

СПЕЦИФИКА ПРИ ПРЕДОСТАВЯНЕТО НА ИНТЕГРИРАНИ УСЛУГИ В УСЛОВИЯТА НА КОНВЕРГЕНЦИЯ НА ТЕХНОЛОГИИТЕ IoT (INTERNET OF THINGS) И AI (ARTIFICIAL INTELLIGENCE)

Цветелина Симеонова

SPECIFICS IN THE PROVISION OF INTEGRATED SERVICES IN THE CONDITIONS OF CONVERGENCE OF IoT (INTERNET OF THINGS) AND AI (ARTIFICIAL INTELLIGENCE) TECHNOLOGIES

Tsvetelina Simeonova

Резюме: Цел на работата е да се изследва спецификата при предоставянето на интегрирани услуги в условията на конвергенция на технологиите IoT (Internet of Things) и AI (Artificial Intelligence). Получени са резултати свързани с особеностите на услуги на IoT базирани на AI, както и със специфика на технологиите за машинно обучение при предоставяне на услуги на IoT. Като приноси моменти се открояват изясняването на спецификата на технологиите за опростена интелигентност в реално време и на федерираното обучение.

Ключови думи: Интернет на нещата, изкуствен интелект, изкуствен интелект на нещата, интегрирани услуги

Abstract: The aim of the work is to research the specifics of the provision of integrated services in the conditions of convergence of Internet of Things (IoT) and Artificial Intelligence (AI) technologies. Results have been obtained related to highlighting the features of AI-based IoT services, as well as the specificity of machine learning technologies in the provision of IoT services. Clarifying the specifics of real-time simplified intelligence technologies and federated learning stand out as contributing moments.

Keywords: Internet of Things, Artificial Intelligence, Artificial Intelligence of Things, Integrated Services

1. ВЪВЕДЕНИЕ

Интернет на нещата IoT (Internet of Things) и изкуственият интелект AI (Artificial Intelligence) понастоящем са две от най-перспективните технологии. Въпреки, че всяка има значителен потенциал, те са най-ефективни, когато работят заедно. Обединяването на IoT и AI, като "Интелигентен интелект на нещата" AIoT (Artificial Intelligence of Things), може да помогне на бизнеса да взема информирани решения с минимизиране на грешките. С използване на IoT се натрупват големи обеми данни, а AI извършва анализа и оценката на тези данни. В тази връзка, при IoT се използват усъвършенствани устройства с възможности за машинно обучение в периферията, които извършват идентифициране на модели и откриване на грешки в събраните данни. В много случаи на използване, моделите за машинно обучение използват данните предоставени от IoT за да осигурят точни изводи, при което устройствата на IoT предоставят данни на алгоритмите на машинното обучение. Комбинирането на AI и IoT отключва максимално потенциала и на двете технологии. Това е стъпка към нов стандарт за бизнеса, управляван от данни [1, 2, 3].

1.1. Предимства на IoT с изкуствен интелект

Интегрирането на IoT с AI може да осигури множество предимства. Също така фирмите могат да оптимизират своите операции и да осигурят по-добра удовлетвореност за своите клиенти с използването на анализи на AI в периферията. Някои предимства на IoT с изкуствен интелект са:

- **По-бързи анализи.** Комбинирането на AI и IoT означава, че данните ще изминават по-малко разстояние, преди да се използват. Смарт устройствата могат да анализират собствената си информация, без да я изпращат до център за данни, позволявайки много по-високи скорости и по-ниска латентност (latency). Тези подобрения са много удобни за много приложения на IoT с машинно обучение. Ниското забавяне може да позволи на самоуправляващите се превозни средства да разпознават почти незабавно препятствията, което води до безопасна навигация. Независимо от спецификата, по-бързият анализ означава по-бързо вземане на решения, което е предимство при всяка индустрия.

- **Подобрена киберсигурност.** AI може да се справи с някои от най-големите предизвикателства на IoT, като най-разпространено и много съществено е киберсигурността. Конвенционалните IoT системи са трудни за защита, поради масовата липса на вградени мерки за сигурност, което увеличава повърхността за атака. Интелигентните алгоритми на AIoT могат активно да наблюдават за подозрителна дейност или неоторизиран достъп на IoT устройствата, като могат да уловят потенциални атаки по-рано, намалявайки значително щетите.

- **Подобрено управление на риска.** Ефективното управление на риска и смекчаването на риска са някои от най-търсените предимства на IoT в бизнеса. Платформите използващи AI и IoT помагат за поддържането на киберсигурността и за управлението на риска, което включва справяне с киберзаплахи и избягване на финансови загуби, като реагират незабавно, за да се смекчат потенциалните рискове.

- **Гъвкава автоматизация.** Например, предизвикателството при роботите да се адаптират към променящите се ситуации може да се преодолее, като им се позволи да комуникират помежду си и да разпознават промените. Свързаните с IoT роботи могат да изпращат един на друг данни за своите работни потоци, вкл. за всякакви необичайни ситуации на които се натъкват. Роботите с функционалност на AI могат да интерпретират тази информация за да се адаптират към променящата се среда.

- **Повишена мащабируемост.** Интегрирането на AI в IoT може да направи и двете технологии по-достъпни и мащабируеми. Алгоритмите на AI могат да избират най-важните IoT данни и да ги обобщават, преди да ги изпратят на други устройства. Това компресиране намалява мрежовите изисквания, което прави широкомащабните IoT среди по-жизнеспособни. Мрежите могат да разпределят работните натоварвания чрез компютинг в периферията (edge computing), намалявайки нуждите от хардуер за усъвършенствани AI анализи в облака.

- **Намаляване на човешките грешки.** В много работни процеси данни от системи на IoT трябва да се преместят на друго място за анализ от AI. AIoT намалява риска от човешка грешка, като анализира информацията там, където възниква, което означава по-малко възможности за грешки. Фирмите имат загуби от човешка грешка и тъй като данните стават все по-ценни, тези грешки ще стават по-скъпи.

- **Подобрена ефективност.** AI и IoT в бизнеса са важни за подобряване на цялостните оперативни процеси чрез използване на информирани прогнози, което води до повишена оперативна ефективност. Алгоритмите на AI могат да анализират големи обеми данни, събрани от устройства на IoT, и да предоставят в резултат ценни изводи чрез които фирмите могат да оптимизират своите операции, да намалят разходите и да подобрят общата си ефективност.

- **Прогнозна поддръжка.** AI може да помогне да се предвиди кога оборудването се нуждае от поддръжка, намалявайки времето за престой поради отказ на оборудването и така повишавайки ефективността. Чрез анализиране на данни от сензори на IoT, алгоритмите на AI могат да открият модели, които да показват потенциални откази на оборудването. Това позволява на екипите за поддръжка да планират ремонти проактивно, преди оборудването да откаже, намалявайки разходите и увеличавайки времето за работа.

- **Подобрена безопасност.** AI може да помогне за подобряване на безопасността в IoT приложенията. Снабдените с изкуствен интелект камери могат да откриват потенциални опасности базирани на настройките в промишлени условия и да предупреждават обслужващите екипи да предприемат подходящи действия. По подобен начин алгоритмите на AI могат да анализират данните, събрани от сензори в превозни средства, за да открият небезопасно поведение при шофиране и да осигуряват на водачите обратна връзка в реално време.

- **Персонализиране.** Обработването на данни е жизненоважно за растежа и развитието на бизнеса и е едно от ключовите приложения на AI, използвани в бизнеса. AI може да помогне на бизнеса да персонализира своите продукти и услуги, за да отговори на нуждите на отделните клиенти. Чрез анализиране на данни от устройства на IoT фирмите могат да получат представа за предпочитанията и поведението на клиентите, което им позволява да предложат персонализирана удовлетвореност.

- **Управление на запасите.** Ефективното управление на запасите е от решаващо значение за бизнеса, за да се балансират търсенето и предлагането. AI в бизнеса точно прогнозира нуждите от възстановяване на запасите, което помага срещу презапасяването.

- **Разработка на нови и подобрени продукти и услуги.** Технологиите за обработка на естествен език NLP (Natural Language Processing) помагат за извличане на данни и има за цел да подобри комуникацията чрез реч, текст или жестове, като увеличава количеството предавана информация между хората и устройствата. Например, роботите и дроновете, работещи с AI, придават изцяло ново значение на наблюдението и инспекцията.

1.2. Предизвикателства при съвместното използване на AI и IoT

Някои от основните предизвикателства при съвместното използване на AI и IoT са:

- **Сигурност.** Рискът от кибератаки се увеличава тъй като повече устройства се свързват с Интернет. Хакерите могат да използват уязвимостите в устройствата на IoT, за да получат достъп до чувствителна информация или да поемат контрола над тези устройства. Системите с AI и интелигентните устройства също са податливи на атаки и ако бъдат компрометирани, те могат да причинят сериозни щети. За да намалят тези рискове компаниите трябва да гарантират, че техните IoT устройства и AI системи са защитени и че разполагат със силни протоколи за сигурност.

- **Съхранение и мениджмънт на данни.** Устройствата на IoT генерират огромен обем данни и е предизвикателство съхранението и мениджмънта на тези данни. Системите с изкуствен интелект изискват големи обеми данни за обучение, и ако данните не се менажират правилно, това може да доведе до неточни резултати. Също така, компаниите трябва да гарантират, че разполагат с инфраструктура, за да менажират и съхраняват сигурно големи обеми данни.

- **Недостиг на квалифицирани специалисти.** Недостигът на квалифицирани специалисти в областта на AI и IoT затруднява компаниите при внедряването и мениджмънта на системите на AI и IoT. Компаниите трябва да инвестират в програми за

обучение, за да повишат уменията на настоящите си служители и да привлекат нови в областта.

1.3. Технологични тенденции на мрежите към 2030

В едно взаимосвързано и базирано на данни общество възприемането на нови технологии е необходимост за постигане на пълен потенциал и конкурентоспособност [4, 5, 6, 7]. С помощта на асистиенти, базирани на изкуствен интелект, фирмите и хората могат да рационализират своите операции, да автоматизират рутинни задачи и да се съсредоточат върху по-стратегически инициативи [8].

- **Проактивност свързана с контекста.** AIoT системите могат да станат още по-проактивни чрез динамично приспособяване към нуждите на потребителите, например, въз основа на актуалните обстоятелства с автоматични модификации базирани на предпочитанията на потребителя, неговия график и външни фактори.

- **Мултимодално (multi-modal) взаимодействие.** Бъдещите системи се стремят към безпроблемно мултимодално взаимодействие, т.е. комбиниране на множество начини на въвеждане (като глас, докосване, поглед и жестове), за създаване на по-интуитивни и плавни взаимодействия, които по-добре имитират човешката комуникация.

- **Множественост (Multiplicity).** Множествеността (големия брой и разнообразието) подобрява системите на AIoT чрез автоматизиране на задачи, подобряване на анализа на данните комбинирано и с човешки прозрения (изводи), осигуряване на адаптивност и подобряване на удовлетвореността на потребителите. В този контекст, мерките за интеграция и безопасност са от решаващо значение.

- **Сигурен достъп до услуга в периферията SASE (Secure Access Service Edge).** SASE е архитектура за интегриране на сигурността и работата в мрежа, която предоставя възможности за конвергирана мрежа и сигурност като услуга, включително SD-WAN и собствени функции за сигурност в облака, като защитени уеб шлюзове, брокери за защита на достъп до облак, защитна стена като услуга и мрежов достъп при нулево доверие.

- **Нанотехнологии.** Компонентите базирани на нанотехнологии са изключително прецизни и реагират бързо, като улавят дори най-малките промени в околната среда. Това способства за създаването на по-усъвършенствани задействащи механизми и сензори за AIoT.

- **Интерфейси "мозък-компютър" BCI (Brain-Computer Interfaces).** Интерфейсите BCI анализират електрическите сигнали за мозъчна активност и ги преобразуват в команди за работа с машини. Може да взаимодействат с персонални устройства и да управляват изискванията на потребителите без никакви външни входове.

2. ОСОБЕНОСТИ НА УСЛУГИ НА IoT БАЗИРАНИ НА AI/ML

Съществуват успешни приложения на изкуствен интелект в различни домейни на IoT. Общо свойство на приложенията и услугите на IoT е, че те изискват бързи анализи, а не по-късни анализи с натрупани данни. В много приложения на IoT широко се използват технологии за изкуствен интелект, базирани на невронни мрежи. Например, простите приложения на IoT включват работа с динамични контексти, които споделят общи характеристики в една и съща административна област (домейн). Устройствата на IoT в същия домейн могат да предоставят контекстите на своите услуги на IoT сървър. Когато възникне динамична промяна в контекста на дадена услуга на IoT, устройството на IoT се нуждае от обработка в реално време, за да активира например спешни събития, предупредителни известия, актуализиране и повторно свързване на контексти [9].

Услугата на IoT трябва да поддържа в реално време взаимодействия между устройството на IoT и системата в същия домейн. Контекстът на услугата на IoT трябва също така да се

споделя между физически обекти в същия домейн. Следователно, технологиите за изкуствен интелект са обещаващи в много области на IoT [10].

- **Умен дом.** Концепцията за интелигентен дом обхваща множество IoT приложения относно здравеопазване, енергия, развлечения, образование и т.н., вкл. гласово разпознаване, обработка на естествен език, разпознаване на обекти на базата на изображения, управление на уреди и много други технологии на изкуствен интелект, интегрирани с IoT. Интелигентните свързани устройства наблюдават дома, за да осигурят по-добър контрол върху домашните консумативи и разходи. Консумацията на енергия и ефективността на домакинските уреди се наблюдават и анализират с технологии, базирани на дълбоко обучение, като изкуствена невронна мрежа, дългосрочна кратковременна памет и др.

- **Умен град.** Умният град съдържа множество IoT домейни, като транспорт, инфраструктура, енергетика и др. Поведението в обществения транспорт и "моделите на движение на тълпата" са важни въпроси и те често се разглеждат с методи, базирани на невронни мрежи, дългосрочна кратковременна памет (long-short-term-memory) и конволюционна невронна мрежа.

- **Интелигентна енергия (Smart energy).** С разгръщането на двупосочна комуникационна енергийна инфраструктура, интелигентната мрежа се превърна в голямо приложение на IoT, което изисква интелигентна обработка на данни. Потребителите на енергия също така искат анализирана информация за собственото си поведение при потреблението на енергия. Повечето резултати са базирани на най-новите технологии за дълбоко обучение, като например многопластов перцептрон¹, повтаряща се невронна мрежа, дългосрочна кратковременна памет, автоенкодер и др.

- **Интелигентен транспорт.** Интелигентната транспортна система е друг източник на големи данни в IoT домейни. Проучени са много случаи на употреба, като например наблюдение и предвиждане на пътния трафик и задръстванията, разпознаване на пътни знаци, откриване на проникване в превозни средства и др. Освен това са необходими много усъвършенствани технологии за изкуствен интелект в автономните и интелигентни превозни средства, които изпълняват много интелигентни подзадачи, като например откриване на пешеходци, избягване на препятствия и т.н.

- **Интелигентно здравеопазване.** IoT и изкуственият интелект са интегрирани в здравеопазването. Повтарящите се невронни мрежи и технологиите за дългосрочна кратковременна памет активно се изучават с цел ранна диагностика и прогнозиране на заболявания с използване на медицински данни във вид на времеви серии. Като пример, могат да бъдат измерени хранителните приеми чрез анализиране с конволюционна невронна мрежа на изображения на храни на мобилни устройства.

- **Интелигентно селско стопанство.** Дълбоката невронна мрежа и конволюционната невронна мрежа се използват за класифициране на култури и разпознаване на болести в растенията. Освен това, с модерни технологии на изкуствен интелект се обработват процеси при автоматично земеделие с автономна работа на машината, като избягването на препятствия, откриване на местоположението на плодовете и много други подзадачи.

¹ В машинното обучение перцептронът е алгоритъм за контролирано обучение на двоични класификатори. Двоичният класификатор е функция, която може да реши дали даден вход, представен от вектор от числа, принадлежи към определен клас.

3. СПЕЦИФИКА НА ТЕХНОЛОГИИТЕ ЗА МАШИННО ОБУЧЕНИЕ ПРИ ПРЕДОСТАВЯНЕТО НА УСЛУГИ НА IoT

3.1. Базови технологии за машинно обучение за IoT

Базовите технологии за машинно обучение (като форма на изкуствения интелект) може да се разделят на: обучение с учител, обучение без учител, обучение с утвърждаване и обучение базирано на невронни мрежи [3, 9]. Разгледана е тяхната специфика и особености.

3.1.1. Обучение с учител

Обучението с учител е базирано на функция, описваща причинно-следствената връзка между входните и изходните данни. Входните данни трябва да бъдат ясно дефинирани и обвързани с подходящи изходни данни, тъй като моделите на обучението с учител се учат изрично посредством директна обратна връзка. Двойка обвързани входящи и изходящи данни образуват "точка" от данни.

- Метод KNN (K-Nearest Neighbor) - KNN при IoT не може да се мащабира при големи масиви от данни, тъй като изисква целия набор от данни за обучение, за да класифицира ново-входящите данни. KNN обаче изисква по-малка мощност на обработка в сравнение с други сложни методи за обучение.

- Метод Naïve Bayes - нова "точка" от данни в класификаторите Naïve Bayes се класифицира въз основа на теоремата на Bayes с „наивното“ допускане за независимост между характеристиките. Класификаторите на Naïve Bayes могат да се справят с "точки" от данни с голяма размерност, те са бързи и силно мащабируеми.

- Метод SVM (Support Vector Machine) е двоичен класификатор без използване на вероятности, който намира "хипер-равнина", като максимизира границата между класовете на набора от данни за обучение. SVM е най-разпространената технология за машинно обучение, до появата на технологиите за невронни мрежи. SVM все още има предимства по отношение на използването на паметта и способността за работа с данни с голям размер, пред алгоритмите, базирани на невронни мрежи и вероятностните подходи, при което може да се използва за приложения на IoT със сериозни ограничения за съхранение на данни.

- При метода "Регресия" се използва "приближение" на обвързките на оценяваната зависима променлива с независимите променливи, които се използват за оценката. Използва се широко за прогнозиране и извеждане на причинно-следствени връзки между входни и изходни данни в чувствителни към времето приложения на IoT.

- В метода Random Forests, за вземане на решения се обучават група "дървета", като всяко се обучава от подмножество на набора за обучение, използвайки произволно избрано подмножество от M входни променливи. Предвид различните структури на групите дървета, методът Random Forests има много висока точност и е подходящ за приложения на IoT, критични по отношение на точност.

3.1.2. Обучение без учител

Обучението без учител е тип машинно обучение, управлявано от данни, което по време на процеса на обучение намира скрита структура в немаркиран набор от данни, без обратна връзка. За разлика от обучението с учител, обучението без учител се фокусира върху откриването на модели в разпределението на данните.

- Методът K-means clustering има за цел да открие групи в данните. Данните от наблюдения се присвояват на K на брой клъстери (групи). При всяко наблюдение имаме присвояване на съответни данни към клъстер, с който има най-голямо сходство. K-means е

много бърз и силно мащабируем алгоритъм за клъстериране, така че може да се използва за приложения на IoT с изисквания за обработка в реално време, като например интелигентен транспорт.

- Методът DBSCAN (Density-Based approach to Spatial Clustering of Applications with Noise) групира набор от данни въз основа на плътността на проби от тези данни. В този модел плътните участъци, които включват проби от данни с много близки съседи, се считат за клъстери, а пробите от данни в участъци с ниска плътност се класифицират като извънредни проби. Методът DBSCAN е ефективен за клъстериране на данни за IoT мрежови среди с ненадеждни големи набори от данни.

- Методът "Намаляване на размерността" (Dimensionality Reduction) има за цел да трансформира високоразмерни данни в нискоразмерни, като същевременно минимизира загубата на информация. С други думи, методът служи за извличане на данни въз основа на характеристиките на някои функции, които могат най-добре да представят тези данни. Чрез намаляване на размерността можем да намалим сложността на модела и да съкратим времето за изчисление. Примери за намаляване на размерността включват: анализ на главните компоненти PCA (Principal Component Analysis), T-SNE (T-Stochastic Neighbor Embedding) и др.

3.1.3. Обучение с утвърждаване

Обучението с утвърждаване е реактивен тип машинно обучение, което научава поредица от действия в даден набор от възможни състояния, като действията са с "награди" или "наказания". Представлява проучване на процеса на вземане на решения и избор на поредица от действия с най-голяма "награда" или най-малко "наказание", което може да бъде цена, приоритет, време и т.н. Обучението с утвърждаване може да бъде полезно за избор на действие от устройство на IoT чрез предоставяне на насока.

- Q-learning е алгоритъм за обучение с утвърждаване без модел (базиран на уравнение на Белман). Целта е да се научи политика за избор на действие, максимизираща Q-стойността, която политика да указва на агент какво действие да предприеме. Може да се използва за IoT устройство за да се определи какво действие трябва да предприеме според зададени условия.

- Методът SARSA (State-Action-Reward-State-Action) е алгоритъм подобен на Q-learning. Основната разлика е, че е алгоритъм базиран на политика, при което агентът взаимодейства с околната среда и актуализира политиката въз основа на предприетите действия. Това означава, че Q-стойността се актуализира чрез действие, извършено от текущата политика, вместо политика, която максимизира Q-стойността (при алгоритъм Q-learning). Използването е уместно, когато някое действие на дадено IoT устройство ще повлияе значително на състоянието на околната среда.

- Методът DQN (Deep Q Network) се използва за решаване на проблеми при неопределени състояния.

Интегрирането на изкуствени невронни мрежи в процеса на Q-обучение се нарича дълбоко Q-обучение, а мрежа, която използва изкуствени невронни мрежи за приближаване на Q-функции, се нарича дълбока Q-мрежа (DQN). Като вариант на класическия алгоритъм за Q-Learning, DQN използва дълбока конволюционна невронна мрежова архитектура за приближение на Q-функция². В реални среди не всички възможни

² Конволюционна невронна мрежа (CNN или ConvNet) е мрежова архитектура за deep learning, която се учи директно от данни, премахвайки необходимостта от ръчно извличане на функции. CNN са особено полезни за намиране на модели в изображения за разпознаване на обекти, лица и сцени.

състояния и условия могат да бъдат наблюдавани. Следователно, в реални приложения при IoT, по-подходящ е DQN спрямо методите Q-learning или SARSA. Тъй като DQN може да се използва за действие само в рамките на отделно пространство, той може да се използва за маршрутизиране на трафик в IoT мрежата.

- Методът DDPG (Deep Deterministic Policy Gradient) пренася DQN в домейна на непрекъснатото действие. DDPG е алгоритъм без модели, базиран на детерминистичен (предварително определен) градиент на политиката. Използват се "актьор", който решава кое е най-доброто действие за всяко състояние, и "критик", който се използва за оценка на политиката, т.е. на избрания набор от действия. В приложения на IoT DDPG може да се използва за задачи, които изискват управление в непрекъснати пространства за действие, като например енергийно ефективно управление на температурата, разтоварване на изчисления, планиране на мрежовия трафик и др.

- Концепцията на метода TRPO (Trust Region Policy Optimization) е да се актуализират параметри в рамките на доверен регион. За да се актуализират параметри за нова политика в рамките на определения регион, тези параметри трябва да бъдат актуализирани посредством проби, получени от локални точки при консервативна итерация на политиката. Също така стойността на размера на стъпката е ограничена до актуализиране на параметри в рамките на дефинирания доверен регион.

В комуникационните мрежи на IoT, като се има предвид, че действията на TRPO се решават в рамките на неговата граница, TRPO може да се внедри за балансиране на натоварването, разпределение на мощността, предоставяне на услуги и т.н.

- Методът PPO (Proximal Policy Optimization) е алгоритъм в областта на обучението с утвърждение, който обучава функцията за вземане на решения на компютърен агент за изпълнение на задачи, като използва първата производна за актуализиране на параметрите на своята политика, за разлика от TRPO. Изчислителната сложност на PPO е значително облекчена в сравнение с тази на TRPO. Докато размерът на стъпката на TRPO постоянно се коригира, за да удовлетвори ограничението, размерът на стъпката на PPO просто използва изрязване, за да фиксира максималната стойност на своята актуализация. При експлоатация, PPO изчислява ентропията на действие, за да определи дали даден агент се нуждае от повече проучване, за да увеличи максимално своята целева функция. PPO е подходящ за обучение на агенти в среда, където пространството за действие е твърде голямо за DQN алгоритъм. Следователно, използването на PPO е ефективно при задачи като асоцииране на потребители, контрол на мощността и разпределение на ресурси в безжичните комуникации.

3.1.4. Алгоритми за IoT базирани на невронни мрежи

- Алгоритъмът RNN (Recurrent Neural Network) е тип модел на дълбоко обучение, който е обучен да обработва и преобразува последователни входни данни в специфични последователни изходни данни. Последователните данни са данни - като думи, изречения или данни от времеви серии - където последователните компоненти са взаимосвързани въз основа на сложна семантика и правила за синтаксис. Той обработва поредици от данни чрез вътрешна памет и е полезен в IoT приложения със зависещи от времето данни, като идентифициране на зависещи от времето модели на сензорни данни, оценяване на поведението на потребление във времето и др.

- Алгоритъмът с дългосрочна кратковременна памет LSTM (Long Short Term Memory) е разширение на RNN. Основната разлика на LSTM от RNN е, че използва концепцията за портове (gates). Алгоритъмът активно контролира пропуските при "забравяне", за да предотврати отслабване на дългосрочната зависимост от времето. Следователно, в сравнение с RNN, той е по-подходящ за данни при които има

дългосрочна зависимост и за приложения на IoT, изискващи анализ на редки събития (продължително забавяне на зависимостта), като разпознаване на дейност, прогнозиране на бедствия и др.

- Алгоритъмът CNN (Convolutional neural network) е вид изкуствена невронна мрежа, като тип модел на обучение с учител. Поради способността ѝ да разпознава модели в изображения, е разработена специално за обработка на двуизмерни данни за изображения с отчитане на локалната свързаност, но понастоящем обикновено се използва за многоизмерни данни като многоканални звукови сигнали, стойности на IoT сензори и т.н. CNN е мощен инструмент, но за обучение изисква милиони етикетирани точки от данни. Тъй като в невронната мрежа CNN невроните са свързани само с малко подмножество от входни и дялови тегловни параметри, структурата на CNN е много с по-оскъдна в сравнение с напълно свързаната мрежа. Алгоритъмът обаче се нуждае от голям набор от данни за обучение, особено за визуални задачи. В CNN е предложена нова функция за активиране на невронна мрежа, Rectified Linear Unit (ReLU), която ускорява времето за обучение, без да засяга генерализацията на мрежата. В домейни на IoT се използва често за задачи за откриване, които изискват известен визуален анализ.

- Алгоритъмът AE (VAE, Variational Autoencoder) по принцип е генеративен тип модел на обучение без учител, чието разпределение на кодирането се регулира по време на обучението. Вариационният автоенкодер е архитектура на изкуствена невронна мрежа и е част от семействата вероятностни графични модели и вариационни байесови методи. AE е обучен да генерира изход, за да реконструира (възстановява) входни данни, поради което има еднакъв брой входни и изходни единици. Подходящ е за извличане на функции и за намаляване на размерността. Поради функционалността си при реконструиране на входните данни в изходния слой, алгоритъмът често се използва за диагностика на неизправности на машини в приложения на IoT.

Най-популярният тип AE използва модел със смесено обучение, като алгоритъмът е подходящ в приложения на IoT, при които данните обикновено са разнообразни и оскъдни.

- Алгоритъмът GAN (Generative Adversarial Network) се базира на хибриден тип модел със смесено обучение, който използва две невронни мрежи - генеративна и дискриминативна мрежи. Генераторът е обучен да научи разпределението на данните от набор от данни за обучение, за да генерира нови данни, които могат да обучат втората мрежа, така нареченият дискриминатор. След това дискриминаторът се научава да разграничава генерираните данни от реалните данни. В приложения на IoT, GAN може да се използва в ситуации, когато от наличните данни трябва да се генерират неща като локализиране, намиране на път и преобразуване на тип данни.

3.2. Технологии за опростена интелигентност в реално време.

С развитието на IoT е необходим някакъв вид опростен интелект, който да поддържа интелигентни обекти. Преди IoT повечето от разработките за обучение не разглеждаха среди с ограничени ресурси. По-специално, моделите за дълбоко обучение изискват много ресурси, като процесорна мощност, памет, стабилен източник на хранване и т.н. Понастоящем е известно, че параметрите на моделите за дълбоко обучение съдържат излишна (резервирана) информация, така че някои части от тях могат да бъдат внимателно премахнати за намаляване на сложността без забележимо влошаване на производителността.

Технологии на алгоритми за обучение в реално време без сървър в среди на IoT са:

- **Мрежова компресия (network compression).** С тази технология мрежата може да бъде намалена по размер и сложност. Изискванията за процесорна мощност и съхранение могат да бъдат намалени чрез изрязване на неподходящите части или несподелянето на излишните (резервирани) параметри. Производителността на мрежата се проверява последователно при процесите на “изрязване”, съобразно минималните изисквания за конкретните приложения и случаи на употреба. Тъй като много параметри се премахват или не се споделят, необходимата памет се намалява, както и изчислителната тежест и енергия (тъй като по-голямата част от енергията в невронната мрежа се използва за достъп до паметта, консумираната енергия силно спада). Основното ограничение е, че няма общо решение за компресиране на всички видове мрежи, а зависи от характеристиките на всяка мрежа. Мрежовата компресия е много разпространен метод за преобразуване на технологиите за дълбоко обучение в опростени и удобни за IoT.

- **Приблизително изчисление.** Подход за поддържане на дълбоко обучение в смарт устройства. Базира се на факта, че за много IoT приложения резултатите от дълбокото обучение не е необходимо да са точни, но все пак са валидни, ако са в приемлив диапазон. Чрез интегрирането на приблизителното изчисление в дълбокото обучение се намалява както времето за изпълнение, така и консумацията на енергия. Мрежата може да бъде "регулируема" при приблизително изчисление въз основа на оптималния компромис между точност и време на работа (или консумация на енергия). Тази технология може да се използва в ситуации, когато времето за реакция е по-важно от резултатите получени чрез сложно анализиране. Въпреки че е технология за улесняване на работата в реално време и е с опростена интелигентност, процесът на обучение на моделите и преобразуването им в приблизителна мрежа изисква известно количество ресурс. Следователно, приближеният модел може да бъде използван на интелигентни устройства, но процесите на обучение и опростяване ще трябва да се извършват на осигурени с ресурси платформи.

- **Бързи изводи.** Моделите за дълбоко обучение се възползват от предимствата на нелинейните свойства при процеса на препращане през голям брой слоеве, но често позволяват изводи с разумно ниво на точност без да се преминава през всички слоеве. Тези технологии, които могат да постигнат бързи изводи за сметка на известна точност, могат да бъдат полезни при вземането на решения, които не са фатални, но изискват бързи реакции в среди на IoT с ограничени ресурси.

3.3. Федерирано (обединено) обучение

Обединеното обучение е метод при който множество устройства на IoT работят заедно, за да обучат модел с предсказване. Въз основа на това могат да се получат по-ниска латентност, по-малко мощност и по-интелигентни модели, има и предимства по отношение на поверителността на данните. Обединеното обучение позволява съвместно обучение на модели за предсказване, при което всички данни са съхраняват на устройството. Подходът позволява извършването на машинно обучение без необходимост от съхраняване на данни в облака, което го прави подходящ за прилагане на изкуствен интелект в устройства на IoT.

- **Хоризонтално обединено обучение (Horizontal Federated Learning).** Хоризонталното обединено обучение се използва главно когато всички модели на обучение са еднакви и всеки потребител има един и същ тип данни. Клиентите се актуализират индивидуално, а сървърът събира всички локални актуализации, изчислява глобалните актуализации на базата на обобщената информация и ги изпраща на всички потребители. Използва се главно в технологии като гласови асистенти в интелигентни домове.

- **Обучение с обединен трансфер (Federated Transfer Learning).** Обучението с обединен трансфер има за цел да обучава в ситуации когато има различни набори от данни и различни примерни/пробни пространства. Обучаването на модела е чрез изпращане на множество данни от различни пространства, които се прехвърлят в едно и също пространство. Този подход се използва в ситуации на сътрудничество.

- **Централизирано обединено обучение (Centralized Federated Learning).** Прилага се на централен сървър и във всеки контур на комуникация всички клиенти се обучават паралелно. Централният сървър използва алгоритъм с претеглена средна стойност (обединено осредняване, Federated Averaging) като се разпределят тегла на всеки клиент. Сървърите са критични за управлението на клиентите относно събирането и разпространението на актуализации и защитата на поверителността.

- **Децентрализирано обединено обучение (Decentralized federated learning).** Децентрализираното обединено обучение използва мрежова топология без централен сървър и всички “теми” на обучението са свързани чрез комуникации P2P. Във всеки сеанс на комуникация клиентите се обучават въз основа на техните собствени данни. Консенсус относно глобалните актуализации се постига въз основа на модели, получени от съседни клиенти. Въз основа на това, методът може да се използва дори когато няма комуникация със сървър и може да се приложи към технологии като блокчейн.

4. ЗАКЛЮЧЕНИЕ

Разгледани са предимствата на IoT с изкуствен интелект, предизвикателствата при съвместното използване на AI и IoT, технологичните тенденции на мрежите към 2030, които си явяват предпоставка за развитието на услуги на IoT базирани на AI/ML.

Обсъдени са особеностите на услуги на IoT базирани на AI/ML и спецификата на технологиите за машинно обучение при предоставянето на услуги на IoT. Акцентирано е на специфични технологии за машинно обучение, приложими при предоставянето на услуги, както и на развиващите се тенденции за прилагане на технологии за опростена интелигентност в реално време и на федерирано (обединено) обучение.

Изкуственият интелект и машинното обучение ще навлизат все по-отчетливо в бизнес средата на организациите и тяхната функционалност ще се вгражда във функционалността при предоставяне на услуги.

ИЗПОЛЗВАНИ ИЗТОЧНИЦИ (REFERENCES)

- [1] JOSÉ, Louise. Benefits and Uses of Artificial Intelligence for the IoT. *Device Authority* [online]. [viewed 20.03.2025]. Available from: <https://www.deviceauthority.com/blog/benefits-and-uses-of-artificial-intelligence-for-the-iot/>
- [2] NEWTON, Emily. 5 benefits of Artificial Intelligence IoT. *Tech Informed* [online]. [viewed 20.03.2025]. Available from: <https://techinformed.com/benefits-of-artificial-intelligence-iot/>
- [3] СИМЕОНОВА, Цветелина. *Развитие на перспективните технологии в „Интернет на свързаните неща“ IoT (Internet of Things)*. София: Асеневи, 2021. ISBN 978-619-7586-25-1. [SIMEONOVA, Tsvetelina. *Razvitie na perspektivnite tehnologii v „Internet na svarzanite neshta“ IoT (Internet of Things)*. Sofia: Asenevsi, 2021. ISBN 978-619-7586-25-1.]
- [4] ПАСАРЕЛСКИ, Росен. *Ново 5G поколение мобилни клетъчни системи: изследване*. София: Нов български университет, 2024. ISBN 978-619-265-048-3. [PASARELSKI, Rosen. *Novo 5G pokolenie mobilni kletachni sistemi: izsledvane*. Sofia: Nov balgarski universitet, 2024. ISBN 978-619-265-048-3.]
- [5] ПЕТРОВ, Георги. *Развитие на Интернет и отворените системи*. Ч. 1. София: Авангард Прима, 2017. ISBN 978-619-160-834-8. [PETROV, Georgi. *Razvitie na Internet i otvorenite sistemi*. Ch. 1. Sofia: Avangard Prima, 2017. ISBN 978-619-160-834-8.]

**СПЕЦИФИКА ПРИ ПРЕДОСТАВЯНЕТО НА ИНТЕГРИРАНИ УСЛУГИ В УСЛОВИЯТА НА
КОНВЕРГЕНЦИЯ НА ТЕХНОЛОГИИТЕ IoT (INTERNET OF THINGS) И AI (ARTIFICIAL
INTELLIGENCE)**

ЦВЕТЕЛИНА СИМЕОНОВА

- [6] ПАСАРЕЛСКИ, Росен и Тереза СТЕФАНОВА. Методи за преход и внедряване на IPv6. *Управление и образование* [онлайн]. 2012, год. VIII (4), с. 203-211 [прегледан 20.03.2025]. ISSN 1312-6121. Достъпен на: https://www.conference-burgas.com/maevolumes/vol8/BOOK%204/b4_31.pdf [PASARELSKI, Rosen i Tereza STEFANOVA. Metodi za prehod i vnedryavane na IPv6. *Upravlenie i obrazovanie* [onlayn]. 2012, god. VIII (4), s. 203-211 [pregledan 20.03.2025]. ISSN 1312-6121. Dostapen na: https://www.conference-burgas.com/maevolumes/vol8/BOOK%204/b4_31.pdf]
- [7] ИВАНОВА, Йоана. Методи и средства за агентно-базирана визуализация на дигитализирани данни. *Годишник Телекомуникации* [онлайн]. 2021, Т. 8, с. 13-22 [прегледан 20.03.2025]. eISSN 2534-854X. Достъпен на: <https://doi.org/10.33919/YTelecomm.21.8.2> [IVANOVA, Yoana. Metodi i sredstva za agentno-bazirana vizualizatsia na digitalizirani dannii. *Godishnik Telekomunikatsii* [onlayn]. 2021, T. 8, s. 13-22 [pregledan 20.03.2025]. eISSN 2534-854X. Dostapen na: <https://doi.org/10.33919/YTelecomm.21.8.2>]
- [8] Future of connected world with AIoT. A Primer. *Lab45* [online]. [viewed 20.03.2025]. Available from: <https://lab45thinktank.com/wp-content/uploads/2024/02/future-of-connected-world-with-aiot-a-primer.pdf>
- [9] CHOI, J.K., J.S. HAN., G.H. LEE., and H.S. PARK. Requirements and Challenges for User-level Service Managements of IoT Network by utilizing Artificial Intelligence. *Datatracker* [online]. [viewed 20.03.2025]. Available from: <https://datatracker.ietf.org/doc/draft-choi-icnrg-aiot/>
- [10] MILOVANOV, Nikolay. Case study: LoRa/LoRaWAN as a suitable LPWAN choice for pressure and flow monitoring in Bulgarian water utility sector. In: *CompSysTech '24: International Conference on Computer Systems and Technologies* [online]. 2024, pp. 173-179 [viewed 20.03.2025]. ISBN 979-8-4007-1684-3. Available from: <https://doi.org/10.1145/3674912.3674945>

Информация за автора:

гл. ас. д-р инж. Цветелина Симеонова, НБУ, департамент "Телекомуникации", ул. Монтевидео № 21, Тел.: 02 8110609, tsvsimeonova@nbu.bg

Contacts:

Assist. Prof. Tsvetelina Simeonova, PhD, New Bulgarian University, Department "Telecommunications", Tel.: 02 8110609, e-mail: tsvsimeonova@nbu.bg

Дата на постъпване на ръкописа (Date of receipt of the manuscript): 25.03.2024

Дата на приемане за публикуване (Date of adoption for publication): 30.09.2024