

ПРОЦЕСИ НАВЧАННЯ В ТЕХНОЛОГІЯХ ШТУЧНОГО ІНТЕЛЕКТУ

О. П. Мінцер

Національний університет охорони здоров'я України імені П. Л. Шупика

Обговорюються існуючі моделі теорії навчання та пропонується нова трансдисциплінарна модель для представлення ролі штучного інтелекту (ШІ) в удосконаленні процесів навчання та процедурах прийняття рішень. Дослідження присвячено концептуалізації основоположних ідей для моделі, що може стати основою розроблення додатків штучного інтелекту для підтримки процесів навчання на різних рівнях трансферу знань. Результати дослідження виявили, що випадкове використання методу навчання не може забезпечити високі результати трансферу знань, оскільки вкрай важливим є обґрунтована селективна стратегія передавання знань. Розроблення високоякісних і надійних симуляційних середовищ для відпрацювання алгоритмів передавання знань в охороні здоров'я може полегшити розроблення та валідацію методів навчання поза обмежень ретроспективних досліджень. Застосування методів, перевірених у таких симуляційних середовищах у реальних клінічних умовах із одночасним наглядом клініцистів дозволить вирішити проблеми вибору алгоритмів.

Ключові слова: процеси навчання в технологіях штучного інтелекту, концептуалізація, контрольоване машинне навчання, напівконтрольоване навчання, алгоритми класифікації, самоконтрольоване машинне навчання, навчання з підкріпленням.

LEARNING PROCESSES IN ARTIFICIAL INTELLIGENCE TECHNOLOGIES

O. P. Mintser

Shupyk National Healthcare University of Ukraine

Background. Existing models of learning theory are discussed and a new transdisciplinary model is proposed for modeling the role of artificial intelligence (AI) in improving learning processes and decision-making procedures. The purpose of the study is to conceptualize the fundamental ideas for the model, which can become the basis for the development of artificial intelligence applications to support learning processes at various levels of knowledge transfer.

Materials and methods. Theoretical analysis, generalization and systematization of research results were carried out using the leading scientometric databases PubMed, Ovid Cochrane Central Register of Controlled Trials, Ovid Cochrane Database of Systematic Reviews, Web of Science and Scopus. Methods of content analysis and knowledge engineering were also applied.

Results. Random use of the teaching method cannot ensure high results of knowledge transfer — a well-founded selective strategy of knowledge transfer is extremely important. Machine learning algorithms are divided into six broad categories: supervised learning, semi-supervised learning, unsupervised learning, self-supervised learning, and reinforcement learning, multi-instance learning. An important challenge in new learning processes is solving moral and ethical problems.

Conclusions. The development of high-quality and reliable simulation environments for practicing knowledge transfer algorithms in health care can facilitate the development and validation of training methods beyond the limitations of retrospective studies. The application of methods tested in such simulation environments in real clinical conditions with simultaneous supervision by clinicians will allow solving the problems of algorithm selection.

Keywords: learning processes in artificial intelligence technologies, conceptualization, supervised machine learning, semi-supervised learning, classification algorithms, self-supervised machine learning, reinforcement learning.

Вступ. Багато сучасних галузей досліджень підкріплюються обчислювальними ресурсами. З'явилася спільна основа для об'єднуючої структури, що охоплює штучний інтелект (ШІ), аналітику навчання, інтелектуальний аналіз освітніх даних, машинне навчання (Machine learning, ML) та теорію складності [2, 4]. Shan Wang et al. проаналізували еволюцію знань у сфері штучного інтелекту в освітніх дослідженнях із 2010 по 2019 роки та знайшли широкий спектр досліджень, зосереджених насамперед навколо інтелектуальних навчальних систем і масово відкритих онлайн-курсів [6].

Нейронні мережі, персоналізоване навчання, відстеження очей і глибоке навчання були додатковими ключовими словами в цій галузі на той час. Оскільки нові можливості штучного інтелекту стають доступними щодня, незабаром системи ШІ стануть широко використовуватися, щоб допомогти написати статтю чи есе, окреслити документ, створити оригінальний витвір мистецтва або виступати в якості співавтора в науковому дослідницькому проекті. Завдяки найсучаснішим досягненням у машинному навчанні, таким як великі мовні моделі, штучний інтелект може відповідати за більшу частину «роботи» в цій діяльності [22]. Такі події ставлять під сумнів давні уявлення про навчання. Виникає багато нових питань, у першу чергу, етичних [5]. Існує п'ять аспектів на які слід звернути увагу під час

використання ШІ в освіті: доступ, представлення, алгоритми, інтерпретація, права та обов'язки суб'єкту навчання.

Окрім потенційної шкоди, науково-педагогічні працівники (НПП), які розглядають ШІ, також можуть бути вразливими до надмірно розкрученого потенціалу та пасток ШІ в освіті — «театру ШІ», за словами N. Selwyn можливо, частково підживленого «зачарованим детермінізмом» — відчуття, що технологія якимось магічним чином підніметься з надлюдською силою, щоб усунути недоліки освіти або врятувати людство від його власних найгірших імпульсів [21].

Основи для теорії навчання були запропоновані з кількох дисциплін, таких як педагогічна психологія (наприклад, біхевіоризм, когнітивізм і конструктивізм), біологія (наприклад, автокаталіз, еволюція, емерджентність) та інформатика (наприклад, одномоментне навчання, глибинне навчання, нейронні мережі, стохастичні блочні моделі нескінченного змішаного членства), але рідко були інтегровані чи уніфіковані в межах або між дисциплінами [3, 9]. Однією з причин, чому існує так багато теорій навчання, є те, що кожна модель пояснює лише частину історії, що призводить до багатьох ідей, які збігаються, або суперечливих ідей.

Ідеї, що збігаються, включають, наприклад, спільне занепокоєння про активну участь у навчанні (реакції у поведінковій моделі, нервова реорганізація

в когнітивній моделі, розроблення ментальної моделі в конструктивістській моделі), тоді як суперечливі ідеї включають обмеження волі (наприклад, моделі поведінки обмежені реакціями на стимули, когнітивні моделі зосереджені переважно на нервовій реорганізації, конструктивістські моделі зосереджені на створенні та адаптації ментальних моделей).

Сьогодні, в епоху штучного інтелекту, переосмислення теорії навчання вимагається з кількох причин: упередженість будь-якого опису, що вимагає постійної відкритості для нових теорій і пояснень; уроки еволюції та складності, які спрямовані на постійну коадаптацію теорії до реальності; і більш потужні обчислювальні моделі навчання, що поглиблюють наше розуміння попередніх теорій і розширюють охоплення та силу як символічної, так і буквальної людської діяльності. Нарешті, можливості великих даних, обчислювальної потужності та моделей глибокого навчання досягли такого етапу, коли питання про роль штучного інтелекту в суспільстві стають більш актуальними, ніж будь-коли. Відповідно, необхідно по-новому побачити потенційну роль штучного інтелекту в навчанні, викладанні навчального матеріалу, організації наукових досліджень і в управлінні системою освіти на всіх її рівнях [1].

Мета дослідження: концептуалізація основоположних ідей для моделі, що може стати основою для розроблення додатків штучного інтелекту для підтримки процесів навчання на різних рівнях освіти. Ключові питання, що ведуть до розгляду: як штучний інтелект може допомогти людям у процесі навчання? Як штучний інтелект може допомогти командам експертів, командам для співпраці та спільнотам знань у процесах навчання? Як ІІІ може допомогти розширенню міждисциплінарної культури в процесах навчання?

Матеріал і методи дослідження. Проведено теоретичний аналіз, узагальнення та систематизацію

результатів досліджень із використанням провідних наукометричних баз даних PubMed, Ovid Cochrane Central Register of Controlled Trials, Ovid Cochrane Database of Systematic Reviews, Web of Science і Scopus. Застосовували також методи контент-аналізу, інженерії знань.

Результати та їх обговорення. Алгоритми машинного навчання поділяють на шість широких категорій: контрольоване навчання, напівконтрольоване навчання, неконтрольоване навчання, самоконтрольоване навчання та навчання з підкріпленням, багатоекземплярне навчання.

Контрольоване машинне навчання (supervised machine learning) — тип передавання знань, де модель навчається на позначеному наборі даних і цільовий або кінцевий рівень знань відомий. Контрольоване навчання зазвичай використовується для оцінювання ризиків, розпізнавання зображень, прогнозування аналітики та включає кілька типів алгоритмів. Серед них виокремлюють алгоритми регресії з кінцевою метою прогнозування вихідних значень досліджуваної характеристики шляхом виявлення лінійних або нелінійних залежностей між реальними чи безперервними значеннями показників (наприклад, артеріальний тиск, частота серцевих скорочень тощо).

Важливе значення в процедурах навчання набувають *алгоритми класифікації*, завданням яких є прогнозування змін категоричних ознак (наприклад, «серцева недостатність» або її відсутність). У групу алгоритмів класифікації включають логістичну регресію, методи кластеризації (k-найближчих сусідів і опорні векторні машини тощо [8, 18, 19, 23].

Для класифікації великих наборів даних використовують наївні класифікатори Байеса. Вони також є частиною сімейства алгоритмів генеративного навчання, що моделюють розподіл вхідних даних певного класу чи категорії. Наївний

алгоритм Байєса включає дерева рішень, що фактично можуть вмістити як алгоритми регресії, так і алгоритми класифікації. У свою чергу *алгоритми випадкового лісу* передбачають значення або категорію шляхом поєднання результатів кількох дерев рішень.

Контрольоване машинне навчання уже сьогодні має широке застосування [11], оскільки розглядається як тип штучного інтелекту, що передбачає навчання алгоритмів на основі даних для вироблення прогнозів або виконання дії без явного програмування. Деякі потенційні застосування машинного навчання в охороні здоров'я включають прогностичну аналітику в тому сенсі, що стає можливим аналіз даних із електронних медичних записів, передбачення ймовірності певних наслідків для здоров'я, таких як повторна госпіталізація або початок хронічних захворювань. Це може допомогти виявленню пацієнтів із високим ризиком і проведенню проактивних заходів для запобігання несприятливим результатам. У діагностиці та лікуванні алгоритми машинного навчання можна навчити аналізувати медичні зображення, наприклад КТ або рентгенівські знімки, щоб допомогти діагностувати або визначити найбільш відповідне лікування для пацієнта. Нарешті, в персоналізованій медицині: за допомогою машинного навчання можна передбачити ймовірність ефективності методів лікування для конкретного пацієнта на основі його індивідуальних особливостей, таких як генетика та історія хвороби.

Дуже важливим напрямом використання подібних алгоритмів являється підтримка клінічних рішень. Алгоритми машинного навчання можна інтегрувати в клінічні системи підтримки прийняття рішень, щоб допомогти постачальникам медичних послуг приймати більш обґрунтовані рішення стосовно догляду за пацієнтами.

Це допомагає пристосувати лікування до унікального генетичного профілю, історії хвороби та факторів способу життя кожного пацієнта. Передбачаючи ефективність методів лікування в конкретному випадку вони будуть мати виключне значення для створення персоналізованої медицини.

Особливе місце займають нейронні мережі, що імітують роботу людського мозку з величезною кількістю пов'язаних вузлів обробки, які можуть сприяти таким процесам, як переклад природною мовою, розпізнавання зображень, розпізнавання мови та створення зображень.

Самоконтрольоване машинне навчання (self-supervised machine learning) дає змогу моделям навчатися на немаркованих даних замість того, щоб вимагати масивних анотованих та/або позначених наборів даних. Алгоритми SSL, що також називаються алгоритмами прогнозування або навчання претексту, вивчають одну частину вхідних даних із іншої частини, автоматично генеруючи мітки та перетворюючи неконтрольовані проблеми на контрольовані. Ці алгоритми особливо корисні для таких робіт, як комп'ютерне бачення, де обсяг позначених навчальних даних, необхідних для навчання моделей, може бути надзвичайно великим.

Навчання з підкріпленням (reinforcement Learning) реалізує навчання на основі зворотного зв'язку людини, являє собою тип динамічного програмування, що навчає алгоритми за допомогою системи «винагород» та «покарання». Відповідно до алгоритму програма виконує дії у певному середовищі для досягнення заздалегідь визначеної мети та отримує винагороду або покарання за свої дії на основі встановленої метрики (зазвичай бали). Програма таким чином заохочується до продовження гарних практик і відкидання поганих.

При повтореннях програма вивчає найкращі стратегії [12]. В охороні здоров'я існує багато ситуацій, коли рішення приймаються послідовно, і підходи до навчання з підкріпленням можуть виявитися корисними для прийняття рішень. Структури та методи навчання з підкріпленням широко застосовуються в клінічних умовах, у яких рішення приймаються послідовно. Визначеним клінічним застосуванням підкріплюючого навчання являється рекомендація про лікування, що було вивчено для різних захворювань і методів лікування, включаючи променеву та хіміотерапію, стимуляцію мозку при епілепсії та стратегії лікування сепсису. В таких умовах рекомендації про лікування відомі як динамічний режим лікування. Існують різні інші клінічні застосування навчання з підкріпленням, включаючи діагностику, медичну візуалізацію та інструменти підтримки прийняття рішень [13-16]. Незважаючи на успіх навчання з підкріпленням у кількох спрощених клінічних умовах, їх широкомасштабне застосування для догляду за пацієнтами поки що стикається з кількома відкритими проблемами, зокрема, складністю процесів розвитку патологій, наявністю великої кількості факторів ризику та конфаундерів. Все це ускладнює моделювання процесів прийняття клінічних рішень як проблему навчання з підкріпленням. Простір станів у таких налаштуваннях часто величезний, що може зробити суто обчислювальний підхід неможливим. Крім того, моделювання всіх потенційних цілей апіорі як функція покарання та винагороди може бути неможливим.

Напівконтрольоване навчання (semi-supervised learning) протягом останніх років стало перспективним нововведенням у дослідженні машинного навчання. Це тісно пов'язане з проблемами того, як робити висновки з даних, що частково перекриваються з трансдуктивним висновком (відмінності ще належить уточнити).

У той же час маємо справу з ситуацією, коли відносно мало позначених тренінгів точки доступні, але надається велика кількість непозначених точок, що безпосередньо актуальні для багатьох практичних проблем, наприклад, автоматичної класифікації веб-сторінок. Напівконтрольоване навчання використовує різноманітний набір інструментів і ілюструє, у невеликому масштабі, складне обладнання, розроблене в різних галузях машинного навчання, наприклад як методи ядра або байєсовські методи. Алгоритми напівконтрольованого навчання навчаються на невеликому наборі даних із мітками та великому наборі даних без міток, причому дані з мітками керують процесом навчання для великої маси даних без міток. Модель напівконтрольованого навчання може використовувати неконтрольоване навчання для ідентифікації кластерів даних, а потім використовувати контрольоване навчання для позначення кластерів. Прикладом напівконтрольованого машинного навчання можуть слугувати генеративні змагальні мережі — інструмент глибокого навчання, що генерує немічені дані шляхом навчання двох нейронних мереж.

Багатореземплярне навчання (multi-instance learning, MIL) — це нова парадигма машинного навчання, що особливо добре підходить для завдань аналізу медичних зображень і відео (medical image and video analysis). Базуючись виключно на мітках класів, глобальне призначених зображенням або відео, алгоритми MIL навчаються виявляти релевантні шаблони локально в зображеннях або відео. Потім ці моделі використовуються для класифікації на глобальному рівні. Оскільки нагляд ґрунтується на глобальних мітках, ручна сегментація для навчання алгоритмів не потрібна [17].

Впровадження технології ML постійне прискорюється. У 2022 році світовий ринок машинного навчання оцінювався у 19 мільярдів

доларів США, а до 2030 року очікується, що він досягне 188 мільярдів доларів США. Масштаб впровадження ML та його зростаючий вплив на бізнес роблять розуміння штучного інтелекту та технологій ML необхідним — і життєво важливим. Абсолютно важливим є пильний моніторинг та своєчасне коригування в міру розвитку технологій. Уже на теперішній час активно використовуються 6 перелічених стратегій навчання (контрольоване навчання; навчання без контролю; навчання з підкріпленням; напівконтрольоване навчання; самоконтрольоване навчання; багатоекземплярне навчання) використовуються різні формати висновків (статистичний висновок; індуктивне навчання; дедуктивний висновок; трансдуктивне навчання). Існує низка проблем з техніки навчання, особливо при реалізації багатозадачного навчання; активного та онлайн-навчання. Постійно вдосконалюється передавання навчальних та ансамблевих технологій навчання.

В результаті, незважаючи на успіх різних стратегій навчання у кількох клінічних умовах, їх широкомасштабне застосування для догляду за пацієнтами стикається з кількома відкритими проблемами. Складність людської біології ускладнює моделювання прийняття клінічних рішень як проблему навчання з підкріпленням. Простір станів у таких налаштуваннях часто величезний, що може зробити суто обчислювальний підхід неможливим. Крім того, моделювання всіх потенційних цілей апріорі як функція винагороди може бути неможливою. Щоб подолати ці проблеми та реалізувати потенціал навчання з підкріпленням, клінічне розуміння може зіграти ключову роль. Точніше, обмеження простору станів лише включенням дуже релевантних клінічних змінних може значно зменшити обчислювальну складність. Крім того, використовуючи навчання зворотного підкріплення, відповідні функції винагороди можна вивчити з ретроспективних досліджень, припускаючи оптимальність клінічних рішень [18-20].

Ще одним важливим викликом стає вирішення морально-етичних проблем. Обов'язково потрібно переконатися, що методи навчання не завдадуть шкоди пацієнту. З цією метою існує необхідність ретельної перевірки таких методів перед їх використанням у догляді за пацієнтами. Отже, існує потреба вийти за рамки ретроспективних досліджень, що використовувалися для підтвердження концепції більшості існуючих методів навчання з підкріпленням у програмах охорони здоров'я. Висновки, отримані в результаті успішного навчання в різних сферах застосування, можуть допомогти визначити шлях до реалізації його потенціалу в охороні здоров'я.

Доступні середовища моделювання з відкритим кодом, що дозволяють дослідникам порівнювати різні підходи, являються важливими для сфери навчання з підкріпленням. Розроблення високоякісних і надійних симуляційних середовищ для програм охорони здоров'я (зокрема нефрології) може полегшити розроблення та валідацію методів навчання з підкріпленням поза обмеженими ретроспективними дослідженнями. Застосування методів, перевірених у таких симуляційних середовищах у реальних клінічних умовах, вимагатиме нагляду клініцистів. Подібно до того, як для безпілотних автомобілів потрібна людина-водій, щоб уникнути зіткнення, нагляд лікарів має вирішальне значення для забезпечення безпеки пацієнтів, особливо на ранніх етапах впровадження методів навчання з підкріпленням. Дані з рішень клініцистів (скасування автоматизованих рекомендацій про лікування) з часом можна використовувати для підвищення надійності автономних систем та зменшення тягаря нагляду для клініцистів.

Висновки. 1. Використання випадковим чином методу навчання не може забезпечити високі результати трансферу знань. Важливою являється обґрунтована селективна стратегія передавання знань.

2. Розроблення високоякісних і надійних симуляційних середовищ для відпрацювання алгоритмів передавання знань в охороні здоров'я може полегшити створення та валідацію методів навчання поза обмежень ретроспективних досліджень.

Література.

1. Learning theories for artificial intelligence promoting learning processes / Gibson D., Kovanovic V., Ifenthaler D. et al. // *British Journal of Educational Technology*. – 2023. – Vol. 54, is. 5. – P. 1125–1146.

2. Superposition of many models into one / Cheung B., Terekhov A., Chen Y. et al. // *Advances in Neural Information Processing Systems*. – 2019. – P. 10867–10876.

3. Paradigm shifts in designed instruction: From behaviorism to cognitivism to constructivism / Cooper P. A. // *Educational Technology*. – 1993. – Vol. 33, no. 5. – P. 12–19.

4. Rethinking learning analytics adoption through complexity leadership theory / Dawson S., Poquet O., Colvin C. et al. // *LAK'18: Proceedings of the 8th International Conference on Learning Analytics and Knowledge*, Sydney, 7–9 March 2018 / Sydney, New South Wales, Australia, 2018. – P. 236–244.

5. The cyclical ethical effects of using artificial intelligence in education / Dieterle E., Dede C., Walker M. // *AI & Society*. – 2022. – Vol. 39, is. 2. – P. 633–643.

6. Artificial intelligence in education: A systematic literature review / Wang S., Wang F., Zhu Z. et al. // *Expert Systems with Applications*. – 2024. – Vol. 252, is. PA. – P. 124167.

7. Behaviorism, cognitivism, constructivism: Comparing critical features from an instructional design perspective / Ertmer P. A., Newby T. J. //

3. Застосування методів, перевірених у таких симуляційних середовищах у реальних клінічних умовах із одночасним наглядом клініцистів, дозволить вирішити проблеми вибору алгоритмів.

Performance Improvement Quarterly. – 1993. – Vol. 6, no. 4. – P. 50–72.

8. Feature selection using principal component analysis / Song F., Guo Z., Mei D. // *Proceedings of the 2010 International Conference on System Science: Engineering Design and Manufacturing Informatization*, Yichang, 12–14 November 2010 / Yichang, China, 2010. – P. 27–30.

9. SENS: Network analytics to combine social and cognitive perspectives of collaborative learning / Gasevic D., Joksimovic S., Eagan B. et al. // *Computers in Human Behavior*. – 2019. – Vol. 92. – P. 562–577.

10. Detecting learning strategies with analytics: Links with self-reported measures and academic performance / Gasevic D., Jovanovic J., Pardo A. et al. // *Journal of Learning Analytics*. – 2017. – Vol. 4, no. 2. – P. 113–128.

11. Robust sparse linear discriminant analysis / Wen J., Fang X., Cui J. et al. // *IEEE Transactions on Circuits and Systems for Video Technology*. – 2018. – Vol. 29, is. 2. – P. 390–403.

12. Reinforcement Learning for Clinical Applications / Khezeli K., Siegel S., Shickel B. et al. // *Clinical Journal of the American Society of Nephrology*. – 2023. – Vol. 18, no. 4. – P. 521–523.

13. Reinforcement learning in healthcare: a survey / Yu C., Liu J., Nemati S. et al. // *ACM Computing Surveys*. – 2021. – Vol. 55, is. 1. – P. 1–36.

14. Reinforcement learning for intelligent healthcare applications: a survey / Coronato A., Naeem M., De Pietro G. et al. // *Artificial Intelligence in Medicine*. – 2020. – Vol. 109. – P. 101964.
15. Reinforcement learning in surgery / Datta S., Li Y., Ruppert M. M. et al. // *Surgery*. – 2021. – Vol. 170, is. 1. – P. 329–332.
16. Decision analysis and reinforcement learning in surgical decision-making / Loftus T. J., Filiberto A. C., Li Y. et al. // *Surgery*. – 2020. – Vol. 168, is. 2. – P. 253–266.
17. Multiple-Instance Learning for Medical Image and Video Analysis / Quellec G., Cazuguel G., Cochener B. et al. // *IEEE Reviews in Biomedical Engineering*. – 2017. – Vol. 10. – P. 213–234.
18. Extracting the nonlinear features of motor imagery EEG using parametric t-SNE / Li M. A., Luo X. Y., Yang J. F. // *Neurocomputing*. – 2016. – Vol. 218. – P. 371–381.
19. Discriminant autoencoder for feature extraction in fault diagnosis / Luo X., Li X., Wang Z. et al. // *Chemometrics and Intelligent Laboratory Systems*. – 2019. – Vol. 192. – P. 103814.
20. Learning designs and learning analytics / Lockyer L., Dawson S. // *LAK'11: Proceedings of the 1st International Conference on Learning Analytics and Knowledge*, Canada, February 27 – March 01 2011 / Canada, 2011. – P. 153–156.
21. The future of AI and education: Some cautionary notes / Selwyn N. // *European Journal of Education*. – 2022. – Vol. 57, is. 4. – P. 620–631.
22. Large language models are human-level prompt engineers / Zhou Y., Muresanu A., Han Z. et al. – 2022. – URL: <https://arxiv.org/abs/2211.01910>.
23. Robust sparse linear discriminant analysis / Wen J., Fang X., Cui J. et al. // *IEEE Transactions on Circuits and Systems for Video Technology*. – 2018. – Vol. 29, is. 2. – P. 390–403.

References.

1. Gibson, D., Kovanovic, V., Ifenthaler, D., Dexter, S., Feng, S. (2023). Learning theories for artificial intelligence promoting learning processes. *British Journal of Educational Technology*, 54(5), 1125–1146. DOI: 10.1111/bjet.13341.
2. Cheung, B., Terekhov, A., Chen, Y., Agrawal, P., Olshausen, B. (2019). Superposition of many models into one. *Advances in Neural Information Processing Systems*, 10867–10876. DOI: 10.48550/arXiv.1902.05522.
3. Cooper, P. A. (1993). Paradigm shifts in designed instruction: From behaviorism to cognitivism to constructivism. *Educational Technology*, 33(5), 12–19.
4. Dawson, S., Poquet, O., Colvin, C., Rogers, T., Pardo, A., Gasevic, D. (2018, March). Rethinking learning analytics adoption through complexity leadership theory. *LAK'18: Proceedings of the 8th International Conference on Learning Analytics and Knowledge*, (p. 236–244). Sydney, New South Wales, Australia. DOI: 10.1145/3170358.3170375.
5. Dieterle, E., Dede, C., Walker, M. (2022). The cyclical ethical effects of using artificial intelligence in education. *AI & Society*, 39(2), 633–643. DOI: 10.1007/s00146-022-01497-w.
6. Wang, S., Wang, F., Zhu, Z., Wang, J., Tran, T., Du, Z. (2024). Artificial intelligence in education: A systematic literature review. *Expert Systems with Applications*, 252 (PA), 124167. DOI: 10.1016/j.eswa.2024.124167.
7. Ertmer, P. A., Newby, T. J. (1993). Behaviorism, cognitivism, constructivism: Comparing critical features from an instructional design perspective. *Performance Improvement Quarterly*, 6(4), 50–72. DOI: 10.1111/j.1937-8327.1993.tb00605.x.

8. Song, F., Guo, Z., Mei, D. (2010, November). Feature selection using principal component analysis. *Proceedings of the 2010 International Conference on System Science: Engineering Design and Manufacturing Informatization*, (p. 27–30). Yichang, China. DOI: 10.1109/ICSEM.2010.14.
9. Gasevic, D., Joksimovic, S., Eagan, B. R., Shaffer, D. W. (2019). SENS: Network analytics to combine social and cognitive perspectives of collaborative learning. *Computers in Human Behavior*, 92, 562–577. DOI: 10.1016/j.chb.2018.07.003.
10. Gasevic, D., Jovanovic, J., Pardo, A., Dawson, S. (2017). Detecting learning strategies with analytics: Links with self-reported measures and academic performance. *Journal of Learning Analytics*, 4(2), 113–128. DOI: 10.18608/jla.2017.42.10.
11. Wen, J., Fang, X., Cui, J., Fei, L., Yan, K., Chen, Y., Xu, Y. (2018). Robust sparse linear discriminant analysis. *IEEE Transactions on Circuits and Systems for Video Technology*, 29(2), 390–403. DOI: 10.1109/TCSVT.2018.2799214.
12. Khezeli, K., Siegel, S., Shickel, B., Ozrazgat-Baslanti, T., Bihorac, A., Rashidi, P. (2023). Reinforcement Learning for Clinical Applications. *Clinical Journal of the American Society of Nephrology*, 18(4), 521–523. DOI: 10.2215/CJN.0000000000000084.
13. Yu, C., Liu, J., Nemati, S., Yin, G. (2021). Reinforcement learning in healthcare: a survey. *ACM Computing Surveys*, 55(1), 1–36. DOI: 10.1145/3477600.
14. Coronato, A., Naeem, M., De Pietro, G., Paragliola, G. (2020). Reinforcement learning for intelligent healthcare applications: a survey. *Artificial Intelligence in Medicine*, 109, 101964. DOI: 10.1016/j.artmed.2020.101964.
15. Datta, S., Li, Y., Ruppert, M. M., Ren, Y., Shickel, B., Ozrazgat-Baslanti, T., Rashidi, P., Bihorac, A. (2021). Reinforcement learning in surgery. *Surgery*, 170(1), 329–332. DOI: 10.1016/j.surg.2020.11.040.
16. Loftus, T. J., Filiberto, A. C., Li, Y., Balch, J., Cook, A. C., Tighe, P. J., Efron, P. A., Upchurch Jr., G. R., Rashidi, P., Li, X., Bihorac, A. (2020). Decision analysis and reinforcement learning in surgical decision-making. *Surgery*, 168(2), 253–266. DOI: 10.1016/j.surg.2020.04.049.
17. Quellec, G., Cazuguel, G., Cochener, B., Lamard, M. (2017). Multiple-Instance Learning for Medical Image and Video Analysis. *IEEE Reviews in Biomedical Engineering*, 10, 213–234. DOI: 10.1109/RBME.2017.2651164.
18. Li, M. A., Luo, X. Y., Yang, J. F. (2016). Extracting the nonlinear features of motor imagery EEG using parametric t-SNE. *Neurocomputing*, 218, 371–381. DOI: 10.1016/j.neucom.2016.08.083.
19. Luo, X., Li, X., Wang, Z., Liang, J. (2019). Discriminant autoencoder for feature extraction in fault diagnosis. *Chemometrics and Intelligent Laboratory Systems*, 192, 103814. DOI: 10.1016/j.chemolab.2019.103814.
20. Lockyer, L., Dawson, S. (2011, February 27 – March 01). Learning designs and learning analytics. *LAK'11: Proceedings of the 1st International Conference on Learning Analytics and Knowledge*, (p. 153–156). Canada. DOI: 10.1145/2090116.2090140.
21. Selwyn, N. (2022). The future of AI and education: Some cautionary notes. *European Journal of Education*, 57(4), 620–631. DOI: 10.1111/EJED.12532.
22. Zhou, Y., Muresanu, A., Han, Z., Paster, K., Pitis, S., Chan, H., Ba, J. (2022). Large language models are human-level prompt engineers. URL: <https://arxiv.org/abs/2211.01910>. DOI: 10.48550/arXiv.2211.01910.

23. Wen, J., Fang, X., Cui, J., Fei, L., Yan, K., Chen, Y., Xu, Y. (2018). Robust sparse linear discriminant analysis. *IEEE Transactions on Circuits and Systems for Video Technology*, 29(2), 390–403. DOI: 10.1109/TCSVT.2018.2799214.

ORCID:

Ozar P. Mintser: 0000-0002-7224-4886