

**МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
ЛЬВІВСЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ
ПРИРОДОКОРИСТУВАННЯ
ФАКУЛЬТЕТ МЕХАНІКИ, ЕНЕРГЕТИКИ ТА ІНФОРМАЦІЙНИХ
ТЕХНОЛОГІЙ
КАФЕДРА ІНФОРМАЦІЙНИХ ТЕХНОЛОГІЙ**

КВАЛІФІКАЦІЙНА РОБОТА

другого (магістерського) рівня вищої освіти

на тему: «Система підтримки прийняття рішень для
прогнозування витрат пального під час транспортування
зернових»

Виконав: студент групи Іт-61

Спеціальності 126 «Інформаційні системи та
технології»

(шифр і назва)

Фамуляк Володимир Юрійович

(Прізвище та ініціали)

Керівник: д.т.н., професор Тригуба А.М.

(Прізвище та ініціали)

Рецензент: к.т.н., доцент Бабич М.І.

(Прізвище та ініціали)

ДУБЛЯНИ-2024

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
ЛЬВІВСЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ ПРИРОДОКОРИСТУВАННЯ
ФАКУЛЬТЕТ МЕХАНІКИ, ЕНЕРГЕТИКИ ТА ІНФОРМАЦІЙНИХ
ТЕХНОЛОГІЙ
КАФЕДРА ІНФОРМАЦІЙНИХ ТЕХНОЛОГІЙ

Другий (магістерський) рівень вищої освіти
Спеціальність 126 «Інформаційні системи та технології»

«ЗАТВЕРДЖУЮ»

Завідувач кафедри _____

д.т.н., проф. А.М. Тригуба

«____» _____ 2023 р.

ЗАВДАННЯ

на кваліфікаційну роботу студенту

Фамуляку Володимирі Юрійовичу

1. Тема роботи: «Система підтримки прийняття рішень для прогнозування витрат пального під час транспортування зернових»

Керівник роботи Тригуба Анатолій Миколайович, професор
затверджені наказом по університету від 12.09.2024 року № 616/к-с.

2. Строк подання студентом роботи 10.01.2024 р.

3. Вихідні дані до роботи: дані оптимізації портфелів проектів розвитку громад; методика дослідження нейромережових моделей.

4. Зміст розрахунково-пояснювальної записки (перелік питань, які необхідно розробити) _____

Вступ.

1. Аналіз стану прогнозування витрат пального автомобілями та завдання кваліфікаційної роботи.

2. Вибір нейромережових моделей та підготовка даних для прогнозування витрат пального під час транспортування зернових.

3. Результати обґрунтування моделі та системи підтримки прийняття рішень для прогнозування витрат пального під час транспортування зернових.

4. Охорона праці та безпека у надзвичайних ситуаціях.

5. Визначення економічної ефективності системи підтримки прийняття рішень для прогнозування витрат пального під час транспортування зернових.

Висновки та пропозиції.

Список використаної літератури.

5. Перелік ілюстраційного матеріалу (з точним зазначенням обов'язкових слайдів): аналіз стану прогнозування витрат пального автомобілями та завдання кваліфікаційної роботи; вибір нейромережових моделей та підготовка даних для прогнозування витрат пального під час транспортування зернових; результати обґрунтування моделі та системи підтримки прийняття рішень для прогнозування витрат пального під час транспортування зернових; визначення економічної ефективності.

6. Консультанти з розділів:

Розділ	Прізвище, ініціали та посада консультанта	Підпис, дата	
		завдання видав	завдання прийняв
1, 2, 3, 5	<i>Тригуба А.М., зав. кафедри інформаційних технологій</i>		
4	<i>Городецький І.М., доцент кафедри фізики, інженерної графіки та безпеки виробництва</i>		

7. Дата видачі завдання

12 вересня 2024 р.

Календарний план

№ з/п	Назва етапів кваліфікаційної роботи	Терміни виконання етапів роботи	Примітка
1	<i>Написання першого розділу</i>	<i>12.09-20.09.24</i>	
2	<i>Виконання другого розділу та аркушів ілюстраційного матеріалу до нього</i>	<i>21.09-14.10.24</i>	
3.	<i>Виконання третього розділу та аркушів ілюстраційного матеріалу до нього</i>	<i>15.10-10.11.24</i>	
4.	<i>Написання розділу «Охорона праці та безпека у надзвичайних ситуаціях»</i>	<i>11.11-20.11.24</i>	
5.	<i>Оцінення ефективності запропонованої системи</i>	<i>21.11-30.30.24</i>	
6.	<i>Завершення оформлення розрахунково-пояснювальної записки та аркушів ілюстраційного матеріалу</i>	<i>01-04.12.24</i>	
7.	<i>Завершення роботи в цілому</i>	<i>05-10.12.24</i>	

Студент _____ Фамуляк В.Ю.
(підпис)

Керівник роботи _____ Тригуба А.М.
(підпис)

УДК 629.11:004.6:004.77

Система підтримки прийняття рішень для прогнозування витрат пального під час транспортування зернових.

Фамуляк В.Ю. Кафедра інформаційних технологій – Дубляни, ЛНУП, 2024.

Кваліфікаційна робота: 66 с. текст. част., 14 рис., 5 табл., 15 арк. ілюстраційного матеріалу, 42 джерела.

Подано особливості оцінки споживання палива транспортним засобом. Проаналізовано інформаційні технології для моніторингу витрат палива на автомобілях. Виконано аналіз особливостей прогнозування витрати палива за допомогою штучних нейронних мереж. Сформульовано завдання роботи. Здійснено вибір та аналіз нейромережевих моделей. Вибрано багатошаровий перцептрон (MLP), рекурентну нейромережу (LSTM) та згорткову нейромережу (CNN). Подано аналіз початкових даних для прогнозування витрат палива транспортними засобами під час транспортування зернових. Наведено результати визначення взаємозв'язків між початковими даними. Створено навчальну та тестову вибірки для навчання моделі. Здійснено навчання нейромережевих моделей. Вибрано раціональну згорткову нейромережу (CNN). Обґрунтована архітектура системи підтримки прийняття рішень для прогнозування витрат пального під час транспортування зернових. Розроблено вікно користувача системи підтримки прийняття рішень для прогнозування витрат пального під час транспортування зернових.

Розроблено заходи із охорони праці під час розробки системи підтримки прийняття рішень для прогнозування витрат пального під час транспортування зернових. Визначено економічну ефективність системи підтримки прийняття рішень для прогнозування витрат пального під час транспортування зернових.

Ключові слова: система підтримки прийняття рішень, прогнозування, пальне, транспортування, зернові, нейронні мережі.

ЗМІСТ

ВСТУП	7
РОЗДІЛ 1. АНАЛІЗ СТАНУ ПРОГНОЗУВАННЯ ВИТРАТ ПАЛЬНОГО АВТОМОБІЛЯМИ ТА ЗАВДАННЯ КВАЛІФІКАЦІЙНОЇ РОБОТИ	9
1.1. Особливості оцінки споживання палива транспортним засобом	9
1.2. Інформаційні технології для моніторингу витрат палива на автомобілях	13
1.3. Прогнозування витрати палива автомобіля за допомогою штучних нейронних мереж.....	18
1.4. Завдання кваліфікаційної роботи	21
РОЗДІЛ 2. ВИБІР НЕЙРОМЕРЕЖЕВИХ МОДЕЛЕЙ ТА ПІДГОТОВКА ДАНИХ ДЛЯ ПРОГНОЗУВАННЯ ВИТРАТ ПАЛЬНОГО ПІД ЧАС ТРАНСПОРТУВАННЯ ЗЕРНОВИХ	23
2.1. ВИБІР ТА АНАЛІЗ НЕЙРОМЕРЕЖЕВИХ МОДЕЛЕЙ ДЛЯ ПРОГНОЗУВАННЯ ВИТРАТ ПАЛИВА ТРАНСПОРТНИМИ ЗАСОБАМИ ПІД ЧАС ТРАНСПОРТУВАННЯ ЗЕРНОВИХ	23
2.1.1. Багатошарова перцептронна модель (MLP)	24
2.1.2. Рекурентна нейромережа (LSTM)	26
2.1.3. Зготкова нейромережа (CNN).....	28
2.2. Аналіз початкових даних для прогнозування витрат палива транспортними засобами під час транспортування зернових	30
2.3. Результати визначення взаємозв'язків між початковими даними	32
РОЗДІЛ 3. РЕЗУЛЬТАТИ ОБҐРУНТУВАННЯ МОДЕЛІ ТА СИСТЕМИ ПІДТРИМКИ ПРИЙНЯТТЯ РІШЕНЬ ДЛЯ ПРОГНОЗУВАННЯ ВИТРАТ ПАЛЬНОГО ПІД ЧАС ТРАНСПОРТУВАННЯ ЗЕРНОВИХ	37
3.1. Створення навчальних та тестових вибірок	37
3.2. Навчання нейромережевих моделей	39

3.3. Архітектура системи підтримки прийняття рішень для прогнозування витрат пального під час транспортування зернових	42
3.4. Розробка вікна користувача системи підтримки прийняття рішень для прогнозування витрат пального під час транспортування зернових	44
РОЗДІЛ 4. ОХОРОНА ПРАЦІ ТА БЕЗПЕКА У НАДЗВИЧАЙНИХ СИТУАЦІЯХ	47
4.1. Аналіз небезпечних чинників під час створення системи підтримки прийняття рішень	47
4.2. Моделювання виникнення травм та аварій	49
4.3. Розробка заходів щодо безпеки у надзвичайних ситуаціях.....	51
РОЗДІЛ 5. ВИЗНАЧЕННЯ ЕКОНОМІЧНОЇ ЕФЕКТИВНОСТІ СИСТЕМИ ПІДТРИМКИ ПРИЙНЯТТЯ РІШЕНЬ ДЛЯ ПРОГНОЗУВАННЯ ВИТРАТ ПАЛЬНОГО ПІД ЧАС ТРАНСПОРТУВАННЯ ЗЕРНОВИХ	53
ВИСНОВКИ І ПРОПОЗИЦІЇ.....	56
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ.....	61

ВСТУП

Сучасний світ та економіка нашого часу стикаються зі зростаючою потребою вдосконалення логістичних процесів та оптимізації витрат пального в транспортних галузях. Автомобільна логістика, зокрема доставка сільськогосподарської продукції, включаючи використання зернових культур, потребує постійного вдосконалення та оптимізації, особливо в умовах зростання цін на пальне та зміну клімату [13].

Одним із ключових факторів, що впливає на успішність логістичних операцій у транспортній галузі, є витрати пального. Використання пального та його ефективність може значно вплинути на витрати та прибутковість транспортних підприємств. Тому виникає актуальна задача розробки інтелектуальних систем, призначених для прогнозування витрат пального під час доставки сільськогосподарської продукції, зокрема використання зернових культур.

Автомобілі DAF відомі надійністю та продуктивністю в транспортній галузі. Ця модель автомобіля використовується для перевезення різних вантажів, у тому числі зернових культур, і є популярною серед перевізників та логістичних компаній [19]. Впровадження системи підтримки прийняття рішень для прогнозування витрат пального під час транспортування зернових може допомогти оптимізувати процес доставки та зменшити витрати пального, що, за часом, сприятиме підвищенню прибутковості та стабільності логістичних операцій у цій галузі.

Мета цієї кваліфікаційної роботи полягає в розробці та апробації системи підтримки прийняття рішень для прогнозування витрат пального під час транспортування зернових. Робота спрямована на вдосконалення логістичних процесів, зниження впливу транспортних витрат на загальні витрати та підвищення екологічних показників у галузі перевезень.

Отже, розробка системи підтримки прийняття рішень для прогнозування витрат пального під час транспортування зернових має практичну цінність та забезпечує підвищення ефективності відповідних логістичних процесів.

Об'єктом дослідження є система підтримки прийняття рішень для прогнозування витрат пального під час транспортування зернових.

Предмет дослідження є вплив виробничих умов на архітектуру системи підтримки прийняття рішень, яка призначена для прогнозування витрат пального під час транспортування зернових.

РОЗДІЛ 1.

АНАЛІЗ СТАНУ ПРОГНОЗУВАННЯ ВИТРАТ ПАЛЬНОГО АВТОМОБІЛЯМИ ТА ЗАВДАННЯ КВАЛІФІКАЦІЙНОЇ РОБОТИ

1.1. Особливості оцінки споживання палива транспортним засобом

На загальну якість життя, економіку домогосподарств і навколишнє середовище глибоко впливає система автомобільного транспорту. Автомобільний транспорт становить приблизно п'яту частину загальних викидів парникових газів. Цікаво, що значну частину доходів підприємств припадає на заправку своїх транспортних засобів. Це означає, що навіть скорочення річного споживання пального автомобілями на 1% призведе до економії мільйонів доларів для країни, а також збереження навколишнього середовища та життя завдяки зниженню викидів у атмосферу.

Використання оцінок потужності як проксі-змінних, багатовимірної лінійної/нелінійної регресії та базового машинного навчання (ML) проводили на прикладі дослідження споживання палива за допомогою GPS [40]. Зазначені дослідження є прикладам спроби моделювання споживання палива з середини 1990-х років. Тим не менш, попередні спроби дослідження споживання палива та моделювання викидів парникових газів можна критикувати принаймні в одному з аспектів, таких як:

- ✓ домінування змодельованих лабораторних даних над даними на дорозі;
- ✓ обмежена різноманітність випробуваного автопарку;
- ✓ низька точність прогнозів;
- ✓ не врахування нелінійних залежностей від вхідних змінних, які неможливо спостерігати без використання спеціалізованих інструментів.

Запропонований підхід до моделювання споживання палива на основі даних і ML відкриває шляхи для усунення вищезгаданих недоліків.

Випробування проводяться на кількох автомобілях з різними специфікаціями, щоб забезпечити врахування різних типів автомобілів автопарку. Прості кінематичні змінні, такі як швидкість, прискорення, ухил дороги та оцінка швидкості двигуна (RPM), замість прямих вимірювань через інтерфейс бортової діагностики (OBD) використовуються як вхідні змінні (рис. 1.1).

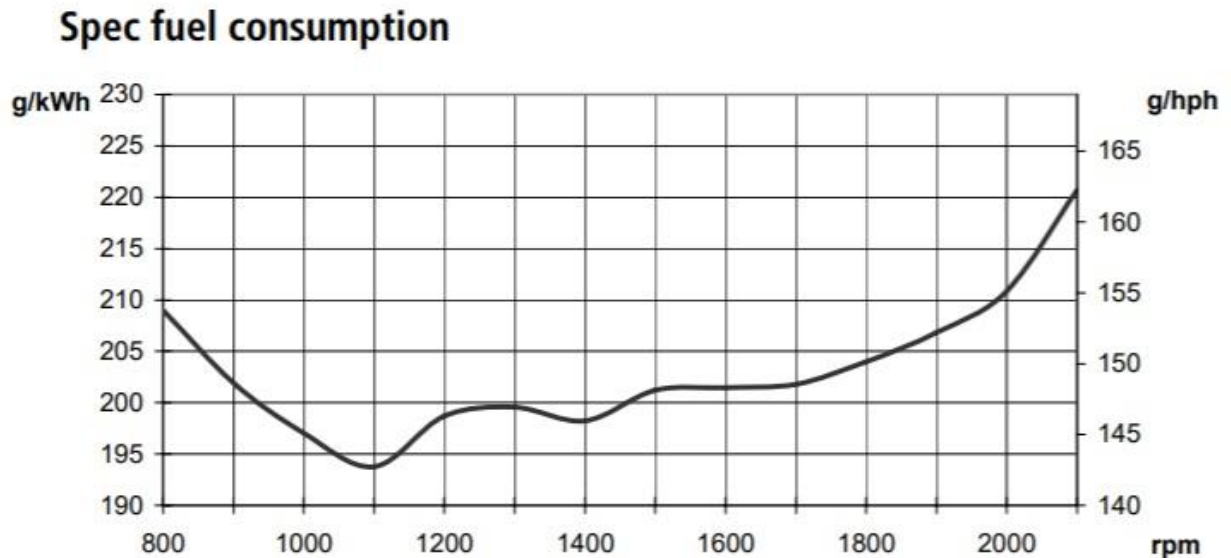


Рисунок 1.1 – Результати моделювання споживання палива на основі даних

Методи машинного навчання використовуються для фіксації зв'язків, які важко сформулювати, між вхідними змінними та їхнім нелінійним впливом на результат. Незалежність моделей від внутрішніх змінних двигуна, таких як RPM, усуває потребу в спеціалізованому обладнанні або доступі програмного забезпечення до даних бортової діагностики (OBD) для оцінки споживання палива під час розгортання моделі (рис. 1.2).

В той час як кінематичний стан транспортного засобу можна легко зафіксувати за допомогою GPS на смартфоні водія.

У результаті використання вище зазначеного підходу до збору даних, вибору функцій (терміни «функція» та «приклад» є загальними прийнятими термінами про найменування категорій в парадигмі машинного навчання для «вхідної змінної» та «запису даних» відповідно) та моделювання можна розробити програмне забезпечення.

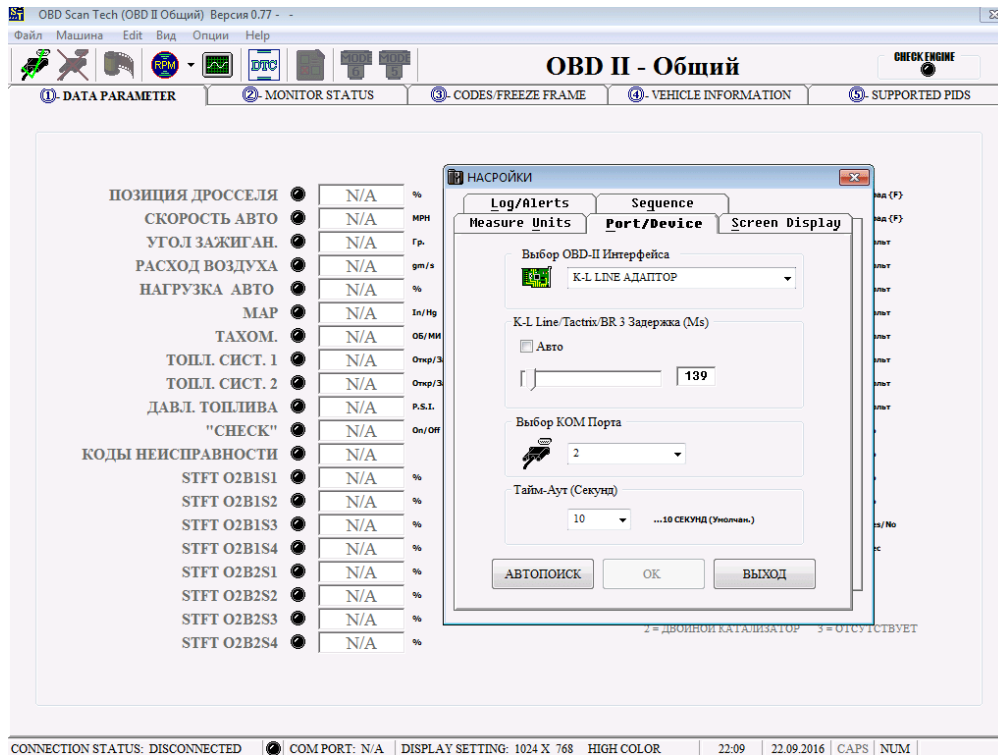


Рисунок 1.2 – Програмне забезпечення бортової діагностики (OBD) автомобілів для визначення витрат палива

Його можна використовувати в галузі вантажних перевезень, громадському транспорті або в легкових автомобілях (особливо в старих автомобілях, які є основними споживачами палива та забруднювачами, хоча вони здебільшого не обладнані вбудованими опціями екологічного водіння). Крім того, моделі, незалежні від OBD, можуть бути включені в програмне забезпечення моделювання дорожнього руху для оцінки витрати палива та викидів у різних масштабах.

З нещодавнім підвищенням цін на паливо мінімізація споживання палива стала головною проблемою екологічного проектування [36]. Зрозуміло, що використання ефективних методів оцінки споживання палива, щоб уникнути непотрібного використання, є важливим завданням [39].

Витрата палива є значущим економічним показником, а також життєво важливим сигналом про негативний вплив на навколишнє середовище. Отже,

надзвичайно важливо проаналізувати споживання палива різними типами транспортних засобів за впливовими факторами [30].

Щоб з'ясувати впливові фактори забруднювачів транспортних засобів, функціональність прогнозування споживання палива може бути корисною для керування їхнім впливом. У роботі [22] використали штучну нейронну мережу (ШНМ) із п'ятьма вхідними даними, а саме об'ємом двигуна, швидкістю, типом палива та кількістю пасажирів, щоб передбачити вартість споживання палива (рис. 1.3).

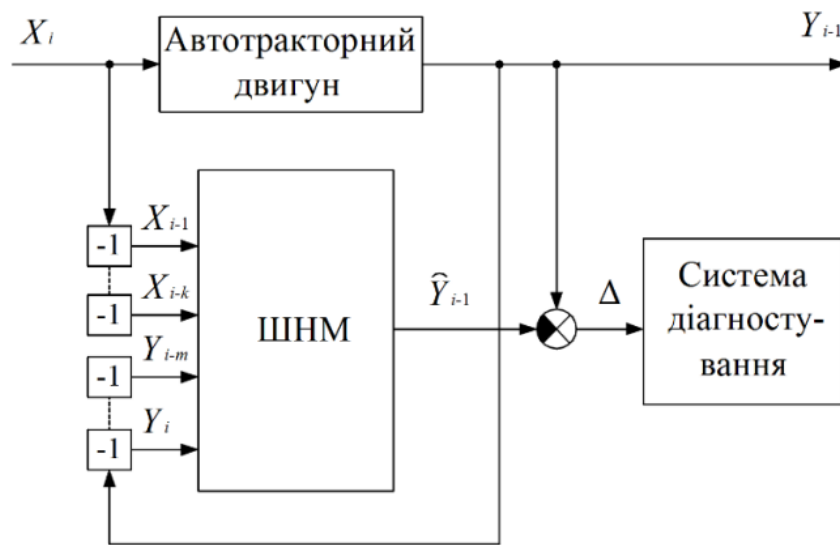


Рисунок 1.3 – Нейронна мережа для прогнозування споживання палива

Ця мережа має 15 вузлів на прихованому рівні, а споживання палива коштує як вихідний вузол. Моделювання та прогнозування споживання палива є цінним інструментом для оцінки витрат на енергію та виробництва парникових газів. Очевидно, що ефективні методи оцінки витрат на споживання палива є незамінними для зменшення непотрібних витрат палива [39].

1.2. Інформаційні технології для моніторингу витрат палива на автомобілях

Система керування паливом – це підрозділ системи керування автопарком, яка використовує інструменти на основі телематики та аналітичне програмне забезпечення для збору даних про споживання палива та покращення економії палива.

Економія/ефективність споживання палива в транспорті – це показник того, скільки часу транспортний засіб може проїхати на одиниці газу. Є багато способів, за допомогою яких ми не можемо покращити економію палива транспортного засобу (тип транспортного засобу та двигун, який він використовує, або скільки років двигуну), але є ще більше способів впливати на економію палива, якими ми можемо керувати:

- ✓ Розумне водіння може збільшити економію палива на 10-40 відсотків і заощадити кошти.
- ✓ Правильне та своєчасне технічне обслуговування автомобіля може збільшити економію палива на 4 відсотки та заощадити кошти.
- ✓ Варіанти палива (літній газ або газ з додаванням етанолу) можуть покращити економію палива до 4 відсотків.

Дані з паливних журналів і паливних карток також використовуються для звітності IFTA. Міжнародна угода про податок на паливо (IFTA) – це угода між 48 владою та 10 провінціями Канади, яка спрощує звітність комерційних автоперевізників про використання палива. Відповідно до IFTA перевізник повинен звітувати про спожите паливо та пройдену відстань у кожній юрисдикції та сплачувати податки на моторне паливо. Щоб автоматизувати цей процес, програмне забезпечення звітності про паливо може використовувати дані з паливних карток або ваших журналів палива.



Рисунок 1.4 – Інформаційні технології звітування IFTA на GeoTab

Використання даних паливного журналу для аналітики може бути надзвичайно корисним, але в деяких сценаріях це не дасть вам повної картини. Переходимо до інших можливостей оптимізації палива.

Комерційні автоперевізники в США зобов'язані мати електронний пристрій реєстрації (ELD), встановлений на своїх вантажівках, щоб повідомляти години роботи своїх водіїв. Але залежно від постачальника та в поєднанні з аналітичними можливостями пристрої ELD можна використовувати для запису різноманітних даних для підвищення безпеки та ефективності. ELD безпосередньо зв'язуються з блоком керування двигуном автомобіля (ECU), що дозволяє отримувати інформацію від датчиків двигуна, гальм і коробки передач, які зрештою показують два основні показники поведінки водія: час простою та різкі події.

Переглядаючи час холостого ходу різних водіїв, ви можете стимулювати більш ефективних драйверів і знайти шляхи вирішення проблеми холостого ходу. Наприклад, ви можете спробувати інвестувати в альтернативні варіанти клімат-контролю та перевірити, чи допоможе це водіям проводити менше часу простою.

KeepTrucking дозволяє фільтрувати за часом простою та використанням палива, щоб відрізнити найкращих і найгірших водіїв.

Зазвичай із гіроскопом і акселерометром ELD може отримувати інформацію про такі події, як різкі повороти, гальмування чи

зіткнення. Реєструючи ці дані, ви можете навчати водіїв безпечній їзді та запобігати майбутнім подіям, надаючи іншим водіям дані про зони з небезпечними поворотами.

В опитуванні 2015 року 53 відсотки операторів автопарків сказали, що вони часто помічали, що витрати на паливо перевищують прогнози. Незрозуміло, скільки пального регулярно крадуть у перевізників, оскільки технології запобігання шахрайству залишаються незвіданою територією для багатьох компаній. Але вони не повинні бути. Ось рішення для двох найпоширеніших методів крадіжки палива.

Скімінг паливної картки – це техніка крадіжки, коли спеціальний пристрій приєднується до платіжного терміналу на АЗС для викрадення даних вашої паливної картки. Існують різні види таких пристроїв. Іноді це просто приховані камери, в інших випадках клавіатури можуть бути підробленими. Але часто це ще складніше, коли тонка смуга прихована в слоті для картки для копіювання даних магнітної смуги вашої картки.

Єдина техніка профілактики, яку ви можете використати, це навчання водіїв тому, як перевіряти термінал на ознаки втручання. Щоб виявити вже викрадену інформацію паливної картки, ви можете використовувати можливості відстеження GPS ELD. Наприклад, якщо місце використання паливної картки відрізняється від поточного місцезнаходження транспортного засобу, система попередить агента про вжиття заходів.

Перекачування – це коли паливо вилучається з активів компанії (паливного баку у вантажівці або резервуара для зберігання палива на місці) і поміщається в транспортний засіб або контейнер, що не належить компанії. Ви можете використовувати дані ELD, щоб виявити порушення після випадку, але ви не зможете дізнатися, коли або ким було перекачено паливо – для цього вам потрібен телематичний пристрій у режимі реального часу. Існує два популярних варіанти.

1) Шина CAN. Шина CAN (мережі контролера) автомобіля є стандартною технологією зв'язку, встановленою в більшості сучасних легкових

транспортних засобів і вантажівок. Він дозволяє бортовому комп'ютеру отримувати дані від датчиків, встановлених виробником в паливному баку. Щоб надіслати цю інформацію до вашої системи управління паливом, вам потрібен пристрій відстеження GPS. Використання датчика шини CAN заощадить ваші витрати та зусилля на встановлення, але було помічено, що він має частоту помилок до 15 відсотків і не обчислює мертві зони в нижній і верхній частинах бака, що робить його менш надійним ніж інші варіанти вимірювання палива.

2) Датчик рівня палива. Датчик рівня палива – це пристрій, який встановлюється в паливний бак автомобіля. Такі датчики мають похибку 1-2 відсотки і можуть давати показання витрати палива, дати і місця заправок, обсяги зливу і обсяги рівня палива в певні періоди часу.

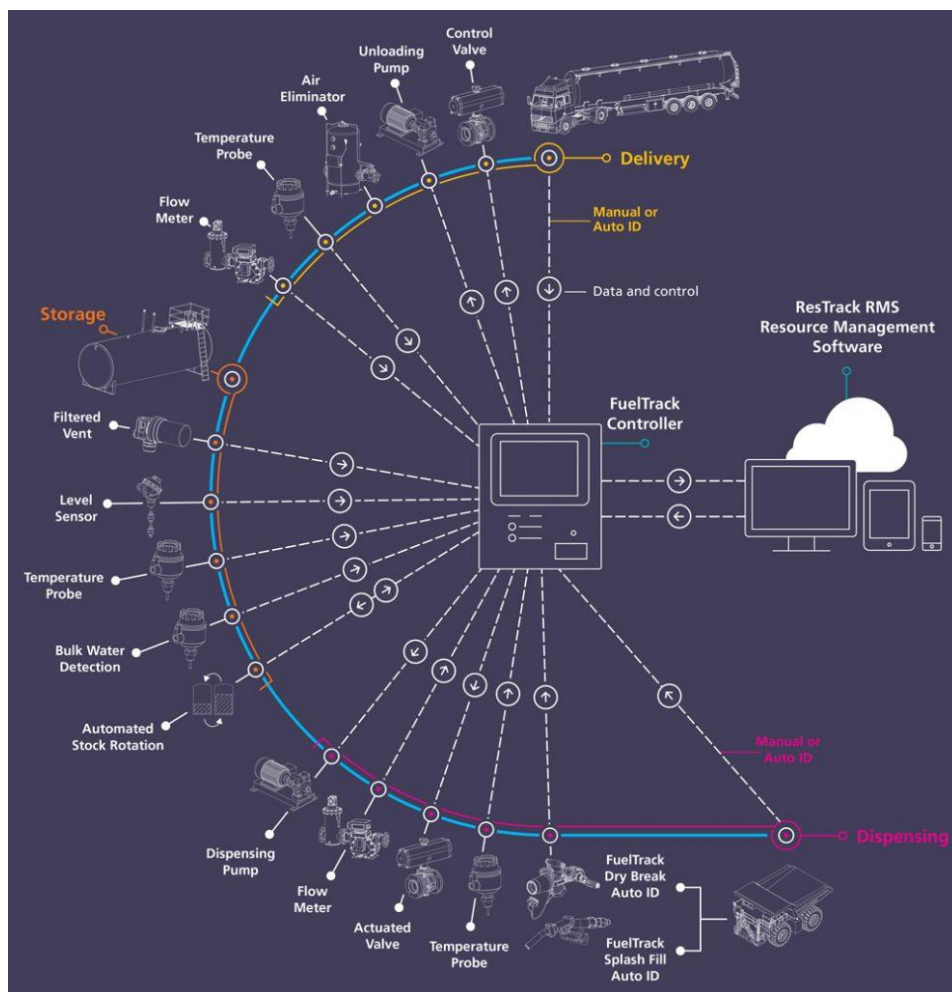


Рисунок 1.5 – Множина інструментів управління паливом

Програмне забезпечення для управління паливом дозволяє запобігти всім видам крадіжки палива з об'єкта, тому лише правильний об'єм палива може надходити до потрібного автомобіля.

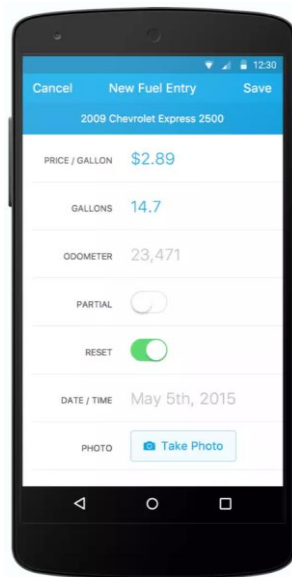


Рисунок 1.6 – Програмне забезпечення для управління паливом на Android та iOS

Однак це лише верхівка айсберга моніторингу, оскільки ви можете встановити будь-яку кількість датчиків, які забажаєте, щоб контролювати не лише видачу палива, але й його доставку та якість під час зберігання.

Існують наступні можливості для економії палива, які передбачають три рівні впровадження управління паливом.

1. Спрощена реєстрація палива та звітність. Найпопулярніші постачальники систем керування автопарком, такі як Samsara, Fleetio або Geotab, уже можуть отримувати дані з паливних карток і мобільних додатків водія для ваших журналів і звітів IFTA. Якщо потрібно підвищити операційну ефективність і контролювати витрати з мінімальними аналітичними можливостями, це достатньо точний інструментарій.

2. Інтеграція ELD без моніторингу в реальному часі. Придбання пристрою ELD, забезпечить встановити прихований потенціал автомобілів. Якщо слід отримувати звіти про поведінку водія, але не підключати пристрої в

реальному часі, можна отримати ELD, який може передавати дані раз на період на USB.

3. ELD з телематичними можливостями та датчиками автомобіля. Щоб використовувати зібрані дані в режимі реального часу, налаштовувати сповіщення та застосовувати прогнозне технічне обслуговування, знадобиться інфраструктура апаратного та програмного забезпечення на основі телематики. Якщо є достатній бюджет на такі інформаційні технології, слід замовити індивідуальну розробку, де можна налаштувати складну інтеграцію між системами та пристроями, установити ефективні конвеєри даних для персоналізованих звітів бізнес-аналітики та вести бізнес без обмежень готових системи.

1.3. Прогнозування витрати палива автомобіля за допомогою штучних нейронних мереж

Окремі дослідники використовують метод штучних нейронних мереж для визначення кількості палива, спожитого транспортними засобами. Множина вхідних даних (факторів, що впливають на рівень споживання палива) надається на вхід нейронної мережі, що призводить до єдиного виходу (швидкість споживання палива) з мережі. Після цього штучна нейронна мережа може обчислити швидкість споживання палива за будь-якого довільного введення.

Як показано на рис. 1.7, у вхідному шарі є загалом п'ять вхідних даних, що представляють об'єм двигуна, кількість циліндрів, кількість клапанів, вагу автомобіля та назву виробника. Після того, як штучна нейронна мережа наблизиться до бажаного результату, вона зможе вивести споживання палива автомобіля з будь-якими характеристиками.




Рисунок 1.7 – Схематична структура штучної нейронної мережі для прогнозування витрати палива

Обчислення штучною нейронною мережею бажаних вхідних даних (5 типів вхідних даних) виконується мережевою функцією в Matlab. Значення цієї функції в цьому документі позначається як «ціль».

Нейронна мережа, яка використовується, є двошаровою мережею з 17 нейронами в прихованому шарі. На навчання було виділено 35 зразків, на випробування – 8, на перевірку – 8. Для навчання використовувався метод Левенберга-Марквардта, розподіл даних проводився на випадковій основі, а функція середньоквадратичної помилки MSE (визначена нижче) використовувалася для визначення продуктивності мережі.

У таблиці 1.1 наведено специфікації оптимальної структури нейронної мережі для прогнозування споживання палива автомобіля.

Прихований шар був навчений за допомогою сигмоїдної передатної функції, а вихідний нейрон навчений за допомогою лінійної передатної функції для моделювання та проектування штучної нейронної мережі. Нейронна мережа може мати два або три прихованих шари. Як правило, чим більше складна система, то велика кількість рівнів знижує точність і може перешкоджати конвергенції мережі.

Таблиця 1.1 – Оптимальна структура нейронної мережі.

Кількість прихованих шарів	2
Кількість прихованих нейронів (n H)	17
Функція активації прихованого шару	Сигмовидна передаточна функція
Функція активації вихідного шару	Лінійна передаточна функція
Навчальна функція	Метод Левенберга–Марквардта

Тут представлена двошарова функція. Було доведено, що двошарові ШНМ із прихованим шаром за допомогою сигмоїдної функції та вихідним шаром за допомогою лінійної функції можуть апроксимувати всі бажані функції з будь-яким ступенем наближення, якщо є достатня кількість нейронів у прихованому шарі [27]. У багатошаровій нейронній мережі кожен рівень має власну вагову матрицю, вектори зміщення та вихід, а вихід кожного середнього шару використовується як вхід наступного рівня.

Іншим важливим параметром є кількість нейронів у прихованому шарі. Найпростіший спосіб запобігти переобладнанню – використовувати належну кількість нейронів у прихованому шарі. Зі збільшенням нейронів прихованого шару точність штучної нейронної мережі зростає відповідно до тренувальних подій [33].

У разі використання надмірної кількості нейронів у прихованому шарі мережа постраждає від перенавчання, а в протилежному випадку обчислення не буде передбачуваним (недонавчання). Нейрони прихованого шару діють як ідентифікатори шаблонів. Тому кількість нейронів у прихованому шарі відіграє значну роль у потужності мережі. Відсутність нейронів знижує ефективність аналізу та, у свою чергу, точність прогнозування [35].

Щоб подолати цю проблему, кількість нейронів у прихованому шарі має бути вибрано таким чином, щоб мережа мала достатню, а не надлишкову потужність для генерування відображень між входом і виходом. Одним із способів визначення кількості нейронів у прихованому шарі є мінімізація MSE [29]. Відповідну кількість нейронів у прихованому шарі можна визначити

методом проб і помилок, а також відповідною регресією та значеннями MSE. Окремі дослідники кількість нейронів у прихованому шарі для досягнення найкращих прогнозів і найменшої кількості помилок у мережі визначають на основі проб і помилок і за допомогою сигмоїдної передатної функції.

1.4. Завдання кваліфікаційної роботи

На основі проведеного аналізу стану питання в теорії та практиці встановлено, що сьогодні залишається невирішеними завдання, які пропонуємо розглянути у кваліфікаційній роботі на тему «Система підтримки прийняття рішень для прогнозування витрат пального під час транспортування зернових». Зокрема, зазначена робота полягає в розробці та впровадженні системи прогнозування витрат пального автомобіля DAF під час доставки зернових культур.

Система повинна бути здатна прогнозувати витрати пального з точністю не менше 95%. Для цього вона повинна використовувати дані про відстань транспортування, вид та вагу вантажу, дорожні умови, погодні умови та інші фактори, що впливають на витрати пального.

Система повинна бути реалізована у вигляді програмного забезпечення, яке можна встановити на ПК. Для реалізації системи необхідно виконати наступні завдання:

- 1) Провести аналіз існуючих методів прогнозування витрат пального.
- 2) Вибрати оптимальний метод прогнозування для даної задачі.
- 3) Розробити алгоритм для реалізації обраного методу.
- 4) Провести експериментальне дослідження системи.
- 5) Оцінити систему підтримки прийняття рішень для прогнозування витрат пального під час транспортування зернових.

В результаті виконання роботи повинен бути розроблений і впроваджений алгоритм прогнозування витрат пального, який дозволить

підвищити ефективність використання пального автомобілями DAF під час доставки зернових культур.

РОЗДІЛ 2.

ВИБІР НЕЙРОМЕРЕЖЕВИХ МОДЕЛЕЙ ТА ПІДГОТОВКА ДАНИХ ДЛЯ ПРОГНОЗУВАННЯ ВИТРАТ ПАЛЬНОГО ПІД ЧАС ТРАНСПОРТУВАННЯ ЗЕРНОВИХ

2.1. Вибір та аналіз нейромережових моделей для прогнозування витрат палива транспортними засобами під час транспортування зернових

Прогнозування витрат палива є важливим завданням для оптимізації логістичних процесів та зменшення експлуатаційних витрат. Щодо транспортування зернових культур прогнозування витрат палива допомагає не лише скоротити витрати, але й зменшити вплив транспорту на навколишнє середовище. Для розв'язання задачі пропонується використовувати нейромережові моделі, які здатні враховувати нелінійні залежності між змінними. Для цього було використано три різних типи нейромережових моделей:

1) Багатошарова перцептрона модель (MLP) – класична нейромережа, яка складається з кількох щільно з'єднаних шарів. Вона є базовою моделлю для порівняння;

2) Рекурентна нейромережа (LSTM) – модель, спеціально розроблена для роботи з послідовними даними. Використовується для обробки тимчасових залежностей у даних;

3) Зготкова нейромережа (CNN) – модель, яка застосовується для знаходження локальних залежностей у даних, ефективна для просторових аналізів.

2.1.1. Багатошарова перцептронна модель (MLP)

Багатошарова перцептронна модель (MLP, Multi-Layer Perceptron) є класичним типом нейромережі, яка складається з кількох шарів нейронів. Вона використовується для розв'язання задач регресії та класифікації завдяки своїй здатності апроксимувати нелінійні функції. Розглянемо основну структуру MLP, використану для прогнозування витрат палива транспортними засобами (рис. 2.1).

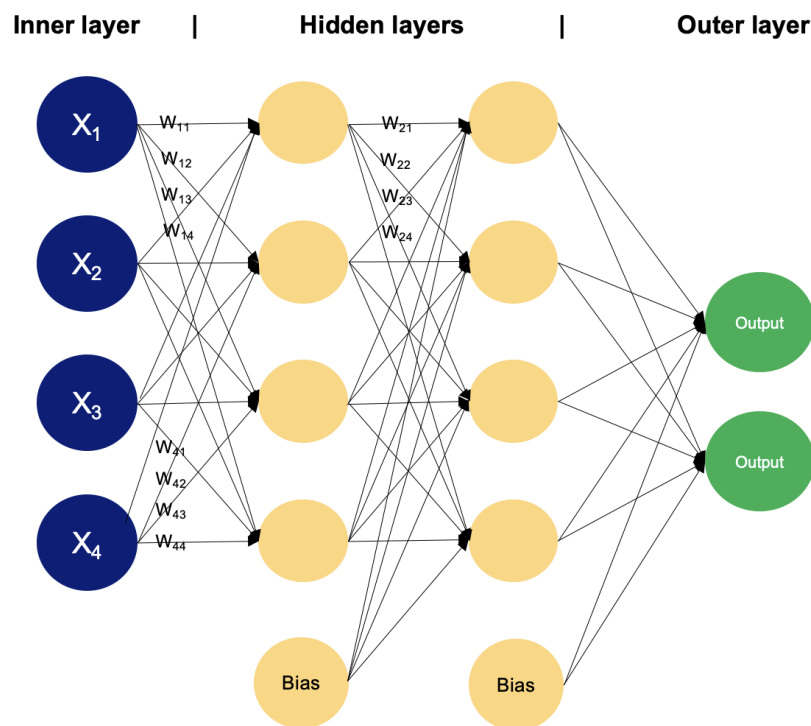


Рисунок 2.1 – Схема багатошарового перцептронна модель (MLP, Multi-Layer Perceptron)

Архітектура MLP моделі для задачі прогнозування витрат палива складається із:

- ✓ Вхідний шар – $x = [x_1, x_2, \dots, x_n]$, де n – кількість вхідних ознак;
- ✓ Два прихованих шари з 128 і 64 нейронами відповідно.
- ✓ Вихідний шар з одним нейроном, що представляє прогнозоване значення витрат палива.

Проведемо математичний опис MLP. На кожному шарі l , нейрон виконує лінійне перетворення:

$$z_i^{(l)} = \sum_{j=1}^n w_{ij}^{(l)} \cdot a_j^{(l-1)} + b_i^{(l)}, \quad (2.1)$$

де $z_i^{(l)}$ – зважена сума для i -го нейрона на шарі l ; $w_{ij}^{(l)}$ – ваговий коефіцієнт між нейронами j та i ; $a_j^{(l-1)}$ – активація j -го нейрона попереднього шару; $b_i^{(l)}$ – зміщення (bias).

Для нелінійності використовується функція активації ReLU (Rectified Linear Unit):

$$a_i^{(l)} = \text{ReLU}(z_i^{(l)}) = \max(0, z_i^{(l)}). \quad (2.2)$$

Вихідний шар виконує регресію, тобто:

$$\hat{y} = z^{(L)}, \quad (2.3)$$

де L – номер останнього шару.

Для навчання MLP використовується функція середньоквадратичної помилки (Mean Squared Error, MSE):

$$L = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2, \quad (2.4)$$

де m – кількість навчальних прикладів; y_i – справжнє значення; \hat{y}_i – прогноз моделі.

Мета навчання – мінімізувати функцію втрат, коригуючи ваги та зміщення нейронів за допомогою алгоритму градієнтного спуску.

Процес навчання моделі MLP включає наступні етапи:


1. Пряме поширення – обчислення активацій нейронів на кожному шарі до отримання прогнозу \hat{y}_i ;
2. Зворотне поширення помилки – обчислення похибки між прогнозом \hat{y}_i та справжнім значенням y_i , а також градієнтів ваг;
3. Оновлення ваг – ваги оновлюються за правилом:

$$w_{ij}^{(l)} \leftarrow w_{ij}^{(l)} - \eta \frac{\partial L}{\partial w_{ij}^{(l)}}, \quad (2.5)$$

де η – коефіцієнт навчання.

2.1.2. Рекурентна нейромережа (LSTM)

Рекурентні нейромережі (RNN) є потужним інструментом для роботи з послідовними та часовими даними. Одним із основних їхніх варіантів є LSTM (Long Short-Term Memory), яка вирішує проблему зникання градієнтів у традиційних RNN. У контексті прогнозування витрат палива, LSTM дозволяє враховувати послідовну залежність між характеристиками маршрутів і витратами (рис. 2.2).



$$z_t = \sigma (W_z \cdot [h_{t-1}, x_t])$$

$$r_t = \sigma (W_r \cdot [h_{t-1}, x_t])$$

$$\tilde{h}_t = \tanh (W \cdot [r_t * h_{t-1}, x_t])$$

$$h_t = (1 - z_t) * h_{t-1} + z_t * \tilde{h}_t$$

Рисунок 2.2 – Схема рекурентної нейромережі модель (LSTM, Long Short-Term Memory)

Архітектура LSTM складається з спеціальних блоків пам'яті, кожен з яких включає:

1. вхідний елемент – приймає вхідні дані на поточному кроці;
2. комірку пам'яті – зберігає довгострокову інформацію;
3. гейтів (воріт) – регулюють, яку інформацію зберігати, забувати чи передавати далі.

Для задачі прогнозування витрат палива використовувалася наступна архітектура:

- ✓ перший LSTM-шар – 128 нейронів з поверненням послідовності;
- ✓ другий LSTM-шар – 64 нейрони без повернення послідовності;
- ✓ вихідний щільний шар – один нейрон для регресії.

Кожен блок LSTM виконує кілька етапів обчислень:

Вхідний гейт визначає, яку нову інформацію додати до комірки пам'яті:

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i), \quad (2.6)$$

де i_t – вхідний гейт; x_t – вхідні дані на кроці t ; h_{t-1} – вихідний стан попереднього блоку; W_i , b_i – ваги та зміщення; σ – сигмоїдна функція активації.

Гейт забування визначає, яку інформацію слід видалити:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f). \quad (2.7)$$

Оновлення стану пам'яті:

$$\begin{aligned} \tilde{C}_t &= \tanh(W_C \cdot [h_{t-1}, x_t] + b_C), \\ C_t &= f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t, \end{aligned} \quad (2.8)$$

де C_t – стан комірки пам'яті.

Вихідний гейт визначає, що передати на вихід:

$$\begin{aligned} o_t &= \sigma(W_o \cdot [h_{t-1}, x_t] + b_o), \\ h_t &= o_t \cdot \tanh(C_t), \end{aligned} \quad (2.9)$$

де h_t – вихід блоку.

Як і для MLP, в LSTM використовується функція середньоквадратичної помилки (MSE) (2.4).

Процес навчання LSTM аналогічний MLP і включає пряме поширення – послідовна обробка кожного кроку та зворотне поширення через час (Backpropagation Through Time, BPTT) – оновлення ваг із врахуванням часової послідовності.

2.1.3. Згорткова неймережа (CNN)

Згорткові неймережі (CNN, Convolutional Neural Networks) відомі своєю здатністю виявляти локальні залежності в даних. Хоча CNN зазвичай використовуються для аналізу зображень, їх ефективність також поширюється на завдання регресії, де важливо виділити локальні шаблони в багатовимірних даних. У задачі прогнозування витрат палива, CNN дозволяє знайти взаємозв'язки між різними характеристиками транспортного процесу (рис. 2.3).

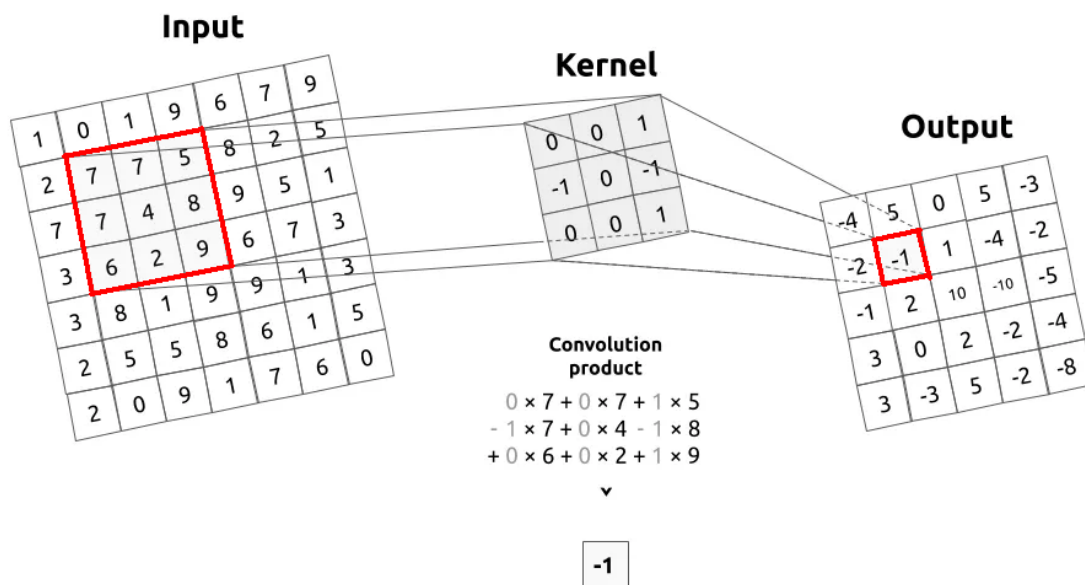


Рисунок 2.3 – Схема згорткової неймережі модель (CNN, Convolutional Neural Networks)

Архітектура згорткової неймережі CNN складається з таких основних компонентів:

1. згортковий шар – обчислює згортки (convolutions) для виділення локальних особливостей;
2. шар об'єднання (pooling) – зменшує розмірність даних, зберігаючи важливу інформацію;

3. шар Flatten – перетворює дані у вектор для подальшої обробки щільними шарами;

4. щільні шари (Dense layers) – виконують кінцеву регресію.

Архітектура CNN для задачі прогнозування витрат палива:

✓ ПЕРШИЙ згортковий шар – 64 фільтри з ядром розміру $2 \times 12 \times 12 \times 1$, функція активації ReLU;

✓ Другий згортковий шар – 32 фільтри з тим самим розміром ядра;

✓ Flatten-шар – перетворює згорткові виходи у вектор;

✓ Щільний шар – 64 нейрони з активацією ReLU;

✓ Вихідний шар – один нейрон для регресії.

У згортковому шарі виконується операція згортки вхідних даних X з ядром K :

$$z_{i,j} = \sum_{m=1}^M \sum_{n=1}^N X_{i+m,j+n} \cdot K_{m,n} + b, \quad (2.10)$$

де $M \times N$ – розмір ядра; b – зміщення; $z_{i,j}$ – результат згортки.

Після згортки застосовується функція активації ReLU:

$$a_{i,j} = \max(0, z_{i,j}). \quad (2.11)$$

Шар об'єднання зменшує розмірність, використовуючи, наприклад, максимальне об'єднання (Max Pooling):

$$p_{i,j} = \max\{a_{m,n}\}, m, n \in \text{вікно об'єднання}. \quad (2.12)$$

Дані зменшеної розмірності передаються на щільні шари для обчислення кінцевого прогнозу.

Для навчання моделі використовувалася функція середньоквадратичної помилки (MSE) (2.4).

Процес навчання CNN відбувається через пряме поширення – обчислення згорткових шарів, активацій та прогнозу та зворотне поширення – оновлення ваг згорткових і щільних шарів за допомогою алгоритму градієнтного спуску.

Згорткова нейромережа (CNN) показує гарні результати у прогнозуванні витрат палива, особливо для складних залежностей між змінними. Її здатність

знаходити локальні шаблони робить її ефективною для подібних завдань. Однак для покращення точності слід розглянути додаткові шари об'єднання або оптимізацію гіперпараметрів.

2.2. Аналіз початкових даних для прогнозування витрат палива транспортними засобами під час транспортування зернових

Для аналізу та прогнозування витрат палива під час транспортування зернових культур було зібрано та підготовлено великий обсяг даних, що включає 13432 записи. Ці дані взято у ТОВ «Волинь-Зерно-Продукт» (м. Луцьк, Волинська область), яке фіксувало діяльність транспортних засобів за 2019...2021 роки. Кожен запис представляє один рейс транспортного засобу та містить такі параметри:

- 1) Транспортний засіб – марка та модель автомобіля;
- 2) Вантаж – тип перевезених зернових культур;
- 3) Відстань, км (загальна) – загальна відстань, пройдена транспортним засобом під час перевезення;
- 4) Фактичні витрати палива, літрів – обсяг використаного палива за весь рейс;
- 5) Витрати ДП, літрів/100км – витрати дизельного палива на 100 км пробігу;
- 6) Вантажообіг, т.км – добуток перевезеного вантажу на відстань, що відображає обсяг транспортної роботи;
- 7) Обсяг вантажу, тон – маса перевезеного зерна.

Для підготовки даних використовували Jupyter Notebook. Код писали із використанням Python 3.11. Фрагмент із початковими даними наведено в таблиці 2.1, що дозволяє ознайомитися із загальною структурою та форматуванням даних.

Таблиця 2.1 – Фрагмент із початковими даними для прогнозування витрат палива транспортними засобами під час транспортування зернових

	Транспортний засіб	Вантаж	Відстань, км (загальна)	Фактичні витрати палива, літрів	Витрати ДП, літрів/100км	Вантажообіг, т.км	Обсяг вантажу, тон
0	DAF FT XF 105	Пшениця	580	97.810	16.863793	1488.28	25.66
1	DAF CF85.430	Пшениця	62	11.400	18.387097	186.00	3.00
2	DAF FT XF 105	Ріпак	55	10.412	18.930909	1363.10	99.22
3	DAF FT XF 105	Ріпак	81	15.424	19.041975	2030.67	25.07
4	DAF FT XF 105	Пшениця	92	17.756	19.300000	149.04	1.62

Нами виконано аналіз типів даних, які використано для прогнозування витрат палива транспортними засобами під час транспортування зернових. Встановлено, що дані складаються з трьох основних типів:

- 1) object (текстові дані) – використовується для ідентифікації транспортних засобів і типів вантажу;
- 2) int64 (цілі числа) – використовується для відстаней у кілометрах;
- 3) float64 (числа з плаваючою комою) – для обсягу вантажу, витрат палива та вантажообігу.

Для кожного стовпця було проаналізовано кількість унікальних значень. Встановлено, що використовувалося 12 унікальних моделей транспортних засіб, 17 різновидів зернових культур, які транспортувалися на відстань, що має 576 унікальних значень і свідчить про різноманітність маршрутів. Пропущені значення в таблиці відсутні, що значно спрощує обробку даних. Характеристика початкових даних представлена у таблиці 2.2.

Таблиця 2.2 – Характеристика початкових даних для прогнозування витрат палива транспортними засобами під час транспортування зернових

	Відстань, км (загальна)	Фактичні витрати палива, літрів	Витрати ДП, літрів/100км	Вантажообіг, т.км	Обсяг вантажу, тон
count	13432.000000	13432.000000	13432.000000	13432.000000	13432.000000
mean	102.515932	46.380649	47.668457	2543.627098	46.026266
std	126.659470	53.375217	8.229414	3149.712167	76.117014
min	1.000000	0.293000	16.863793	1.000000	0.972000
25%	40.000000	19.492250	44.637849	999.945000	24.780000
50%	69.000000	32.304000	46.545254	1710.030000	25.820000
75%	105.000000	48.627500	49.859386	2629.200000	49.120000
max	1125.000000	473.202000	99.966667	28777.500000	1667.900000

Аналізуючи характеристики даних, можна зробити висновок, що середня відстань транспортування становить 102,52 км, із середнім значенням витрат палива 46,38 літрів за поїздку та середньою витратою дизельного палива 47,67 літрів/100км. Дані мають значну варіативність, що підтверджує великим стандартним відхиленням, наприклад, для відстані 126,66 км та витрати палива 53,38 літрів. Максимальні значення вказують на наявність довгих маршрутів 1125 км. Середній вантажообіг становить 2543.63 т·км, але притаманний розподіл, де максимальне значення сягає 28777.5 т·км. Обсяг вантажу що перевозиться, у середньому становить 46,03 тон, а максимальний обсяг вантажу – 1667,9 тон. Це свідчить про те, що використання різних типів транспортних засобів і вантажів. Ці дані демонструють значну різноманітність умов транспортування, що потрібно врахувати під час прогнозування витрат палива.

2.3. Результати визначення взаємозв'язків між початковими даними

Для покращення розуміння структури даних і взаємозв'язків між змінними були побудовані наступні графіки. Нами побудовано залежність витрат палива від відстані (рис. 2.4).

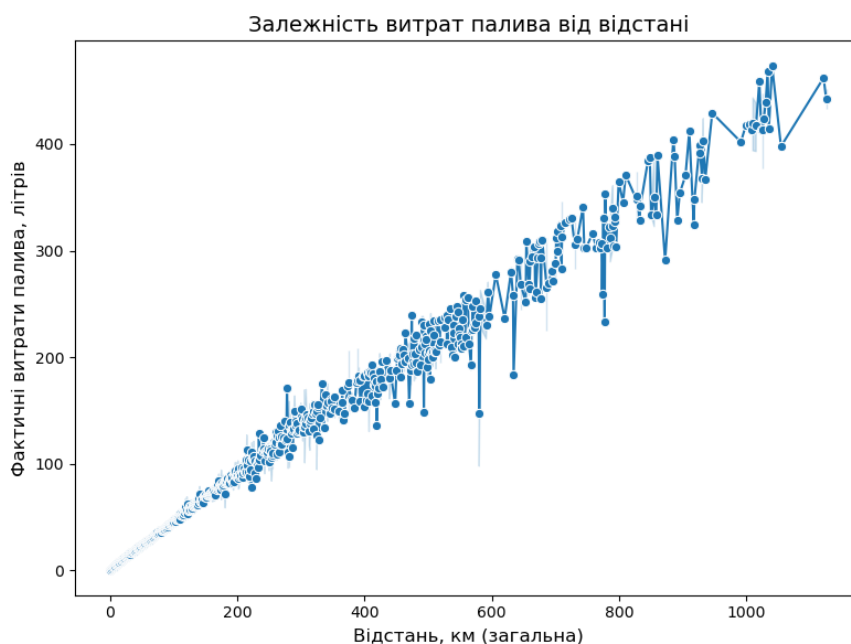


Рисунок 2.4 – Залежність витрат палива від відстані

Встановлено, витрати палива мають мінливу тенденцію до зростання зі збільшенням відстані, що очікувано для транспортних засобів.

Також нами побудовано гістограму зміни вантажообігу для різних типів вантажів (рис. 2.5).

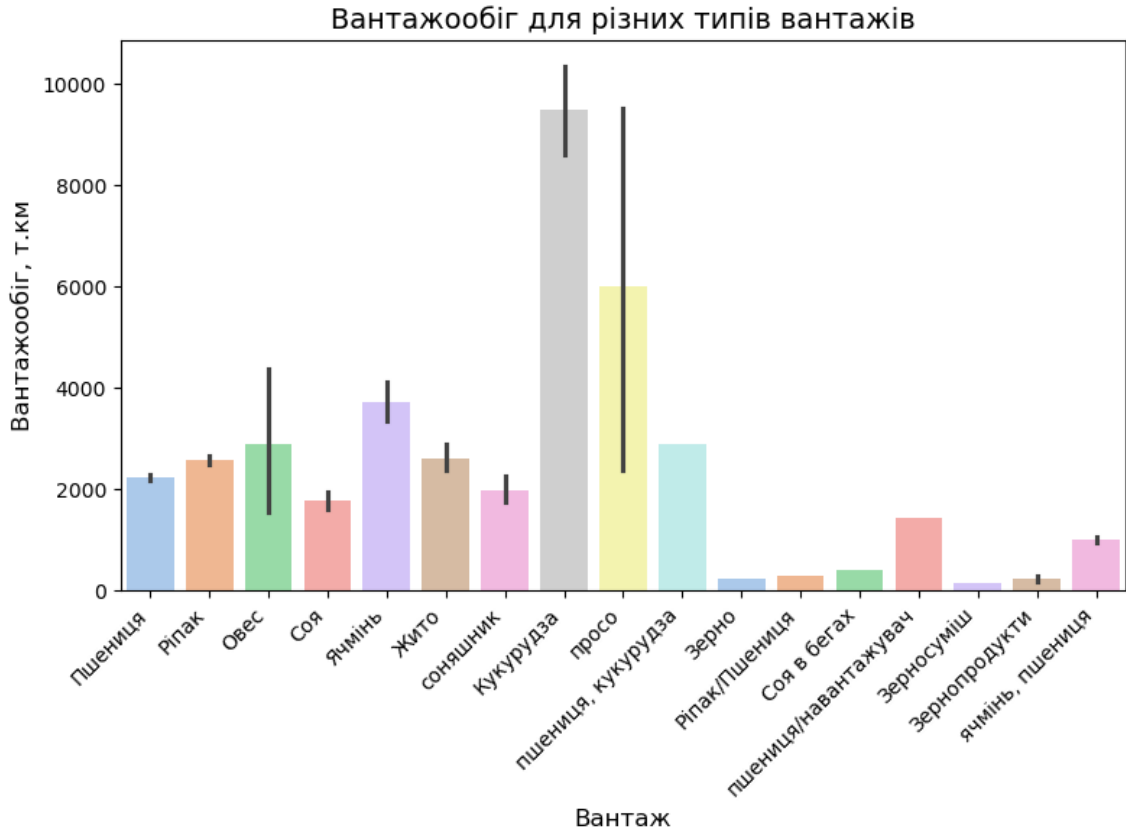


Рисунок 2.5 – Гістограма зміни вантажообігу для різних типів вантажів

Отримана гістограма показує, як різні типи вантажів впливають на вантажообіг. Видно, що вантажообіг найбільший для кукурудзи 8500...9300 т.км, що можна пояснити його більшою вагою на одиницю обсягу. Найменше транспортувалося зерноsumішей та зернопродуктів.

У подальшому нами побудовано розподіл витрат дизельного палива (рис. 2.6).

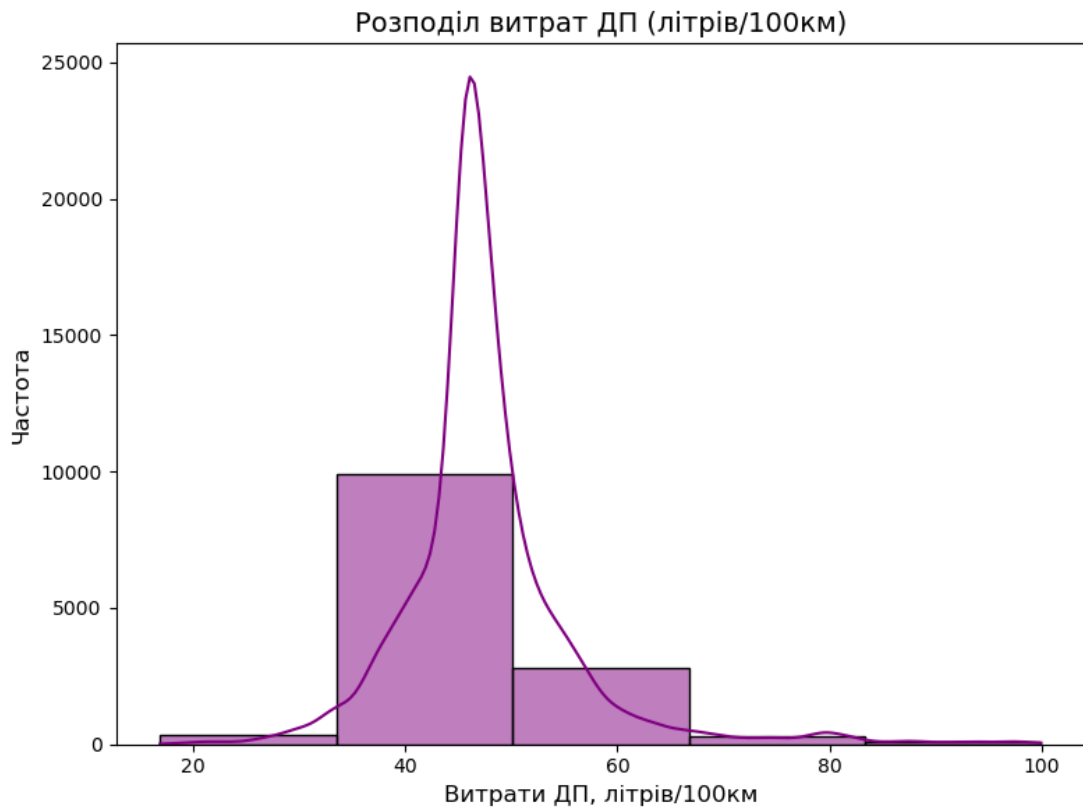


Рисунок 2.6 – Розподіл витрат дизельного палива, літрів/100км

Нами побудовано залежність фактичних витрат палива від вантажообігу (рис. 2.7).

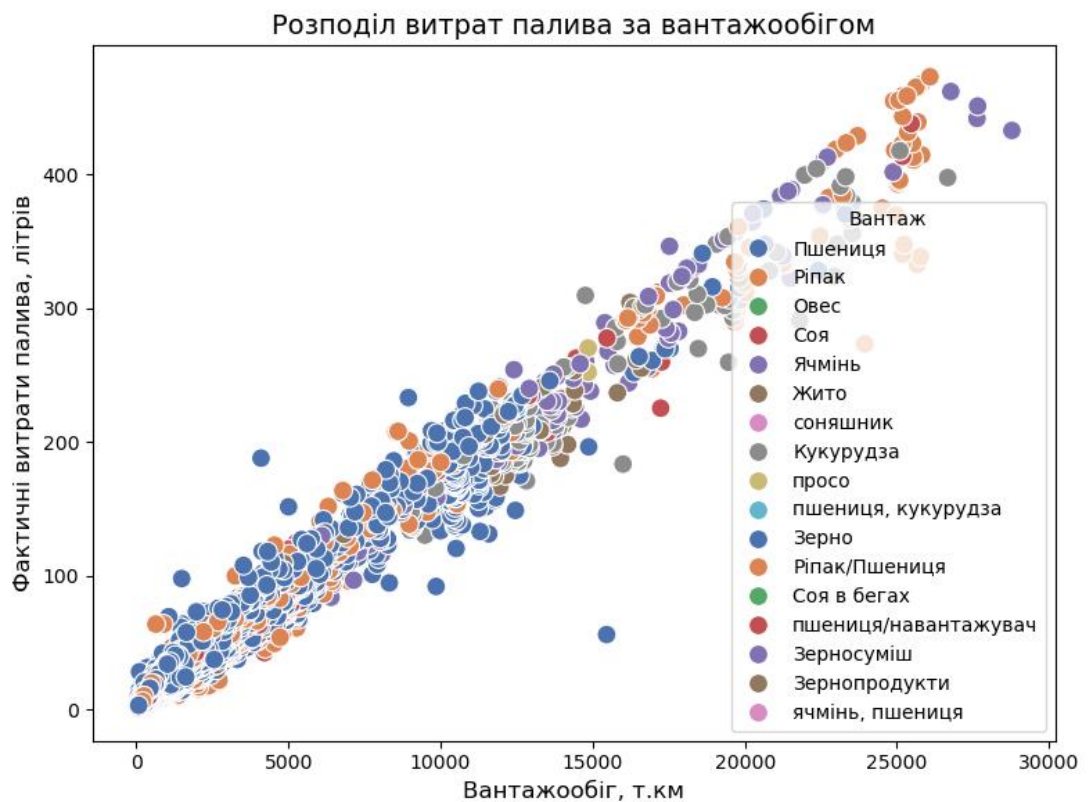


Рисунок 2.7 – Залежність фактичних витрат палива від вантажообігу

Отриманий розподіл (рис. 2.6) показує, що цей показник є мінливим і найбільші витрати дизельного палива припадають на діапазон – 38..50 літрів/100км. Розподіл близький до нормального, з кількома аномальними значеннями, що можуть вимагати подальшого аналізу.

Встановлено, що для всіх видів вантажів витрати палива залежать від вантажообігу. Відображена тенденція зростання витрат із збільшенням вантажообігу описується лінійною залежністю із мінливістю та окремими аномальними екземплярами даних. Нами побудована кореляційна матриця взаємозв'язків між показниками транспортування зернових (рис. 2.8).

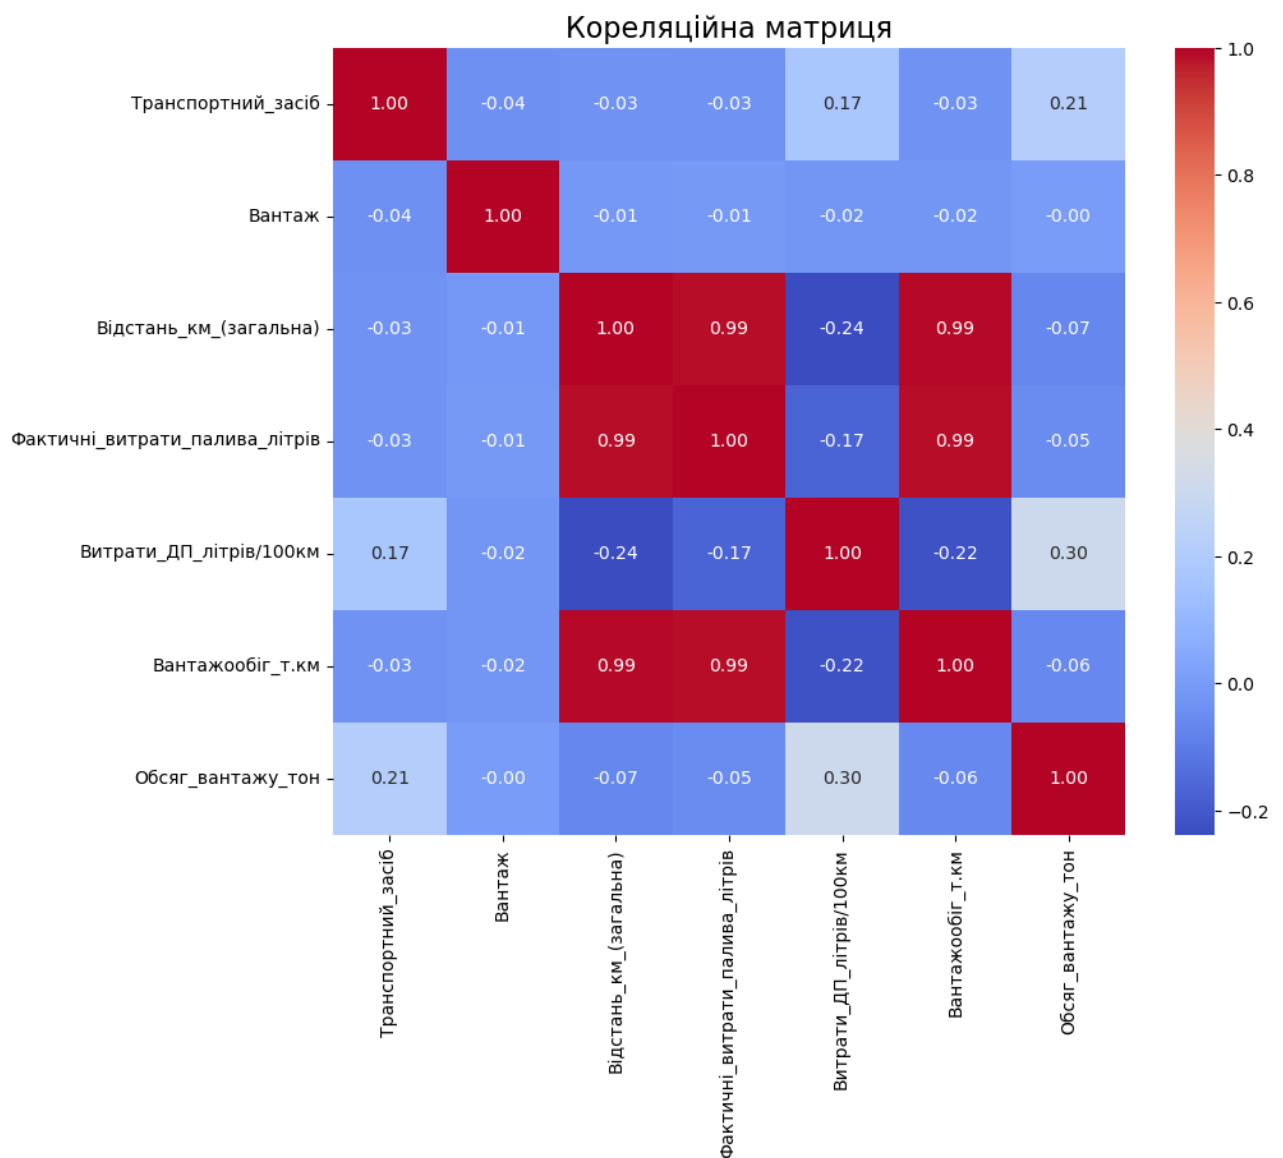


Рисунок 2.8 – Кореляційна матриці взаємозв'язків між показниками транспортування зернових

Аналіз кореляційної матриці показав, що найбільший вплив на витрати палива має відстань транспортування – кореляція відстанню та фактичними витратами палива становить 0,989, що підтверджує майже лінійну залежність. Схожий сильний зв'язок між відстанню та вантажообігом – 0,995, свідчить про те, що транспортна робота прямо пропорційна відстані. Витрати палива на 100 км мають слабку негативну кореляцію з відстанню (-0.239), що свідчить про більшу ефективність транспортних засобів на довших маршрутах. Тип транспортного засобу також впливає на витрати палива. Кореляція між маркою транспортного засобу і витратами палива літрів/100км становить – 0,169. Однак обсяг вантажу показав низьку кореляцію з витратами палива (-0,053), а тип вантажу практично не впливає на інші показники (усі кореляції менше 0,04). Ці кількісні показники свідчать про потребу врахування відстані та транспортної роботи для точного прогнозування витрат палива.

Збір та попередня обробка даних дозволили отримати повноцінний набір даних для подальшого аналізу. Графіки показали основні тенденції, що можуть бути використані для побудови прогнозних моделей. Надалі планується застосування різних видів нейромереж для прогнозування витрат палива, використовуючи наявні дані.

РОЗДІЛ 3.

РЕЗУЛЬТАТИ ОБҐРУНТУВАННЯ МОДЕЛІ ТА СИСТЕМИ ПІДТРИМКИ ПРИЙНЯТТЯ РІШЕНЬ ДЛЯ ПРОГНОЗУВАННЯ ВИТРАТ ПАЛЬНОГО ПІД ЧАС ТРАНСПОРТУВАННЯ ЗЕРНОВИХ

3.1. Створення навчальних та тестових вибірок

Нами здійснено процес підготовки даних для побудови моделі прогнозування витрат палива. Розглянемо основні етапи підготовки даних, до яких належить очищення, кодування категоріальних змінних, нормалізацію числових даних та поділ на навчальні і тестові вибірки.

На першому етапі було перевірено типи даних, а також виконано приведення числових змінних до відповідного формату за допомогою методу `pd.to_numeric` (рис. 3.1).

```
# 1. Очищення даних: Приведення числових колонок до правильного типу
df["Вантажообіг_т.км"] = pd.to_numeric(df["Вантажообіг_т.км"], errors="coerce")
df["Фактичні_витрати_палива_літрів"] = pd.to_numeric(df["Фактичні_витрати_палива_літрів"], errors="coerce")
df["Обсяг_вантажу_тон"] = pd.to_numeric(df["Обсяг_вантажу_тон"], errors="coerce")
df["Витрати_ДП_літрів/100км"] = pd.to_numeric(df["Витрати_ДП_літрів/100км"], errors="coerce")
df["Відстань_км_(загальна)"] = pd.to_numeric(df["Відстань_км_(загальна)"], errors="coerce")

# Видалення рядків з пропущеними значеннями
df.dropna(inplace=True)
```

Рисунок 3.1 – Фрагмент коду для приведення числових колонок до правильного типу та видалення рядків з пропущеними значеннями

У подальшому нами були видалені всі рядки з пропущеними значеннями. Це забезпечило чистоту даних і коректність роботи моделі.

Для перетворення категоріальних змінних («Транспортний_засіб» і «Вантаж») у числовий формат використовувалися `LabelEncoder` нами написано відповідний код (рис. 3.2).

```

# 2. Кодування категоріальних даних
# Кодування транспортного засобу
le_transport = LabelEncoder()
df["Транспортний_засіб"] = le_transport.fit_transform(df["Транспортний_засіб"])

# Кодування вантажу
le_vantazh = LabelEncoder()
df["Вантаж"] = le_vantazh.fit_transform(df["Вантаж"])

```

Рисунок 3.2 – Фрагмент коду для кодування категоріальних змінних

Кодування категоріальних змінних Це дозволяє нейромережевим моделям правильно обробляти нечислові змінні.

Для числових змінних було виконано нормалізацію в діапазоні від 0 до 1 за допомогою MinMaxScaler (рис. 3.3).

```

# 3. Нормалізація числових даних
scaler = MinMaxScaler()
numerical_columns = [
    "Відстань_км_(загальна)",
    "Витрати_ДП_літрів/100км",
    "Вантажообіг_т.км",
    "Обсяг_вантажу_тон"
]
df[numerical_columns] = scaler.fit_transform(df[numerical_columns])

```

Рисунок 3.3 – Фрагмент коду для кодування для нормалізації числових даних

Написаний код забезпечує рівномірний вплив різних змінних на навчання моделі.

Після підготовки даних таблиця була розділена на набір ознак (X) і цільову змінну (y) (рис. 3.4).

```

# 4. Розділення на ознаки (X) і мітки (y)
X = df.drop(columns=["Фактичні_витрати_палива_літрів"]) # Все, крім залежної змінної
y = df["Фактичні_витрати_палива_літрів"] # Залежна змінна

# 5. Розділення на навчальну та тестову вибірки
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)

# Перевірка готовності даних
print("Розмір навчальної вибірки:", X_train.shape)
print("Розмір тестової вибірки:", X_test.shape)

```

Рисунок 3.4 – Фрагмент коду для кодування для нормалізації числових даних

Для навчання та тестування моделі дані були розділені у співвідношенні 80:20 за допомогою `train_test_split`. Відповідно набір даних передбачає розмір навчальної вибірки – 80%, а тестової – 20%.

В результаті підготовки даних створено навчальну та тестову вибірки, які відповідають усім вимогам для подальшого навчання моделей. Очищення, кодування та нормалізація даних сприяють коректному функціонуванню алгоритмів машинного навчання, а розділення даних гарантує об'єктивність оцінки точності моделей.

3.2. Навчання нейромережових моделей

Для прогнозування витрат палива транспортними засобами було використано три нейромережові моделі: багатошарова перцептронна модель (MLP); рекурентна нейромережа (LSTM) та згортова нейромережа (CNN). Нами описано основні етапи навчання моделей, оцінку їх точності та результати аналізу.

Фрагмент коду для побудови та навчання багатошарового перцептронна (MLP) представлено на рис. 3.5.

```
# 1. MLP Model
mlp_model = Sequential([
    Dense(64, activation='relu', input_shape=(X_train.shape[1],)),
    Dense(64, activation='relu'),
    Dense(1)
])
mlp_model.compile(optimizer='adam', loss='mse', metrics=['mae'])

print("Training MLP Model...")
mlp_model.fit(X_train, y_train, epochs=20, batch_size=32, verbose=0)
results.append(evaluate_model(mlp_model, X_test, y_test, "MLP"))
```

Рисунок 3.5 – Фрагмент коду для навчання багатошарового перцептронна (MLP)

MLP (Multilayer Perceptron) є простою повнозв'язною нейромережею, що складається з трьох шарів:

- 1) вхідний шар із розмірністю, що відповідає кількості ознак у вхідних даних;
- 2) два приховані шари, кожен із 64 нейронами та функцією активації ReLU;
- 3) вихідний шар із одним нейроном для регресійного прогнозування.

Параметри навчання моделі передбачають використання оптимізатора Adam, функції втрат Mean Squared Error (MSE), метрики Mean Absolute Error (MAE), кількості епох – 20 та розміру батчу – 32.

Фрагмент коду для побудови та навчання рекурентної нейромережі (LSTM) представлено на рис. 3.6.

```
# 2. LSTM Model (requires reshaped input)
X_train_lstm = X_train.values.reshape((X_train.shape[0], 1, X_train.shape[1]))
X_test_lstm = X_test.values.reshape((X_test.shape[0], 1, X_test.shape[1]))

lstm_model = Sequential([
    LSTM(64, activation='tanh', input_shape=(X_train_lstm.shape[1], X_train_lstm.shape[2])),
    Dense(1)
])
lstm_model.compile(optimizer='adam', loss='mse', metrics=['mae'])

print("Training LSTM Model...")
lstm_model.fit(X_train_lstm, y_train, epochs=20, batch_size=32, verbose=0)
results.append(evaluate_model(lstm_model, X_test_lstm, y_test, "LSTM"))
```

Рисунок 3.6 – Фрагмент коду для навчання рекурентної нейромережі (LSTM)

LSTM (Long Short-Term Memory) є типом рекурентних нейромереж, здатних враховувати послідовність даних. У цьому випадку дані було перетворено для включення часових залежностей. Дані було перетворено у форму тривимірного масиву – зразки, час, ознаки. Модель складається з одного шару LSTM із 64 нейронами та вихідного шару з одним нейроном.

Параметрами навчання є оптимізатор Adam, функція втрат MSE, метрика MAE, кількість епох – 20 та розмір батчу – 32.

Фрагмент коду для побудови та навчання згорткової нейромережі (CNN) представлено на рис. 3.7. CNN (Convolutional Neural Network) була застосована для обробки вхідних даних у формі тривимірного масиву. Дані було перетворено у форму – зразки, ознаки, канали.


```

# 3. CNN Model
X_train_cnn = X_train.values.reshape((X_train.shape[0], X_train.shape[1], 1))
X_test_cnn = X_test.values.reshape((X_test.shape[0], X_test.shape[1], 1))

cnn_model = Sequential([
    Conv1D(32, kernel_size=2, activation='relu', input_shape=X_train_cnn.shape[1], 1)),
    Flatten(),
    Dense(64, activation='relu'),
    Dense(1)
])
cnn_model.compile(optimizer='adam', loss='mse', metrics=['mae'])

print("Training CNN Model...")
cnn_model.fit(X_train_cnn, y_train, epochs=20, batch_size=32, verbose=0)
results.append(evaluate_model(cnn_model, X_test_cnn, y_test, "CNN"))

```

Рисунок 3.7 – Фрагмент коду для навчання рекурентної нейромережі (CNN)

Модель рекурентної нейромережі (LSTM) складається із згорткового шару (32 фільтри, ядро розміром 2), шару Flatten для згортки даних у вектор та двох повнозв'язних шарів для прогнозування.

Параметри навчання є оптимізатор Adam, функція втрат MSE, метрика MAE, кількість епох – 20 та розмір батчу – 32.

Для оцінки точності прогнозування було використано такі метрики:

- ✓ Mean Squared Error (MSE) – середнє квадратичне відхилення;
- ✓ Mean Absolute Error (MAE) – середнє абсолютне відхилення;
- ✓ R² Score – коефіцієнт детермінації.

При цьому було написано код функції evaluate_model (3.8).

```

# Модифікована функція для оцінки моделі з додатковими метриками
def evaluate_model(model, X_test, y_test, model_name):
    predictions = model.predict(X_test)
    mse = mean_squared_error(y_test, predictions)
    mae = mean_absolute_error(y_test, predictions)
    r2 = r2_score(y_test, predictions)
    print(f"{model_name} Evaluation:")
    print(f"Mean Squared Error (MSE): {mse:.4f}")
    print(f"Mean Absolute Error (MAE): {mae:.4f}")
    print(f"R^2 Score: {r2:.4f}")
    return {"Model": model_name, "MSE": mse, "MAE": mae, "R2": r2}

```

Рисунок 3.8 – Фрагмент коду функції evaluate_model для оцінки точності прогнозування

Отримані результати дали можливість побудувати гістограми із кількісними значеннями метрик для оцінки точності нейромережових моделей прогнозування витрат пального під час транспортування зернових (рис. 3.9).




Рисунок 3.9 – Гістограми із кількісними значеннями метрик для оцінки точності нейромережових моделей прогнозування витрат пального під час транспортування зернових

Результати оцінювання трьох моделей нейромереж показали різну точність прогнозування витрат палива. Багатошарова перцептронна модель (MLP) продемонструвала високу точність із $MSE=47.18$, $MAE=3.93$ та коефіцієнтом детермінації $R^2=0.981$, що свідчить про ефективне моделювання залежності. Рекурентна нейромережа (LSTM) досягла меншої точності з $MSE=304.089$, $MAE=4.7908$ та $R^2=0.877$, вказуючи на її обмежену ефективність. Найкращі результати показала згорткова нейромережа (CNN) із найменшим $MSE=37.044$, найнижчим $MAE=2.665$ та найвищим $R^2=0.985$, що робить її оптимальним вибором для прогнозування витрат палива серед розглянутих моделей.

3.3. Архітектура системи підтримки прийняття рішень для прогнозування витрат пального під час транспортування зернових

Система підтримки прийняття рішень для прогнозування витрат пального під час транспортування зернових базується на сучасній модульній архітектурі з можливістю ефективною заміною функціональних блоків без зміни загальної

структури системи. Відповідно до сучасних підходів до розробки програмної системи окремі функціональні блоки об'єднуються в підсистеми за шаблонами функціональної подібності (рис. 3.10).

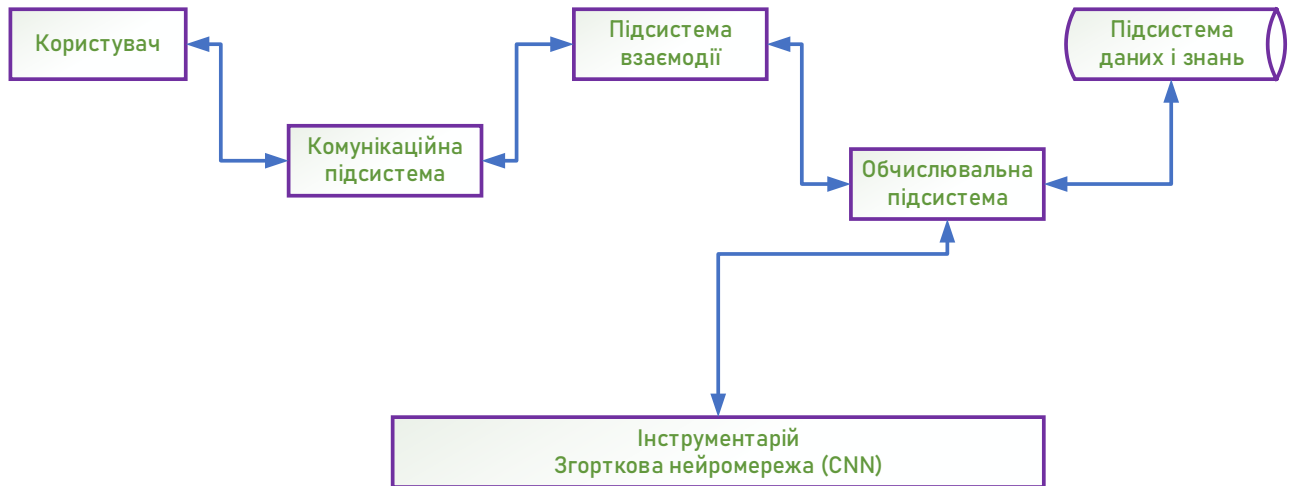


Рисунок 3.10 – Архітектура системи підтримки прийняття рішень для прогнозування витрат пального під час транспортування зернових

Запропонована архітектура системи підтримки прийняття рішень для прогнозування витрат пального під час транспортування зернових передбачає інтеграцію таких п'яти підсистем:

- 1) база даних і знань (ДКВ);
- 2) обчислювальна підсистема;
- 3) комунікаційна підсистема, що забезпечує зв'язок з різними пристроями;
- 4) підсистема взаємодії;
- 5) підсистема інструментарію додатків.

Перші чотири підсистеми утворюють виконуваний компонент для системи підтримки прийняття рішень для прогнозування витрат пального під час транспортування зернових. Остання (п'ята) підсистема інтегрує набір алгоритмів, які реалізують конкретні обчислювальні процедури, пов'язані з задачею, що розв'язується.

Підсистема база даних і знань ДКВ містить усі необхідні для ефективного функціонування системи підтримки прийняття рішень для прогнозування витрат пального під час транспортування зернових ресурси знань і даних. Вона має такі основні елементи, що утворюють підсистему:

- ✓ формати читання та запису даних для введення інформації в систему та виведення проміжних і кінцевих результатів;
- ✓ критерії оцінки якості моделей і прогнозних оцінок;
- ✓ дані щодо процесу транспортування зернових;
- ✓ налаштування даних для системи та її окремих елементів;
- ✓ проміжні та кінцеві результати обчислень тощо.

Обчислювальна підсистема реалізує набір основних прийомів попередньої обробки вхідних даних (блок попередньої обробки даних). Кожна техніка вимагає додаткових параметрів для налаштування. Існує можливість послідовного застосування кількох методів обробки даних для одних і тих же даних, що забезпечує реалізацію ефективних багатоетапних процедур попередньої обробки.

Блок синтезу моделі використовує спеціальні процедури вивчення параметрів моделі для виконання синтезу моделі з використанням даних навчання з ДКВ. Підсистема організована таким чином, що її функціонування не залежить від типу задачі що вирішується. Такий підхід забезпечує можливість сумісності системи з довільною обчислювальною процедурою, взятою з інструментальної підсистеми.

3.4. Розробка вікна користувача системи підтримки прийняття рішень для прогнозування витрат пального під час транспортування зернових

Для зручності взаємодії користувачів із системою підтримки прийняття рішень було розроблено графічний інтерфейс, який дозволяє швидко вводити

необхідні параметри для прогнозування витрат пального транспортними засобами під час перевезення зернових культур, отримувати результати, зберігати їх у файл та очищати введені дані. Основна увага приділена ергономіці, естетиці дизайну та функціональності (рис. 3.11).

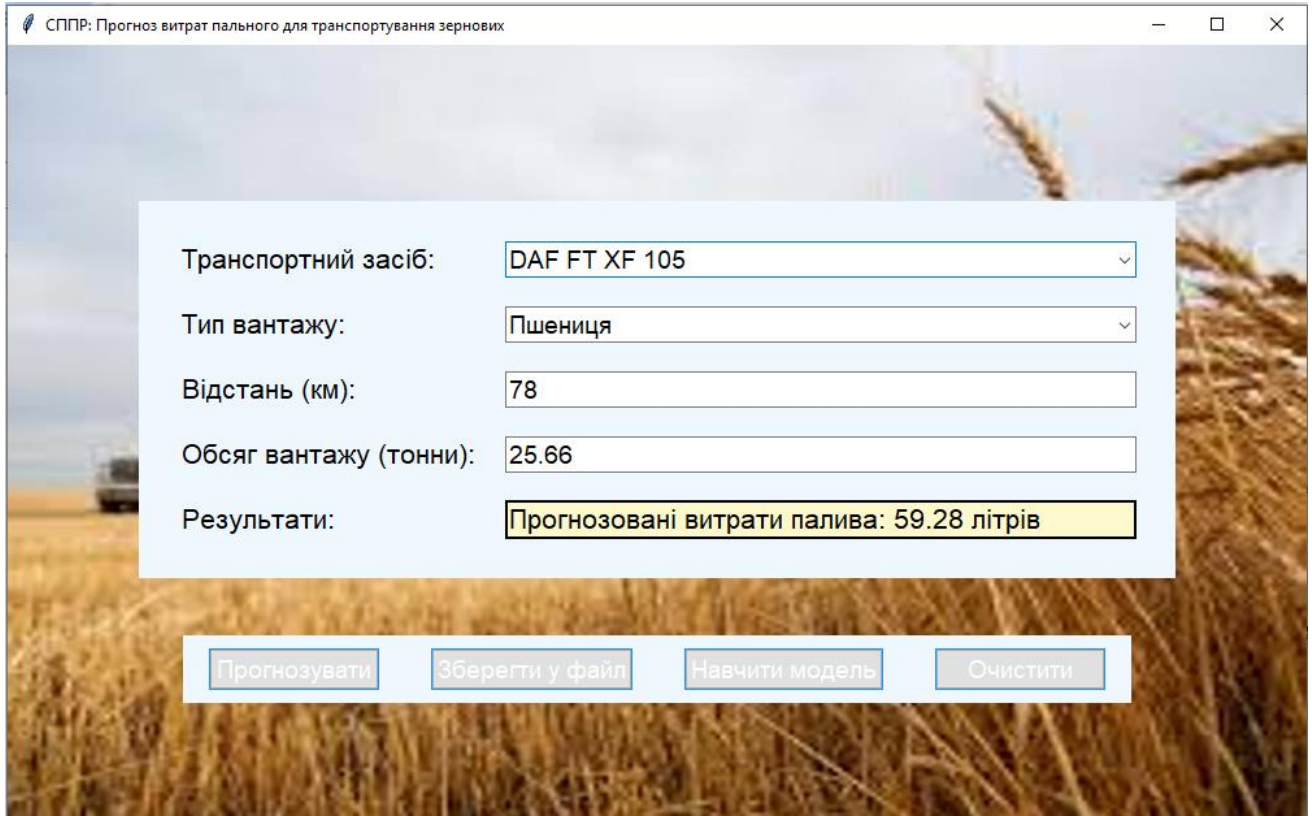


Рисунок 3.11 – Вікно користувача системи підтримки прийняття рішень для прогнозування витрат пального під час транспортування зернових

Розроблене вікно має розміри 1000x600, що забезпечує достатньо місця для розміщення всіх елементів інтерфейсу без перенасичення простору. Для покращення візуального сприйняття було додано фон у вигляді зображення, яке масштабувалося під розмір вікна. Це створює естетично привабливий вигляд, покращує зручність використання та знижує візуальне навантаження.

Користувач має можливість ввести наступні параметри для прогнозування:

✓ Транспортний засіб – вибір із випадуючого списку (наприклад, «DAF FT XF 105», «DAF CF85.430»);

- ✓ Тип вантажу – вибір із випадającego списку (наприклад, «Пшениця», «Ріпак», «Кукурудза»);
- ✓ Відстань (км) – числове поле для введення значення відстані, яку потрібно подолати;
- ✓ Обсяг вантажу (тон) – числове поле для введення ваги вантажу.

Всі введення відображаються в структурованій формі та перевіряються на коректність. Якщо дані некоректні, користувач отримує повідомлення про помилку.

Результати розрахунків відображаються в окремому текстовому полі з підписом «Результати», яке має жовтий фон та рамку для зручності виділення інформації.

Код програми базується на бібліотеках TKinter для створення інтерфейсу та PIL (Pillow) для роботи із зображеннями. Функціональність передбачає перевірку коректності введених значень. Взаємодію з користувачем через діалогові вікна (наприклад, для збереження файлу або повідомлення про помилку). Виконання необхідних розрахунків і дій, таких як збереження результатів.

Розроблене вікно користувача є зручним і функціональним інструментом для роботи з системою підтримки прийняття рішень. Воно дозволяє автоматизувати процес прогнозування витрат пального для транспортування зернових, надаючи користувачам можливість швидко отримати результати, зберігати їх і легко очищувати поля для введення нових даних.

РОЗДІЛ 4.

ОХОРОНА ПРАЦІ ТА БЕЗПЕКА У НАДЗВИЧАЙНИХ СИТУАЦІЯХ

4.1. Аналіз небезпечних чинників під час створення системи підтримки прийняття рішень

Працівники, задіяні на роботах, пов'язаних з періодичною або постійною роботою за комп'ютером, піддаються впливу факторів виробничої небезпеки, основними з яких є:

1. Фізичні

- Підвищений рівень напруги в електричному ланцюзі, замикання якої може пройти через тіло працюючого.
- Підвищений рівень рентгенівського випромінювання.
- Підвищений рівень ультрафіолетового випромінювання.
- Підвищений рівень інфрачервоного випромінювання.
- Можливість ураження статичною електрикою.
- Запиленість повітря робочого приміщення.
- Підвищений вміст важких (+) аероіонів.
- Нерівномірний розподіл яскравості в полі зору.
- Підвищений рівень пульсації світлового потоку.

2. Хімічні.

- Підвищений вміст у повітрі вуглекислого газу, озону, аміаку, фенолу, формальдегіду та інших речовин.

3. Психофізіологічні.

- Напруга зору.
- Напруга пам'яті.
- Напруга уваги.
- Тривале статичне напруження.
- Відносно великий обсяг інформації, що обробляється в одиницю часу.

- Монотонність праці в окремих випадках.
- Нераціональна організація робочого місця.

До основних шкідливих факторів при роботі з комп'ютером відносять: тривале сидяче положення, електромагнітне випромінювання, навантаження на зір, перевантаження кистьових суглобів, можливість захворювань органів дихання, алергії, порушення нормального перебігу вагітності та ін ^ Тривале сидяче положення приводить до напруги м'язів шиї, голови, рук і плечей, остеохондрозу, у дітей - ще й до сколіозу.

Тривале сидяче положення ще приводить до застою крові в тазових органах і, як наслідок, до простатиту й геморою. Малорухливий спосіб життя призводить до ожиріння. Остеохондроз виникає при порушенні міжхребцевих дисків, яке призводить до випинання в яку або сторону (грижі міжхребцевого диска). Грижа може зашкодити спинний мозок і нервові відростки. Наслідки можуть бути найрізноманітнішими, від болів в спині і кінцівках, до паралічу кінцівок і смерті. Одна з поширених причин остеохондрозу - дистрофія м'язів спини.

Людина, що проводить в основному сидячий спосіб життя, цілком може захворіти остеохондрозом. Ознаки початку захворювання: дискомфорт у спині та больові відчуття, головні болі, порушення роботи внутрішніх органів. До факторів ризику захворювання гемороєм відносять: сидячий спосіб життя, ожиріння, надмірне вживання копчених, гострих, солоних і пряних продуктів, запальні захворювання малого таза та ін Ожиріння виникає через нераціональне харчування, малорухомого і в тому числі сидячого способу життя, неадекватної реакції на стресові ситуації, надмірно довгий сон, застосування гормональних препаратів, перевантаження організму харчовими жирами тощо.

Ожиріння призводить до збільшення навантаження на серце, зміни конфігурації та положення серця в грудній порожнині, підвищення вмісту холестерину в крові, в результаті він відкладається на стінках судин (атеросклероз). Підвищений скупчення жиру всередині грудної порожнини

впливає на роботу органів дихання, що призводить до появи задишки та гіпоксії органів і тканин.

Навантаження на зір. Людське око реагує на найдрібнішу вібрацію тексту і на мерехтіння екрану. М'язи ока, керуючі кришталиком, перебувають у постійній напрузі, що обов'язково призводить до втрати гостроти зору. Немаловажне значення для профілактики зорових дисфункцій надають: правильний чи рекомендований підбір кольору, шрифтів, компоновки вікон у використовуваних додатках, орієнтація дисплея монітора. Тривала робота за комп'ютером – це величезне навантаження на очі, оскільки зображення на моніторі складається не з безперервних ліній, як на папері, а з окремих точок, які світяться і мерехтять. У користувача неминуче погіршується зір, очі починають слізотитися, з'являється головний біль, втома, зображення двоїться і спотворюється.

4.2. Моделювання виникнення травм та аварій

Метод логічного моделювання процесів формування, виникнення небезпечних ситуацій та їх наслідків доцільно застосовувати для аналізу існуючих або потенційних небезпек, що виявленні під час обстеження робочих місць, окремих видів комп'ютерної техніки. Але, як показали дослідження, будь-яка аварія може бути наслідком однієї чи багатьох потенційних небезпечних ситуацій або їх поєднання. Тому метод логічного моделювання не може бути застосований для моделювання складних аварій і катастроф. Обчислення рівняння безпеки можна спрямувати на удосконалення конструкції комп'ютерної техніки, на зниження їх безпеки, а також вживати термінових заходів для першочергового усунення небезпек з більш високим рівнем.

Аналіз умов, обставин та причин різних аварій, виробничих травм та деяких катастроф показав, що процеси формування та виникнення цих явищ

можна заздалегідь моделювати, застосовуючи метод побудови «дерева відмов» та помилок оператора комп'ютерної техніки. Так, побудовані операторні або логіко-імітаційні моделі травм при роботі із комп'ютерною технікою.

Аналіз моделей процесів формування й виникнення аварій, травм показав, що вони повністю імітують усі процеси та явища, що беруть участь у їх зародженні й виникненні. У зв'язку з цим, моделі, що отримали назву «дерево відмов комп'ютерної техніки і помилок оператора» можна назвати імітаційними. А оскільки виникнення кожної наступної події знаходять шляхом логічного аналізу попередніх, то для кращого розуміння суті таких моделей, їх можна назвати логічно-імітаційними.




Рис. 4.1. Схема побудови логіко-імітаційної моделі:

1 – головна подія; 2-5 – проміжні події; 6 – базова подія.

Основні принципи побудови моделі такі. Виявляється комп'ютеризований процес, на якому вже були раніше або можуть статися аварії, виробничі травми чи катастрофи. За своєю формою модель нагадує крону дерева, тому вона і одержала назву «дерево відмов і помилок». Кінцеві події називають базовими.

Для побудови логіко-імітаційних моделей застосовують різні символи, що характеризують ті чи інші події. Як правило, побудова моделі починається з головної події, а наступні розміщують зверху вниз, аж до базових подій (рис. 4.1).

Кожен блок рисунку, позначений відповідним номером, означає подію або окремий етап побудови моделі:

- 1 – відмова (аварія, травма) системи – головна подія;
- 2 – послідовність подій, що приводять до відмови системи;
- 3 – послідовність подій зображується за допомогою логічних операторів;
- 4 – усі вхідні і вихідні події, що входять до моделі, зображуються у вигляді прямокутників з відповідними написами всередині;
- 5 – послідовний підхід до базових подій, частоти виникнення яких відомі;
- 6 – базові події зображують у вигляді кружечків з написами всередині, вони є межею аналізу побудованої моделі.

4.3. Розробка заходів щодо безпеки у надзвичайних ситуаціях

Забезпечення безпеки населення у надзвичайних ситуаціях під час разі загрози та виникнення надзвичайних ситуацій є одним з найважливіших завдань, яке покладається на службу з охорони праці окремої ІТ-компанії чи організації.

Захист населення базується на державній системі заходів, що забезпечують виконання організаційних, інженерно - технічних, санітарне - гігієнічних та інших заходів в сфері запобігання та ліквідації наслідків надзвичайних ситуацій.

До надзвичайних ситуацій природного характеру, які можуть виникнути на території господарства належить: пожежа, ураган, смерч, землетрус, великі опади дощів.

З метою захисту населення, зменшення втрат та шкоди економіці в разі виникнення надзвичайних ситуацій має проводитись спеціальний комплекс заходів, а саме:

- оповіщення та інформування населення про надзвичайну ситуацію, яка може виникнути;
- спостереження і контроль за довкіллям, продуктами харчування і водою;
- створення захисних споруд та укриття в них усього населення відповідно до приналежності (працююча зміна, населення, яке проживає в небезпечній зоні);
- проведення медичного захисту для зменшення ступеня ураження людей, своєчасне надання допомоги та лікування.

РОЗДІЛ 5.

ВИЗНАЧЕННЯ ЕКОНОМІЧНОЇ ЕФЕКТИВНОСТІ СИСТЕМИ ПІДТРИМКИ ПРИЙНЯТТЯ РІШЕНЬ ДЛЯ ПРОГНОЗУВАННЯ ВИТРАТ ПАЛЬНОГО ПІД ЧАС ТРАНСПОРТУВАННЯ ЗЕРНОВИХ

Економічна ефективність системи підтримки прийняття рішень (СППР) оцінюється на основі потенційної економії пального, зниження витрат на транспортування, а також часу, який витрачається на планування маршрутів. Основні показники економічної ефективності включають:

- 1) економію пального (E_{fuel}), яка розраховується у літрах;
- 2) економію витрат (C_{fuel}), яка визначається як добуток економії пального на середню вартість 1 літра пального.
- 3) економічну вигоду (W), яка враховує зниження витрат на транспортування та потенційну оптимізацію логістичних процесів.

Таблиця 5.1 – Початкові дані визначення ефективності системи підтримки прийняття рішень для прогнозування витрат пального під час транспортування зернових

Транспортний засіб	Витрати пального, літрів	Прогнозовані витрати пального, літрів	Економія пального, літрів	Середня вартість пального, грн/л	Вартість впровадження СППР, грн
DAF FT XF 105	98.0	95.5	2.5	55	12000
MAN TGX 18.500	67.5	65.0	2.5	55	
Volvo FH	112.3	108.1	4.2	55	
Scania R450	54.2	52.5	1.7	55	
Iveco Stralis	72.8	70.1	2.7	55	

Формула для розрахунку загальної економії витрат:

$$C_{fuel} = E_{fuel} \cdot P_{fuel} , \quad (5.1)$$

де P_{fuel} – середня вартість 1 літра пального (приймаємо, $P_{fuel} = 55$ грн/л).

Формула для розрахунку економічної вигоди:

$$W = C_{fuel} - C_{system} , \quad (5.2)$$

де C_{system} – вартість впровадження та підтримки СППР.

Для прикладу аналізу використовується автопарк, що складається з 5 автомобілів. Дані наведено в таблиці 5.1.

Розрахунок економії пального виконаємо за формулою:

$$E_{fuel} = \sum_{i=1}^n (y_i - \hat{y}_i) , \quad (5.3)$$

де y_i – фактичні планові витрати пального, \hat{y}_i – прогнозовані витрати.

$$E_{fuel} = (98.0 - 95.5) + (67.5 - 65.0) + (112.3 - 108.1) + \\ + (54.2 - 52.5) + (72.8 - 70.1) = 2.5 + 2.5 + 4.2 + 1.7 + 2.7 = 13.6 \text{ л.}$$

Таблиця 5.2 – Результати визначення економічної ефективності системи підтримки прийняття рішень для прогнозування витрат пального під час транспортування зернових

Показник	Одиниця виміру	Значення
Загальна економія пального впродовж доби	літрів	13.6
Середня економія на автомобіль впродовж доби	літрів	2.72
Загальна економія витрат впродовж доби	грн	748
Тривалість сезону транспортування зернових	діб	35
Вартість впровадження СППР	грн	12000
Економічна вигода	грн	14180
Термі окупності капіталовкладень	років	0,85

Виконаємо розрахунок економії коштів:

$$C_{fuel} = E_{fuel} \cdot P_{fuel} = 13.6 \cdot 55 = 748 \text{ грн.}$$

Виконаємо розрахунок економічної вигоди впродовж періоду транспортування $N_d=35$ днів:

$$W = C_{fuel} \cdot N_d - C_{system} = 748 \cdot 35 - 12000 = 14180 \text{ грн.}$$

Отримані результати визначення економічної ефективності системи підтримки прийняття рішень для прогнозування витрат пального під час транспортування зернових подано у таблиці 5.2.

Результати розрахунків показують, що впровадження системи підтримки прийняття рішень для прогнозування витрат пального під час транспортування зернових дозволяє досягти економії пального на рівні 13.6 л/добу, що становить 748 грн/добу за поточними цінами на пальне. Враховуючи вартість впровадження системи, загальна економічна вигода впродовж періоду транспортування зернових ($N_d=35$ днів) становить 14180 грн. Це свідчить про окупність цієї систем менш як за один сезон.

ВИСНОВКИ І ПРОПОЗИЦІЇ

Виконана робота передбачає розробку систему підтримки прийняття рішень для прогнозування витрат пального під час транспортування зернових, яка базується на використанні нейромережових моделей. Вона забезпечує зниження впливу витрат палива на загальні витрати виконання логістичних процесів та підвищення ефективності перевезень зернових.

Нами проаналізовано особливості оцінки споживання палива транспортним засобом. Встановлено, що оцінка споживання палива транспортним засобом є основним завданням для підвищення ефективності транспортування зернових. Аналіз витрат палива дозволяє не лише оптимізувати логістичні процеси, але й зменшити експлуатаційні витрати, сприяючи більш раціональному використанню ресурсів. Встановлено, що відомі підходи до моделювання споживання палива на основі даних і машинного навчання відкривають шляхи для усунення недоліків існуючих методів оцінки.

Інформаційні технології для моніторингу витрат палива на автомобілях надають можливість оперативного аналізу та прогнозування витрат, що є важливим для оптимізації транспортних процесів. Використання таких технологій дозволяє автоматизувати збір даних, підвищити точність оцінки ефективності транспортних засобів та забезпечити прийняття обґрунтованих рішень. Водночас, розробка системи підтримки прийняття рішень для прогнозування витрат пального є доцільною, оскільки вона не лише забезпечує інтеграцію сучасних методів моделювання, але й сприяє зниженню витрат на транспортування зернових, покращенню екологічних показників та підвищенню ефективності логістичних операцій.

Прогнозування витрати палива автомобіля за допомогою штучних нейронних мереж є перспективним напрямком, який забезпечує високу точність та адаптивність моделей до змінних умов експлуатації. Використання нейромережових технологій дозволяє враховувати широкий спектр впливових

чинників, таких як тип транспортного засобу, вантажообіг, відстань маршруту та інші параметри, що важко формалізувати за допомогою класичних методів. Розробка системи підтримки прийняття рішень із використанням нейромереж для прогнозування витрат пального є доцільною, оскільки вона сприяє автоматизації процесу управління витратами, зниженню транспортних витрат та підвищенню конкурентоспроможності компаній у логістичній сфері.

Нами проаналізовано три основні нейромережеві моделі для прогнозування витрат палива транспортними засобами під час транспортування зернових: багатошарову перцептронну модель (MLP), рекурентну нейромережу (LSTM) та згорткову нейромережу (CNN). Кожна з моделей має свої переваги та особливості. MLP продемонструвала високу швидкість навчання та точність для завдань з лінійною залежністю параметрів. Модель LSTM виявилася корисною для врахування послідовності даних, але потребує значних обчислювальних ресурсів. CNN показала найкращі результати у прогнозуванні завдяки здатності виявляти приховані залежності між параметрами та оптимізувати витрати обчислень. Результати аналізу підтверджують доцільність використання CNN як базової архітектури для реалізації системи підтримки прийняття рішень, оскільки ця модель забезпечує найвищу точність та ефективність прогнозування.

Для аналізу та прогнозування витрат палива під час транспортування зернових культур було зібрано та підготовлено великий обсяг даних, що включає 13432 записи. Ці дані взято у ТОВ «Волинь-Зерно-Продукт» (м. Луцьк, Волинська область), яке фіксувало діяльність транспортних засобів за 2019...2021 роки. Кожен запис представляє один рейс транспортного засобу та містить 7 параметрів. Для підготовки даних використовували Jupyter Notebook. Код писали із використанням Python 3.11.

Для кожного стовпця було проаналізовано кількість унікальних значень. Встановлено, що використовувалося 12 унікальних моделей транспортних засіб, 17 різновидів зернових культур, які транспортувалися на відстань, що має 576 унікальних значень і свідчить про різноманітність маршрутів. Аналізуючи

характеристики даних, можна зробити висновок, що середня відстань транспортування становить 102,52 км, із середнім значенням витрат палива 46,38 літрів за поїздку та середньою витратою дизельного палива 47,67 літрів/100км.

Для покращення розуміння структури даних і взаємозв'язків між змінними були побудовані наступні графіки. Нами побудовано залежність витрат палива від відстані (рис. 2.4). Встановлено, витрати палива мають мінливу тенденцію до зростання зі збільшенням відстані, що очікувано для транспортних засобів.

Також нами побудовано гістограму зміни вантажообігу для різних типів вантажів (рис. 2.5). Отримана гістограма показує, як різні типи вантажів впливають на вантажообіг. Видно, що вантажообіг найбільший для кукурудзи 8500...9300 т·км, що можна пояснити його більшою вагою на одиницю обсягу. Найменше транспортувалося зерноsumішей та зернопродуктів.

Аналіз кореляційної матриці показав, що найбільший вплив на витрати палива має відстань транспортування – кореляція відстанню та фактичними витратами палива становить 0,989, що підтверджує майже лінійну залежність. Схожий сильний зв'язок між відстанню та вантажообігом – 0,995, свідчить про те, що транспортна робота прямо пропорційна відстані. Витрати палива на 100 км мають слабку негативну кореляцію з відстанню (-0.239), що свідчить про більшу ефективність транспортних засобів на довших маршрутах. Тип транспортного засобу також впливає на витрати палива.

У результаті підготовки даних створено навчальну та тестову вибірки, які відповідають усім вимогам для подальшого навчання моделей. Очищення, кодування та нормалізація даних сприяють коректному функціонуванню алгоритмів машинного навчання, а розділення даних гарантує об'єктивність оцінки точності моделей.

Для прогнозування витрат палива транспортними засобами було використано три нейромереві моделі: багатошарова перцептронна модель (MLP); рекурентна нейромережа (LSTM) та згорткова нейромережа (CNN).

Нами описано основні етапи навчання моделей, оцінку їх точності та результати аналізу.

Результати оцінювання трьох моделей нейромереж показали різну точність прогнозування витрат палива. Багатошарова перцептронна модель (MLP) продемонструвала високу точність із $MSE=47.18$, $MAE=3.93$ та коефіцієнтом детермінації $R^2=0.981$, що свідчить про ефективне моделювання залежності. Рекурентна нейромережа (LSTM) досягла меншої точності з $MSE=304.089$, $MAE=4.7908$ та $R^2=0.877$, вказуючи на її обмежену ефективність. Найкращі результати показала згорткова нейромережа (CNN) із найменшим $MSE=37.044$, найнижчим $MAE=2.665$ та найвищим $R^2=0.985$, що робить її оптимальним вибором для прогнозування витрат палива серед розглянутих моделей.

Система підтримки прийняття рішень для прогнозування витрат пального під час транспортування зернових базується на сучасній модульній архітектурі з можливістю ефективною заміни функціональних блоків без зміни загальної структури системи. Відповідно до сучасних підходів до розробки програмної системи окремі функціональні блоки об'єднуються в підсистеми за шаблонами функціональної подібності (рис. 3.10). Перші чотири підсистеми утворюють виконуваний компонент для системи підтримки прийняття рішень для прогнозування витрат пального під час транспортування зернових. Остання (п'ята) підсистема інтегрує набір алгоритмів, які реалізують конкретні обчислювальні процедури, пов'язані з задачею, що розв'язується.

Розроблене вікно користувача є зручним і функціональним інструментом для роботи з системою підтримки прийняття рішень. Воно дозволяє автоматизувати процес прогнозування витрат пального для транспортування зернових, надаючи користувачам можливість швидко отримати результати, зберігати їх і легко очищувати поля для введення нових даних.

Розроблені заходи з охорони праці та забезпечення безпеки в умовах надзвичайних ситуацій спрямовані на створення безпечного середовища для

роботи з системою підтримки прийняття рішень, призначеною для прогнозування витрат пального під час транспортування зернових.

Результати розрахунків показують, що впровадження системи підтримки прийняття рішень для прогнозування витрат пального під час транспортування зернових дозволяє досягти економії пального на рівні 13.6 л/добу, що становить 748 грн/добу за поточними цінами на пальне. Враховуючи вартість впровадження системи, загальна економічна вигода впродовж періоду транспортування зернових (35 днів) становить 14180 грн. Це свідчить про окупність цієї систем менш як за один сезон.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Введення в машинне навчання за допомогою Python и Scikit-Learn. URL: <https://habr.com/ua/company/mlclass/blog/247751/> (дата звернення: 26.08.2024).
2. Григорович О.В. Застосування багат шарових перцептронів для класифікації позичальників юридичних осіб. Нейронечіткі технології моделювання в економіці. Науково-аналітичний журнал. Київ, 2019. №8. С.48-64.
3. Жидецький В.Ц., Джигирей В.С., Мельников О.В. Основи охорони праці. Підручник. Вид. 5-е, доповнене. Львів: Афіша, 2012. 350с.
4. Класифікація в Python з Scikit-Learn та Pandas. URL: <https://stackabuse.com/classification-in-python-with-scikit-learn-and-pandas/> (дата звернення: 21.07.2024).
5. Коваль Н.Я., Кондисюк І.В., Тригуба А.М. Алгоритм навчання нейронної мережі для планування часу виконання робіт у гібридних проєктах. Молодь у світі сучасних технологій за тематикою: Сучасні інформаційні технології: стан та перспективи розвитку : матеріали міжнар. наук.-практ. конф. (4 червня 2021 р., м. Херсон) / за заг. ред. Г.О. Райко. – Херсон: Видавництво ФОП Вишемирський В. С., 2021. – С. 153-156.
6. Лехман С.Д., Рублев В.І., Рябцев Б.І. Запобігання аварійності і травматизму у сільському господарстві. К.: Урожай, 1993. 267 с.
7. Новоселецький О.М., Якубець О.В. Моделювання кредитоспроможності юридичних осіб на основі дискримінантного аналізу та нейронних мереж. Нейронечіткі технології моделювання в економіці. Науково-аналітичний журнал. Київ, 2014. №3. С.120-151.
8. Огляд методів класифікації у машинному навчанні за допомогою Scikit-Learn. URL: <https://tproger.ru/translations/scikit-learn-in-python/s://stackabuse.com/classification-in-python-with-scikit-learn-and-pandas/> (дата звернення: 15.09.2024).

9. Tryhuba A., Kondysiuk I., Tryhuba I., Koval N., Boiarchuk O., Tatomyr A. Intellectual information system for formation of portfolio projects of motor transport enterprises, in: I Workshop Information Technologies in Energy and Agro-industrial Complex, ITEA-WS 2021, CEUR Workshop Proceedings 3109, Dubliany, Lviv region, 2021, pp. 44–52.

10. Тригуба А., Кондисюк І., Коваль Н. Формування портфелів гібридних проєктів автотранспортних підприємств. Вісник Національного технічного університету «ХПІ». Сер. : Стратегічне управління, управління портфелями, програмами та проєктами : зб. наук. праць – Харків : НТУ «ХПІ», 2021. – № 2 (4). – С. 67-72.

11. Тригуба А., Кондисюк І., Коваль Н., Тригуба І., Боярчук Ок., Боярчук Ол. Планування часу виконання робіт у гібридних проєктах. Вісник Національного технічного університету «ХПІ». Сер. : Стратегічне управління, управління портфелями, програмами та проєктами : зб. наук. праць Харків : НТУ «ХПІ», 2022. № 2 (6). С. 64-71.

12. Тригуба А., Пташник В., Татомир А., Коваль Н.Я., Кондисюк І.В. Використання штучних нейронних мереж для прогнозування складових гібридних проєктів. Теорія і практика розвитку агропромислового комплексу та сільських територій: матеріали ХХІІ Міжнародного науково-парктичного форуму, 5-7 жовтня 2021р.: у 2 т. Львів: ННВК «АТБ», 2021. Т.2. С. 96-100.

13. Тригуба А., Тригуба І., Фтома О., Кондисюк І., Коваль Н. Системний підхід до оцінення ризиків несвоєчасного виконання робіт в інтегрованих проєктах. Вісник Львівського національного аграрного університету: агроінженерні дослідження. №23. Львів: Львів НАУ, 2019. С. 123-130.

14. Тригуба А., Тригуба І., Чубик Р., Кондисюк І., Коваль Н., Панюра Я. Прогнозування обсягів заготівлі сировини на території громад із використанням штучних нейронних мереж. Вісник Львівського національного аграрного університету: агроінженерні дослідження. №24. Львів: Львів НАУ, 2020. С.143-151.

15. Тригуба А.М., Кондисюк І., Коваль Н. Алгоритм прийняття управлінських рішень в умовах невизначеності із використанням машинного навчання. Вчені Львівського національного аграрного університету виробництву: каталог інноваційних розробок за заг. ред. В. В. Снітинського, І. Б. Яціва. Вип. 20. Львів: Львів. нац. аграр. ун-т, 2020. С. 39.

16. Тригуба А.М., Кондисюк І.В. Алгоритм оптимізації портфелів гібридних проєктів автотранспортних підприємств. Вчені Львівського національного аграрного університету виробництву: каталог інноваційних розробок за заг. ред. В. В. Снітинського, І. Б. Яціва. Вип. 22. Львів: Львів. нац. аграр. ун-т, 2022. С. 26.

17. Тригуба А.М., Кондисюк І.В. Метод формування портфелів гібридних проєктів автотранспортних підприємств. Вчені Львівського національного аграрного університету виробництву: каталог інноваційних розробок за заг. ред. В. В. Снітинського, І. Б. Яціва. Вип. 21. Львів: Львів. нац. аграр. ун-т, 2021. С. 52.

18. Тригуба А.М., Кондисюк І.В., Татомир А.В., Шолудько Я.В., Боярчук О.В. Інтелектуальна інформаційна система формування портфелів проєктів автотранспортних підприємств. Інформаційні технології в енергетиці та агропромисловому комплексі: матеріали Х-ї міжнародної наукової конференції, присвяченої 165-річчю університету. Львів-Дубляни, 2021, С. 113–115.

19. Тригуба А.М., Ратушний Р.Т., Кондисюк І., Коваль Н. Рівні та особливості моделювання гібридних проєктів розвитку територіальних систем. Управління проєктами: стан та перспективи: матеріали XVI Міжнар. конф. – Миколаїв: НУК, 2020. С. 74-75.

20. Тригуба А.М., Тригуба І.Л., Коваль Н.Я., Кондисюк І.В. Використання моделі SARIMA для прогнозування проєктного середовища гібридних проєктів заготівлі молока на території громад. Тези доп. XIX-й Міжнародній науково-практичній конференції «Управління проєктами у розвитку суспільства». Київ: КНУБА, 2022. С.279-284.

21. Тригуба А.М., Тригуба І.Л., Кондисюк І.В., Коваль Н.Я. Планування змісту та часу виконання робіт у гібридних проєктах із використанням штучних нейронних мереж. Тези доп. XVII-ї Міжн. конф. Управління проєктами у розвитку суспільства: Управління проєктами в умовах пандемії COVID-19». Київ: КНУБА, 2021. С.279-284.
22. Amer, A., et al., Prediction of vehicle fuel consumption model based on artificial neural network. In: Applied Mechanics and Materials. Trans Tech Publ. 2014.
23. Anvari S. , *et al.* Implementation of ANN on CCHP system to predict trigeneration performance with consideration of various operative factors. Energy Convers. Manage., 101 (2015), pp. 503-514.
24. Ardakani F. , Ardehali M. Novel effects of demand side management data on accuracy of electrical energy consumption modeling and long-term forecasting. Energy Convers. Manage., 78 (2014), pp. 745-752.
25. Benjamin J.R. , Cornell C.A. Probability, Statistics, and Decision for Civil Engineers. Courier Corporation, 2014. P.236-278.
26. Cecchel S. , *et al.* Impact of reduced mass of light commercial vehicles on fuel consumption, CO2 emissions, air quality, and socio-economic costs. Sci. Total Environ., 2018, 613, pp. 409-417.
27. Demuth, H., Beale, M., 1993. Neural Network Toolbox For Use with Matlab--User'S Guide Verion 3.0. Dindarloo and Siami-Irdemoosa, 2016. pp. 123-128.
28. Dindarloo S.R. , Siami-Irdemoosa E. Determinants of fuel consumption in mining trucks. Energy, 112 (2016), pp. 232-240.
29. Doukim C.A. , Dargham J.A. , Chekima A. Finding the number of hidden neurons for an MLP neural network using coarse to fine search technique. 10th International Conference on Information Science, Signal Processing and their Applications (ISSPA 2010), IEEE, 2010.

30. Du J. , *et al.* Potential for reducing GHG emissions and energy consumption from implementing the aluminum intensive vehicle fleet in China. *Energy*, 35 (12), 2010, pp. 4671-4678.
31. Du Y. , *et al.* Predicting vehicle fuel consumption patterns using floating vehicle data. *J. Environ. Sci.*, 59, 2017, pp. 24-29.
32. Ghritlahre H.K. , Prasad R.K. Application of ANN technique to predict the performance of solar collector systems – a review. *Renew. Sust. Energy Rev.*, 84, 2018, pp. 75-88.
33. Giustolisi O. , Laucelli D. Improving generalization of artificial neural networks in rainfall–runoff modelling. Amélioration de la généralisation de réseaux de neurones artificiels pour la modélisation pluie-débit. *Hydrol. Sci. J.*, 50 (3), 2005. 156p.
34. H. Hao, *et al.* Scenario analysis of energy consumption and greenhouse gas emissions from China’s passenger vehicles. *Energy*, 91 (2015), pp. 151-159.
35. Haykin S. , Network N. A Comprehensive Foundation. *Neural Networks*. McMaster University Hamilton, Ontario, Canada, 2004, p. 823.
36. He K. , *et al.* Oil consumption and CO2 emissions in China’s road transport: current status, future trends, and policy implications. *Energy Policy*, 33 (12) (2005), pp. 1499-1507.
37. Kondysiuk I., Tryhuba A., Bashynsky O., Grabovets V., Dembitskyi, V., Myskovets, I. Formation and risk assessment of stakeholders value of motor transport enterprises development projects. *IEEE 16th International Conference on Computer Sciences and Information Technologies, CSIT-2021, IEEE, Lviv, 2021, pp. 307–310. doi: 10.1109/CSIT52700.2021.9648739.*
38. Koval N., Tryhuba A., Kondysiuk I., Tryhuba I., Boiarchuk O., Rudynets M., Grabovets V., Onyshchuk V. Forecasting the fund of time for performance of works in hybrid projects using machine training technologies. *3rd International Workshop on Modern Machine Learning Technologies and Data Science Workshop, MoMLeT and DS 2021, CEUR Workshop Proceedings 2917, Lviv-Shatsk, 2021, pp. 196–206.*

39. Siami-Irdemoosa E. , Dindarloo S.R. Prediction of fuel consumption of mining dump trucks: a neural networks approach. *Appl. Energy*, 2015, 151, pp. 77-84.
40. Tryhuba A., Sholudko Y., Kondysiuk I. Justification of the configuration of the logistic delivery system of perishable agricultural products. 2nd International Conference on Agriculture, Technology, Engineering and Sciences (ICATES 2019), 2019. Lviv. P. 144.
41. Tryhuba A., Tryhuba I., Bashynsky O., Kondysiuk I., Koval N., Bondarchuk L., Conceptual Model of Management of Technologically Integrated Industry Development Projects. *IEEE 15th International Conference on Computer Sciences and Information Technologies, CSIT-2020*, IEEE, Lviv, 2020, pp. 155–158. doi: 10.1109/CSIT49958.2020.9321903.
42. Tryhuba, A., Kondysiuk I., Tryhuba I., Lub P. Approach and Software for Risk Assessment of Stakeholders of Hybrid Projects of Transport Enterprise. *CEUR Workshop Proceedings* [this link is disabled](#), 2022, 3295, pp. 86–96.