함할 수 있다. 컴퓨터 판독가능 저장 매체는 다양한 정보, 예컨대, 프로세서에 의해 수행될 수 있는 프로세서 실행가능(processor executable) 명령어의 세트 및/또는 다른 정보로써 인코딩된다. 예를 들어, 컴퓨터 판독가능 저장 매체는 프로세서에 의해 실행되는 경우 컴퓨팅 장치(가령, 프로세서)로 하여금 본 문서에 개시된 몇몇 동작을 수행하게 하는 컴퓨터 프로그램 명령어 및/또는 그러한 동작에서 사용되는 정보, 데이터, 변수, 상수, 데이터 구조, 기타 등등이 내부에 저장될 수 있다. 컴퓨터 판독가능 저장 매체는, 예컨대, 판독 전용 메모리(Read-Only Memory: ROM), 랜덤 액세스 메모리(Random-Access Memory: RAM), 휘발성(volatile) 메모리, 비휘발성(non-volatile) 메모리, 착탈가능(removable) 메모리, 비착탈가능(non-removable) 메모리, 플래시(flash) 메모리, 솔리드 스테이트(solid-state) 메모리, 다른 타입의 메모리 디바이스, 하드 디스크, 플로피 디스크 및 자기 테이프와 같은 자기 매체, CD-ROM, DVD와 같은 광 기록 매체, 플롭티컬 디스크와 같은 자기-광 매체, 다른 타입의 저장 디바이스 및 저장 매체, 또는 이의 임의의 적합한 조합을 포함할 수 있다.
- [0129] 특정한 예에서, 본 문서에 기술된 동작, 기법, 프로세스, 또는 이의 어떤 양상이나 부분은 컴퓨터 프로그램 제품 내에 구체화될 수 있다. 그러한 컴퓨터 프로그램은 컴퓨터에 의해 실행될 수 있는 어떤 유형의 (가령, 컴파일형(compiled) 또는 해석형(interpreted)) 프로그래밍 언어, 예컨대, 어셈블리(assembly), 기계어(machine language), 프로시저형(procedural) 언어, 객체지향(object-oriented) 언어 등등으로 구현될 수 있고, 하드웨어 구현과 조합될 수 있다. 컴퓨터 프로그램 제품은 컴퓨터 판독가능 저장 매체의 형태로 배포될 수 있거나 온라인으로 배포될 수 있다. 온라인 배포를 위해, 컴퓨터 프로그램 제품의 일부 또는 전부가 서버(가령, 서버의 컴퓨터 판독가능 저장 매체) 내에 일시적으로 저장되거나 일시적으로 생성될 수 있다.
- [0130] 이상의 설명은 상세하게 몇몇 예를 제시하고 기술하기 위해 제시되었다. 본 개시의 범주에서 벗어나지 않고서 위의 교시에 비추어 많은 수정 및 변형이 가능함을 당업자는 응당 이해할 것이다. 다양한 예에서, 전술된 기법이 상이한 순서로 수행되고/거나, 전술된 시스템, 아키텍처, 디바이스, 회로 및 유사한 것의 컴포넌트 중 일부가 상이한 방식으로 결합 또는 조합되거나, 다른 컴포넌트 또는 이의 균등물에 의해 대체 또는 치환되더라도 적절한 결과가 달성될 수 있다.
- [0131] 그러므로, 본 개시의 범주는 개시된 그 형태에 한정되어서는 안 되며, 후술하는 청구항 및 이의 균등물에 의해 정해져야 한다.


부호의 설명

[0132]


- 100: 수신기
- 150: 자동 변조 분류부
- 170: 신경망 모델
- 210: 임계 값제거기
- 220: 순환 신경망 기반 분류기

도면


도면1




도면2




도면3




도면4a




도면4b




도면5




도면6



도면7



도면8



도면9

