



О. М. Павлюк, М. В. Міщук, М. О. Медиковський

Національний університет "Львівська політехніка", м. Львів, Україна

ПІДХІД ДО ІНТЕЛЕКТУАЛІЗАЦІЇ ПРОМИСЛОВИХ ПІДПРИЄМСТВ НА ПІДСТАВІ РОЗПІЗНАВАННЯ СКЛАДНИХ ВИДІВ ДІЯЛЬНОСТІ ПЕРСОНАЛУ

Проаналізовано технології, які базують на використанні носійних пристроїв (англ. *Wearable Devices*) для розпізнавання видів людської діяльності, що робить цей напрям дуже актуальним у контексті розроблення підходів до інтелектуалізації промислових підприємств. У межах проведених досліджень представлено метод на підставі нейромереж для виявлення видів діяльності промислового персоналу з метою подальшої інтеграції його в інформаційну технологію для інтелектуального управління виробничими процесами. Для цього розроблено: застосунок для смартгодинника, який збирає дані сенсорів; хмарну базу даних для зберігання цієї інформації; методи машинного навчання для визначення складних видів діяльності промислового персоналу. Для попереднього оброблення та розділення зібраного набору даних застосовано конвеєр, який фільтрує фрейми даних, агрегує їх в неперервні послідовності з фіксованою кількістю зразків базових активностей та тривалістю 60 с і перемішує їх. Отримані дані розділено на навчальні та тестові підмножини, за двома стратегіями. Далі до сигналів застосовано неперервне Вейвлет-перетворення. Встановлено, щоб підвищити здатність розпізнавати дуже складні послідовності операцій, можна за допомогою архітектури стекування класифікаторів, що дає змогу виявляти прості операції та класифікувати складені дії на підставі аналізу послідовності простих операцій. Досліджено, що базовий класифікатор, побудований на DenseNet121, з перенесеним навчанням може розрізняти чотири базові види діяльності з точністю 90,90 %: сидіння, стояння, ходьба та перехід із положення сидячи в положення стоячи. Встановлено, що мета-класифікатор, який навчається на послідовностях передбачень із верхнього рівня базового класифікатора, може класифікувати агрегат з точністю 79,17 та 87,50 % для першої і другої стратегії відповідно. З'ясовано, що переваги цього дослідження полягають у розробленні методів розпізнавання видів діяльності персоналу на підставі використання тільки смартгодинників, знімають обмеження щодо їх руху. Ці дослідження можна використовувати для інтелектуалізації промислових підприємств у таких напрямках: оптимізація виробничих процесів (автоматизація контролю за робочими процесами); управління ресурсами (розподіл робочого часу, використання енергії та матеріалів); безпека праці (запобігання нещасним випадкам та порушенню безпеки на робочому місці); виявлення недоліків у виробничому процесі та надання рекомендацій щодо їх усунення; аналіз тенденцій та прогнозування розвитку виробничих процесів.

Ключові слова: визначення людської активності; базовий класифікатор; мета-класифікатор; перенесене навчання; виробничі процеси.

Вступ / Introduction

Із розвитком індустрії 4.0 та людиноорієнтованим виробництвом зростає складність інтелектуалізації промислових підприємств [9]. Стало необхідним опрацьовувати великий обсяг різноманітної інформації, яка збирається з різноманітних сенсорів на промислових підприємствах, враховуючи носійні мобільні пристрої (англ. *Wearable Mobile Devices*). Внаслідок цього з'явилася можливість ефективно впроваджувати інтелектуальні методи аналізу та концептуальні підходи, стимулювати інноваційний розвиток, оптимізувати управлінські процеси та покращувати взаємодію між людиною та технологіями на підприємствах. Основними перевагами інтелектуалізації підприємств, порівняно з

традиційними виробництвами, є: підвищення рівня конкурентоспроможності; ефективне задоволення потреб суспільства; підвищення якості та ефективності управління.

Щоб оптимізувати процеси та підвищувати ефективність виробництва, потрібно:

- впроваджувати цифрові інструменти управління виробництвом;
- формувати цифрову культуру та цінності інтелектуалізації серед персоналу підприємства;
- підвищувати кваліфікацію персоналу та підтримувати інноваційне середовище на підприємстві.

Підхід до інтелектуалізації промислових підприємств на підставі розпізнавання складних видів діяльності персоналу базується на використанні передо-

Інформація про авторів:

Павлюк Олена Миколаївна, канд. техн. наук, доцент, кафедра автоматизованих систем управління.

Email: olena.m.pavliuk@lpnu.ua; <https://orcid.org/0000-0003-4561-3874>

Міщук Мирослав Володимирович, магістр, кафедра автоматизованих систем управління.

Email: olena.m.pavliuk@lpnu.ua; <https://orcid.org/0000-0001-8723-2514>

Медиковський Микола Олександрович, д-р техн. наук, професор, кафедра автоматизованих систем управління.

Email: medykmo@gmail.com; <https://orcid.org/0000-0003-2492-8578>

Цитування за ДСТУ: Павлюк О. М., Міщук М. В., Медиковський М. О. Підхід до інтелектуалізації промислових підприємств на підставі розпізнавання складних видів діяльності персоналу. Науковий вісник НЛТУ України. 2024, т. 34, № 4. С. 102–109.

Citation APA: Pavliuk, O. M., Mishchuk, M. V., & Medkovsky, M. O. (2024). Approach to intellectualization of industrial enterprises based on the recognition of complex staff activities. *Scientific Bulletin of UNFU*, 34(4), 102–109. <https://doi.org/10.36930/40340413>

вих технологій збирання даних, оброблення та аналізу, таких як системи збирання інформації з носійних мобільних пристроїв, а саме зі смартгодинників. Основна ідея полягає в тому, щоб збирати дані про робочі процеси, дії працівників та їхню взаємодію з обладнанням на підприємстві, а потім використовувати ці дані для аналізу та прийняття рішень з метою оптимізації продуктивності та зниження витрат.

Останніми роками розвиток технологій, заснованих на використанні носійних пристроїв, для розпізнавання видів людської діяльності (ВЛА), став особливо актуальним у розробленні підходів до інтелектуалізації промислових підприємств. Незважаючи на те, що сучасні методи успішно вирішують завдання визначення основних (одинарних) людських активностей, останні дослідження націлені на розроблення та вдосконалення методів безперервного визначення складних людських активностей, пов'язаних з організаційно-технічними системами. Ця тенденція підкреслює потребу у створенні підходів для постійного визначення людської активності без заздалегідь визначених маркерів початку та кінця. Використання такого підходу охоплює різноманітні сфери, зокрема Індустрію 4.0 для інтелектуального управління мобільними робототехнічними платформами (МРП), моніторингу в галузі охорони здоров'я, виявлення аномальних поведінок промислового персоналу та ін.

Отже, актуальною проблемою є розроблення нейромережевого методу визначення діяльності промислового персоналу, на підставі якого в подальшому можна було б розробити інформаційну технологію інтелектуального управління МРП.

Об'єкт дослідження – розпізнавання складних видів діяльності промислового персоналу.

Предмет дослідження – методи та засоби машинного навчання для визначення складних видів діяльності промислового персоналу і подальшої інтелектуалізації промислових підприємств.

Мета роботи – розробити підхід до інтелектуалізації промислових підприємств на підставі розпізнавання складних видів діяльності персоналу, що дасть змогу покращити контроль за виробничими процесами, оптимізувати використання ресурсів, підвищити рівень безпеки праці та виявити можливості для оптимізації виробничих потоків.

Для досягнення зазначеної мети визначено такі основні завдання дослідження:

- розробити застосунок для смартгодинника, який збиратиме дані сенсорів, що дасть змогу автоматично відстежувати, аналізувати та оптимізовувати активність персоналу;
- розробити хмарну базу даних, що зберігатиме інформацію, зібрану зі сенсорів смартгодинника, що дасть змогу зберігати та обробляти великі обсяги даних від персоналу і розширити аналітичні інструменти для аналізу зібраних даних;
- розробити методи машинного навчання для визначення складних видів діяльності промислового персоналу, що забезпечить автоматизацію високоточної ідентифікації різноманітних складних дій персоналу під час виробничих процесів;
- описати підходи до інтелектуалізації промислових підприємств на підставі розпізнавання складних видів діяльності персоналу, що уможливить вдосконалення виробничих процесів, моніторинг та аналіз робочих операцій, оптимізацію виробничих процесів та підвищення продуктивності і безпеки праці.

Аналіз останніх досліджень та публікацій. Більшість наявних рішень для відстеження та розпізнавання активності промислового персоналу базують на аналізі зображень, портативних сенсорах або поєднанні обох підходів. Запропонований у роботах [16, 17] мультимодальний підхід для розпізнавання активності працівників використовує як носійні пристрої, так і візуальні камери, враховуючи доповнення даних на підставі кінематики. Недоліком таких мультимодальних рішень є їх обмежена сфера застосування: оператор завжди має бути у фіксованому положенні, а камера має контролювати весь виробничий процес. Тому співпраця з МРП відрізняється від цього випадку, оскільки виробничий персонал повинен переміщатися між МРП, які очікують розвантаження в пунктах завантаження або розвантаження виробничої станції, або виконувати кілька допоміжних дій.

Рішення, запропоноване [5], не вимагає використання камери та не обмежує розмір виробничої станції. Носійна сенсорна система поєднує інерційний вимірювальний блок і модулі вимірювання ємності тіла для розпізнавання одинадцяти видів діяльності працівників на виробничій лінії. Підходи мультимодального об'єднання даних сенсорів для багатоканального часу базують на згорткових нейронних мережах і довготривалій короткочасній пам'яті (LSTM) [7]. Недоліком рішення є потреба розроблення спеціальних сенсорів, які збирають дані персоналу через 10 каналів на давач, загалом 20 каналів, що потребує спеціального обладнання, яке має бути здатним безперервно працювати в складних промислових умовах. Окрім цього, складність роботи штатної машини зростає, коли МРП обладнано колаборативним роботом для співпраці, коли його дані, МРП і люди повинні бути об'єднані [9, 20].

Матеріали та методи дослідження. Методика дослідження базується на використанні смартгодинників для аналізу дій оператора, заснованого на розробленому програмному забезпеченні для збирання даних, пов'язаних з діями промислового персоналу. Основним внеском у дослідження є розроблення підходу до інтелектуалізації промислових підприємств на підставі розпізнавання складних видів діяльності персоналу, який побудований на машинному навчанні. Згідно з цим підходом, можна автоматично класифікувати складні дії, які виконує промисловий персонал. Основне припущення полягає в тому, що дуже коротке мережеве навчання досягається за допомогою перенесеного навчання. Також здатність розпізнавати дуже складні послідовності операцій за допомогою архітектури стекування класифікаторів, що дає змогу виявляти прості операції та класифікувати складні дії на підставі аналізу послідовності простих операцій.

Результати дослідження та їх обговорення / Research results and their discussion

Опис розробленого застосунку смартгодинника для збирання даних. Дані з носійних пристроїв Інтернету речей збирають за допомогою апаратно-програмної системи, побудованої для Samsung Galaxy Watch 5 з WearOS. Для розроблення використовували мову програмування Kotlin, яка є стандартом для операційних систем WearOS та AndroidOS. Застосунок призначений для збирання даних зі сенсорів, їх передачі на хмарний сервер і забезпечення інтерфейсу для управління цим

процесом. Отримані дані надсилаються на хмарний сервер, побудований на MySQL. Вибір технологій зумовлений наявністю легкодоступних хмарних рішень, сумісних з MySQL, та розширеним арсеналом бібліотек і ефективних плагінів для WearOS.



Рис. 1. Екрани розробленого застосунку для смартгодинника / Screens of the developed application for a smart watch

Основні екрани користувацького інтерфейсу застосунку показано на рис. 1, зокрема: екран запуску/зупинки збирання даних із сенсорів; екран керування проведенням сесій збирання даних та композитними активностями; екран вибору базових активностей; екран ви-

бору суб'єкта збирання даних; екран, що відображає інформацію про сенсори.

Платформа як послуга PaaS (англ. *Platform-as-a-Service*) – одна з хмарних моделей, яка є готовою до використання платформою для розроблення, тестування та розгортання програмного забезпечення. Бізнес отримує цю послугу від постачальника без потреби управляти власною локальною інфраструктурою та купувати обладнання.

Запропоноване нами хмарне рішення на підставі платформи PaaS забезпечує масштабованість та розширені можливості у сфері безпеки. Ця система дає змогу одночасно отримувати дані від різних джерел, що забезпечує їх ефективне управління та підвищує ефективність дослідження. Основне призначення хмарного сервера – зберігання, оброблення та аналіз зібраних даних. Загальну структуру системи наведено на рис. 2.

Дані з двовісного акселерометра та гіроскопа з частотою дискретизації 100 Гц, враховуючи сигнали без видалення шуму, надсилаються у формі фреймів. Вони містять інформацію про тип активності, суб'єкта, час початку та кінця сигналу, позицію годинника, частоту дискретизації та тривалість фрагмента, з подальшою асинхронною передачею до хмарної бази даних через виділений потік. У разі втрати з'єднання або припинення збирання даних неповні фрейми відкидаються, а фрейми з однаковими часовими мітками початку об'єднують у шестиканальний сигнал.




Рис. 2. Структура розробленої системи збирання даних / Structure of the developed data gathering system

Опис експерименту. Під агрегатом будемо розуміти послідовність базових рухів або дій, виконаних у певному порядку. Учасники використовували спеціальний застосунок (див. рис. 1) на своїх смартгодинниках для реєстрації часу початку та завершення кожної експериментальної сесії, типу агрегату та кожної базової дії, яку вони виконали під час цих сесій. Обидва агрегати розпочинаються з однієї точки. Перший агрегат охоплює послідовність дій: сидіння (в точці 1), перехід до стояння, стояння, ходьба до точки 2, поворот на 90 градусів, ходьба до точки 3, стояння, перехід до сидіння, і знову сидіння. Потім ці дії виконують в зворотному порядку для повернення до початкової точки. Другий агрегат охоплює таку послідовність: сидіння (в точці 1), перехід до стояння, стояння, ходьба до точки 2, поворот на 180 градусів через будь-яке плече, ходьба назад до точки 1, стояння, перехід до сидіння, і знову сидіння. Усі учасники експерименту носили смартго-

динник на лівому чи правому зап'ясті. Під час фази збирання даних траплялися випадки тимчасової втрати зв'язку або навмисного припинення експерименту учасниками натисканням кнопки "Стоп" у додатку. Ці події будуть враховані та вирішуватимуться під час фази попереднього оброблення даних, щоб забезпечити цілісність та безперервність даних.

Протягом експериментів учасники безперервно виконували один із двох попередньо визначених агрегатів і вказували свої дії на годиннику. Отриманий набір даних враховує ідентифікатор базової діяльності для кожного фрейму та інформацію про учасника, від якого ці дані надійшли, разом з детальними записами про час початку та завершення експериментальних сесій з виконанням певної композитної активності.

Розподіл фреймів у зібраному наборі даних представлено на рис. 3. Розподіли фреймів у зібраному наборі даних відсортовані за базовими активностями, іде-

нтіфікаторами суб'єктів та приналежністю до певного типу агрегату (див. рис. 3). Ідентифікатори діяльності визначені так: 1 – стояти, 2 – сидіти, 5 – перехід між стоянням і сидінням (і навпаки), і 12 – ходьба. Причому дані є незбалансованими, оскільки переважає вид діяльності "ходити".




Рис. 3. Розподіл фреймів у зібраному наборі даних, розподілені за (a) базовими активностями, (b) ідентифікаторами суб'єктів та (c) належністю до певного типу агрегату / Distribution of dataframes within the collated dataset, categorized by (a) activities, (b) subject IDs, and (c) association with the aggregates

Попереднє оброблення та розділення зібраного набору даних. Для оброблення набору даних та отримання послідовностей фіксованої довжини базових активностей запропоновано використовувати конвеєр попереднього оброблення, який складається з кількох етапів. На першому етапі фільтрують фрейми даних, що входять у межі часу експериментальних сесій. Другий етап передбачає агрегацію фреймів у неперервні послідовності, з урахуванням часових проміжків між ними. Третій етап визначає підпослідовності з фіксованою кількістю зразків базових активностей та фіксованою тривалістю 60 с. На четвертому етапі підпослідовності перемішують для зменшення упередженості в мета-класифікаторі, а набір даних розбивається на навчальні та

тестові підмножини, за двома різними стратегіями. Проте недостатня кількість навчальних даних негативно впливає на мета-класифікатор, оскільки він не використовує переднє навчання. 60-секундні послідовності перемішують у випадковому порядку та розділяються (рис. 4).




Рис. 4. Розділення набору даних / Dataset partitioning

Другий підхід передбачає використання 40 % набору даних для навчання як базового, так і мета-класифікаторів, тоді як інші 40 % використовують для додаткового навчання метакласифікатора та тестування базового класифікатора. Цей метод надає більше навчальних даних для мета-класифікатора, проте може погіршити його здатність виявляти помилки базового класифікатора на нових даних.

Для виконання перенесеного навчання, частоту дискретизації подвоїли від 50 до 100 Гц за допомогою віконної техніки без перекриття з тривалістю вікна 3 секунди. Далі до сигналів застосували неперервне Вейвлет-перетворення (НВП), тобто математичну операцію, яка визначається виразом:

$$X_{\omega}(a, b) = \frac{1}{|a|^{\frac{1}{2}}} \int_{-\infty}^{+\infty} x(t) \bar{\psi}\left(\frac{t-b}{a}\right) dt, \quad (1)$$

де: $x(t)$ – функція або сигнал у часовій області; $a \in \mathbb{R}^{+*}$ – значення масштабування; $b \in \mathbb{R}$ – паралельний перенос; $\bar{\psi}(t)$ – неперервна функція у частотній та часовій областях (материнський вейвлет).

НВП є перспективною технікою для покращення точності згорткових нейронних мереж (ЗНМ) під час класифікації часових рядів. Відмінною особливістю НВП є те, що воно дає змогу звести задачу розпізнавання мультимодальних одновимірних сигналів до задачі класифікації зображень, яка значно розвинулася за останні роки. НВП має певні переваги над іншими розглянутими перетвореннями. По-перше, воно надає краще представлення функцій з гострими розривами та піками, які часто є важливими характеристиками сигналів у проблемах ВЛА. По-друге, воно дає змогу отримувати як часову, так і локальну спектральну інформацію, долаючи проблему нестационарної природи сигналів. Хоча НВП не є новим інструментом в обробленні сигналів, і поєднання НВП та ЗНМ є мало дослідженими, а саме вплив параметрів перетворення на продуктивність нейронних мереж. Також малодосліджене ВЛА на підставі портативних сенсорів, які порівнювали продук-

тивність різних архітектур нейромереж при класифікації скалограм, створених за допомогою НВП.

Стекування класифікаторів та перенесення знань.

У попередніх дослідженнях автори запропонували методологію, яка використовує техніку ансамблевого навчання, а саме стекування класифікаторів, для прогнозування типу агрегату на підставі сигналів з сенсорів [11, 15]. Базовий класифікатор навчений розрізняти чотири базові види діяльності: сидіння, стояння, ходьба та перехід із положення сидячи в положення стоячи. Мета-класифікатор навчається на послідовностях передбачень із верхнього рівня базового класифікатора, щоб класифікувати певний агрегат. Окрім цього, попереднє навчання та перенесення знань використовується для застосування знань, отриманих із більш обширного набору даних ВЛА, з метою пом'якшення проблем перенавчання та недонавчання, цим самим покращуючи можливості генералізації моделі. Спочатку зібраний набір даних проходить попереднє оброблення, щоб отримати послідовності із фіксованою кількістю фреймів, що асоціюються з виконанням конкретного агрегату. На цьому етапі також розглядаються будь-які потенційні переривання зібраних даних сигналу. Після цього, для кожного фрейму застосовується НВП до кожного з шести каналів, що призводить до генерації багатоканальних скалограм. На третьому етапі набір базових класифікаторів навчається на сторонньому наборі даних ВЛА для застосування знань, отриманих із більшого набору даних, після чого відбирається найкраща модель. На четвертому етапі, попередньо навчений базовий класифікатор навчається на отриманому наборі даних, щоб розрізняти базові активності. Потім мітки класів базових активностей для всього набору даних перевизначаються на підставі результатів передбачення нейронів верхнього рівня базового класифікатора. На останньому кроці мета-класифікатор навчається на послідовностях прогнозів базового класифікатора фіксованого розміру, щоб визначити тип агрегату, який виконується.

Попередньо навчена модель на підставі DenseNet121, спеціально розроблена для вирішення проблеми класифікації ВЛА, була обрана як базовий класифікатор. Ця модель навчена на скалограмах, створених з набору даних KU-HAR, продемонструвала високий показник F1 у 97,52 % на початковому наборі даних і значне зростання продуктивності на невеликих наборах даних при використанні техніки заморожування шарів [13]. Застосування методології передачі знань із набору даних KU-HAR до зібраного набору даних проілюстровано безпосередньо на рис. 5.




Рис. 5. Підхід до передачі знань, використаний для базового класифікатора / Knowledge transfer approach used for the base classifier




Рис. 6. Запропонована архітектура мета-класифікатора / Proposed meta-classifier architecture

Для донавчання попередньо навченої моделі на зібраному наборі даних, верхній шар нейронів було видалено та замінено новим, який містить чотири нейрони, що відповідає кількості класів базових активностей у цільовому наборі даних. Нейрони були ініціалізовані за схемою Xavier/Glorot. Потім модель була донавчена на

наборі даних дослідження, при цьому нижні 136 шарів були заморожені. Це число було обрано в попередніх дослідженнях авторів [13], де ця конфігурація показала найкращі загальні результати на малих наборах даних ВЛА. Гіперпараметри підбрано експериментально для оптимізації ефективності моделі та процесу навчання.

Використано категоріальну функцію втрат перехресної ентропії, оптимізатор Адама та розмір батча 32. Модель тренували 100 епох. Окрім цього, для покращення навчання та збереження оптимальних станів моделі використовувалися зворотні виклики "ReduceLrOnPlateau" та "ModelCheckpoint". Вагові коефіцієнти класів базових активностей були скориговані, щоб пом'якшити ефект дисбалансу набору даних.

Для побудови мета-класифікатора обрано ЗНН завдяки її здатності фіксувати часові залежності, особливо в межах сегментів даних послідовності фіксованого розміру. Архітектура запропонованого мета-класифікатора наведено на рис. 6. Вхідними даними мета-класифікатора є матриця, що інкапсулює послідовність двадцяти результатів класифікації з чотирьох верхніх нейронів базового класифікатора. Запропонована архітектура містить два шари двовимірної згортки, із застосуванням шарів пакетної нормалізації та шарів максимального об'єднання для підвищення стабільності навчання та узагальнення моделі, а також два повноз'язані шари. Функції активації були обрані як Leaky ReLu, щоб запобігти проблемі "вмираючих нейронів". Окрім цього, під час навчання використовувалися шари Dropout, щоб пом'якшити можливе перенавчання.

Вибрані гіперпараметри містять оптимізатор SGD, функцію категоріальної крос-ентропійної втрати та розмір батча 16. Навчання тривало 500 епох, враховуючи зворотні виклики "ReduceLrOnPlateau" та "ModelCheckpoint". Окрім цього, для усунення дисбалансу набору даних використовували відповідні ваги класів композитних активностей.

У табл. 1 наведено показники продуктивності базового класифікатора на тестовій підмножині. Досягнуте значення точності становить 90,90 %, що ми вважаємо достатньою продуктивністю, особливо з огляду на обмежені навчальні дані та можливість дублювання базових активностей у 3-секундному кадрі даних (у разі, якщо декілька базових активностей підпадають під один 3-секундний фрейм).

Табл. 1. Результати класифікації базового класифікатора на тестовій підмножині / Classification results of the base classifier on the test subset

Accuracy, %	Precision, %	Recall, %	AUC, %	F1-score, %
90,90	91,33	90,69	97,26	91,01

Табл. 2. Результати класифікації мета-класифікаторів на тестовій підмножині / Classification results of meta-classifiers on the test subset

	Accuracy, %	Precision, %	Recall, %	AUC, %	F1-score, %
Стратегія розділення 1	79,17	79,17	79,17	84,34	79,17
Стратегія розділення 2	87,50	87,50	87,50	92,40	87,50

Окрім цього, показник F1 становить 91,01 %. Оскільки цей показник стійкий до незбалансованості набору даних, це означає, що класифікатор зберігає неупередженість у всіх видах діяльності, забезпечуючи збалансовану можливість класифікації. На наступному етапі мітки активності в наборі даних були перевизначені результатами прогнозування нейронів верхнього рівня базового класифікатора. Показники продуктивності мета-класифікаторів, навчених із використанням першої та другої стратегій розділення набору даних, на-

ведено в табл. 2. Модель, навчена за допомогою другої стратегії розділення, продемонструвала кращу продуктивність порівняно з моделлю, навченою з "ідеальною" конфігурацією розділення, результати якого відображені у значенні F1-score 87,50 %. Для валідації у другій стратегії розділення було виділено 15 % навчального набору даних.

Отримані результати свідчать про те, що модель другої стратегії отримала позитивний ефект від розширених знань зі спільних навчальних даних, одночасно успішно використовуючи інформацію з другої підмножини для пом'якшення неточностей базового класифікатора. Продуктивність мета-класифікатора є задовільною, особливо враховуючи подібність між агрегатами та змінними темпами, з якими суб'єкти виконували ці агрегати. Ця продуктивність, незважаючи на виклики, з якими стикаються, підкреслює значний потенціал запропонованого нами методу. Очікується, що продуктивність моделі може бути додатково покращена за рахунок включення додаткових базових типів діяльності, таких як обертальні рухи, скорочення тривалості фреймів і розширення набору даних для включення більшої різноманітності суб'єктів. Окрім цього, інтеграція шарів LSTM і Gated Recurrent Unit (GRU) у мета-класифікатор є багатообіцяючою стратегією.

Обговорення результатів дослідження. Практичне застосування видів людської діяльності (ВЛА) охоплює різні сфери: охорона здоров'я [7]; спорт [1, 2]; управління інтелектуальною логістикою [10, 11, 12, 14]. ВЛА можна розділити на два основні типи діяльності. Перший тип охоплює прості, повторювані рухові дії, такі як біг, сидіння або підіймання сходами, які легко розпізнати за допомогою статистичного аналізу і базових моделей машинного навчання.

Другий тип належить до комплексної, функціональної та контекстної діяльності, такої як робота, приготування їжі або заняття спортом. Ця діяльність характеризується високою складністю і вимагає передових методів класифікації та виявлення. Розпізнавання цих складних дій у реальному часі є важливим, оскільки усуває потребу ручного введення позначок часу початку та кінця користувачем. Хоча розпізнавання основних видів людської діяльності було успішно вивчено, акцент на поточних дослідженнях все більше звертається на складні, багатоетапні види діяльності. Це підкреслює потребу передових методів для ідентифікації діяльності без попередньо визначених маркерів початку та кінця. Додатки комплексного ВЛА поширюються на такі галузі, як інтелектуальне управління в індустрії 4.0, моніторинг охорони здоров'я, виявлення аномалій і спортивна аналітика. Зростаюча популярність МРП, застосовуваних для гнучкого виробництва, стала результатом не тільки їхніх технічних особливостей, але й їхньої здатності до взаємодії з виробничим персоналом. Співпраця між персоналом і МРП створює кілька проблем, пов'язаних із використанням штучного інтелекту (ШІ) [6]. Одним з них є автоматичне розпізнавання діяльності оператора.

Розвиток машинного навчання та ШІ значно розширив методи та моделі, що використовують в області ВЛА: дерева рішень, випадковий ліс, К найближчих сусідів або опорної векторної машини [3, 4]. Такі підходи мають недоліки: дрібних особливостей часто недостатньо для розпізнавання перехідних станів і багато-

етапної діяльності; вимагає від інженера машинного навчання високої кваліфікації та індивідуального підходу до кожного набору даних. Альтернативою цьому підходу є ШНМ, але вони вимагають великих навчальних наборів даних, а це часто проблематично забезпечити [8, 15, 18]. Для усунення цього недоліку в запропонованій роботі використовують техніку перенесеного навчання, а потім точного налаштування на конкретному наборі даних.

Поточні рішення для моніторингу та розпізнавання дій оператора в основному зосереджені на аналізі зображень, технології портативних сенсорів або гібридних. Проте вони мають низку недоліків: забезпечення конфіденційності, обмеження руху персоналу, складність інтеграції камер і сенсорів та значні фінансові затрати. Це дослідження передусім зосереджено на розробленні та вдосконаленні підходу до виявлення складних рухів промислового персоналу на підставі сенсорів смартгодинників.

Отже, за результатами виконаної роботи можна сформулювати такі наукову новизну та практичну значущість результатів дослідження.

Наукова новизна отриманих результатів дослідження – удосконалено методику для подальшого дослідження інтелектуалізації промислових підприємств на підставі розпізнавання складних видів діяльності персоналу, що дасть змогу точніше і повніше оцінювати діяльність персоналу, виявляти шляхи підвищення продуктивності праці та оптимізації робочих процесів, впроваджувати більш інтелектуальні системи управління на промислових підприємствах, вдосконалити технології та методи управління виробничими процесами.

Практична значущість результатів дослідження – отримані результати створюють підґрунтя для подальшого точнішого аналізу взаємодії виробничого персоналу з МРП на підставі складних ВЛА та інтелектуалізації промислових підприємств.

Висновки / Conclusions

Розроблено комплексний підхід до інтелектуалізації промислових підприємств на підставі розпізнавання складних видів діяльності персоналу, що дало змогу ефективно інтегрувати працівників у інформаційну технологію для управління виробничими процесами. Проаналізовано можливість для оптимізації виробничих процесів, управління ресурсами та забезпечення безпеки праці на промислових підприємствах. За результатами дослідження можна зробити такі основні висновки.

1. Розроблено застосунок для смартгодинника, який збирає дані сенсорів. Це дає змогу отримувати в режимі реального часу важливу інформацію про активність промислового персоналу для подальшого аналізу та використання у процесі інтелектуалізації промислових підприємств. З'ясовано, що переваги цього дослідження полягають у розробленні методів розпізнавання видів діяльності персоналу на підставі використання тільки смартгодинників, які знімають обмеження щодо їх руху.
2. Розроблено хмарну базу даних, що зберігає інформацію, зібрану зі сенсорів смартгодинника та інформацію про події, пов'язані з композитними активностями і сесії збирання даних. Вона забезпечує доступність даних для аналізу та використання їх у різних виробничих процесах.
3. Розроблено методи машинного навчання для визначення складних ВЛА, які дають змогу автоматично розпіз-

навати і класифікувати різні складні дії персоналу на підприємстві на основі застосування технологій: ансамблевого навчання; стекування класифікаторів; перенесення знань та неперервного Вейвлет-перетворення. Встановлено, що базовий класифікатор, побудований на DenseNet121, може розрізняти базові види діяльності з точністю 90,90 %. Мета-класифікатор може класифікувати агрегат з точністю 79,17 та 87,50 % для першої і другої стратегій відповідно.

4. Представлено підхід до інтелектуалізації промислових підприємств на основі розпізнавання складних ВЛА. Це створює можливість для оптимізації виробничих процесів, управління ресурсами та підвищення безпеки праці на підприємстві.

Результати дослідження свідчать про значний потенціал цього методу для розроблення надійної структури для розпізнавання ВЛА, що може бути використана для інтелектуального управління підприємством. Запропонований підхід може допомогти оптимізувати та автоматизувати внутрішні логістичні процеси на підприємстві, зокрема для розпізнавання дій персоналу, який взаємодіє з МРП, та аналізу їхньої ефективності. Це може допомогти у плануванні маршрутів МРП, оптимізації розподілу завдань між МРП та персоналом, а також у виявленні можливих проблем або несправностей у роботі системи МРП. Такий підхід може підвищити ефективність та автономність логістичних операцій на промисловому підприємстві, сприяючи підвищенню продуктивності та зниженню витрат.

References

1. Abdel-Basset, M., Hawash, H., Chakraborty, R., Ryan, M., Elhoseny, M., & Song, H. (2020). ST-DeepHAR: Deep Learning Model for Human Activity Recognition in IoT Applications. *IEEE Internet of Things Journal*, 8(6), 4969–4979. <https://doi.org/10.1109/JSEN.2019.2946095>
2. Al-Amin, M., Tao, W., Doell, D., Lingard, R., Yin, Z., Leu, M. C., & Qin, R. (2019). Action recognition in manufacturing assembly using multimodal sensor fusion. *Procedia Manufacturing*, 39, 158–167. <https://doi.org/10.1016/j.promfg.2020.01.288>
3. Attal, F., Mohammed, S., Dedabrishvili, M., Chamroukhi, F., Oukhellou, L., & Amirat, Y. (2015). Physical Human Activity Recognition Using Wearable Sensors. *Sensors*, 15, 31314–31338. <https://doi.org/10.3390/s151229858>
4. Bannasar, M., Price, B. A., Gooch, D., Bandara, A. K., & Nuseibeh, B. (2022). Significant Features for Human Activity Recognition Using Tri-Axial Accelerometers. *Sensors*, 22 p. <https://doi.org/10.3390/s22197482>
5. Castro-García, J. A., Molina-Cantero, A. J., Gómez-González, I. M., Lafuente-Arroyo, S., & Merino-Monge, M. (2022). Towards Human Stress and Activity Recognition: A Review and a First Approach Based on Low-Cost Wearables. *Electronics*, 11 p. <https://doi.org/10.3390/Electronics11010155>
6. Cupek, R., Lin, J. C.-W., & Syu, J. H. (2022). Automated Guided Vehicles Challenges for Artificial Intelligence. In *2022 IEEE International Conference on Big Data*, 6281–6289. <https://doi.org/10.1109/BigData55660.2022.10021117>
7. Li, H., Shrestha, A., Heidari, H., Le Kernec, J., & Fioranelli, F. (2020). Bi-LSTM Network for Multimodal Continuous Human Activity Recognition and Fall Detection. *IEEE Sensors Journal*, 20, 1191–1201. <https://doi.org/10.1109/JSEN.2019.2946095>
8. Mahmud, T., Sayyed, A. Q. M. S., Fattah, S. A., & Kung, S.-Y. (2021). A Novel Multi-Stage Training Approach for Human Activity Recognition From Multimodal Wearable Sensor Data Using Deep Neural Network. *IEEE Sensors Journal*, 21, 1715–1726. <https://doi.org/10.1109/JSEN.2020.3015781>
9. Mohsen, S., Elkaseer, A., & Scholz, S. G. (2021). Industry 4.0-Oriented Deep Learning Models for Human Activity Recognition. *IEEE Access*, 9, 150508–150521. <https://doi.org/10.1109/ACCESS.2021.3125733>

10. Nahorna, I. I. (2019). Labor intellectualization development at an industrial enterprise. *Efektivna ekonomika*, 6 p. <https://doi.org/10.32702/2307-2105-2019.6.61>
11. Niemann, F., Lüdtke, S., Bartelt, C., & ten Hompel, M. (2022). Context-Aware Human Activity Recognition in Industrial Processes. *Sensors*, 22, 134 p. <https://doi.org/10.3390/s22010134>
12. Pavliuk, O., & Mishchuk, M. (2022). A novel Deep-Learning model for Human Activity Recognition based on Continuous Wavelet Transform. In *5th International Conference on Informatics & Data-Driven Medicine*, pp. 236–245. CEUR Workshop Proceedings. <https://ceur-ws.org/Vol-3302/paper14.pdf>
13. Pavliuk, O., Mishchuk, M., & Strauss, C. (2023). Transfer Learning Approach for Human Activity Recognition Based on Continuous Wavelet Transform. *Algorithms*, 16(2), 77 p. <https://doi.org/10.3390/a16020077>
14. Pavliuk, O., Steclik, T., & Biernacki, P. (2022). The forecast of the AGV battery discharging via the machine learning methods. In *2022 IEEE International Conference on Big Data (Big Data)*, 6315–24. <https://doi.org/10.1109/BigData55660.2022.10020968>
15. Sikder, N., Ahad, M. A. R., & Nahid, A.-A. (2021). Human Action Recognition Based on a Sequential Deep Learning Model. In *2021 Joint 10th International Conference on Informatics, Electronics & Vision (ICIEV) and 2021 5th International Conference on Imaging, Vision & Pattern Recognition (icIVPR)*, 1–7. <https://doi.org/10.1109/ICIEVicIVPR52578.2021.9564234>
16. Suh, S., Rey, V. F., Bian, S., Huang, Y. C., Rožanec, J. M., Ghinani, H. T., Zhou, B., & Lukowicz, P. (2023). Worker Activity Recognition in Manufacturing Line Using Near-body Electric Field. *IEEE Internet of Things Journal*, 1–1. <https://doi.org/10.48550/arXiv.2308.03514>
17. Tao, W., Leu, M. C., & Yin, Z. (2020). Multi-modal recognition of worker activity for human-centered intelligent manufacturing. *Engineering Applications of Artificial Intelligence*, 95 p. <https://doi.org/10.1016/j.engappai.2020.103868>
18. Xu, C., Chai, D., He, J., Zhang, X., & Duan, S. (2019). InnoHAR: A Deep Neural Network for Complex Human Activity Recognition. *IEEE Access*, 7, 9893–9902. <https://doi.org/10.1109/ACCESS.2018.2890675>
19. Zhuang, Z., & Xue, Y. (2019). Sport-Related Human Activity Detection and Recognition Using a Smartwatch. *Sensors*, 19 p. <https://doi.org/10.3390/s19225001>
20. Ziebinski, A., Mrozek, D., Cupek, R., Grzechca, D., Fojcik, M., Drewniak, M., Kyrkjebø, E., Lin, J. C.-W., Ovsthus, K., & Biernacki, P. (2021). Challenges associated with Sensors and data fusion. https://doi.org/10.1007/978-3-030-77970-2_45

O. M. Pavliuk, M. V. Mishchuk, M. O. Medykovskyy

Lviv Polytechnic National University, Lviv, Ukraine

APPROACH TO INTELLECTUALIZATION OF INDUSTRIAL ENTERPRISES BASED ON THE RECOGNITION OF COMPLEX STAFF ACTIVITIES

Technologies based on the use of wearable devices for recognizing types of human activity are analyzed, which makes this direction quite relevant in the context of developing approaches to the intellectualization of industrial enterprises. Within the framework of the conducted research, a method based on neural networks is presented for identifying the types of activity of industrial personnel in order to integrate it further into information technology for intelligent management of production processes. Therefore, the following was developed: an application for a smart watch that collects sensor data; a cloud database for storing this information; machine learning methods for determining complex activities of industrial personnel. For pre-processing and separation of the collected data set, a pipeline is applied, which filters data frames, aggregates them into continuous sequences with a fixed number of samples of basic activities and the duration of 60 s, and also shuffles them. The obtained data is divided into training and test subsets, according to two strategies. Moreover, the continuous wavelet transform is applied to the signals. It has been established that the ability to recognize very complex sequences of operations can be improved using a classifier stacking architecture, which allows detecting simple operations and classifying complex operations based on the analysis of sequences of simple operations. It is found that the base classifier built on DenseNet121 with transfer learning can distinguish the following four basic activities with 90.90 %: sitting, standing, walking, transition from sitting to standing. We have also revealed that a meta-classifier trained on prediction sequences from the top-level of the base classifier can classify the aggregate with 79.17 % and 87.50 % accuracy for the first and second strategies, respectively. Thus, the advantages of this study are the development of methods for recognizing the types of personnel activities based on the use of only smart watches, removing restrictions on their movement. These studies can be used for the intellectualization of industrial enterprises in the following areas: optimization of production processes (automation of work process control); resource management (allocation of working time, use of energy and materials); occupational safety (prevention of accidents and safety violations at the workplace); identifying flaws in the production process and providing recommendations for their elimination; analysis of trends and forecasting the development of production processes.

Keywords: human activity recognition; basic classifier; meta-classifier; transferred learning; production processes.