

Оптимізація корпоративного навчання: Використання лінійних моделей і нейронних мереж

Любомудрова Надія Петрівна¹, Ямщиков Ігор Ігорович²

Опубліковано	Секція	УДК
06.09.2024	Економіка	005.95:004.8

DOI: <https://doi.org/10.5281/zenodo.13709942>

Анотація. Робота присвячена питанням ефективності навчання персоналу в організаціях та ролі машинного навчання в цьому процесі. В статті приділяється особлива увага аналізу наявних алгоритмів машинного навчання, розглядаються особливості їх застосування. В статті проведено огляд лінійних моделей для класифікації та регресії, а також ролі кореляції в аналізі даних. На основі проаналізованого матеріалу визначається доцільність використання розглянутих моделей машинного навчання у контексті навчання та розвитку персоналу. У статті підкреслюється важливість інтеграції розглянутих моделей з більш складними методами машинного навчання для покращення ефективності навчальних програм для працівників організації з метою оптимізації та покращення навчальних процесів у корпоративному середовищі.

Ключові слова: ефективність навчання, машинне навчання, лінійні моделі, нейронні мережі, класифікація, регресія, аналіз даних, продуктивність працівників, індивідуалізація навчання, корпоративне навчання, оцінка ефективності.

Optimization of Corporate Training: Utilizing Linear Models and Neural Networks

Annotation. This work is dedicated to the issues of personnel training efficiency in organizations and the role of machine learning in this process. The article pays special attention to the analysis of existing machine learning algorithms, examining their application features. The paper provides an overview of linear models for classification and regression, as well as the role of correlation in data analysis. Based on the analyzed material, the appropriateness of using the discussed machine learning models in the context of personnel training and development is determined. The article emphasizes the importance of integrating the reviewed models with more complex machine learning methods to improve the effectiveness of training programs for employees, aiming to optimize and enhance training processes in the corporate environment.

Keywords: efficiency of training, machine learning, linear models, neural networks, classification, regression, data analysis, employee productivity, personalized training, corporate training, effectiveness assessment.

¹ Любомудрова Надія Петрівна, к.е.н, доцент, доцент кафедри менеджменту персоналу та адміністрування, НУ «Львівська політехніка», ORCID: <https://orcid.org/0000-0002-1982-0442>

² Ямщиков Ігор Ігорович, аспірант кафедри менеджменту персоналу та адміністрування, НУ «Львівська політехніка» ORCID: <https://orcid.org/0009-0005-7366-8129>

Вступ

Питання ефективності навчання персоналу є критично важливим для будь-якої організації, оскільки завдяки ефективному навчанню персоналу можна досягти підвищення продуктивності працівників, розвинути їхні навички та компетенції, покращити конкурентоспроможність організації. Крім цього навчання персоналу потрібне для того, щоб відповідати певним регулятивним вимогам чи стандартам. Ці та інші фактори роблять навчання персоналу надзвичайно важливим елементом діяльності організацій, незалежно від галузі. Окрема увага приділяється методам оцінки ефективності навчання персоналу.

Дослідженням щодо використання машинного навчання присвячено багато наукових робіт серед зарубіжних та вітчизняних науковців. Серед зарубіжних напрацювань варто відзначити роботи таких науковців як Шай Шалев-Шварц та Шай Бен-Давид, які широко розкривають принципи роботи машинного навчання, розглядають деталі алгоритмів та реалізації моделей машинного навчання. [1] Крістофер М. Бішоп у своїх працях приділяє увагу завдання з визначення шаблонів за допомогою машинного навчання. [2] Застосування новітніх технологій, а також проблеми та рішення для завдань з оцінки роботи персоналу також широко досліджувались такими вітчизняними науковцями, як наприклад Балановська Т. І., Михайліченко М. В., Троян А. В. [3] Питання вибору та застосування популярних алгоритмів реалізації машинного навчання в контексті навчання та оцінювання персоналу потребують додаткових досліджень, для ефективного вибору наявних інструментів та їх застосування в процесі розвитку працівників в організаціях різних рівнів.

Метою статті є здійснити огляд та аналітичне дослідження наявних алгоритмів машинного навчання з акцентом на вивченні їхніх архітектурних особливостей та механізмів функціонування. Крім цього, одним із завдань даної статті є визначення доцільності застосування проаналізованих моделей для професійного корпоративного навчання персоналу.

Результати

Щоб зрозуміти потенціал машинного навчання, необхідно порівняти його з традиційним програмуванням. Під час розробки комп'ютерної програми програмісти визначають кожен крок та правила для кожного рішення. Проблема такого підходу полягає в тому, що він часто бракує гнучкості. Подібно до бюрократії, він буде надто спрощеним та жорстким. Машинне навчання — це загальний термін для багатьох різних методів, які застосовують спільний підхід. Методи машинного навчання використовують навчальні дані, які складаються з багатьох прикладів завдань, зазвичай минулих прикладів. Потім вони шукають закономірності в цих даних. Як приклад, алгоритм, розроблений на основі машинного навчання для передбачення плину кадрів, буде використовувати дані з минулого, аби виявляти шаблони поведінки у групах працівників, які залишили компанію. [4]

Для кращого розуміння переваг і недоліків машинного навчання розглянемо порівняльну таблицю, яка ілюструє, як моделі машинного навчання працюють у порівнянні з людськими можливостями.

Аналізуючи дані подані у Таблиці 1, можемо зробити такі висновки: люди володіють здоровим глуздом, емоційним інтелектом та здатністю до співчуття, що дозволяє їм ефективно спілкуватися та адаптуватися до змін. Водночас людські рішення можуть бути обтяжені інтуїтивними відчуттями, упередженнями та обмеженою здатністю до обробки великої кількості інформації.

Таблиця 1

Порівняльний аналіз принципів роботи машинного навчання та людських можливостей

Людина	Модель штучного інтелекту
Принципи сприйняття світу	
Може робити обґрунтовані припущення в нових ситуаціях	Приймає рішення, ґрунтуючись на навчальних даних, а не на припущеннях
Керується “здоровим глуздом”	Може виявляти закономірності, які люди не помічають
Краще розуміє причинно-наслідкові зв'язки	Не завжди працюватиме ефективно в контекстах, які відрізняються від даних, на яких було проведено навчання
Має здатність розпізнавати зміни умов або особливі випадки	Може мати труднощі з незвичайними випадками, які не представлені в навчальних даних
Надмірна залежність від інтуїтивних відчуттів та припущень	Обмежені розглядом вхідних даних, визначених в алгоритмі
Швидкість/об'єм інформації	
Обмежена швидкість, обмежений об'єм порівняно з ШІ	Після навчання має великий потенціал для швидкості та масштабування
Обмежена кількістю факторів, які може враховувати	Може потенційно враховувати велику кількість факторів
Людський фактор	
Здатні до співчуття та емоційного інтелекту	Може надавати відгуки, які людям було б важко висловити
Можуть спілкуватися з тактовністю	Люди можуть не довіряти, можуть сприймати процес як знелюднення
Можливе несвідоме упередження та надання переваги людям, схожим на себе	Може створювати ілюзію об'єктивності, насправді посилюючи людські упередження
Відповідальність, підзвітність та прозорість рішень	
Може нести відповідальність за прийняті рішення	Може забезпечувати послідовність процесів та рішень
Рішення часто не мають добре обґрунтованого пояснення	Створює документацію/письмові свідчення рішення (навіть якщо вони важкі для розуміння)
Можливі Схильний прояви корупції або особистого збагачення	Не несе відповідальність/підзвітності
Може містити упередженість та фаворитизм	Може бути складно надати зрозуміле обґрунтування рішення

Джерело: розроблено авторами на основі джерела [4]

Моделі штучного інтелекту, з іншого боку, засновані на аналізі навчальних даних та здатні обробляти значно більший обсяг інформації з високою швидкістю. Вони

можуть виявляти складні закономірності та взаємозв'язки, недоступні для людського сприйняття. Однак штучний інтелект обмежений даними, на яких було здійснено навчання, та може мати труднощі з адаптацією до нових або незвичайних ситуацій. Часом моделі штучного інтелекту хоч і створюють ілюзію об'єктивності, вони також схильні посилювати існуючі людські упередження.

Для того щоб зрозуміти чи доцільно застосовувати лінійні моделі машинного навчання та нейромережі в контексті навчання персоналу, ми розглянемо основні принципи роботи цих інструментів.

Лінійні моделі. Найбільш популярним методом застосування лінійних моделей машинного навчання є їх використання для класифікації певних класів, ми розглянемо саме такий варіант застосування лінійних моделей, оскільки в контексті навчання персоналу класифікація є досить важливим завданням. Завдання класифікації полягає в тому, щоб класифікувати вхідний вектор x і віднести його до одного з K окремих класів C_k , такого де $k = 1, \dots, K$. Зазвичай припускається, що кожен вхідний елемент належить лише одному класу. В результаті, простір вхідних даних розділяється на зони прийняття рішень, границі між якими називають межами або поверхнями рішень. Ми розглянемо на лінійні моделі класифікації, що означає, що поверхні рішень є лінійно залежними від вхідного вектора x і визначені через $(D - 1)$ вимірні гіперплощини в просторі вхідних даних з розмірністю D . Набори даних, де класи можна чітко розділити за допомогою лінійних границь рішень, вважаються лінійно роздільними. [1]

Коли ми використовуємо лінійну регресію для передбачення результатів, ми користуємось двома основними твердженнями.

Віддільність та адитивність: Якщо існують різні фактори, що впливають на наші прогнози, ми формуємо наші висновки, сумуючи вплив кожного фактора, ніби кожен з них діє окремо. Наприклад, якщо встановлено, що люди, які працюють у компанії з кожним роком покращують ефективність на 1%, а люди що пройшли курси підвищення кваліфікації працюють на 2% краще за інших тоді очікуватиметься, що працівник який працює в компанії 1 рік та пройшов курси підвищення кваліфікації працюватиме на 3% краще порівняно з людиною, котру щойно найняли на роботу. Припущення про те, що ефекти кожного фактору в ізоляції підсумовуються, коли вони відбуваються разом, є значним, але воно слугує хорошою відправною точкою для багатьох застосувань регресії.

Монотонність та лінійність: Модель вважається монотонною, коли будь-яка зміна вхідного параметра незмінно призводить до збільшення або зменшення передбачуваного результату. Наприклад, припустимо, що ви прогнозуєте вагу людини, використовуючи її зріст як вхідний параметр, і ваша модель монотонна, тоді кожне збільшення зросту призведе до зростання прогнозованої ваги. Монотонність є сильним припущенням, оскільки існує багато ситуацій, коли результат спочатку зростає зі збільшенням вхідного параметра, а потім починає знижуватися. Однак припущення монотонності є менш строгим, ніж повне припущення лінійної регресії, яке називається лінійністю. Лінійність означає, що на графіку взаємозв'язку вхідних даних і результатів ви побачите пряму лінію, а не щось більш складне, наприклад криву. Це також означає, що зміна вхідного параметра на одиницю завжди призводить до збільшення або зменшення виходу на фіксовану кількість одиниць N . Кожна лінійна модель задовольняє умови монотонності, проте не кожна монотонна крива є лінійною. Тому лінійність накладає більш жорсткі обмеження, ніж проста монотонність. [5]

Лінійні регресії часто використовуються разом з кореляцією. У найточнішому визначенні, дві змінні вважаються корельованими, якщо їхній зв'язок може бути представлений у вигляді прямої лінії. Тобто, кореляція — це оцінка того, наскільки адекватно лінійна регресія може описати взаємозв'язок між двома змінними. Кореляція 0 свідчить про відсутність виразного лінійного зв'язку між змінними. Кореляція 1

означає наявність ідеальної позитивної прямої лінії, що пов'язує дві змінні. Водночас кореляція -1 показує, що існує ідеально негативна пряма лінія, зв'язуючи між собою дві змінні. [5]

Розглянемо приклад, де ми хочемо встановити кореляцію між двома масивами даних. Припустимо, у нас є наступні масиви:

Години навчання працівника (X): [2,4,6,8,10]. Оцінки ефективності виконання роботи (Y): [5,7,7,8,10]. Якщо ми хочемо дізнатися, чи існує кореляція між кількістю годин, витрачених на навчання, та ефективністю виконання роботи, то виконати наступні дії:

Обчислення середніх значень: Розраховуємо середнє значення для кожного масиву даних. Для X середнє значення $(2 + 4 + 6 + 8 + 10)/5 = 6$. Для Y середнє значення $(5 + 7 + 7 + 8 + 10)/5 = 7,4$.

Обчислення відхилень від середнього: Для кожного значення у масивах X і Y розраховуємо його відхилення від відповідного середнього значення в результаті чого отримаємо $X = [-4, -2, 0, 2, 4]$, $Y = [-2.4, -0.4, 0.4, 0.59, 2.59]$.

Обчислення коефіцієнту кореляції: Використовуємо формулу Пірсона для обчислення коефіцієнту кореляції між X і Y . Коефіцієнт кореляції розраховується як сума добутків відхилень кожної пари значень X і Y , поділена на добуток стандартних відхилень X і Y , помножене на кількість спостережень. Це дає нам міру лінійної залежності між X і Y .

Розрахуємо сума добутків $XY = [9.6, 0.8, 0, 1.19, 10.39]$.

Наступним кроком обчислюємо квадрати відхилень, отримаємо [16, 4, 0, 4, 16] та [5.76, 0.16, 0.16, 0.35, 6.75] відповідно.

Коефіцієнт кореляції розраховується діленням суми добутку відхилень на добуток сум квадратів відхилень. В результаті отримуємо коефіцієнт кореляції 0.9574. [5]

Інтерпретація результату: Коефіцієнт кореляції може варіюватися від -1 до 1 . Чим ближче значення до 1 або -1 , тим сильніше лінійна залежність. Якщо коефіцієнт близький до 0 , це означає, що між змінними немає значущої лінійної залежності. У нашому прикладі існує висока лінійна залежність між змінними у масивах, проте лінійна залежність не обов'язково відображає нелінійні взаємозв'язки. Якщо залежність між змінними нелінійна, лінійний коефіцієнт кореляції може не відображати повної картини взаємодії. Висока кореляція повинна бути оцінена у контексті статистичної значимості, щоб визначити, чи є спостережувана кореляція випадковою. Статистичні тести, такі як t -тест для коефіцієнта кореляції, можуть допомогти встановити, чи є кореляція значимою. [5]

Лінійна класифікація має ряд переваг, таких як простота та легкість інтерпретації, однак вона також стикається з кількома обмеженнями та проблемами, зокрема вона може бути неефективною для наборів даних, які мають нелінійні відносини. Лінійні класифікатори припускають, що межі між класами можна описати за допомогою прямої лінії, що не завжди є випадком в реальних даних. Лінійні класифікатори чутливі до викидів у даних, тобто до екстремальних значень, які відрізняються від інших спостережень. Викиди можуть значно вплинути на розташування рішучої межі, що призводить до неправильної класифікації.

Нейронні мережі. Штучна нейронна мережа представляє собою обчислювальну модель, яка була розроблена під впливом структури мозкових нейронних мереж. Вона містить численні базові елементи обчислення (нейрони), які утворюють складну мережу комунікацій, дозволяючи мозку здійснювати складні обчислювальні процеси. Ці штучні нейронні мережі створюються як точні обчислювальні структури, які імітують вказаний обчислювальний підхід. Застосування нейронних мереж для освітніх цілей почалося в середині ХХ століття і демонструє високу ефективність навчання, досягаючи лідируючих позицій у різноманітних навчальних завданнях останнім часом. Штучну

нейронну мережу можна представити у формі спрямованого графа, де вузли являють собою нейрони, а зв'язки між ними — це ребра графа. Кожен нейрон на вході обробляє зважену суму вихідних сигналів нейронів, з якими він пов'язаний вхідними зв'язками. [2]

Ідея, що лежить в основі нейронних мереж, полягає в тому, що багато нейронів можуть бути з'єднані між собою комунікаційними зв'язками для виконання складних обчислень. Зазвичай структуру нейронної мережі описують як граф, вузли якого є нейронами, а кожне спрямоване ребро у графі з'єднує вихід одного нейрону з входом іншого нейрону. Ми зосередимо нашу увагу на структурах прямопрямованих мереж, де базовий граф не містить циклів. Складність інтерпретації результатів: Нейронні мережі часто називають "чорними скриньками" через їхню складність та відсутність прозорості у тому, як саме модель приймає рішення. Це може ускладнити розуміння та аналіз результатів навчання, а також перевірку коректності роботи моделі. Висока вимогливість до даних: Для ефективного навчання нейронних мереж потрібні великі обсяги даних. У контексті навчання персоналу може виникнути проблема з недостатньою кількістю релевантних даних для тренування моделі. Час та витрати на навчання: Навчання нейронних мереж може бути часомістким та вимагати значних обчислювальних ресурсів. Це може стати проблемою для організацій з обмеженими ресурсами або для ситуацій, де швидкість впровадження є критичною. Також існує ризик, що модель "навчиться" шуму у даних, а не загальним тенденціям, що може призвести до поганих результатів при застосуванні моделі на нових даних. У контексті навчання персоналу це може означати, що модель буде ефективною лише для конкретної групи співробітників, на даних яких вона навчалася. [1]

Висновки

Аналізуючи лінійні моделі класифікації в контексті навчання персоналу та оцінки результатів такого навчання, ми приходимо до висновку, що хоча ці моделі можуть здаватися занадто простими інструментами для розгляду складних взаємозв'язків, вони все ж таки надають цінний вступ до аналізу даних. Лінійні моделі дозволяють нам виявити основні тенденції та залежності, що існують між різними параметрами навчання та їхнім впливом на продуктивність співробітників. Використання кореляції разом із лінійною регресією розширює наші можливості аналізу, дозволяючи кількісно оцінити силу та напрямок лінійних залежностей між змінними. Це в свою чергу, може сприяти кращому розумінню того, як різні аспекти навчального процесу впливають на ефективність персоналу. Проте, як було зауважено, кореляція сама по собі не може слугувати остаточним доказом причинно-наслідкових зв'язків, що підкреслює необхідність подальшого статистичного аналізу та валідації виявлених залежностей. Важливо розуміти, що лінійні моделі та кореляція можуть виявити існуючі залежності в наборі даних, але для більш глибокого розуміння цих залежностей та врахування нелінійностей і взаємодій між змінними може знадобитись використання складніших методів машинного навчання. Це може допомогти в формуванні тренувальних даних для більш складних моделей, які здатні забезпечити вищу точність прогнозування та індивідуалізації навчальних підходів. Отже, хоча лінійні моделі та кореляційний аналіз можуть не бути ідеальними для всебічного розуміння всіх аспектів навчання персоналу, вони слугують важливим вступом до аналізу даних і надають основу для подальших досліджень. Використання отриманих даних для подальшої валідації за допомогою статистичних методів або інших технік аналізу дозволить отримати більш точні та надійні висновки. Глибокий аналіз даних є критично важливим для розробки ефективних стратегій навчання та розвитку персоналу, які враховують унікальні потреби та характеристики кожного співробітника. В кінцевому підсумку, інтеграція лінійних моделей з більш складними методами машинного навчання та аналізу даних

відкриває нові горизонти для підвищення ефективності навчальних програм. Використання цих інструментів дозволяє не лише визначити ключові фактори, що впливають на продуктивність персоналу, але й адаптувати навчальні підходи для задоволення індивідуальних освітніх потреб та стилів навчання. Таким чином, можливо не тільки збільшити загальну ефективність навчання, але й сприяти більшій задоволеності та мотивації співробітників. З огляду на виклики, пов'язані з застосуванням лінійних моделей, такі як обмежена здатність моделювати складні взаємозв'язки та чутливість до вкидів тестових даних, стає очевидним, що ретельний вибір інструментів аналізу та валідації є ключовим для успішної реалізації стратегій навчання. Водночас, підкреслюючи значення статистичної значимості та потребу в подальшій валідації знахідок, ми можемо забезпечити, що висновки, до яких ми приходимо на основі аналізу даних, будуть надійними та доречними.

Ми можемо побачити, що, хоча нейронні мережі є потужним інструментом для обробки та аналізу даних, вони водночас мають низку складнощів у реалізації та потенційні недоліки, які можуть обмежувати їхню ефективність у деяких сценаріях навчання персоналу. Серед основних викликів варто виділити складність інтерпретації рішень моделі, високі вимоги до обсягів та якості навчальних даних, значні час та ресурси, необхідні для навчання моделей, а також ризик перенавчання моделі на специфічних даних. Тим не менш, можливості застосування нейронних мереж для створення більш ефективних систем автоматизації рекомендацій, заснованих на результатах навчання, відкривають перспективні шляхи для подальших досліджень. Такий підхід потребуватиме від нас розробки та використання нормалізованого набору даних, який можна було б ефективно використовувати для тренування та валідації нейронної мережі. Важливо розуміти, що незважаючи на потенційні перешкоди, інтеграція штучного інтелекту та нейронних мереж у процеси навчання та розвитку персоналу може принести значну користь, підвищуючи якість та індивідуалізацію навчальних програм. Таким чином, подальші дослідження та експерименти в цій області можуть виявити нові можливості для оптимізації навчальних процесів у корпоративному середовищі.

Список використаних джерел

1. Ben-David S., Shalev-Shwartz S. Understanding Machine Learning: From Theory to Algorithms From Theory to Algorithms. *Cambridge University Press*, 2014
2. Bishop C. M. Pattern Recognition and Machine Learning. *Springer Science+Business Media, LLC*, 2006
3. Балановська Т. І., Михайліченко М. В., Троян А. В. Сучасні технології управління персоналом. *ФОП Ямчинський О.В.*, 2020.
4. Human-Centred Artificial Intelligence for Human Resources – офіційний сайт World Economic Forum. URL: <https://www.weforum.org/publications/human-centred-ai-for-hr-state-of-play-and-the-path-ahead/toolkit/>
5. Conway D., White J.M. Machine Learning for Hackers. *O'Reilly Media, Inc.*, 2012