

ДОДАТОК А

Слайди презентації




Рисунок А.1 – Слайд 1




Рисунок А.2 – Слайд 2

Постановка завдань дослідження

аналіз та підготовка даних шляху кліків

реалізація обраних алгоритмів для прогнозування дій користувача та їх тестування на підготовлених наборах даних

дослідження результатів роботи та підведення підсумків

реалізація програмного забезпечення для ілюстрації результатів дослідження.

Рисунок А.3 – Слайд 3

Зростання користувачів Internet





Рисунок А.4 – Слайд 4

kaggle									
Q Search									
Data Kernels Discussion Activity Metadata Settings									
(Download 0 MB) New Thread									
data_id	IP	timestamp	IP	event_type	IP	data_id	IP	page_text	additional_info
1987		1301942772	309	2274		1st Player: Raymond Kt (color: 300) Black			
2363		1301942819	CHIT_F12N	2254		0.9x11 3004-3009 123456 010-3009			
1989		1301943086	CHIT_F12N	4071		ATP info: Mats Black-Red 100-01000- 801			
6942		1301943601	309	8680		Implicit Motives 70 and 300 30			
1989		1301943755	FWG_F12N	5056		Курсовые работы по ФП 0010-0-0 Зачет 3000			AMC
6189		1301943272	309	9420		кармачки vs F100 300 3000			
2001		1301943347	FWG_F12N	5367		Зачет Портфолио 100 0-100 300 3-1 Type-C 0-1000 0-1 0-0			-
1989		1301943363	FWG_F12N	2315		тестов 3004-3005 01000 010-3100			-
6058		1301943428	FWG_F12N	7340		2nd-0 00-0010 00101 0000 2 0 001012 00 000 0-1			
6842		1301943602	CHIT_F12N	8615		Зачет ФП 0010-0-100 00100 0-000			AMC

Рисунок А.5 – Слайд 5

Нейронна мережа та нейрон



Нейрон – елемент нейронної мережі, зазвичай являє собою функцію від одного аргументу. Цю функцію називають ф-цією активації.

Рисунок А.6 – Слайд 6

Автокодувальники




Рисунок А.7 – Слайд 7

Функція втрат

$$E(t, z) = \frac{1}{2}(t - z)^2$$

де t – оригінальні вхідні дані, а z – результат роботи автоенкодера

Рисунок А.8 – Слайд 8




Рисунок А.9 – Слайд 9




Рисунок А.10 – Слайд 10

Показник AUC при навчанні за допомогою DBN та за допомогою DBN + SdA

Набір	DBN	DBN + SdA
Набір 3	0.82	0.83
Набір 6	0.84	0.86

Рисунок А.11 – Слайд 11

Програмна реалізація

Для відображення результатів дослідження було прийнято розробити прототип програмної системи. Програмна система виконує функції рекомендації товару в інтернет-магазині базуючись на минулих інтересах користувача отриманих через дані шляху.

Рисунок А.12 – Слайд 12



Рисунок А.13 – Слайд 13




Рисунок А.14 – Слайд 14

Апробація результатів роботи

ПІДТВЕРДЖЕННЯ ПРО УЧАСТЬ У МІЖНАРОДНІЙ НАУКОВО-ПРАКТИЧНІЙ КОНФЕРЕНЦІЇ ТА ПУБЛІКАЦІЮ НАУКОВОЇ РОБОТИ

Організаційний комітет міжнародної мультидисциплінарної науково-практичної конференції «Public communication in science: philosophical, cultural, political, economic and IT context», яка відбудеться 15 травня 2020 року у м. Х'юстон (USA), зареєстрував заяву на участь у заході.

Наукова робота, подана для публікації в рамках участі, відповідає усім встановленим вимогам, успішно пройшла оглядове рецензування та буде надрукована в збірнику наукових праць «LOGOS» за матеріалами конференції.

Відомості про роботу:

Автор(-и) роботи	Дорошенко Олександр Вадимович
Науковий керівник	Лановий О.Ф.
Секційний напрям	Технічні науки та інформаційні технології
Назва роботи	ДОСЛІДЖЕННЯ НЕЙРОМЕРЕЖЕВОГО ПІДХОДУ ДЛЯ ПРОГНОЗУВАННЯ ПОВЕДІНКИ КОРИСТУВАЧІВ У WEB СИСТЕМАХ
Результати рецензування	успішно пройшла рецензування
Поточний статус	прийнята до публікації

Рисунок А.15 – Слайд 15

Висновки

У цій роботі ми застосовуємо різні алгоритми машинного навчання, а саме глибинні мережі переконань (DBN) та автоенкодери (SdA) для навчання повно зв'язної, динамічної, багатопшарової нейронної мережі. Дослідження показало що використання stacked denoising autoencoders для тренування перед використанням deep belief network покращило показник AUC в порівнянні з нейронною мережею коли було використано тільки алгоритм DBN для навчання.

Рисунок А.16 – Слайд 16

ДОДАТОК Б

Апробація результатів атестаційної роботи

ΛΟΓΟΣ

Σ

THE ART OF SCIENTIFIC MIND

COLLECTION OF SCIENTIFIC PAPERS

WITH PROCEEDINGS OF THE INTERNATIONAL SCIENTIFIC AND PRACTICAL CONFERENCE

PUBLIC COMMUNICATION IN SCIENCE: PHILOSOPHICAL, CULTURAL, POLITICAL, ECONOMIC AND IT CONTEXT

MAY 15, 2020 • HOUSTON, USA 

VOLUME 2



DOI 10.36074/15.05.2020.v2
ISBN 978-0-208-87341-5

- [2] Галько, С. В., Жарков, В. Я. & Жарков, А. В. (2019). *Технології та засоби перетворення відновлюваних джерел енергії для приватних домогосподарств*. Мелітополь: Люкс. ISBN 978-617-7218-62-2.
- [3] Twidell, J. & Weir, T. (2006). *Renewable Energy Resources*. London & New York: Taylor & Francis.
- [4] Галько, С. В. Експериментальне дослідження і визначення параметрів когенераційного фотоелектричного модуля для гібридних сонячних електростанцій. *Традиційні та інноваційні підходи до наукових досліджень: матеріали Міжнародної наукової конференції*. (Т. 1, с. 83-90). 10 квітня, 2020, Луцьк, Україна: МЦНД. <https://doi.org/10.36074/10.04.2020.v1.10>.
- [5] Вин, Й. & Виссарионов, В. И. (2012). Исследование влияния температуры на характеристики фотоэлектрических преобразователей. *Научно-техническое творчество молодежи – путь к обществу, основанному на знаниях* (с. 486-488). Москва: ВВЦ.
- [6] Джумаев, А. Я. Анализ влияния температуры на рабочий режим фотоэлектрической солнечной станции. *Технические науки – от теории к практике: материалы XLVI Междунар. науч.-практ. конф.* (№ 5 (42)). 27 мая, 2015, Новосибирск: СибАК. Вилучено із <http://sibac.info>.
- [7] Какурина, Н. А., Какурин, Ю. Б., Курсай, Д. Е. & Осипов, Н. А. (2016). Исследование электрофизических характеристик солнечной панели с помощью компьютеризированного измерительного стенда. *Инженерный вестник Дона*, (3). Вилучено із http://idvon.ru/uploads/article/pdf/IVD_37_kakurin_kakurina.pdf_e3a16aeaf8.pdf.
- [8] Галько, С. В. (2019). Використання когенераційних фотоелектричних модулів для зарядки електромобілів. *Праці Таврійського державного агротехнологічного університету*, 19(3), 130-141. <https://doi.org/10.31388/2078-0877-19-3-130-141>.

DOI 10.36074/15.05.2020.v2.24

ДОСЛІДЖЕННЯ НЕЙРОМЕРЕЖЕВОГО ПІДХОДУ ДЛЯ ПРОГНОЗУВАННЯ ПОВЕДІНКИ КОРИСТУВАЧІВ У WEB СИСТЕМАХ

Доротенко Олександр Вадимович

здобувач магістерського ступеня факультету комп'ютерних наук
Харківський національний університет радіоелектроніки

НАУКОВИЙ КЕРІВНИК:

Лановий О.Ф.

канд. тех. наук, доцент, доцент кафедри програмної інженерії
Харківський національний університет радіоелектроніки

УКРАЇНА

Всесвітня мережа (WWW) представляє багато комерційних можливостей, даючи користувачам інформацію для придбання товарів та або послуг. Відстеження поведінки або тенденцій користувачів дозволяє прогнозувати майбутні дії користувачів та можуть забезпечити більше можливостей для отримання користувачем актуальної для нього інформації.

Розуміння поведінки користувачів в Інтернеті викликає все більший інтерес для наукових дослідників у різних сферах. Традиційно, в галузі маркетингу, комерційні дослідницькі компанії вивчають поведінку споживачів, щоб зрозуміти, коли і де клієнти вирішують купувати продукцію. З цією метою веб-метрики окремих веб-сайтів служать докладним джерелом інформації про те, коли, як, якими розділами цікавиться користувач.

Прогнозування наміру користувача щодо певного продукту чи категорії продуктів на основі взаємодії в межах веб-сайту має вирішальне значення для

сайтів електронної комерції та мереж показу реклами. Слідкуючи за моделями пошуку споживачів, інтернет-продавці можуть краще зрозуміти їх поведінку та наміри. А це, в свою чергу, допомагає підвищувати якість послуг які надає бізнес.

Мета в цій роботі полягає у тому щоб розглянути алгоритми класифікації та аналізу даних у сфері аналізу та передбачення дій певних користувачів, класифікації їх з використанням алгоритмів машинного навчання, на основі отриманих результатів провести порівняння та зробити висновок щодо ефективності такого підходу.

Використовувані дані – це навчальна вибірка і вона складається приблизно з 1 мільйона сеансів (шляху кліків), що містять дані про кліки користувачів, проте лише 3% навчальних даних складаються з сеансів покупки – тому це робить даний набір даних дуже незбалансованим.

Шлях кліку або потік кліків – це послідовність гіперпосилань, які один або більше відвідувачів веб-сайту відвідали на певному веб-сайті, подані в порядку перегляду. Шлях натискання відвідувача може починатися на веб-сайті або на окремому веб-сайті третьої сторони, часто на сторінці результатів пошуку, і він продовжується як множина послідовних веб-сторінок, які відвідує користувач. Шлях натискання приймає дані та може порівнювати їх із джерелами оголошень, ключовими словами та / або посилаються доменами, щоб фіксувати дані.

Дані потоку кліків можуть використовуватися для кількісної оцінки поведінки пошуку за допомогою машинного навчання, в основному, зосередженого на записах про покупки.

Дані складаються з півроку записів взаємодії користувачів із веб-сайтом електронної комерції. Події мають ідентифікатор користувача, часову мітку та тип події. Існує 5 категорій подій: перегляд сторінки, перегляд кошика, покупка, перегляд реклами та показ реклами. Існує близько 25 000 різних видів продукції. У разі купівлі чи перегляду у кошику ми маємо інформацію про ціну та додаткові деталі. Ми ігноруємо події показу реклами та її перегляду, оскільки вони не є актуальними для наших цілей. Дані дуже розріджені та великі. Є два очевидних способи зменшити розмірність даних: або згрупувати перегляди сторінок на користувача за період часу (сукупні перегляди сторінок на користувача за період), або згрупувати перегляди сторінок продукту (сукупні продукти, що переглядаються за часові рамки). У цій роботі ми дотримуємось першого підходу, оскільки більшість покупок (~ 87%) відбувається протягом 5 днів із першого відвідування. Навчальна вибірка складається з набору сеансів $s \in S$ і кожен сеанс містить набір елементів $i \in I$, які відображалися користувачеві. Елементи, придбані в сесії s , позначаються B_s . Існує два типи сеансів S_b – сеанси, які закінчуються покупкою, та S_{nb} – сеанси, які не закінчуються покупкою.

Враховуючи набір сеансів S_t , завдання – знайти всі сеанси S_b , які мають принаймні одну подію покупки. Якщо сеанс буде містити подію покупки, ми хочемо передбачити придбані товари. Тому у нас є дві широкі цілі: 1) класифікація та 2) передбачення порядку. У цій роботі ми зупинимось лише на першому завданні. В таблиці 1 наведені шість підготовлених наборів даних з якими і будуть проведені дослідження.

Таблиця 1

Набори даних використанні в дослідженні

Набір	Розмір	Опис
Набір 1	3 000	Покупки згруповані за тиждень
Набір 2	10 000	Набір 1 з більшою кількістю даних
Набір 3	30 000	Набір 1 з більшою кількістю даних

Продовження табл. 1

Набір	Розмір	Опис
Набір 4	10 000	Набір 2, але згрупований за пів тижня
Набір 5	10 000	Набір 1 за 2000 категорій продуктів
Набір 6	30 000	Набір 3 за 2000 категорій продуктів

Ми будемо використовувати непідконтрольний алгоритм навчання для класу глибоких генеративних моделей, званих мережами глибоких переконань (DBN). DBN складається із стеку обмежених машин Больцмана (RBM) [1].. Окремо, ініціалізація ваг MLP з відповідно налаштованим DBN часто дає набагато кращі результати, ніж ті, що мають випадкові ваги. DBN належить до класу моделей на основі енергії. У цьому випадку алгоритм працює наступним чином. Для заданої RBM ми співвідносимо одиниці з енергетичною функцією,

$$Energy(v, h) = -b'h - c'h - h'Wv \quad (1)$$

де b , c – зміщення, а W містить вагові з'єднувальні вузли. Спільна ймовірність видимого (v) та прихованого (h) єдностей, (v, h) дорівнює:

$$P(v, h) = \frac{1}{Z} e^{-Energy(v, h)} \quad (2)$$

де Z – член нормалізації. Вільну форму енергії ми отримуємо, маргіналізуючи h :

$$P(v) = \frac{\sum_h e^{-Energy(v, h)}}{Z} = \frac{e^{-FreeEnergy(v)}}{Z} \quad (3)$$

Користуючись перевагами вільної енергії, це полегшує обчислення градієнтів лише з видимими одиницями. Ми переписуємо енергетичну функцію у форму,

$$Energy(v, h) = -\beta(v) - \sum_i \gamma_i(v, h_i) \quad (4)$$

Тоді ми розкладемо $P(v)$:

$$\begin{aligned} P(v) &= \frac{\sum_h e^{-Energy(v, h)}}{Z} = \frac{e^{-FreeEnergy(v)}}{Z} = \frac{1}{Z} \sum_{h_1} \sum_{h_2} \dots \sum_{h_k} e^{\beta(v) - \sum_i \gamma_i(v, h_i)} = \\ &= \frac{1}{Z} \sum_{h_1} \sum_{h_2} \dots \sum_{h_k} e^{\beta(v)} \prod_i e^{-\gamma_i(v, h_i)} = \frac{e^{\beta(v)}}{Z} \sum_{h_1} e^{-\gamma_1(v, h_1)} \dots \frac{e^{\beta(v)}}{Z} \sum_{h_2} e^{-\gamma_2(v, h_2)} = \\ &= \frac{e^{\beta(v)}}{Z} \prod_i \sum_{h_i} e^{-\gamma_i(v, h_i)} \end{aligned} \quad (5)$$

DBN використовувались для найрізноманітніших проблем, починаючи від розпізнавання зображень, алгоритмів рекомендацій та моделювання тем. Окрім постачання прийнятних точок ініціалізації для багатошарової мережі (див. рис. 1), DBN має й інші привабливі властивості:

- алгоритм навчання дозволяє ефективно використовувати незазначені дані;
- він може бути інтерпретований як імовірнісна генеративна модель;

– проблема переоцінки, яка часто спостерігається в моделях з мільйонами параметрів, таких як DBN, може бути ефективно усунена на етапі генеральної попередньої підготовки.

Мінусом DBN є те, що вони важко навчаються і вони дуже чутливі до таких параметрів навчання, як ініціалізація ваг.




Рис 1. Структура глибокої мережі переконань

Autoencoder (див. рис. 2) – це невідтримувана штучна нейронна мережа, яка вчиться ефективно стискати та кодувати дані, потім навчається реконструювати дані назад із зменшеного кодованого подання до представлення, яке є максимально наближеним до вихідного вводу. Autoencoder, за задумом, зменшує розміри даних, навчившись ігнорувати шум у даних [2].

Автокодувальник – це нейронна мережа з одним прихованим шаром, де вихідний і вхідний шар мають однаковий розмір. Припустимо, що вхід $x \in R_m$ і прихованому шарі є n вузлів. Тоді маємо вагову матрицю $W \in R_m \times n$ та вектори зміщення b і b_0 в R_m і R_n відповідно.




Рис 2. Структура автокодувальника

Нехай $s(x) = 1 / (1 + e^{-x})$ – сигмоїдна (логістична) функція передачі. Тоді ми маємо нейронну мережу, як показано на рисунку 4.2. Використовуючи автокодер для кодування даних, обчислюємо вектор $y = s(Wx + b)$; відповідно, коли ми використовуємо автокодер для декодування та реконструкції назад вхідних даних, обчислюємо $z = s(W^T x + b')$. Вагова матриця стадії декодування – це транспонування вагової матриці стадії кодування з метою зменшення кількості параметрів для вивчення. Ми хочемо оптимізувати W , b і b' так, щоб реконструкція була максимально схожою на початкові вхідні дані стосовно деякої функції втрат. Використана функція втрат – це найменша втрата квадратів:

$$E(t, z) = \frac{1}{2}(t - z)^2 \quad (6)$$

де t – оригінальні вхідні дані. Після тренування автокодера, його етап декодування відміняється, а етап кодування використовується для перетворення прикладів введення тренінгу як етап попередньої обробки. Після того, як пройшов тренінг шару автокодування, другий автокодер може тренуватися, використовуючи вихід першого шару автокодера. Цю процедуру можна повторити нескінченно та створити складені шари автоенкодера довільної глибини. Показано, що кожен наступний натренований шар вчиться кращому розпізнаванню ознак ніж попередній. Використання глибоких нейронних мереж, таких як складені автокодери для розпізнавання ознак також називається глибокими автокодерами – окрема область машинного навчання. Для звичайних автокодерів ми зазвичай хочемо, щоб $n < m$, вивчене існувало в просторі менших розмірів, ніж вхідне. Це робиться для того, щоб автокодер не засвоїв тривіальну трансформацію ідентичності. Варіантом є позначаючи автокодери, які використовують різний критерій реконструкції для вивчення ознак. Це досягається пошкодженням вхідних даних та навчанням автокодера для реконструкції вихідних непошкоджених даних. Навчившись позначати, автокодер змушений зрозуміти справжню структуру вхідних даних і навчитися добре їх уявляти. Під час навчання з критерієм, що позначає, глибокий автокодер є також генеративною моделлю. Хоча функція втрат $E(t, z)$ для нейронних мереж взагалі не випукла, стохастичний градієнтний спуск (SGD) достатній для більшості проблем, і ми використовуємо його в цій роботі.

ROC-крива – графік, що дозволяє оцінити якість бінарної класифікації, відображає співвідношення між часткою об'єктів від загальної кількості носіїв ознаки, вірно класифікованих до загальної кількості об'єктів, що не несуть ознаки, помилково класифікованих, як такі, що мають ознаку. Також відома як крива похибок. Аналіз класифікацій із застосуванням ROC-кривих називається ROC-аналізом. Кількісну інтерпретацію ROC дає показник AUC – площа, обмежена ROC-кривою і віссю частки помилкових позитивних класифікацій. Чим вище показник AUC, тим якісніше діє класифікатор, при цьому значення 0,5 демонструє непридатність обраного методу класифікації (відповідає звичайному вгадуванню).

Для кожного аналізу ми використали випадково 25% даних для використання в якості тестового набору, залишивши решту 75% як навчальний набір. Ми розділили навчальний набір на чотири склади і тренували кожну модель чотири рази з різною складкою, в якості даних валідації. Ми оцінюємо AUC для тестового набору чотирьох моделей, коли отримуємо результати тестових наборів. Ми використали показники моделей на даних валідації, щоб вибрати найкращу конкретну модель у кожному сімействі моделей.

Результати представлені в таблиці 2.

Таблиця 2

Показник AUC для класифікації використанням DBN та SdA методів

Набір	DBN	SdA
Набір 3	0.82	0.83
Набір 6	0.84	0.86

Ми можемо бачити, що мережі, попередньо підготовлені зі stacked denoising autoencoders, досягають найвищої точності, що може бути пов'язано з тим, що у нас дуже рідкий набір даних. Покращення, порівняно з іншими традиційними методами, мало відомі.

Висновки.

У даній роботі були досліджені нейромережеві методи для передбачення дій користувача у WEB-системі. Завдяки проведеній роботі ми переконалися що Stacked Denoising Autoencoders (SdA) показують найбільшу ефективність в даній задачі.

Список використаних джерел:

- [1] Yidong, L. & Yanzhi, W. (2018). "An energy-efficient stochastic computational deep belief network". Вилучено з <https://ieeexplore.ieee.org/document/8342191>
- [2] Qingyang, X., & Yiqin, Y. (2017). "The difference learning of hidden layer between autoencoder and variational autoencoder". Вилучено з <https://ieeexplore.ieee.org/document/7979344>

DOI 10.36074/15.05.2020.v2.25

ЗАГАЛЬНИЙ МЕХАНІЗМ ЕКОНОМІЧНОГО ОЦІНЮВАННЯ ІННОВАЦІЙНОЇ ЕНЕРГОЗБЕРІГАЮЧОЇ ПРОДУКЦІЇ ПІДПРИЄМСТВ МАШИНОБУДУВАННЯ

Зарицька Оксана Леонідівна

канд. екон. наук, доцент кафедри економіки підприємства та інвестицій
Національний університет «Львівська політехніка»

Симак Анастасія Валеріївна

канд. екон. наук, доцент, доцент кафедри економіки підприємства та інвестицій
Національний університет «Львівська політехніка»

Вовк Олена Борисівна

канд. техн. наук, доцент кафедри систем штучного інтелекту
Національний університет «Львівська політехніка»

УКРАЇНА

Одним з головних чинників, які визначають величину фінансових результатів діяльності підприємств, є рівень цін на їх продукцію. Цей рівень повинен бути достатнім для того, щоб покрити понесені підприємствами витрати та, окрім того, забезпечити їх належну прибутковість. При цьому слід враховувати галузеву специфіку виробників продукції. Зокрема, стосовно