

1. Визначити чіткі цілі та завдання
2. Визначити ключові показники та джерела даних
3. Впровадити надійну інфраструктуру даних
4. Обрати правильні інструменти та технології ВІ
5. Виконати аналіз та візуалізацію даних
6. Розвивати культуру прийняття рішень на основі даних
7. Провести моніторинг
8. Налаштувати комунікацію
9. Оцінити результати
10. Постійно вдосконалювати систему показників

Незалежно від того, який процес використовувався, важливо залучати ключові зацікавлені сторони до визначення показників інноваційної діяльності, які керуватимуть організацією в майбутньому.

Вимірювання ключових показників інноваційної діяльності має важливе значення для будь-якої організації, яка прагне процвітати на сучасному динамічному ринку. ВІ-інструменти пропонують надійне рішення для відстеження та аналізу цих показників, що дозволяє організаціям приймати обґрунтовані рішення та стимулювати постійне вдосконалення. Використовуючи інструменти ВІ, компанії можуть переконатися, що їхні інноваційні зусилля ефективні та відповідають їхнім стратегічним цілям.

Література:

1. Inc. 5000 (2024). Meet the Fastest-Growing Private Companies in America. <https://www.inc.com/inc5000>
2. Aase, G., Roth, E., Swaminathan, S. (2018, April 20). Taking the measure of innovation. <https://www.mckinsey.com/capabilities/strategy-and-corporate-finance/our-insights/taking-the-measure-of-innovation>
3. Schlegel, K., Ganeshan, A., Pidsley, D., Sun, J., O'Callaghan, G., Long, C., Quinn, K., Macari, E., Fei, F., O'Brien, J. (2024, June 20). Gartner Magic Quadrant for Analytics and Business Intelligence Platforms. <https://www.gartner.com/en/documents/5519595>

ВИКОРИСТАННЯ МЕТОДІВ МАШИННОГО НАВЧАННЯ ДЛЯ МОДЕЛЮВАННЯ ЛОГІСТИЧНИХ ПОТОКІВ У КРИЗОВИХ УМОВАХ

Бойко Денис, студент 2-го курсу магістратури
Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»
Київ, Україна
ORCID ID 0009-0006-0425-5002
e-mail: denboiko86@gmail.com

Науковий керівник: Лазаренко Ірина, доцент, доцент кафедри економічної кібернетики
Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»
Київ, Україна
ORCID ID 0000-0002-3384-1186
e-mail: irynalazar@gmail.com

Логістика відіграє критичну роль у забезпеченні ефективного функціонування економічних і гуманітарних процесів, особливо в умовах кризи. Під час воєнних конфліктів, природних катастроф або глобальних пандемій, як це стало очевидним у випадку COVID-19, логістичні ланцюги стикаються з низкою викликів, зокрема порушенням транспортної інфраструктури, дефіцитом ресурсів та різким зростанням потреб у гуманітарних поставках. Традиційні методи управління логістичними потоками в таких умовах часто виявляються недостатньо гнучкими або ефективними для реагування на швидко мінливі обставини. У цьому контексті машинне навчання (ML) та інші інноваційні підходи до моделювання логістичних операцій стають все більш актуальними.

Машинне навчання – це один із напрямків штучного інтелекту, що дозволяє комп’ютерам самостійно навчатися на основі великих обсягів даних та знаходити оптимальні рішення у складних та динамічних середовищах. Особливо цінним є використання методів машинного навчання для оптимізації доставки гуманітарної допомоги, управління запасами та координації транспорту в умовах обмежених ресурсів [1].

У кризових ситуаціях, коли традиційні математичні моделі часто не можуть забезпечити достатньо швидкі та точні рішення, методи машинного навчання можуть допомогти знаходити нові ефективні рішення, враховуючи широкий спектр факторів, таких як динамічні зміни попиту, доступність транспортних шляхів та обмеженість матеріальних ресурсів.

Крім того, машинне навчання дає можливість створювати адаптивні системи управління логістичними потоками, які постійно оновлюються на основі нових даних, що надходять у реальному часі. Це забезпечує гнучкість і дозволяє швидко реагувати на непередбачувані ситуації, такі як зміни в політичній ситуації, блокування транспортних шляхів або зміна потреб населення.

Моделювання логістичних потоків у кризових умовах є складним і важливим завданням, яке вимагає адаптивних підходів через непередбачуваність ситуацій і змінність даних. Класичні методи планування логістичних операцій часто не можуть бути застосовані через нестабільність умов, обмеженість ресурсів або швидке змінення середовища. Тому важливість машинного навчання (МН) в таких умовах полягає у здатності адаптуватися до нових даних та переробляти моделі в реальному часі, що дозволяє ефективно оптимізувати потоки вантажів, знижуючи витрати та покращуючи швидкість доставки.

Однією з важливих задач кризової логістики є оптимальне зонування територій та розміщення логістичних центрів. Це дозволяє мінімізувати витрати на транспортування та забезпечити максимальну ефективність використання ресурсів у складних умовах. Математична модель оптимального зонування території дозволяє визначити, які точки на території повинні обслуговувати певні логістичні центри з урахуванням обмежених ресурсів і потужностей.

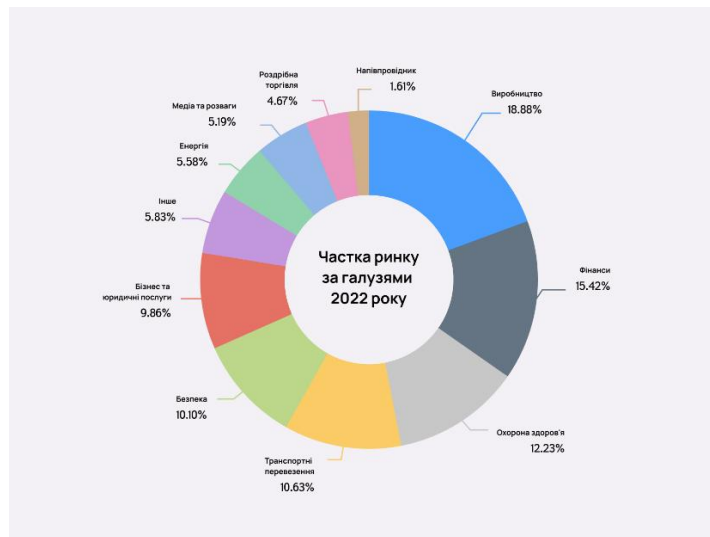


Рисунок 1 - Розподіл ринку ML по основних секторах

Джерело: узагальнено та формалізовано автором на основі [2].

Математична модель зонування території:

Мета моделі — мінімізація сумарних витрат на транспортування ресурсів із логістичних центрів до точок споживання:

$$\min \sum_{i=1}^n \sum_{j=1}^m x_{ij} d(t_i, c_j) \quad (1)$$

де $d(t_i, c_j)$ - відстань або витрати на транспортування між точкою t_i , та центром c_j , а $x_{ij}=1$, якщо пункт t_i , обслуговується центром c_j , і 0 в іншому випадку.

Обмеження:

Потужність кожного логістичного центру обмежена:

$$\sum_{i=1}^n x_{ij} \leq P_j \quad \forall j = 1, \dots, m \quad (2)$$

де P_j — максимальна кількість ресурсу, яку може обробити центр c_j .

Кожна точка повинна бути обслугована хоча б одним центром:

$$\sum_{j=1}^m x_{ij} = 1 \quad \forall i = 1, \dots, n \quad (3)$$

Для розв'язання таких задач використовуються субградієнтні методи та штрафні функції, що дозволяють адаптувати модель до динамічних умов кризи. Такі алгоритми здатні забезпечувати постійну адаптацію до змін інфраструктури та доступності ресурсів.

Для більш складних сценаріїв, таких як доставка ресурсів через проміжні логістичні центри, використовується двоетапна модель розподілу ресурсів. Ця модель передбачає мінімізацію загальних витрат на транспортування з початкового пункту через проміжні центри до кінцевих точок споживання.

Математична модель двоетапної доставки:

Задача мінімізує сумарні витрати на транспортування на двох етапах:

$$\min \sum_{i=1}^k \sum_{j=1}^m \sum_{l=1}^n x_{ij} y_{jl} (f(s_i, c_j) + g(c_j, d_l)) \quad (4)$$

де $f(s_i, c_j)$ — витрати на транспортування між початковим пунктом і логістичним центром, а $g(c_j, d_l)$ — витрати між центром і кінцевим пунктом.

Обмеження:

Обмеження на потужність центрів та потреби споживачів:

$$\sum_{i=1}^k x_{ij} \leq P_j, \quad \sum_{j=1}^m y_{jl} \geq d_l \quad (5)$$

де P_j — потужність логістичного центру, а d_l — потреби споживача .

Модель двоетапної доставки застосовується для кризових ситуацій, коли важливо швидко перенаправляти потоки ресурсів через проміжні центри, адаптуючи маршрути до змін у доступності шляхів або ресурсів [3].

Машинне навчання відіграє важливу роль у підвищенні адаптивності логістичних моделей. Наприклад, нейронні мережі можуть використовуватися для прогнозування потреб у доставці або для динамічного оновлення маршрутів на основі змін у стані інфраструктури або безпекових умов. Градієнтний бустинг допомагає оптимізувати маршрути доставки в реальному часі, враховуючи поточні умови транспортування та змінні фактори.

Застосування цих моделей забезпечує ефективне управління логістичними потоками під час кризових ситуацій, дозволяючи мінімізувати витрати, оптимізувати використання ресурсів та забезпечити оперативну доставку допомоги.

У сучасному світі кризові ситуації, такі як воєнні конфлікти, природні катастрофи чи глобальні пандемії, створюють значні виклики для управління логістичними потоками. Традиційні підходи часто виявляються неефективними у швидко змінних умовах, що підкреслює необхідність впровадження інноваційних технологій.

Особлива увага приділена гнучким алгоритмам, таким як нейронні мережі та градієнтний бустинг, які можуть оновлювати маршрути в реальному часі, враховуючи зміни у доступності ресурсів чи інфраструктурі. Це забезпечує не лише економічну ефективність, але й оперативну відповідь на нагальні потреби.

Таким чином, впровадження ML у логістичні процеси в кризових умовах є ключовим кроком для підвищення стійкості та адаптивності систем управління. Це не лише сприяє зниженню витрат та оптимізації ресурсів, а й дозволяє більш ефективно реагувати на глобальні виклики, забезпечуючи надійність гуманітарних та економічних операцій.

Література:

1. Західноукраїнський центр громадської кіберосвіти. (2024). Штучний інтелект та машинне навчання. https://web-learn.org/shtuchnij-intelekt-ta-mashinne-navchannya/?gad_source=1&gclid=CjwKCAiAjKu6BhAMEiwAx4UsAhCnWAXZM4tzwEsy8aOH0lLes9acsjrYF15bHOapjHlFeP2b7o1nlhoCJZUQAvD_BwE
2. Майбутнє машинного навчання: індустрії та тренди. (2024). <https://wezom.com.ua/ua/blog/maybutnje-mashinnogo-navchannya-industriyi-ta-trendi>
3. Koriashkina L., Dziuba S. (2024). Математичні моделі та методи зонування і розміщення об'єктів в системах екстреної логістики. <https://doi.org/10.34185/1562-9945-6-149-2023-09>

ВИКОРИСТАННЯ АВТОМАТИЗОВАНИХ ЗАСОБІВ ДЛЯ ВИРІШЕННЯ ПРОБЛЕМИ ВРАХУВАННЯ ГЕТЕРОСКЕДАСТИЧНОСТІ ПІД ЧАС ДОСЛІДЖЕННЯ ЕКОНОМІЧНИХ СИСТЕМ В УМОВАХ ПІДВИЩЕНОГО РИЗИКУ

Бондаренко Олена, к.е.н., доцент кафедри загальноінженерних дисциплін та обладнання Донецький національний університет економіки і торгівлі ім. Михайла Туган-Барановського
Кривий Ріг, Україна
ORCID ID 0000-0002-0387-3486
e-mail: bondarenko_oo@donnuet.edu.ua

Використання автоматизованих засобів для вирішення економічних задач стає все більш поширеним, особливо в умовах зростання обсягів даних та складності економічних моделей. Автоматизовані засоби дозволяють здійснювати швидку та точну обробку великих обсягів даних, проводити аналіз економічних систем та прогнозування їх розвитку. Проте, при дослідженні економічних систем в умовах підвищеного ризику, проблема врахування гетероскедастичності може стати досить серйозною.

Одним з основних припущень моделі класичної лінійної регресії є припущення про сталість дисперсії кожної випадкової величини u_i . Це явище називається гомоскедастичністю. Формалізовано це припущення записується у вигляді: $\text{const } \sigma^2(u_i) = M(u_i^2) - \bar{u}^2 = \sigma^2$ (7.1) Якщо це припущення не задовольняється у якомусь окремому випадку, то має місце гетероскедастичність. Суть припущення гомоскедастичності полягає в тому, що варіація кожної u_i навколо її математичного сподівання залежить від значення x . Дисперсія кожної u_i зберігається сталою незалежно від малих чи великих значень факторів: $\sigma^2(u_i)$ не є функцією x , тобто $\sigma^2(u_i) = \sigma^2$. Графічно випадок гомоскедастичності для простої лінійної регресії показано випадковою дисперсією u у межах сталої відстані навколо лінії регресії (рисунок 7.1 а). Якщо $\sigma^2(u)$ не є сталою, а її значення залежить від значення x , можемо записати $\sigma^2(u) = \sigma^2(x)$. У цьому випадку маємо справу з гетероскедастичністю.

Якщо дисперсія залишків змінюється для кожного спостереження або групи спостережень, тобто $\sigma^2(u) = \sigma^2(x)$, то це явище називається гетероскедастичністю. Гетероскедастичність полягає в тому, що дисперсія помилки моделі залежить від значень залежної змінної. Це означає, що стандартні методи оцінювання параметрів моделей, які не враховують гетероскедастичності, можуть бути неточними та призводити до неправильних висновків.

Якщо існує гетероскедастичність залишків, то це спричиняється до того, що оцінки параметрів моделі МНК будуть незміщеними, обґрунтованими, але не ефективними. При цьому формулу для стандартної помилки оцінки застосовувати не можна. Виявити наявність