



МОДЕЛЬ ІНТЕГРАЦІЇ ФЕДЕРАТИВНОГО НАВЧАННЯ В МЕРЕЖІ МОБІЛЬНОГО ЗВ'ЯЗКУ П'ЯТОГО ПОКОЛІННЯ

Б. Шубин, Т. Максимюк, О. Яремко, Л. Фабрі¹, Д. Мрозек²

¹ Національний університет “Львівська політехніка”, вул. С. Бандери, 12, Львів, 79013, Україна
² Сілезький технологічний університет, Катовіце, Польща

Відповідальний за рукопис: Шубин Богдан (boshubin@gmail.com)

(Подано 26 Липня 2022)

У роботі досліджено основні переваги використання федеративного навчання (FL) для обміну досвідом між інтелектуальними пристроями в середовищі мереж мобільного зв'язку п'ятого покоління. Цей підхід дає змогу будувати ефективні алгоритми машинного навчання у випадку використання конфіденційних даних, втрата яких може бути небажаною або навіть небезпечною для користувачів. Отже, для завдань, у яких важлива конфіденційність даних, що необхідні для обробки та аналізу, пропонуємо використовувати підходи FL. У такому випадку вся особиста інформація користувачів буде оброблятися локально на їхніх пристроях. FL забезпечує безпеку конфіденційних даних для абонентів, дає операторам мобільних мереж змогу зменшити кількість надлишкової інформації в радіоканалі та оптимізувати функціонування мобільної мережі. В роботі наведено трирівневу модель інтеграції федеративного навчання в мережу мобільного зв'язку та описано основні особливості цього підходу. Висвітлено також експериментальні дослідження, які демонструють результати використання запропонованого підходу.

Ключові слова: федеративне навчання; машинне навчання; штучний інтелект; 5G; Інтернет речей.

УДК 621.391

1. Вступ

У сучасному світі ми можемо спостерігати стрімкий розвиток багатьох технологій, які істотно впливають на наше життя та нашу взаємодію з ними. Стрімкий розвиток штучного інтелекту (ШІ) та підходів до машинного навчання [1] справляють значний вплив на тенденції розвитку мобільних мереж, даючи змогу підвищити їхню продуктивність, автоматизацію та поліпшити загальну якість послуг для користувачів.

Сьогодні ми спостерігаємо швидку інтеграцію ШІ в мобільну мережу. Багато різних дослідників пропонують використовувати різноманітні алгоритми нейронних мереж та підходи до машинного навчання. Однак більшість цих робіт розглядає використання штучного інтелекту централізовано на одному сервері, куди передаватиметься велика кількість користувацького трафіку. Ми ж пропонуємо використовувати децентралізований підхід, який описано в цій роботі.

Для забезпечення стандартних підходів машинного навчання, які потребують централізованого розміщення навчальних даних на одному сервері компанії, будують великі хмарні інфраструктури для оброблення цих даних або орендують ці ресурси в різноманітних компаніях. Все це роблять для того, щоб мати можливість покращити послуги кінцевим користувачам. Проте ми

пропонуємо для цілей і завдань, які використовують багато незалежних пристроїв (наприклад, мобільні телефони, автопілоти для машин/автономних роботів на підприємствах), використовувати децентралізований вид машинного навчання під назвою “Федеративне Навчання” [2].

2. Аналіз та основна ідея федеративного навчання

Основна мета федеративного навчання полягає у тому, щоб розмістити моделі нейронних мереж у безпечному середовищі та навчати їх без переміщення даних з пристрою, де вони були згенеровані.

Ідея федеративного навчання виникла через те, що велику кількість даних, які містять корисну інформацію для вирішення певних конкретних проблем, важко отримати в кількостях, достатніх для навчання потужній моделі глибокого навчання [3]. На додаток до корисної інформації, необхідної для навчання моделі, набори даних також містять іншу інформацію, яка не стосується проблеми, але її розкриття потенційно може зашкодити абонентам. Це дуже важливо з погляду безпеки конфіденційних даних абонентів, і часто нам потрібно знати параметри антен пристроїв користувачів, розташування абонентів для виявлення закономірностей мобільності користувачів тощо. В результаті виникають етичні питання, які стосуються конфіденційності даних, наданих оператору мобільного зв'язку. Користувачі не завжди хочуть повідомляти своє місцезнаходження, навіть для того, щоб покращити якість послуг.

Тому для завдань, у яких важлива конфіденційність даних, необхідних для оброблення та аналізу, ми пропонуємо використовувати підходи ФН, оскільки всі розрахунки оброблятимуться локально на пристрої користувача.

Однією із головних цілей ФН є децентралізація обробки даних. У результаті удосконалення мікропроцесорів і стрімкого розвитку ШІ бачимо, як виробники смартфонів, ноутбуків та іншого цифрового обладнання використовують у своїх пристроях блоки або цілі мікропроцесори для виконання функцій ШІ.

Запропонований підхід має низку переваг, а саме:

- *Безпека особистої інформації користувачів.*

Перша перевага використання федеративного навчання полягає у тому, що всі конфіденційні дані користувачів оброблятимуться локально на їхніх пристроях. Користувачам більше не потрібно надсилати свою конфіденційну інформацію третім особам (наприклад, оператору мобільного зв'язку). Більшість нових пристроїв вже містять процесори з окремим ШІ контролером, що, як правило, доволі потужні й дають змогу виконувати такі розрахунки з достатньою швидкістю та з мінімальними витратами батареї пристрою. Крім того, інформація може зберігатися локально на пристрої протягом декількох днів і тренувати нейронну мережу, коли пристрій не використовується і заряджатиметься.

- *Зменшення кількості службового трафіку в радіоканалі.*

Друга перевага полягає у тому, що такий підхід дає змогу значно зменшити кількість надлишкового трафіку в радіоканалі, оскільки більше не потрібно надсилати величезну кількість даних з усіх пристроїв користувачів на базові станції. Потрібно буде надсилати лише ваги нейронних мереж, які подано у вигляді списку. Це дасть змогу вивільнити ресурси в радіоканалі для передавання корисної інформації, а отже, збільшити пропускну здатність для користувачів.

- *Економічні переваги з погляду витрат на обчислювальну потужність.*

Федеративне навчання дає змогу істотно знизити витрати на утримання центрів оброблення даних. Операторам мобільного зв'язку не доведеться вкладати величезні суми в своє обладнання, адже вони мають в своєму розпорядженні мільярди Android, IOS та інших пристроїв у всьому світі, які можуть виконувати ці обчислення локально на своїх пристроях.

Користувачі можуть бути задоволені цим мізерним навантаженням на своїх пристроях, оскільки це допомагає покращити послуги, якими вони користуються. І, як ми вже зазначали, це

дасть їм змогу захистити свої конфіденційні дані, не надсилаючи їх у центр оброблення даних. Також цілком можливо побудувати енергоефективні моделі нейронних мереж, робота яких буде невідчутною для кінцевого користувача.

3. Упровадження федеративного навчання у мережі мобільного зв'язку п'ятого покоління

Машинне навчання та нейронні мережі – чудові технології, які застосовують для оптимізації та автоматизації багатьох процесів у життєвому циклі мобільних мереж, тому ми пропонуємо використовувати їх децентралізовано (рис. 1). Кожен рівень мобільної мережі використовуватиме свою окрему “маленьку” (тобто таку, яка не потребуватиме багато ресурсів) нейронну мережу. І навіть більше, буде використовуватися спільна база знань, а її особливість полягає в тому, що вона не передаватиме увесь нефільтрований трафік, тільки результати нейронних мереж з пристроїв будуть передані в базу знань, і тільки потім інформація буде передана всім іншим рівням мобільної мережі.

Це рішення істотно звільнить радіоканал від надлишкового трафіку, що дасть користувачам змогу збільшити обсяг корисної інформації. Це також захистить особисту інформацію користувачів від несанкціонованого доступу до їхніх даних та місцезнаходження. Усі персональні дані користувачів оброблятимуться локально на пристрої, передаючи в базу знань лише результати нейронної мережі, з яких неможливо отримати корисну інформацію. Вони будуть придатні лише для подальшого оброблення нейронною мережею на рівні загальної бази знань.

Цей підхід поділено на три основні рівні, а саме:

- *штучний інтелект на пристрої;*
- *спільна база знань;*
- *управління процесами мобільної мережі.*



Рис. 1. Концептуальна архітектура децентралізованого управління на основі федеративного навчання

Штучний інтелект на пристрої. На рівні штучного інтелекту на пристрої застосовується нейронна мережа, яка обробляє та локально аналізує необхідні дані на пристроях користувачів, використовуючи мінімальні ресурси та енергію пристроїв користувачів (рис. 2). Відстежуючи певну логіку користувачів, їх повсякденну рутину та поведінку, вона створюватиме шаблони користувачів і надсилатиме їх на рівень загальної бази знань, яка аналізуватиме використання абонентського трафіку залежно від місця розташування або певних тимчасових подій (футбольні матчі, концерти тощо).

Знаючи щоденну рутину кожного користувача в мобільній мережі, збираючи та аналізуючи дані протягом тривалого періоду, ми зможемо визначити, скільки трафіку та де користувачі споживають найбільше.

Щоб не аналізувати та не накопичувати непотрібні дані про користувача на його пристрої в режимі реального часу (оскільки це будуть величезні обсяги даних, а отже, величезне енергоспоживання), пропонуємо використовувати параметр QoE (Quality of Experience), який дасть змогу визначити мінімально допустимий поріг якості для кожного абонента. І як тільки він перевищить порогове значення QoE (зміниться розпорядок дня тощо), ми заново почнемо процес навчання нейронної мережі.

Такий підхід може забезпечити також динамічний вибір оператора мережі на основі використання штучного інтелекту. В разі динамічного вибору оператора (перспектива для мереж шостого покоління) пропонуємо використовувати на пристроях користувачів локальну нейронну мережу, яка може самостійно вибирати оператора за певними показниками, такими як рівень сигналу, вартість послуги, QoS, QoE, максимальна швидкість передавання даних тощо. Це не лише забезпечить найкращий QoS для абонентів, а й своєрідну конкуренцію між невеликими мережевими операторами, що змусить їх постійно оновлювати своє обладнання, тим самим покращуючи технологічний розвиток мобільних мереж в Україні.



Рис. 2. ШІ на рівні пристрою

- *Управління процесами мобільної мережі*

Цей рівень запропонованої моделі використовується для того, щоб оптимізувати та автоматизувати різноманітні процеси у життєвому циклі мобільної мережі. Тут ми опишемо лише два варіанти оптимізації з багатьох інших можливостей, а саме управління спектром та управління хендовером (рис. 3).

Управління спектром [4]. На основі інформації, отриманої зі спільної бази знань, ми можемо розділити абонентів на певні групи залежно від кількості та місця споживання трафіку з метою ефективнішого регулювання частотних ресурсів між мікро- та макрокомірками. Такий підхід дасть

змогу ефективно використовувати недовантажені ресурси комірки, передаючи частотні ресурси перевантаженим коміркам.

Управління хендовером [5]. На основі інформації другого рівня (а саме моделі трафіку абонента) і знаючи, де спостерігається перевантаження та недовантаження стільникового зв'язку, пропонуємо використовувати нейронну мережу, яка регулюватиме зсуви MLB і MRO, щоб ефективно здійснити передавання абонента із меж однієї базової станції до іншої без втрати зв'язку. Це дасть нам змогу перевести абонента із перевантаженої комірки в ненавантажену, якщо він рухається або перебуває на їх межі, щоб поліпшити якість зв'язку та збільшити швидкість передавання даних.



Рис. 3. Рівень управління процесом мобільної мережі

- *Спільна база знань*

Спільна база знань використовується для того, щоб узагальнити знання, одержані в результаті аналізу даних на кожному локальному пристрої з метою отримання ширшої картини роботи мережі. На цей рівень дані відправляють у формі ваг нейронної мережі, що дає змогу зменшити кількість службової інформації. Такий підхід дозволить розділити користувачів на певні групи (основні точки поглинання трафіку), тобто точки, де користувачі здебільшого використовують стільникові дані для поглинання різних типів інформації, і групи поглинання трафіку (залежно від кількості необхідного трафіку, місця, де вони використовують трафік найінтенсивніше), для прикладу:

- абоненти, які використовують невеликий трафік (0–200 Мб на день);
- абоненти, які поглинають середній обсяг трафіку (200–1000 МБ на добу);
- абоненти, які споживають великий трафік (1000+ Мб на день).

4. Інтеграція федеративного навчання в мобільну мережу 5G

У цьому розділі ми описуємо процес інтеграції федеративного навчання у життєвий цикл мобільних мереж 5G [6]. У випадку мобільних мереж у нас є велика кількість різних областей управління мережею, і на кожному з цих рівнів ми приймаємо певні рішення, які дають змогу оптимізувати використання доступних ресурсів. Ми вирішили розділити роботу мобільної мережі

на кілька рівнів, щоб було легше пояснити, як ми пропонуємо інтегрувати в її роботу методи федеративного навчання (рис. 4).

- *Рівень передавання даних*

Інформація з пристроїв користувачів більше не буде передаватися в такому обсязі, як раніше. З кінцевих пристроїв користувачів вся інформація передаватиметься у вигляді ваг нейронних мереж, які може обробити лише нейронна мережа на рівні спільної бази знань. Усі ці дані передаються з пристроїв користувачів на базові станції, на яких вони працюють, а потім до загальної бази знань. Дуже важливо правильно організувати передавання даних між усіма площинами. У режимі реального часу швидкість і точність передавання цих даних є дуже важливим показником ефективності.

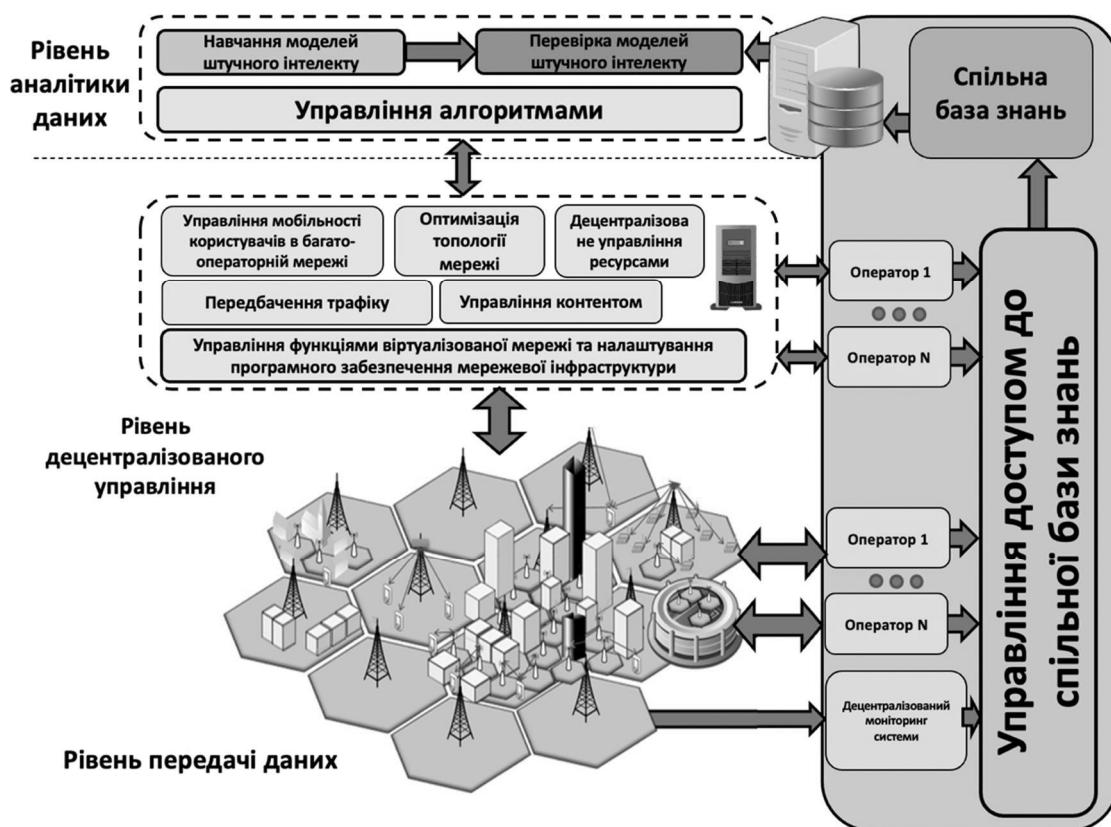


Рис. 4. Архітектура для інтеграції Federated Learning у мобільну мережу

- *Рівень децентралізованого управління*

Як ми знаємо, у мобільних мережах є різноманітні ресурси та можливості, які впливають на продуктивність мережі [7]. Якщо ми правильно розподілимо ці ресурси, то зможемо досягти величезних параметрів пропускної здатності та належної якості обслуговування для кінцевих користувачів.

На цьому рівні буде створено кілька нейронних мереж, які відповідатимуть за оптимізацію певних конкретних функцій. Вони отримають потрібні дані з площини загальної бази знань і зможуть на основі цих даних приймати рішення щодо оптимізації частотних ресурсів, надання необхідної пропускної здатності користувачам тощо.

- *Рівень аналітики даних*

Ця площина є однією із основних, яка працюватиме для майбутнього розвитку мобільного оператора. На основі цієї площини мобільні оператори зможуть постійно аналізувати та контролювати мережу в режимі реального часу. Вона дасть змогу виявити слабкі місця мережі,

визначити, де не вистачає пропускну здатності, як ефективніше використовувати частотні ресурси тощо. Усе це дозволить розширити та масштабувати мобільну мережу для підвищення її ефективності. Також така аналітика дасть можливість ефективно використовувати кошти компанії, адже ми точно знатимемо, що і як робити для її швидкого розвитку.

- *Рівень загальної бази знань*

Як зазначено в попередньому підрозділі, на площині загальної бази знань оброблятиметься вся вхідна інформація від користувачів у вигляді набору даних, який буде зрозумілий тільки для нейронної мережі цього рівня. Ця площина стане центром пропонованої моделі, оскільки її розрахунки та результати її роботи будуть основним показником ефективності мобільної мережі. З цієї площини дані відправлятимуться для подальшого оброблення в площину аналітики та площину децентралізованого управління. У цій площині буде зосереджена основна обчислювальна потужність у вигляді нейронної мережі, яка зможе збирати всю інформацію про стан мережі та надавати рішення для підвищення продуктивності мобільної мережі.

5. Моделювання та експерименти

Для проведення експерименту ми використали набір даних (рис. 5), що містить інформацію про кількість користувачів, які перебувають у радіусі дії різних базових станцій у певний момент часу. Дані збирали цілодобово протягом одного року з інтервалом у 5 хв. Така велика кількість даних дасть змогу краще зрозуміти мобільне середовище та всі можливі відхилення й аномалії в мобільній мережі.

Ми розділили набір даних на дві основні частини. Перша частина – це 70 % даних, які використані для навчання нейронної мережі за допомогою контрольованого навчання (рис. 6), інші 30 % – для тестування точності передбачень. На підставі цих даних виконаємо перевірки коректності й ефективності моделі нейронної мережі.

	datetime	FemtoCell_2602	FemtoCell_2603	FemtoCell_2604	FemtoCell_2605
11	2019-01-13 06:55:00	27	0	0	66
12	2019-01-13 07:00:00	43	0	0	70
13	2019-01-13 07:05:00	49	0	0	78
14	2019-01-13 07:10:00	50	0	0	75
15	2019-01-13 07:15:00	84	0	0	71
16	2019-01-13 07:20:00	89	0	0	77
17	2019-01-13 07:25:00	87	0	0	71
18	2019-01-13 07:30:00	93	0	0	69
19	2019-01-13 07:35:00	101	0	0	72
20	2019-01-13 07:40:00	90	0	0	67
21	2019-01-13 07:45:00	83	0	0	52
22	2019-01-13 07:50:00	85	0	0	48

Рис. 5. Набір даних для експерименту

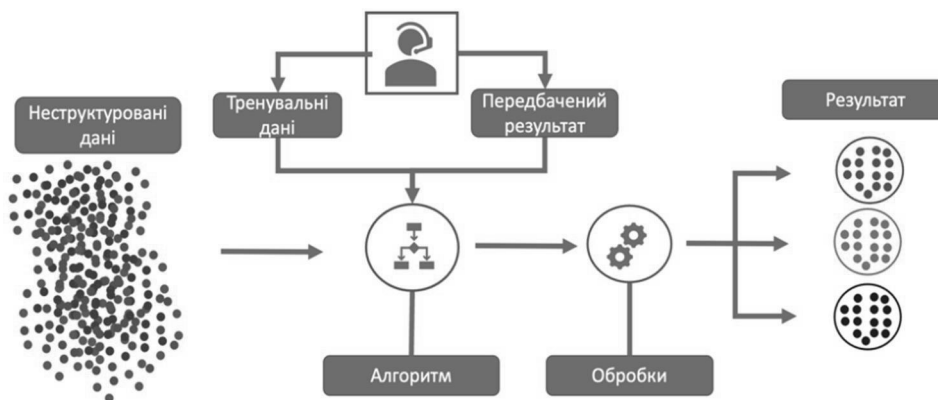


Рис. 6. Принцип роботи контрольованого навчання

Оскільки ми працюємо з часовими рядами, то вирішили використовувати рекурентні нейронні мережі (RNN), а саме модифіковану рекурентну нейронну мережу архітектуру на основі комірці довготривалої короткочасної пам'яті (LSTM) (рис. 7).




Рис. 7. Архітектура рекурентної нейронної мережі на основі комірці довготривалої короткочасної пам'яті

Ключовим компонентом LSTM є стан комірці. Інформація по ній проходить безпосередньо через всю комірці. LSTM може видаляти інформацію про стан комірці за допомогою фільтрів. Вони дають змогу пропускати інформацію на основі деяких умов і складаються з рівня сигмоїдної функції та операції поелементного множення.

```

array([[ 2.4036822,  2.3056104,  0.8332669, -0.5595883,  0.34979057,
         0.08153749, -2.3644524, -1.3128968, -1.6871997,  1.6359411,
         1.3598547, -1.300773, -0.42262134,  0.2619015,  0.64486927,
        -1.7404754 ]], dtype=float32),
array([[ 1.8783534, -0.7514225,  3.077768,  0.8019451,  1.7466648,
         0.03405923,  2.064834,  0.7759836, -0.9461984, -1.5045012,
         0.8663146, -0.43342087,  1.6028442,  0.24820396,  2.225446,
         0.9583358 ],
        [-0.80469567, -0.06197764, -2.4939291, -0.30273, -1.5986611,
        -1.4809117, -1.0258833, -0.52086,  0.9318235, -1.6439681,
        -2.0942771,  1.1352262, -0.95891976, -2.0130994, -1.4421998,
        -0.07709111],
        [ 0.5071647,  0.84380555, -2.169385, -1.5008307, -0.81627387,
         0.50129277, -2.1922143, -1.3338512,  2.776319,  1.728105,
        -1.0121331,  0.46326354, -0.7031315,  1.1064318, -1.9704168,
        -1.8649075 ],
        [ 0.5070094, -1.2743897,  3.1952524,  0.7029176, -0.2567885,
        -2.2935476,  1.8128397,  0.8475016,  0.18896309, -0.6401183,
         0.6380945, -0.10045538,  0.5567279, -0.11921524,  2.7146215,
         0.7416903 ]], dtype=float32),
array([ 1.4794482,  0.5151107,  0.43922287,  0.30407503,  0.02747638,
        -0.79182506, -0.7659425,  0.9289594,  1.2463478, -0.8230281,
        -0.9564313,  1.3003014, -1.0424709, -1.0322589, -0.0237885,
        -0.05491779], dtype=float32),
array([[ -0.09102181],
        [ 0.7776629 ],
        [ 0.32449514],
        [-0.8589849 ]], dtype=float32),
array([0.84753335], dtype=float32)]
    
```

Рис. 8. Приклад вигляду збережених ваг нейронної мережі

Для проведення цього дослідження запропоновано порівняти ефективність RNN на основі комірки LSTM, навченої на повному наборі тренувальних даних, і ефективність FL, яка організована так:

1. Ми розділили тренувальний набір даних на три частини та провели навчання на різних віртуальних пристроях (також із використанням LSTM).
2. На кожному із пристроїв ми зберегли навчену модель у вигляді ваг нейронної мережі (рис. 8).
3. Ваги нейронних мереж перенесено в загальну базу знань (у нашому випадку це окремий віртуальний клієнт), яка усереднює ваги і створює глобальну модель на підставі досвіду всіх пристроїв.
4. На тестовому пристрої ми оновили локальну модель до отриманої глобальної моделі.
5. На основі глобальної моделі прогнозуємо кількість абонентів у конкретній комірці базової станції.

У результаті ми змогли порівняти ефективність LSTM і Federated Learning. Для порівняння ефективності запропонованих моделей застосовано метрику “середня квадратична помилка” (MSE). Для LSTM MSE становить 259, а для FL MSE – 225. Результати прогнозування кількості абонентів у конкретній комірці базової станції наведено на рис. 9.

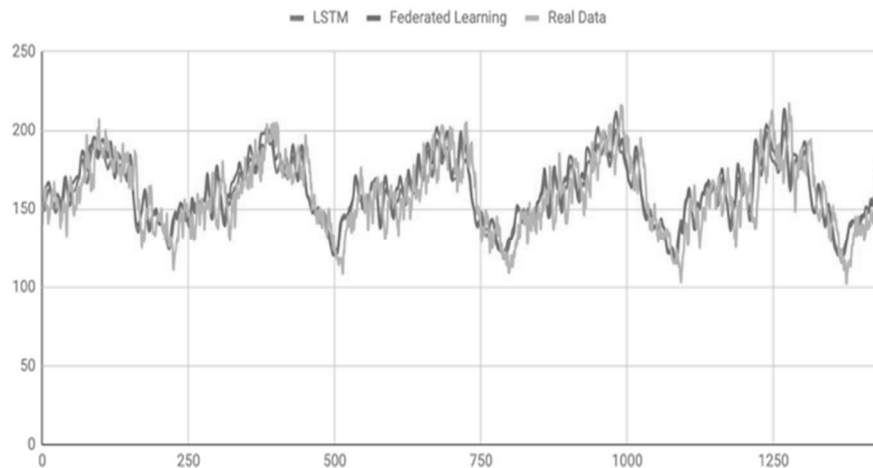


Рис. 9. Порівняння точності прогнозування LSTM та FL з реальними даними

Отримані графіки чітко показують, що відмінність між цими підходами з погляду продуктивності мінімальна, й обидва варіанти дуже точні для прогнозування, але підхід на основі FL має додаткові переваги, вказані в цій статті, а саме безпека інформації користувачів, зменшення надлишкового трафіку в радіоєфірі та необхідних обчислювальних потужностей для операторів мережі мобільного зв'язку.

Висновки

У роботі наведено приклад використання федеративного навчання у середовищі мереж мобільного зв'язку. Запропонований алгоритм дає змогу забезпечити максимальну безпеку даних кінцевих користувачів і зменшити обсяг надлишкового трафіку в мережі. Крім того, за такого підходу мобільні оператори зможуть використовувати менше обчислювальних ресурсів, оскільки вся особиста інформація користувачів оброблятиметься на їхніх мобільних телефонах локально.

Результат показав, що відмінність у точності між класичним LSTM і LSTM на основі федеративного навчання майже однакова, з мінімальною перевагою FL. Проте безпека даних, менша надмірність у мережі та використання меншої обчислювальної потужності мобільними операторами є позитивними змінними, які дадуть змогу ефективніше керувати ресурсами в мобільній мережі.

Список використаних джерел

- [1] Michalski et al. R. (2013), “Machine learning: An artificial intelligence approach”, Springer Science & Business Media”.
- [2] Kang, J.; Xiong, Z.; Niyato, D.; Zou, Y.; Zhang, Y.; and Guizani, M. (2020), *Reliable federated learning for mobile networks. IEEE Wireless Communications* 27(2): 72–80.
- [3] Kairouz, P.; McMahan, H. B.; Avent, B.; Bellet, A.; Bennis, M. Bhagoji, A. N.; Bonawitz, K.; Charles, Z.; Cormode, G.; Cummings, R.; et al. (2019), *Advances and open problems in federated learning. arXiv preprint arXiv:1912.04977*.
- [4] Maksymyuk T. et al. (2019), “Intelligent Spectrum Management in 5G Mobile Networks based on Recurrent Neural Networks”, *15th IEEE Int. Conf. The Experience of Designing and Application of CAD Systems (IEEE CADSM'2019), February, Polyana, Ukraine*.
- [5] Luntovskyy A. et al., (2021). “5G Slicing and Handover Scenarios: Compulsoriness and Machine Learning,”. *2020 Lecture Notes in Networks and Systems, vol 212. Springer, Cham. https://doi.org/10.1007/978-3-030-76343-5_12*.
- [6] Bonawitz, K.; Eichner, H.; Grieskamp, W.; Huba, D.; Ingerman, A.; Ivanov, V.; Kiddon, C.; Konecny, J.; Mazzocchi, S.; McMahan, H. B.; et al. (2019). *Towards federated learning at scale: System design. arXiv preprint arXiv:1902.01046*.
- [7] Luntovskyy A. and Shubyn B. (2020), “Highly-Distributed Systems Based on Micro-Services and their Construction Paradigms”, *2020 IEEE 15th International Conference on Advanced Trends in Radio-electronics, Telecommunications and Computer Engineering (TCSET), pp. 7–14, DOI: 10.1109/TCSET49122.2020.235378*.

FEDERATED LEARNING FOR 5G MOBILE NETWORKS

B. Shubyn, T. Maksymyuk, O. Yaremko, L. Fabri¹, D. Mrozek²

¹ Lviv Polytechnic National University, 12, S. Bandery str., Lviv, 79013, Ukraine

² Silesian University of Technology, Gliwice, Poland

This paper investigates the main advantages of using Federated Learning (FL) for sharing experiences between intelligent devices in the environment of 5th generation mobile communication networks. This approach makes it possible to build effective machine learning algorithms using confidential data, the loss of which may be undesirable or even dangerous for users. Therefore, for the tasks where the confidentiality of the data is required for processing and analysis, we suggest using Federated Learning (FL) approaches. In this case, all users' personal information will be processed locally on their devices. FL ensures the security of confidential data for subscribers, allows mobile network operators to reduce the amount of redundant information in the radio channel, and also allows optimizing the functioning of the mobile network. The paper presents a three-level model of integration of Federated Learning into the mobile network and describes the main features of this approach, as well as experimental studies that demonstrate the results of the proposed approach.

Key words: *Federated Learning; machine learning; artificial intelligence; 5G; Internet of things.*