

Д. С. Положий, О. О. Орехов

Національний аерокосмічний університет «ХАІ», Харків, Україна

## ПРОГНОЗУВАННЯ РИЗИКІВ ДОРОЖНЬО-ТРАНСПОРТНОГО РУХУ НА ОСНОВІ НЕЙРОННОЇ МЕРЕЖІ

**Анотація.** На підставі структурного аналізу статистики ДТП в Україні виділені найбільш небезпечні їх причини: перевищення безпечної швидкості, порушення правил маневрування, порушення правил проїзду перехресть та пішохідних переходів. Розглянуто запропоновані моделі прогнозування безпеки дорожньо-транспортного руху і ризику водіння. Досліджено та систематизовано фактори безпеки дорожньо-транспортного руху. Запропонована модель прогнозування ризику дорожньо-транспортного руху із використанням інтелектуальної транспортної системи (ITS) та нейронної мережі. Модель побудована на технології обробки нейронною мережею зважених статистичних та динамічних масивів вхідних даних, що характеризують внутрішнє і зовнішнє середовище транспортного засобу з метою отримання оцінки ризику дорожньо-транспортного руху. Запропоновано алгоритм прогнозування ризику нейронною мережею. Навчання багатопарової нейронної мережі здійснюється за алгоритмом зворотного поширення помилки. Тестування роботи системи прогнозування продемонструвало точність передбачень 85-90%.

**Ключові слова:** безпека дорожньо-транспортного руху, фактори безпеки, моделювання, транспортний засіб, нейронна мережа, інтелектуальна транспортна система.

### Вступ та опис проблеми

Стійкою тенденцією сучасності є збільшення інтенсивності дорожнього руху, а внаслідок цього і зростання кількості ДТП та жертв і травмованих на дорогах людей. Аналіз статистики патрульної поліції України [1] свідчить про те, що в 2023 році на дорогах України в середньому щодоби гинуло понад 8 осіб і було травмовано понад 80 осіб. У довоєнні роки (2020-2021) ці показники були ще вище. Тому проблема забезпечення безпеки дорожнього руху залишається актуальною і потребує втілення сучасних технологічних рішень. Концепція безпеки дорожнього руху на даний час ґрунтується на розпізнаванні об'єктів перешкоди транспортному руху, а саме транспортних засобів, пішоходів, тварин, інших рухомих і

нерухомих об'єктів. В той же час проведений аналіз статистики причин дорожньо-транспортних пригод по Україні за 2020-2023 рр. вказує на те, що структура причин ДТП щороку майже повторюється, спостерігається також їх часова залежність продовж доби, а найбільш небезпечними причинами виникнення аварій є наведені у табл. 1.

Найбільша кількість ДТП (39,1%) за даними табл. 1 трапляється через перевищення транспортними засобами безпечної швидкості – саме такі аварії призвели до найбільшої кількості загиблих (51,6% від загальної кількості загиблих). На другому місці серед причин ДТП – порушення правил маневрування, що привели до зіткнень. Значна кількість аварій траплялась також через порушення при проїздах перехресть та пішохідних переходів.

Таблиця 1 – Структура ДТП з загиблими та травмованими за причинами за період 2020-2023 рр.

Причини ДТП	Частка у загальній кількості, %		
	ДТП	Осіб, які загинули	Травмованих осіб
Перевищення безпечної швидкості	39,1	51,6	38,7
Порушення правил маневрування	21,1	14,1	21,1
Порушення правил проїзду перехресть	8,5	2,5	9,5
Порушення правил проїзду пішохідних переходів	7,3	3,6	6,0
Недотримання дистанції	5,2	2,5	5,3
Інше	18,8	25,7	19,4

Джерело: складено і розраховано автором за даними [1].

Але будь яке ДТП, як правило, є наслідком збігу декількох причин. Тому перед сучасними системами запобігання аваріям стоїть завдання отримання і обробки великих обсягів різномірної і мінливої інформації, яку надають учасники дорожнього руху, дорожня інфраструктура, метеопрогнози, і виокремлювати найважливішу для безпеки інформацію та виконувати її класифікацію для прогнозування дорожньо-транспортних пригод на різних ділянках дороги. Вирішення таких завдань можливо за допо-

могою сучасних технологій високошвидкісної передачі даних та використання нейронних мереж для їх обробки у хмарі.

**Аналіз останніх досліджень і публікацій.** Спектр наукової думки що до проблем безпеки дорожнього руху та прогнозування ризиків водіння на даний час є достатньо широким і різноманітним.

Сучасну концепцію інтелектуальної системи автомобільної безпеки на основі хмарної архітектури проаналізували Д. С. Положий та О.О. Орехов

[2]. Їми доведено необхідність розподіленої та динамічно масштабованої архітектури мережевої програми, щоб задовольнити зростаючі вимоги до розширюваної системи додатків IoT (Інтернету речей), до категорії яких можна віднести і прилади сучасних транспортних засобів для збору інформації або виконання команд управління під дистанційним керуванням.

А.А. Кашкановим і О.В. Пальчевським [3] проведено аналіз методів прогнозування трафіку та дорожньої безпеки ITS, за результатами якого вони прийшли до висновку, що найбільш перспективними моделями для швидкого та ефективного вирішення неординарних ситуацій дорожнього руху є моделі із застосуванням штучного інтелекту або комбінації із ними, засновані на алгоритмах глибокого навчання.

Зарубіжними авторами запропоновані різні методи прогнозування ризику водіння та зіткнень, які поділяють на два класи:

- засновані на математичних моделях;
- засновані на навчанні на основі попереднього досвіду [4].

Методи, що засновані на математичних моделях, спираються на апріорні знання про транспортний засіб та інфраструктуру дорожнього руху, представлені у формалізованому вигляді їх динаміки або імовірності подій. Найбільш розповсюдженими є моделі інтелектуального драйвера, моделі на основі локально зваженої регресії та моделі на основі звичайних нейронних мереж.

Найпоширенішою моделлю динаміки транспортного засобу є модель часу до зіткнення при умові, що транспортний засіб продовжує поточний шлях з поточною швидкістю [5]. Інші моделі включають інтегрований час до зіткнення, час експозиції до зіткнення, час після вторгнення і швидкість уповільнення для уникнення зіткнення. Однак більшість моделей безпеки дорожнього руху базуються лише на аналізі швидкості автомобіля [6, 7].

Nyothiri Aung із співавторами [8] запропонували систему прогнозування аварій для автомобільних спеціальних мереж (VANET) у міських умовах, в якій ризик розглядається як прихована змінна, отримана за допомогою спостережень за іншими факторами безпеки, такими як швидкість руху, погодні умови, місце дії, інтенсивність руху транспортних засобів поблизу та втома водія. Для моделювання кореляції між цими спостереженнями та латентною змінною ризику використана прихована модель Маркова. За свідченням авторів, запропонована система має кращі характеристики з точки зору чутливості та точності порівняно з моделями, заснованими на формалізації динаміки одного фактора. Недоліком цієї моделі є те, що вона не враховує небезпеки від транспортних засобів, які рухаються поруч і часто стають причинами аварій.

В публікаціях останніх років великої популярності для прогнозування аварій на дорозі набули також підходи, які включають різноманітні алгоритми машинного навчання. Найпопулярнішим є використання технології глибокого навчання, яка надає можливість отримувати від системи рішення у

неординарних обставинах. Наприклад, Стрикленд та співавтори [9] реалізували модель глибокого навчання з байєсівською згортковою довготривалою пам'яттю (LSTM).

А. Iqbal із співавторами [10] запропонували систему виявлення небезпеки можливих зіткнень з транспортними засобами, що рухаються поруч, шляхом надання попереджувальної інформації. Для об'єднання даних кількох датчиків в системі була використана динамічна байєсівська мережа (DBN). Характеристики руху зустрічних транспортних засобів система збирала за допомогою бортової камери та інерціального вимірювального блоку (IMU), яким фіксувались швидкість, прискорення та напрямки руху транспортного засобу. Зібрані дані подавались в класифікатор на основі градієнтних ознак.

Чен та співавтори [11] використали нейронну мережу для обробки інфраструктурної інформації, отриманої за допомогою зв'язку V2I (транспортний засіб – інфраструктура) та інформації, яку отримано за допомогою зв'язку V2V (транспортний засіб – транспортний засіб) для запобігання зіткненню.

Halim Z. із співавторами [12] представили систему на основі глибокого навчання та штучного інтелекту для виявлення ризиків водіння для легкових транспортних засобів, яка генерує ранні попередження перед очікуваною аварією. Система збирає та вивчає різні шаблони стилю водіння водія на симуляторі, а потім застосовує глибоке навчання для віднесення поведінки водія до одного з попередньо визначених класів.

S. Orgea із співавторами [13] наводять огляд та класифікацію методів глибокого навчання для прогнозування ДТП. Інтелектуальні системи на основі моделі машинного навчання для уникнення ДТП автори пропонують будувати з використанням алгоритмів штучної нейронної мережі (ANN), логістичної регресії (LR), дерева рішень (DT), K-найближчого сусіда (KNN), опорної векторної машини (SVM), байєсівської системи (NB), стохастичного градієнтного спуску (SGD) та ін. [14]

Оскільки значна кількість інформації про навколишнє середовище транспортного засобу отримується через відеодатчики, запропоновано багато систем запобігання зіткнень, які побудовані на обробці відео спостережень за допомогою нейронних мереж.

Так В. Maaloul розглядає алгоритми виявлення ДТП на основі відео інформації [15]. Robles-Serrano [16] пропонує автоматичне виявлення ДТП за допомогою відео спостереження з використанням методів глибокого навчання.

R. Coll-Josifov із співавторами [17] пропонують систему, в якій нейронні мережі YOLO навчаються на наборі даних з метою виявлення та класифікації предметів із картинок вулиці, яку видно зверху з безпілотної. Навчені моделі використовуються для виявлення та класифікації об'єктів у міському сценарії дорожнього руху в режимі реального часу. Нарешті, пропонується алгоритм відстеження об'єктів, прогнозування їх майбутніх траєкторій та потенційних зіткнень.

Отже, методи засновані на навчанні використовують параметри, які мінімізують функцію небезпеки, що оцінюється на наборі навчальних даних. Значною мірою вони залежать від якості та обсягу таких даних, що дає можливість перенавчання при зміні умов. Недоліком таких систем є те, що у разі недостатньо повного масиву навчальних даних, такі системи зазвичай сходяться до локальних оптимумів, що може привести до прийняття помилкового рішення. Або такі системи навчають оперувати тільки декількома факторами безпеки, які є найважливішими на думку розробників, і не оцінюють всього спектру важливих факторів, що впливають на безпеку дорожнього руху. Внаслідок цього система може не спрацювати у неординарній ситуації.

**Постановка завдання.** Метою статті є дослідження факторів небезпеки дорожньо-транспортного руху та пропозиція рішень по системі прогнозування ризиків на дорожній дільниці з використанням інфраструктури ITS на основі технології, заснованій на нейронній мережі.

### Виклад основного матеріалу

**Систематизація факторів небезпеки.** Системи, побудовані на технологіях штучного інтелекту, швидко поширюються в тих секторах, де потрібно виявляти як закономірності у великих обсягах даних, так і відхилення від таких закономірностей, і на основі результатів обробки даних прогнозувати ситуацію та приймати рішення.

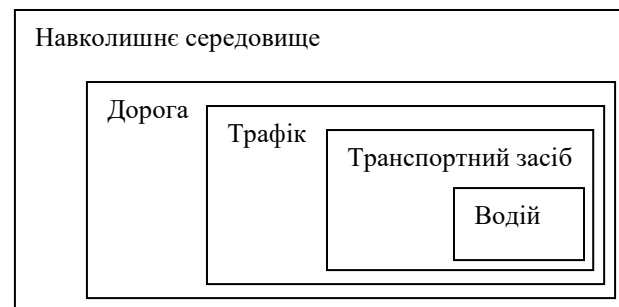
Саме до такого сектору з великими обсягами різноманітних динамічних даних відноситься система безпеки дорожнього руху, яка відстежує інформацію з великої кількості транспортних засобів, компонентів інфраструктури дороги, враховує інформацію про погодні та часові умови, рухомі та нерухомі перешкоди дорожньому руху (пішоходи, травини тощо).

Підхід до забезпечення безпеки такої системи полягає у визначенні загального ризику від сукупності можливих перешкод від всіх елементів системи і впровадження заходів що до мінімізації таких ризиків з урахуванням часу їх можливого настання.

Сучасні технології високошвидкісної передачі інформації 5G та хмарні технології зберігання та обробки великих даних дозволяють проводити обробку і передачу інформації із великої кількості датчиків одночасно з незначними затримками, тому система забезпечення безпеки на дорозі технологічно в спроможності враховувати інформацію про значну кількість факторів, як високо динамічних, так і тих, що змінюються повільно або періодично.

З системної точки зору основними підсистемами джерел небезпеки в дорожньому русі є: водій, транспортний засіб, трафік на дільниці дороги, дорожнє полотно та навколишнє середовище (рис. 1).

До атрибутів навколишнього середовища відносять: погодні умови, просторово-часові умови, можливість появи тварин на дорозі. Несприятливі погодні умови – дощ, туман, ожеледь і вітер – впливають на видимість і, як наслідок, на безпеку дорожнього руху.



**Рис. 1.** Основні підсистеми джерел небезпеки  
*Джерело: здобуток автора*

Час доби також впливає як на видимість, освітленість, так і на втому водія та інтенсивність трафіку на дорозі. Тварини також можуть становити небезпеку на ділянках проїжджій частині, якщо маршрути їх міграції пролягають в прилеглих районах. Тож мають бути вжиті відповідні заходи, такі як огорожі чи попереджувальні знаки, а в ITS повинна зберігатися відповідна інформація.

До атрибутів проїжджій частини відносяться як тип та стан дорожнього покриття на дорожній дільниці, дорожні смуги, так і геометрія дороги, розв'язки, перехрестя, пішохідні переходи. Крім цього до даної підсистеми відноситься інформація про перешкоди, аварійні дільниці, огорожені дільниці, слизьке дорожнє покриття в зимових умовах, що за своєю природою є динамічною. Атрибути проїжджій частини можуть збиратися як спеціалізованими компаніями технічного обслуговування доріг, так і учасниками дорожньо-транспортного руху з датчиків вібрації автомобіля та з камери, що надає дані та зображення тротуарів, смуг та перешкод.

Атрибути трафіку на певній ділянці дороги включають: обсяг трафіку, швидкість транспортних засобів і події, такі як випадкові аварії, аварійні маневри тощо. Збір таких даних є першочерговим питанням для моделей прогнозування ризиків небезпеки, і може здійснюватися за допомогою транспортних засобів, смартфонів та інших пристроїв, щоб досягти повного покриття мережі.

Обсяг трафіку є наріжним камнем аналізу безпеки, але його часто бракує в моделях прогнозування ризику. Якщо вихідні дані про обсяг трафіку походять із розміру парку транспортних засобів, то їм бракує репрезентативності. Достовірні оцінки обсягу трафіку на всій мережі доріг можуть бути зібрані за допомогою ITS з наземних приладів оцінки трафіку з передачею даних на сервер.

До цієї категорії відноситься також інформація про транспортні засоби навколо, небезпеку їх маневрів та манери водіння.

Швидкість руху – один із найважливіших факторів безпеки на дорозі, як показує статистика ДТП (табл. 1). Дані про швидкість мають бути пріоритетним пунктом у списку даних, пов'язаних з безпекою. Звичайне надання даних про швидкість усіма виробниками автомобілів на сервер ITS могло б пом'якшити помилки, виявлені в телематичних даних навігації придорожніми приладами. Технологія GPS за певних обставин також може посилити збір

даних про швидкість руху, але ці дані недостатньо точні в міських умовах і недоступні в тунелях.

Атрибути транспортного засобу можна поділити на такі, що характеризують його технічний стан та динамічні характеристики (швидкість, маневри, відстань до перешкоди, наявність перешкоди). Сучасні автомобілі оснащені системою ADAS, яка за допомогою сенсорів, що під'єднанні до Інтернету речей, допомагає уникати зіткнень та ДТП, попереджає водіїв про потенційні проблеми, здійснює запобіжні заходи, а в деяких випадках перебирає на себе контроль над автомобілем. Інформація з системи ADAS може передаватися до серверу ITS для оцінки ризику водіння на ділянці дороги.

До атрибутів водія, які впливають на безпеку дорожньо-транспортного руху, відносяться: стан здоров'я водія, втома, манера водіння, присутність алкоголю або наркотиків в організмі. Такі показники може збирати та передавати до захищеного сервера бортова система контролю стану водія [18] або оснащена відповідними сенсорами сучасна автомобільна система ADAS.

Таким чином, із розвитком дорожньої інфраструктури та розвитком автомобільних систем ADAS кількість атрибутів дорожньо-транспортного руху, які можуть бути передані до серверу ITS, зростає, і це може збільшити прогностичну силу моделей прогнозування ризику з одночасним їх ускладненням.

Визначення важливості окремих вхідних змінних для прогностичної сили моделі є складною проблемою. Рішення залежатиме передусім від достатніх історичних даних. Доцільно обрати ті атрибути, які мали великий вплив на виникнення ДТП в минулому.

Тоді можна передбачити ймовірність ризиків подібних подій у найближчому майбутньому.

Для моделювання відбираємо найбільш значущі атрибути, наведені у табл. 2.

Таблиця 2 – Перелік вхідних змінних

Підсистема	Вхідні змінні, $X_i$
Водій	Стан водія
	Манера водіння
Транспортний засіб	Швидкість
	Технічний стан
Трафік	Інтенсивність руху
	Наближення перешкод
	Небезпечне авто поблизу
Дорога	Тип дорожнього покриття
	Стан покриття
	Слізка дорога
	Складність геометрії
Зовнішнє середовище	Видимість
	Погодні умови
	День тижня, час доби

Джерело: здобуток автора

Фактичні значення атрибутів, отримані за допомогою сенсорів або із баз даних, для цілей прогнозування ДТП потрібно нормалізувати відносно мінімуму або відносно середнього.

Треба зазначити, що кожен з наведених у табл. 2 атрибутів, як правило, є комплексним і складається із групи ознак. Наприклад, стан водія складається із показників його фізичного стану (тиск, пульс, температура), наявності алкоголю або наркотиків в організмі, сонливості, втоми та ін. Отже, оцінку стану водія виконує окрема підсистема по п'ятибальній шкалі.

Також виконується комплексна оцінка і інші вхідні змінні.

**Формалізація задачі.** Стан безпеки дорожнього руху на ділянці дороги постійно змінюється і для його оцінки в системі запропоновано використовувати класифікатор за рівнем ризику, наведений у табл. 3.

Таблиця 3 – Класифікатор ризиків безпеки

Рівень ризику	Значення ризику	Категорія ризику
Катастрофічний	0,511÷0,89	3
Критичний	0,141÷0,51	2
Граничний	0,08÷0,14	1
Незначний	0,01÷0,08	0

Джерело: складено автором на основі даних з [19]

Оскільки ризик має імовірнісну природу, то може бути оцінений як математичне очікування збитку від усіх факторів небезпеки за формулою:

$$R(t) = \sum_{i=1}^n W_i P_i(t), \quad (1)$$

де  $R(t)$  – ризик небезпеки системи;

$P_i(t)$  – імовірність збитку від  $i$ -го фактору;

$W_i$  – вагова функція  $i$ -го фактору, за допомогою якої наслідки різних факторів небезпеки приводяться до єдиної шкали;

$n$  – кількість задіяних в системі факторів ризику.

Функціонування нейрона визначається співвідношенням:

$$s = \sum_{i=1}^n w_i x_i, \quad (2)$$

$$y = f(s, b),$$

де  $x_i$  – вхідні сигнали;

$w_i$  – вагові коефіцієнти;

$s$  – зважена сума вхідних сигналів;

$b$  – поріг рівень нейрона;

$f$  – функція активації.

Порівнюючи формули (1) і (2), можна прийти до висновку, що для завдання визначення ризику системи безпеки може бути використана нейронна мережа, яка складається з декількох шарів: вхідного, внутрішніх (прихованих) та вихідного.

Вхідний шар реалізує зв'язок з вхідними даними, вихідний – з вихідними. На кожному шарі міститься декілька нейронів, з'єднаних між собою вагами.

На вхід якої подається набір вхідних змінних, що є оцінками вагомих факторів безпеки на ділянці дороги:

$$X = (X_1, X_2, \dots, X_n). \quad (3)$$

У якості вхідних змінних використано обсяг різнорідних даних: транспортно-технічних, метеорологічних та ін., що наведені у табл. 2. Мета полягає в тому, щоб передбачити єдину змінну, якою є ймовірність ризику аварії, використовуючи інструмент багатшарової нейронної мережі.

На виході нейронної мережі маємо одну вихідну змінну, яка може приймати одне із чотирьох значень, наведених у табл. 3, які є категоріями ймовірності ризику ДТП на даній ділянці дороги для даного транспортного засобу:

$$R = (0, 1, 2, 3). \quad (4)$$

Ці категоріальні змінні не можна безпосередньо вставити в матрицю плану, тому що нейронна мережа передбачає фіктивні змінні:

$$Y = (Y_1, Y_2, Y_3, Y_4) = \begin{bmatrix} 0 & 0 & 0 & 1 \\ 0 & 0 & 1 & 0 \\ 0 & 1 & 0 & 0 \\ 1 & 0 & 0 & 0 \end{bmatrix}. \quad (5)$$

Для набору значень вхідних змінних за допомогою нейронної мережі можна, наприклад, отримати наступний вихідний вектор, що представляє ймовірності настання конкретних ризикових станів:

$$Y = (0,15; 0,58; 0,35; 0,74)$$

Після перекодування найбільшого значення у векторі  $Y$  приймає значення 1, а решти – 0, в результаті отримуємо вектор ймовірності категорії ризику:

$$YD = (0, 0, 0, 1).$$

Отриманий результат показує, що для даного набору вхідних змінних ризик ДТП є «катастрофічним», отже потрібні негайні дії для його усунення.

Оскільки проект має дослідницьку мету, то використовувалася багатшарова нейронна мережа з функцією активації.

**Проектування нейромережі.** За теоремою Колмогорова функція  $n$  змінних може бути подана як суперпозиція одновимірних функцій у кількості  $2n+1$ . Отже, кількість прихованих елементів для даної системи можна обрати  $14 \times 2 + 1 = 29$ . Але не можна просто вибрати теоретичний максимум кількості вагомих коефіцієнтів, бо в цьому разі мережа навчиться мати справу тільки з тими даними, що надавалися в процесі тренування, і в результаті узагальнююча здатність мережі буде слабкою. Тому розмір прихованих шарів вибираємо емпірично з урахуванням особливостей розв'язуваної задачі, оцінюючи точність прогнозу моделі з різною структурою. Загальна структура двошарової нейронної мережі наведена на рис. 1.




Рис. 1. Структура нейронної мережі

Вхідний шар вважається нульовим. Кожен нейрон наступних шарів видає на вихід сигнал  $y$ , перетворюючи зважену суму виходів нейронів попереднього шару.

Завдання навчання багатшарових штучних нейронних мереж вирішує алгоритм зворотного поширення помилки. Обираємо для нього гладку функцію активації:

$$y = \frac{1}{1 + e^{-s}}. \quad (6)$$

Ця функція зручна тим, що її похідна виражається через саму функцію:

$$y' = y(1 - y). \quad (7)$$

Кількість тренувальних прикладів має приблизно дорівнювати кількості ваг мережі, помноженій на зворотну величину помилки, тобто

$$w < n/e, \quad (8)$$

де  $w$  – кількість тренувальних прикладів;  
 $e$  – припустима помилка,

$$w < 14 / 0,03 = 467.$$

Отже, приймаємо кількість тренувальних прикладів приблизно 500.

В процесі навчання одноразова перехресна перевірка передбачає розбиття вибірки на взаємно доповнювані підвибірки з метою проведення аналізу на одній частині (навчальному наборі) та перевірки результатів на іншій частині (тестовому наборі). Для зниження дисперсії здійснюється багаторазова перехресна перевірка, а результати перевірок усереднюються.

**Проектування системи.** Система запрограмована на Python з використанням FastAPI як HTTP API серверу, та Tensorflow для побудови нейронної мережі.

Алгоритм прогнозування ризику дорожньо-транспортного руху включає наступні кроки:

- 1) Отримати файл з історичними даними про аварії;
- 2) Перетасувати дані (для зменшення ризику переналаштування нейронної мережі);
- 3) Завантажити вхідні змінні  $X_i$  (зчитування змінних на основі прогнозування ризику ДТП, змінні можна додавати та видаляти, модель адаптована);
- 4) Перекодувати вихідні змінні  $X_i$  в числа, а потім в дуальні матриці;

5) Розділити дані на навчальний і тестовий набір (тестовий набір даних становить 20% від загального набору даних);

6) Поділити набір навчальних даних на дані навчання та перевірки;

7) Задати первісні ваги нейронної мережі в інтервалі  $(-1, 1)$ ;

8) Встановити максимальну кількість періодів навчання на 500 та виконати ініціалізацію нейронної мережі з коефіцієнтом навчання 0,01.

9) Якщо кількість епох навчання більше або дорівнює максимальній кількості епох, навчання припиняється, інакше для кожної епохи навчання виконати:

- вибір і подачу одного вхідного вектора нейрона з навчального набору;

- отримання реакції нейрона методом зворотного поширення,

- корекцію ваг нейронів на основі помилки;

- оцінку помилки класифікації в усьому навчальному наборі – якщо помилка менша за прийнятну межу, навчання завершується;

- оцінку успішності мережевої діяльності на тестовому наборі.

10) Виконати прогнозування вектора значень вихідної змінної (ризик) для конкретних значень вхідних змінних.

Архітектура системи прогнозування ризику складається з декількох компонентів, діаграма взаємодії яких наведена на рис. 2.

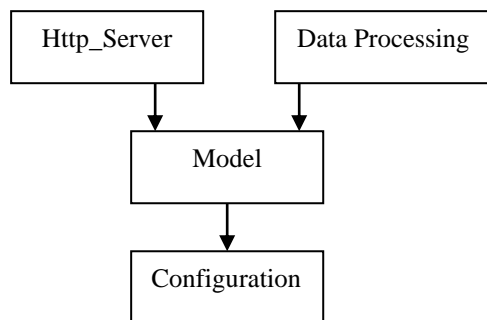


Рис. 2. Діаграма взаємодії компонентів

Загальна архітектура системи включає:

1) Компонент обробки даних Data Processing:

- dataset.csv та test\_dataset.csv - набори даних для тренування та тестування моделі;

- make\_dataset.com - скрипт для підготовки набору даних.

2) Компонент моделі Model:

- model.com - код для побудови та тренування нейронної мережі;

- model директорія, що містить файли, пов'язані з натренованою моделлю, включаючи параметри, збережені змінні та метадані моделі.

3) Компонент Http Server:

- http\_ari директорія, що містить код для реалізації HTTP API серверу;

- schemas.com - схеми даних для валідації вхідних та вихідних даних API;

- server.com - код, який обробляє HTTP запити, отримує вхідні дані та надає прогноз рівня небезпеки на дорозі.

4) Конфігураційний компонент Configuration:

- config.com - налаштування проекту, такі як параметри підключення до бази даних та налаштування HTTP сервера;

- gunicorn.conf.com - файл конфігурації для Gunicorn, що використовується для розгортання та обробки HTTP API.

5) Інші компоненти:

- check.com - скрипт для перевірки наявності необхідних залежностей та конфігурації перед запуском;

- requirements.txt - перелік залежностей, необхідних для розгортання та роботи проекту.

**Результати тестування.** Було оброблено кілька джерел ДТП, метеорологічних та інших пов'язаних даних. Попередньо дані були відсортовані, оброблені належним чином, а потім класифіковані. Всього було використано 14 показників, наведених у табл. 2.

В результаті аналізу отримано оптимальні параметри нейронної мережі, яка демонструє найвищу точність прогнозування: багатощарова нейронна мережа, що містить два прихованих шари, у першому прихованому шарі 80 нейронів, у другому прихованому шарі 40 нейронів. Емпіричне тестування виявило, що точність прогнозування зростала із зростанням кількості нейронів у кожному прихованому шарі. Кількість нейронів 80/40 демонструє точність 85-90%. З більшою кількістю нейронів точність прогнозу не зростає, але значно ускладнюються обчислення алгоритму.

Точність результату нейронної мережі для класифікації та прогнозування ризику дорожньо-транспортного руху склала 85-90%. Її порівнювали з точністю прогнозування за допомогою класифікації з використанням дерева рішень.

Використання дерев рішень показує набагато точність 70-80%. Точність у цьому випадку залежить від кількості дерев рішень і глибини кожного дерева рішень. Дерево випадкових рішень складається з кількох дерев рішень, і його кінцева точність є середнім значенням точності кожного дерева. Можна стверджувати, що із збільшенням кількості дерев рішень і зростанням глибини дерева рішень точність кінцевого прогнозу зростає.

## Висновки

У роботі розглянуто можливості прогнозування та класифікації відносного ризику дорожньо-транспортних рухів з реальними вхідними даними, що збираються в ITS, за допомогою нейронних мереж.

Систематизовано фактори безпеки дорожньо-транспортного руху та зроблено вибір значущих факторів для вхідних даних нейронної мережі системи прогнозування ризику.

Розроблено алгоритм прогнозування ризику дорожньо-транспортного руху нейронною мережею та архітектуру системи.

Система запрограмована на Python з використанням FastAPI, як HTTP API серверу, та Tensorflow для побудови нейронної мережі.

Точність передбачення нейронної мережі порівнювали з точністю прогнозів дерева рішень, і нейронні мережі показали найвищу точність.

Отримані результати можуть мати практичне застосування для попередження водіїв про високий рівень небезпеки. Перспективами подальших досліджень є розширення кількості вхідних змінних нейронної мережі, проведення експериментів з різноманітною вхідною інформацією.

#### СПИСОК ЛІТЕРАТУРИ

1. Офіційний сайт патрульної поліції України. Статистика. URL: <https://patrolpolice.gov.ua/statystyka/>
2. Положий Д. С., Орехов О. О. Інтелектуальні системи автомобільної безпеки на основі хмарних архітектур // Системи управління, навігації та зв'язку, 2023. № 4. С. 91-95.
3. Кашканов А.А., Пальчевський О.В. Інтелектуалізація управління дорожнім рухом як засіб підвищення ефективності транспортної мережі міста в неординарних ситуаціях // DOI: <https://doi.org/10.31649/2413-4503-2022-16-2-42-50>
4. Anukruthi Karre, Akramul Azim. Collision Prediction of Smart Cities Using Co-simulation // Procedia Computer Science 224 (2023) 205-214. URL: [www.sciencedirect.com](http://www.sciencedirect.com)
5. Hou J., List G. F., Guo X. 2014. New Algorithms for Computing the Time-to-Collision in Freeway Traffic Simulation Models URL: <https://doi.org/10.1155/2014/761047>
6. Sharma, B.; Katiyar, V.K.; Kumar, K. Kranti Kumar Traffic Accident Prediction Model Using Support Vector Machines with Gaussian Kernel. In Proceedings of Fifth International Conference on Soft Computing for Problem Solving; Pant, M., Deep, K., Bansal, J.C., Nagar, A., Das, K.N., Eds.; Springer: Singapore, 2016; pp. 1–10.
7. Wu, Q.; Hui, L.C.K.; Yeung, C.Y.; Chim, T.W. Early car collision prediction in VANET. In International Conference on Connected Vehicles and Expo (ICCVE); IEEE: Shenzhen, China, 2015; pp. 19–23.
8. Aung N., Zhang, W., Dhelim, S., Yibo Ai. Accident Prediction System Based on Hidden Markov Model for Vehicular Ad-Hoc Network in Urban Environments //MDPI, 2018, 9, 311. doi:10.3390/info9120311
9. Strickland, M., Fainekos, G., & Ben Amor, H. (2018). Deep predictive models for collision risk assessment in autonomous driving. In *2018 IEEE International Conference on Robotics and Automation, ICRA 2018* (pp. 4685-4692). Institute of Electrical and Electronics Engineers Inc.. URL: <https://doi.org/10.1109/ICRA.2018.8461160>
10. Iqbal, A., Busso, C., Gans, N.R. (2015) Adjacent Vehicle Collision Warning System using Image Sensor and Inertial Measurement Unit. In Proceedings of the 2015 ACM on International Conference on Multimodal Interaction—ICMI '15, Seattle, WA, USA, 9–13 November 2015; ACM Press: New York, NY, USA, 2015; pp. 291–298.
11. C. Chen, L. Liu, T. Qiu, Z. Ren, J. Hu, and F. Ti, "Driver's intention identification and risk evaluation at intersections in the Internet of vehicles," *IEEE Internet Things J.*, vol. 5, no. 3, pp. 1575–1587, Jun. 2018.
12. Halim Z., Sulaiman M., Waqas M. (2022). Deep neural network-based identification of driving risk utilizing driver dependent vehicle driving features: a scheme for critical infrastructure protection // Journal of Ambient Intelligence and Humanized Computing, 2022, 14(2):1-19. DOI:10.1007/s12652-022-03734-y
13. Oprea,S., Martinez-Gonzalez,P., Garcia-Garcia,A., Castro-Vargas,J.A., Orts-Escolano,S., Garcia-Rodriguez,J., Argyros,A. (2020). A review on deep learning techniques for video prediction / IEEE Transactions on Pattern Analysis and Machine Intelligence.
14. Kushwaha, M.; Abirami, M.S. (2023). Intelligent Model for Avoiding Road Accidents Using Artificial Neural Network, *International Journal of Computers Communications & Control*, 18(5), 5317, 2023. <https://doi.org/10.15837/ijccc.2023.5.5317>
15. Maaloul, B. (2018). Video-based algorithms for accident detections. Ph.D. thesis. Universit. Ede Valencienne set du Hainaut-Cambresis; Universit. edeMons.
16. Robles-Serrano, S., Sanchez-Torres,G., Branch-Bedoya,J., 2021. Automatic detection of traffic accidents from video using deep learning techniques. Computers 10, 148.
17. Coll-Josifov, R., Masip-Alvarez, A., Lav`ernia-Ferer, D., 2022. Deep learning classification applied to traffic accident prediction, in: XLIII Jornadasde Autom.atica, Universidadeda Coru`na .Servizode Publicaci. ons. pp. 964–971.
18. Сергиенко Н.Е., Маренич А.Н. Бортова система контролю стану водія // Автомобільний транспорт, 2010. Вип. 27. С. 148-152.
19. Purkrábková, Z., Růžička, J., Bělinová, Z., Korec, V. Traffic accident risk classification using neural networks // Neural Network World, 2021, Issue 5, p.343

Received (Надійшла) 12.11.2024

Accepted for publication (Прийнята до друку) 19.02.2025

#### Prediction of traffic risks based on a neural network

Denys Polozhyi, Oleksandr Oriekhov

**Abstract.** On the basis of the structural analysis of traffic accident statistics in Ukraine, the most dangerous causes were identified: exceeding the safe speed, violation of maneuvering rules, violation of the rules for crossing intersections and pedestrian crossings. The proposed models for predicting the danger of road traffic and the risk of driving are considered. The factors of road traffic danger have been studied and systematized. A traffic risk prediction model is proposed using an intelligent transport system (ITS) and a neural network. The model is built on the technology of neural network processing of weighted statistical and dynamic arrays of input data characterizing the internal and external environment of the vehicle in order to obtain a traffic risk assessment. A neural network risk prediction algorithm is proposed. The learning of a multilayer neural network is carried out using the backpropagation algorithm. Testing of the forecasting system demonstrated the accuracy of predictions of 85-90%.

**Keywords:** traffic safety, risk factors, modeling, vehicle, neural network, intelligent transport system.