



고급소프트웨어

논문관련 발표

202271094 최미영

AI for RFID & Modeling based Indoor Recognition

Observation

RFID 기술의 발전으로 가격 하락, 인식률 상승 및 다양한 분야에서의 활용이 가능

RFID 를 활용하는 분야에서의 단점으로는 RSSI 의 세기 정도에 따라, 실내환경에 따라 RFID 의 인식률 및 신호의 세기들이 일정하지 않음

현재 인공지능 분야의 발전은 지속적으로 상승하고 있음

Problem / Definition

물류관리나 재고관리 시스템의 노동생산성이 저하

노동력의 비용 및 관리 비용 상승

모델링을 통해서 실제 테스트 전에 일어날 수 있는 경우의 수를 미리 파악하고 실제 테스트에 적용

발생할 수 있는 가능성들 파악에 용이

인공지능 분야에서의 인공지능망에 관련된 모델링 기법이 아직은 많이 발전하지 않음





AI for RFID based Indoor Localization & Recognition - cont'd

Related papers

- 3DLRA: An RFID 3D Indoor Localization Method Based on Deep Learning
- A Model-Based Approach for RFID Application Testing
- Deep Convolutional Neural Network for Passive RFID Tag Localization Via Joint RSSI and PDOA Fingerprint Features
- Deep Learning for RFID-Based Activity Recognition

URL

- https://en.wikipedia.org/wiki/Message_sequence_chart



AI for RFID based Indoor Localization & Recognition - cont'd

Solution

- RFID 특성파악
- 실내에서 발생가능한 다양한 오류 체크, 환경 분석 및 파악
- 인공지능 분야에서 RFID 에 적합한 신경망 네트워크 선별
- 선별된 네트워크를 통해 제기된 문제들을 적용
- 시나리오케이스를 통한 적용 및 테스트
- 전반적인 RFID 사용부터 AI 신경망 사용 부분까지 MSC(Message Sequence Chart) 적용

AI for RFID based Indoor Localization & Recognition - cont'd

Demonstration

RFID 의 특성을 파악하여 RFID 입력 데이터를 인공지능을 통해 분석하고 그를 통해서 정확도를 측정

측정된 데이터의 정확도를 분석

MSC 를 활용한 내용을 실제에서 어느정도 잘 적용되고 있는지, 예외 상황 부분은 없는지 측정

예) RFID 적용부분, AI 신경망 설계 부분 등


RFID (Radio Frequency Identification)



- 무선인식장치이다.
- 반도체 칩이 내장된 태그(Tag), 라벨(Label), 카드(Card) 등의 저장된 데이터를 무선주파수를 이용하여 비접촉으로 읽어내는 인식시스템이다.
- RFID 태그는 전원을 필요로 하는 능동형(Active 형)과 리더기의 전자기장에 의해 작동되는 수동형(Passive 형)으로 나뉜다.
- Active 타입은 리더기의 필요전력을 줄이고 리더기와의 인식거리를 멀리할 수 있다는 장점이 있다.
- 전원공급장치를 필요로 하기 때문에 작동시간의 제한을 받으며 Passive 형에 비해 고가인 단점이 있다.
- Passive 형은 Active 형에 비해 매우 가볍고 가격도 저렴하면서 반영구적으로 사용이 가능하다.
- 인식거리가 짧고 리더기에서 훨씬 더 많은 전력을 소모한다는 단점이 있다.

Sequence-to-sequence modeling for graph representation learning

- <https://appliednetsci.springeropen.com/track/pdf/10.1007/s41109-019-0174-8.pdf>





OPTIMIZING GRAPH NEURAL NETWORKS WITH MESSAGE PASSING DATA FLOW GRAPH

- <https://proceedings.mlsys.org/paper/2022/file/a87ff679a2f3e71d9181a67b7542122c-Paper.pdf>

```

1 def message_gat(edges):
2     # equation (1)
3     z_src, z_dst = edges.src['h'] @ W, edges.dst['h'] @ W
4     # equation (2)
5     e = leaky_relu(concat(z_src, z_dst, dim=1) @ W_att)
6     return {'m': z_src, 'e': e}
7
8 def message_hgt(edges):
9     # equation (3)
10    k = batch_mm(edges.src['h'], edges.srctype['hk'])
11    q = batch_mm(edges.dst['h'], edges.dsttype['Wq'])
12    v = batch_mm(edges.src['h'], edges.srctype['Wv'])
13    # equation (4)
14    m = batch_mm(v, edges.type['W_msg'])
15    # equation (5)
16    e = sum(batch_mm(k, edges.type['W_att']) * q, dim=1)
17    return {'m': m, 'e': e}
18
19 def aggregate_func(nodes):
20     # equation (6)
21     alpha = softmax(nodes.mailbox['e'], dim=1)
22     # equation (7)
23     r = sum(alpha * nodes.mailbox['m'], dim=1)
24     return {'r': r}
25

```



(a)

(b)

OPTIMIZING GRAPH NEURAL NETWORKS WITH MESSAGE PASSING DATA FLOW GRAPH - cont'd

- <https://proceedings.mlsys.org/paper/2022/file/a87ff679a2f3e71d9181a67b7542122c-Paper.pdf>





Table 1: Inference rules of data residency.

Op/API	Loc of Call	Data Movement
edges.data	Msg Creation	Fetch data : D_E
edges.src	Msg Creation	Broadcast _{src} : $D_V \rightarrow D_E$
edges.dst	Msg Creation	Broadcast _{dst} : $D_V \rightarrow D_E$
edges.srcType	Msg Creation	Broadcast _{src} : $D_A \rightarrow D_E$
edges.dstType	Msg Creation	Broadcast _{dst} : $D_A \rightarrow D_E$
edges.type	Msg Creation	Broadcast : $D_R \rightarrow D_E$
nodes.mailbox	Msg Aggr.	Fetch data : D_E
nodes.data	Msg Aggr. / Feat. Update	Fetch data : D_V
nodes.type	Msg Aggr. / Feat. Update	Broadcast : $D_A \rightarrow D_V$
sum, max, ... with dim=1	Msg Aggr.	Reduce : $D_E \rightarrow D_V$
softmax, ... with dim=1	Msg Aggr.	Norm : $D_E \rightarrow D_E$
Other tensor ops	Anywhere	Dense : §4.1



Related Papers

3DLRA: An RFID 3D Indoor Localization Method Based on Deep Learning

3DLRA: 딥러닝 기반 RFID 3D 실내 측위 방법

Abstract

사물인터넷의 핵심 지원기술인 RFID(Radio Frequency Identification) 기술은 지능형 운송, 물류관리, 산업자동화 등의 분야에서 빠르게 대중화되고 있으며, 빠른 속도와 빠른 처리 속도 때문에 발전 잠재력이 크다. 효율적인 데이터 수집 능력. RFID 기술은 3차원 측위가 보다 실제적이고 구체적인 목표 위치 정보를 얻을 수 있는 실내 측위 분야에서 널리 사용된다.

본 논문에서는 기존의 RFID 기반 3차원 측위 방식을 목표로 딥러닝 기반의 새로운 3차원 측위 방법을 제안한다. 심층 학습을 통해 데이터 특성을 추가로 마이닝하고 이 방법을 스마트 라이브러리 장면에 적용한다.

실험 결과는 3DLRA라는 기법이 더 높은 위치 정확도와 더 나은 시스템 안정성을 가지고 있음을 보여준다.

실험에서는 태그의 RSSI, Phase, Timestamp를 입력 데이터로 사용하여 추출

실험 모형은 스마트 도서관 - 책장과 RFID 태그 및 안테나 사용

안테나와 태그 시퀀스 사이의 거리, 사람의 이동 속도, 안테나 높이를 달리하여 실험함

3DLRA: An RFID 3D Indoor Localization Method Based on Deep Learning

3DLRA: 딥러닝 기반 RFID 3D 실내 측위 방법

Problem

RFID 실내 측위 방식

1차원 절대 또는 상대 측위



- 대상 물체의 절대 위치 또는 상대 위치 관계를 얻을 수 있으며 조립 라인 상황에서 물품의 관리 및 기록에 적합
- 실내 환경에서는 목표물체의 위치가 변하기 때문에 상대 측위 방식은 일반적으로 목표물체의 위치 정보에 의해 결정

2차원 평면 측위

- 거리 측위와 비거리 측위로 구분

3차원 공간 측위

- 표적의 공간적 위치 정보를 얻을 수 있어 실내 항법 기술의 발전에 이롭고 사람들의 삶을 더 편리하게 만든다.
- 3차원 공간 측위의 연구가 활발



3DLRA: An RFID 3D Indoor Localization Method Based on Deep Learning

3DLRA: 딥러닝 기반 RFID 3D 실내 측위 방법

Conclusion

본 논문에서는 일종의 RFID 3차원 측위 기법을 제안한다. (3DLRA)

시스템은 상대 위치 지정과 절대 위치 지정을 결합하고 딥 러닝 기술을 사용하며 태그의 RSSI, 위상 및 타임스탬프를 사용하여 모델을 훈련하여 최종적으로 더 나은 위치 결정 결과를 얻는다.

실험적 검증을 통해 포지셔닝 모델의 안정성이 좋고 실제 시나리오에 적용할 수 있다.

시스템의 개발 전망은 많은 실내 측위 환경에서 널리 사용될 수 있다.

이동 안테나가 필요하지 않으므로 인력과 비용을 절약

절대 위치 지정 및 상대 위치 지정과 함께 딥 러닝 기술을 사용하여 데이터 기능을 추가로 마이닝하여 더 높은 위치 정확도를 얻음

RFID Positioning Method	3D Positioning	No Need to Move the Antenna	Combining Deep Learning	High Accuracy of Positioning
PRDL [6]			✓	✓
HMRL [7]		✓		✓
LANDMARC [9]				✓
ANTspin [12]	✓		✓	✓
Active-Passive [20]	✓			✓
VLM [17]	✓	✓		✓
3DLRA	✓	✓	✓	✓

A Model-Based Approach for RFID Application Testing

RFID 애플리케이션 테스트를 위한 모델 기반 접근 방식

Abstract





무선 주파수 식별 응용 프로그램을 테스트하기 위한 새로운 접근 방식을 제시

RFID 응용 프로그램을 설명하기 위해 집합 기반 의미론이 도입

UML을 사용하여 테스트 중인 시스템의 특성을 모델링

도메인 모델, 이동 모델 및 프로세스 모델로 구성된 세 가지 모델 유형의 조합을 통해 테스트 케이스를 추출하고 테스트 중인 애플리케이션의 기능적 측면을 평가

이 모델 기반 테스트 접근 방식은 의류 소매점 프로세스의 사례 연구에서 검증



A Model-Based Approach for RFID Application Testing

RFID 애플리케이션 테스트를 위한 모델 기반 접근 방식

Problem

RFID(Radio Frequency Identification)는 가시선 없이 물체를 식별할 수 있는 프로세스 자동화 및 그 이상을 위한 유망한 기술이다
물체를 자동으로 식별하려는 경향은 고품질 RFID 애플리케이션에 대한 요구도 증가한다.

RFID 시스템에 대한 테스트에 대한 연구가 가속화되고 있으며 테스트를 위한 체계적인 접근이 필요하다.

RFID 애플리케이션 테스트를 위한 새로운 접근 방식은 UML(Unified Modeling Language) 모델을 기반한다.

도메인별 용어, 이동 패턴 및 RFID 관련 비즈니스 프로세스를 나타낼 수 있는 세 가지 유형의 모델을 설명한다.

- UML 클래스 다이어그램은 도메인 모델
- 테스트 중인 애플리케이션의 동작과 비즈니스 프로세스를 설명하는 UML 상태 다이어그램의 형태로 프로세스 모델에 사용
- Movement Model이라는 UML 상태 다이어그램은 RFID 태그가 이동할 수 있는 가능한 경로와 타이밍 순서에 대한 정보를 제공

A Model-Based Approach for RFID Application Testing

RFID 애플리케이션 테스트를 위한 모델 기반 접근 방식

Conclusion

실험된 RFID 데이터를 가상으로 적용할 모델의 입력 데이터로 사용

의류 소매점의 사례 연구를 소개하여 논문의 접근 방식을 평가

UML 상태 다이어그램인 이동 모델에는 RFID 태그가 따라 이동할 수 있는 모든 경로가 포함

UML을 사용하여 모호성이 최소화되므로 테스트 케이스를 구축하는 노력이 줄어든다.

모델 추출 결과를 실행할 수 있는 가상 RFID 프레임워크를 사용하여 테스트 설정 비용을 절감

사용 가능한 가상 리더와 함께 모델을 사용하여 테스트 사례를 구축하면 테스트 생성 속도가 빨라지고 초기 개발 단계에서도 개발 및 테스트 주기가 빨라진다.

RFID 응용 프로그램에 대한 기능 테스트 기술을 소개

복잡성을 줄이기 위해 관심 분리 원칙을 사용

UML 다이어그램은 RFID 애플리케이션의 측면을 지정하는 데 사용

테스트 케이스의 생성은 UML과 RFID 애플리케이션을 지정하는 세트 기반 의미를 기반으로 한다.

RFID 리더가 모니터링하는 영역에서 RFID 태그의 존재는 시간 기반 세트로 모델링할 수 있다.

테스트 케이스를 구축하기 위해 모델을 사용하여 RFID 애플리케이션 테스트를 위한 노력. 또한 즉시 사용 가능한 가상 리더와 함께 테스트 생성 속도를 높이고 초기 개발 단계에서도 개발 및 테스트 주기를 단축할 수 있다.

Deep Convolutional Neural Network for Passive RFID Tag Localization Via Joint RSSI and PDOA Fingerprint Features

공동 RSSI 및 PDOA 지문 기능을 통한 수동 RFID 태그 위치 파악을 위한 심층 컨볼루션 신경망

Abstract

RFID 로컬라이제이션에 대한 딥 러닝은 많은 이점이 있다.

RSSI(Received Signal Strength Indication)와 PDOA(Phase Difference of Arrival)의 공동 지문 기능을 활용하여 수동 RFID 태그 위치 파악을 위한 CNN(Deep Convolutional Neural Network) 기반 접근 방식을 제시

- RFID 리더기로부터 수신된 신호로부터 RSSI와 PDOA 데이터를 추출
- 3개의 컨볼루션 레이어와 풀링 레이어가 있는 CNN을 설계하고 정규화된 RSSI 및 PDOA 데이터를 입력으로 이미지로 형성하여 오프라인 단계에서 가중치를 훈련
- 온라인 단계에서는 테스트 태그의 RSSI 및 PDOA 데이터를 수집하고 설계된 CNN을 기반으로 알려지지 않은 태그의 위치를 예측
- 위치 정확도가 분석
- 복잡한 실내 환경에서 높은 정확도와 안정성으로 여러 태그를 찾을 수 있으며 기존의 다른 방식보다 성능이 뛰어나다.
- 오프라인단계에서는 지문 데이터의 특징과 훈련 매개변수는 신경망 모델을 구축하여 깊이 학습되므로 CNN은 데이터를 심층적으로 학습하고 복잡한 실내 전자파 간섭 환경에 잘 적응
- phase difference of arrival (PDOA)

Deep Convolutional Neural Network for Passive RFID Tag Localization Via Joint RSSI and PDOA Fingerprint Features

공동 RSSI 및 PDOA 지문 기능을 통한 수동 RFID 태그 위치 파악을 위한 심층 컨볼루션 신경망




Problem

기존의 범위 기반 기술보다 측량 데이터를 더 잘 활용할 수 있음에도 불구하고 데이터를 충분히 활용하고 IoT 장치에 대량으로 배치된 RFID 태그를 현지화하는 데 많은 제한이 있다.

데이터 세트에는 필연적으로 노이즈가 존재하는데, 이는 데이터에 대한 딥 러닝을 수행할 수 없기 때문에 이러한 전통적인 지문 기반 알고리즘으로 잘 처리되지 않는다. 포지셔닝 정확도는 더 이상 향상될 수 없다.

RFID 실내 위치 파악에 대한 응용 프로그램과 함께 딥 러닝에 대해 설명한다.

포지셔닝 모델을 단순화하기 위해 대규모 RFID 태그로 인해 발생하는 신호 다중화 및 리소스 스케줄링 문제를 무시한다.



Deep Convolutional Neural Network for Passive RFID Tag Localization Via Joint RSSI and PDOA Fingerprint Features

공동 RSSI 및 PDOA 지문 기능을 통한 수동 RFID 태그 위치 파악을 위한 심층 컨볼루션 신경망

Conclusion

RSSI와 PDOA의 공동 지문 특성을 활용하여 수동 RFID 태그 위치 파악을 위한 심층 CNN 기반 접근 방식을 제안한다.

RSSI 및 PDOA 데이터는 RFID 리더와 태그를 배열하여 수집되고 정규화된다.

오프라인 단계에서는 3개의 컨볼루션 레이어와 풀링 레이어가 있는 CNN을 사용하여 정규화된 데이터의 특성을 깊이 학습하고 BP 알고리즘을 사용하여 네트워크 매개변수를 최적화한다.

온라인 테스트 단계에서 훈련된 CNN 모델을 사용하여 테스트 데이터의 확률 분포를 출력하고 greedy 방법과 결합하여 정확도를 높인다.

CNN 기반 접근 방식의 포지셔닝 효과는 세 가지 유형의 데이터 세트에 의해 검증되었다.

딥 러닝 기반 접근 방식이 기존의 지문 기반 방식보다 우수하고 복잡한 실내 환경에서 RFID 태그 위치 파악에 더 적합함을 보여준다.

* back propagation algorithm (BP)

Deep Learning for RFID-Based Activity Recognition

RFID 기반 활동 인식을 위한 딥 러닝

Abstract

심층 컨볼루션 신경망을 사용하여 수동 RFID 데이터에서 활동 인식을 위한 시스템을 제시

RFID 데이터에서 객체 사용을 먼저 감지한 다음 활동을 예측하는 캐스케이드 구조를 사용하는 대신 활동 인식을 위해 RFID 데이터를 심층 컨볼루션 신경망에 직접 제공
14시간의 RFID 데이터를 포함하여 외상실에서 수집된 RFID 데이터를 사용하여 시스템을 테스트

RFID 데이터에서 활동 인식을 위한 현재 딥 러닝 아키텍처의 강점과 한계를 분석

Deep Learning for RFID-Based Activity Recognition

RFID 기반 활동 인식을 위한 딥 러닝

Problem

활동 인식에 사용되어 어느 정도 성공을 거두었지만 RFID 기반 활동 인식은 감지된 RFID 데이터가 제공하는 정보가 제한적이다.

카메라 기반 솔루션이 개인 정보 보호 문제로 제한되고 웨어러블 센서 기반 솔루션이 착용하기 불편하고 작업을 방해할 수 있는 의료 애플리케이션과 같이 다른 센서가 적합하지 않은 일부 애플리케이션 시나리오에서 활동 인식에 사용

RFID 기반 시스템은 빠르게 진행되고 혼잡한 환경에서 높은 정확도의 활동 인식을 달성하는 데 실패

RFID 기반 활동 인식의 두 가지 주요 과제는 필터링할 수 없는 RSS(수신 신호 강도)의 잡음과 원시 RSS 값과 인간 활동(추상적인 개념) 간의 직접적인 연결 부재 대규모 이미지 분류를 위한 컴퓨터 비전과 시끄러운 환경에서 음성을 텍스트로 변환하기 위한 음성 인식에도 유사한 문제이다.

딥러닝의 도입은 높은 수준의 성능을 달성했다.

수동형 RFID만을 사용하여 빠르게 변화하는 실제 환경에서의 활동 인식 문제에 딥러닝을 적용

Deep Learning for RFID-Based Activity Recognition

RFID 기반 활동 인식을 위한 딥 러닝

Conclusion



본 논문에서는 수동형 RFID 데이터를 기반으로 한 복잡한 팀워크 활동을 위한 딥 러닝 시스템을 제시

제조된 기능과 일련의 물체 사용 감지 및 활동 인식에 의존하는 기존 시스템과 달리 당사 시스템은 RFID 데이터와 직접 작동하며 작업 활동 또는 프로세스 단계의 다중 클래스 분류를 생성

딥 러닝 접근 방식은 일반적으로 새로운 분류자를 추가하지 않고 새로운 활동을 포함하도록 확장 가능한 확장을 지원

수동형 RFID 를 기반으로 하는 활동 인식을 위한 딥러닝의 힘을 보여주었다.

데이터 수집에 특별한 장비나 사람의 협력이 필요하지 않다는 장점이 있다.



Process phase detection system	Acc.	Pre.	Rec.	F-S
Automatic phase detection from low-level surgical activities [10]	n/a	0.75	0.74	0.74
Modeling and online recognition of surgical phases using hidden Markov models [36]	83%	n/a	n/a	n/a
Phase recognition during surgical procedures using embedded and body-worn sensors [15]	77%	n/a	n/a	n/a
Our deep learning network	72%	0.63	0.70	0.65

Thank you