

- D1.1 스마트시티 거버넌스 체계 및 프레임워크 개발 - 한국건설기술연구원, 가천대학교
D1.2 통합플랫폼 등 공공서비스 표준화 및 표준 인덱스 개발 연구 - 스마트도시협회, 성균관대학교
D1.3 스마트시티 포트폴리오-프로그램-프로젝트 프로세스 표준화 - 한양대학교
D1.4 스마트시티 데이터 상호운용성 확보 및 가이드라인 정립 - 한국정보통신기술협회
D2.1 스마트교통-에너지 연계분야 표준지침개발 - 한국지능형교통체계협회, 한국교통대학교, 홍익대학교, 한국전기연구원
D2.2 스마트에너지-빌딩 연계분야 표준지침개발 - 스마트에너지협회, 한국기계전기전자시험연구원
D2.3 스마트시티 공간정보 분야 표준지침개발 - 한국정보통신기술협회, 안양대학교
D2.4 스마트 ICT분야 표준지침개발 - 한국전자기술연구원, 연세대학교
D3.1 스마트시티 표준화 역량강화 프로그램 - 한국정보통신기술협회, 영국왕립표준협회(BSI)
D3.2 스마트시티 품질 평가체계 구축 및 인증 - 한국정보통신기술협회, 영국왕립표준협회(BSI)
D3.3 스마트시티 국제표준화를 위한 협력프로그램 - 한국정보통신기술협회, 영국왕립표준협회(BSI)

**STRATEGIC PLANNING
GOVERNANCE**
스마트시티 표준화 전략 및
체계 구축

**TECHNOLOGY
STANDARDS**
스마트시티 도메인별 기술표준 및
서비스 시험표준 개발

스마트시티 표준화역량개발
및 국제협력
**CAPABILITY
DEVELOPMENT**

KAIA KOREA AGENCY FOR INFRASTRUCTURE TECHNOLOGY ADVANCEMENT

SMART CITY STANDARDS

SMART BUILDING

Leveraging Machine Learning and Big Data for Smart Buildings

Machine Learning

Basheer Oloomany, Graduate Student Member, IEEE, Ala Al-Fuqaha, Senior Member, IEEE, Ajay Gupta, Senior Member, IEEE, Driss Benhaddou, Member, IEEE, Safaa Alwardy, Junaid Qadir, Senior Member, IEEE, Alvis C. Fong, Senior Member, IEEE

+ Big Data

A Comprehensive Survey

Leveraging Machine Learning and Big Data for Smart Buildings: A Comprehensive Survey

SMART BUILDING



ISSUE
05

AUG 2021



SMART BUILDINGS SMART HOMES 5

23 NETWORKING AND HOME GATEWAY

네트워킹 및 홈 게이트웨이



Technical Standards
for Smart Cities
스마트시티 국제표준화
기반조성(R&D)

CONTENT

7. SB TRENDS AND MARKET IMPACT

스마트 빌딩 동향 및 시장 영향
관련 연구 논문 조사

12. SMART BUILDINGS: CONCEPT AND ARCHITECTURE

스마트 빌딩: 개념 및 아키텍처

19. SMART BUILDING COMPONENTS

스마트 빌딩 컴포넌트

21. SMART CONTROL DEVICES

스마트 컨트롤 디바이스

25 SOFTWARE PLATFORM

소프트웨어 플랫폼



Technical Standards
for Smart Cities
스마트시티 국제표준화
기반조성(R&D)



Illusion never changed into something
real. It's wide awake and ready to go.

SB LEVERAGING MACHINE LEARNING AND BIG DATA FOR SMART BUILDINGS



54 OPEN ISSUES AND FUTURE RESEARCH DIRECTIONS

오픈 이슈 및 향후 연구 방향

27. ML BACKGROUND FOR SBS: MODELS, TASKS, AND TOOLS

스마트 빌딩의 머신 러닝 배경: 모델, 테스크 및 툴

35. ML TASKS FOR SBS

스마트 빌딩을 위한 머신러닝 테스크

39. ML TOOLS & PLATFORMS FOR SBS

스마트 빌딩을 위한 머신러닝 툴 및 플랫폼

41. REAL-TIME BIG DATA ANALYTICS TOOLS FOR SBS

스마트 빌딩을 위한 실시간 빅데이터 분석 툴

45 APPLICATIONS OF ML-BASED CONTEXT-AWARE SYSTEMS FOR SBS

스마트 빌딩을 위한 머신러닝 기반 상황 인식 시스템의 적용



Technical Standards
for Smart Cities
스마트시티 국제표준화
기반조성(R&D)

INTRODUCTION



미래의 건물은 거주자에게 새로운 편리함, 편안함 및 효율성의 가능성을 제공할 것이다. 기술이 사람들의 삶에 관여하고 정보 처리가 일상 생활 활동과 대상에 완전히 통합됨에 따라 사람들의 생활 방식에 변화가 생길 것이다. 스마트 빌딩에 대한 미래의 기대에는 거주자의 경험을 최대한 쉽고 편안하게 만드는 것이 포함된다. 스마트 빌딩의 가전제품 및 기기에서 생성, 수집되는 방대한 스트리밍 데이터에는 적시에 조치를 취하고 더 나은 의사결정을 내리기 위해 캐내야 하는 중요한 정보가


포함되어 있다. 머신러닝과 빅데이터 분석은 의심할 여지없이 이러한 스마트 서비스를 제공하는 데 중요한 역할을 할 것이다. 이번 이슈 리포트에서는 Leveraging Machine Learning and Big Data for Smart Buildings: A Comprehensive Survey를 바탕으로 머신러닝 및 빅데이터 분석 기술의 역할을 중심으로 스마트 빌딩 영역을 기술했다. 또한, 스마트 빌딩 서비스 개발에서 직면한 현재 동향과 과제를 검토했다.

의 가능성을 높여줄 것이며, 이제는 가정의 전자제품에서 꽃병에 이르는 모든 기본 건물 편의시설과 생필품이 상호 연결되고 있다. 그러나 이러한 초연결성은 스마트 빌딩 매니지먼트 프로세스를 복잡하게 만든다. 특히 스마트 빌딩과 거주자는 대량의 스트리밍 데이터를 생성할 것으로 예상된다. 머신러닝, 샘플링, 압축, 학습 및 필터링 기술은 개인의 빅데이터 스트림을 관리하는 데 더욱 중요해지고 있다. 1981년에 지능형 빌딩(Intelligent Building, IB)는 미국 United Technology Building Systems (UTBS)에 의해 처음 만들어졌다. 1983년 7월, IB는 미국 코네티컷주 하트포드의 시티 플레이스 빌딩이 문을 열면서 현실이 되었다[1]. 오늘날, 스마트 빌딩의 수는 스마트 오피스, 스마트 호스피탈리티(Smart Hospitality), 스마트 교육 퍼실리티 등을 포함하여 전례없는 속도로 증가하고 있다[2].

Smart buildings ‘스마트 빌딩(Smart Building, SB)’이라는 용어는 용어가 공상과학 영화에 나오는 가상의 스마트 공간을 떠올리게 할 수 있지만, 현실은 오늘날 스마트 빌딩이 존재하고, 그 수는 점점 증가하고 있다. 최근 머신러닝(Machine Learning, ML), 빅데이터 분석, 센서 기술 및 사물인터넷(IoT)의 발전에 따라 최소한의 인프라 변경으로 일반 건물을 비용 효율적으로 스마트 빌딩으로 전환할 수 있다. 이에 따라 스마트 오피스, 스마트 도서관, 스마트 홈, 스마트 건강 매니지먼트 시설, 스마트 병원 및 기타 많은 유형의 스마트 빌딩이 있으며, 이는 많은 부가가치 서비스(예를 들면 에너지 낭비 감소)를 제공하고 거주자의 편안함, 건강 및 안전을 보장하는 데 도움이 될 수 있다. IoT의 등장으로 인해 발생할 초연결성은 스마트 빌딩

스마트 빌딩(Smart Building)
스마트 홈(Smart Home)
사물 인터넷(Internet of Things, IoT)
빅데이터 분석(Big Data Analytics)
머신러닝(Machine learning, ML)

SMART BUILDING




SMART BUILDING (SB)

스마트 빌딩은 다양한 컴퓨팅 및 통신 인프라와 기술을 활용하는 통합 시스템으로 인정받고 있다 [3]. 스마트 빌딩 서비스의 예로는 수동 구성을 최소화하거나 아예 사용하지 않고 하루/년 중 시간과 사용자의 선호도에 따라 온도를 제어할 수 있는 스마트 온도조절기가 있다. 적절한 조치를 취하기 전에 데이터 분석을 실시하여 사용자의 선호도를 ‘학습’하는 것이 IB를 위한 가장 중요한 활성화 기술이다[4]. 최근에는 사용자의 선호도와 일정에 따라 자동으로 커피를 만들 수 있는 스마트 커피 머신이 시장에 등장했다. 냉장고는 제어를 위해 할당된 프로그래밍 인터페이스를 제공할 수 있다[5]. IB는 사용자에게 안전하고 에너지 효율적이며 환경 친화적이며 편리한 서비스를 제공하는 것을 목표로 한다.

INTELLIGENT BUILDINGS (IB)

편안함을 극대화하고 비용을 최소화하며 주민들의 요구에 적응하기 위해 스마트 빌딩은 정교한 틀에 의존하여 학습하고 예측하며 지능적인 결정을 내려야 한다. 스마트 빌딩 알고리즘은 예측, 의사결정, 로봇공학, 무선 센서 네트워크, 멀티미디어, 모바일 컴퓨팅, 클라우드 컴퓨팅을 포함한 다양한 기술을 포함한다. 이러한 기술을 통해 건물은 보안, 개인 정보 보호, 에너지 효율성, 조명, 유지 관리, 노인 돌봄 및 멀티미디어 엔터테인먼트와 같은 많은 스마트 빌딩 서비스를 인지적으로 관리할 수 있다.



SENSORY DATA

센서와 기기에서 수집된 방대한 양의 감지 데이터를 알고리즘으로 분석하여 정보로 변환하고 지식을 추출하여 기계가 환경보다 인간을 더 잘 이해할 수 있도록 만들어야 한다. 또한 가장 중요한 것은 이러한 지식이 우리의 삶을 획기적으로 변화시킬 수 있는 새로운 제품과 서비스로 이어질 수 있다는 것이다. 예를 들어, 스마트 미터의 판독 값을 사용하여 전력 사용량을 더 잘 예측하고 균형을 맞출 수 있다. 환자에게 부착된 웨어러블(Wearable) 센서의 감각 데이터를 모니터링하고 처리하면 새로운 원격 의료 서비스를 생성할 수 있다.

MACHINE LEARNING (ML)

머신러닝의 기본 철학은 알고리즘이 사용 가능한 데이터에서 지속적으로 학습할 수 있도록 분석 모델을 자동으로 생성하는 것이다. 머신러닝 기술의 적용 분야는 방대한 양의 복잡한 데이터의 가용성과 현재 머신러닝 툴의 사용 편의성이 향상됨에 따라 지난 20년 동안 확대되었다. 오늘날 머신러닝은 이미 온라인 서비스(예를 들면 Amazon, Netflix)에서 제공하는 추천 시스템과 은행에서 사용하는 자동 신용 평가 서비스 등 다양한 적용 분야에 광범위하게 적용되고 있다. 알파벳(Alphabet)의 네스트(Nest) 온도조절기는 머신러닝을 사용하여 사용자의 온도 선호도를 ‘학습’하고 작업 일정에 적응하여 에너지 사용을 최소화한다. 머신러닝 적용 분야의 널리 알려진 다른 예로는 구글의 자율주행차, 아마존과 트위터 데이터의 감성 분석, 사용자가 업로드한 이미지에 추천인을 태그하는 데 사용되는 페이스북의 얼굴 인식 기술이 있다.



Nest | Create a Connected Home
<https://nest.com/>

The SB market is estimated to grow from 7.42 billion dollars in 2017 to 31.74 billion dollars by 2022, at a Compound Annual Growth Rate (CAGR) of 33.7% from 2017 to 2022.

A. SB Trends and Market Impact

스마트 빌딩 동향 및 시장 영향
여기에서는 스마트 빌딩 관련 통계를 살펴볼 수 있고, 스마트 빌딩에 대한 산업시장 동향과 학술 연구의 현재 동향과 동기를 이해할 수 있다. MarketsandMarket[6]의 보고서에 따르면 스마트 빌딩 시장은 2017년 74억 2000만 달러에서 2022년 317억 4000만 달러로 2017~2022년 연평균 성장률(CAGR) 33.7% 성장할 것으로 예상된다. 또 다른 보고서인 Zion Market Research[7]에서는 2016년에서 2024년까지 61.9억 달러에 이를 것으로 예상된다.

2017년과 2024년 사이에 34% 이상의 CAGR을 보일 것으로 예상된다. 시장은 주로 스마트 빌딩 프로젝트에 대한 전세계 정부 이니셔티브와 통합 보안 및 안전 시스템과 에너지 효율적인 빌딩 시스템에 대한 시장 증가에 의해 주도된다. [그림 1]은 Statista[8]의 2016~2022년 세계 스마트 홈 시장 규모를 예상 시장 규모를 보여준다(단위: 10억 달러).

Gartner 보고서[9]에 따르면 스마트 커넥티드 홈(Connected Home)의 수는 2020년까지 7억 가수로 증가할 것으로 예상되며, 이는 대규모 소비자의 채택과 사용 가능한 기기와 애플리케이션 수의 증가로 인해 공급될 것으로 예상된다. [그림 2]는 딥러닝, 머신러닝, 커넥티드 홈, 스마트 워크스페이스(Smart Workspace)에 대한 Gartner의 2018년 하이프 사이클(Hype Cycle) 기대치를 보여준다.

Research and Markets [10][11]의 보고서에 따르면, 글로벌 IoT 스마트 빌딩 시장은 2023년까지 전세계적으로 약 514.4억 달러에 이를 것이다. 이 보고서는 또한 IoT 스마트 빌딩 시장의 33%가 2023년까지 인공지능 기술을 통해 공급되고, 스마트 빌딩의 자동화 시스템은 2018~2023년에 CAGR 48.3% 성장할 것으로 전망했다.

Frost & Sullivan은 2025년까지 커넥티드 홈 리빙(Connected Home Living)의 성장 규모가 개인 간 연결측면(Connected Person World)에서 스마트폰 37억대, 태블릿 7억대, 웨어러블 건강 관련 기기 5억 2000만대, 스마트 기기 4억 1000만대에 이를 것으로 전망했다.

B. Related Survey Papers

관련 연구 논문 조사

스마트 빌딩에 초점을 맞춘 많은 조사 논문이 발표되었지만 스마트 빌딩의 맥락에서 데이터 분석 및 머신러닝의 역할에 초점을 맞춘 조사 논문은 거의 없었다. 다음으로 관련 조사 논문을 설명하고 이러한 조사 논문과 본 논문을 표 II에서 비교할 것이다. 2008년에 Chan 등은 스마트 홈 연구에 대한 개요를 제공했다[12]. 또한 어시스턴트 로봇과 웨어러블 기기에 대해서도 설명했다. 이 리포트는 국가별 및 대륙별로 정렬된 스마트 홈 프로젝트를 검토했다. Alam 등 [13]은 스마트 홈에서 사용되는 센서, 장치, 알고리즘 및 통신 프로토콜에 대한 세부 정보를 제공했다. 또한, 이 리포트에서는 원하는 서비스 및 연구 목표, 즉 보안, 편안함 및 건강 관리에 따라 스마트 홈 작업을 검토했다.

Lobaccaro 등 [14]은 스마트 홈 및 스마트 그리드 기술의 개념을 제시하고 스마트 홈 기술의 몇 가지 과제, 이점 및 향후 동향에 대해 논의하였다. Pan 등 [15]은 마이크로그리드를 사용한 스마트 빌딩의 효율적인 에너지 소비에 대한 작업을 검토하였다.




Fig. 1: Forecast market size of the global smart home market from 2016 to 2022 [8]

2016년부터 2022년까지 전세계 스마트 홈 시장 규모 예측[8]

GLOBAL SMART HOME MARKET SIZE 2016-2022 GARTNER HYPE CYCLE RESEARCH METHODOLOGY




Fig. 2: Hype Cycle for the Connected Home, 2018 [7].

커넥티드 홈에 대한 하이프 사이클 주기, 2018 [7].

TABLE I: LIST OF IMPORTANT ACRONYMS USED

사용된 중요 약어 목록.

AAL	Ambient Assisted Living	LANs	Local Area Networks
ANNs	Artificial Neural Networks	LCR	Lighting Control and Reduction
AODE	One-Dependence Estimators	LDA	Linear Discriminant Analysis
APAC	Asia and Pacific	LOESS	Locally Estimated Scatterplot Smoothing
AR	Accuracy Rate	LoT	Lab of Things
BBN	Bayesian Belief Network	MARS	Multivariate Adaptive Regression Splines
BT-LE	Bluetooth Low Energy	M-Bus	Meter-Bus
CAGR	Compound Annual Growth Rate	MISs	Management Information Systems
CAN	Controller Area Network	ML	Machine Learning
CART	Classification and Regression Tree	NFC	Near Field Communication
CEA	Consumer Electronics Association	NLP	Natural Language Processing
CEP	Complex Event Processing	OA	Office Automation
CHAID	Automatic Interaction Detection	OLSR	Ordinary Least Squares Regression
CNN	Convolutional Neural Network	ORE	Oracle R Enterprise
CNN	Convolutional Neural Networks	OSX	Oracle Stream Explorer
CRF	Conditional Random Field	PCA	Principal Component Analysis
DBM	Deep Boltzmann Machine	PCR	Principal Component Regression
DBN	Deep Belief Networks	PLC	Powerline Communication
DIY	Do-It-Yourself	PSNR	Peak-Signal-to-Noise Ratio
ECG	Electrocardiography	RBFN	Radial Basis Function Network
EEG	Electroencephalography	RBM	Restricted Boltzmann Machine
EM	Expectation Maximization	RDDs	Resilient Distributed Datasets
EMG	Electromyography	RFID	Radio Frequency Identification
EMSs	Energy Management Systems	RNN	Recurrent Neural Networks
EOG	Electrooculography	SB	Smart Building
ET-KNN	Evidence Theoretic Knearest Neighbors	SVMs	Support Vector Machines
FLS	Fire and Life Safety	TMSs	Temperature Monitoring Systems
GBM	Gradient Boosting Machines	UTBS	United Technology Building Systems
GBRT	Gradient Boosted Regression Trees		
GSR	Galvanic Skin Response		
GUI	Graphical User Interface		
HDFS	Hadoop Distributed File System		
HMMs	Hidden Markov Models		
HVAC	Heating, Ventilation, and Air Conditioning		
IBs	Intelligent Buildings		
IBT	Intelligent Building Technology		
ICA	Independent Component Analysis		
ICT	Information and Communication technologies		
ID3	Iterative Dichotomiser 3		
IoT	Internet of Things		
ISM Bands	Industrial Scientific Medical Bands		
KNX	Konnex		

주변생활지원, 인공 신경망, 단일 종속 추정기, 아시아 태평양, 정확도, 베이지안 믿음 네트워크, 저전력 블루투스, 연평균 복잡성 장률, 계측 제어기 통신망, 분류 및 회귀 트리, 미국가전협회, 복잡 이벤트 처리, 자동 상호 작용 감지, 컨볼루션 신경망, 조건 임의 필드, 침침 불쓰만 머신, 침침 믿음 신경망, D.I.Y, 침전도 기록, 뇌파 기록, 기대 최대화, 근전도 기록, 에너지 관리 시스템, 전기 안구도 기록, 증명 이론-k-최근접 이웃, 화재 및 생명 안전, 그래디언트 부스팅 머신, 그래디언트 부스트 회귀 트리, 전기 피부 반응, 그래픽 사용자 인터페이스, 하둡 분산 파일 시스템, 은닉 마르코프 모델, 공조, 지능형 빌딩, 지능형 빌딩 기술, 독립 성분 분석, 정보통신기술, 반복 이분법 3, 사물 인터넷, 산업/과학/의학용 대역, 근거리 통신망, 조명 제어 및 감소, 선형 판별 분석, 국소 추정 산점도 평활화, 다변량 적응 회귀 스플라인, 미터 버스, 관리 정보 시스템, 머신러닝, 근거리 무선 통신, 자연어 처리, 사무자동화, 일반 최소 제곱 회귀 분석, 오라클 R 엔터프라이즈, 오라클 스트림 익스플로러, 주성분 분석, 주성분 회귀 분석, 전력선 통신망, 신호대 잡음비, 방사 기저 함수 네트워크, 제한 불쓰만 머신, 탄력적 분산 데이터 세트, 무선 주파수 인식, 순환 신경망, 스마트 빌딩, 서포트 벡터 머신, 온도 모니터링 시스템, 유나이티드 테크놀로지 빌딩 시스템

SB TRENDS AND MARKET IMPACT

본 조사는 연구 주제와 스마트 빌딩의 최근 발전 및 마이크로 그리드의 비전을 조사했다. 몇몇 조사는 스마트 홈에서 노인들의 독립생활을 촉진하는 작업을 검토하였다. Ni 등 [16]은 스마트 홈에서 노인의 자립 생활을 지원할 수 있는 감지 기반시설의 특징과 활동에 대한 조사를 실시했다. 노인을 위한 주변 생활지원 기술에 대한 조사가 Rashidi와 Mihailidis [17]에 의해 제시되었다. Peetoom 등 [18]은 낙상 감지 및 건강 상태 변화와 같은 가정 내 생활 활동을 인식하는 모니터링 기술에 중점을 두었다. Salih 등 [19]은 주변 지능형 생활환경 건강 매니지먼트 모니터링 서비스에 대한 리뷰를 제시하고 기존 연구 문헌에 채택된 다양한 애플리케이션, 통신 및 무선 센서 네트워크 기술을 설명했다. IoT를 중점적으로 다룬 논문: (a) Perera 등 [20]은 상황 인식 및 자율 학습의

관점에서 IoT 적용 분야를 논의했다. (b) Tsai 등 [21]은 IoT에서 데이터 마이닝 기술의 적용 분야를 조사했다. (c) Mahdavinjad 등 [22]은 IoT 데이터 분석에 적용할 수 있는 몇 가지 머신러닝 방법을 검토했다.

C. Contributions and Organization of This Report

본 리포트의 기여 및 구성

이 리포트는 애플리케이션, 데이터 분석 및 머신러닝의 관점에서 공동으로 스마트 빌딩을 다루는 조사이다. 본 리포트의 주요 기여는 다음과 같다.

- 스마트 빌딩 서비스를 제공하기 위한 머신러닝 기반 상황 인식 시스템의 잠재력 탐색
- 스마트 빌딩에 대한 연구과제 및 방향식별 및 머신러닝 모델이 이러한 과제를 해결하는 데 어떻게 도움이 될 수 있는지 확인

- 편안함, 보안, 에너지 효율성 및 편의성을 포함한 스마트 빌딩 애플리케이션 식별과 이러한 애플리케이션에서 머신러닝의 역할. 우리의 연구는 머신러닝 연구자들이 새롭고 흥미로운 머신러닝 기반 스마트 빌딩 서비스를 조사하도록 자극할 수 있다.

본 리포트의 나머지 부분은 다음과 같이 구성되어 있다. II 장에서는 스마트 빌딩의 개념과 기본 아키텍처를 소개한다. III 장에서는 스마트 빌딩 생태계의 다양한 구성 요소와 기본 아키텍처를 소개한다. V 장에서는 상황 인식 및 활동 모델링과 스마트 빌딩에서 머신러닝의 역할을 설명한다. VI 장에서는 연구 및 개발 과제를 강조하고 스마트 빌딩 프로젝트의 미래 관점을 제공한다. 마지막으로 VII 장에서는 학습한 교훈의 요약과 제공하고 논문을 마무리한다. 표 I에 사용된 중요한 약어를 열거하였다.



II. SMART BUILDINGS: CONCEPT AND ARCHITECTURE

TABLE II: COMPARISON OF RELEVANT SURVEY PAPERS

관련 조사 논문 비교

Cite	Purpose	Limitations
Chan et al. [12]	Review SH projects arranged by country and continent as well as the associated technologies for monitoring systems and assistive robotics	Does not focus on the role of ML and big data analytics, it does not review and categorize the papers according to the applications of SH
Alam et al. [13]	Reviews SH projects according to research objectives and services; namely, comfort, healthcare, and security.	Does not focus on the role of ML and big data analytics for SB.
Lobaccaro et al. [14]	Review of existing software, hardware, and communications control systems for SH and smart grid	Does not focus on the role of ML and big data analytics. It also does not focus on reviewing and categorizing papers according to the applications of SH.
Pan et al. [15]	Review the research topics on the energy efficiency and the vision of microgrids in SBs.	The focus of the paper is not the ML and big data analytics for SB services. It also does not cover other applications of SB rather than energy efficiency.
Ni et al. [16]	Propose a classification of activities considered in SH for older peoples independent living, they also classify sensors and data processing techniques in SH.	Does not cover all the services in SH. It also does not categorize the research according to different ML model styles.
Rashidi and Mi-hailidis [17]	Review AAL technologies, tools, and techniques	The paper focuses only on AAL in healthcare, and does not cover the other applications in SH or SB; in addition, there is no classifying of the researches according to ML model styles
Peetoom et al. [18]	Review the works on monitoring technologies that detect ADL or significant events in SH.	Does not focus on the role of ML in SB.
Salih et al. [19]	Review the works on ambient intelligence assisted healthcare monitoring focuses only on AAL in healthcare, and does not cover the other applications in SH or SB.	The paper also does not show the challenges and the future research directions in the field.
Perera et al. [20]	Review the works in context awareness from an IoT perspective	Does not focus specifically to the SB domain and its application services.
Tsai et al. [21]	Review the research works of data mining technologies for IoT applications.	Does not focus specifically to SB applications.
Mahdavinejad et al. [22]	Review some ML methods applied to IoT data by studying smart cities as a use case scenario.	Does not focus on SB and its applications as a use case.

II. SMART BUILDINGS: CONCEPT AND ARCHITECTURE

스마트 빌딩: 개념 및 아키텍처

1984년, 뉴욕 타임스는 부동산 개발업자들이 '지능형 빌딩이라고 부르는 새로운 세대의 건물'을 만들고 있다는 기사를 실었다. 이러한 지능형 빌딩(Intelligent Building, IB)은 '오래된 빌딩 매니지먼트와 통신의 두 가지 기술의 결합'으로 정의되었다[23]. 그 이후로 스마트 빌딩에 대한 많은 정의가 제안되었다. 이는 빌딩 계획, 설계, 구현 및 운영의 수명주기가 서로 다른 역할을 하는 여러 업계 참여자들과 연관되어 있기 때문이다. 또한 기술의 급격한 변화는 이러한 정의에 영향을 미치고 있다. 예를 들어 IoT와 스마트시티 개념의 출현은 스마트 빌딩의 정의에 영향을 미치고 있다. 따라서 전세계적으로 인정되는 단일 정의로는 IB에 대한 고유한 관점을 구성하기가 어렵다. 그러나 스마트 빌딩 개발에 참여하는 주요 표준 기관과 회사를 잘 이해하는 것이 중요하다[1]. 빌딩 효율성 연구소(Institute for Building Efficiency) [24]은 효율적이고 건강하고 쾌적한 환경을 제공하기 위한 빌딩 운영에 초점을 맞추고 있다[25]. 또한 IBM [26]은 안정적이고 지속 가능하며 비용 효율적인 점유 서비스를 제공하는 통합된 물리적 및 디지털 인프라를 제공하기 위한 스마트 빌딩의 운영에 초점을 맞추고 있다. 유럽 위원회(European Commission) Information Society [27]에 따르면, 스마트 빌딩은 유비쿼터스 컴퓨팅과 IoT를 결합한 맥락에서 정보통신기술에 의해 공급되는 건물

을 의미한다. 일반적으로 더 많은 정보를 수집, 필터링 및 생산하기 위해 센서, 액추에이터, 마이크로칩, 마이크로 및 나노 내장형 시스템(Micro- and Nano-embedded Systems)을 공급하는 건물은 로컬에서 더 많은 정보를 수집, 필터링 및 생성하고 비즈니스 기능에 따라 전세계적으로 통합 및 매니지먼트될 수 있다. 스마트 빌딩에서는 다음 사항을 포함한 다양한 AI 및 다중 에이전트 시스템 기술이 사용된다.

- 1) 기기 및 홈 서비스를 나타내기 위한 온톨로지 및 규칙을 포함하는 추론 및 지식표현
- 2) 인간 활동 인식을 위한 머신러닝
- 3) 분산 인텔리전스 및 의미론적 상호운용성(Semantic Interoperability)을 위한 멀티 에이전트 시스템
- 4) 리소스 및 서비스의 효율적인 매니지먼트를 위한 계획, 지능형 제어, 적응형 인터페이스 및 최적화와 같은 지능형 접근 방식



SMART APPLIANCES, SENSORS, AND ACTUATORS IN A SMART RESIDENTIAL BUILDING

따라서 스마트 빌딩은 에너지 매니지먼트 시스템, 온도 모니터링 시스템, 액세스 보안 시스템, 화재 및 생명 안전, 조명 제어 및 감소, 원격통신 서비스, 사무 자동화, 컴퓨터 시스템, 지역 위치 확인 시스템, LAN, 관리 정보 시스템, 케이블링 및 기록, 퍼실리티 매니지먼트 시스템, 전문가 시스템을 포함하는 통합 환경에 대한 광범위한 시스템 및 서비스의 통합이다[29].

그림 3은 공조 시스템, 조명 시스템, 태양 에너지 발전기, 전원 공급 시스템, 온도 센서, 습도 센서, 전력 사용량 센서 및 감시 카메라를 포함한 스마트 빌딩 기기의 예를 보여준다. 예를 들어, 이러한 요소를 중앙 집중식으로 제어하면 조명 및 에어컨 장치의 지능적 제어와 여러 환경에 무해한 에너지원과 환경에 유해한 에너지원의 지능적 매니지먼트를 통해 효율적인 에너지 사용을 촉진할 수 있다. 대부분의 경우, 스마트 빌딩은 계측 제어기 통신망(Controller Area Network, CAN)으로 연결되는 브리지가 있는 이더넷 백본망(Ethernet Backbone Network)을 사용한다[26].

주거용 건물은 기술 디바이스가 적고 효율성 요구사항이 덜 까다롭기 때문에 상업용 건물에 비해 스마트 서비스를 도입하기가 더 쉽다. 상업용 건물에는 일반적으로 더 많은 일반 방문자가 있으므로 상업용 건물의 모델을 구축하는 것은 대부분의 시간에 거주자가 제한된 주거용 건물의 모델을 구축하는 것 보다 일반적으로 더 어렵다. 또한 상업

용 건물에 스마트 디바이스 및 인프라를 구입하고 설치하는 데 드는 비용은 주거용 건물보다 많다. 그림 4는 지능형 센서 네트워크를 사용하는 주거용 건물의 통합 프레임워크를 보여준다. 이러한 센서는 에너지 생성, 계량, 공조설비, 조명 및 보안과 같은 시스템을 제어한다. 빌딩 자동화 시스템은 스마트 기기, 센서, 액추에이터 세트를 매니지먼트하여 주민들의 행복을 위한 서비스를 일괄적으로 제공한다. 이러한 스마트 디바이스, 센서 및 액추에이터의 예로는 세탁기 및 건조기, 냉장고, 히터, 온도조절기, 조명 시스템, 전원 콘센트, 에너지 미터기, 연기 감지기, 텔레비전, 게임 콘솔, 윈도우/도어 컨트롤러 및 센서, 에어컨, 비디오 카메라, 음향 감지기가 있다. 스마트 플로어(Smart Floor) 및 스마트 가구와 같은 스마트 디바이스가 지속적으로 개발되고 있다[28], [30]. IoT는 스마트 빌딩 내 기기종 디바이스의 통합과 상호운용성 뿐만 아니라 건물의 최적 제어와 운영을 지원하기 위해 센서에서 생성된 데이터의 실시간 처리를 가능하게 한다. IoT는 그림 5와 같이 계층으로 모델링된 아키텍처를 기반으로 한다. 감지 계층(그림 5의 맨 아래 계층)에서 볼 수 있듯이 입력 데이터는 환경 매개변수를 모니터링하고 거주자에 대한 데이터를 수집하며 이상 징후(예를 들면 화재 및 수도관 파열)를 감지하는 다양한 유형의 물리적 센서에서 수집된다. 이 계층에는 에너지 절약, 물 소비 최소화 등을 위해 제어할 수 있는 액추에이터도 포함된다.

네트워크 계층(그림 5의 두 번째 계층)에는 투명한 데이터 전송 기능을 제공하는 액세스 및 코어 네트워크가 포함된다. 이 계층은 주로 데이터 처리를 담당하는 감지 계층과 상위 계층 간의 브리지 역할을 한다.

미들웨어 계층(그림 5의 세 번째 계층)이라고 하는 중간 소프트웨어 계층은 아키텍처의 감지 계층에 포함된 기기종 디바이스 및 네트워크의 원활한 통합을 제공하기 위해 필요하다. 이 계층은 스마트 센서를 실행하는 내장형 소프트웨어와 백엔드 소프트웨어 서비스를 연결하는 브리지 역할을 한다.

이 계층은 표준화된 프로그래밍 인터페이스와 프로토콜을 사용하여 상호운용성을 제공한다[31]. 따라서 계층은 다양




Fig. 3: Example of SB appliances.

스마트 빌딩 기기의 예




Fig. 4: Smart appliances, sensors, and actuators in a smart residential building.

스마트 주거용 건물의 스마트 기기, 센서 및 액추에이터

Leveraging Machine Learning and Big Data for Smart Buildings: A Comprehensive Survey




Fig. 5: Layers of the base IoT architecture that serves as the foundation for SBs.
스마트 빌딩의 기반 역할을 하는 기본 IoT 아키텍처의 계층



한 데이터 형식에서 수집된 데이터를 공통 표현으로 변환하는 프로세스를 수행한다. 스마트 빌딩 미들웨어는 개방형 표준 또는 독자적 애플리케이션별 또는 범용을 기반으로 할 수 있다. 대부분 독자적 미들웨어는 애플리케이션별로 고유하지만 범용 미들웨어는 개방형 표준을 기반으로 한다[28].

컨텍스트 및 의미 탐색계층(그림 5의 네 번째 계층)은 컨텍스트 및 의미 탐색기의 생성, 구성 및 저장을 포함한 컨텍스트 및 의미 탐색을 매니지먼트하는 역할을 한다.

프로세스 및 추론 계층(그림 5의 다섯 번째 계층)은 미들웨어에서 추출된 정보의 처리(Processing)를 담당하며, 애플리케이션 유형에 따라 의사결정들을 하게 된다. 이 계층에는 방대한 데이터를 유용한 실행 가능한 지식으로 융합하고, 추출하며, 맥락과 관련 짓기 위하여 적용되는 다양한 정보 처리 기술들이 있다. 이 계층에서는 미들웨어의 컨텍스트 소비자 및 미들웨어의 컨텍스트 생성자라는 두 단계로 식별되어야 한다. 컨텍스트 소비자 단계에서는 미들웨어에 의해 생성된 데이터에 데이터 처리 기술이 적용된다. 반면에 컨텍스트 생성자 단계에서는 서비스 계층에 가치가 큰 지식을 제공하기 위하여 의사결정 프로세스가 구현된다. 두 번째 단계 동안에 추가 컨텍스트 정보를 미들웨어에 제공하여 온톨로지 컨텍스트에 등록할 수 있다.

특정 서비스 및 애플리케이션은 애플리케이션 계층(그림 5의 최상위 계층)에서 추상화된다. 이 계층은 다양한 유형의 애플리케이션을 구현하는 데 사용되는 기본 기능에 직접 액세스할 수 있는 프레임워크를 제공한다. 또한 자동화된 실내 공간을 제어하고 지역(Local) 인간-기계 인터페이스를 지원하기 위해 컨트롤 패널을 건물 내에 설치해야 한다. 예를 들어, 다층 건물에서는 각 층마다 제어반을 두어 창문 열기, 원하는 온도에 도달하기 위한 에어컨 컨트롤, 인공조명을 사용하기 전에 블라인드를 원하는 조도에 따라 닫기/열기를 컨트롤할 수 있다[32] [33].

SMART BUILDING?

WHAT

IS IT

In this section, we reviewed many definitions for SBs by many institutes, counties, regions and different disciplines; each has their own definition for SBs.

Layers of the base IoT architecture that serves as the foundation for SBs.

여전히 스마트 빌딩에 대한 단일 표준 정의는 없다. 이 장에서는 많은 기관, 자치시, 지역 및 다른 분야의 스마트 빌딩에 대한 많은 정의를 검토했으며, 각각 분야는 스마트 빌딩에 대한 자체 정의를 가지고 있다. 스마트 빌딩 환경에서 서비스 적응을 위한 계층화된 아키텍처 패턴을 제시했다. 스마트 빌딩의 다양한 컨텍스트 버전에 따른 동작을 조정하기 위한 일반적인 설계를 제공하고자 하였다. 이 아키텍처는 지능형 교통 시스템, 보안, 의료 지원 및 스마트 빌딩과 같은 다양한 스마트 환경에서 사용될 수 있다. 스마트 빌딩에서 환경 정보를 수집하기 위해 설치된 다양한 유형의 센서를 포함하는 감지 계층에서 시작하여 아키텍처를 6개 계층으로 계층화하였다. 네트워크 계층은 데이터 스트림 지원 및 데이터 흐름 제어기를 제공하며, Wi-Fi, Bluetooth, 이더넷 등과 같은 데이터 전송 프로토콜을 사용하여 메시지가 안정적으로 도착하도록 한다. 반면에 데이터 수집 계층은 이기종 데이터 소스에서 데이터를 수집한다. 컨텍스트 및 의미 탐색계층 (Discovery Layer)은 컨텍스트 및 의미론적 정보를 생성, 구성 및 저장한다. 컨텍스트 처리 및 추론 계층은 정보를 처리하고 애플리케이션 컨텍스트에 따라 결정을 내리는 지식을 추출한다. 그리고 마지막 계층은 보건 지원 및 노인 자택 요양, 편의 및 엔터테인먼트 서비스, 보안, 원격 관리, 스마트 급수, 에너지 효율 등과 같은 애플리케이션 계층이다. 상업용 및 주거용 건물의 주요 구성요소를 논의한 후, 다음 장에서 스마트 빌딩의 구성 요소에 대한 상세한 논의를 위한 장을 마련하였다.

III. SMART BUILDING COMPONENTS

III. SMART BUILDING COMPONENTS

스마트 빌딩 컴포넌트

스마트 빌딩 테크놀로지의 발전은 IT와 빌딩 자동화 시스템의 융합을 통해 건물 소유자의 경제적, 환경적 이익을 창출하기 위한 스마트 빌딩의 광범위한 개발로 이어졌다. 그림 6은 광범위한 센서 및 액추에이터 시스템, 네트워킹 및 통신 시스템, 소프트웨어 플랫폼 시스템, 공조설비 시스템 및 스마트 제어 장치를 포함하는 스마트 빌딩 시스템의 주요 구성요소를 보여준다.

현재 시스템은 중앙 시스템에 연결된 제어 장치와 스마트 센서를 활용한다. 이러한 제어 장치와 스마트 센서는 환경 전체에 배치된다. 각 특정 시스템에는 중앙 시스템과 통신할 수 있는 자체 네트워킹 및 통신 시스템이 있다. 스마트 빌딩은 여러 시스템의 통신 백본 역할을 하는 연결 네트워크 역할을 하고 있다.

여러 면에서 공조(HVAC) 장비는 난방, 냉방 및 환기를 생성하도록 배치 되는 수많은 구성 요소를 갖

춘 가장 복잡한 빌딩 시스템이다. 공조설비 시스템은 건물을 거주자를 건강하고 편안하게 해줄 뿐만 아니라 소비되는 에너지의 상당 부분을 매니지먼트하고 생활 안전에 중요한 역할을 한다. 스마트 빌딩은 퍼실리티 시스템을 모니터링 및 컨트롤하고 필요한 수정을 수행하는 기술을 채택한다. 스마트 빌딩의 목적은 컴퓨터와 소프트웨어를 활용하여 단일 컴퓨터 인터페이스를 통해 조명, 정보 시스템, 공조설비 및 기타 시스템을 제어하는 것이다.

A. Sensors and Actuators for SBs

스마트 빌딩용 센서 및 액추에이터

센서와 액추에이터는 환경의 환경적 값을 측정하고 제어하는 기계 구성품이다. 센서는 환경에서 정보를 수집하여 시스템에 사용할 수 있도록 한다. 예를 들어 IR 센서(Infrared Sensor)는 실내에서 사람의 존재를 감지하는 데 사용할 수 있다. 액추에이터는 전기 제어 신호를 물리적 동작으로 변환하여 의사결정을 내리고 환경에 따라 적절한 동작을 수행함으로써 환경과의 자동 및 원격 상호 작용을 가능하게 하는 장치이다. 예를 들어 조명 액추에이터는 하나 이상의 전등을 켜고 끌 수 있다[34]. 마이크로 공학, 마이크로 전자 기술, 통합광학 등 관련 기술의 빠른 발전으로 스마트 빌딩 환경에서 일상 사물 및 인프라에 통합되거나 사용자가 착용하는 다양한 스마트 센서의 개발이 촉진되었으며, 네트워크 기술로 연결되어 에너지 소비는 낮추고 처리 자원을 줄이면서 일상 생활 활동에 대한 상황 정보를 보다 효율적이고 빠르게 수집한다. 환경 센서는 건물의 특정 위치에서 수행되는 특정 물체의 인간 활동을 감지하는 데 활용되며, 웨어러블 센서는 이동 활동과 생리적 신호를 제어 및 관찰하는 데 활용된다[35].




Fig. 6: Components of smart buildings.

스마트 빌딩의 구성요소

1) Environmental Sensors

환경 센서

환경 센서로부터 수집된 데이터는 스마트 빌딩 내 인간 행동을 모니터링하는 데 중요한 정보를 형성할 수 있는 것으로 조사되었다. 그런 다음 이러한 감각 데이터를 분석하여 목욕, 옷 입기, 식사 준비, 약 복용 등 거주자가 수행하는 기본 및 중요한 일상 생활 활동을 식별하고 관찰한다. 환경 감지는 일반적으로 가정의 모든 부분에 있는 몇 가지 간단한 2진 센서(Binary Sensor), RFID 기술 및 비디오 카메라를 기반으로 한다. 이러한 다양한 감지는 복잡성과 같은 비용이 발생할 수 있지만 상황 및 실제 활동에 대한 중요한 통찰력을 구현할 수 있다. 동작 센서는 집안 어디에서나 거주자의 존재와 위치를 감지하는 데 사용된다. 다양한 유형의 동작 센서가 있다. IR 감지 센서는 스마트 빌딩에서 거주자의 존재를 감지하는 데 가장 많이 사용되는 동작 센서 종류 중 하나이다. 압력 센서를 침대, 의자, 소파 및 바닥과 같은 물체에 부착하여 거주자의 행동과 위치를 추적할 수 있다. 반면 접촉 스위치는 일반적으로 거주자가 이러한 물체에 대해 수행하는 동작을 감지하기 위해 냉장고, 방 또는 캐비닛 문에 배치된다[36]. 광센서, 습도 센서, 온도 센서 또는 전원 센서는 활동을 인식하기 위해 스마트 빌딩에 배치되고 활용되는 다른 유형의 센서이다. 광센서는 건물 내 특정 공간에서 광도를 측정하는 데 사용된다. 습도 센서는 건물 내 특정 위치의 공기 습도를 감지하는 데 사용된다. 온도 센서는 특정 환경의 온도를 측정하는 데 사용된다. 반면에 전력 센서는 전기 장치의 전력 사용량을 식별하는 데 사용된다.

2) Wearable Sensors and Biosensors

웨어러블 센서 및 바이오 센서

이러한 센서는 사용자 신체에 직접 또는 간접적으로 부착된다. 크기가 작기 때문에 이러한 센서를 손목시계, 안경, 벨트, 신발 등에 부착할 수 있다. 이러한 센서는 관성 센서와 활력 징후(Vital Sign) 센서(또는 바이오 센서)로 분류할 수 있다. 웨어러블 관성 센서는 이동성이 뛰어나고 거주자의 동작과 신체 자세에 대한 정확한 세부 기능을 제공할 수 있는 고정 장치가 없다. 이 센서들은 가속도계, 자이로스코프, 자기 센서로 구성되어 있다. 데이터 수집 과정에서 수신기와 카메라가 필요하므로 실험실 환경 밖에서 사용할 수 있다[37].

혈압, 피부 온도 및 심박수와 같은 웨어러블 바이오 센서는 건강을 모니터링 하기 위해 활력 징후를 수집하는 데 중요하다. 모바일 활동 모니터링에 가장 일반적으로 사용되는 관성 센서는 가속도계와 자이로스코프이다. 가속도계는 민감한 축에 수반되는 가속도를 측정하는 데 사용될 수 있으며, 운동하기, 서기, 앉기, 걷기, 계단 올라가기 및 내려가기 등과 같은 동작의 활동을 모니터링하는 데 유용하다. 자이로스코프를 사용하여 각속도를 측정하고 방향을 유지할 수 있다. 주요 활력 징후의 몇 가지에는 심전도(ECG), 심박수, 혈압, 혈당, 산소 포화도 및 호흡률이 있다. 전기적 뇌활동을 관찰하기 위한 뇌파 기록 센서(Electroencephalography sensor, EEG), 안구 활동에서 눈의 움직임을 관찰하기 위한 전기 안구도 기록

Environmental Sensors:
It is found that data collected from environmental sensors can form important information to monitor human behaviors within an SB

센서(Electrooculography sensor, EOG), 근육 활동을 관찰하기 위한 근전도 기록 센서(Electromyography sensor, EMG) 등 다양한 생체 신호를 측정하는 데 사용되는 다양한 활력 징후 센서가 있다. 심장 활동을 관찰하기 위한 심전도 기록 센서(Electrocardiography sensor, ECG), 혈압 관찰을 위한 압력 센서, 호흡 관찰을 위한 CO2 가스 센서, 체온 관찰을 위한 열센서, 피부 땀 관찰을 위한 전기 피부 반응 센서도 있다[38][39].

3) Heating, Ventilation, and Air Conditioning, HVAC)

공조설비 시스템

공조설비 시스템은 스마트 빌딩 서비스에서 중요한 역할을 한다. 공조설비 시스템은 스마트 빌딩의 효율적인 에너지 소비에 중요한 역할을 할 뿐만 아니라 거주자의 편안함을 높이기 위한 새로운 작동 옵션을 제공한다. 원하는 온도를 충족하는 것 외에도, 공조설비 제어 시스템은 스마트 빌딩에서 특정 수준의 습도, 압력, 공기 움직임 및 공기 품질을 센싱하여 밀폐된 공간에서 편안함을 유지하기 위해 생산된다[40]. 건물의 CO2, 습도 및 온도 수준은 거주자의 건강과 편안함에 영향을 미칠 수 있으며, 결과적으로 이러한 맥락에서 CO2, 습도 및 온도를 측정하면 개인의 행복을 향상시킬 수 있다[41]. 냉난방 시스템은 건물에서 엄청난 양의 에너지를 소비하므로 오퍼레이션 비용을 절감하기 위해 스마트 컨트롤러와 센서를 활용하여 이를 최적화할 필요가 있다. 스마트 공조설비 시스템은 건물 전체의 분산 센서와 VAV 팬을 활용하여 건물 내부의 다양한 공기질 매개변수를 감지하고 효율적으로 제어할 수 있다[42]. 스마트 빌딩의 현재 공조설비 시스템의 대부분은 공조설비 시스템에 특별히 사용되는 센서와 카메라를 사용하여 거주자에 대해 수집된 데이터를 기반으로 한다. 확실히, 데이터 수집 네트워크의 설계, 유지보수, 설정 및 하드웨어에 대한 특정한 비용이 있다[43]. 표 III은 스마트 빌딩의 다양한 스마트 센서 유형에 대한 요약을 보여준다.

TABLE III: VARIOUS SMART SENSORS USEFUL IN THE CONTEXT OF SBs

스마트 빌딩의 상황에서 유용한 다양한 스마트 센서

Sensor	Measurement	Category
Infrared sensor	User presence in a room	Environmental sensors
Video cameras	Human actions	Environmental sensors
RFID	Object identification	Environmental sensors
Motion sensor	Object/User presence/ location	Environmental sensors
Contact switch	Detect users' interaction with the object	Environmental sensors
Pressure sensor	Tracking movements and location of the user	Environmental sensors
Light sensor	Intensity of light	Environmental sensors
Temperature sensor	Temperature of surrounding environment	Environmental sensors
Humidity sensor	Detect the air humidity in a specific area	Environmental sensors
Power sensor	Detect the usage of electric devices	Environmental sensors
Accelerometer	The rate of acceleration accompanying a sensitive axis	Wearable inertial sensors
Gyroscope	Angular velocity and maintain orientation	Wearable inertial sensors
Electroencephalography	Observing electrical brain activity	Wearable vital sign sensors
Electrooculography	Observing eye movement of ocular activity	Wearable vital sign sensors
Electromyography	Observing muscle activity	Wearable vital sign sensors
Electrocardiography	Observing cardiac activity, pressure sensors for observing blood pressure	Wearable vital sign sensors
CO2 gas sensors	Observing respiration	Wearable vital sign sensors
Thermal sensors	Observing body temperature	Wearable vital sign sensors
galvanic skin response	Observing skin sweating	Wearable vital sign sensors

SMART CONTROL DEVICES

B. Smart Control Devices

스마트 컨트롤 디바이스

스마트 컨트롤 디바이스는 다양한 센서에서 데이터를 수집하고 이 데이터를 처리하며 액추에이터를 활성화하여 센서가 감지한 이벤트에 반응한다. 스마트 컨트롤 디바이스는 중앙 서버의 제어없이 독립적으로 작동할 수 있다. 하지만 다양한 제어 장치 간에 통신이 필요하거나 스마트 게이트웨이를 사용하여 서로 연결할 수 있다. WeMo [44]는 어디서나 전자 장치를 켜고 끄는 데 사용되는 Wi-Fi 지원 스위치이다. 스마트 폰 앱이나 브라우저에서 LED 모션 센서, 전구, 스마트 월(Smart Wall) 스위치와 플러그, 조명 장치 등을 제어할 수 있다. WeMo 디바이스에는 허브가 필요하지 않으며 Belkin에서 제공하는 무료 클라우드 서비스를 통해 모든 것을 관리할 수 있다. 특정 채널을 사용하여 디바이스를 Gmail과 같은 전자 서비스에 연결하여 특정 동작을 트리거할 수 있다. WeMo 디바이스는 상황 인식 기능도 지원하며, 일출 또는 일몰 등 하루 중 시간에 따라 자동으로 켜지거나 꺼진다.

구글이 인수한 네스트가 개발한 스마트 디바이스인 Nest Thermostat(온도조절기)[45]는 스마트 디바이스로서, 생활에 맞춰 조정되며 계절에 따라 자동으로 온도를 조절해 준다. 일주일만 사용하면 자체적으로 프로그래밍 된다. 또한 거주자가 선호하는 온도 수준에 대해 학습하고 상황에 맞는 맞춤형 일정을 작성한다. 스마트 온도조절기는 거주자가 건물을 떠날 때 자동으로 에너지 효율적인 모드로 전환된다. 거주자가 퇴근 후 귀가하는 등의 활동을 감지하면 해당 구역을 따뜻하게 할 수 있다. 온도조절기는 스마트 폰과 설치된 앱을 통해 제어할 수 있다. 잠시 자리를 비운 경우에도, 이 장치는 집안의 특정 온도를 유지할 수 있는 기능도 있다. Lockitron [46]은 인터넷을 통해 원격으로 문을 제어하여 전화로 열고 닫을 수 있는 도어 잠금 장치이다. Lockitron 앱은 모든 iOS 또는 안드로이드 스마트폰에서 설치 및 사용할 수 있다. 주택 소유자는 인터넷을 통해 승인을 제공하여 가족과 친구에게 주어진 문을 열 수 있는 접근을 직접 허가할 수 있다. Lockitron은 Bluetooth 저에너지 기술을 활용할 수 있으므로 인터넷이나 정전시에도 지속적으로 제어할 수 있다. 또한 Lockitron은 브리지를 통해 인터넷에 연결할 수 있으며, 이를 통해 거주자는 전 세계 어디서나 볼트를 제어할 수 있다.

SmartThings [47]는 다양한 스마트 디바이스와 장치를 지원하는 통신 스마트 허브로 구성된 스마트 빌딩 자동화 시스템이다. 스마트 허브는 ZigBee, Z-Wave와 같은 다양한 기술과 프로토콜은 물론 IP 접속 가능 장치를 지원하며 Wi-Fi 및 Bluetooth 연결을 사용하여 디바이스를 제어할 수 있다. SmartThings는 스마트플러그와 함께 온도를 측정하고 존재 유무, 움직임, 방향 및 진동

TABLE IV: COMPARISON AMONG VARIOUS SMART CONTROL DEVICES IN SB

스마트 빌딩의 상황에서 유용한 다양한 스마트 센서

	Technology	Platform used	Pros	Cons
WeMo	Wi-Fi	Android, iOS, Window phone	Affordable hardware options. Can expand using SmartThings hub. Can expand using IFTTT.	No color bulbs, no dimmer switches. Experienced some latency issues.
Nest Thermostat	Wi-Fi, Zigbee, Thread	iOS, or Android, Mac OS, Windows	Easy to program. It learns the user daily routine, it could set itself up for the user lifestyle after the first week of use.	More expensive than other smart thermostats. The Nest might not be for you if you are a stickler for temperatures that are “just right”.
Lockitron	Bluetooth	Android, iOS	Affordable, easy to install, quiet operation, Offers proximity locking and unlocking.	Wi-Fi bridge costs extra. Does not work with other devices.
SmartThings	Wi-Fi, Zigbee, Z-Wave, Bluetooth	Android, iOS, Window phone	Affordable. Easy to install. Quiet operation. Offers proximity locking and unlocking.	Compatibility issues with other devices, workarounds for non-natively supported devices will be difficult for some.
Philips Hue	Wi-Fi	Android, iOS	Modest list of 3rd party integrations. Offers own proprietary hardware. Active web community for help. Deep customization for power users. Easy to set up and use. Excellent light quality	Least user-friendly app. Complex to configure simple tasks. Missing some “key” integrations.
Blufitbottle	Bluetooth	iOS and Android device	Simple and easy to set up.	The Philips HUE kit, has a fairly high cost. Expensive.
Canary	Wi-Fi	iOS or Android device	High-quality voice recognition. Integrations with all of the “key players”. Works for all users, regardless of phone brand.	The system only detects the intruder once they are inside premises.
Amazon Echo	Wi-Fi, Bluetooth	Fire OS, Android, and iOS	Easy installation.	Priced higher than other smart thermostats with similar functionality.
Honeywell	Wi-fi, Z-Wave	iOS and Android		

을 감지하는 데 사용할 수 있는 기본 센서를 포함한 키트를 제공한다. SmartThings에는 스마트 디바이스 공급업체 및 타사 소프트웨어가 플랫폼과 함께 사용할 수 있는 하드웨어 및 소프트웨어를 제공할 수 있는 개방형 플랫폼도 포함되어 있다. Philips Hue [48]는 LED 조명과 모바일 테크놀로지의 조합이다. Wi-Fi 기술을 활용하여 기본 모드에 따라 조명 시스템을 제어하고 색상 세트를 변경할 수 있는 모바일 앱이 함께 제공된다. 새로운 Philips Hue 브리지는 Apple HomeKit 기술을 통해 Philips Hue가 다른 HomeKit 지원 액세서리에 연결하여 가정을 제어할 수 있도록 하는 데 필요한 인증을 지원한다. Blufitbottle [49]은 사용자의 음주 습관을 기록하고 사용자의 건강과 수분 유지를 위해 마셔야 할 물의 양과 시간에 대한 알림을 보낸다. 이 앱은 체중과 나이와 같은 사용자에게 대한 데이터와 현재 온도 및 습도 수준과 같은 다른 요소를 수집하여 수분을 유지하는 데 필요한 물의 양을 추정한다. 사용자의 수분 공급이 늦어지면 경고음과 함께 LED를 살짝 쳐다보는 것만으로도 다음 수분 섭취 시간이 언제인지 알려준다. Canary [50]는 온도, 공기질, 소리, 동작 진동과 같은 센서 세트와 HD 비디오 카메라가 하나의 장치로 구성된 일체형 가정용 보안 시스템이다. 이 시스템은 머신러닝 알고리즘을 사용하여 집에서 무슨 일이 일어나고 있는지 사용자에게 알리고, 무슨 일이 생기면 휴대폰으로 알림을 보내 조치를 취한다. 이러한 머신러닝 모델은 시간이 지남에 따라 학습하고 동작을 감지하면 사용자에게 더 스마트한 알림을 보낸다. 따라서 시스템을 오래 사용할수록 더 효과적이다. Canary는 사용자 행동과 주변 소음 수준 및 가정 온도 패턴을 학습하여 허위 경고 발생률을 줄일 수 있다.

Amazon Echo [51]는 사용자가 음성을 통해 가정 내의 모든 것을 제어할 수 있는 작은 원통형 기기이다. Amazon Echo에는 강력한 음성 인식 기능이 있으므로 사용자는 음성의 복잡성에 대해 걱정할 필요가 없다. Amazon Echo는 Wi-Fi 또는 Bluetooth를 통해 연결할 수 있으며, 사용자는 음성 명령을 전송하여 스피커는 물론 Belkin의 WeMo 및 Philips Hue와 같은 기타 호환 장치를 제어할 수 있다. 또한 Amazon 클라우드 Lambda 서비스를 사용하여 명령을 보낼 수도 있다. 명령을 보내려면 프로그램 이름을 포함해야 한다(예를 들면 알렉사(Alexa), TV 켜!). 또한 응답 시간을 늦추는 원격 서버에 대한 네트워크도 포함된다. Honeywell Total Connect Remote Services [52]는 개인용 스마트 홈 자동화와 보안 모니터링 과업을 통합한다. 이를 통해 거주자는 조명 및 창 블라인드 시스템에서 보안 카메라 및 화재 경보기에 이르기까지 집안의 모든 것을 제어하고 모니터링할 수 있다. 사용자는 제어 및 모니터링을 위해 스마트폰 앱 또는 데스크톱 장착 하드웨어 콘솔을 사용할 수 있다. 실시간 알림, GPS 차량 및 자산 추적, 비디오 보기 및 모바일 컨트롤 기능을 제공할 수 있다. 이 시스템은 Z-Wave 장치만 지원하며, 공인 Honeywell 대리점에서 설치해야 한다. Wi-Fi 지원 스마트 온도조절기에서는 작동하지 않는다. 또한 Honeywell은 보안 카메라와 센서를 제공하며 Yale 잠금 장치 및 Lutron 조명과 같은 타사의 다른 스마트 장치도 지원한다. 표 IV는 스마트 빌딩의 다양한 스마트 제어 장치 간의 비교를 나타냈다.

NETWORKING AND HOME GATEWAY

An SB combines a communication network in order to control smart devices and services within the building.

C. Networking and Home Gateway

네트워킹 및 홈 게이트웨이

스마트 빌딩은 건물 내 스마트 디바이스와 서비스를 제어하기 위해 통신 네트워크를 결합한다. 스마트 빌딩의 통신 네트워크는 기존의 컴퓨터 네트워크와 같이 연선 케이블과 같은 다양한 통신 매체를 기반으로 할 수 있다. 빌딩 자동화 시스템의 네트워킹은 다양한 통신 매체와 네트워크 표준으로 구성된 이기종 네트워크를 활용하는 경향이 있다. 빌딩 자동화 네트워크는 물리적 기술과 통신 프로토콜로 식별된다. 건물 내부의 장치를 연결하는 내부 네트워크뿐만 아니라 외부 네트워크도 별도로 통합할 수 있다. 공용 인터넷, ISDN 및 휴대폰 네트워크는 외부 네트워크의 몇 가지 예이다[28][53].

일반적인 스마트 빌딩은 센서, 액추에이터, 통신 및 처리 디바이스와 같은 다양한 컴포넌트로 구성될 수 있다. 특성상 이러한 컴포넌트는 배터리 용량 및 데이터 처리 능력 측면에서 제한된 성능과 연산 용량을 갖는다. 이 문제를 해결하기 위해, 대부분의 스마트 빌딩 시스템은 건물의 다양한 센서 및 액추에이터에서 컨텍스트 데이터를 수집, 처리 및 분석하는 중앙 게이트웨이로 활용되었다. Bluetooth, ZigBee, Wi-Fi 및 Z-wave와 같은 여러 프로토콜을 게이트웨이가 통신에 사용할 수 있다. 홈 게이트웨이는 특정 기간 동안 데이터를 수집하고 저장할 수도 있다. 일반적으로 이러한 게이트웨이는 클라우드 서비스에 연결하여 데이터 처리 및 추론 과업을 수행할 수 있다. 중앙 집중식 게이트웨이에는 일반적으로 인터페이스가 없다. 스마트폰, 태블릿 또는 컴퓨터를 사용하여 컨트롤 및 모니터링할 수 있다[54], [55].

일반적으로 사용되는 통신 매체에 따라 스마트 빌딩 네트

워크 기술은 상호 연결 방식에 따라 크게 세 가지 유형으로 분류할 수 있으며(전력선, 버스 라인 및 무선[15][56]), 이어서 설명한다.

1) Powerline communication (PLC)

전력선 통신망

PLC 방법은 건물 전기 네트워크를 재사용한다. 즉, 건물에서 이미 사용 가능한 전기 콘센트를 활용하여 장치, 디바이스 및 서비스가 주전원 공급 장치에 직접 연결되도록 한다. 데이터는 건물의 장치를 활성화 또는 비활성화하기 위해 일반 케이블 시스템을 통해 전송된다. PLC 시스템은 역사적으로 스마트 빌딩에서 가장 오래된 기술이며 일반적으로 저렴하지만 신뢰성과 확장성이 떨어진다[3]. 원래, PLC의 적용은 배전반과 발전소 간의 직접 정보 교환을 통해 고장 또는 고장 발생 시 전력 공급 시스템의 일반적인 작동을 확보하는 것이었다. 따라서, 이 접근방식은 스마트 빌딩 네트워킹에 대한 경쟁력 있는 선택이 되었으며, 가용성, 견고성 및 이 방식의 준비된 연결성의 이점을 누리고 있다. 이 방법의 프로토콜 중 일부는 단방향 통신을 제공하여 디바이스가 정보만 수신할 수 있을 뿐 통신하지 못하게 한다. PLC 방법에는 X-10, INSTEON, HomePlug, BACnet 및 Lonworks와 같은 다양한 주류 프로토콜이 있다.

2) Busline

버스라인

스마트 빌딩 네트워크의 버스라인 별도의 물리적 매체를 사용하며, 일반적으로 전기 신호 전송을 위한 네트워크 서비

스에 사용되는 물리적 케이블과 유사한 연선 케이블을 사용한다. 이러한 유형의 시스템은 구성 프로세스가 복잡하고 네트워킹에 대한 약간의 지식이 필요하기는 하지만 건물 거주자에게 만족스러운 시스템이다. 이 시스템의 구성이 복잡하고 설치 비용이 많이 들지만, 별도의 케이블을 사용하면 이 방식에 긍정적인 모습을 제시할 수 있다. 이 방법을 사용하면 네트워킹 방법이 더 높은 대역폭을 제공하고 세 가지 방법 중에서 가장 신뢰할 수 있기 때문이다. 또한, 이 기술은 일반적으로 가전제품이 서로 쉽게 통신할 수 있도록 하는 완성된 양방향 통신 프로토콜을 지원한다[57]. 버스라인 기술의 프로토콜은 Konnex (KNX), CAN (Controller Area Network), Modbus, Meter-Bus (M-Bus)가 있다.

3) Wireless interconnection

무선 상호 접속

많은 새로운 스마트 빌딩 애플리케이션은 적외선, 무선 주파수 등의 무선 기술을 사용하고 있는데, 이러한 기술은 줄에 매여 있지 않은 특성과 케이블이 필요없기 때문에 사용자에게 더 편리하다. 스마트 빌딩 내의 장치는 전파가 바닥, 캐비닛 및 벽을 통과할 수 있으므로 무선 통신을 할 수 있다[56]. 스마트 빌딩의 잠재적 개조 및 재배선 과정의 복잡성과 비용 때문에, 여러 가지 다른 무선 기술이 등장하여 건물 내 이러한 와이어의 물리적 배선 및 배치를 고려하지 않고 거주자에게 편리한 유연한 네트워킹 패턴을 생성하고 있다. 일반적으로 블루투스 (Bluetooth), 지그비(ZigBee), WLAN, 지-웨이브(Z-wave),

RFID 등과 같은 무선 시스템을 위한 다양한 프로토콜이 있으며, 이는 산업 과학 의료 대역, 특히 2.4GHz 주파수 범위에서 기본적으로 작동한다. 이러한 무선 기술은 일반적으로 저전력 소비, 높은 비용 효율성, 저속, 네트워킹 유연성, 배치 및 빌딩 도달율과 같은 스마트 빌딩의 일부 제어 네트워크 개념과 관련이 있다[3]. 게이트웨이는 IoT 솔루션에 일반적으로 사용되는 스마트 빌딩의 중앙 서버이다. 게이트웨이에서 제공하는 서비스는 기본적으로 시스템 및 해당 장치의 모니터링, 제어 및 구성과 같은 시스템 관리 기능과 관련이 있다. 또한 복잡한 애플리케이션에 필요한 처리 및 데이터 저장 기능을 지원한다.

Technical
Standards
for Smart Cities
스마트시티 국제표준화
기반조성(R&D)

SOFTWARE PLATFORM

Technical Standards for Smart Cities
스마트시티 국제표준화 기반조성(R&D)

D. Software platform

소프트웨어 플랫폼

빌딩이 ‘스마트’해지려면 빌딩의 모든 가전제품과 시스템이 클라우드의 스마트폰, 태블릿 및 서버와 안전하게 통신하고 데이터를 교환하는 것이 중요하다. 소프트웨어 플랫폼은 다양한 프로토콜을 통해 정보를 교환, 보관 및 배포하는 데 중요한 역할을 한다. 이러한 플랫폼은 푸시(Push), 풀(Pull), 퍼블리시(Publish)/구독(Subscribe) 등을 사용한다. 공동 영리 기업의 목표는 여러 제조업체의 디바이스 간에 데이터를 더 쉽게 교환할 수 있도록 오픈 소스 소프트웨어 플랫폼을 개발하는 것이다. 따라서 사용자는 가정에서 다른 제조업체의 전기 및 전자 디바이스를 사용할 때 향후 호환성 문제에 대해 걱정할 필요가 없을 것이다. 또한, 새로운 플랫폼은 엔터테인먼트, 에너지 효율성, 보안 기술과 같은 다양한 홈 서비스를 제공할 수 있다. 따라서, 이러한 사용 영역을 위한 다양한 앱을 만들 수 있다[58].

ABB, Robert Bosch GmbH 및 Cisco Systems Inc.는 Mozaic Operations GmbH [59]라는 공개 소프트웨어 플랫폼을 구축하여 스마트 홈 기술을 통합하고 건물 내 모든 기기와 서비스에 상호운용성을 제공하여 거주자의 경험을 단순화했다. 이를 통해 사용자는 에너지 효율을 개선하고 고유한 수준의 제어와 편안함을 달성하기 위해 장치의 제조업체 및 브랜드에 관계없이 가전제품과 장치를 원활하고 직관적으로 사용자 정의할 수 있다. 예를 들어, 사용자는 스마트폰에서 클릭하거나 사전 설정된 지시로 가정에서 블라인드를 닫고, 아이들이 밖으로 나가 놀 수 있도록 모든 화면 장치를 자동으로 끌 수 있다. 스마트 빌딩에서 많은 디바이스와 가전제품은 서로 간에, 스마트폰 및 기타 스마트 디바이스, 그리고 일반적으로 인터넷과 간단하고 안전하게 정보를 공유할 수 있다.

Indigo Domotics [60]는 DIY(Do-it-Yourself) 스마트 빌딩 플랫폼을 구현한다. Mac OS에서 사용할 수 있는 Indigo 가정 자동화 소프트웨어 컨트롤러를 사용하면 거주자가 일련의 공통 INSTEN, Z-Wave 및 X10 장치를 결합하여 건물 조명, 센서, 온도조절기 및 가전제품을 비할 데 없이 편하게 제어할 수 있다. Indigo Touch(iTunes 앱 스토어를 통해 판매, iOS 전용)를 사용하면 아이폰, 아이패드, 아이팟 터치 등을 활용해 손쉽게 디바이스를 원격 컨트롤할 수 있다. 또한 어떤 장치에서도 웹 브라우저를 사용하여 전 세계 어디에서나 가상으로 가전제품을 컨트롤할 수 있다. 사용자는 문 열림/닫힘, 정전 등에 대해 감지된 특정 이벤트에 대한 문자 또는 이메일을 받을 수 있다. Perceptive Automation의 Indigo는 최신 맥용 가정 자동화 소프트웨어이다.

OpenHAB [61]는 스마트 빌딩 시스템의 다양한 기술을 단일 솔루션으로 통합하기 위해 미들웨어 방식을 따르는 오픈 소스 소프트웨어 플랫폼이다. OpenHAB 플랫폼은 스마트 빌딩 영역의 다양한 네트워크 기술과 가전제품을 다룬다. 현재, 빌딩 자동화 시스템과 서로 다른 장치를 연결하는 공통 언어가 없기 때문에 특정 공급업체에 대한 의존성이 문제가 되고 있다. OpenHAB 플랫폼의 주요 목표는 커뮤니티 기반 접근 방식을 통해 스마트 빌딩 시스템에 새로운 장치와 기술을 통합하는 것이다. OpenHAB는 다양한 기술과 장치 간의 통신을 위해 OSGi 기반 모듈식 시스템을 활용한다. 바인딩(Binding)은 특정 기술과 장치를 연결하기 위해 OSGi 번들로 개발 및 배치될 수 있다. EnOcean, KNX, Z-Wave와 같은 다양한 지원 기술이 있으며 특수 바인딩을 통해 지원되는 다른 기술도 있다[62]. SmartThings [47]는 하드웨어 장치, 센서 및 소프트웨어 애플리케이션으로 구성된 플랫폼이다. 컨텍스트 정보는 센서에서 수집되며, 이 컨텍스트는 애플리케이션에서 수행되는 추론 및 조치에 기여한다. 예를 들어, 정원의 스

프링클러는 비를 감지하고 그에 따라 물을 절약하기 위해 스스로 전원을 끌 수 있다. SmartThings 키트는 센서, 스마트 장치 및 허브로 구성된다. SmartThings 애플리케이션은 사용자가 스마트폰 기기를 통해 건물 환경을 컨트롤하고 모니터링할 수 있도록 구성되어 있다. SmartThings Hub는 센서, 기기 및 건물의 인터넷 라우터를 서로 연결하고 클라우드에 연결하는 역할을 한다. Zigbee, Z-Wave, IP 접속 가능 장치와 같은 다양한 통신 프로토콜과 호환된다. 또한 SmartThings는 온도조절기, 수분 센서, 동작 센서, 존재 센서, 잠금 장치 및 차고 문 열림 장치와 같은 다른 센서 및 장치와 호환된다[63].

HomeOS [64]는 개인용 컴퓨터에 설치할 수 있는 마이크로소프트의 가정용 운영 체제 플랫폼이며, 마이크로소프트 윈도우 기반 장치에 국한되지 않는 개방형 플랫폼이다[65][66]. HomeOS 플랫폼을 사용하면, 애플리케이션을 설치하여 다양한 상황 인식 기능을 유지할 수 있다. 예를 들어, 누군가가 초인종을 눌렀을 때 도어 카메라로 이미지를 촬영하고 이미지를 사용자에게 전송한다. HomeOS는 스마트 빌딩 환경에서 네트워크 기기의 기술을 관리하여 사용자와 개발자에게 확장하는 PC와 같은 추상화를 제공한다. 이러한 설계를 통해 사용자는 프로토콜에 독립적인 서비스를 매핑하여 간단한 API, 커널 및 특정 장치의 프로토콜로 애플리케이션을 지원할 수 있다. HomeOS는 일반적으로 홈 게이트웨이와 같은 할당된 컴퓨터에서 실행되며 상용제품 장치에 맞추는 조정이 불필요하다. HomeOS는 일반적으로 (i) 스마트홈의 기술 매니지먼트 프로세스를 용이하게 하기 위한 데이터로그 기반 액세스 제어 (ii) 기기 및 애플리케이션을 통합하기 위한 커널 (iii) 개발자에게 기기에 관리 가능한 액세스를 허용하는 프로토콜 독립 서비스를 활용한다.

Lab of Things(LoT)[67][68]는 건물에서 연결된 장치들을 활용하는 실험 연구 플랫폼이다. LOT는 시스템 상태에 대한 원격 모니터링 및 업데이트, 클라우드 스토리지의 여러 가전제품에서 수집된 데이터 로깅 등과 같은 배포 기능을 제공하는 프레임워크를 제공한다. 이를 통해 데이터 공유 및 수집, 코드 공유, 하드웨어 센서를 소프트웨어 플랫폼에 연결하고, 참여자는 HomeOS를 사용할 수 있다. 이 플랫폼은 홈OS와 결합하여 작동하므로 의료, 에너지 매니지먼트 서비스 등 IoT 기반 스마트 서비스에 배포할 수 있는 솔루션을 간편하게 구축할 수 있도록 설계되었다.

Eclipse Smarthome [69]은 스마트 빌딩 및 주변 생활 지원과 같은 이기종 환경에 초점을 맞춘 프레임워크이다. 이 플랫폼은 기존의 다양한 통신 메커니즘을 고려한다. Eclipse SmartHome은 시스템 및 프로토콜 경계를 넘어 통신을 가능하게 하는 추상화 및 변환 프레임워크 역할을 한다. 스마트 빌딩 서비스에 중요한 많은 구현된 확장, 프로토콜 및 표준을 제공한다. 이러한 구현은 Java 라이브러리 또는 OSGi 번들 형태로 수 있으므로 나머지 프로젝트와 독립적으로 사용할 수 있다. 이 프레임워크는 BeagleBone Black, Intel Edison 또는 Raspberry Pi와 같은 다양한 내장형 기기에서 작동할 수 있다. Eclipse SmartHome 확장 기능은 여러 공급업체에서 제공하는 솔루션과 호환된다. 이는 특정 목적으로 작성된 코드를 상용 플랫폼에서 쉽게 확장할 수 있음을 의미한다. Eclipse SmartHome은 사용자 의 기대에 맞는 특별한 스마트 홈 솔루션을 설계할 수 있도록 다양한 특성을 제공한다[70].

다양한 스마트 빌딩 솔루션에 대한 논의 외에도, Cooja라는 인기있는 시뮬레이터가 내장 센서와 액추에이터의 비교적 큰 무선 네트워크 및 무선 센서 네트워크 기술을 기반으로 시스템을 개발, 디버그 및 평가하기 위한 연결된 장치에 대한 소규모 시뮬레이션을 생산하기 위해 연구 커뮤니티에서 널리 사용된다는 점을 강조한다. Cooja 시뮬레이터는 Java 기반 무선 센서 네트워크 시뮬레이터이며, Contiki OS 프로젝트와 함께 배포된다. Cooja는 센서 노드 세트의 에뮬레이션을 가능하게 하며, 또한 시스템의 물리적 및 애플리케이션 계층을 시뮬레이션할 수 있다[71]. Cooja에서 시뮬레이션된 노드에 대한 세 가지 기본 속성이 있다(하드웨어 주변 장치, 노드 유형 및 데이터 메모리). 노드 유형은 여러 노드 간에 공유될 수 있으며 이러한 모든 노드에 공통적인 속성을 정의한다[72].

요약: 스마트 빌딩 분야에는 빌딩 제어 및 에너지 매니지먼트 시스템을 비롯하여 상업, 산업, 기관 및 국내 빌딩 전반에 걸쳐 다양한 기술이 포함되어 있다. 몇몇 조직 및 기관에서는 거주자가 단일 장치를 채택하여 모든 전자 디바이스 및 가전제품을 제어할 수 있는 기술을 빌딩에 공급하기 위해 노력하고 있다. 여기에서는 센서 및 액추에이터, 스마트 제어 장치, 스마트 게이트웨이, 네트워킹 및 소프트웨어 플랫폼 등 스마트 빌딩의 다양한 컴포넌트에 대해 논의하였다.

MACHINE LEARNING

ML BACKGROUND FOR SBS: MODELS, TASKS, AND TOOLS
Massive data generated from sensors, wearable devices, and other IoT technologies provide rich information

IV. ML BACKGROUND FOR SBS: MODELS, TASKS, AND TOOLS

스마트 빌딩의 머신러닝 배경: 모델, 태스크 및 툴
센서, 웨어러블 기기 및 기타 IoT 기술에서 생성된 방대한 데이터는 사용자의 컨텍스트 및 빌딩 상태에 대한 풍부한 정보를 제공하며 스마트 빌딩 매니지먼트 설계에 활용할 수 있다. 이 컨텍스트 정보는 다양한 이해 관계자를 위해 유용하고 흥미로운 인사이트(Insight)를 추출하는 데 필요하다. 데이터 양이 매우 많은 경우 기존 접근법을 사용하여 예측 모델을 개발하면 정확한 통찰력을 얻을 수 없으므로 빅데이터에서 새로 개발된 툴이 필요하다. 빅데이터는 스마트 빌딩에 큰 영향을 미칠 것으로 예상되며, 이미 건축, 엔지니어링 및 건설(AEC)산업[73], 특히 폐기물 분석[74]과 폐기물 최소화[75]에서 큰 역할을 하고 있다. 머신러닝은 우리 주변의 다양한 소스에서 수집된 방대한 양의 데이터를 마이닝하고 복잡한 세상을 이해하는 데 도움이 되는 강력한 툴이다. 머신러닝 알고리즘은 학습 세트라고 하는 일련의 관찰된 데이터 예제 셋에서 모델을 학습하여 새 데이터에 모델을 적용한다. 예를 들어 걷기 또는 조깅으로 표시된 샘플 가속도계 데이터셋에 대해 훈련을 받은 후 머신러닝 알고리즘은 미래의 데이터 포인트를 걷기 및 조깅 클래스로 분류할 수 있다. 머신러닝을 사용하면 사람의 개입 없이도 고급 소프트웨어 시스템을 비교적 쉽게 개발할 수 있으며, 스마트 빌딩 환경의 많은 실제 문

제에 적용할 수 있다. 또한 자습 및 협업 시스템을 설계하고 개발할 수 있다. 머신러닝은 데이터 사이언스에서 인간의 요소를 제거하지 않으며, 빅데이터를 처리하는 데 있어서 시맨틱(Semantic)과 컨텍스트(Context)에 대한 이해를 보완하기 위해 빅데이터를 처리하는 컴퓨터의 장점을 활용한다. 주어진 시스템을 개선하는 데 필요한 더 나은 기능이나 매개 변수를 추출하기 위한 학습 데이터만 필요하다. 머신러닝 알고리즘을 사용하여 데이터 패턴을 기반으로 예측할 수 있다. 이를 통해 컴퓨터가 명시적으로 프로그래밍하지 않고도 입력 데이터에서 학습할 수 있도록 하여 머신러닝 알고리즘이 입력 데이터에서 학습하고 예측할 수 있도록 한다[76][77]. 네스트(Nest) 온도조절기는 거주자의 선호도에 따라 특정 공간 및 특정 시간에 특정 온도를 적용하는 디바이스의 예이다. 아마존의 에코(Amazon Echo)와 같이 음성 패턴으로부터 학습할 수 있는 디바이스가 있고, 훨씬 더 복잡한 행동과 활동 패턴으로부터 학습하는 디바이스도 있다. 머신러닝 기법은 스마트 빌딩의 컨텍스트 수정에 따라 감지하고 반응할 수 있는 스마트 시스템을 개발하는 데 널리 사용되었다[78]. 두 가지 유명한 정리인 'No Free Lunch 정리(특정한 문제에 최적화된 알고리즘은 다른 문제에서는 그렇지 않다)'와 'Ugly Duckling 정리(일종의 편향없이 분류가 정말로 불가능하다)'에 따르면 다양한 머신러닝

알고리즘이 있다. No Free Lunch 정리에서는 문제에 대한 사전 정보 없이는 '다른 어떤 알고리즘보다 더 낫고 할 수 있는 알고리즘은 없으며', 어떤 두 알고리즘은 문제 해결을 똑같이 잘 수행할 수 있다고 명시한다. 반면에 Ugly Duckling 정리는 '다른 어떤 두 패턴도 다른 어떤 쌍보다 서로 더 유사하다고 말할 수 없다'고 명시한다[79].

머신러닝은 주로 다음과 같이 다양한 유형의 학습 과제를 처리하는 4가지 범주로 분류된다(지도 학습, 비지도 학습, 준지도 학습, 강화 학습(RL) 알고리즘). 그림 7은 머신러닝의 종류를 보여준다. 이러한 범주는 다음에 설명되며 이러한 머신러닝 기법 간의 요약 비교는 표 V에 제시되어 있다.

1) 지도 학습(Supervised Learning): 레이블이 지정된 학습 데이터셋을 기반으로 알고리즘을 개발하는 것을 의미하며, 여기서 학습자는 입력, 출력 및 시스템 매개변수 사이의 관계를 나타내는 시스템 모델을 구축하여 표현을 일반화해야 한다. 머신러닝 모델은 모델이 원하는 수준의 정확도에 도달할 때까지 입력 학습 데이터에서 계속되는 학습 과정을 통해 개발된다[80][81]. 일반적인 지도 머신러닝 알고리즘의 몇 가지 예: 나이브 베이즈 모델(naive Bayes model), 의사 결정 트리(decision tree), 서포트 벡터 머신(support vector machines, SVM)같은 선형식별함수, 인공 신경망(ANN), 은닉 마르코프 모델(hidden Markov models, HMM), 인스턴스 기반 학습(instance-based learning, 예를 들면 최근접 이웃학습(k-nearest-neighbor learning), 앙상블(ensembles, bagging, boosting, random forest), 로지스틱 회귀(logistic regression), 유전 알고리즘(genetic algorithms)[82][83]. 지도 학습 접근법은 스마트 빌딩의 다양한 문제를 해결하는 데 광범위하게 사용된다.



스마트 빌딩 애플리케이션(Application in SBS): Boger 등 [76]은 치매 환자의 손 씻기 과정을 돕기 위해 마야코프 의사 결정 프로세스를 사용하는 지도 학습 시스템을 제안했다. Altun 등 [84]은 신체 착용 소형 관성 및 자기 센서를 사용하여 감속한 인간 활동 분류 접근법에 대한 비교 연구를 수행했다. Mozer [85]는 스마트 홈 환경에서 공기 난방, 조명, 환기 및 온수 난방을 제어하기 위해 신경망과 강화 학습을 사용하여 가정 환경 시스템의 거주자 편의 제어를 개발했다. Bouroubou 등 [86]은 스마트 환경에서 사용자 활동을 식별하고 예측하기 위해 ANN과 K-패턴 군집화를 사용한 하이브리드 접근법을 제시하였다. Hsu 등 [87]은 활동, 관심사, 기분, 경험, 인구통계학적 정보 데이터와 같은 사용자 맞춤형 속성을 기반으로 신경망 모델을 사용하는 TV 추천 시스템을 제안했다. Fleury 등 [88]은 SVM 알고리즘을 사용하여 다양한 센서의 데이터를 기반으로 일상생활 활동을 분류하는 의료 중심의 스마트 홈 시스템을 제안했다. 지도 학습 문제는 분류, 회귀, 시계열 및 앙상블 방법 문제로 더 상세히 분류될 수 있다.


a) 분류(Classification): 분류 알고리즘의 태스크는 사례(Instance)를 가능한 범주의 특정 개별 집합으로 분류하는 것이다. 두 세트의 데이터(라벨이 있는 데이터셋과 라벨이 없는 데이터셋)가 주어지면 라벨이 지정된 데이터셋이 학습 프로세스에 사용되며, 반면 라벨이 지정되지 않은 데이터셋은 분류 결과를 평가하는 데 사용된다. 일반적인 프로세스는 [21]에 정의된 정확도 비율(AR)이라고도 하는 올바른 범주에 할당된 사례의 수를 계산하는 것이다.




TABLE V: COMPARISON OF ML TECHNIQUES

머신 러닝 기법 비교


Category	Type	Algorithms	Pros	Cons	Applicability in SBs	Cited
Supervised Learning	Classification	Neural net-works	Requires little statistical train- ing; Can detect com- plex non- linear relation- ships	Computational burden; Prone to Overfitting; Picking the correct topology is diffi- cult; Training can take a long time and a lot of data;	Used for classification, control and automated home appliances, next step/action prediction.	[99][100] [101][102] [103][104]
		SVM	Can avoid overfitting using the regularization; expert knowledge using appropri- ate kernels	Computationally expensive; Slow; Choice of kernel mod- els and parameters sensitive to overfitting	Classification and regres- sion problems in SBs such as activity recognitions, human tracking, energy efficiency services	[105][106] [107][88] [108]
		Bayesian net- works	Very simple representation does not allow for rich hy- potheses	You should train a large training set to use it well.	Energy management sys- tem and human activity recognition.	[109][96] [97][98]
		Decision trees	Non-parametric algorithm that is easy to interpret and explain.	Can easily overfit	Patient monitoring, healthcare ser- vices, awareness and notifica- tion services.	[92][93]
		Hidden Markov	Flexible generalization of sequence profiles; Can handle variations in record structure	Requires training using an- notated data; Many unstruc- tured parameters	Daily living activities rec- ognition classification	[110][111] [112][113]
		Deep Learning	Enables learning of features rather than hand tuning; Reduce the need for feature engineering	Requires a very large amount of labeled data, computationally really ex- pensive, and extremely hard to tune.	Modeling occupant's behavior, and in human voice recognition and monitoring systems; Con- text-aware SB services.	[114][115] [116][117] [118][119]
	Regression	Orthogonal matching pursuit	Fast	Can go seriously wrong if there are severe outliers or influential cases	For regression problem such as energy efficiency services in SBs.	[120]
		Clustered- based	Straightforward to understand and explain, and can be regu- larized to avoid overfitting.	It is not flexible enough to capture complex patterns	Gesture recognition.	[121]
	Ensemble methods	N/A	Increased model accuracy through averaging as the number of models increases.	Difficulties in interpreting decisions; Large computa- tional requirements.	Human activity recogni- tion and Energy efficiency services.	[122][123] [124]
	Time series	N/A	Can model temporal relation- ships; Applicable to settings where traditional between- subject designs are impossi- ble or difficult to implement	Model identification is dif- ficult; Traditional measures may be inappropriate for TS designs; Generalizability cannot be inferred from a single study.	Occupant comfort ser- vices and energy efficien- cy services in SBs.	[125] [126] [127]
Unsu- pervised learning	Clustering	KNN	Simplicity; Sufficient for ba- sic problems; Robust to noisy training data.	High computation cost; Lazy learner	Human activity recogni- tion.	[128]
		K-pattern clus- tering	Simple; Easy to implement and interpret; Fast and com- putationally efficient	Only locally optimal and sensi- tive to initial points; Difficult to predict K-Value.	Predict user activities in smart environments.	[86]
		Others	N/A	N/A	N/A	[82][83] [129][130]
Semi-Su- pervised learning	N/A	N/A	Overcome the problem of su- pervised learning hav- ing not enough labeled data.	false labeling problems and inca- pable of utilizing out- of-domain samples.	Provide context aware services such as health monitoring and elderly care services.	[131][132] [133][134] [135]
Rein- forcement learning	N/A	N/A	Uses "deeper" knowledge about domain	Must have (or learn) a model of environment; must know where actions lead in order to evaluate actions	Lighting control services and learning the occu- pants, preferences of mu- sic and lighting services.	[136][137] [138][139]



(a) Supervised Learning



(c) Semi-supervised Learning



(b) Unsupervised Learning



(d) Reinforcement Learning

Fig. 7: ML styles.

머신 러닝 종류

분류 알고리즘은 수학적으로 다음과 같이 설명할 수 있다.

$$AR = \frac{N_c}{N_t} \quad (1)$$

여기서 N_c 는 속한 범주에 올바르게 할당된 테스트 사례의 수를 나타내며, N_t 는 테스트 사례의 수를 나타낸다. 정밀도(P) 및 재현율(R)은 분류 결과의 세부사항을 측정하는 데 사용된다. 가능한 네 가지 결과는 일반적으로 참 양성(TP), 거짓 음성(FN), 거짓 양성(FP) 및 참 음성(TN)이며, 정밀도(P) 및 재현율(R)은 다음과 같이 정의된다.

$$P = \frac{TP}{TP + FP} \quad (2)$$

P와 R이 주어지면, F-score 또는 F-measure라고 하는 전체 분류 결과의 정밀도 및 재현율을 설명하는 간단한 방법은 다음과 같이 정의된다.

$$F = \frac{2PR}{P + R} \quad (3)$$

일반적으로 사용되는 분류 기법에는 의사결정 트리, SVM, 규칙 기반 귀납법, 신경망, 딥러닝, 메모리 기반 추론, 베이즈 네트워크가 포함된다[89].

b) 의사결정 트리 알고리즘(Decision Tree Algorithms): 의사결정 트리 방법은 중요한 예측 머신러닝 모델링 접근법이며, 데이터에 실제 특성 값을 기반으로 제시된 의사결정 모델을 구성한다. 의사결정 트리는 분류 및 회귀 문제 모두에 사용할 수 있다. 트리 구조에서 잎은 클래스 레이블을 나타내고 가지는 해당 레이블로 연결되는 속성의 결함을 나타낸다[90].

대상 변수가 회귀 트리(Regression Tree)라고 하는 연속 값을 취하는 의사결정 트리이다. 의사결정 트리는 속도와 정확성 때문에 머신러닝 알고리즘이 가장 선호하는 머신러닝 알고리즘 가운데 하나이다. 의사결정 트리에 대한 가장 일반적인

알고리즘[91]은 분류 및 회귀 트리, ID3, C4.5 및 C5.0, 카이제곱(Chi-squared), M5 그리고 조건부 결정 트리이다. 스마트 빌딩 애플리케이션(Application in SBs): Delgado 등 [92]은 스마트 환경에서 인간 행동을 신속하게 생성하기 위해 의사결정 트리를 기반으로 한 머신러닝 기법을 제안하여 인간 행동의 가장 빈번한 활동과 이러한 활동의 시간적 관계를 추출한다. Viswanathan 등 [93]은 환자 모니터링 및 보건 서비스를 제공할 수 있는 C4.5 분류 알고리즘을 사용하여 의료 환경을 위한 프로토타입 분산 데이터 마이닝 시스템을 소개한다. 의사결정 트리 알고리즘은 해석하고 설명하기 쉬운 바-매개변수 알고리즘이다. 이 알고리즘의 주요 단점은 쉽게 과다 적합할 수 있다는 것이다.

c) 베이저안 알고리즘(Bayesian Algorithms): 베이저안 방법은 분류 및 회귀 문제에 대한 베이저의 정리를 활용한다. 가장 일반적인 베이저안 알고리즘 [94]: 나이브 베이즈(Naive Bayes), 가우시안 나이브 베이즈(Gaussian naive Bayes), 베이저안 믿음 네트워크(Bayesian Belief Network), 베이저안 네트워크(Bayesian Network). 스마트 빌딩 애플리케이션(Application in SBs): Parnandi 등 [95]은 나이브 베이즈 분류와 동적 시간 왜곡에 기반한 빌딩 내 위치추정 접근법을 제안하고, 스마트폰의 내장 센서를 활용하여 사용자가 진입한 건물과 사용자가 건물 내에서 수행하는 활동을 결정한다. Verbert 등 [96]은 공조설비 시스템의 고장을 진단하기 위해 베이저안 네트워크를 기반으로 하는 머신러닝 접근법을 제안했다. 이 모델은 보존 법칙, 구성 요소 상호의존성 및 가상 센서를 사용한 이력 데이터에 관한 전문가 지식을 기반으로 구축되었다. 나이브 베이즈(Naive Bayes) 분류기 접근법은 [97][98]에서 인간 활동 인식에 대한 잠재적 결과와 함께 적용되었다. 나이브 베이즈 접근법은 관찰된 일련의 센서 판독 값에 대해 가장 높은 확률로 식별되는 인간 활동을 인식한다.

d) 서포트 벡터 머신(Support Vector Machine, SVM): 주로 분류 과제에 사용되지만 분류 및 회귀 문제 모두에 적용할 수 있는 지도 머신러닝 알고리즘이다[140]. SVM은 얼굴 및 물체 인식, 텍스트 분류, 스팸 탐지, 필기 분석 등과 같은 많은 통계 학습 문제에 가장 널리 사용되는 머신러닝 알고리즘 중 하나이다[141]. SVM은 두 클래스의 가장 가까운 지점의 초평면 간 사이를 분리하는 여백을 최대화하는 것이다. 서포트 벡터는 경계에 있는 점이며 최적의 분리 초평면은 여백의 중간이다[142].

스마트 빌딩 애플리케이션(Application in SBs): Fu 등 [105]은 전기 보조 계량 시스템이 있는 공공 건물의 시스템 수준 전기 부하를 예측하는 SVM 방법을 제안했다. Nguyen 등[106]은 유비쿼터스 스마트 홈에 있는 4대의 카메라 네트워크에서 입력 이미지를 기반으로 사람의 움직임을 예측하고 인식하기 위해 SVM을 사용하는 실시간 인간 추적 시스템을 제안했다. Petersen 등 [107]은 각 방의 무선 모션 센서가 제공하는 데이터만 사용하여 방문자가 집에 있는 시간을 예측하는 SVM 모델을 개발했다. Fleury 등 [88]은 SVM을 기반으로 한 스마트 홈의 일상생활 활동을 자동으로 인식하는 연구 결과를 발표했다. 이들은 적외선 감지 센서, 도어 접점, 온도 및 습도 측정 센서, 마이크와 같은 다양한 센서에서 데이터를 수집했다. Das 등 [108]은 1 클래스(one-class) SVM(one-class SVM)을 사용하여 스마트 홈에서 실시간 활동 오류 감지를 위한 1 클래스 분류 접근법을 제안했다. Zhao 등 [143]은 에너지 효율 소비 목적을 위해 온도 및 열원 정보를 통해 건물의 점유 행동을 감지하기 위해 SVM 및 RNN을 기반으로 한 머신러닝 접근법을 제안했다.

e) 인공 신경망 알고리즘(Artificial Neural Network, ANN): ANN 모델은 생물학적 신경망의 과정에서 영감을 받았다.



ANN 모델은 일반적으로 회귀 및 분류 문제에 활용된다. 일반적인 인공 신경망(ANN) 알고리즘[94]: 퍼셉트론(Perceptron), 역전파(Back-Propagation), 홉필드 네트워크(Hopfield Network), 방사 기저 함수 네트워크(Radial Basis Function Network, RBFN) 등이 있다.

ANN은 통계적 학습이 덜 필요하고, 예측 변수와 응답 변수 사이의 복잡한 비선형 관계를 탐지할 수 있는 능력과 예측 변수 사이의 가능한 모든 관계를 탐지할 수 있는 능력을 포함하여 많은 이점을 제공한다[104]. 반면에 단점으로는 ‘블랙박스(black box)’ 특성, 과중한 계산 부담, 과적합의 경향이 있다. 그러나 신경망의 고유한 특성으로 인해, 로컬 최적화가 없는 학습의 어려움, 행동의 수정에 대한 적응, 결과의 검증 프로세스, 네트워크 성능 해석의 복잡성 등이 주요 한계이다.

스마트 빌딩 애플리케이션(Application in SBs): Badlani와 Bhanot [99]은 ANN에 기반한 패턴 인식을 적용하여 에너지 효율을 위한 스마트 홈 시스템을 개발했다. 이 시스템은 인간의 행동 패턴을 수집하기 위한 RNN과 스마트 홈의 보안 애플리케이션을 위한 ANN을 통합했다. 다른 연구자들은 상황 인식 서비스를 제공하기 위해 ANN을 적용했다. Campo 등 [100]은 건물의 각 구역에 대한 점유 확률을 계산하고 그 확률을 현재 상황과 체계적으로 비교하는 시스템을 개발했다. 스마트 홈 서비스를 위한 ANN의 역할에 초점을 맞춘 조사 논문으로는 [101]을 참조하기 바란다. Ermes 등 [102]은 조정, 자전거 타기, 축구, 걷기, 달리기, 앉기 또는 하이킹과 같은 활동을 인식하기 위해 선험적 지식과 ANN으로 구성된 트리 구조를 사용하는 하이브리드 분류기 접근 방식을 제안했다. Ciabattini 등 [103]은 주어진 시간 동안 태양광 발전소의 전력 생산과 가정 소비를 예측하기 위해 신경망 알고리즘을 사용하는 가정 에너지 매니지먼트 시스템 설계를 제안했다.

f) 딥러닝 알고리즘(Deep Learning Algorithms): 딥러닝 방법은 심층 아키텍처(다중 선형 및 비선형 변환을 포함하는 많은 계층)가 사용되는 인공 신경망(ANN)의 진화된 형태를 나타낸다[144]. 딥러닝의 약속 중 하나는 수동으로 선택한 기능을 효율적인 비지도 또는 준지도 학습 및 계층적 특성 추출 알고리즘으로 대체하는 것이다. 가장 일반적인 딥러닝 알고리즘[145]: 컨볼루션 신경망(Convolutional Neural Network, CNN), 순환 신경망(Recurrent Neural Network, RNN), 심층 볼츠만 머신(Deep Boltzmann Machine, DBM), 심층 믿음 신경망(Deep Belief Network, DBN), 적층 오토 인코더(Stacked Auto-Encoder). 딥러닝은 다양한 빅데이터 분석 애플리케이션, 특히 자연어 처리(NLP) 애플리케이션, 의료 진단, 주식 시장 거래, 네트워크 보안 및 이미지 식별에 성공적으로 사용되고 있다.

딥러닝은 이제 주요 비즈니스와 회사에서 보편적으로 사용되고 있다. 딥러닝 시스템에 대한 마이크로소프트의 연구는 중국어와 영어 간의 실시간 음성 번역 시스템을 제시했다[146]. 애플의 시리(Siri)는 딥러닝 학습 모델을 사용하고 구글 안드로이드 폰의 음성 인식도 딥러닝 학습 모델을 사용한다[147]. 딥러닝은 모델이 고차원 데이터에서 효율적으로 학습할 수 있도록 하는 드롭 아웃(Drop-out) 및 컨볼루션과 같은 여러 기술을 활용한다. 그러나 딥러닝은 모델에 필요한 추정 매개변수의 크기 때문에 다른 알고리즘에 비해 학습하는 데 훨씬 더 많은 데이터가 필요하다.

스마트 빌딩 애플리케이션(Application in SBs): Choi 등 [114]은 건물 내 다양한 인간 활동을 예측하기 위한 딥러닝 프레임워크를 기반으로 두 가지 예측 알고리즘인 심층 믿음 신경망과 제한 볼츠만 머신을 제안했다. 또한 인간 행동을 예측하기 위해 결합된 하이브리드 모델을 제시했다. 이 논문[115]은 가속도계, 자이로스코프 또는 자기장 센서와 같은 멀티모달 웨어러블 센서에 적합한 인간 활동 인식을 위해 컨볼루션 및 순환 신경망(RNN)에 기반한 은닉 마르코프 모델의 하이브리드 접근법을 제안한다. Alsheikh 등 [116]은 3축 가속도계를 사용하여 인간 활동 인식을 위해 딥러닝 및 은닉 마르코프 모델의 하이브리드 접근법을 제안하였다. Baccouche 등 [117]은 인간 활동을 분류하기 위해 2단계 신경 기반 심층 모델을 제안하며, 모델의 첫 번째 단계는 컨볼루션 신경



망을 기반으로 자동으로 학습된 시공간적 특성이다. 그런 다음 모델의 두 번째 단계에서는 순환 신경망(RNN)을 사용하여 각 시간 단계에 대해 학습된 특성의 전체 시퀀스를 분류한다. [118]에서는 컨볼루션 신경망을 사용하는 가속도 기반 인간 활동 인식 방법을 제안한다. [119]에서는 스마트 폰에서 가속도계와 자이로스코프를 사용하여 인간 활동을 인식하는 자동 특성 추출기 및 분류기로서 심층 컨볼루션 신경망을 제안한다. Hammerla 등 [148]은 웨어러블 센서를 사용하여 인간 활동 인식을 위한 심층, 컨볼루션 및 순환 접근법의 성능을 탐색한다. 성능을 측정하기 위해 저자는 웨어러블 센서에서 수집된 모션 데이터를 구성을 포함하는 세 가지 대표적인 데이터셋을 사용했다.

g) 은닉 마르코프 모델(Hidden Markov models, HMM): 은닉 마르코프 모델은 다른 확률 과정에 의해 방출되는 관찰된 기호 시퀀스를 통해 관찰할 수 있는 숨겨진 기본 확률적 프로세스를 가진 이중 확률 과정이다.

스마트 빌딩 애플리케이션(Application in SBs): Wu 등 [113]은 장애인에게 서비스를 제공하기 위해 사용자 행동을 예측하는 향상된 은닉 마르코프 모델을 제안했다. 또한 고정 상태 변환 매트릭스 대신 활용될 시간 상태 변환 매트릭스를 개발했다. Lv와 Nevatia [112]는 신체 재할에 대한 실시간 평가와 피드백을 가능하게 하기 위해 3차원 인간 활동의 자동 인식 및 분할에 은닉 마르코프 모델을 사용했다. Cheng 등 [110]은 일상생활 인식 기능의 포괄적인 활동을 제공하는 은닉 마르코프 모델 기반 추론 엔진을 제안했다. 또한 정확성과 학습 능력을 향상시키기 위해 Viterbi와 BaumWelch 알고리즘을 모두 통합했다. Chahua 등 [111]은 스마트 빌딩 환경에서 일상 생활 활동을 온라인으로 인식하기 위한 시퀀스 기반 모델을 제안했다. 또한 세 가지 시퀀스 기반 모델을 제시했다(은닉 마르코프 모델, 조건 임의 필드, 순차적 마르코프 논리 네트워크).

h) 시계열 분석(Time Series Analysis): 시계열은 시간을 기준으로 한 사례들의 집합이다. 시계열 데이터셋은 일반적으로 고차원적이고, 사례 수가 많으며, 지속적인 업데이트 등을 포함하는 아래의 특성을 갖는다[149]. 시계열 표현의 중요한 목적 중 하나는 차원을 줄이는 것이며, 모델 기반 표현, 비데이터 적응 표현, 데이터 적응 표현 등 세 가지 범주로 나뉜다[150][151].

스마트 빌딩 애플리케이션(Application in SBs): Survadevara 등[125]은 노인 수면 경향을 예측하기 위해 스마트 홈 환경에서 수면 활동 시나리오와 함께 계절적 자기 회귀 통합 이동 평균 시계열을 사용하는 웰빙 모델을 제안했다. Zhou 등 [126]은 스마트 빌딩의 데이터 센서의 경우 비정상 시계열 간의 관계를 탐색하기 위해 시계열 분석 프레임워크를 제안했다. Jakkula와 Cook [127]은 스마트 홈에서 거주자의 신체적, 도구적 활동을 관찰하여 시간적 규칙을 결정하기 위해 시계열 기반 프레임워크를 제안했다.

i) 회귀(Regression): 회귀 문제의 목적은 실제 값 목표 함수를 추정하는 것이다. 이는 모델에 의해 만들어진 예측에서 오차 척도를 이용하여 반복적으로 처리되는 변수 간의 관계를 나타내는 것과 관련이 있다[152]. 가장 일반적인 회귀 알고리즘은 선형 회귀, 로지스틱 회귀, 단계적 회귀, 일반 최소 제곱 회귀이다.

스마트 빌딩 애플리케이션(Application in SBs): Chen 등 [120]은 스마트 빌딩에서 에너지 효율성을 제공하는 물리적 및 환경적 매개변수를 식별하기 위해 직교 매칭 추구 알고리즘의 회귀 기법을 사용했다. Bouchard 등 [121]은 스마트 환경에서 몸짓 방향을 인식하고 일상적인 사용 활동의 지속적인 몸짓 세분화를 추정하기 위해 상관계수와 결합된 선형 회귀를 사용하는 몸짓 인식 시스템을 제시했다.

j) 앙상블 방법(Ensemble methods): 분류기 앙상블이라고도 하는 여러 분류기의 조합, 개별적으로 학습된 분류 모델 그룹 및 이러한 모델의 예측이 전체 예측을 생성하는 방식으로 결합된다[154]. 가장 인기있는 앙상블 학습 기반 분류 기법[155]: 랜덤 포레스트(Random Forest), 부스팅(Boosting), 그라디언트 부스팅 머신(Gradient Boosting Machine), 에이다 부스트(AdaBoost : Adaptive Boosting), 배깅(Bagging) 그리고 블렌딩(Blending).

스마트 빌딩 애플리케이션(Application in SBs): Jurek 등[122]은 스마트 홈 애플리케이션 영역 내 활동 인식을 위한 클러



연관규칙 학습이다. 일반적으로 사용되는 다양한 비지도 학습 알고리즘이 있으며, 이러한 알고리즘 중 일부는 선형적(Apriori) 알고리즘 및 k-평균(k-Means)과 같은 지도 학습 알고리즘을 기반으로 한다. 비지도 학습에서는 일반적으로 출력에 대한 측정이 없다. 특성만 인식하고 목표는 입력의 입력 측정 사이의 패턴과 관계를 정의하는 것이다[80]. 비지도 학습의 주요 단점은 학습 알고리즘의 방향이 없다는 점이며, 따라서 학습을 위해 선택된 속성 세트에 유용한 감지된 지식이 없을 수 있다. 군집화는 각 데이터 요소를 k-클러스터 그룹에 배치하여 데이터의 패턴을 감지하는 비지도 학습 방법으로, 각 그룹은 서로 가장 유사한 데이터 요소를 보유한다[157]. 비지도 학습 문제는 다음에서 설명하는 군집화 및 연관 문제로 분류할 수 있다.

a) 군집화(Clustering): 군집화 문제는 구매 습관에 따라 고객을 그룹화하는 것과 같이 입력 데이터의 내부 그룹화를 탐색한다. 군집화 기법은 일반적으로 중심 기반 및 계층 구조와 같은 모델링 전략으로 구성된다. 모든 방법은 데이터를 최대 공통성 그룹으로 적절하게 구성하기 위해 입력 데이터의 내부 구조를 처리하는 것과 관련이 있다[158]. 군집화 결과의 품질은 군집화 알고리즘을 사용하는 애플리케이션 유형에 따라 평가된다. 예를 들어, 제품 오차의 합은 일반적으로 데이터 군집화에 사용되는 반면, 피크 신호대 잡음비는 이미지 군집화에 사용된다[21]. 가장 일반적인 군집화 알고리즘은 k-평균값, k-중앙값, 기대 최대화 그리고 계층적 군집화이다. 스마트 빌딩 애플리케이션(Application in SBs): Fahad 등

[128]은 분류와 군집화를 결합하는 활동 인식 접근법을 제안하며, 이 접근법에서 활동 인스턴스는 Lloyd의 군집화 알고리즘을 사용하여 군집화된다. 그런 다음 K-최근린(KNN)과 Dampster Shafer 증거 이론을 결합한 증거 이론 K-최근린(evidence theoretic K-Nearest neighbor)을 적용한다. 연구 [86]는 스마트 환경에서 사용자 활동을 인식하고 예측하는 하이브리드 접근법을 제안한다. 그들은 K-패턴 군집화 알고리즘을 사용하여 매우 다양하고 복잡한 사용자 활동을 분류하고 K-최근린을 사용하여 개인실에서 사용자의 활동을 인식하고 예측한다. Lapalu 등 [82]은 스마트 홈에서 일상생활 활동의 학습 문제를 해결하기 위해 비지도 학습 방식을 사용했다. 그들은 알츠하이머병과 같은 일부 유형의 치매로 고통받는 사람들을 돕는 인지 보조 서비스에서 사용 사례의 군집화 분석을 위해 Flocking 알고리즘을 사용한다. Aicha 등[83]은 마르코프 변조 푸아송 프로세스 모델을 기반으로 스마트 홈 환경에서 노인의 비정상적인 방문을 감지하기 위한 비지도 학습 접근법을 제시한다. 이 모델은 현관 센서 전환 및 일반 센서 전환과 같은 여러 데이터 스트림을 결합했다. 소셜 커뮤니케이션 서비스(Social Communication Services)의 다른 사례: Cook 등 [129]은 사회적 상호작용을 감지하고 스마트 공간에서 일상 생활을 모니터링하기 위해 비지도 학습 접근법을 적용했으며, 이들의 접근법은 거주자의 암시적이고 명시적으로 식별된 피드백으로부터 발견된 패턴의 변화를 반영하도록 자동으로 적응하고 업데이트할 수 있다. Rashidi 등 [130]은 스마트 환경에서 개인의 일상에서 일반적으로 발생하는 정상적인 활동을 식별하고 추적하는 비지도 방법을 소개한다. 시스템의 활동 탐색 방법은 간단한 k-평균 알고리즘을 기반으로 시퀀스를 클러스터링하기 위해 생성된다. Fiorini 등 [159]은 스마트 빌딩의 저수준 센서에서 수집된 주

석없는 데이터를 사용하여 거주자의 행동 패턴을 식별하는 비지도 머신러닝 접근법을 제안했다. 그들의 접근법에는 다양한 센서를 갖춘 지역사회 기반 가정에 살고 있는 17명의 노인들의 일상생활 활동과 관련하여 수집된 데이터를 처리하고 분석하는 것이 포함된다. 하루 중 다른 시간에 수집된 데이터에서 활동 정보를 추출한다.

b) 연관(Association): 연관 규칙 학습 문제는 입력 데이터의 많은 부분을 정의하는 규칙을 식별하는 데 활용된다. 예를 들어, X 항목을 구입하는 사람은 Y 항목을 구매하는 경향이 있다. 연관 분석은 if/then 문장에 대한 입력 데이터를 분석하고 지원 및 신뢰 기준을 사용하여 관계형 데이터베이스 또는 다른 정보 저장소에서 관련없는 데이터 간의 관계를 탐색함으로써 탐색된 규칙에 대해 수행된다. 여기서 ‘지원(support)’은 항목이 데이터베이스에 나타나는 빈도를 나타내고 ‘신뢰도(confidence)’는 if/then 문장이 참인 것으로 확인된 횟수를 나타낸다. 연관 규칙을 생성하기 위한 많은 알고리즘이 제안되었다. 선형적 알고리즘(A Priori Algorithm)은 가장 잘 알려진 연관 알고리즘이다[160].

스마트 빌딩 애플리케이션(Application in SBs): Aztiria 등 [161]은 연관, 워크플로우 마이닝, 군집화 및 분류 기술을 사용하여 인간 행동의 빈번한 패턴을 학습하는 시스템을 제안했다. 시스템의 핵심 부분은 패턴의 표준 개념화를 제공하는 언어 모듈과 패턴을 발견하는 알고리즘 모듈의 두 개의 모듈로 구성된 학습 계층이다. Kang 등 [162]은 스마트 빌딩 환경의 모든 장치의 상태에서 추출한 연관 규칙을 해석하기 위한 서비스 시나리오 생성 체계를 제안했다. 일반적으로 이러한 상태는 장치에서 특정 시간 간격으로 주기적으로 수집된다. Nazerfard 등 [163]은 스마트 홈에서 시간 연관 규칙 기술을 사용하여 활동의 일시적 순서와 시작 시간 및 기간을 포함하여 활동의 시간적 특성을 탐색하기 위한 프레임워크를 제안했다.

3) 준지도 학습(Semi-Supervised Learning): 준지도 학습은 지도 방법과 비지도 방법 사이에 있다. 입력 데이터는 라벨이 있는 샘플과 라벨이 없는 샘플의 합성물이다. 이러한 하이브리드 알고리즘은 주요 범주의 강점을 계승하면서 약점을 완화하는 것을 목표로 한다. 이 모델은 데이터에 존재하는 패턴을 학습하고 예측도 한다. 문제의 예는 분류와 회귀가 있다[164]. 생성 모델, 휴리스틱 접근법, 준지도 서포트 벡터 머신, 그래프 기반 방법, 자율 학습, 도움말 학습, 혼합 모델, 협동 학습(Co-training) 및 다중시점 학습을 포함하는 몇 가지 일반적인 준지도 학습 모델이 있다[94].

스마트 빌딩 애플리케이션(Application in SBs): Cook [131]은 스마트 홈에서 개별적으로 생활하는 데 어려움을 겪는 사람들을 위해 건강 모니터링 및 상황 인식 서비스를 지원하는 활동을 인식하고 따를 수 있도록 완전 지도 학습 및 준지도 학습을 결합했다. Liu 등 [132]은 가장 높은 확신으로 활동을 해석하여 인간 활동의 라벨링 과제를 극복할 수 있도록 낙상 감지 및 스마트 환경에서의 기타 일상 생활을 인식하는 비전 기반 준지도 학습 접근법을 제안했다. Fahmi 등 [133]은 학습 과정에서 의사결정 트리를 활용한 지도 알고리즘과 프로파일 사용 해 복수의 임계값을 기반으로 하는 준지도 알고리즘을 구현하는 준지도 낙상 감지 접근법을 제안했다. Radu 등 [134]은 사용자가 실내 또는 실외에 있는지 확인하는 문제를 고려하여 스마트폰의 저전력 센서만 사용하는 준지도 머신

러닝 방법을 제공한다. Guan 등 [135]은 제한된 수의 라벨이 있는 샘플로 활동 학습의 성능을 향상시키기 위해 사용 가능한 라벨이 없는 샘플을 사용하기 위해 En-Co-training이라는 활동 인식을 위한 반지도 학습 알고리즘을 제안한다. 제안된 알고리즘은 앙상블 방법을 사용하여 co-training(협동 학습) 패러다임을 확장한다.

4) 강화 학습(Reinforcement Learning): 강화 학습은 장기 목표를 나타내는 성과 측정을 극대화하기 위해 시스템을 제어하는 학습 접근법이다[165]. 행동주의 심리학의 영감을 받은 머신러닝 분야인 강화 학습은 누적 보상 개념을 극대화하기 위해 소프트웨어 에이전트가 환경에서 조치를 취해야 하는 방식과 관련이 있다. 강화 학습 알고리즘은 특히 사전 지식이 없고 방대한 양의 학습 데이터가 있는 경우 제어 정책을 학습한다. 강화 학습 알고리즘은 특히 선형지식이 없고 다량의 연습데이터가 있을 경우 제어 정책을 학습한다. 그러나 강화 학습 알고리즘의 단점은 최적의 솔루션을 선택하기 위



해 모든 상태를 방문해야 하는 등 최적의 솔루션을 찾는 데 필요한 많은 계산 비용이 요구되는 점이다. 강화 학습의 잘 알려진 접근법은 브루트 포스(Brute force), 몬테카를로 법(Monte Carlo method), 시간 차이 방법(Temporal difference methods) 및 가치 함수(Value function)이다[166]. Q-학습(Q-learning)[167]은 주어진 상태 결정에 따라 필요한 유틸리티를 학습하는 데 기반한 모델없는 강화 학습 접근법이다. 스마트 빌딩 애플리케이션(Application in SBs): Mozer [136]은 건물 내 조명을 켜고 끄는 시간을 예측하기 위해 조명 조절에 Q-학습을 적용했다. 이 예측 모델은 효율적인 에너지 소비 제안을 위해 건물의 조명 활성화 일정을 잡는데 활용할 수 있다. Li와 Jayaweera [137]는 보다 효율적이고 유연하며 적응력이 뛰어난 방법을 제공하기 위해 Q-학습 기반 근사 동적 프로그래밍 알고리즘을 제안했다. 이러한 접근법을 통해 고객을 스마트 빌딩 환경에서 최적의 온라인 의사결정을 내릴 수 있어 완전히 관찰 가능한 지역 및 건물의 숨겨진 추정 정보를 기반으로 수익을 극대화할 수 있다. Khalili와 Aghajan [138]은 스마트 빌딩 환경에서 사용자의 서로 다른 상태가 존재하는 상황에서 사용자의 음악 선호도 및 조명 서비스 설정에 대한 자율 학습을 위한 강화 학습 방법의 시간적 차이 클래스(Temporal Differential Class)를 제안했다. 이 모델에서는 제공된 서비스에 반응할 때 사용자의 명시적 또는 암시적 피드백을 사용하여 선호도를 학습한다. Xu 등[139]은 합수 근사를 사용하여 강화 학습 알고리즘의 개발을 조사한다. 그들은 몇 가지 벤치마크 학습, 예측 및 학습 제어 과업을 사용하여 서로 다른 강화 학습 알고리즘을 평가하고 비교했다.



B ML TASKS FOR SBS

In this section, we will describe the major ML tasks that are relevant for SB


B. ML Tasks for SBs

스마트 빌딩을 위한 머신러닝 테스트
여기에서는 스마트 빌딩과 관련된 주요 머신러닝 과업을 설명한다. 스마트 빌딩의 머신러닝 과업과 스마트 빌딩 환경에서 머신러닝을 구현하기 위한 단계에 대한 일반적인 설명은 그림 8을 참조한다.
1) 데이터 수집 및 수신(Data Collection and Acquisition): 다양한 데이터 수집 접근법이 사용되며 각 접근법은 능력, 에너지 효율성 및 연결 측면에서 서로 다른 거래를 한다. 스마트 빌딩의 센서 및 유사한 개체는 자동화된 방식으로 동시에 원시 데이터를 생성하며, 이러한 장치는 특정 기간 동안 데이터를 저장하거나 제어된 구성요소에 대한 데이터를 보고할 수 있다[168]. 데이터는 게이트웨이에서 수집될 수 있다. 수집된 데이터는 필터링 및 처리되고 효율적인 전송을 위해 압축한 형태로 통합된다. Zigbee, Wi-Fi 및 셀룰러 등 다양한 통신 기술을 사용하여 데이터를 수집 지점으로 전송한다. 글로벌 규모의 스마트 사물 배포에서 수집된 데이터는 의사결정 및 서비스 제공의 기반을 정의한다. 활용된 데이터의 품질이 좋지 않을 때 결정을 신뢰할 수 없을 수 있다[169].

Zhao 등 [170]은 건물에 설치된 터미널 계량기에서 에너지 소비 데이터(예를 들면 전기, 수도, 가스, 난방 등)를 수집하는 모니터링 시스템에 사용할 수 있는 데이터 수집 및 전송 시스템을 제안한다. 시스템은 데이터를 분석하고 처리한 후 주기적으로 데이터를 저장하고 최종적으로 이더넷을 통해 서버로 전송한다. Rowley 등 [171]은 새 건물과 개조된 실제 상황에서 모두 빌딩 에너지 인프라 제공을 지원할 수 있는 데이터 수집 및 모델링 접근법을 제안한다. 이러한 방법은 다목적 지속가능한 결과에 대한 가능한 시나리오 경로의 단기, 중기 및 장기 예측을 달성하는 수단을 제공한다.
CLEEN MMEA [172] 데이터를 수집, 처리 및 관리하고 상황별 지식 추출을 시작하는 플랫폼이다. 목적은 데이터를 수집하고 다양한 회사에 서비스를 제공하기 위한 온라인 마켓플레이스를 구축하는 것이다. 인터페이스는 공개되므로 모든 회사가 네트워크에 쉽게 가입하여 서비스를 구입하거나 판매할 수 있다. 분석 결과는 소유자에게 서비스를 제공하기 위해 에너지 서비스 회사에 제공할 수 있다. 오픈 액세스 데이터 수집 시스템의 전형적인 예는 VTT가 핀란드 지방 자치 단체와 공동으로 개발한



e3Portal [173]이다. e3Portal은 자치 건물의 절약 조치 및 에너지 보강 계획을 수립할 때 정보와 도구를 제공한다. 또한 학교, 유치원, 사무실, 병원, 기타 의료 퍼실리티 등과 같은 수천 개의 공공 퍼실리티에서 에너지 및 물 소비와 관련하여 자주 업데이트되는 데이터를 포함한다. 의사 결정권자, 설계자들, 오퍼레이션 및 매니지먼트 담당자들 그리고 건물 사용자들도 이를 활용할 수 있다.
추가 연구를 수행하기 위해 연구자들이 공적으로 이용할 수 있는 스마트 빌딩 데이터셋을 제공하는 프로젝트들이 있다. 'Home Datasets' [174] 목록에는 UC 버클리, MIT, 워싱턴 주립대학, 암스테르담 대학, 에딘버러 대학 및 도쿄 대학의 프로젝트에서 수집한 데이터셋이 포함된다. UC 버클리의 NSF TRUST Center에서 지원하는 WARD [175] 프로젝트는 웨어러블 동작 센서 네트워크를 사용하여 인간 행동 인식을 위한 벤치마크 데이터셋을 제공한다. 이 데이터셋은 19세에서 75세 사이의 13명의 남성과 7명의 여성 참가자에 의한 13건의 반복 동작에서 수집되었다. MIT 프로젝트 [176]는 2주 이내에 2개의 1인 아파트에서 일일 활동 데이터셋을 수집했다. 개폐 이벤트를 기록하기 위한 84개의 센서가 서랍, 냉장고, 용기 등과 같은 다양한 디바이스와 장치에 부착되었다. Baos 등 [177]은 신체의 여러 부분에 부착된 다양한 관성센서(Inertial Measurement Unit, IMU)에서 수집한 개방형 벤치마크 데이터셋을 도입했다. 그들은 17명의 참가자가 9개의 관성센서 장치를 사용하여 기록된 33개의 피트니스 활동을 고려했다. 워싱턴주립대학교의 CASAS 프로젝트 [178]는 욕실 1개, 부엌 및 거실이 있는 침실 3개짜리 아파트에 대한 공개 데이터셋을 제공한다. 온도 측정값을 지원하기 위해 다양한 유형의 동작 및 디지털 센서가 설치되며, 온수, 냉수, 스토브 버너 사용 판독 값을 지원하기 위해 아날로그 센서가 설치된다[179]. MIT의 PlaceLab 프로젝트[180]는 동작, 스위치 및 RFID 센서를 포함하여 900개 이상의 센서가 있는 원룸 아파트에서 수집한 데이터셋을 제공한다. 이는 스마트 홈의 맥락에서 환경의 활동을 모니터링하는 데 사용된다. 영국의 5개 주택에서 스마트 미터 데이터셋[182]은 4억 개의 사례로 구성된다. 유효 전력은 6초마다 서로 다른 기기와 집 전체 전력 수요에 의해 형성된다. 데이터 수집에서 발생하는 주요 과제는 확장성, 개인 정보 보호, 보안 및 자원의 이질성이다 [183]. 자동화된 센서 데이터 수집 프로세스는 IoT 기기 및 소셜 미디어와 같은 다른 소스에서 수집된 데이터에 비해 수집 및 분석 센터를 압도하는 대량의 데이터를 수집한다. 이로






Fig. 8: ML tasks in SB environment.

스마트 빌딩 환경에서 머신러닝 테스트

인해 데이터베이스 스토리지 시스템에 수많은 소규모 동시 쓰기 작업이 발생하여 결과적으로 스토리지 시스템 설계에 심각한 성능 병목 현상이 발생한다[184]. RFID 기술의 광범위한 사용으로 인해, 데이터 수집에서 개인 정보 문제가 발생한다. 예를 들어, 개인이 휴대하는 RFID 태그는 해당 개인의 고유한 식별자가 될 수 있다. 또한, 예를 들어 RFID 기술의 무선 신호가 쉽게 방해받는 등 다른 보안 문제가 나타난다. 따라서, 이는 데이터 수집 과정을 방해할 수 있다[185]. 서로 다른 리소스에서 수집되는 데이터의 이질성은 또 다른 주요 과제이다. 따라서 데이터는 매우 잡다하고 대규모이며 분산되어 있다. 따라서 기존 데이터 처리 기법에 대한 명확한 설명 없는 수집된 데이터를 효과적으로 사용하기가 매우 어렵다[184].

2) 데이터 전처리(Data Preprocessing): 스마트 빌딩의 센서는 많은 양의 데이터를 생성한다. 이 데이터는 다양한 형식과 구조를 가진 다양한 소스에서 제공된다. 일반적으로 이 데이터는 배터리 전원 부족, 교정 불량, 다양한 악성 요소에 대한 노출 및 간섭으로 인해 불완전하거나 중복될 수 있으므로 분석할 준비가 되지 않았다. 따라서 원시 데이터는 일반적으로 누락된 데이터를 처리하고, 노이즈가 큰 중복 데이터를 버리고, 스토리지에 넣기 전에 다양한 소스의 데이터를 통합 스키마로 통합하기 위해 전처리되어야 한다. 이 전처리를 데이터 클리닝(Data Cleaning)이라고 한다. 데이터가 최종 사용자에게 도착하기 전에 데이터에 몇 가지 클리닝 기법을 적용함으로써 데이터의 품질을 크게 개선할 수 있다[168][186]. 데이터 클리닝은 데이터 처리 단계에서 중요한 과업 중 하나이다. 데이터 클리닝은 IoT 데이터 처리에 특화된 새로운 프로세스가 아니다. 데이터베이스 매니지먼트 시스템에 대한 프로세스로 이미 적용되었다. 데이터 클리닝

방법 제시는 애플리케이션이 데이터 신뢰성 후처리 오버헤드에 대한 걱정없이 핵심 로직에 집중하도록 도와줄 것이다[184].

Kalman 필터 [187], 통계 모델 [186] 및 이상값 감지 모델 [184]과 같은 노이즈가 많은 데이터 스트림을 정리하는 문제를 처리하기 위해 사용된 많은 다양한 기술이 있다. 스마트 빌딩의 데이터 클리닝 기법의 주요 과제 중 하나는 다양한 소스, 특히 WSN 및 RFID 지원 데이터 스트림에서 수집된 데이터의 이질성이다. 활용된 데이터 클리닝 기법은 관측된 외부 온도, 사용자 습관, 에너지 매니지먼트 등을 기반으로 가정 온도를 설정하는 것과 같이 IoT 애플리케이션의 요구사항을 충족하는 몇 가지 관심 변수를 처리할 수 있어야 한다[169]. 데이터 수집 과정에서 센서 장애, 네트워크 문제, 카메라 장애 또는 데이터베이스 충돌과 같은 모든 유형의 장애는 데이터를 무효화한다. 결과적으로 이러한 유형의 장애는 데이터 수집에 필요한 시간을 극적으로 증가시킬 것이다[179].

3) 차원 축소(Dimensionality Reduction): 스마트 빌딩에 사용되는 기기종 및 유비쿼터스 센서에서 수집되는 방대한 양의 원시 데이터가 있다. 이러한 센서에서 수집된 데이터의 대부분은 중복되며 중요한 정보를 손실하지 않고 차원 축소 기법을 적용하여 더 적은 수의 특성으로 축소해야 한다[188]. 차원 축소 전략의 주요 아이디어는 중요한 정보의 손실 없이 훨씬 적은 특성으로 입력 데이터를 표현할 수 있는 새로운 좌표계를 찾는 것이다. 차원 축소는 두 가지 다른 방법으로 수행할 수 있다: 중요한 데이터 특징을 나타내는 특성을 추출하거나(이 기술을 특성 추출이라고 함), 또는 근원 데이터셋에서 가장 관련성이 높은 특성만 선택하는 방법(이 방법을 특성 선택이라고 함)[189][190].

군집화 방법과 마찬가지로 차원 축소 접근법은 데이터의 내부 구조를 탐색하고 활용하지만, 이 경우에는 더 적은 정보를 사용하는 비지도 방식으로 활용한다. 이러한 기법의 대부분은 분류 및 회귀 문제에 활용될 수 있다. 몇 가지 두드러진 알고리즘의 예[153]: 주성분 분석(Principal Component Analysis, PCA), 주성분 회귀 분석(Principal Component Regression, PCR), 선형 판별 분석(Linear Discriminant Analysis, LDA). Chen 등 [191]은 웨어러블, 물체 및 주변 센서에서 인간 활동 인식에 대한 데이터셋의 차원수를 줄이기 위해 데이터의 로컬 기하학의 분류 정보를 사용하는 프레임워크를 제안한다.

a) 특성 추출(Feature Extraction): 근원 데이터의 주요 구성요소는 특성이다. 원시 데이터셋에서 특성을 추출한 후 이러한 특성에는 활동 식별을 위해 학습 알고리즘에서 사용하는 중요한 정보가 포함되어 있다. 특성 추출의 가장 일반적인 방법은 시간, 주파수 및 이산 영역에서 작동한다[192]. 시간 영역 방법 중 평균 및 표준 편차는 거의 모든 센서 유형에 대한 주요 접근법이다. 주파수 영역 방법은 수집된 데이터의 주기적 구조에 초점을 맞춘다. 웨이블릿 변환(Wavelet Transformation) 및 푸리에 변환(Fourier Transform)이 가장 일반적인 접근법이다. 또한 유클리드 기반 거리(Euclidean-based distances), 동적 시간 왜곡(Dynamic Time Warping) 및 레벤슈테인 편집 거리(Levenshtein edit distance)와 같은 이산 영역 방법은 문자열 유사성, 인간 활동 분류 및 인간 행동 패턴 모델링(Human Behavioral Patterns)과 같은 여러 애플리케이션에서 구현된 주요 접근법이다[16][193].

b) 특성 선택(Feature Selection): 특성 선택의 주요 역할은 특성의 고차원 벡터 내에서 가장 관련성이 높은 특성의 하위 집합을 구별하여 학습 모델에 대한 노이즈(Noise) 및 계산 비용을 줄이는 것이다. 특성의 고차원 벡터를 저차원 벡터에 매핑하기 위해 선형 판별 분석(Linear Discriminant Analysis, LDA), 주성분 분석(Principal Component Analysis, PCA), 독립 성분 분석(Independent Component Analysis, ICA)과 같은 몇 가지 일반적인 알고리즘이 사용된다[194]. Hausmann과 Ziekow [195]는 래퍼(Wrapper) 방법과 유전자 최적화를 기반으로 시계열 데이터에서 스마트 빌딩 애플리케이션 머신러닝 모델에 대한 특성 선택을 자동으로 조정하는 접근법을 제안했다. Fahad 등 [196]은 복수의 위치 및 물체에 배치된 센서에서 얻은 가장 중요한 정보와 가장 중요한 특성을 구분하는 K-최근접 접근법을 사용하여 중복 활동에 대한 활동 인식 접근법을 제안한다. Fang 등 [197]은 서로 다른 특성 셋이 인간 활동을 인식하는 데 있어 서로 다른 수준의 정확도를 발생시키고, 부적절한 데이터셋을 선택하면 스마트 홈 환경에서 계산 복잡성이 증가하고 예측 정확도가 감소한다고 판단한다. 래퍼와 필터링은 특성 선택 문제의 두 가지 주요 통계 방법이다. 래퍼 접근법이 더 나은 성능을 얻을 수 있지만, 필터는 리소스 집약적이지 않고 더 빠르다는 주장이 있다[198]. [199]에서는 관찰된 센서로부터 인간 활동을 인식하기 위해 학습 문제의 차원 축소 과정에 다양한 특성 선택 방법이 활용된다. 저자들은 인간 활동을 인식하는 학습 모델의 성과가 활용된 특성과 밀접한 관계를 가지고 있음을 보여준다.

c) 특성 투영(Feature Projection): 특성 투영은 원래 특성 세트에서 학습 기준을 최적화하는 적절한 세트로의 매핑으로

표현될 수 있다. 따라서 특성 투영 접근법은 고차원 특성 벡터를 저차원 특성 벡터로 시각화하고 매핑하는 프로세스를 가능하게 하며, 또한 축소된 특성 벡터의 분포를 분석할 수 있다[200]. 결과적으로, 특성 투영 접근법은 패턴 인식의 처리 시간을 단축하고 축소된 형상 벡터에 대해 가장 적합한



분류기를 선택할 수 있도록 한다. 따라서 실시간 구현이 가능하다[198]. Chu 등 [201]은 9가지 손 동작 인식을 시도한 EMG 패턴 인식에 LDA 알고리즘을 활용하는 선형 지도 특성 투영을 제안했다.

C. ML Tools & Platforms for SBs

스마트 빌딩을 위한 머신러닝 툴 및 플랫폼 학습 과정을 지원하기 위한 다양한 기존 머신러닝 플랫폼과 툴(Tool)이 있다. 현재 이러한 종류의 툴킷의 수가 증가함에 따라 다양한 소스의 빅데이터 스트리밍을 처리하는 데 적합한 툴을 선택하는 일은 여전히 어려울 수 있다. 일반적으로 모든 문제에 맞는 솔루션을 제공하는 단일 툴킷은 없다. 사용 가능한 툴킷의 대부분은 용도가 중복될 수 있으며 각각 장단점이 있다 이러한 툴킷의 대부분은 프로그래밍 언어 및 시스템 아키텍처 분야의 경험이 필요할 수 있다. 또한 일반적으로 많은 사람들이 기능과 이용 가능한 플랫폼 사용 방법에 대해 완전히 이해하지 못한다[202]. 특정 머신러닝 툴을 선택할 때 고려해야 할 중요한 요소는 확장성, 속도, 적용 범위, 사용성, 확장성 및 프로그래밍 언어 지원이다. 확장성 요소와 관련하여 데이터의 크기와 복잡성을 고려하여 특정 툴킷이 적합한지 결정해야 한다. 라이브러리가 실행되는 처리 플랫폼과 알고리즘의 복잡성이 속도 요소에 영향을 미친다. 모든 프로젝트가 속도 요소에 우선 순위를 두는 것은 아니다. 모델에 빈번한 업데이트가 필요한 경우 속도가 중요한 문제가 될 수 있지만, 그렇지 않은 경우도 있다 적용 범위는 툴에 구현된 머신러닝 알고리즘의 수를 나타낸다. 이기종 소스에서 대량의 데이터를 캡처하는 머신러닝 커뮤니티는 머신러닝 모델이 빅데이터를 효율적으로 처리하고 이를 통해 학습할 수 있는 방법에 대한 과제에 직면해 있다.

일반적으로 사용 가능한 빅데이터 툴은 모든 상이한 종류의 머신러닝 알고리즘을 모두 구현하지는 않으며, 보통 적용 범위는 수십 개의 알고리즘에서 약 24가지 알고리즘의 범위이다. 유용성 요소에는 초기 설정 처리, 지속적인 유지관리, 사용 가능한 프로그래밍 언어 및 사용자 인터페이스, 문서의 양 또는 지식 있는 사용자의 가용성과 같은 요소가 포함된다. 확장성 요소는 툴에 도입된 구현을 새로운 시스템을 위한 빌딩 블록으로 활용할 수 있음을 의미한다. 툴이 이러한 요소를 얼마나 잘 충족할 수 있는지 평가할 필요가 있다. 다양한 프로그래밍 언어로 사용할 수 있는 다양한 머신러닝 라이브러리가 있다. 수행하려는 과업에 따라 특정 언어, 라이브러리 및 툴이 다른 것보다 더 효과적일 수 있다. 다음은 가장 많이 사용되는 딥러닝 및 머신러닝 툴의 강점과 약점을 자세히 살펴 본 내용이다. 또한 표 VI에 설명된 딥러닝 및 머신러닝 툴의 간략한 표 요약을 참조한다.

1) H2O: H2O [203]은 병렬 처리, 분석, 데이터 전처리 및 평가 도구와 함께 머신 러닝 라이브 러리를 지원하는 빅 데이터 분석을 위한 오픈 소스 인메모리(in-memory) 분산 및 확장 가능한 머신러닝 프레임워크이다. 2011년 실리콘밸리에서 설립된 H2O.ai에서 제작했다. 이 제품의 가장 주목할 만한 특징은 심층 신경망을 위한 다양한 툴을 제공한다는 것이다. H2O 소프트웨어 API는 Python, Java, R 및 Scala에서 호출할 수 있다. 프로그래밍 전문 지식이 없는 사용자도 웹 기반 사용자 인터페이스를 통해 이 툴을 사용할 수 있다. H2O 프레임워크에서 제공하는 처리 엔진 외에도 사용자는 Spark 및 Storm과 같은 다른 사용 가능한 프레임워크와 모델을 통합할 수 있다. 알고리즘에 적합한 것에 따라 H2O의 엔진은 메모리에서 데이터를 완전히 처리하기 위해 여러 실행 방법을 사용한다. 일반적으로 사용되는 기술은 분산 Fork/Join으로, 신뢰할 수 있고 대규모 병렬 과업에 적합하다. H2O 소프트웨어는 마이크로소프트 윈도우즈, Mac OS X 및 리눅스(예: Ubuntu 12.04; CentOS)와 같은 다양한 운영체제에서 실행될 수 있으며, 빅데이터 분석을 위해 Apache Hadoop Distributed File System(HDFS) 및 Spark 시스템에서도 실행된다. 또한 Amazon EC2, Google Compute Engine 및 Microsoft Azure와 같은 다양한 클라우드 컴퓨팅 환경에서 작동할 수 있다. 2016년 7월 현재 H2O에서 지원되는 알고리즘은 과업 분류, 클러스터링, 일반화된 선형 모델, 통계 분석, 앙상블, 최적화 도구, 데이터 전처리 옵션 및 심층 신경망을 포함한다.

2) MLlib (Spark): MLlib [204]는 Apache Spark의 ML 라이브러리이다. MLlib는 확장 가능하고 사용하기 쉬운 기계학습(ML) 방법을 제공하는 것을 목표로 한다. 여기에는 분류, 회귀, 군집화, 차원 축소를 위한 공통 ML 알고리즘과 하위 레벨 최적화 기초 요소와 상위 레벨 파이프라인 API가 포함된다. SVM, 랜덤 포레스트, 로지스틱 회귀, 나이트 베이즈, 의사결정 트리 및 그래디언트 부스트 트리의 분류 기법이 지원되며, 반면 군집화의 경우 k-평균, 가우스 혼합 및 전력 반복 군집화가 지원된다. MLlib는 선형 회귀 및 등장(Isotonic) 회귀에 대한 구현을 지원하고 교대 최소 제곱을 사용하는 협업 필터링 알고리즘을 통합한다. PCA는 차원 축소를 위해 지원된다. MLlib에는 Scala, Java, Python 및 Spark R에서 개발하기 위한 API가 포함되어 있다. 일반적으로 MLlib는 Spark의 반복 배치 및 스트리밍 접근법뿐만 아니라 인메모리(in-memory) 계산 사용에 따라 달라진다.

3) TensorFlow: Tensorflow[205]는 데이터 흐름 그래프를 활용하는 다양한 지각 및 언어 이해 과업에서 수치 계산과 심층 ML을 위한 오픈 소스 소프트웨어 라이브러리이다. TensorFlow는 원래 Google Brain팀에서 개발했으며 2015년 11월에 Apache 2.0 오픈 소스 라이선스로 출시되었다. TensorFlow에는 딥러닝, 강화 학습 및 기타 알고리즘을 지원하는 툴이 있다. TensorFlow는 데이터 흐름 그래프를 구현한다. 여기서 ‘tensor(텐서)’는 그래프로 정의된 알고리즘 집합으로 처리할 수 있는 데이터 배치이다. 시스템을 통한 데이터 이동을 ‘flow(흐름)’이라고 하므로, TensorFlow라고 작명하였다. TensorFlow는 여러 CPU 및 GPU에서 실행할 수 있다. Linux, Mac OS X 데스크톱 및 서버 시스템에서 실행할 수 있으며, 로드맵에서 Windows 지원은 물론 Android 및 Apple의 iOS 모바일 컴퓨팅 플랫폼에서도 실행할 수 있다. TensorFlow는 C/C++ 엔진을 통해 Python API로 작성되어 빠른 속도로 실행된다. TensorFlow는 새로운 네트워크를 쉽게 정의하기 위해 벡터 연산 방법의 기호 그래프를 사용한다. 그러나 TensorFlow에는 모델링 유연성과 관련된 약점이 있다. 각 계산 흐름은 정적 그래프로 구성되어야 한다. 따라서 빔 탐색(Beam Search)과 같은 일부 계산이 어렵다.

4) Torch: Torch [206]는 다양한 머신러닝 알고리즘을 지원하는 오픈 소스 ML 컴퓨팅 프레임 워크이다. Torch는 원래 뉴욕대학에서 개발되었다. Lua 프로그래밍 언어에 기반한 스크립트 언어와 C/CUDA 구현 덕분에 Torch는 이식 가능하고, 빠르고, 확장 가능하며, 개발에 사용하기 쉽다. Torch의 일부 버전은 구글 딥마인드, 페이스북 AI 리서치 그룹, IBM, Yandex 및 Idiap Research Institute와 같은 대기업에서 사용한다. 또한 안드로이드 및 iOS 플랫폼에서 실행되도록 확장되었다. Torch에 대한 다양한 커뮤니티 제공 패키지로 다양한 지원 및 기능을 제공한다. 컴퓨터 비전, 신호, 이미지, 비디오, 오디오 처리, 병렬 처리 및 네트워크를 지원하는 다양한 딥러닝 알고리즘을 제공한다[207].



5) Deeplearning4j: Deeplearning4j [221]는 오픈 소스 분산 DL 라이브러리이며, 샌프란시스코의 ML 그룹 소속 Adam Gibson이 주도적으로 개발하였다. DeepLearning4j는 Java 및 JVM을 위해 작성되었으며, 제한 볼츠만 머신, 심층 믿음 신경망, 컨볼루션 네트워크, 순환 신경망, 심층 오토 인코더, 스택 노이즈 자동 인코더, 재귀 신경 텐서 네트워크 등 다양한 DL 알고리즘을 지원한다. 이러한 모든 알고리즘은 분산 병렬 처리를 위해 Hadoop 및 Spark와 통합될 수 있다. Deeplearning4j는 Java 프로그래밍 언어에 의존하며, Clojure와 호환되며 Scala API를 포함한다. Deeplearning4j는 연구 툴이 아닌 비즈니스 환경에서 활용되도록 설계되었다. 사기 탐지, 이상 탐지, 추천 시스템, 이미지 인식 등 다양한 적용 분야에 적용된다.

6) Massive Online Analysis (MOA): MOA [222]는 데이터 스트림 마이닝 및 소유를 위한 일반적인 오픈 소스 프레임워크 중 하나이다. OA는 뉴질랜드 와이카토 대학에서 개발한 WEKA 프로젝트와 관련된 Java로 작성되었다. 여기에는 GUI, 명령줄 및 Java API에서 사용할 수 있는 일련의 학습자 및 스트림 생성기가 포함된다. MOA는 분류, 회귀, 군집화, 이상값 검출을 위한 다양한 머신러닝 알고리즘과 평가를 위한 일부 툴을 지원한다[223].

7) Caffe: Caffe [224]는 DL 프레임워크이며, 주로 표현, 속도 및 모듈성을 고려하여 개발되었다. C 및 C++로 포팅된 Matlab의 고속 컨볼루션 신경망을 위해 머신 비전 라이브러리를 활용한다. Berkeley 비전 및 학습 센터와 커뮤니티 공헌자들에 의해 개발되었다. Caffe에서 멀티미디어 과학자와 실무자들은 DL 알고리즘을 위한 체계적이고 최첨단 툴킷을 보유하고 있다. Caffe는 원래 기계 시각을 위해 개발되었으며 로봇 공학, 신경 과학, 음성 인식 및 천문학과 같은 다른 분야의 사용자가 활용하고 개선했다. 또한 Python 및 MATLAB 코드 바인딩을 지원한다. Caffe는 최첨단 컨볼루션 신경망(CNN) 알고리즘으로 이미지 분류를 제공한다. Caffe는 주로 Model Zoo 사이트에서 호스팅되는 사전 학습된 모델의 소스로 활용된다.

Caffe는 컨볼루션 신경망을 이용한 이미지 분석과 RCNN을 이용한 이미지 내 지역 분석에 유용하다. Caffe의 성능과 처리 속도는 Caffe가 연구 실험 및 산업 전계에 가장 많이 활용되는 플랫폼 중 하나가 되게 하였다. 단일 NVIDIA K40 GPU로 하루에 6천만 개 이상의 이미지를 처리할 수 있다. Caffe는 이미 UC 버클리와 다른 대학의 많은 연구 프로젝트에 적용되어 객체 분류, 객체 감지 및 의미 특성 학습(Learning Semantic Feature)과 같은 많은 과업에서 매우 잘 수행되고 있다. 또한 모델 교육, 테스트, 튜닝 및 배포를 위한 완벽하고 잘 문서화된 툴킷을 제공한다. Caffe는 다양한 일반적인 이미지 분류 과업에 적합한 Model Zoo라는 사전 학습된 신경망 모델의 대규모 저장소를 활용한다[225].

8) Azure ML: Microsoft는 2014년 6월에 Azure ML [226]를 프리뷰로 처음 출시했다. Azure ML을 통해 사용자는 모델을 만들고 학습시킨 다음 해당 모델을 다른 서비스에 적용할 수 있는 API로 변환할 수 있다. 사용자는 모델 데이터에 대해 계정 당 최대 10GB의 스토리지를 얻을 수 있지만, 더 큰 모델의 경우 자체 Azure 스토리지를 서비스에 연결할 수도 있다. 프로그래머는 Azure 서비스로 개발하기 위해 R 또는 Python 프로그래밍 언어를 사용할 수 있다. 사용자는 Microsoft Azure Marketplace에서 ML 알고리즘을 구입할 수 있으며, Microsoft에서 만든 커뮤니티 갤러리에서 무료로 ML 알고리즘을 받아 서로 공유할 수도 있다. 그들은 Cortana라고 하는 Windows Phone의 개인 비서에 대한 많은 예측 분석을 공유한다. Azure ML은 Xbox 및 Bing의 솔루션도 활용한다. Azure는 현재 Azure에서 Ubuntu Linux를 통해 Hadoop을 실행하는 것과 같은 다양한 기능을 지원하고 데이터 스트림 분석을 위한 Storm 호스팅도 지원한다. 또한 개발자가 .NET 및 Java 라이브러리를 Storm에 연결할 수 있다. Azure ML Studio는 교육, 점수 산정 및 유효성 검사 프로세스를 위한 다양한 모듈을 지원한다. Azure ML에는 예측 분석을 위한 알고리즘 라이브러리가 제공된다. 널리 사용되는 알고리즘 제품군은 회귀, 이상 탐지, 군집화 및 분류이다.

D. Real-time Big Data Analytics Tools for SBs

스마트 빌딩을 위한 실시간 빅데이터 분석 툴 일부 애플리케이션은 스트림 데이터에 대한 실시간 데이터 분석이 필요하며 정보가 보관되기를 기다린 후 분석하는 것은 이러한 유형의 애플리케이션에는 적합하지 않다. 일반적으로 스트림 처리는 대량의 데이터를 분석하고 SQL형 쿼리 등 연속 쿼리를 활용하여 확장 가능하고 고장 허용형 아키텍처를 활용하여 실시간으로 스트리밍 데이터를 처리하는 것을 목적으로 한다. 스트림 처리에 필수적인 것은 스트리밍 분석이다. 점점 더 많은 툴이 실시간 스트리밍 데이터의 가능성을 제공한다. 다음은 일반적이고 널리 사용되는 몇 가지 옵션을 제시한다.

1) Apache Storm: Storm [227]은 대규모로 확장 가능한 이벤트 컬렉션을 제공하는 오픈 소스 분산 실시간 데이터 처리 프레임워크이다. 최초 출시는 2011년 9월 17일에 있었고 Nathan Marz와 Back-Type의 팀이 만들었으며 현재는 Twitter가 소유하고 있다. Storm은 어떤 프로그래밍 언어로도 무제한 스트림을 쉽게 처리할 수 있다. 확장성이 뛰어나고 고장 허용성이 있으며 안정적인 아키텍처를 사용하여 노드당 초당 백만 개 이상의 튜플(Tuple)을 처리할 수 있다. Storm은 Java와 Clojure로 작성되었다. Trident는 Storm의 상위 레벨 추상화 계층으로, 상태 관리 지속성을 달성하는 데 활용할 수 있다. Storm은 복잡한 이벤트 처리 시스템이다. 이러한 유형의 솔루션을 통해 기업은 갑작스럽고 지속적인 데이터(센서에 의해 실시간으로 수집되는 정보, 트위터, WhatsApp 및 페이스북과 같은 소셜 네트워크에서 생성되는 수백만 건의 의견, 은행 이체 등)에 대응할 수 있다. Storm의 일부 특정 애플리케이션에는 실시간 고객 서비스 관리, 운영 대시보드, 데이터 수익화, 사이버 보안 분석 및 위협 탐지가 포함된다.

2) Apache Kafka: Kafka [228]는 빠르고 확장 가능하며 고장 허용성이 있으며 내구성이 뛰어난 오픈 소스 메시지 브로커 프로젝트이며, LinkedIn에 의해 개발되어 2011년 초에 오픈 소스가 공개되었으며 이후 2012년 10월 23일에 Apache Software Foundation에서 출시되었다. Kafka는 Scala로 작성되었다. 높은 처리량, 안정성 및 확장성 특성에 중점을 두고 다양한 사용 사례 시나리오를 지원한다. 예를 들어, 사무실 건물에 있는 냉난방 장비의 센서 데이터를 메시지로 보낼 수 있다.

3) Oracle: 2013년에 오라클(Oracle)은 모든 빅데이터 기술을 관리하기 위해 Oracle Big Data Appliance가 포함된 Oracle Enterprise Manager를 활용하기 시작했다. 오라클은 또한 Oracle Event Processing, Coherence, NoSQL, Business Analytics 및 Real-Time Decisions를 포함하여 Oracle Fast Data 구성요소를 위한 여러 개의 저지연 기술(low-latency technologies)을 개발했다. Oracle Event Processing은 실시간으로 이벤트를 필터링,

상관 및 처리하는 애플리케이션을 구축하기 위한 솔루션을 제공한다. 다양한 데이터 소스로부터의 데이터 스트리밍에 대한 실행 가능한 통찰력을 실시간으로 제공하여 IoT 서비스를 지원한다[229].

Oracle Stream Explorer (OSX) 및 Oracle R Enterprise (ORE)는 센서, 이상 감지 및 이러한 시스템의 장애 예측을 통해 다양한 구성요소로 구성된 시스템의 장비 모니터링 애플리케이션을 지원하는 것을 목표로 한다. ORE [230]는 배치 모드에서 저주파 스트림을 처리하는 데 사용되며, OSX는 실시간 예측을 통해 고주파 스트림을 처리하고 결과를 출력 채널과 통신하는 사용자 애플리케이션으로 다시 전송한다. OSX [231]는 센서, 소셜 미디어, 금융 피드 등과 같은 다양한 소스의 다양한 스트리밍 데이터 애플리케이션을 위해 실시간으로 대량의 스트리밍 데이터를 처리할 수 있는 기능을 갖춘 미들웨어 플랫폼이다. 또한 Apache Hadoop, Apache HBase, Apache Hive, Apache Flume 및 Apache Kafka를 비롯한 가장 인기있는 빅데이터 솔루션으로 실시간 데이터 전달을 간소화하여 통찰력을 개선하고 적시에 조치를 취할 수 있도록 지원한다. Oracle Real-Time Decisions [232]는 비즈니스 프로세스 내에서 메시징, 이미지, 제품 및 서비스를 통해 최적화된 권장사항과 행동을 결정하는 자체 학습 기능을 갖춘 의사결정 매니지먼트 플랫폼이다.

4) Amazon Kinesis Streams: Amazon Kinesis [233]는 AWS에서 대규모 데이터 스트림을 실시간으로 수집 및 처리하는 플랫폼이다. AWS는 2013년 11월에 Kinesis를 출시하여 스트리밍 데이터를 로드하고 분석하는 강력한 서비스를 제공하며, 전문화된 요구에 맞는 맞춤형 스트리밍 데이터 애플리케이션을 제공한다. 때로는 웹 애플리케이션, 모바일 장치, 웨어러블, 산업용 센서 등과 같은 다양한 애플리케이션 서비스에서 지속적으로 수집, 저장 및 처리해야 하는 시간당 테라 바이트(Terabyte)의 데이터가 생성될 수 있다. 일반적으로 Amazon Kinesis Streams 애플리케이션은 Amazon Kinesis Client Library를 사용하고 Amazon Kinesis 스트림의 데이터를 데이터 레코드로 읽을 수 있다. 이러한 애플리케이션은 Amazon EC2 인스턴스에서 실행될 수 있다.

5) Apache Spark Streaming: Apache Spark [234]는 실시간 데이터 처리를 위한 오픈 소스 플랫폼으로, 4가지 언어로 구현할 수 있다(플랫폼이 작성되는 구문인 Scala, 그리고 Python, R, Java). Spark Streaming은 핵심 Spark API의 확장이다. 실시간 데이터 스트림의 고장 허용성 처리를 구축할 수 있다. Spark Streaming을 사용하면 클러스터 간에 수백만 개의 데이터를 처리할 수 있으며 Spark SQL을 사용하면 SQL 언어를 통해 데이터를 보다 쉽게 활용할 수 있다. Spark Streaming은 라이브 데이터 스트림을 미리 정의된 배치 간격으로 분할한 다음 각 데이터 배치를 RDD(Resilient

TABLE VI: COMPARISON BETWEEN DEEP LEARNING AND ML TOOLS

딥러닝과 머신러닝 툴 비교

Tool	Creator	OS	Open Source?	Written In	Interface	CUDA support?	Algorithm	Release Date	Used in
TensorFlow	Google Brain team	Linux, Mac OS X (Windows support on roadmap)	Yes	C++, Python	Python, C/C++	Yes	Deep Learning Algorithm: RNN, CN, RBM and DBN	Novmber 2015	[208] [209]
Theano	Universit de Montral	Cross-platform	Yes	Python	Python	Yes	Deep Learning Algorithm: RNN, CN, RBM and DBN	September 2007	[210] [211] [212]
H2O	H2O.ai	Linux, Mac OS, Microsoft Windows And Cross-platform incl. Apache HDFS; Amazon EC2, Google Compute Engine, and Microsoft Azure	Yes	Java, Scala, Python, R	Python, R	No	Algorithms for classification, clustering, generalized linear models, statistical analysis, ensembles, optimization tools, data preprocessing options and deep neural networks.	August 2011	[213]
Deeplearning4	Various, Original author Adam Gibson	Linux, OSX, Windows, Android, CyanogenMod (Cross-platform)	Yes	Java, Scala, C, CUDA	Java, Scala, Clojure	Yes	Deep Learning Algorithms Including: RBN, DBN, RNN, deep autoencoder	August 2013	[214]
MLlib Spark	Apache Software Foundation, UC Berkeley AMPLab, Databricks	Microsoft Windows, OS X, Linux	Yes	Scala, Java, Python, R	Scala, Java, Python, R	No	Classification, regression, clustering, dimensionality reduction, and collaborative filtering	May 2014	[215]
Azure	Dave Cutler from Microsoft	Microsoft Windows, Linux	Yes	C++	C++, Java, ASP.NET, PHP, Node.js, Python	Yes	Classification, regression, clustering	October 2010	[216]
Torch	Ronan Collobert, Koray Kavukcuoglu, Clement Farabet	Linux, Android, Mac OS X, iOS	Yes	C, Lua	Lua, LuaJIT, C, Utility Library for C++/OpenCL	Yes	Deep Algorithms	October 2002	[217] [218]
MOA	University of Waikato	Cross-platform	Yes	Java	GUI, The Command-line, and Javaaa	No	ML algorithms (classification, regression, clustering, outlier detection, concept drift detection and recommender systems)	November 2014	[219]
Caffe	Berkeley Vision and Learning Center, community contributors	Ubuntu, OS X, AWS, unofficial Android port, Windows support by Microsoft Research, unofficial Windows port	Yes	C++, Python	C++, command line, Python, MATLAB	Yes	Deep learning algorithms: CN, and RNN	December 2012	[220]

Distributed Dataset)로 처리한다. 그런 다음 Map, Reduce, Join, Window 등과 같은 작업을 적용하여 이러한 RDD를 처리할 수 있다. 그런 다음 이러한 작업의 마지막 결과가 일괄 반환된다.

Spark Streaming은 실시간 모니터링 및 애플리케이션 서버 로그 분석 등 다양한 애플리케이션에 활용할 수 있다. 이러한 로그 메시지는 시계열 데이터로 간주된다. 이러한 데이터 유형의 예로는 센서 데이터, 날씨 정보 및 클릭 스트림(Clickstream) 데이터가 있다. 이 데이터는 과거 데이터를 기반으로 미래의 상태를 예측하는 데도 사용할 수 있다. Apache는 현재 Hadoop MapReduce가 메모리에서 제공하는 것보다 100배 더 빠르고 디스크보다 10배 더 빠른 연산 속도를 보장

한다. Spark는 Hadoop, Apache Mesos 및 EC2와 같은 서로 다른 프레임워크에서 독립 클러스터 모드 또는 클라우드에서 실행할 수 있다. 또한 Spark는 HDFS, Cassandra, HBase, 또는 Amazon의 데이터 웨어하우스인 S3와 같은 수많은 데이터베이스에 액세스할 수 있다.

6) Apache Flume: Flume [242]은 분산되고 신뢰할 수 있는 오픈 소스 로그 데이터 집계 프레임워크이다. Apache Flume은 로그 데이터 집계에서 네트워크 트래픽 데이터, 소셜 미디어 생성 데이터, 이메일 메시지 및 가능한 거의 모든 데이터 소스를 포함한 대량의 이벤트 데이터를 HDFS로 전송하기 위해 다양한 애플리케이션에 적용된다.



Technical
Standards
for Smart Cities
스마트시티 국제표준화
기반조성(R&D)

Technical
Standards
for Smart Cities
스마트시티 국제표준화
기반조성(R&D)

Flume의 아키텍처는 간단하고 유연하며 페일오버(failover) 및 복구를 위한 조정 가능한 안정성 메커니즘으로 견고하고 고장 허용성(Fault Tolerant)이다. 로그 제조 작업은 Flume 응용의 한 예이다. 대용량 로그 파일 데이터는 Flume을 통해 스트리밍할 수 있다. 로그 파일 데이터는 HDFS에 저장하고 Apache Hive를 활용하여 분석할 수 있다.

7) Apache SAMOA: SAMOA [243]는 분산 스트리밍 ML 알고리즘에 대한 프로그래밍 추상화를 포함하는 분산 스트리밍 ML 프레임워크이다. 그 이름은 Scalable Advanced Massive Online Analysis의 약자로서 원래 야후!(Yahoo!)에서 개발되었다. 연구소는 2013년 바르셀로나에 있었으며 2014년 말부터 Apache 인큐베이터에 참여하고 있다. SAMOA는 플랫폼이자 라이브러리이다. 이를 통해 알고리즘 개발자는 코드를 재사용하여 다른 기본 실행 엔진에서 실행할 수 있다. 또한 SAMOA를 다른 엔진으로 포팅하는 플러그인 모듈을 지원한다. SAMOA를 활용하면 ML 알고리즘 개발자는 기본 분산 스트림 처리 엔진의 복잡성에 대해 걱정할 필요가 없다. 로컬

에서 실행하거나 Storm, S4 또는 Samza와 같은 스트림 처리 엔진 중 하나를 사용할 수 있다.

SAMOA는 분류, 회귀, 군집화, 그리고 앙상블 학습을 위한 부스팅 및 배깅을 포함한 다양한 과업을 위한 머신러닝 알고리즘을 제공한다. 또한 이러한 머신러닝 알고리즘 구현을 위한 플랫폼과 사용자가 자체 분산 스트리밍 알고리즘을 작성할 수 있는 프레임워크를 제공한다. 예를 들어, 군집화를 위한 CluStream과 의사결정 트리 위에 수직 병행성(Parallelism)을 사용하는 Vertical Hoeffding Tree 또는 분류를 위한 Hoeffding Tree가 있다. 회귀를 위해 수직 및 수평 병행성을 모두 사용하는 Adaptive Model Rules Regressor도 있다[244]. 다양한 실시간 데이터 분석 툴(Analytics Tool) 간의 요약 비교는 표 VII에 나와 있다.

V

V. APPLICATIONS OF ML-BASED CONTEXT-AWARE SYSTEMS FOR SBS



CONTEXT-AWARE SYSTEMS FOR SBS

V. APPLICATIONS OF ML-BASED CONTEXT-AWARE SYSTEMS FOR SBS

스마트 빌딩을 위한 머신러닝 기반 상황 인식 시스템의 적용

스마트 빌딩 환경에서 머신러닝의 잠재적인 사용은 탐지, 인식, 예측, 최적화의 네 가지 범주로 나눌 수 있다[79]. 이러한 범주는 다음에 개별적으로 논의한다.

일반적으로 탐지(Detection)는 더 큰 정보 스트림에서 특정 정보를 추출하는 것이다. 화재 탐지, 누출 탐지 및 이상 탐지와 같은 스마트 빌딩의 많은 감지 애플리케이션이 있다[245]. 연구자들은 스마트 빌딩의 활동 인식에서 다양한 적용 분야를 연구했다. 예를 들어 피트니스 추적, 건강 모니터링, 낙상 감지 등이 있다[246].

인식(Recognition)의 목표는 물체 또는 이벤트를 미리 정의된 범주로 분류하는 것이다. 컴퓨터 프로그램이 이미지에서 물체를 인식하는 것과 같은 지능적이고 인간과 유사한 과업을 수행하도록 만드는 방법에 초점을 맞추고 있다.



TABLE VII: COMPARISON BETWEEN REAL-TIME DATA ANALYTICS TOOLS
딥러닝과 머신러닝 툴 비교

Tool	Storm	Kafka	Oracle	Spark	Amazon Kinesis	Flume	SAMOA
First released in	Sept. 2011	Jan. 2011	Jan. 2013	May 2014	Dec. 2012	May 2013	May 2013
Main Owner	Backtype, Twitter	LinkedIn, Confluent	Oracle	AMPLab, Data-bricks	AWS	Apple, Cloudera	Created at Yahoo Labs
Platform	Cross-platform	Cross-platform	Cross-platform	Microsoft Windows, OSX, Linux	Microsoft Windows, OSX, Linux	Cross-platform	Cross-platform
Written in	Clojure and Java	Scala	Java	Scala, Java, Python, R	C++, Java, Python, Ruby, Node.js, .NET	Java	Java
API Languages	Any programming language Java, C++, Node.js	Java, C++, Node.js	Java, Node.js, Python, PHP and Ruby	Scala, Java, Python, R	C++, Java, Python, Ruby, Node.js, .NET	Java	Java
Auto-Scaling?	No	Yes	Yes	Yes	Yes	No	Yes
Event Size	Single	Single	NA	Minibatch	Data blob of 1MB size	Single	NA
Fault Tolerance	Yes	Yes	Yes	Yes	Yes	Just with file channel	Yes
Type	Distributed stream processing	Message broker	Distritued stream processing	Streaming analytics	Real-time streaming	Distriuted stream processing	Distriuted stream processing
Used in	[235] [236]	[237] [236] [238]	[239]	[237] [215]	[240]	[215]	[241]



Fig. 9: Steps involved in applying ML models in an SB environment.
스마트 빌딩 환경에서 머신러닝 모델을 적용하는 단계





Fig. 10: SB services taxonomy.
스마트 빌딩 서비스 분류체계



예측(Prediction)의 목표는 가까운 장래에 일어날 일을 예측하기 위해 특정 이벤트 간의 시간 관계 모델을 결정하는 것이다. 예측은 분류 또는 회귀 문제에 대한 것일 수 있다[247]. 가장 가능성이 높은 이벤트 또는 후속 활동을 예측하는 것이 목표인 경우 이벤트 예측은 분류 문제의 예이고, 출력이 연속 값을 취할 때의 자연 시간 예측은 회귀 문제의 예다. 스마트 빌딩 환경에서 이벤트를 예측하기 위해 머신러닝 프로세스를 적용하는 일반적인 단계는 그림 9에 나와 있다.

반면 최적화(Optimization)의 목표는 다양한 상황에서 적절한 결정을 내림으로써 장기적인 이익을 극대화하는 것이다. 강화 학습은 이러한 문제에 활용될 수 있다. 일부 최적화 문제는 예측 문제로 관리할 수 있으므로 서로 다른 동작에



대한 이익을 예측하고 이익이 가장 높은 동작을 선택할 수 있다. 의사결정은 최적화 문제의 가장 일반적인 경우이다. 다양한 변수를 고려하고 환경의 서로 다른 위치의 이익 간의 거래를 해결해야 한다[248].

스마트 빌딩에는 다양한 매개변수를 측정하는 다양한 센서가 점점 더 많이 공급되고 있으며, 이러한 센서의 데이터는 머신러닝 알고리즘으로 분석되고 건물 거주자의 활동을 위한 다양한 서비스 및 애플리케이션에 사용된다. 스마트 빌딩은 에너지 절약과 지속가능성 목표에 기여하는 것을 훨씬 넘어선다. 스마트 빌딩이 제공하는 애플리케이션 및 서비스는 e-헬스, e-마케팅, 지능형 주차 시스템, 지능형 교통 시스템, 자동화 및 물류 서비스에 이르기까지 주거용 및 상업용에 모두 해당될 수 있다.

그림 10은 스마트 빌딩 서비스의 기본 영역 분류체계를 보여준다. 조명 서비스는 조명이 필요하지 않을 때 에너지를 절약하기 위한 센서를 갖춘 스마트 빌딩 내 활동에 따라 거주자의 웰빙(Well-being)과 관련된다. 전력 및 전기 시스템은 스마트 빌딩에서 소비되는 전력의 비율을 제공하기 위해 현장 재생 에너지를 가질 수 있다. 공조 시스템은 습도, 환기 및 에어컨 시스템을 의미하며, 환경과 효과적으로 상호작용하는 거주자의 편의를 위한 것이다. 물 관리 서비스는 절약량을 늘리고 수세식, 조정 및 냉방 시스템을 위한 물 재 활용을 관리하는 것과 관련이 있다.



폐기물 관리는 스마트 빌딩 내 폐기물 관리 시스템 모니터링 및 규제와 함께 수집, 분리, 운송에 필요한 활동 및 조치와 관련이 있다. 주차 서비스는 주차 차량에 필요한 면적과 부피를 최소화하는 것과 관련이 있다. 카셰어링(Car Sharing), 전기차, 자전거 보관소도 지원할 수 있다. 보안은 자동 잠금 장치, 생체 인식 장치 및 스마트 빌딩의 비디오 감시 시스템 관리와 관련이 있다. 운영제어센터는 운영에 대한 시스템 분석 및 의사결정을 지원한다. 시각적 인터페이스는 건물 자원을 더 잘 관리하기 위해 스마트 빌딩 서비스 및 작업자의 상태를 보여주는 대시보드(Dashboard)를 제공한다. 또한 이러한 인터페이스를 통해 거주자는 일상생활에서 편안함과 생산성 향상을 위해 최적의 매개변수를 설정할 수 있다. 마지막으로, 통신 센터는 운영제어센터 뿐만 아니라 건물의 센서 및 액추에이터를 연결하는 것과 관련이 있다.

문헌 조사에 따르면 스마트 빌딩 적용 분야는 노인 돌봄, 안락/오락, 보안/안전, 에너지 매니지먼트 및 기타 프로젝트 등으로 확인하였다. 이 장의 나머지 부분에서는 다음의 스마트 빌딩 서비스를 제공하는 주요 영역에 대해 간략하게 설명한다. (1) 노인 요양 (2) 에너지 효율 향상 (3) 편안함 또는 엔터테인먼트 제공 (4) 안전 및 보안 강화 (5) 기타 프로젝트.

a) 노인 자택 요양(Elderly Population's Home Care): 센서, 음성 활성화, GPS, 블루투스, 휴대폰을 통한 무선전화 연결, 스마트폰 모니터링 앱, 정교한 컴퓨터와 같은 스마트 빌딩 기술은 독립적으로 사는 노인이나 장애인에게 특히 유용할 수 있다. 노인은 이러한 기술(예: 모니터링 시스템, 비상 시스템, 위험한 주방 기기 감지, 낙상 감지)을 활용하여 독립적으로 생활하면서 안전하고 건강한 생활 방식을 유지할 수 있다[56][249].

스마트 빌딩의 스마트 기술은 인간의 일상 활동에 대한 실시간 정보를 수집하고 개인 패턴을 학습하는 것을 목표로 한다. 머신러닝 기술은 의료 서비스 제공자와 환자 모두에게 변화를 가져올 수 있는 매우 광범위한 새로운 혁신의 잠재력을 가지고 있다. 표준 패턴에서 이탈이 감지될 때마다 스마트 빌딩 시스템은 가족 구성원과 보호자에게 정보를 보내 긴급 대응 조치를 취하도록 한다. 빅데이터 분석과 ML 알고리즘을 사용하면 전자 의료 기록에 포함된 대규모 데이터를 분석할 수 있다. 예를 들어 의사가 처방하는 약을 포함하여 환자를 치료하는 방법을 자동으로 학습할 수 있다[250].

이 영역의 몇 가지 주요 프로젝트에 대해서는 다음에 설명한다. Chernbumroong 등 [56]은 서포트 벡터 머신을 적용하여 노인의 일상 생활 활동을 탐지하기 위한 활동 인식 및 분류 접근법을 제안했다. 이들은 손목에 착용하는 다중 센서, 즉 가속도계, 온도 센서, 고도계 등 이용해 식사하기, 몸 단장, 옷 입기, 이동성, 계단 등 5가지 기본 활동을 탐지했다. 그리고 설거지, 다림질, 청소 및 TV 시청과 같은 기타 도구 활동도 탐지했다. Taleb 등 [251]은 스마트 홈 환경에서 노인 지원을 위해 탐지 및 모니터링 서비스를 모두 통합하는 미들웨어 레벨 솔루션을 제안했다. 제안된 프레임워크에 사용된 기기에는 건물 전체를 커버하는 RFID 리더, 사운드 센서, 비디오 카메라, 스마트 도어록, 마이크 및 시스템과의 상호작용을 위한 스피커가 포함된다. CAALY [252]는 유럽연합 집행위원회가 자금을 지원하는 프로젝트로서 노인들의 자율성과 자신감을 지원하고 있다. 이 서비스는 노인 모니터링 서비스 시스템, 가정 모니터링 서비스 시스템 및 관리인의 모니터링 서

시스템을 포함한 세 가지 개별 서브 시스템으로 구성된다. 이 시스템은 노인 사용자의 지리적 위치 및 임상 상태 등 응급 서비스에 대한 최우선 순위 메시지를 전달한다. EasyLine+[253] 프로젝트는 유럽위원회에서 자금을 지원하는 프로젝트로서, 장애 유무에 관계없이 가정에서 더 긴 독립생활을 수행하는 노인들을 지원한다. 이 시스템은 신경망, 보조 소프트웨어, 조명 센서, 온도 센서, 도어 센서, RFID와 같은 다양한 센서를 사용하여 백색 가전제품을 제어할 수 있는 기능을 제공한다. Hossain 등 [254]은 몸짓 기반 가전제품 제어를 지원하는 노인을 위한 클라우드 기반 사이버-물리적 다중 감각 스마트 홈 프레임워크를 제안했다. Suryadevara 등 [255]은 센서 활동 패턴을 생성하고 가전 제품을 사용하는 노인의 행동을 예측하는 모델을 제안했다.

b) 에너지 효율(Energy Efficiency): 집의 여러 구역에서 온도가 올라가거나 내려가면 히터, 에어컨, 선풍기 및 기타 장치가 켜지거나 꺼진다(또는 속도 또는 온도가 증가하거나 감소). 공급 시스템의 효율적인 에너지 소비를 수행하기 위해서는 현재 에너지 소비 시스템이 건물에서 사용하는 방식을 분석하는 중요한 단계가 필요하다[256]. 지난 10년 동안 스마트 공간의 에너지 효율 분석은 점점 더 많은 관심을 받았다. 프로파일, 기후 데이터 및 건물 특성에 기반한 예측 모델링을 활용하여 에너지 효율성에 대한 다양한 접근법이 제안되었다[32][257]. 예를 들어 집 전체의 조명은 하루 중 시간에 따라 켜지거나 꺼질 수 있다.

과거에는 주거 단위의 시설에서 스마트 미터링 및 센서 네트워크를 사용하여 스마트 빌딩의 에너지 효율을 개선하기 위한 다양한 시도가 있었다. 이러한 유형의 인프라가 더욱 널리 보급되고 있지만 그 다양성과 규모로 인해 에너지 효율성을 개선하는 데 도움이 되는 결론을 내리는 데 직접 활용될 수 없다는 것은 사실이다. 머신러닝 접근법은 스마트 빌딩의 에너지 효율 문제를 처리하는 데 핵심이 될 것이다. 거주자의 소비 습관에 대해 학습하면 거주자가 더 나은 소비를 하도록 돕는 협력적 소비 예측을 생성할 수 있다[258].

이 영역의 몇 가지 주요 프로젝트에 대해서는 다음에 설명한다. Reinisch 등 [259]은 스마트 빌딩 환경에 최적화된 AI 시스템 애플리케이션을 개발했다. 이 시스템은 편재성, 상황 인식, 갈등 해결 및 자체 학습 기능과 같은 일부 기능에 초점을 맞춘다. 이 시스템은 에너지 효율 및 사용자 편의를 달성하는 데 필요한 모든 정보를 저장하는 지식 기반에서 작동한다. Jahn 등 [260]은 Hydra 미들웨어 프레임워크 위에 구축된 에너지 효율 기능 시스템을 제안했다[261]. 이 시스템은 스마트 환경을 모니터링하고 제어하기 위한 고정 및 모바일 사용자 인터페이스를 제공한다. Pan 등 [262]은 스마트 빌딩의 효율성을 높이기 위해 스마트폰 플랫폼과 클라우드 컴퓨팅 기술을 사용하는 IoT 프레임워크를 제안했다. 그들은 에너지 소비 데이터 분석을 위한 실험적인 테스트베드를 구축했다. Fensel 등 [263]은 SESAME-S 프로젝트(SEmantic SmArt Metering-Services for energy efficient houses)를 제안했다. 이 프로젝트는 최종 소비자가 올바른 결정을 내리고 에너지 소비를 제어할 수 있도록 에너지 효율 서비스를 설계 및 평가하는 데 초점을 맞추고 있다. 이 시스템은 스마트 미터, 다양한 센서, 액추에이터 및 세탁기와 같은 가상 기기를 통합할 수 있는 시뮬레이터와 같은 다양한 스마트 빌딩 구성요소를 결합한다. Vastardis 등 [264]은 홈 자동화, 에너지 사

용량 관리 및 스마트 그리드 운영을 지원 하는 사용자 중심의 스마트 홈 게이트웨이 시스템 아키텍처를 제안했다. 게이트웨이는 사용자의 행동 패턴을 추출하여 게이트웨이에 피드백할 수 있는 C4.5 및 RIPPER와 같은 머신러닝 분류 알고리즘 구성요소에 의해 지원된다. 비와 토양 상태를 추적하고 적절하게 관개하는 관개 시스템 모니터링 및 스마트 급수 시스템은 옥외 용수 소비를 줄이는 매우 비용 효율적인 방법이다. 물 매니지먼트 소프트웨어 및 서비스, 물 효율적인 배관 및 관개 관리에 대한 투자는 경제적 및 지속가능한 이점을 제공한다. 물 절약 및 매니지먼트는 이러한 이점의 한 예이다[265].

c) 편안함/엔터테인먼트(Comfort/Entertainment): 스마트 빌딩 조사의 주요 목표 중 하나는 사용자의 만족도와 편안함을 높여 일상 생활을 용이하게 하는 것이다. 스마트 빌딩은 더 나은 삶의 질을 제공하기 위해 자동화된 가전제품 제어 및 보조 서비스를 지원한다. 이러한 서비스는 상황 인식 기술을 활용하여 건물 환경에서 미리 정의된 조건의 제약에 기반하여 거주자의 편안함을 최적화한다. 편의 서비스의 대표적인 예로는 조명, 배경 음악, 일상 활동의 자동화, 음성 또는 몸짓에 기반한 고급 사용자 인터페이스 등이 있다[30]. 스마트 빌딩 환경의 편의 서비스와 관련된 다른 서비스로는 실내 온도 조절 및 지능형 온도 조절기가 있다[265]. 실내 온도 조절: 온도, 조명, CO2 야외 공기의 측정 및 제어. 스마트 빌딩 환경에서 공조설비 시스템은 실내 환경 품질을 형성하는데 필수적인 역할을 한다. 일반적으로 공조설비 시스템은 가열 및 냉각할 뿐만 아니라 대형 건물의 실외 공기를 흡입 및 순환하기 위해 제작된다[266]. Kabir 등 [267]은 사용자의 미리 정의된 선호도에 따라 서비스를 제공하는 상황 인식 애플리케이션을 제공한다. 그들은 K-최근린(KNN) 분류기를 사용하여 사용자의 편의성과 안전성을 극대화하는 동시에 환경과 사용자의 명시적 상호 작용을 최소화하는 미리 정의된 서비스를 추론한다. Ahn 등 [268]은 주기적으로 대기 변화를 추정하고 가까운 미래의 실내 공기 질을 예측하는 딥러닝 모델을 제안했다.

d) 안전/보안(Safety/Security): 스마트 빌딩 기술이 발전함에 따라 보안 및 연결 기기에 머신러닝 및 딥러닝의 역할이 증가할 것이다. 딥러닝은 특히 이미지와 비디오에서 이전에는 접근할 수 없었던 빅데이터를 사용하여 통찰력을 얻는 데 계속 도움이 될 것이다. 새로운 위협을 탐지, 분류 및 차단하는 행동 분석 및 머신러닝과 같은 고급 기술이 유용할 것이다. 전통적인 가정 시스템에서는 화재가 감지되는 즉시 화재/연기 감지기가 활성화되고 화재 정보를 보내기 시작한다. 그러나 스마트 빌딩은 기존의 시스템보다 훨씬 더 나은 성능을 발휘할 수 있다. 경보를 울릴 뿐만 아니라 가장 안전한 경로에만 조명을 켜고 건물 거주자를 밖으로 안내할 뿐 아니라 연기 환기를 위해 문과 창문을 열고 모든 장치를 끄고 가장 가까운 소방서를 호출할 수 있다. 이 밖에도 건물 주변 영역의 지역의 영상을 촬영하고, 창문 파손 정보 상태를 제공하고, 마지막 사람 이 집을 떠날 때 모든 문과 창문을 자동으로 잠글 수 있다[30].

스마트 빌딩의 주요 보안 및 안전 서비스: 경계 접근 제어, 액체 존재 감지(Liquid Presence), 지능형 화재 정보, 침입 감지 및 동작 감지 시스템 [265]. 경계 접근 제어 서비스는 제한된 영역에 대한 제어를 제공하고 해당 영역에 접근하는

승인되지 않은 사용자를 탐지한다. 출입 카드는 직원, 공급업체 또는 계약자가 지정한 특정 시간에 특정 영역에 접근할 수 있도록 하는 다양한 솔루션을 제공한다. 동일한 출입 카드를 사용하여 직원의 출석을 확인할 수도 있다. 또한 지문, 얼굴 인식, 홍채 스캔 등 생체 인식 기술이 광범위하게 사용되고 있다 [269]. 또한 액체 존재 감지 기술은 데이터 센터, 창고 및 민감한 건물 부지에서 이러한 영역의 고장 및 부식을 방지하기 위해 활용되었다[270].

지능형 화재 경보기와 그에 상응하는 안전 시스템은 지능형 빌딩의 중요한 부분이다. 다기능 센서(예: 화학 가스 센서, 통합 센서 시스템, 컴퓨터 비전 시스템)가 있는 시스템이다. 이 센서를 통해 건물 내 연기와 일산화탄소(CO) 수준을 측정할 수 있다. 그리고 경고, 엄정 큰 경보를 제공하고 연기와 일산화탄소의 장소와 수준에 대해 사람의 목소리로 말할 수 있다. 또한 연기와 일산화탄소 알람이 울리면 스마트폰으로 메시지를 보낼 수 있다[271]. 창문 및 문 열림 감지 및 침입 방지를 포함한 침입 감지 시스템의 예가 있다[265]. 적외선 동작 센서는 건물의 특정 영역에서 움직임을 감지하는 데 사용된다. 이 센서는 시스템이 환경 장애에 적응하기 위한 알고리즘을 구현하고 거짓 경보를 줄이면서 경보 패널(Alarm Panel)에 정보를 안정적으로 전송할 수 있다[265].

보안 소프트웨어에서 이미지 인식 솔루션을 사용하여 사람, 장소, 사물 등을 식별할 수 있다. 또한 비정상적인 패턴과 활동을 감지하는 데 사용할 수 있다. Clarifai [272]는 컴퓨터가 이미지와 비디오를 ‘볼’ 수 있도록 가르치는 ‘컴퓨터 비전(computer vision)’으로 알려진 머신러닝 분야를 전문으로 한다. Clarifai의 기술은 보안 감시에서 핵심적인 역할을 할 수 있으며 현재 회사는 가정용 보안으로만 작업하고 있다. 각 이미지는 복잡한 신경망을 통해 픽셀 단위로 처리된다. Bangali와 Shaligram [273]은 사용자가 집에서 멀리 떨어져 있을 때 집을 모니터링하는 가정용 보안 시스템을 제안했다. 이 시스템은 두 가지 방법으로 구성되어 있다. 첫번째 방법은 카메라 앞에서 동작이 감지될 때마다 웹 카메라를 사용하여 침입자를 감지하고, 소리와 관련한 보안 경고 및 이메일을 거주자에게 전달한다. 두 번째 방법은 SMS를 보내는 GSM 기술을 기반으로 한다. 불법적인 가정 침입 시 집 주인과 경찰서에 경고 메시지를 보내는 가정 보안 시스템은 [274]에 제안되어 있다. 시스템은 입력 구성요소로 다른 센서 노드로 구성되며, 출력 구성요소는 입력 구성요소에서 수신된 신호에 응답한다. 센서 노드는 도난 경고, 존재 감지 회로 및 침입 카메라로 구성된다. Zhao와 Ye [275]는 저비용, 저전력 소비, GSM/GPRS를 활용하는 무선 가정용 보안 시스템을 제안하였다. 이 시스템은 사용자 인터페이스를 갖추고 있으며 경보 발생에 대응할 수 있다.

e) 기타 프로젝트: CASS [178]는 워싱턴 주립대학교의 프로젝트로, 스마트 빌딩의 치매 환자를 위한 비침습적 보조 환경을 제공한다. 이 프로젝트는 스마트 빌딩의 세 가지 주요 영역인 의료 모니터링, 친환경 생활 및 일반 편의성에 중점을 둔다. CASAS 프로젝트는 물리 계층, 미들웨어 계층 및 소프트웨어 애플리케이션 계층의 세 계층으로 구성된다. Aware Home Research Initiative(AHRI) [276]는 조지아 공과대학의 의료 및 웰빙, 디지털 미디어 및 엔터테인먼트, 지속가능성 분야에서 스마트 빌딩 서비스를 위한 그룹에 의해 구성된 프로젝트이다. AHRI는 스마트 플로어 센서와 같은 다양한 센

서를 활용하고 있으며, 노인을 모니터링하고 도움을 주기 위한 보조 로봇도 활용한다.

House_n [277]은 MIT 연구팀이 주도하는 다분야 영역 프로젝트이다. 이 프로젝트의 주요 목표는 스마트 홈 및 관련 기술, 제품 및 서비스의 설계를 촉진하는 것이다. 가정에는 가정의 거의 모든 부분에 설치된 수백 개의 다양한 센서가 제공되며 사용자가 환경을 제어 및 모니터링하고 자원을 절약하며 심신 활동을 유지하고, 건강을 유지할 수 있는 사용자 인터페이스 애플리케이션을 개발하는 데 활용된다.

Microsoft Research의 EasyLiving 프로젝트 [278]는 다양한 장치를 지능형 환경에 대한 일관된 사용자 경험으로 통합하기 위한 프로토타입 아키텍처 및 기술 개발과 관련이 있다. EasyLiving 프로젝트는 상황 인식 컴퓨팅 서비스를 제공하도록 설계되었다. 이 프로젝트는 다양한 센서와 카메라를 사용하여 실내의 기하학적 모델을 사용하고 실내에 설치된 센서에서 판독 값을 받아 실내의 인간 활동을 추적하고 인식한다.

Gator Tech Smart House 프로젝트 [279]는 미국 플로리다 대학의 모바일 및 편재형(Pervasive) 컴퓨팅 실험실에서 개발한 노인 및 장애인을 위해 특별히 설계된 프로그래밍 가능한 공간이다. 이 프로젝트의 목표는 자신과 거주자를 감지할 수 있는 스마트 빌딩 환경을 만드는 것이다. 이 프로젝트는 거주자에게 이동성, 건강 및 기타 나이와 관련된 장애와 같은 특별한 인지 서비스를 제공한다. 건물의 모든 센서 및 액추에이터에 대한 서비스 정의를 유지하기 위해 일반 미들웨어를 사용하여 시스템 구성요소를 통합한다. 별도의 물리적, 센서 플랫폼, 서비스, 지식, 컨텍스트 관리 및 애플리케이션 계층을 포함하는 미들웨어의 구성요소가 있다 [280]. 다른 잘 알려진 스마트 홈 프로젝트에는 스마트 빌딩에서 모바일 컴퓨팅과 인지 지원을 지원하는 캐나다 셔브룩(Sherbrooke) 대학의 연구 프로젝트인 DOMUS [281]가 있다. 이 프로젝트는 알츠하이머형 치매, 정신분열증, 두개골 외상, 지적 결함 등으로 고통받는 사람들을 돕는 것을 목적으로 한다.


콜로라도 대학의 Adaptive House 프로젝트 [136]는 소리, 움직임, 온도, 조도 등 다양한 환경 정보를 제공하는 다양한 센서가 장착된 프로토타입 시스템을 구축했다. 또한 공간 및 온수기를 제어하는 액추에이터, 조명장치 및 천장 선풍기도 있다.

아시아에서는 심전도, 체중 및 기타 온도 측정 지표와 같은 다양한 센서가 장착된 ‘Welfare Techno House’ 프로젝트와 같은 다른 스마트 빌딩 프로젝트도 개발되었다[282]. 유비쿼터스 홈 프로젝트[283]는 일본의 또 다른 스마트 빌딩 프로젝트로서, RFID, PIR, 압력 센서는 물론 노인 모니터링을 위해 카메라와 마이크를 활용한다.

f) 요약: 최근에는 스마트 빌딩 서비스를 지원하기 위해 여러 가지 상황 인식 및 머신러닝 기술을 활용하고 있다. 머신러닝 기반 접근법은 다른 접근법보다 예측과 적응을 더 잘 수행할 수 있다. 머신러닝의 기본 철학은 알고리즘을 통해 사용할 가능한 데이터를 활용하여 분석 모델을 만들 수 있는 학습 프로세스를 자동화하는 것이다. 머신러닝은 지도 학습, 비지도 학습, 준지도 학습, 그리고 모델과 환경 간의 상호작용으로 학습이 이루어지는 경우 강화 학습 등 다양한 학습 스타일로 적용될 수 있다. 스마트 빌딩 서비스를 위한 머신러닝의 일반적인 용도는 탐지, 인식, 예측 및 최적화이다. 이 장에서는 여러 분산 및 이기종 소스에서 컨텍스트를 얻는 방법과 이러한 컨텍스트를 스마트 빌딩의 애플리케이션 서비스에서 사용할 수 있도록 모델링 및 처리하는 기술에 대해서도 설명하였다. 또한 빅데이터를 효율적으로 처리하고 학습하기 위해 머신러닝 커뮤니티에서 실시간 데이터 분석을 위해 가장 많이 사용되는 툴과 플랫폼 머신러닝 등에 대해서도 설명하였다. 이러한 머신러닝 툴이 없으면 기술과 효율적인 엔지니어링 관행에 대한 전문 지식이 필요한 모든 기술을 처음부터 구현해야 한다.

TABLE VIII: CATEGORIZED APPLICATIONS OF SB
스마트 빌딩의 범주화된 응용

Application category	Cited	Characteristics	ML algorithm	Technology used
Elderly Population's Home Care	Chernbumroong et al. [56]	detection basic five activities namely feeding, grooming, dressing, mobility, and stairs.	SVM	wrist worn multi-sensors
	Taleb et al. [251]	Framework integrates both the sensing and the monitoring services for assisting elders at smart homes environment	NA	RFID readers with coverage of the whole house, video cameras, sound sensors, smart door lock, microphone and speakers
	CAALYX [252]	Elderly monitoring subsystem, home monitoring subsystem and the caretaker's monitoring subsystem.	NA	Vital sign sensors, GPS
	EasyLine+ [253]	Support elderly people in carrying out a longer independent life at home.	Neural Network	Illumination sensor, temperature sensor, door sensors, and RFID
Energy Efficiency	Reinisch et al. [259]	Operates on a knowledge base that stores all information needed to fulfill the goals of energy efficiency and user comfort	AI methods	Household appliances
	Jahn et al. [260]	Stationary and mobile user interfaces for monitoring and controlling the smart environment	NA	Wireless power metering plugs, household devices
	Fensel et al. [263]	Designing and evaluating end consumer energy efficient services	NA	Smart meters, different types of sensors and actuators
	Vastardis et al. [264]	Gateway system architecture to support home-automation, energy usage management, and smart-grid operations.	classification algorithms such as C4.5 and RIPPER	Smart gateway
Safety and Security	Clarifai [272]	Computer vision platform for security surveillance in smart homes	CNN	Surveillance cameras
	Bangali and Shaligram [273]	Composed of two methods: web camera to detect the intruder, and GSM technology that sends SMS.	NA	Web camera and GSM technology
	Zhao and Ye [275]	Low cost, low power consumption	NA	GSM/GPRS
	Kabir et al. [267]	Provide service according to context-aware feature of the user	K-nearest neighbors classifier	Environment monitoring sensors
Comfort and entertainments	Ahn et al. [268]	Estimate the atmospheric changes and predict the indoor air quality	Deep Learning	Carbon dioxide, fine dust, temperature, humidity, and light quantity sensors
	CASAS [178]	Medical monitoring, green living, and general comfort.	Classification, regression and clustering algorithms.	Wearable sensors
Miscellaneous projects	AHRI [276]	SB services in the fields of health and well-being, digital media and entertainment, and sustainability	NA	Smart floor sensors, assistive robots
	House n [277]	Control people to control their environment, save resources, remain mentally and physically active	NA	Home environmental sensors
	EasyLiving project [278]	Context-aware computing services through video tracking and recognition	NA	Contains myriad devices that work together





FUTURE RESEARCH DIRECTIONS



VI. OPEN ISSUES AND FUTURE RESEARCH DIRECTIONS

오픈 이슈 및 향후 연구 방향

스마트 빌딩에 대한 연구는 최근 몇 년 동안 큰 진전을 이루었지만 여전히 많은 과제가 남아 있다. 이 부분에서 스마트 빌딩과 관련된 몇 가지 주요 과제를 제시한다. 이러한 과제는 향후 스마트 빌딩에 대한 연구 방향에 방향을 전환할 것이다.

A. Security and Privacy

보안 및 개인 정보 보호

두 시스템 또는 네트워크(유선 또는 무선)가 상호 연결되어 있는 곳에는 보안 및 개인 정보 보호 문제가 있으며 스마트 빌딩의 경우도 마찬가지다. 보안은 스마트 빌딩 환경에서 필수적인 역할이다. 모든 스마트 빌딩 애플리케이션은 데이터의 기밀성과 무결성을 보장해야 한다. 접근 제어는 스마트 빌딩 시스템에 반드시 포함되어야 한다. 예를 들어 권한이 없는 사용자가 편재형(Pervasive) 시스템에 연결하여 정보 시스템을 차단시킬 수 없어야 한다. 설치된 다양한 센서와 가전제품에 대량의 스트리밍이 수집되므로 이러한 데이터를 처리하고 저장해야 한다. 따라서 이를 위해 클라우드 컴퓨팅 서비스를 활용할 수 있다. 그러나 이 모든 데이터가 전송됨에 따라 개인 정보 손실 문제가 증가한다. 따라서 개인 정보 보호를 위해 다른 암호화 기술이 필요하다[285]. 개인 정보의 데이터에 대한 개인 정보 보호와 개인의 물리적 위치 및 추적에 대한 개인 정보 보호와 관련된 문제를 포함하여 사용자의 개인 정보보호와 관련된 구체적인 도전적 과제가 있다. 이를 위해서는 사용자 및 개체의 ID 관리를 위

한 개인 정보 보호 강화 기술과 관련 보호법 및 도구가 필요하다[286]. 최근 머신 러닝 연구 동향은 스마트 빌딩 환경의 보안 및 개인 정보 문제를 처리하는 데 초점을 두고 있다. 활동 및 잠재적으로 유해한 행동을 탐지 및 차단하여 안전한 장치 동작을 결정하는 것과 같은 다양한 보안 관련 서비스들이 머신 러닝 기술을 활용했다[287].

머신 러닝 기술은 사용자의 습관과 행동을 학습, 식별 및 탐지할 수 있기 때문에 보안 격차를 줄일 수 있다. 결과적으로 위험과 침입이 발생하기 전에 이상 행동을 사전에 탐지할 수 있다. 예를 들어 머신러닝 모델은 집에 도착하거나 잠자리에 드는 시간과 같은 사용자의 일상을 학습한다. 이러한 모델은 연결된 모든 장치에서 탐지된 동작을 기반으로 규칙을 제안할 수 있다[288].

B. SBs and Context-aware Computing

스마트 빌딩 및 상황 인식 컴퓨팅

스마트 빌딩 환경에서는 다양한 인간 활동과 행동에 대해 지속적으로 수집되는 대량의 원시 데이터가 있다. 이 원시 데이터를 귀중한 지식으로 변환하는 기술을 개발하는 것이 중요하다[289]. 상황 인식 및 머신러닝 기술은 빅데이터를 처리 및 저장하고 이 모든 데이터에서 중요한 지식을 생성하는데 큰 도움이 될 것으로 기대된다[290].

데이터 해석 및 지식 추출 프로세스에는 노이즈가 많은 실제 데이터를 처리하고 기존 알고리즘의 한계가 없는 추론 기술을 추가로 개발할 수 있는 능력을 포함하여 다음과 같은 과제가 있다. 복잡한 인간의 생리학, 심리학, 행동적 측면 때문에 일반적으로 인간 행동과 관련된 상황 정보를 표준 방식으로 형식화하고 모델링하는 것은 매우 복잡하다[291].

VI. OPEN ISSUES AND FUTURE RESEARCH DIRECTIONS

Research on SBs has made great strides in recent years, but a number of challenges remain. We present some major challenges related to SBs in this part of the work.

These challenges will channelize the research directions for future SBs.



인간은 풍부한 언어와 몸짓 표현들을 통하여 의사소통을 한다. 현대의 유비쿼터스 컴퓨터 시스템에는 인간처럼 정보를 추론하는 자동 메커니즘이 없다. 애플리케이션과 인간 사이의 복잡한 종속성을 이해하기 위해 인간 활동과 행동 인식을 높이기 위해 새로운 연구가 필요하다[292][293]. 상황 인식 프롬프트 시스템은 비상 알림, 약물치료 프롬프팅(Prompting), 심박수 모니터링, 아젠다 알림 생성 및 기상 정보와 같은 스마트 빌딩의 필수 애플리케이션을 가지고 있다. 그러나 탐지된 모든 오류에 대해 프롬프트를 표시하는 것은 거짓 양성반응일 수 있으며 결과적으로 성가심을 유발하고 때로는 특정 활동에 대해 안전하지 않은 것으로 입증된다. 머신러닝 방법은 일상 생활에서 어려움 을 겪을 때 정확하고 정확한 예측을 위해 사용될 수 있다[294].

C. Personal Data Stream Management in SBs

스마트 빌딩의 개인 데이터 스트림 매니지먼트 데이터 스트리밍 매니지먼트 시스템은 다양한 센서에서 수집된 원시 데이터를 처리하고 정보로 전송할 수 있으며, 또한 이 정보를 특성에 통합하고 특성을 직접 처리할 수 있다[295]. 단일 스마트 빌딩에 대한 데이터 처리는 간단하지만 여러 스마트 빌딩의 데이터를 처리할 때 더 복잡하다. 서로 다른 사람들이 공통 관심사를 공유하지 않고 처리된 데이터에 대해 상반된 관심사를 갖기 때문이다[296]. 스마트 빌딩 환경의 간단한 센서는 온도, 움직임, 빛 또는 날씨와 관련된 다양한 이벤트를 감지할 수 있다. 또한 텔레비전 및 전화와 같은 다른 기기도 상태 또는 다른 데이터를 이벤트로 보낼 수 있다. 서로 다른 센서의 이 모든 데이터는 스마트 빌딩 서비스에서 특정 상태를 감지하고, 특정한 미리 정의된 규칙(예: 텔레비전이 사용되는 경우 조명 켜기)에 따라 일부 액추에이터에 요청을 보내는 데 사용될 수 있다[297]. 그러나 동일한 건물에 거주하는 그룹의 경우 이러한 접근법을 일반화할 수 없다. 개인의 선호도를 자동으로 학습할 수 있는 경우 특정 개인에 잘 작동할 수 있지만, 각 거주자는 자신의 규칙 집합을 정의해야 한다[298]. 데이터 스트림을 생성하는 센서의 수가 증가하고 있기 때문에 이러한 데이터 스트림의 기존 분석 및 처리 기술은 현재 대부분 비현실적이다[299]. 그러나 스마트 빌딩의 다양한 센서에 의해 지속적으로 생성되는 방대한 양의 데이터를 처리하기 위한 새로운 도구와 시스템이 있음에도 불구하고 고급 데이터 분석에 대한 진정한 가능성은 여전히 순수 기술의 영역을 넘어선다[296]. [300]에서는 실제 애플리케이션의 데이터 스트림에 대한 연구 과제를 설명한다. 또한 개인 정보, 타이밍, 사전 처리, 관계 및 이벤트 스트림, 모델 복잡성 및 평가, 정보 가용성 및 레거시 시스템 관련 문제와 관련된 문제를 분석한다.

D. Big data challenges in SBs

스마트 빌딩의 빅데이터 과제 오늘날 스마트 빌딩의 다양한 감지 기술을 활용하여 합리적인 비용으로 방대한 양의 이기종 데이터를 수집할 수 있다. 일반적으로 단일 스마트 빌딩에서 매일 수십만 개의 트랜잭션을 생성할 수 있다. 이 데이터를 장기간 저장하는 과정은 쉽지 않다[258]. 수십 개의 스마트 빌딩에서 들어오는 데이터를 매니지먼트하기 위해 회사 또는 정부가 앞으로 직면하게 될 도전과 기회를 상상할 수 있다. 이 새로운 데이터는 더 많은 상황에 맞는 정보를 제공하여 거주자에게 훨씬 더 나은

서비스를 제공할 수 있다[301]. 하지만 빅데이터의 세계에서는 방대한 양의 데이터 가용성에도 불구하고 데이터에서 의미 있는 정보를 추출하기 위해 시행착오와 같은 기존의 접근법을 활용하여 중요한 정보를 얻기가 쉽지 않다. 이러한 방대한 양의 데이터를 분석하려면 빅데이터를 효과적으로 저장, 구성 및 처리하기 위한 새로운 기술이 필요하며, 빅데이터에서 통찰력을 발견할 수 있는 고성능 프로세서가 필요하다. 또한 유연한 클라우드 컴퓨팅 서비스 및 가상화 기술은 물론 Apache Hadoop 및 Spark와 같은 소프트웨어도 필요하다[302]. 위의 문제를 효과적이고 효율적으로 해결하려면 기존 접근법과 다른 적절한 머신러닝 기술을 제공해야 한다. 이러한 이유로 연구자들은 최근 스마트 빌딩 환경에서 빅데이터를 채택함으로써 발생하는 문제와 기회에 대해 생각하기 시작했다[303][304]. 이러한 빅데이터에서 추출한 정보는 상당한 가치가 있으며, 보조 도구로서 그리고 더 나은 서비스 제공에 있어 스마트 빌딩의 미래에 크게 기여할 수 있다. 이것이 연구자들이 스마트 빌딩에서 빅데이터의 현재와 미래의 도전적 과제에 대한 해결책을 분석하고 생각해야 하는 필요성에 대한 이유이다[305].

E. Interoperability

상호운용성 상호운용성은 두 개(또는 그 이상의) 시스템이 함께 작동하도록 설계되지 않았더라도 변경없이 함께 작동한다는 것을 의미한다. 통신 및 네트워킹 기술이 서로 다른 장비, 장치 또는 기기가 효과적으로 통신할 수 있을 때 상호운용성이 충족된다. 다양한 구성요소를 가진 스마트 빌딩을 이해하는 것은 어려운 과제다. 일반적으로, 이러한 각 구성 요소는 서로 다른 설계 제약 조건 및 고려사항 하에서 서로 다른 공급업체에서 생산되었을 수 있다[306]. 따라서 스마트 빌딩의 다양한 부분에서 다양한 이기종 통신 및 네트워킹 기술이 공존할 수 있도록 상호운용성을 충족하는 것이 필수적이다. 예를 들어, 에너지 관리 시스템은 통신 목적으로 Wi-Fi와 ZigBee를 사용할 수 있다. 이러한 맥락에서 많은 작업이 수행될 수 있다[307].

F. Reliability

신뢰성 안정성은 스마트 빌딩 시스템의 거주자 및 개발자의 주요 관심사 중 하나라고 예상할 수 있다. 텔레비전, 전자레인지, 세탁기 등 스마트 빌딩에 존재하는 다양한 가전 제품 및 장치는 신뢰성이 매우 요구된다. 특히 스마트 빌딩에서 예상할 수 있는 이러한 장치와 활용되는 통신 기술과 연계된 경우 예상되는 수준의 안정성을 달성하는 것은 큰 과제이다. 기술적 접근법, 규제, 개발 문화 및 시장의 기대치의 차이에 따라 이러한 과제에 다양한 이유가 있다[306].

G. Integration

통합 성공적인 스마트 빌딩 구현의 핵심은 통합이다. 센서 및 제어 시스템을 사용하여 조명, 전력 계량기, 수도 계량기, 펌프, 난방 및 냉방 시설과 같은 빌딩 시스템을 함께 연결한 다음 빌딩 자동화 시스템을 엔터프라이즈 시스템에 연결한다. 통합을 통해 경영진은 신축 건물에서, 그리고 기존 건물을 스마트 빌딩으로 전환하여 스마트 빌딩의 이점을 얻을 수 있

다. 이러한 스마트 빌딩의 공통점은 통합이다. 일반적으로 스마트 빌딩 시스템의 통합은 에너지 절약에서 생산성 향상, 지속가능성에 이르기까지 다양한 이점을 제공한다. 스마트 빌딩 시스템을 엔터프라이즈 비즈니스 시스템과 연결하여 의사 결정을 강화하고 빌딩 성능을 개선하는 또 다른 수준의 지능을 추가할 수 있다[2]. 그러나 각 개별 시스템에는 고유한 가정, 물리적 세계를 제어하기 위한 전략 및 의미가 있기 때문에 여러 시스템을 통합하는 것은 매우 어렵다. 스마트 빌딩에 두 시스템을 통합한 예로서, 에너지 매니지먼트를 담당하는 시스템과 건강 매니지먼트를 위한 다른 시스템이 동시에 실행되고 있다고 가정한다. 이 경우 통합 시스템은 건강 매니지먼트 시스템에서 제안하는 대로 사용되는 동안 에너지를 절약하기 위해 의료 기기를 끄지 않아야 한다[292]. 스마트 빌딩의 향후 관점에서, 여러분은 알람 소리에 눈을 뜨는 동시에 사용 가능한 센서도 사용자가 깨어나고 있음을 인식할 것이다. 조도 센서와 같은 다른 센서는 건물의 조명을 자동으로 켜고, 온도조절기는 건물에서 사용하려는 영역을 따뜻하게 할 것이다. 커피가 추출되기 시작하고 날씨에 대한 알림도 휴대전화 받게 된다. 주방과 냉창고에 있는 다른 센서는 저녁을 만들기 위해 직장에서 집으로 가는 길에 사야 할 품목 목록을 알려준다. 집을 나설 때, 자가 운전을 하기 위해 휴대폰의 버튼을 누를 수 있다. 그 후 보안 시스템이 집을 모니터링하고 제어하기 시작한다. 도어는 자동으로 잠긴다. 가정용 기기는 에너지 절약 모드로 전환된다. 홈 서버가 가상 울타리(Geofencing) 기술을 활용하여 집으로 돌아오는 것을 감지하면, 도착 전에 다시 준비하고, 온도조절기를 작동시키고, 차를 세울 때 차고 문이 열리고, 걸어 들어갈 때 가장 좋아하는 음악이 재생되기 시작할 것이다[141]. 요약: 최근 연구는 스마트 빌딩 분야에서 이루어졌지만 더 많은 노력이 필요하다. 그러나 스마트 빌딩이 가까운 장래에 대중화가 가능하다고 믿는다. 이 분야의 주요 과제와 향후 연구 방향은 다음과 같이 요약할 수 있다. 행동 및 의도 측면에서 사용자 컨텍스트를 연구하고 가능한 한 존중해야 한다. 상황 인식 프롬프트 시스템, 개인 데이터 스트리밍 및 스마트 빌딩 환경에서 거주자의 빅데이터 분석에 대한 추가 연구가 필요하다. 상호운용성, 신뢰성 및 통합과 같은 다른 과제는 여전히 더 많은 주의가 필요하다.

VII. CONCLUSIONS

결론 스마트 빌딩(SB)은 여러분의 요구를 예측하고 버튼 터치 한 번으로 원하는 대로 정확하게 실행할 수 있는 가정용 기기의 세계를 약속한다. 스마트 빌딩과 그 거주자는 방대한 양의 스트리밍 데이터를 생성하기 때문에 스마트 빌딩 연구자들은 빅데이터를 관리, 처리 및 통찰력을 얻기 위해 머신러닝 및 빅데이터 분석 기술을 찾고 있다. 이 이슈 보고서에서는 수행한 작업과 머신러닝과 데이터 분석 영역에서 추가 연구가 필요한 문제에 특히 중점을 두고 스마트 빌딩의 가장 중요한 측면을 검토했다. 이와 관련하여, 특히 스마트 인프라 및 서비스 구축을 위한 머신러닝 및 빅데이터 사용과 관련된 연구 작업에 대한 포괄적인 조사를 실시했다. 최근 스마트 빌딩 개념을 실현 가능하게 하는 기술의 발전에도 불구하고, 스마트 빌딩 분야의 대규모 실제 시스템을 제한하는 다양한 과제가 여전히 있다. 이러한 과제를 해결하는 것은 스마트 빌딩 연구의 산업 및 학술 분야에서 발전을 위한 강력한 원동력이 될 것이다.

REFERENCES

- [1] A. T.-p. So and W. L. Chan, "Applications in Electrical Systems," in Intelligent Building Systems, ser. The International Series on Asian Studies in Computer and Information Science. Springer, Boston, MA, 1999, pp. 123–142. [Online]. Available: https://link.springer.com/chapter/10.1007/978-1-4615-5019-8_13
- [2] "Improving Performance with Integrated Smart Buildings," Dec. 2017. [Online]. Available: [http://www.facilitiesnet.com/emails/Building Maximizer/Whitepaper/041912.asp](http://www.facilitiesnet.com/emails/Building%20Maximizer/Whitepaper/041912.asp)
- [3] J. Cheng and T. Kunz, "A Survey on Smart Home Networking," Carleton University, Systems and Computer Engineering,, Tech. Rep., Sep. 2009. [Online]. Available: [http://kunz-pc.sce.carleton.ca/Thesis/ SmartHomeNetworking.pdf](http://kunz-pc.sce.carleton.ca/Thesis/SmartHomeNetworking.pdf)
- [4] N. Davies, "How the Internet of Things will enable smart buildings," Jul. 2015. [Online]. Available: <https://www.extremetech.com/extreme/209715-how-the-internet-of-things-will-enable-smart-buildings>
- [5] A. Kamilaris, "Enabling smart homes using web technologies," phdthesis, University of Cyprus, Department of Computer Science, Dec. 2012.
- [6] "Smart Building Market by Type & region - Global Forecast 2022," MarketsAndMarkets, UK, Technical Report TC 3445, Aug. 2017. [Online]. Available: [https://www.marketsandmarkets.com/ Market-Reports/smart-building-market-1169.html](https://www.marketsandmarkets.com/Market-Reports/smart-building-market-1169.html)
- [7] "Global Forecast for Smart Building Market Size & Share to Surpass USD 61,900 million by 2024: Zion Market Research," Zion Market Research, Technical Report ZMR-2574, May 2018. [Online]. Available: [http://globenewswire.com/news-release/2018/05/25/1512045/0/en/ Global-Forecast-for-Smart-Building-Market-Size-Share-to-Surpass-USD-61-900-million-by-2024-Zion-Market- Research.html](http://globenewswire.com/news-release/2018/05/25/1512045/0/en/Global-Forecast-for-Smart-Building-Market-Size-Share-to-Surpass-USD-61-900-million-by-2024-Zion-Market-Research.html)
- [8] "Statista - The Statistics Portal for Market Data, Market Research and Market Studies." [Online]. Available: <https://www.statista.com/>
- [9] "Market Insight: The Move From the Connected Home to the Intelligent Home," Gartner, Inc, Technical Report G00355564, Jul. 2018. [Online]. Available: [https://www.gartner.com/doc/3876868/ market-insight-connected-home-intelligent](https://www.gartner.com/doc/3876868/market-insight-connected-home-intelligent)
- [10] "IoT in Smart Buildings Market Outlook and Forecasts 2018 - 2023," ResearchAndMarkets, Global, Technical Report 4539838, May 2018. [Online]. Available: [https://www.researchandmarkets.com/ reports/4539838/iot-in-smart-buildings-market-outlook-and](https://www.researchandmarkets.com/reports/4539838/iot-in-smart-buildings-market-outlook-and)
- [11] "Intelligent CRE for Enterprise: Smart Buildings, Intelligent Workplace, and Management Systems 2018 - 2023," Research and Markets, Technical Report 4559384, Jun. 2018. [Online]. Available: [https://www.researchandmarkets.com/reports/ 4559384/intelligent-cre-for-enterprise-smart-buildings](https://www.researchandmarkets.com/reports/4559384/intelligent-cre-for-enterprise-smart-buildings)
- [12] M. Chan, D. Estve, C. Escriba, and E. Campo, "A review of smart homesPresent state and future challenges," Computer Methods and Programs in Biomedicine, vol. 91, no. 1, pp. 55–81, Jul. 2008. [Online]. Available: [http://www.sciencedirect.com/science/article/pii/ S0169260708000436](http://www.sciencedirect.com/science/article/pii/S0169260708000436)
- [13] M. R. Alam, M. B. I. Reaz, and M. A. M. Ali, "A Review of Smart Homes - Past, Present, and Future," IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews), vol. 42, no. 6, pp. 1190–1203, Nov. 2012.
- [14] G. Lobaccaro, S. Carlucci, E. Lfstrm, G. Lobaccaro, S. Carlucci, and E. Lfstrm, "A Review of Systems and Technologies for Smart Homes and Smart Grids," Energies, vol. 9, no. 5, p. 348, May 2016. [Online]. Available: <https://www.mdpi.com/1996-1073/9/5/348>
- [15] J. Pan, R. Jain, and S. Paul, "A Survey of Energy Efficiency in Buildings and Microgrids using Networking Technologies," IEEE Communications Surveys Tutorials, vol. 16, no. 3, pp. 1709–1731, 2014.
- [16] Q. Ni, A. B. Garca Hernando, and I. P. de la Cruz, "The Elderlys Independent Living in Smart Homes: A Characterization of Activities and Sensing Infrastructure Survey to Facilitate Services Development," Sensors, vol. 15, no. 5, pp. 11 312–11 362, May 2015. [Online]. Available: <http://www.mdpi.com/1424-8220/15/5/11312>
- [17] P. Rashidi and A. Mihailidis, "A Survey on Ambient-Assisted Living Tools for Older Adults," IEEE Journal of Biomedical and Health Informatics, vol. 17, no. 3, pp. 579–590, May 2013.
- [18] K. K. B. Peetoom, M. A. S. Lexis, M. Joore, C. D. Dirksen, and L. P. De Witte, "Literature review on monitoring technologies and their outcomes in independently living elderly people," Disability and Rehabilitation. Assistive Technology, vol. 10, no. 4, pp. 271–294, Jul. 2015.
- [19] A. Salih and A. Abraham, "A review of ambient intelligence assisted healthcare monitoring," International Journal of Computer Information Systems and Industrial Management (IJCISIM), vol. 5, pp. 741–750, 2013.
- [20] C. Perera, A. Zaslavsky, P. Christen, and D. Georgakopoulos, "Context Aware Computing for The Internet of Things: A Survey," IEEE Communications Surveys Tutorials, vol. 16, no. 1, pp. 414–454, 2014.
- [21] C. W. Tsai, C. F. Lai, M. C. Chiang, and L. T. Yang, "Data Mining for Internet of Things: A Survey," IEEE Communications Surveys Tutorials, vol. 16, no. 1, pp. 77–97, 2014.
- [22] M. S. Mahdavinejad, M. Rezvan, M. Barekatin, P. Adibi, P. Barnaghi, and A. P. Sheth, "Machine learning for internet of things data analysis: a survey," Digital Communications and Networks, vol. 4, no. 3, pp. 161–175, Aug. 2018. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S235286481730247X> [23] J. M. Sinopoli, Smart Buildings Systems for Architects, Owners and Builders, 1st ed. Amsterdam ; Boston: Butterworth- Heinemann, Nov. 2009.
- [24] "Institute for Building Efficiency," Sep. 2018. [Online]. Available: <https://buildingefficiencyinitiative.org/>
- [25] F. Zafari, I. Papapanagiotou, and K. Christidis, "Microlocation for Internet-of-Things-Equipped Smart Buildings," IEEE Internet of Things Journal, vol. 3, no. 1, pp. 96–112, Feb. 2016.
- [26] M. Kehoe, M. Cosgrove, S. Gennaro, C. Harrison, W. Harthoorn, J. Hogan, J. Meegan, P. Nesbitt, and C. Peters, "Smarter cities series: a foundation for understanding IBM smarter cities," Redguides for Business Leaders, IBM, 2011.
- [27] European Commission and Directorate-General for the Information Society and Media, ICT for a low carbon economy: smart electricity distribution networks. Luxembourg: EUR-OP, 2009.
- [28] C. Badica, M. Brezovan, and A. Bdic, "An Overview of Smart Home Environments: Architectures, Technologies and Applications," in CEUR Workshop Proceedings, Thessaloniki, Greece, Sep. 2013, pp. 78–85.
- [29] B. M. Flax, "Intelligent buildings," IEEE Communications Magazine, vol. 29, no. 4, pp. 24–27, Apr. 1991.
- [30] "The Introduction To Smart Home Technologies Information Technology Essay," Dec. 2017. [Online]. Available: [https://www.uniassignment.com/essay-samples/information- technology/the-introduction-to-smart-home-technologies-information-technology-essay.php](https://www.uniassignment.com/essay-samples/information-technology/the-introduction-to-smart-home-technologies-information-technology-essay.php)
- [31] R. E. Schantz and D. C. Schmidt, "Middleware for Distributed Systems," in Wiley Encyclopedia of Computer Science and Engineering. John Wiley & Sons, Inc., 2007. [Online]. Available: [http://onlinelibrary.wiley.com/doi/10.1002/ 9780470050118.ecse241/abstract](http://onlinelibrary.wiley.com/doi/10.1002/9780470050118.ecse241/abstract)
- [32] M. V. Moreno, B. beda, A. F. Skarmeta, and M. A. Zamora, "How can We Tackle Energy Efficiency in IoT Based Smart Buildings?" Sensors (Basel, Switzerland), vol. 14, no. 6, pp. 9582–9614, May 2014. [Online]. Available: [https://www.ncbi.nlm.nih.gov/pmc/articles/ PMC4118407/](https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4118407/)
- [33] O. Hersent, D. Boswarthick, and O. Elloumi, The Internet of Things: Key Applications and Protocols, 2nd ed. Chichester, West Sussex: Wiley, Feb. 2012.
- [34] K. Pohl, G. Bckle, and F. J. v. d. Linden, Software Product Line Engineering: Foundations, Principles and Techniques, 2005th ed. New York, NY: Springer, Sep. 2005.
- [35] S. C. Mukhopadhyay, "Wearable Sensors for Human Activity Monitoring: A Review," IEEE Sensors Journal, vol. 15, no. 3, pp. 1321–1330, Mar. 2015.
- [36] D. Ding, R. A. Cooper, P. F. Pasquina, and L. Fici-Pasquina, "Sensor technology for smart homes," Maturitas, vol. 69, no. 2, pp. 131–136, Jun. 2011. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0378512211000983>
- [37] D. T.-P. Fong and Y.-Y. Chan, "The use of wearable inertial motion sensors in human lower limb biomechanics studies: a systematic review," Sensors (Basel, Switzerland), vol. 10, no. 12, pp. 11 556–11 565, 2010.
- [38] T. Yilmaz, R. Foster, and Y. Hao, "Detecting vital signs with wearable wireless sensors," Sensors (Basel, Switzerland), vol. 10, no. 12, pp. 10 837–10 862, 2010.
- [39] P. Lpez, D. Fernndez, A. J. Jara, and A. F. Skarmeta, "Survey of Internet of Things Technologies for Clinical Environments," in 2013 27th International Conference on Advanced Information Networking and Applications Workshops, Mar. 2013, pp. 1349–1354.
- [40] V. Smith, T. Sookoor, and K. Whitehouse, "Modeling building thermal response to HVAC zoning," ACM SIGBED Review, vol. 9, no. 3, pp. 39–45, 2012.

[41] N. Forouzandehmehr, S. M. Perlaza, Z. Han, and H. V. Poor, “A satisfaction game for heating, ventilation and air conditioning control of smart buildings,” Dec. 2013, pp. 3164–3169.

[42] A. Kottolli, “How Innovations in IoT & Smart Buildings are creating Sustainable Work Places,” Dec. 2015. [Online]. Available: <https://www.linkedin.com/pulse/how-innovations-iot-smart-buildings-creating-work-places-kottolli/>

[43] K. Akkaya, I. Guvenc, R. Aygun, N. Pala, and A. Kadri, “IoT-based occupancy monitoring techniques for energy-efficient smart buildings,” in 2015 IEEE Wireless Communications and Networking Conference Workshops (WCNCW), Mar. 2015, pp. 58–63.

[44] “WEMO,” Dec. 2017. [Online]. Available: <http://www.wemo.com/>

[45] “Nest,” Dec. 2017. 2017. [Online]. Available: [Online]. Available: <https://www.nest.com/>

[46] “Lockitron,” Dec. <https://lockitron.com/>

[47] “SmartThings,” Dec. 2017. <https://www.smartthings.com/>

[48] “Philips Hue,” Dec. 2017. [Online]. Available: <http://www2.meethue.com/>

[49] “Oleo Apps Inc. , BluFit Bottle,,” Dec. 2017. [Online]. Available: <http://www.indigodomo.com/>

[50] “Canary - A complete security system in a single device.” Dec. 2017. [Online]. Available: <https://canary.is/>

[51] R. Crist and D. Carnoy, “Amazon Echo review,” Dec. 2017. [Online]. Available: <https://www.cnet.com/products/amazon-echo-review/> [52] “Home - Honeywell Security Group,” Dec. 2017. [Online]. Available:<http://www.security.honeywell.com/index.html>

[53] K. Karamantas, “Smart home technologies and remote access,” Master of Science in Networking and Data Communications, Kingston University, School Of Computing And Information Systems, UK, Jul. 2010. [Online]. Available: <http://docplayer.net/37654484-Smart-home-technologies-and-remote-access-karamantas-eystratios-master-of-science-in-networking-and-data-communications-thesis.html>

[54] C. Perera, C. H. Liu, S. Jayawardena, and M. Chen, “A Survey on Internet of Things From Industrial Market Perspective,” IEEE Access, vol. 2, pp. 1660–1679, 2014.

[55] S. Gupta, “Home gateway,” 2004.

[56] S. Chernbumroong, A. Atkins, and H. Yu, “Perception of Smart Home Technologies to Assist Elderly People,” Paro, Bhutan, 2010.

[57] P. Carner, “Project Domus: Designing Effective Smart Home Systems,” BSc in Information Systems and Information Technology (DT249), Dublin Institute of Technology, Dublin, Ireland, Apr. 2009.

[58] “Open Software Platform for the Smart Home,” Dec. 2014. [Online]. Available: <http://newsroom.cisco.com/press-release-content?type=webcontent&articleId=1559246>

[59] “Mozaik.” [Online]. Available: <https://www.mozaik.io/>

[60] The Indigo Smart Home System for Mac OS X. [Online]. Available: <http://www.indigodomo.com/>

[61] “openHAB.” [Online]. Available: <http://www.openhab.org/>

[62] L. Smirek, G. Zimmermann, and D. Ziegler, “Towards Universally Usable Smart Homes How Can MyUI, URC and openHAB Contribute to an Adaptive User Interface Platform?”

[63] J. Ong, “SmartThings officially launches its connected home platform with a new certification program,” May 2014. [Online]. Available: <https://thenextweb.com/insider/2014/05/21/smartthings-officially-launches-connected-home-platform-new-certification-program/>

[64] C. Dixon, R. Mahajan, S. Agarwal, A. J. Brush, B. Lee, S. Saroiu, and P. Bahl, “An Operating System for the Home,” in Proceedings of the 9th USENIX Conference on Networked Systems Design and Implementation, ser. NSDI’12. Berkeley, CA, USA: USENIX Association, 2012, pp. 25– 25. [Online]. Available: <http://dl.acm.org/citation.cfm?id=2228298.2228332>

[65] F. AL-Riyami, “Microsofts Lab of Things platform is an IoT development playground with life- changing potential.” [Online]. Available: <https://www.onmsft.com/news/microsofts-lab-things-platform-iot-development-playground-life-changing-potential>

[66] A. J. B. Brush, R. Mahajan, and A. Samuel, “Lab of Things: Simplifying and Scaling Deployments of Experimental Technology in Homes,” in Handbook of Smart Homes, Health Care and Well-Being, J. van Hoof, G. Demiris, and E. J. Wouters, Eds. Cham: Springer International Publishing, 2014. [Online]. Available: https://doi.org/10.1007/978-3-319-01904-8_35-1

[67] “Lab Of Things,” Jan. 2018. [Online]. Available: <https://labofthings.codeplex.com/Wikipage?ProjectName=labofthings>

[68] G.-M. Jeong, P. H. Truong, T.-Y. Lee, J.-W. Choi, and M. Lee, “Course design for Internet of Things using Lab of Things of Micro-soft Research,” in 2016 IEEE Frontiers in Education Conference (FIE), Oct. 2016, pp. 1–6.

[69] “Eclipse SmartHome - A Flexible Framework for the Smart Home,” Jan. 2018. [Online]. Available: <https://www.eclipse.org/smarthome/>

[70] L. Smirek, G. Zimmermann, and M. Beigl, “Just a Smart Home or Your Smart Home A Framework for Personalized User Interfaces Based on Eclipse Smart Home and Universal Remote Console,” Procedia Computer Science, vol. 98, pp. 107–116, Jan. 2016. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S1877050916321391>

[71] J. Eriksson, F. sterlind, N. Finne, N. Tsiftes, A. Dunkels, T. Voigt, R. Sauter, and P. J. Marrn, “COOJA/MSPSim: interoperability testing for wireless sensor networks,” in Proceedings of the 2nd International Conference on Simulation Tools and Techniques. ICST (Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering), 2009, p. 27.

[72] P. Kugler, P. Nordhus, and B. Eskofier, “Shimmer, Cooja and Contiki: A new toolset for the simulation of on-node signal processing algorithms,” in 2013 IEEE International Conference on Body Sensor Networks, May 2013, pp. 1–6.

[73] M. Bilal, L. O. Oyedele, J. Qadir, K. Munir, S. O. Ajayi, O. O. Akinade, H. A. Owolabi, H. A. Alaka, and M. Pasha, “Big data in the construction industry: A review of present status, opportunities, and future trends,” Advanced engineering informatics, vol. 30, no. 3, pp. 500–521, 2016.

[74] M. Bilal, L. O. Oyedele, O. O. Akinade, S. O. Ajayi, H. A. Alaka, H. A. Owolabi, J. Qadir, M. Pasha, and S. A. Bello, “Big data architecture for construction waste analytics (cwa): A conceptual framework,” Journal of Building Engineering, vol. 6, pp. 144–156, 2016.

[75] M. Bilal, L. O. Oyedele, J. Qadir, K. Munir, O. O. Akinade, S. O. Ajayi, H. A. Alaka, and H. A. Owolabi, “Analysis of critical features and evaluation of bim software: towards a plug-in for construction waste minimization using big data,” International Journal of Sustainable Building Technology and Urban Development, vol. 6, no. 4, pp. 211– 228, 2015.

[76] J. Boger, J. Hoey, P. Poupart, C. Boutilier, G. Fernie, and A. Mihailidis, “A planning system based on Markov decision processes to guide people with dementia through activities of daily living,” IEEE Transactions on Information Technology in Biomedicine, vol. 10, no. 2, pp. 323–333, Apr. 2006.

[77] A. Fleury, N. Noury, and M. Vacher, “Introducing knowledge in the process of supervised classification of activities of Daily Living in Health Smart Homes,” in The 12th IEEE International Conference on e-Health Networking, Applications and Services, Jul. 2010, pp. 322– 329.

[78] S. Belaidouni and M. Miraoui, “Machine Learning Technologies in Smart Spaces,” 2016, pp. 52–55.

[79] S. Stenudd, “Using machine learning in the adaptive control of a smart environment,” VTT Publications 751, p. 82, 2010. [Online]. Available: <https://www.vtt.fi/inf/pdf/publications/2010/P751.pdf>

[80] T. Hastie, R. Tibshirani, and J. Friedman, “Unsupervised Learning,” in The Elements of Statistical Learning: Data Mining, Inference, and Prediction, Second Edition, 2nd ed. New York, NY: Springer, 2016.

[81] R. O. Duda, P. E. Hart, and D. G. Stork, Pattern Classification, 2nd ed. New York: Wiley- Interscience, Nov. 2000.

[82] J. Lapalu, K. Bouchard, A. Bouzouane, B. Bouchard, and S. Giroux, “Unsupervised Mining of Activities for Smart Home Prediction,” Procedia Computer Science, vol. 19, pp. 503–510, Jan. 2013. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S1877050913006753>

[83] A. N. Aicha, G. Englebienne, and B. Krse, “Modeling Visit Behaviour in Smart Homes Using Unsupervised Learning,” in Proceedings of the 2014 ACM International Joint Conference on Pervasive and Ubiquitous Computing: Adjunct Publication, ser. UbiComp ’14 Adjunct. New York, NY, USA: ACM, 2014, pp. 1193–1200. [Online]. Available: <http://doi.acm.org/10.1145/2638728.2638809>

[84] K. Altun, B. Barshan, and O. Tunel, “Comparative study on classifying human activities with miniature inertial and magnetic sensors,” Pattern Recognition, vol. 43, no. 10, pp. 3605–3620, Oct. 2010. [Online]. Available: <http://linkinghub.elsevier.com/retrieve/pii/S0031320310001950>

[85] M. C. Mozer, “The Neural Network House: AnEnvironmentthat Adapt- sto its Inhabitants,” 1998, p. 5.

[86] S. T. M. Bourobou and Y. Yoo, “User Activity Recognition in Smart Homes Using Pattern Clustering Applied to Temporal ANN Algorithm,” Sensors (Basel, Switzerland), vol. 15, no. 5, pp. 11 953–11 971, May 2015. [Online]. Available: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4481973/>

[87] S. H. Hsu, M.-H. Wen, H.-C. Lin, C.-C. Lee, and C.-H. Lee, “AIMED-A Personalized TV Recommendation System,” in Interactive TV: a Shared Experience, ser. Lecture Notes in Computer Science, P. Cesar, K. Chorianopoulos, and J. F. Jensen, Eds. Springer Berlin Heidelberg, 2007, pp. 166–174.

[88] A. Fleury, M. Vacher, and N. Noury, “SVM-Based Multimodal Classification of Activities of Daily Living in Health Smart Homes: Sensors, Algorithms, and First Experimental Results,” IEEE Transactions on Information Technology in Biomedicine, vol. 14, no. 2, pp. 274–283, Mar. 2010.

[89] X. Wu, V. Kumar, J. Ross Quinlan, J. Ghosh, Q. Yang, H. Motoda, G. J. McLachlan, A. Ng, B. Liu, P. S. Yu, Z.-H. Zhou, M. Steinbach, D. J. Hand, and D. Steinberg, “Top 10 algorithms in data mining,” Knowledge and Information Systems, vol. 14, no. 1, pp. 1–37,

- Jan. 2008. [Online]. Available: <https://doi.org/10.1007/s10115-007-0114-2>
- [90] Y.-y. SONG and Y. LU, “Decision tree methods: applications for classification and prediction,” Shanghai Archives of Psychiatry, vol. 27, no. 2, pp. 130–135, Apr. 2015. [Online]. Available: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4466856/>
- [91] L. Rokach and O. Maimon, “Decision Trees,” in Data Mining and Knowledge Discovery Handbook, O. Maimon and L. Rokach, Eds. Boston, MA: Springer US, 2005, pp. 165–192. [Online]. Available: https://doi.org/10.1007/0-387-25465-X_9
- [92] M. Delgado, M. Ros, and M. Amparo Vila, “Correct behavior identification system in a Tagged World,” Expert Systems with Applications, vol. 36, no. 6, pp. 9899–9906, Aug. 2009. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S095741740900116X>
- [93] M. Viswanathan, “Distributed Data Mining in a Ubiquitous Healthcare Framework,” in Advances in Artificial Intelligence, ser. Lecture Notes in Computer Science, Z. Kobti and D. Wu, Eds. Springer Berlin Heidelberg, 2007, pp. 261–271.
- [94] I. H. Witten, E. Frank, and M. A. Hall, Data Mining: Practical Machine Learning Tools and Techniques, 3rd ed. Burlington, MA: Morgan Kaufmann, Jan. 2011.
- [95] A. Parnandi, K. Le, P. Vaghela, A. Kolli, K. Dantu, S. Poduri, and G. S. Sukhatme, “Coarse In-Building Localization with Smart-phones,” in Mobile Computing, Applications, and Services, ser. Lecture Notes of the Institute for Computer Sciences, Social Informatics and Telecommunications Engineering. Springer, Berlin, Heidelberg, Oct. 2009, pp. 343–354. [Online]. Available: https://link.springer.com/chapter/10.1007/978-3-642-12607-9_25
- [96] K. Verbert, R. Babuka, and B. De Schutter, “Combining knowledge and historical data for system-level fault diagnosis of HVAC systems,” Engineering Applications of Artificial Intelligence, vol. 59, pp. 260–273, Mar. 2017. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S095219761630255X>
- [97] O. Brdiczka, P. Reignier, and J. L. Crowley, “Detecting Individual Activities from Video in a Smart Home,” in Knowledge-Based Intelligent Information and Engineering Systems, ser. Lecture Notes in Computer Science, B. Apolloni, R. J. Howlett, and L. Jain, Eds. Springer Berlin Heidelberg, 2007, pp. 363–370.
- [98] T. v. Kasteren and B. Krose, “Bayesian activity recognition in residence for elders,” in 2007 3rd IET International Conference on Intelligent Environments, Sep. 2007, pp. 209–212.
- [99] A. Badlani and S. Bhanot, “Smart Home System Design based on Artificial Neural Networks,” in Proceedings of the World Congress on Engineering and Computer Science 2011, San Francisco, USA, Oct. 2011, pp. 106–111.
- [100] E. Campo, S. Bonhomme, M. Chan, and D. Esteve, “Learning life habits and practices: an issue to the smart home,” in 4th international conference on smart Homes and health telematic, Belfast, Northern Ireland, 2006, pp. 355–358. [Online]. Available: <http://ebooks.iospress.nl/volumearticle/574>
- [101] R. Begg and R. Hassan, “Artificial Neural Networks in Smart Homes,” in Designing Smart Homes: The Role of Artificial Intelligence, ser. Lecture Notes in Computer Science, J. C. Augusto and C. D. Nugent, Eds. Berlin, Heidelberg: Springer Berlin Heidelberg, 2006, pp. 146–164. [Online]. Available: https://doi.org/10.1007/11788485_9
- [102] M. Ermes, J. Prkk, J. Mntyjrvi, and I. Korhonen, “Detection of Daily Activities and Sports With Wearable Sensors in Controlled and Uncontrolled Conditions,” IEEE Transactions on Information Technology in Biomedicine, vol. 12, no. 1, pp. 20–26, Jan. 2008.
- [103] L. Ciabattoni, G. Ippoliti, A. Benini, S. Longhi, and M. Pirro, “Design of a Home Energy Management System by Online Neural Networks,” IFAC Proceedings Volumes, vol. 46, no. 11, pp. 677–682, Jan. 2013. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S1474667016330221>
- [104] J. V. Tu, “Advantages and disadvantages of using artificial neural networks versus logistic regression for predicting medical outcomes,” Journal of Clinical Epidemiology, vol. 49, no. 11, pp. 1225–1231, Nov. 1996. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0895435696000029>
- [105] Y. Fu, Z. Li, H. Zhang, and P. Xu, “Using Support Vector Machine to Predict Next Day Electricity Load of Public Buildings with Sub-metering Devices,” Procedia Engineering, vol. 121, pp. 1016–1022, Jan. 2015. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S1877705815029252>
- [106] Q. C. Nguyen, D. Shin, D. Shin, and J. Kim, “Real-Time Human Tracker Based on Location and Motion Recognition of User for Smart Home,” in 2009 Third International Conference on Multimedia and Ubiquitous Engineering, Jun. 2009, pp. 243–250.
- [107] J. Petersen, N. Larimer, J. A. Kaye, M. Pavel, and T. L. Hayes, “SVM to detect the presence of visitors in a smart home environment,” Conference proceedings: ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Annual Conference, vol. 2012, pp. 5850–5853, 2012.
- [108] B. Das, D. J. Cook, N. C. Krishnan, and M. Schmitter-Edgecombe, “One-Class Classification-Based Real-Time Activity Error Detection in Smart Homes,” IEEE journal of selected topics in signal processing, vol. 10, no. 5, pp. 914–923, Aug. 2016. [109] A.
- [109] Parnandi, K. Le, P. Vaghela, A. Kolli, K. Dantu, S. Poduri, and G. S. Sukhatme, “Coarse In-Building Localization with Smart-phones,” in Mobile Computing, Applications, and Services, ser. Lecture Notes of the Institute for Computer Sciences, Social Informatics and Telecommunications Engineering, T. Phan, R. Montanari, and P. Zerfos, Eds. Springer Berlin Heidelberg, 2010, pp. 343–354.
- [110] B.-C. Cheng, Y.-A. Tsai, G.-T. Liao, and E.-S. Byeon, “HMM machine learning and inference for Activities of Daily Living recognition,” The Journal of Supercomputing, vol. 54, no. 1, pp. 29–42, Oct. 2010. [Online]. Available: <https://doi.org/10.1007/s11227-009-0335-0>
- [111] P. Chahuara, A. Fleury, F. Portet, and M. Vacher, “On-line Human Activity Recognition from Audio and Home Automation Sensors: comparison of sequential and non-sequential models in realistic Smart Homes,” Journal of ambient intelligence and smart environments, vol. 8, no. 4, pp. 399–422, Jul. 2016. [Online]. Available: <https://hal.archives-ouvertes.fr/hal-01336552>
- [112] F. Lv and R. Nevatia, “Recognition and Segmentation of 3-D Human Action Using HMM and Multi-class AdaBoost,” in Computer Vision ECCV 2006, ser. Lecture Notes in Computer Science, A. Leonardis, H. Bischof, and A. Pinz, Eds. Springer Berlin Heidelberg, 2006, pp. 359–372.
- [113] E. Wu, P. Zhang, T. Lu, H. Gu, and N. Gu, “Behavior prediction using an improved Hidden Markov Model to support people with disabilities in smart homes,” in 2016 IEEE 20th International Conference on Computer Supported Cooperative Work in Design (CSCWD), May 2016, pp. 560–565.
- [114] S. Choi, E. Kim, and S. Oh, “Human behavior prediction for smart homes using deep learning,” in 2013 IEEE RO-MAN, Aug. 2013, pp. 173–179.
- [115] F. Ordez, D. Roggen, F. J. Ordez, and D. Roggen, “Deep Convolutional and LSTM Recurrent Neural Networks for Multimodal Wearable Activity Recognition,” Sensors, vol. 16, no. 1, p. 115, Jan. 2016. [Online]. Available: <http://www.mdpi.com/1424-8220/16/1/115>
- [116] M. A. Alsheikh, A. Selim, D. Niyato, L. Doyle, S. Lin, and H.-P. Tan, “Deep Activity Recognition Models with Triaxial Accelerometers,” Oct. 2016, p. 6.
- [117] M. Baccouche, F. Mamalet, C. Wolf, C. Garcia, and A. Baskurt, “Sequential Deep Learning for Human Action Recognition,” in Human Behavior Understanding, ser. Lecture Notes in Computer Science, A. A. Salah and B. Lepri, Eds. Springer Berlin Heidelberg, 2011, pp. 29–39.
- [118] Y. Chen and Y. Xue, “A Deep Learning Approach to Human Activity Recognition Based on Single Accelerometer,” in 2015 IEEE International Conference on Systems, Man, and Cybernetics, Oct. 2015, pp. 1488–1492.
- [119] C. A. Ronao and S.-B. Cho, “Human activity recognition with smartphone sensors using deep learning neural networks,” Expert Systems with Applications, vol. 59, pp. 235–244, Oct. 2016. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0957417416302056>
- [120] X. Chen, X. Li, and S. X. Tan, “From robust chip to smart building: CAD algorithms and methodologies for uncertainty analysis of building performance,” in 2015 IEEE/ACM International Conference on Computer-Aided Design (ICCAD), Nov. 2015, pp. 457–464.
- [121] K. Bouchard, B. Bouchard, and A. Bouzouane, “Regression analysis for gesture recognition using RFID technology,” in 2014 IEEE International Conference on Pervasive Computing and Communication Workshops (PERCOM WORKSHOPS), Mar. 2014, pp. 1–8. [Online]. Available: doi.ieeecomputersociety.org/10.1109/PerComW.2014.6815280
- [122] A. Jurek, C. Nugent, Y. Bi, and S. Wu, “Clustering-Based Ensemble Learning for Activity Recognition in Smart Homes,” Sensors (Basel, Switzerland), vol. 14, no. 7, pp. 12 285–12 304, Jul. 2014. [Online]. Available: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4168494/>
- [123] I. Fatima, M. Fahim, Y.-K. Lee, and S. Lee, “Classifier Ensemble Optimization for Human Activity Recognition in Smart Homes,” in Proceedings of the 7th International Conference on Ubiquitous Information Management and Communication, ser. ICUIMC ’13. New York, NY, USA: ACM, 2013, pp. 83:1–83:7. [Online]. Available: <https://doi.acm.org/10.1145/2448556.2448639>
- [124] Y. Guan and T. Pltz, “Ensembles of Deep LSTM Learners for Activity Recognition Using Wearables,” Proc. ACM Interact. Mob. Wearable Ubiquitous Technol., vol. 1, no. 2, pp. 11:1–11:28, Jun. 2017. [Online]. Available: <https://doi.acm.org/10.1145/3090076>
- [125] N. K. Survadevara, S. C. Mukhopadhyay, and R. K. Rayudu, “Applying SARIMA time series to forecast sleeping activity for wellness model of elderly monitoring in smart home,” in 2012 Sixth International Conference on Sensing Technology (ICST), Dec. 2012, pp. 157–162.
- [126] Y. Zhou, Z. Kang, L. Zhang, and C. Spanos, “Causal analysis for non-stationary time series in sensor-rich smart buildings,” in 2013 IEEE International Conference on Automation Science and Engineering (CASE), Aug. 2013, pp. 593–598.
- [127] V. R. Jakkula and D. J. Cook, “Learning temporal relations in smart home data,” in Proceedings of the second International

Conference on Technology and Aging. Canada.(To, 2007.

[128] L. G. Fahad, S. F. Tahir, and M. Rajarajan, “Activity Recognition in Smart Homes Using Clustering Based Classification,” in 2014 22nd International Conference on Pattern Recognition, Aug. 2014, pp. 1348– 1353.

[129] P. Rashidi and D. J. Cook, “Keeping the Resident in the Loop: Adapting the Smart Home to the User,” IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans, vol. 39, no. 5, pp. 949–959, Sep. 2009.

[130] P. Rashidi, D. J. Cook, L. B. Holder, and M. Schmitter-Edgecombe, “Discovering Activities to Recognize and Track in a Smart Envi- ronment,” IEEE Transactions on Knowledge and Data Engineering, vol. 23, no. 4, pp. 527–539, Apr. 2011.

[131] D. J. Cook, “Learning Setting-Generalized Activity Models for Smart Spaces,” IEEE intelligent systems, vol. 2010, no. 99, p. 1, Sep. 2010. [Online]. Available: [https://www.ncbi.nlm.nih.gov/pmc/articles/ PMC3068197/](https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3068197/)

[132] T. Liu, H. Yao, R. Ji, Y. Liu, X. Liu, X. Sun, P. Xu, and Z. Zhang, “Vision-Based Semi-supervised Homecare with Spatial Con- straint,” in Advances in Multimedia Information Processing - PCM 2008, ser. Lecture Notes in Computer Science, Y.-M. R. Huang, C. Xu, K.-S. Cheng, J.-F. K. Yang, M. N. S. Swamy, S. Li, and J.-W. Ding, Eds. Springer Berlin Heidelberg, 2008, pp. 416–425.

[133] P. N. A. Fahmi, V. Viet, and C. Deok-Jai, “Semi-supervised fall detection algorithm using fall indicators in smartphone,” in Proceedings of the 6th International Conference on Ubiquitous Information Management and Communication - ICUIMC ’12. Kuala Lumpur, Malaysia: ACM Press, 2012, p. 1. [Online]. Available: <http://dl.acm.org/citation.cfm?doid=2184751.2184890>

[134] V. Radu, P. Katsikouli, R. Sarkar, and M. K. Marina, “A semi- supervised learning approach for robust indoor-outdoor detection with smartphones,” in Proceedings of the 12th ACM Conference on Embedded Network Sensor Systems - SenSys ’14. Memphis, Tennessee: ACM Press, 2014, pp. 280–294. [Online]. Available: <http://dl.acm.org/citation.cfm?doid=2668332.2668347>

[135] D. Guan, W. Yuan, Y. Lee, A. Gavrilov, and S. Lee, “Activity Recogni- tion Based on Semi- supervised Learning,” in 13th IEEE International Conference on Embedded and Real-Time Computing Systems and Applications (RTCSA 2007), Aug. 2007, pp. 469–475.

[136] M. C. Mozer, “Lessons from an Adaptive Home,” in Smart Envi- ronments. Wiley-Blackwell, 2005, pp. 271–294. [Online]. Avail- able: <https://onlinelibrary.wiley.com/doi/abs/10.1002/047168659X.ch12>

[137] D. Li and S. K. Jayaweera, “Reinforcement learning aided smart-home decision-making in an interactive smart grid,” in 2014 IEEE Green Energy and Systems Conference (IGESC), Nov. 2014, pp. 1–6.

[138] A. H. Khalili, C. Wu, and H. Aghajan, “Autonomous Learning of Users Preference of Music and Light Services in Smart Home Applications,” in Behavior Monitoring and Interpretation Workshop at German AI Conf, Sep. 2009, p. 12.

[139] X. Xu, L. Zuo, and Z. Huang, “Reinforcement Learning Algorithms with Function Approximation: Recent Advances and Appli- cations,” Inf. Sci., vol. 261, pp. 1–31, Mar. 2014. [Online]. Available: <https://doi.org/10.1016/j.ins.2013.08.037>

[140] A. Desarkar and A. Das, “Big-Data Analytics, Machine Learning Algorithms and Scalable/Parallel/Distributed Algorithms,” in Internet of Things and Big Data Technologies for Next Generation Healthcare, ser. Studies in Big Data, C. Bhatt, N. Dey, and A. S. Ashour, Eds. Cham: Springer International Publishing, 2017, pp. 159–197. [Online]. Available: https://doi.org/10.1007/978-3-319-49736-5_8

[141] R. Burbidge and B. Buxton, “An introduction to support vector ma- chines for data mining,” in Keynote Papers, Young or12, University of Nottingham, Operational Research Society, Operational Research Society, 2001, pp. 3–15.

[142] D. Meyer, Support Vector Machines. The Interface to libsvm in package e1071, Jul. 2018.

[143] H. Zhao, Q. Hua, H.-B. Chen, Y. Ye, H. Wang, S. X.-D. Tan, and E. Tlelo-Cuautle, “Thermal-Sensor- Based Occupancy Detection for Smart Buildings Using Machine-Learning Methods,” ACM Transactions on Design Automation of Electronic Systems, vol. 23, no. 4, pp. 1–21, June 2018. [Online]. Available: <http://dl.acm.org/citation.cfm?doid=3217208.3200904>

[144] X. Chen and X. Lin, “Big Data Deep Learning: Challenges and Perspectives,” IEEE Access, vol. 2, pp. 514–525, 2014.

[145] M. A. Nielsen, “Neural Networks and Deep Learning,” Determination Press, Dec. 2017. [Online]. Available: [http://neuralnet- worksanddeeplearning.com](http://neuralnet-worksanddeeplearning.com)

[146] How technology can bridge language gaps, May 2013. [Online]. Available: [https://www.microsoft.com/en-us/research/blog/ technology-can-bridge-language-gaps/](https://www.microsoft.com/en-us/research/blog/technology-can-bridge-language-gaps/)

[147] M. Berry, T. E. Potok, P. Balaprakash, H. Hoffmann, and R. Vatsavai, “Machine Learning and Understanding for Intelligent Extreme Scale Scientific Computing and Discovery,” Advanced Scientific Computing Research (ASCR) Division of the Office of Science, U.S. Department of Energy, Rockville, MD, DOE Workshop Report, Jan. 2015. [Online]. Available: [https://www.ornl.gov/machinelearning2015/ Machine Learning DOE Workshop Report 6.pdf](https://www.ornl.gov/machinelearning2015/Machine%20Learning%20DOE%20Workshop%20Report%206.pdf)

[148] N. Y. Hammerla, S. Halloran, and T. Plotz, “Deep, Convolutional, and Recurrent Models for Human Activity Recognition Using Wearables,” Apr. 2016, pp. 1533 – 1540.

[149] T.-c. Fu, “A review on time series data mining,” Engineering Applications of Artificial Intelligence, vol. 24, no. 1, pp. 164–181, Feb. 2011. [Online]. Available: [http://www.sciencedirect.com/science/ article/pii/S0952197610001727](http://www.sciencedirect.com/science/article/pii/S0952197610001727)

[150] P. Esling and C. Agon, “Time-series Data Mining,” ACM Comput. Surv., vol. 45, no. 1, pp. 12:1– 12:34, Dec. 2012. [Online]. Avail- able: <http://doi.acm.org/10.1145/2379776.2379788>

[151] F. Chen, P. Deng, J. Wan, D. Zhang, A. V. Vasilakos, and X. Rong, “Data Mining for the Internet of Things: Literature Re- view and Challenges,” Int. J. Distrib. Sen. Netw., vol. 2015, pp. 12:12–12:12, Jan. 2015. [Online]. Available: [https://doi. org/10.1155/2015/431047](https://doi.org/10.1155/2015/431047)

[152] W. Bhmer and K. Obermayer, “Regression with Linear Factored Functions,” in Machine Learning and Knowledge Discovery in Databases, ser. Lecture Notes in Computer Science, A. Appice, P. P. Rodrigues, V. Santos Costa, C. Soares, J. Gama, and A. Jorge, Eds. Springer International Publishing, 2015, pp. 119–134.

[153] J. Brownlee, “A Tour of Machine Learning Algorithms,” Nov. 2013. [Online]. Available: [https://machinelearningmastery.com/a- tour-of-machine-learning-algorithms/](https://machinelearningmastery.com/a-tour-of-machine-learning-algorithms/)

[154] L. Rokach, “Ensemble-based classifiers,” Artificial Intelligence Review, vol. 33, no. 1, pp. 1–39, Feb. 2010. [Online]. Avail- able:<https://doi.org/10.1007/s10462-009-9124-7>

[155] Y. Bian and J. B. Holland, “Ensemble Learning of QTL Models Improves Prediction of Complex Traits,” G3 (Bethesda, Md.), vol. 5, no. 10, pp. 2073–2084, Aug. 2015.

[156] M. Usama, J. Qadir, A. Raza, H. Arif, K.-L. A. Yau, Y. Elkhatib, A. Hussain, and A. Al-Fuqaha, “Unsupervised machine learning for networking: Techniques, applications and research challenges,” arXiv preprint arXiv:1709.06599, 2017.

[157] B. Wooley, Scaling Clustering for the Data Mining Step in Knowledge Discovery, 1999. [Online]. Available: [http://penguin.lhup. edu/bwooley/ presentation SIGCSE99 scalable KD/paper.html](http://penguin.lhup.edu/bwooley/presentation/SIGCSE99%20scalable%20KD/paper.html)

[158] L. Rokach and O. Maimon, “Clustering Methods,” in Data Mining and Knowledge Discovery Handbook, O. Maimon and L. Rokach, Eds. Boston, MA: Springer US, 2005, pp. 321–352. [Online]. Available: https://doi.org/10.1007/0-387-25465-X_15

[159] L. Fiorini, F. Cavallo, P. Dario, A. Eavis, and P. Caleb-Solly, “Unsupervised Machine Learning for Developing Personalised Behaviour Models Using Activity Data,” Sensors (Basel, Switzerland), vol. 17, no. 5, May 2017. [Online]. Available: [https://www. ncbi.nlm.nih.gov/pmc/articles/PMC5469639/](https://www.ncbi.nlm.nih.gov/pmc/articles/PMC5469639/)

[160] P.-N. Tan, M. Steinbach, and V. Kumar, Introduction to Data Mining, 1st ed. Boston: Pearson, May 2005.

[161] A. Aztiria, J. C. Augusto, R. Basagoiti, A. Izaguirre, and D. J. Cook, “Learning Frequent Behaviors of the Users in Intelligent Environ- ments,” IEEE Transactions on Systems, Man, and Cybernetics: Systems, vol. 43, no. 6, pp. 1265–1278, Nov. 2013.

[162] K. J. Kang, B. Ka, and S. J. Kim, “A Service Scenario Generation Scheme Based on Association Rule Mining for Elderly Surveil- lance System in a Smart Home Environment,” Eng. Appl. Artif. Intell., vol. 25, no. 7, pp. 1355–1364, Oct. 2012. [Online]. Available: <http://dx.doi.org/10.1016/j.engappai.2012.02.003>

[162] E. Nazerfard, P. Rashidi, and D. J. Cook, “Using Association Rule Mining to Discover Temporal Relations of Daily Activities,” in Toward Useful Services for Elderly and People with Disabilities, ser. Lecture Notes in Computer Science, B. Abdulrazak, S. Giroux, B. Bouchard, H. Pigot, and M. Mokhtari, Eds. Springer Berlin Heidelberg, 2011, pp. 49–56.

[164] X. Zhu, “Semi-Supervised Learning Literature Survey,” Computer Science, University of Wisconsin- Madison, Technical Report 1530.

[165] S. Sukode, S. Gite, and H. Agrawal, “Context Aware Framework in IoT: A survey,” International Journal, vol. 4, no. 1, 2015.

[167] K. Judah, S. Roy, A. Fern, and T. G. Dietterich, “Reinforcement Learning Via Practice and Critique Advice,” in Proceedings of the Twenty-Fourth AAAI Conference on Artificial Intelligence (AAAI-10), 2010, pp. 481 – 486.

[168] S. Gu, T. Lillicrap, I. Sutskever, and S. Levine, “Continuous Deep Q-learning with Model-based Acceleration,” in Proceedings of the 33rd International Conference on International Conference on Machine Learning - Volume 48, ser. ICML’16. New York, NY, USA: JMLR.org, 2016, pp. 2829–2838. [Online]. Available: <http://dl.acm.org/citation.cfm?id=3045390.3045688>

[169] M. Abu-Elkheir, M. Hayajneh, and N. A. Ali, “Data Management for the Internet of Things: Design Primitives and Solution,” Sensors, vol. 13, no. 11, pp. 15 582–15 612, Nov. 2013. [Online]. Available: <http://www.mdpi.com/1424-8220/13/11/15582>

[170] A. Karkouch, H. Mousannif, H. Al Moatassime, and T. Noel, “Data quality in internet of things: A state-of-the-art survey,” Jour- nal of Network and Computer Applications, vol. 73, pp. 57–81, Sep. 2016. [Online]. Available: [http://linkinghub.elsevier.com/ retrieve/pii/ S1084804516301564](http://linkinghub.elsevier.com/retrieve/pii/S1084804516301564)

[171] L. Zhao, J. Zhang, and R. Liang, “Data Acquisition and Transmission System for Building Energy Consumption Moni- toring,” Abstract and Applied Analysis, vol. 2013, pp. 1–8, 2013. [Online]. Available: [http://www.hindawi.com/journals/ aaa/2013/613043/](http://www.hindawi.com/journals/aaa/2013/613043/)

[172] P. Rowley, R. Gough, N. Doylend, A. Thirkill, and P. Leicester, “From smart homes to smart communities: Advanced data acquisition and analysis for improved sustainability and decision making,” in International Conference on Information Society (i-Society 2013), Jun. 2013, pp. 263– 268.

[173] “Mmea.” [Online]. Available: <http://mmea.fi/> [173] “e3portaali.” [Online]. Available: <http://e3portal.vtt.fi>

[174] “List of Home Datasets.” [Online]. Available: [http:// boxlab.wikispaces.com/List+of+Home+Datasets](http://boxlab.wikispaces.com/List+of+Home+Datasets)

[175] A. Yang, A. Giani, and R. Giannattonio, Distributed Human Action Recognition via Wearable Motion Sensor Networks. [Online]. Available: <https://people.eecs.berkeley.edu/yang/software/WAR/>

[176] “Activity Recognition in the Home Setting Using Simple and Ubiquitous Sensors,” Jan. 2018. [Online]. Available: <http://courses.media.mit.edu/2004fall/mas622j/04.projects/home/>

[177] O. Baos, M. Damas, H. Pomares, I. Rojas, M. A. Tth, and O. Amft, “A Benchmark Dataset to Evaluate Sensor Displacement in Activity Recognition,” in Proceedings of the 2012 ACM Conference on Ubiquitous Computing, ser. UbiComp ’12. New York, NY, USA: ACM, 2012, pp. 1026–1035. [Online]. Available: <http://doi.acm.org/10.1145/2370216.2370437>

[178] “CASAS,” Sep. 2018. [Online]. Available: <http://casas.wsu.edu/>

[179] D. Cook, M. Schmitter- Edgecombe, A. Crandall, C. Sanders, and B. Thomas, “Collecting and disseminating smart home sensor data in the CASAS project,” in Proceedings of the CHI Workshop on Developing Shared Home Behavior Datasets to Advance HCI and Ubiquitous Computing Research, 2009, pp. 1–7.

[180] The PlaceLab. [Online]. Available: [http://web.mit.edu/cron/group/ house n/placelab.html](http://web.mit.edu/cron/group/house n/placelab.html)

[181] B. Logan, J. Healey, M. Philipose, E. M. Tapia, and S. Intille, “A Long-term Evaluation of Sensing Modalities for Activity Recognition,” in Proceedings of the 9th International Conference on Ubiquitous Computing, ser. UbiComp ’07. Berlin, Heidelberg: Springer-Verlag, 2007, pp. 483–500. [Online]. Available: <http://dl.acm.org/citation.cfm?id=1771592.1771620>

[182] J. Kelly and W. Knottenbelt, “The UK-DALE dataset, domestic appliance-level electricity demand and whole-house demand from five UK homes,” Scientific Data, vol. 2, p. 150007, Mar. 2015, arXiv: 1404.0284. [Online]. Available: <http://arxiv.org/abs/1404.0284>

[183] U. Sivarajah, M. M. Kamal, Z. Irani, and V. Weerakkody, “Critical analysis of Big Data challenges and analytical methods,” Journal of Business Research, vol. 70, pp. 263–286, Jan. 2017. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S014829631630488X>

[184] C. C. Aggarwal, N. Ashish, and A. Sheth, “The Internet of Things: A Survey from the Data-Centric Perspective,” in Managing and Mining Sensor Data, C. C. Aggarwal, Ed. Boston, MA: Springer US, 2013, pp. 383–428. [Online]. Available: https://doi.org/10.1007/978-1-4614-6309-2_12

[185] C. C. Aggarwal and J. Han, “A Survey of RFID Data Processing,” in Managing and Mining Sensor Data, C. C. Aggarwal, Ed. Boston, MA: Springer US, 2013, pp. 349–382. [Online]. Available: https://doi.org/10.1007/978-1-4614-6309-2_11

[186] S. Gill, B. Lee, and E. Neto, “Context aware model-based cleaning of data streams,” in 2015 26th Irish Signals and Systems Conference (ISSC), Jun. 2015, pp. 1–6.

[187] K. Kenda, J. krbec, and M. krjanc, “Usage Of The Kalman Filter For Data Cleaning Of Sensor Data,” in Proceedings of the 16th International Multiconference Information Society, Ljubljana, 2013, pp. 172–175.

[188] A. Ghodsi, “Dimensionality Reduction A Short Tutorial,” Department of Statistics and Actuarial Science, Univ. of Waterloo, Ontario, Canada, vol. 37, 2006. [Online]. Available: <https://www.math.uwaterloo.ca/aghodsib/courses/f06stat890/readings/tutorial stat890.pdf>

[189] C. O. S. Sorzano, J. Vargas, and A. P. Montano, “A survey of dimensionality reduction techniques,” arXiv:1403.2877 [cs, q- bio, stat], Mar. 2014, arXiv: 1403.2877. [Online]. Available: <http://arxiv.org/abs/1403.2877>

[190] Y. Saeys, I. Inza, and P. Larraaga, “A review of feature selection techniques in bioinformatics,” Bioinformatics, vol. 23, no. 19, pp. 2507–2517, Oct. 2007. [Online]. Available: <https://academic.oup.com/bioinformatics/article/23/19/2507/185254>

[191] Y.-L. Chen, X. Wu, T. Li, J. Cheng, Y. Ou, and M. Xu, “Dimensionality reduction of data sequences for human activity recognition,” Neurocomputing, vol. 210, pp. 294–302, Oct. 2016. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S092523121630594X>

[192] F. Alas, J. Socor, X. Sevillano, F. Alas, J. C. Socor, and X. Sevillano, “A Review of Physical and Perceptual Feature Extraction Techniques for Speech, Music and Environmental Sounds,” Applied Sciences, vol. 6, no. 5, p. 143, May 2016. [Online]. Available: <http://www.mdpi.com/2076-3417/6/5/143>

[193] O. D. Lara and M. A. Labrador, “A Survey on Human Activity Recognition using Wearable Sensors,” IEEE Communications Surveys Tutorials, vol. 15, no. 3, pp. 1192–1209, 2013.

[194] M. Ramaswami and R. Bhaskaran, “A Study on Feature Selection Techniques in Educational Data Mining,” arXiv:0912.3924 [cs], Dec. 2009, arXiv: 0912.3924. [Online]. Available: <http://arxiv.org/abs/0912.3924>

[195] M. Hausmann and H. Ziekow, “The Potential of Household Specific Feature Selection for Analysing Smart Home Time-Series Data,” in Smart SysTech 2016; European Conference on Smart Objects, Systems and Technologies, Jul. 2016, pp. 1–6.

[196] L. G. Fahad, S. F. Tahir, and M. Rajarajan, “Feature selection and data balancing for activity recognition in smart homes,” in 2015 IEEE International Conference on Communications (ICC), Jun. 2015, pp. 512–517.

[197] H. Fang, L. He, H. Si, P. Liu, and X. Xie, “Human activity recognition based on feature selection in smart home using back-propagation algorithm,” ISA Transactions, vol. 53, no. 5, pp. 1629–1638, Sep. 2014. [Online]. Available: <http://www.science-direct.com/science/article/pii/S0019057814001281>

[198] I. Guyon and A. Elisseeff, “An Introduction to Variable and Feature Selection,” J. Mach. Learn. Res., vol. 3, pp. 1157–1182, Mar. 2003. [Online]. Available: <http://dl.acm.org/citation.cfm?id=944919.944968>

[199] H. Fang, R. Srinivasan, and D. J. Cook, “Feature selections for human activity recognition in smart home environments,” International Journal of Innovative Computing, Information and Control, vol. 8., pp. 3525–3535, May 2012.

[200] J. P. Cunningham and Z. Ghahramani, “Linear Dimensionality Reduction: Survey, Insights, and Generalizations,” Journal of Machine Learning Research, vol. 16, pp. 2859–2900, 2015. [Online]. Available: <http://jmlr.org/papers/v16/cunningham15a.html>

[201] J. Chu, I. Moon, Y. Lee, S. Kim, and M. Mun, “A Supervised Feature-Projection-Based Real-Time EMG Pattern Recognition for Multifunction Myoelectric Hand Control,” IEEE/ASME Transactions on Mechatronics, vol. 12, no. 3, pp. 282–290, Jun. 2007.

[202] S. Landset, T. M. Khoshgoftaar, A. N. Richter, and T. Hasanin, “A survey of open source tools for machine learning with big data in the Hadoop ecosystem,” Journal of Big Data, vol. 2, no. 1, p. 24, Nov. 2015. [Online]. Available: <https://doi.org/10.1186/s40537-015-0032-1>

[203] H2O platform. [Online]. Available: <https://www.h2o.ai/>

[204] “MLlib Apache Spark.” [Online]. Available: <http://spark.apache.org/mllib/>

[205] “TensorFlow.” [Online]. Available: <https://www.tensorflow.org/>

[206] “Torch Scientific computing for LuaJIT.” [Online]. Available: <http://torch.ch/>

[207] J. Murphy, “Deep Learning Frameworks: A Survey of TensorFlow, Torch, Theano, Caffe, Neon, and the IBM Machine Learning Stack,” Jan. 2016. [Online]. Available: <https://www.microway.com/hpc-tech-tips/deep-learning-frameworks-survey-tensorflow-torch-theano-caffe-neon-ibm-machine-learning-stack/>

[208] M.-H. Park, Y.-H. Jang, Y.-W. Ju, and S.-C. Park, “Design of TensorFlow-Based Proactive Smart Home Managers,” in Advances in Computer Science and Ubiquitous Computing, ser. Lecture Notes in Electrical Engineering, J. J. Park, V. Loia, G. Yi, and Y. Sung, Eds. Springer Singapore, 2018, pp. 83–89.

[209] J. Vzquez-Canteli, S. Ulyanin, J. Kmpf, and Z. Nagy, “Fusing TensorFlow with building energy simulation for intelligent energy management in smart cities,” Sustainable Cities and Society, Nov. 2018. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S2210670718314380>

[210] H.-Y. Lin, Y.-L. Hsueh, and W.-N. Lie, “Abnormal Event Detection Using Microsoft Kinect in a Smart Home,” in 2016 International Computer Symposium (ICS). Chiayi, Taiwan: IEEE, Dec. 2016, pp. 285–289. [Online]. Available: <http://ieeexplore.ieee.org/document/7858486/>

[211] W. Wang and C. Miao, “Activity Recognition in New Smart Home Environments,” in Proceedings of the 3rd International Workshop on Multimedia for Personal Health and Health Care - HealthMedia’18. Seoul, Republic of Korea: ACM Press, 2018, pp. 29–37. [Online]. Available: <http://dl.acm.org/citation.cfm?doid=3264996.3265001> [212] B. Qolomany, A. Al-Fuqaha, D. Benhaddou, and A. Gupta, “Role of Deep LSTM Neural Networks and Wi-Fi Networks in Support of Occupancy Prediction in Smart Buildings,” in 2017 IEEE 19th International Conference on High Performance Computing and Communications; IEEE 15th International Conference on Smart City; IEEE 3rd International Conference on Data Science and Systems (HPCC/SmartCity/DSS), Dec. 2017, pp. 50–57.

[213] B. Qolomany, M. Maabreh, A. Al-Fuqaha, A. Gupta, and D. Benhad-dou, “Parameters optimization of deep learning models using Particle swarm optimization,” in 2017 13th International Wireless Communications and Mobile Computing Conference (IWCMC), Jun. 2017, pp. 1285–1290.

[214] J. A. C. Soto, M. Jentsch, D. Preuveneers, and E. Ilie-Zudor, “CEML: Mixing and moving complex event processing and machine learning to the edge of the network for IoT applications,” in Proceedings of the 6th International Conference on the Internet of Things - IoT’16. Stuttgart, Germany: ACM Press, 2016, pp. 103–110. [Online]. Available: <http://dl.acm.org/citation.cfm?doid=2991561.2991575>

[215] M. R. Bashir and A. Q. Gill, “Towards an IoT Big Data Analytics Framework: Smart Buildings Systems,” in 2016 IEEE 18th International Conference on High Performance Computing and Communications; IEEE 14th International Conference on Smart City; IEEE 2nd International Conference on Data Science and Systems (HPCC/SmartCity/DSS). Sydney, Australia: IEEE, Dec. 2016, pp. 1325–1332. [Online]. Available: <http://ieeexplore.ieee.org/document/7828529/>

[216] B. Van Hoof, “View chooses Microsoft Azure IoT to accelerate development of smart building applications,” Nov. 2018. [Online]. Available: <https://azure.microsoft.com/en-us/blog/view-chooses-microsoft-azure-iot-to-accelerate-development-of-smart-building-applications/>

[217] N. D. Lane, S. Bhattacharya, P. Georgiev, C. Forlivesi, and F. Kawsar, “An Early Resource Characterization of Deep Learning on Wearables, Smartphones and Internet-of-Things Devices,” in Proceedings of the 2015 International Workshop on Internet of Things towards Applications - IoT-App’15. Seoul, South Korea: ACM Press, 2015, pp. 7–12. [Online]. Available: <http://dl.acm.org/citation.cfm?doid=2820975.2820980>

[218] “Torch AI: Unleashing the Power of Network-Centric Intelligence.” [Online]. Available: <https://smart-solutions.govciooutlook.com/vendor/torch-ai-unleashing-the-power-of-networkcentric-intelligence-cid-133-mid-18.html>

[219] “Massive Online Analysis (MOA),” Jan. 2011. [Online]. Available: <https://moa.cms.waikato.ac.nz/related-projects/>

[220] G. Mittal, K. B. Yagnik, M. Garg, and N. C. Krishnan, “SpotGarbage: smartphone app to detect garbage using deep learning,” in Proceedings of the 2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing - UbiComp’16. Heidelberg, Germany: ACM Press, 2016, pp. 940–945. [Online]. Available: <http://dl.acm.org/citation.cfm?doid=2971648.2971731>

[221] “Deeplearning4j.” [Online]. Available: <https://deeplearning4j.org/>

[222] “MOA.” [Online]. Available: <https://moa.cms.waikato.ac.nz/>

[223] A. Bifet, G. Holmes, R. Kirkby, and B. Pfahringer, “MOA: Massive Online Analysis,” Journal of Machine Learning Research, vol. 11, no. May, pp. 1601–1604, 2010. [Online]. Available: <http://www.jmlr.org/papers/v11/bifet10a.html>

[224] “Caffe Deep Learning Framework.” [Online]. Available: <http://caffe.berkeleyvision.org/>

[225] Y. Jia, E. Shelhamer, J. Donahue, S. Karayev, J. Long, R. Girshick, S. Guadarrama, and T. Darrell, “Caffe: Convolutional Architecture for Fast Feature Embedding,” arXiv:1408.5093 [cs], Jun. 2014, arXiv: 1408.5093. [Online]. Available: <http://arxiv.org/abs/1408.5093>

[226] Microsoft Azure Machine Learning. [Online]. Available: <https://azure.microsoft.com/en-us/services/machine-learning-studio/>

[227] “Apache Storm.” [Online]. Available: <http://storm.apache.org/>

[228] “Apache Kafka.” [Online]. Available: <http://kafka.apache.org/>

[229] Oracle Fusion Middleware. [Online]. Available: <https://docs.oracle.com/middleware/1213/eventprocessing/>

[230] “Oracle Stream Explorer Platform SOA Oracle.” [Online]. Available: <http://www.oracle.com/us/products/middleware/soa/stream-explorer-platform/overview/index.html>

[231] Oracle R Enterprise. [Online]. Available: <https://www.oracle.com/technetwork/database/database-technologies/r/r-enterprise/overview/index.html>

[232] “Oracle Real-Time Decisions Oracle.” [Online]. Available: <https://www.oracle.com/solutions/business-analytics/business-intelligence/real-time-decisions/>

[233] “Amazon Kinesis.” [Online]. Available: <https://aws.amazon.com/kinesis/>

[234] “Spark Streaming Apache Spark.” [Online]. Available: <http://spark.apache.org/streaming/>

[235] P. Wang, F. Ye, and X. Chen, “A Smart Home Gateway Platform for Data Collection and Awareness,” arXiv:1804.01242 [cs], Apr. 2018, arXiv: 1804.01242. [Online]. Available: <http://arxiv.org/abs/1804.01242>

[236] M. Syafrudin, N. L. Fitriyani, D. Li, G. Alfian, J. Rhee, and Y.-S. Kang, “An Open Source-Based Real-Time Data Processing Architecture Framework for Manufacturing Sustainability,” Sustainability, vol. 9, no. 11, p. 2139, Nov. 2017. [Online]. Available: <https://www.mdpi.com/2071-1050/9/11/2139>

[237] J. Lohokare, R. Dani, A. Rajurkar, and A. Apte, “An IoT ecosystem for the implementation of scalable wireless home automation systems at smart city level,” in TENCON 2017 - 2017 IEEE Region 10 Conference, Nov. 2017, pp. 1503–1508.

[238] A. Petheriotis, “IoT for Smart Homes and trillions of messages from Kafka to Elasticsearch,” Mar. 2018. [Online]. Available: <https://www.landoop.com/blog/2018/03/kafka-elasticsearch-kubernetes-iot/>

[239] X. Liu and P. S. Nielsen, “Streamlining Smart Meter Data Analytics,” in Proceedings of the 10th Conference on Sustainable Development of Energy, Water and Environment Systems. Technical University of Denmark, Denmark: DTU library, 2015, p. 15.

[240] “Supercell Case Study Amazon Web Services (AWS).” [Online]. Available: <https://aws.amazon.com/solutions/case-studies/supercell/>

[241] H. Elkhokhi, Y. NaitMalek, A. Berouine, M. Bakhouya, D. Elouadghiri, and M. Essaaidi, “Towards a Real-time Occupancy Detection Approach for Smart Buildings,” Procedia Computer Science, vol. 134, pp. 114–120, 2018. [Online]. Available: <https://linkinghub.elsevier.com/retrieve/pii/S1877050918311141>

[242] Apache Flume. [Online]. Available: <https://flume.apache.org/>

[243] “Apache SAMOA.” [Online]. Available: <https://samoa.incubator.apache.org/>

[244] G. De Francisci Morales, “SAMOA: a platform for mining big data streams,” in Proceedings of the 22nd International Conference on World Wide Web - WWW’13 Companion. Rio de Janeiro, Brazil: ACM Press, 2013, pp. 777–778. [Online]. Available: <http://dl.acm.org/citation.cfm?doid=2487788.2488042>

[245] S.-S. Choi, M.-J. Chun, Y.-S. Lee, and H.-R. Lee, “A Practical Methodology and Framework for Comprehensive Incident Handling Focused on Bot Response,” in Future Generation Information Technology, ser. Lecture Notes in Computer Science, T.-h. Kim, Y.-h. Lee, B.-H. Kang, and D. Izak, Eds. Springer Berlin Heidelberg, 2010, pp. 481–492.

[246] J. W. Lockhart, T. Pulickal, and G. M. Weiss, “Applications of Mobile Activity Recognition,” in Proceedings of the 2012 ACM Conference on Ubiquitous Computing, ser. UbiComp’12. New York, NY, USA: ACM, 2012, pp. 1054–1058. [Online]. Available: <http://doi.acm.org/10.1145/2370216.2370441>

[247] C. Nyce, Predictive Analytics White Paper. American Institute for Chartered Property Casualty Underwriters/Insurance Institute of America,, 2007.

[248] S. Stenudd, “A Model for Using Machine Learning in Smart Environments,” in Grid and Pervasive Computing Workshops, ser. Lecture Notes in Computer Science, M. Rautiainen, T. Korhonen, E. Muta-fungwa, E. Ovaska, A. Katasonov, A. Evesti, H. Ailisto, A. Quigley, J. Hkkil, N. Milic-Frayling, and J. Riekkilä, Eds. Springer Berlin Heidelberg, 2012, pp. 24–33.

[249] S. Abrahms, “Technology, Gadgets For Seniors Aging In Place,” Mar. 2014. [Online]. Available: <http://www.aarp.org/home-family/personal-technology/info-2014/is-this-the-end-of-the-nursing-home.html>

[250] R. Das, “Design and Implementation of a Smart Home for the Elderly and Disabled,” International Journal of Computer Networks and Applications, vol. 2, no. 6, pp. 242 – 246, Dec. 2015.

[251] T. Taleb, D. Bottazzi, M. Guizani, and H. Nait-Charif, “Angeloh: a framework for assisting elders at home,” IEEE Journal on Selected Areas in Communications, vol. 27, no. 4, pp. 480–494, May 2009.

[252] M. N. K. Boulos, A. Rocha, A. Martins, M. E. Vicente, A. Bolz, R. Feld, I. Tchoudovski, M. Braecklein, J. Nelson, G. Laighin, C. Sdogati, F. Cesaroni, M. Antomarini, A. Jobes, and M. Kinirons, “CAALYX: a new generation of location-based services in healthcare,” International Journal of Health Geographics, vol. 6, p. 9, Mar. 2007. [Online]. Available: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC1828720/>

[253] M. N. Kamel Boulos, R. C. Lou, A. Anastasiou, C. D. Nugent, J. Alexandersson, G. Zimmermann, U. Cortes, and R. Casas, “Connectivity for Healthcare and Well-Being Management: Examples from Six European Projects,” International Journal of Environmental Research and Public Health, vol. 6, no. 7, pp. 1947–1971, Jul. 2009. [Online]. Available: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC2738891/>

[254] M. S. Hossain, M. A. Rahman, and G. Muhammad, “Cyberphysical cloud-oriented multi-sensory smart home framework for elderly people: An energy efficiency perspective,” Journal of Parallel and Distributed Computing, vol. 103, pp. 11–21, May 2017. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S074373151630123X>

[255] N. K. Suryadevara, A. Gaddam, R. K. Rayudu, and S. C. Mukhopadhyay, “Wireless sensors network based safe home to care elderly people: Behaviour detection,” Sensors and Actuators A: Physical, vol. 186, pp. 277–283, Oct. 2012. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0924424712001847>

[256] Z. J. Yu, F. Haghighat, and B. C. M. Fung, “Advances and challenges in building engineering and data mining applications for energy-efficient communities,” Sustainable Cities and Society, vol. 25, pp. 33–38, Aug. 2016. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S2210670715001067>

[257] J. King and C. Perry, “Smart Buildings: Using Smart Technology to Save Energy in Existing Buildings,” American Council for an Energy-Efficient Economy, Washington, DC, USA, Technical Report A1701, Feb. 2017. [Online]. Available: <https://aceee.org/research-report/a1701>

[258] M. Rodriguez Fernandez, A. Cortes Garca, I. Gonzalez Alonso, and E. Zalama Casanova, “Using the Big Data generated by the Smart Home to improve energy efficiency management,” Energy Efficiency, vol. 9, no. 1, pp. 249–260, Jan. 2016. [Online]. Available: <https://doi.org/10.1007/s12053-015-9361-3>

[259] C. Reinisch, M. Kofler, F. Iglesias, and W. Kastner, “ThinkHome Energy Efficiency in Future Smart Homes,” EURASIP Journal

on Embedded Systems, vol. 2011, no. 1, p. 104617, Sep. 2010. [Online]. Available: <https://doi.org/10.1155/2011/104617>

[260] M. Jahn, M. Jentsch, C. R. Prause, F. Pramudianto, A. Al-Akkad, and R. Reiners, “The Energy Aware Smart Home,” in 2010 5th Interna- tional Conference on Future Information Technology, May 2010, pp. 1–8.

[261] Hydra middleware, Mar. 2016. [Online]. Available: <https://vicinity2020.eu/vicinity/content/hydra>

[262] J. Pan, R. Jain, S. Paul, T. Vu, A. Saifullah, and M. Sha, “An Internet of Things Framework for Smart Energy in Buildings: De- signs, Prototype, and Experiments,” IEEE Internet of Things Journal, vol. 2, no. 6, pp. 527–537, Dec. 2015.

[263] A. Fensel, S. Tomic, V. Kumar, M. Stefanovic, S. V. Aleshin, and D. O. Novikov, “SESAME-S: Semantic Smart Home System for Energy Efficiency,” Informatik-Spektrum, vol. 36, no. 1, pp. 46–57, Feb. 2013. [Online]. Available: <https://doi.org/10.1007/s00287-012-0665-9>

[264] N. Vastardis, M. Kampouridis, and K. Yang, “A user behaviour-driven smart-home gateway for energy management,” Jour- nal of Ambient Intelligence and Smart Environments, vol. 8, no. 6, pp. 583–602, Jan. 2016. [Online]. Available: <https://content.iospress.com/articles/ journal-of-ambient- intelligence-and-smart-environments/ais403>

[265] O. Vermesan, Internet of things applications - from research and innovation to market deployment. Place of publication not identified: River Publishers, 2014, oCLC: 884398675.

[266] S. S. Khan and J. Hoey, “Review of fall detection techniques: A data availability perspective,” Medical Engineering & Physics, vol. 39, pp. 12–22, Jan. 2017. [Online]. Available: <http://www.sciencedirect.com/ science/article/pii/S1350453316302600>

[267] M. H. Kabir, M. R. Hoque, and S.-H. Yang, “Development of a Smart Home Context-aware Application: A Machine Learning based Approach,” International Journal of Smart Home, vol. 9, no. 1, pp. 217–226, Jan. 2015. [Online]. Available: <http://www.sersc.org/ journals/IJSH/vol9 no1 2015/23.pdf>

[268] J. Ahn, D. Shin, K. Kim, and J. Yang, “Indoor Air Quality Analysis Using Deep Learning with Sensor Data,” Sensors (Basel, Swit- zerland), vol. 17, no. 11, Oct. 2017. [Online]. Available: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC5712838/>

[269] “Transit Security Design Considerations Final Report November 2004,” Final Report, p. 341, 2004.

[270] A. Kaklauskas and R. Gudauskas, “17 - Intelligent decision-support systems and the Internet of Things for the smart built environment,” in Start-Up Creation, F. Pacheco-Torgal, E. Rasmussen, C.- G. Granqvist, V. Ivanov, A. Kaklauskas, and S. Mako- nin, Eds. Woodhead Publishing, Jan. 2016, pp. 413–449. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/B9780081005460000170>

[271] Q. Ding, Z. Peng, T. Liu, and Q. Tong, “Multi-Sensor Building Fire Alarm System with Information Fusion Technology Based on D-S Evidence Theory,” Algorithms, vol. 7, no. 4, pp. 523–537, Oct. 2014. [Online]. Available: <http://www.mdpi.com/1999-4893/7/4/523>

[272] Clarifai. [Online]. Available: <https://www.clarifai.com/>

[273] J. Bangali and A. Shaligram, “Design and Implementation of Security Systems for Smart Home based on GSM technology,” International Journal of Smart Home, vol. 7, no. 6, pp. 201–208, Nov. 2013. [Online]. Available: <http://www.sersc.org/journals/ IJSH/vol7 no6 2013/19.pdf>

[274] J.-V. Lee, Y.-D. Chuah, and C.-T. Chai, “A Multilevel Home Security System (MHSS),” International Journal of Smart Home, vol. 7, no. 2, pp. 49–60. [Online]. Available: <http://www.earticle.net/ article.aspx?sn=204606>

[275] Y. Zhao and Z. Ye, “A low cost GSM/GPRS based wireless home security system,” IEEE Transactions on Consumer Electronics, vol. 54, no. 2, pp. 567–572, May 2008.

[276] Aware Home Research Initiative. [Online]. Available: <http://www.awarehome.gatech.edu/>

[277] “House n The PlaceLab,” Sep. 2018. [Online]. Available: <http://web.mit.edu/cron/group/house n/placelab.html>

[278] B. Brumitt, B. Meyers, J. Krumm, A. Kern, and S. Shafer, “EasyLiving: Technologies for Intelligent Environments,” in Hand- held and Ubiqui- tous Computing, ser. Lecture Notes in Computer Science, P. Thomas and H.-W. Gellersen, Eds. Springer Berlin Heidelberg, 2000, pp. 12– 29.

[279] “Mobile & Pervasive Computing at the University of Florida.” [Online]. Available: <https://www.cise.ufl.edu/helal/gt.htm>

[280] S. Helal, W. Mann, H. El-Zabadani, J. King, Y. Kaddoura, and E. Jansen, “The Gator Tech Smart House: a programmable perva- sive space,” Computer, vol. 38, no. 3, pp. 50–60, Mar. 2005.

[281] K. Bouchard, S. Giroux, R. Radziszewski, M. Gagnon, Q. Szymanski, S. Pinard, M. Levasseur, and N. Bier, “Maintaining Good Relationships in Clinical Setting: The Bonus DOMUS Project,” in Proceedings of the 8th ACM International Conference on PER- vasive Technologies Related to Assistive Environments, ser. PETRA ’15. New York, NY, USA: ACM, 2015, pp. 8:1–8:4. [Online]. Available: <http://doi.acm.org/10.1145/2769493.2769554>

[282] T. Tamura, A. Kawarada, M. Nambu, A. Tsukada, K. Sasaki, and K.-I. Yamakoshi, “E-healthcare at an experimental welfare

techno house in Japan,” The Open Medical Informatics Journal, vol. 1, pp. 1–7, 2007.

[283] T. Yamazaki, “The Ubiquitous Home,” International Journal of Smart Home, vol. 1, no. 1, pp. 17–22, 2007.

[284] M. A. Al-Qutayri and J. S. Jeedella, “Smart homes: technologies, applications and challenges,” International Journal of Com- puter Aided Engineering and Technology, vol. 2, no. 2-3, pp. 125–144, Dec. 2009. [Online]. Available: <https://www.inderscien- ceonline.com/doi/ abs/10.1504/IJCAET.2010.030541>

[285] K. Islam, W. Shen, and X. Wang, “Security and privacy considerations for Wireless Sensor Networks in smart home environ- ments,” in Pro- ceedings of the 2012 IEEE 16th International Conference on Computer Supported Cooperative Work in Design (CSCWD), May 2012, pp. 626– 633.

[286] D. Bandyopadhyay and J. Sen, “Internet of Things: Applications and Challenges in Technology and Standardization,” Wireless Personal Communications, vol. 58, no. 1, pp. 49–69, May 2011. [Online]. Available: <https://doi.org/10.1007/s11277-011-0288-5>

[287] P. Smitka, Get Ready for the Intelligent Workplace, Jun. 2016. [Online]. Available: <https://peter.smitka.net/data/Intelligent Workplace v1.1.pdf>

[288] K. Rose, S. Eldridge, and L. hapin, “The internet of things: An overview,” Oct. 2015. [Online]. Available: <https://www.internet- society.org/wp-content/uploads/2017/ 08/ISOC-IoT-Overview-20151221-en.pdf>

[289] D. Zhang, B. Guo, and Z. Yu, “The Emergence of Social and Com- munity Intelligence,” Computer, vol. 44, no. 7, pp. 21–28, Jul. 2011.

[290] A. Ali, J. Qadir, R. u. Rasool, A. Sathiaselalan, A. Zwitter, and J. Crowcroft, “Big data for development: applications and tech- niques,” Big Data Analytics, vol. 1, no. 1, p. 2, Jul. 2016. [Online]. Available: <https://doi.org/10.1186/s41044-016-0002- 4>

[291] B. C. Ooi, K. L. Tan, Q. T. Tran, J. W. Yip, G. Chen, Z. J. Ling, T. Nguyen, A. K. Tung, and M. Zhang, “Contextual Crowd In- telligence,” SIGKDD Explor. Newsl., vol. 16, no. 1, pp. 39–46, Sep. 2014. [Online]. Available: <http://doi.acm.org/10.1145/2674026.2674032>

[292] R. Alur, E. Berger, A. W. Drobnis, L. Fix, K. Fu, G. D. Hager, D. Lopresti, K. Nahrstedt, E. Mynatt, S. Patel, J. Rexford, J. A. Stan- kovic, and B. Zorn, “Systems Computing Challenges in the Internet of Things,” p. 15.

[293] J. A. Stankovic, “Research Directions for the Internet of Things,” IEEE Internet of Things Journal, vol. 1, no. 1, pp. 3–9, Feb. 2014.

[294] W. K. Edwards and R. E. Grinter, “At Home with Ubiquitous Com- puting: Seven Challenges,” in Ubicomp 2001: Ubiquitous Computing, ser. Lecture Notes in Computer Science, G. D. Abowd, B. Brumitt, and S. Shafer, Eds. Springer Berlin Heidelberg, 2001, pp. 256–272.

[295] M. Stonebraker, U. etintemel, and S. Zdonik, “The 8 requirements of real-time stream processing,” ACM SIGMOD Record, vol. 34, no. 4, pp. 42–47, Dec. 2005. [Online]. Available: <http://portal.acm.org/ citation.cfm?doid=1107499.1107504>

[296] D. Geesen, H. J. Appelrath, M. Grawunder, and D. Nicklas, “Challenges for Personal Data Stream Management in Smart Build- ings,” Creating Personal, Social, and Urban Awareness through Pervasive Computing, pp. 201–219, 2014. [Online]. Available: <https://www.igi- global.com/chapter/challenges- for-personal-data-stream-management-in-smart-buildings/88816>

[297] S. Talari, M. Shafie-khah, P. Siano, V. Loia, A. Tommasetti, and J. P. S. Catalo, “A Review of Smart Cities Based on the Internet of Things Concept,” Energies, vol. 10, no. 4, pp. 1–23, 2017. [Online]. Available: <https://ideas.repec.org/a/gam/jeners/v10y-2017i4p421-d93860.html>

[298] J. Ye, S. Dobson, and S. McKeever, “Situation identification techniques in pervasive computing: A review,” Pervasive and Mobile Computing, vol. 8, no. 1, pp. 36–66, Feb. 2012. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S1574119211000253>

[299] B. Babcock, S. Babu, M. Datar, R. Motwani, and J. Widom, “Models and Issues in Data Stream Systems,” in Proceedings of the Twenty-first ACM SIGMOD-SIGACT-SIGART Symposium on Principles of Database Systems, ser. PODS ’02. New York, NY, USA: ACM, 2002, pp. 1–16. [Online]. Available: <http://doi.acm.org/10.1145/543613.543615>

[300] G. Kreml, I. liobaite, D. Brzeziski, E. Hillermeier, M. Last, V. Lemaire, T. Noack, A. Shaker, S. Sievi, M. Spiliopoulou, and J. Stefanowski, “Open Challenges for Data Stream Mining Research,” SIGKDD Explor. Newsl., vol. 16, no. 1, pp. 1–10, Sep. 2014. [Online]. Available: <http://doi.acm.org/10.1145/2674026.2674028>

[301] E. Al Nuaimi, H. Al Neyadi, N. Mohamed, and J. Al-Jaroodi, “Applications of big data to smart cities,” Journal of Internet Ser- vices and Applications, vol. 6, no. 1, p. 25, Dec. 2015. [Online]. Available: <https://doi.org/10.1186/s13174-015-0041-5>

[302] J. Al-Jaroodi and N. Mohamed, “Characteristics and Requirements of Big Data Analytics Applications,” in 2016 IEEE 2nd Inter- national Conference on Collaboration and Internet Computing (CIC), Nov. 2016, pp. 426–432.

[303] P. Thakuriah, N. Tilahun, and M. Zellner, “Big data and urban Informatics: innovations and challenges to urban planning and

knowledge discovery,” in *Seeing Cities Through Big Data: Research Methods and Applications in Urban Informatics*, P. Thakuriah, N. Tilahun, and M. Zellner, Eds. New York: Springer, 2016, pp. 11–45. [Online]. Available: <http://www.springer.com/gb/book/9783319409009>

- [304] A. Gandomi and M. Haider, “Beyond the hype: Big data concepts, methods, and analytics,” *International Journal of Information Management*, vol. 35, no. 2, pp. 137–144, Apr. 2015. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0268401214001066>
- [305] K. Bouchard and S. Giroux, “Smart Homes and the Challenges of Data,” in *Proceedings of the 8th ACM International Conference on Pervasive Technologies Related to Assistive Environments*, ser. PETRA '15. New York, NY, USA: ACM, 2015, pp. 66:1–66:4. [Online]. Available: <http://doi.acm.org/10.1145/2769493.2769519>
- [306] N. Javaid, I. Khan, M. N. Ullah, A. Mahmood, and M. U. Farooq, “A Survey of Home Energy Management Systems in Future Smart Grid Communications,” in *2013 Eighth International Conference on Broadband and Wireless Computing, Communication and Applications*, Oct. 2013, pp. 459–464.
- [307] S. Murphy, “This is your future smart home and no, it doesn't look like 'The Jetsons',” Jan. 2015. [Online]. Available: <https://mashable.com/2015/01/10/future-smart-home/>

Basheer Qolomany (S'17) received the Ph.D. and second masters en-route to Ph.D. degrees in Computer Science from Western Michigan University (WMU), Kalamazoo, MI, USA, in 2018. He also received his B.Sc. and M.Sc. degrees in computer science from University of Mosul, Mosul, Iraq, in 2008 and 2011, respectively. He is currently an Assistant Professor at Department of Computer Science, Kennesaw State University, Marietta, GA, USA. Previously, he served as a Graduate Doctoral Assistant at Department of Computer Science, WMU, in 2016–2018; he also served as a lecturer at Department of Computer Science, University of Duhok, Kurdistan region of Iraq, Iraq, in 2011–2013. His research interests include machine learning, deep learning, Internet of Things, smart services, cloud computing, and big data analytics. Dr. Qolomany has served as a Technical Program Committee (TPC) member and a reviewer of some international conferences include: IWCMC 2018, VTC 2018, MEDES 2016, and IC4 2016.

Ala Al-Fuqaha (S'00–M'04–SM'09) received Ph.D. degree in Computer Engineering and Networking from the University of Missouri-Kansas City, Kansas City, MO, USA, in 2004. His research interests include the use of machine learning in general and deep learning in particular in support of the data-driven and self-driven management of large-scale deployments of IoT and smart city infrastructure and services, Wireless Vehicular Networks (VANETs), cooperation and spectrum access etiquette in cognitive radio networks, and management and planning of software defined networks (SDN). He is a senior member of the IEEE and an ABET Program Evaluator (PEV). He serves on editorial boards and technical program committees of multiple international journals and conferences.

Ajay Gupta (S'88 – M'89 – SM'05) received his Ph.D. in Computer Science from Purdue University in 1989, his M.S. in Mathematics and Statistics from the University of Cincinnati in 1984, and his B.E. (Honors) in Electrical and Electronics Engineering from Birla Institute of Technology and Sciences, Pilani, India in 1982. He is currently a Professor of Computer Science at Western Michigan University, Kalamazoo, MI, USA. From 1998 to 2002, he was the Chairman of the Computer Science Department at Western Michigan University. He has also been two term Chair of the IEEE-CS Technical Committee on Parallel Processing from 2011 to 2015 and Vice-Chair of the Technical Activities Committee of the IEEE-CS in 2015–2016. His research interests include high performance computing, proteogenomics, data analytics, machine learning, sensor systems, cloud computing, mobile computing, web technologies, computer networks, evolutionary computation, scientific computing, and design and analysis of parallel and distributed algorithms. He has published numerous technical papers and book chapters in refereed conferences and journals in these areas. Dr. Gupta is a senior member of the IEEE and member of the IEEE Computer Society, the IEEE Communications Society, the ASEE and the ACM. He actively helps organize various ACM and IEEE conferences. He is also involved in the global efforts to revise undergraduate and graduate computer science and computer engineering curriculum to keep pace with the technological advances.