

Дніпровський національний університет імені Олеся Гончара
Міністерство освіти і науки України
Дніпровський національний університет імені Олеся Гончара
Міністерство освіти і науки України

Кваліфікаційна наукова праця
на правах рукопису

СТРЕМБОВСЬКИЙ ВОЛОДИМИР ВАСИЛЬОВИЧ

УДК 533.6

ДИСЕРТАЦІЯ

**ОПТИМІЗАЦІЯ ТРАЄКТОРІЙ РУХУ КОСМІЧНИХ ОБ'ЄКТІВ В
АТМОСФЕРІ ЗЕМЛІ ЗА ТЕПЛОВИМ ЧИННИКОМ**

113 Прикладна математика

11 Математика та статистика

Подається на здобуття ступеня доктора філософії. Дисертація містить результати власних досліджень. Використання ідей, результатів і текстів інших авторів мають посилання на відповідне джерело

_____ В. В. Стрембовський

Науковий керівник:
Дреус Андрій Юлійович
доктор технічних наук, професор

Дніпро – 2025

АНОТАЦІЯ

Стрембовський В.В. Оптимізація траєкторій руху космічних об'єктів в атмосфері Землі за тепловим чинником. – Кваліфікаційна наукова праця на правах рукопису.

Дисертація на здобуття доктора філософії за спеціальністю 113 Прикладна математика. – Дніпровський національний університет імені Олеся Гончара, м. Дніпро, 2025.

У зв'язку зі зростанням числа штучних супутників, ракетних запусків та випадків фрагментації космічних об'єктів проблема космічного сміття набуває дедалі більшої актуальності в контексті світової космічної безпеки. На низьких навколоземних орбітах сконцентровано десятки тисяч нефункціональних об'єктів, що становлять значну загрозу для діючих апаратів і міжнародної інфраструктури. Одним із найперспективніших підходів до зменшення кількості космічних відходів є кероване відведення космічних об'єктів з орбіти за допомогою комбінованих методів видалення із забезпеченням їх необоротного згоряння в атмосфері Землі.

Для досягнення необхідного рівня ефективності та безпеки процесу зведення слід здійснювати оптимізацію траєкторії спуску таким чином, щоб гарантовано забезпечити повну термічну деструкцію об'єкта та мінімізувати ризик досягнення уламками поверхні Землі. У цьому зв'язку виникає задача оптимізації траєкторій відведення космічних об'єктів, яка передбачає максимізацію теплового навантаження в критичних ділянках конструкції та визначення оптимального кута входу для забезпечення повного знищення без створення нових загроз. Розв'язання такої задачі може бути реалізовано з використанням сучасних методів математичної оптимізації та технологій штучного інтелекту.

Впровадження цих методик сприятиме вирішенню проблеми екологічної безпеки космічного простору та відповідає стратегічним завданням космічних держав, зокрема України. Застосування моделей аеродинамічного нагріву, методів оптимального керування, машинного

навчання та генетичного алгоритму оптимізації дозволяє створити високоефективний комплексний підхід для проєктування сучасних активних і комбінованих технологій відведення космічного сміття.

У вступі викладено обґрунтування вибору теми на тлі стрімкого накопичення космічного сміття та пов'язаних ризиків для орбітальної інфраструктури. Окреслено зв'язок роботи за науковими програмами і темами. Сформульовано мету і задачі дослідження. Визначено об'єкт і предмет дослідження. Підкреслено очікувану наукову новизну й практичну цінність роботи. Наведено відомості про особистий внесок автора, структуру і обсяг дисертації.

У першому розділі здійснено розширений аналітичний огляд класичних напівемпіричних кореляцій, CFD-підходів та інженерних програмних пакетів для оцінювання теплових навантажень при вході в атмосферу. Розглянуто стан технологій активного, пасивного та комбінованого видалення космічного сміття, включно з результатами демонстраційних місій. Виявлено провідну роль кута входу й початкових кінематичних параметрів у формуванні інтегрального теплового навантаження на КО. Сформульовано перелік невирішених науково-прикладних питань, що потребують удосконалення й визначають напрямок дисертаційного дослідження.

У другому розділі побудовано фізично-математичну модель руху КО в атмосфері Землі та сформульовано задачу максимізації інтегрального теплового навантаження з урахуванням кінематичних і термостійкісних обмежень. Запропоновано варіаційну постановку, у якій кут входу θ виступає оптимізовним параметром, а нагрів описується інтегралом теплового потоку. Обґрунтовано використання гібридної схеми «машинне навчання + генетичний алгоритм», що поєднує швидкий нейромережевий прогноз теплового навантаження із глобальним еволюційним пошуком оптимального кута входу. Визначено робочі діапазони параметрів моделей та критерії прийнятності розв'язків щодо точності та обчислювальних витрат.

У третьому розділі детально викладено процедуру формування навчального датасету з каталогу ESA DISCOS: очищення, усунення викидів, генерацію похідних ознак і стратифіковане розбиття на підвибірки. Проведено статистичний аналіз, який підтвердив відсутність мультиколінеарності та визначив релевантність кожної ознаки. Описано вибір архітектур машинного навчання, а також реалізовано баєсову оптимізацію їхніх гіперпараметрів. Показано, як підготовлена вибірка й налаштовані моделі інтегруються у подальший ГА-процес оптимізації траєкторій.

У четвертому розділі виконано фінальне навчання обраних нейромереж на повному датасеті та здійснено їх порівняльну оцінку за валідною похибкою, швидкодією та ресурсними витратами. Transformer-модель піддалася зовнішній валідації на незалежних експериментальних даних ESA, що підтвердило її високий рівень узагальнення. Використовуючи цю модель як функцію пристосованості, проведено серію ГА-експериментів для різних масово-геометричних конфігурацій, отримано оптимальні кути входу й визначено відповідні інтегральні теплові навантаження. Сформульовано практичні рекомендації щодо параметрів деорбітальних маневрів, які підвищують ймовірність повного згоряння КО в атмосфері

Наукова новизна одержаних результатів полягає в наступному:

- розроблено модель машинного навчання для оцінки теплових навантажень на об'єкт, що рухається в атмосфері Землі, яка вперше забезпечує комплексний аналіз впливу траєкторних параметрів на формування теплових потоків у атмосферних ділянках траєкторій.
- запроваджено гібридну методику, що поєднує алгоритми машинного навчання для високоточних прогнозів характеристик теплового потоку з генетичним алгоритмом для оптимізації параметрів входження об'єкта в атмосферу.

Практичне значення даного дослідження полягає у розробці методології розрахунку та оптимізації траєкторій сходження космічних об'єктів з навколоземної орбіти з урахуванням теплового чинника.

Запропонована методика може бути застосована під час проєктування місії активного видалення космічних відходів для обґрунтованого вибору параметрів входження в атмосферу, що забезпечують повне згорання об'єкта без утворення небезпечних фрагментів, здатних досягти поверхні Землі або лишитися на орбіті.

Отримані результати становлять основу для створення автоматизованих програмних комплексів, які поєднують алгоритми оптимізації, методи машинного навчання та моделі теплової деструкції для підтримки прийняття рішень у режимі реального часу під час керування сходженням космічних тіл.

Крім того, розроблена методика може бути використана в освітньому процесі та підготовці фахівців як приклад міждисциплінарної задачі, що інтегрує елементи космічної механіки, термодинаміки, оптимізації та штучного інтелекту.

Ключові слова: космічне сміття, теплове навантаження, машинне навчання, архітектура Transformer, генетичний алгоритм, оптимізація траєкторій, аеродинамічний нагрів, математичне моделювання, траєкторія входу, нейронні мережі, елементи конструкцій, конструкційні матеріали, космічні апарати, глибоке навчання.

ABSTRACT

Strembovskiy V.V. Optimization of space objects' trajectories in the Earth's atmosphere based on the thermal factor. – Qualification scientific work in the form of a manuscript.

Dissertation for the degree of Doctor of Philosophie in specialty 113 Applied Mathematics. – Oles Honchar Dnipro National University, Dnipro, 2025.

The rapid increase in artificial satellites, launch activities, and fragmentation events has amplified the space-debris problem, making it a critical issue for global space safety. Tens of thousands of non-functional objects are now clustered in low-Earth orbits, posing a substantial threat to operational spacecraft and international infrastructure. One of the most promising mitigation approaches is the controlled de-orbiting of space objects using combined removal techniques that guarantee their irreversible ablation in Earth's atmosphere.

Achieving the requisite efficiency and safety calls for optimising the descent trajectory so that complete thermal destruction of an object is ensured while the probability of surviving fragments reaching the surface is minimised. This leads to an optimisation problem in which the entry trajectory must maximise thermal loads in structurally critical regions and determine an entry-angle profile that yields full demise without creating new hazards. Modern mathematical-optimisation tools and artificial-intelligence techniques provide a viable pathway for solving this problem.

Implementing such methods will contribute to the ecological safety of outer space and aligns with the strategic objectives of space-faring nations, including Ukraine. By combining aerodynamic-heating models, optimal-control methods, machine-learning algorithms, and a genetic-algorithm optimiser, the present research develops a highly effective integrated framework for designing contemporary active and combined debris-removal technologies.

Introduction – Justifies the topic selection against the backdrop of accelerating debris accumulation and the attendant risks to orbital infrastructure. Links the work to relevant research programmes, states the aim and objectives, specifies the object and subject of study, highlights the expected scientific novelty

and practical value, and outlines the author’s personal contribution, structure, and length of the thesis.

Chapter 1 – Provides an extended analytical review of classical semi-empirical correlations, CFD-based approaches, and engineering software used to estimate atmospheric heating loads. Current active, passive, and combined removal technologies—including demonstration missions—are surveyed. The dominant role of entry angle and initial kinematic parameters in shaping the integral thermal load is established, and a set of unresolved applied-science questions that motivate the thesis is formulated.

Chapter 2 – Develops a physico-mathematical model of an object’s motion through Earth’s atmosphere and formulates the problem of maximising the integral thermal load under kinematic and material constraints. A variational statement is proposed in which the entry angle θ is the optimisation variable and heating is expressed via the time integral of the heat-flux profile. A hybrid “machine-learning + genetic-algorithm” scheme is substantiated, combining rapid neural-network predictions of heating loads with global evolutionary search for the optimal entry angle. Working parameter ranges and admissibility criteria balancing accuracy and computational cost are specified.

Chapter 3 – Describes the construction of a training data set from the ESA DISCOS catalogue: cleaning, outlier removal, creation of derived features, and stratified partitioning. Statistical analysis confirms the absence of multicollinearity and establishes the relevance of each feature. Machine-learning architectures are selected, and Bayesian hyperparameter optimisation is implemented. The prepared data and tuned models are then embedded into the subsequent GA-based trajectory-optimisation workflow.

Chapter 4 – Presents final training of the selected neural networks on the complete data set and compares them in terms of validation error, computational speed, and resource demand. The Transformer model undergoes external validation against independent ESA experimental data, demonstrating strong generalisation. Using this model as a fitness function, a series of GA experiments covering various

mass-and-geometry configurations yields optimal entry angles and corresponding integral thermal loads. Practical recommendations are formulated for de-orbit manoeuvre parameters that maximise the probability of full atmospheric demise.

Scientific contributions

- a machine-learning model for atmospheric-heating assessment is developed that, for the first time, provides a comprehensive analysis of how trajectory parameters influence heat-flux formation along re-entry paths.

- a hybrid methodology is introduced that integrates high-accuracy machine-learning predictions of heat-flux characteristics with a genetic algorithm for optimising atmospheric-entry parameters.

Practical significance

The research offers a methodology for calculating and optimising re-entry trajectories of space objects from low-Earth orbit with explicit consideration of thermal factors. The proposed framework can be applied during mission design for active debris-removal systems to select entry parameters that ensure complete burn-up without generating hazardous fragments capable of reaching Earth's surface or remaining in orbit. The results lay the groundwork for automated decision-support tools that couple optimisation algorithms, machine-learning methods, and thermal-destruction models for real-time re-entry management. Moreover, the methodology can serve as an educational case study illustrating the integration of space mechanics, thermodynamics, optimisation, and artificial intelligence.

Keywords: space debris, thermal load, machine learning, Transformer architecture, genetic algorithm, trajectory optimization, aerodynamic heating, mathematical modeling, reentry trajectory, neural networks, structural elements, construction materials, spacecraft, deep learning.

СПИСОК ПУБЛІКАЦІЙ ЗДОБУВАЧА

1. Strembovskyi V., Dreus A. Identification of heat loads on space objects re-entering the Earth's atmosphere using machine learning methods. *Journal of Rocket-Space Technology*. 2024. Vol. 33, no. 4-29. P. 65–73. URL: <https://doi.org/10.15421/452452>. **(фахове видання, категорія Б)** (особистий внесок авторів: Стрембовський В.В.: побудовано моделі машинного навчання та виконано розрахунки, Дреус А.Ю.: постановка задачі).
2. Strembovskyi V. V., Dreus A. Y. Аналіз практики використання методів машинного навчання для моделювання траєкторій руху космічних об'єктів. *Journal of Rocket-Space Technology*. 2024. Т. 33, № 4. С. 108–117. URL: <https://doi.org/10.15421/452415>. **(фахове видання, категорія Б)** (особистий внесок авторів: Стрембовський В.В.: проведено аналіз та систематизацію світових практик використання методів машинного навчання для вирішення задач космічних місій, Дреус А.Ю.: постановка задачі).
3. A. Yu. DREUS, M. M. DRON, L. G. DUBOVIK, V. V. STREMBOVSKIYI Assessment of the possibility of using polymers in the bodies of promising launch vehicles based on the heat resistance factor. *Kosmìčna nauka i tehnologiâ*. 2023. Vol. 29, no. 6. P. 03–12. URL: <https://doi.org/10.15407/knit2023.06.003>. **(фахове видання, категорія А, Scopus, Q4)** (особистий внесок авторів: Стрембовський В.В.: аналіз впливу теплових навантажень на характеристики матеріалів, Дреус А.Ю.: математична модель, Дронь М.М.: результати експериментальних досліджень, Дубовик Л.Г.: обговорення результатів).
4. Dreus, A.; Strembovskyi, V.; Dubovik, L.; Dron, M.; Golubek, A. Thermal optimization of trajectories of space debris removal into the earth's atmosphere. *Proceedings of the International Astronautical Congress, IAC, 2022*. ISSN: 00741795. | **(Scopus)** (особистий внесок авторів: Стрембовського В.В.: розроблено алгоритм генетичної оптимізації, Дреус А.Ю.: концептуалізація, Дронь М.М.: математична модель, результати експериментальних досліджень, Дубовик Л.Г.: обчислювальні експерименти, Голубек О.В.: опис комбінованого методу відведення КО).

ЗМІСТ

ВСТУП.....	12
РОЗДІЛ 1. СУЧАСНИЙ СТАН ІСНУЮЧИХ ПІДХОДІВ ОЦІНКИ ТЕПЛОВИХ НАВАНТАЖЕНЬ НА КОСМІЧНІ ОБ'ЄКТИ ПІД ЧАС РУХУ В АТМОСФЕРІ ЗЕМЛІ.....	16
1.1. ПРОБЛЕМА КОСМІЧНОГО СМІТТЯ В АТМОСФЕРІ ЗЕМЛІ.....	16
1.2. МЕТОДИ БОРОТЬБИ З КОСМІЧНИМ СМІТТЯМ	18
1.2.1. Активне видалення сміття.....	18
1.2.2. Пасивне видалення космічних об'єктів	18
1.2.3. Комбіновані методи	19
1.3. Огляд підходів до опису процесів нагрівання КО в АТМОСФЕРІ 21	
1.3.1. Напівемпіричні та аналітичні формули	23
1.3.2. Об'єктно-орієнтовані інструменти повторного входу.....	28
1.3.3. Високоточне моделювання на основі фізичних процесів.....	30
1.4. НОВІТНІ ПІДХОДИ ДО ВИРІШЕННЯ ПРОБЛЕМ КОСМІЧНОГО СМІТТЯ ..	30
1.4.1. Застосування машинного навчання в задачах космічної тематики	31
1.4.2. Генетичні алгоритми та еволюційні методи	38
Висновки до розділу 1	41
РОЗДІЛ 2. ПОСТАНОВКА ЗАДАЧІ ПРО ОПТИМІЗАЦІЮ НАГРІВУ І МЕТОДОЛОГІЯ ДОСЛІДЖЕННЯ	42
2.1. ПОСТАНОВКА ЗАДАЧІ ПРО ОПТИМІЗАЦІЮ НАГРІВУ КО.....	42
2.1.1. Фізична постановка задачі.....	42
2.1.2. Математична постановка задачі.....	46
2.2. ОБЧИСЛЮВАЛЬНА СТРАТЕГІЯ	51
2.2.1. Загальні відомості про методи МН та ГА	51
2.2.2. Опис алгоритму розв'язання задачі	57
Висновки до розділу 2.....	61
РОЗДІЛ 3. АНАЛІЗ ВХІДНИХ ДАНИХ ДЛЯ ПОБУДОВИ ДАТАСЕТУ ТА РОЗГЛЯД АРХІТЕКТУР МАШИННОГО НАВЧАННЯ.....	63
3.1. АНАЛІЗ ТА ПІДГОТОВКА ДАНИХ	63
3.2. ОЦІНКА АЕРОДИНАМІЧНИХ І ГЕОМЕТРИЧНИХ ПАРАМЕТРІВ C_d ТА R_n ..	75
3.3. ФОРМУВАННЯ ФІНАЛЬНОГО ДАТАСЕТУ ДЛЯ МАШИННОГО НАВЧАННЯ .	76
3.4. РОЗРОБКА МОДЕЛЕЙ МАШИННОГО НАВЧАННЯ	79
3.4.1. Модель <i>MLP</i>	80
3.4.2. Модель <i>LSTM</i>	83
3.4.3. Модель <i>Transformer</i>	87
3.4.4. Порівняльний аналіз <i>MLP</i> , <i>LSTM</i> та <i>Transformer</i>	93
3.4.5. Гіперпараметри моделей та їхній вплив	95
3.5.3. Налаштування гіперпараметрів <i>ГА</i>	104
Висновки до розділу 3.....	106

РОЗДІЛ 4. ПРАКТИЧНА РЕАЛІЗАЦІЯ	108
4.1. ПРОЦЕС НАВЧАННЯ ТА ТЕХНІКИ РЕГУЛЯРИЗАЦІЇ.....	108
4.2. РЕЗУЛЬТАТИ ОПТИМІЗАЦІЇ ГІПЕРПАРАМЕТРІВ МАШИННОГО НАВЧАННЯ	109
4.3. РЕЗУЛЬТАТИ ФІНАЛЬНОГО НАВЧАННЯ АЛГОРИТМІВ MLP, LSTM І TRANSFORMER.....	113
4.4. ЕКСПЕРИМЕНТАЛЬНА ВАЛІДАЦІЯ МОДЕЛІ TRANSFORMER НА НЕЗАЛЕЖНИХ ДАНИХ КАТАЛОГУ DISCOS ESA	116
4.5. РЕЗУЛЬТАТИ ГЕНЕТИЧНОЇ ОПТИМІЗАЦІЇ КУТА ВХОДУ КО В АТМОСФЕРІ ЗЕМЛІ	118
ВИСНОВКИ ДО РОЗДІЛУ 4	123
ВИСНОВКИ.....	125
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ.....	127
ДОДАТОК А СПИСОК ПУБЛІКАЦІЙ АВТОРА ЗА ТЕМОЮ ДИСЕРТАЦІЇ.....	148
ДОДАТОК Б ПРОГРАМНИЙ КОД МОДЕЛІ TRANSFORMER ТА РЕАЛІЗАЦІЇ ГА	149

ВСТУП

Обґрунтування вибору теми дослідження. Зі зростанням кількості штучних супутників, запусків ракет та фрагментаційних подій, проблема космічного сміття вийшла на передній план світової космічної безпеки. На навколоземних орбітах – особливо на низьких (LEO) – накопичено десятки тисяч об'єктів, що вже не функціонують, але становлять реальну загрозу для активних апаратів та міжнародної інфраструктури.

Одним із перспективних методів зменшення кількості космічного сміття є кероване зведення об'єктів з орбіти з подальшим згоранням в атмосфері Землі. Щоб зробити цей процес ефективним і безпечним, необхідно оптимізувати траєкторію спуску так, щоби забезпечити гарантовану термічну деструкцію об'єкта, мінімізуючи ризик досягнення уламками земної поверхні. У цьому контексті виникає задача оптимізації траєкторій відведення космічних об'єктів (елементів сміття), що забезпечує: максимізацію теплового навантаження в критичних зонах конструкції, визначення ефективного кута входу для повного знищення об'єкта без створення нових загроз. Розв'язання такої задачі може бути виконано з використанням сучасних методів математичної оптимізації з використанням технологій штучного інтелекту.

Актуальність дослідження обумовлюється тим, що тематика досліджень пов'язана з новими методами керованого відведення фрагментів космічного сміття з LEO, що розробляються в теперішній час в Україні. Впровадження таких методів сприятиме вирішенню проблеми екологічної безпеки космічного простору, та є стратегічною задачею для всіх космічних держав, до яких відноситься і Україна. Використання моделей аеродинамічного нагріву, оптимального керування, машинного навчання та генетичної оптимізації дозволяє створює новий високоефективний підхід для проєктування новітніх активних і комбінованих методів та технологій відведення космічного сміття.

Зв'язок з науковими програмами та темами. Тематика досліджень пов'язана з держбюджетною темою 4-648-20 «Теоретичне і експериментальне обґрунтування автофажних систем відведення космічних об'єктів з низьких навколоземних орбіт», № держреєстрації 0120U102254, що фінансувалася Міністерством освіти і науки в Дніпровському національному університеті імені Олеся Гончара.

Метою роботи є розробка інтегрованої методики прогнозування максимальних теплових навантажень та вибору траєкторних параметрів руху космічних об'єктів в атмосфері Землі на основі поєднання методів машинного навчання і генетичної оптимізації.

Для досягнення поставленої мети визначено такі **наукові завдання**:

1. Аналітичний огляд існуючих математичних моделей та інженерних методик прогнозування аеродинамічного нагріву КО; виокремлення кола підзадач, у яких традиційні підходи демонструють обмежену точність або надмірні обчислювальні витрати.
2. Формування репрезентативного датасету, що охоплює траєкторні, геометричні та фізико-механічні параметри КО; забезпечення очищення, нормалізації та генерації розширених комбінацій вхідних ознак для подальшого моделювання.
3. Розробка та навчання моделей машинного навчання; оцінка ефективності алгоритмів МН; вибір оптимальної архітектури.
4. Побудова генетичного алгоритму для пошуку оптимальних траєкторних параметрів, що максимізують інтегральне теплове навантаження на критичному інтервалі.
5. Узагальнення рекомендацій щодо вибору початкових умов входу для різних типових класів космічних об'єктів; формулювання практичних вказівок для проєктування місій активного або комбінованого видалення сміття з урахуванням теплового чинника.

Об'єкт дослідження. Процес керованого відведення космічного сміття з орбіти шляхом входу в атмосферу Землі.

Предмет дослідження. Математичні моделі та алгоритми оптимізації траєкторій зниження космічних об'єктів з урахуванням теплового навантаження, зокрема на основі машинного навчання та генетичних алгоритмів.

Методи дослідження. У процесі дослідження використовувався комплекс методів, що охоплюють: аналіз і синтез науково-технічної інформації – для вивчення існуючих підходів до прогнозування аеродинамічного нагріву, зведення об'єктів з орбіти та методів оптимального керування, методи математичного моделювання – для побудови моделей руху космічних об'єктів в атмосфері, включаючи рівняння динаміки польоту, моделі аеродинамічного опору та теплового навантаження, методи машинного навчання— для побудови емпіричних моделей прогнозування теплового навантаження на основі великої кількості вхідних параметрів (форма, маса, кут входу, швидкість тощо): регресійні моделі, дерева рішень, нейронні мережі, генетичні алгоритми – для оптимізації траєкторних параметрів з урахуванням цільової функції, що включає максимізацію теплового навантаження та мінімізацію ризику досягнення уламками земної поверхні.

Наукова новизна.

1. Вперше для визначення теплових навантажень на об'єкт що рухається в атмосфері Землі побудована модель МН що дозволяє комплексно оцінити вплив траєкторних параметрів на теплові потоки що виникають на атмосферних ділянках траєкторій.
2. Вперше використано гібридний підхід, що поєднує машинне навчання для точного прогнозування характеристик теплового потоку та генетичний алгоритм для оптимізації параметрів траєкторії входу в атмосферу.

Практична значимість дослідження полягає в розробці методики для розрахунку до оптимізації траєкторій зведення космічних об'єктів з орбіти з

урахуванням теплового чинника. Запропонована методика може бути використана під час проєктування місії активного видалення космічного сміття для вибору параметрів входу в атмосферу, що забезпечують гарантоване згорання об'єкта без утворення фрагментів, які можуть досягти земної поверхні або залишитися на орбіті. Для створення автоматизованих програмних комплексів – які поєднують алгоритми оптимізації, машинного навчання та моделі теплової деструкції для підтримки рішень у реальному часі при управлінні спуском космічних тіл, а також У навчальному процесі та підготовці фахівців – як приклад міждисциплінарної задачі, що поєднує космічну механіку, термодинаміку, оптимізацію та штучний інтелект.

Достовірність отриманих результатів забезпечується застосуванням загальноновизнаних та багаторазово апробованих моделей, коректним формулюванням математичних постановок задач, використанням теоретично обґрунтованих методів і алгоритмів, що не суперечать усталеним науковим положенням. Окрім цього, достовірність підтверджується контрольованою точністю обчислень, проведенням валідації моделей на незалежних вибірках, а також узгодженістю отриманих результатів з опублікованими даними інших дослідників.

Публікації та особистий внесок здобувача.

Основні результати роботи викладено в 4 працях, серед яких 2 входять до наукометричної бази Scopus, 2 опубліковані в фахових виданнях України категорії Б. Список наведено в Додатку А. Усі основні ідеї, розрахунки та результати дисертаційної роботи отримані здобувачем самостійно.

Структура та обсяг дисертації.

Робота складається зі вступу, чотирьох розділів, висновків, списку використаної літератури та додатків, що містять 40 рисунків та 15 таблиць, загальний обсяг роботи складає 154 сторінки, список літератури займає обсяг 20 сторінок.

РОЗДІЛ 1. СУЧАСНИЙ СТАН ІСНУЮЧИХ ПІДХОДІВ ОЦІНКИ ТЕПЛОВИХ НАВАНТАЖЕНЬ НА КОСМІЧНІ ОБ'ЄКТИ ПІД ЧАС РУХУ В АТМОСФЕРІ ЗЕМЛІ

1.1. Проблема космічного сміття в атмосфері Землі

З моменту запуску першого штучного супутника кількість тіл, що обертаються навколо Землі, постійно зростає за експоненціальним трендом. У Звіті про космічне сміття [1] показано поточні тенденції щодо об'єктів розміром понад 10 см, що знаходяться на орбіті Землі. Кількість космічних об'єктів (КО), їхня сумарна маса та площа неухильно збільшуються, що призводить до появи мимовільних зіткнень між робочим корисним навантаженням і космічним сміттям (рис. 1.1).




Рисунок – 1.1. Розподіл космічних об'єктів в атмосфері Землі згідно [2]

Ризик зіткнення з орбітальним сміттям для космічних апаратів або пілотованих кораблів є одним з основних факторів безпеки функціонування

космічних систем у навколоземному просторі [3], оскільки він може призвести до каскадного ефекту, потенційно неконтрольованого, відомого як синдром Кesslera [4]. Серед 20 000 великих об'єктів, які наразі знаходяться у відкритому каталозі [5], лише 2000 є діючими, з них 1500 є маневреними, що становить менше 10%, здатних за необхідності виконати активний маневр уникнення зіткнення.

У [6] автори вводять поняття «економічного синдрому Кesslera», момент, коли прибутки від запуску супутників падають нижче очікуваних витрат через зростання ризику зіткнень. Моделювання шести різних політик показує, що добровільна 95% стратегія слідування рекомендаціям ООН [7] чи податок на запуск лише сповільнюють, але не зупиняють накопичення уламків (рис. 1.2). Єдиний шлях до фактичного зменшення сміття – це активне видалення сміття із щорічним нарощуванням темпів, поєднане з високою дисципліною дотримання правил. Така комбінована стратегія здатна «очистити» орбіту (>10 см) до кінця XXI ст., тоді як без втручання сміття зростатиме експоненційно й зробить орбіти економічно непридатними.




Рисунок – 1.2. Кількість космічного сміття у різних сценаріях [6]

1.2. Методи боротьби з космічним сміттям

Згідно робіт [8-13] методи можна поділити на три великі групи: активне, пасивне та комбіноване видалення космічного об'єктів.

1.2.1. Активне видалення сміття

Активні методи передбачають використання спеціально оснащених космічних кораблів або роботизованих апаратів, які зближуються з орбітальним уламком і активно втручаються в його рух. Такі апарати можуть захоплювати сміття механічними засобами (сітками, гарпунами, роботизованими руками, клеючими поверхнями тощо) або змінювати його орбіту безконтактно (лазерним імпульсом [14, 15], іонним променем [16, 17]). У роботі [18] розроблено та експериментально підтверджено алгоритм керування гнучкою сіткою, що забезпечує надійне захоплення уламка і стабільний буксирний режим після обгортання. Автори у [19] виконали числові й мікрогравітаційні випробування гарпунної системи, встановивши вимоги до кінематичних параметрів пострілу та віддачі носія при перфорації великих об'єктів. Роботи [20, 21] оцінюють використання електродинамічних тросів у ролі «буксира».

1.2.2. Пасивне видалення космічних об'єктів

Пасивні методи спираються на природні чинники (атмосферний опір, гравітаційні збурення) або прості пристрої, встановлені на космічних апаратах, які після завершення місії допомагають їм самостійно зійти з орбіти. Ідея полягає в тому, щоб мінімізувати утворення нового сміття і прискорити природну деградацію орбіт без активного втручання іншого космічного апарата. Пасивні заходи, як правило, менш складні технічно і дешевші: їх закладають у конструкцію космічного апарата заздалегідь. Однак вони здебільшого ефективні для об'єктів на низьких навколоземних орбітах і не можуть швидко прибрати вже існуючі великі уламки, що не оснащені спеціальними пристроями. Стаття [22] демонструє, як можна використати

орбітальні резонанси для пасивного видалення космічного сміття, спонукаючи супутники до орбітальних змін, які прискорюють їхній розпад через атмосферний опір. Автори у [23] пропонують концепцію пасивного видалення орбітального сміття за допомогою розгортання великої площі поліімідної плівки, що сповільнює рух уламків і сприяє їх природному розпаду. Romagnoli і Theil у [24] змоделювали орбітальну динаміку сонячного вітрила і показали скорочення часу природного сходження більш ніж удвічі порівняно з пасивним атмосферним гальмуванням. У статті [25] авторами досліджено можливість використання іоносферного опору, що виникає внаслідок обміну імпульсом через електростатичну взаємодію між іонами та електронами іоносфери та електрично зарядженого космічного апарата, для прискорення сходження космічного апарата з низької навколоземної орбіти.

1.2.3. Комбіновані методи

Комбіновані методи поєднують елементи активного втручання з подальшим пасивним видаленням сміття. Такі гібридні підходи намагаються використати переваги обох стратегій: активна фаза забезпечує надійне захоплення або початкове переміщення уламка, а пасивна фаза зменшує сумарні енергетичні витрати та ризик утворення нових уламків при остаточному зведенні об'єкта з орбіти. Комбіновані рішення особливо корисні для великих КО: спочатку потрібен контрольований вплив, щоб змінити їхній рух, але далі аеродинамічні сили можуть завершити роботу. У роботі [26] представлено перший успішний орбітальний експеримент із видалення космічного сміття. Авторами продемонстровано послідовне використання сітки та гарпуна для фіксації цілі, після чого апарат розгорнув драг-вітрило й увійшов у атмосферу разом із захопленим кубосупутником, доводячи ефективність інтеграції активних і пасивних технологій у межах однієї платформи. У роботі [27] розглянуто новий комбінований підхід до відведення великогабаритного космічного сміття в щільні шари атмосфери Землі (рис. 1.3.). Цей метод передбачає спільне використання активного засобу –

реактивної рухової установки – і пасивного засобу – аеродинамічного парусного пристрою.




Рисунок – 1.3. Схема комбінованого відведення великогабаритних космічних об'єктів з використанням сміттєзбирача: а – Земля, б – сміттєзбірник з включеною реактивною руховою установкою, в – сміттєзбірник з вимкненою реактивною руховою установкою, г – орбіта д – цільовий об'єкт космічного сміття, е – сміттєзбірник з цільовим об'єктом космічного сміття і вимкненою реактивною руховою установкою, ж – сміттєзбірник з цільовим об'єктом космічного сміття і включеною реактивною руховою установкою, з – орбіта уводу, з – орбіта уводу до – сміттєзбірник з цільовим об'єктом космічного сміття і розгорнутим аеродинамічний вітрил [27]

Таким чином, найбільший потенціал для швидкого та безпечного очищення орбіт мають саме комбіновані рішення, які інтегрують силові (активні) та аеродинамічні чи фотонні (пасивні) методи в єдині місії, забезпечуючи ефективне захоплення й енергоощадний спуск космічного сміття.

1.3. Огляд підходів до опису процесів нагрівання КО в атмосфері

В процесі входження в атмосферу КО руйнуються під дією різних сил, таких як гравітація та аеродинаміка, і утворюють велику кількість уламків [28] (рис. 4).




Рисунок – 1.4. Загальна схема руйнування та згоряння КО в атмосфері Землі [9]

Більшість уламків руйнується внаслідок термічної абляції в атмосфері, але є ймовірність неповного руйнування і згоряння об'єкта та падіння на поверхню Землі з відповідними ризиками для людей і навколишнього середовища. Комбіновані методи відведення космічного сміття з низьких навколосеземних орбіт дозволяють контроль параметрів входження об'єкту в атмосферу [29], отже, є можливість впливу на тепловий режим об'єкту.

Прогнозування кількості отриманого тепла об'єктом є достатньо складною математичною задачею, яка потребує розв'язання систем диференціальних рівнянь балістики і аеротермодинаміки, врахування динаміки атмосфери, аеродинамічні характеристики, моделювання процесів прогріву і абляції і абляції. Це потребує значних обчислювальних ресурсів і відносно тривалого часу на розрахунок.

В найпростішому випадку для розрахунку аеродинамічного нагріву потрібно розв'язати систему диференціальних рівнянь руху КО в атмосфері [9]

$$\left. \begin{aligned} \frac{dp}{dt} &= 2\sqrt{\frac{p}{\mu}}TR \\ \frac{di}{dt} &= \frac{WR \cos u}{\sqrt{\mu p}} \\ \frac{d\Omega}{dt} &= \frac{WR \sin u}{\sqrt{\mu p} \sin i} \\ \frac{dl}{dt} &= \sqrt{\frac{p}{\mu}} \left[S \sin u + T \left(\frac{p+R}{p} \cos u + \frac{R}{p} l \right) + W \frac{R}{p} h \cot i \sin u \right] \\ \frac{dh}{dt} &= \sqrt{\frac{p}{\mu}} \left[-S \cos u + T \left(\frac{p+R}{p} \sin u + \frac{R}{p} h \right) - W \frac{R}{p} l \cot i \sin u \right] \\ \frac{du}{dt} &= \sqrt{\frac{p}{\mu}} \left(\frac{\mu}{R^2} - W \frac{R}{p} \cot i \sin u \right) \end{aligned} \right\}, \quad (1.1)$$

де p – фокальний параметр; i – нахилення; Ω – довгота висхідного вузла; l і h – параметри Лапласа; t – час; u – аргумент широти; S, T, W – радіальне, бінормальне й трансверсальне збурюючі прискорення; μ – гравітаційна постійна; $R = p/(1 + l \cos u + h \sin u)$ – геометрична відстань до КО.

До системи 1.1 додаються необхідні початкові умови, що визначають параметри входу КО в атмосферу. Серед таких параметрів найважливішими, з точки зору визначення траєкторії, є кут входу, початкова швидкість та висота. Теплове навантаження визначається як

$$q_t = q_{s \text{ conv}} + q_{s \text{ rad}}, \quad (1.2)$$

де $q_{s \text{ conv}}$ і $q_{s \text{ rad}}$ – конвекційна і радіаційна складові теплового потоку відповідно. В точці гальмування можуть бути представлені у вигляді [30]

$$q_{s \text{ conv}} = \frac{A_{\text{conv}}}{\sqrt{r}} \left(\frac{\rho}{\rho_0} \right)^n \left(\frac{V}{V_1} \right)^{3.25}, \quad (1.3)$$

де r – характерний розмір КО; ρ – густина атмосфери; ρ_0 – густина атмосфери на рівні моря; V – швидкість руху об’єкта по траєкторії; V_1 – перша космічна швидкість; показник n визначається характером пограничного шару. Для ламінарного пограничного шару, що має місце поблизу точки гальмування, $n = 0.5$. Коефіцієнт A_{conv} у системі СІ має значення $1.93 \times 10^5 \text{ кДж}/(\text{м}^{3/2} \text{ с})$. Радіаційна складова теплового потоку

$$q_{srad} = A_{rad} r \rho^{1.68} \left(\frac{V}{10^3} \right)^{7.4}, \quad (1.4)$$

де параметр $A_{rad} = 1.038 \times 10^{-4}$, розмірність q_{srad} у формулі (4) має значення $\text{кВт}/\text{м}^2$.

Отже, для кожного конкретного випадку входу КО в атмосферу необхідно розв’язувати систему (1)-(4) для визначення траєкторії і, відповідно, теплових навантажень з урахуванням змін параметрів атмосфери.

Різні підходи до моделювання балансують між точністю і обчислювальною вартістю для врахування цих взаємопов’язаних аспектів. Протягом багатьох років дослідники розробили цілий спектр моделей, від швидких інженерних інструментів до високоточних симуляцій, для прогнозування нагріву і згорання при вході в атмосферу.

1.3.1. Напівемпіричні та аналітичні формули

Емпіричні та аналітичні моделі ґрунтуються як на теоретичних висновках, так і на експериментальних спостереженнях. Ці моделі використовують рівняння або кореляції закритої форми для оцінки ключових величин, таких як поверхневі теплові потоки і швидкість абляції під час входу в атмосферу. Їхньою перевагою є простота і швидкість, що дозволяє робити швидкі оцінки без інтенсивних обчислень. Так у огляді [31] представлено всебічний аналіз аеродинамічних сил, нагріву та засобів теплового захисту – від абляційних матеріалів до теплоізоляційних покриттів. У статті [32]

авторами запропоновано підхід до оптимізації траєкторій повторного входження безградієнтними алгоритмами. У дослідженні [33] надано нові кореляції для розрахунку конвективного та радіаційного теплового потоку в точці стагнації. Автори у [34] пропонують аналітичні розв'язки другого порядку для задачі входження КО в атмосферу Землі. Аналіз виживаності уламків висвітлено в роботі [35]. Нарешті, в статті [36] запропоновано аналітичну методику з урахуванням каталітичної рекомбінації на поверхні уламків розміром 2.5-10 см.

У роботі [37] автори всебічно проаналізували історичний та сучасний набір напівемпіричних і аналітичних кореляцій, що застосовуються для швидкої інженерної оцінки конвективного теплового навантаження космічних об'єктів під час гіперзвукового проходження щільних шарів атмосфери. Усі формули орієнтовані на стагнаційний тепловий потік q_c і, попри відмінності у способі побудови, ґрунтуються на спільному закономірному зв'язку:

$$q_c \propto \frac{\sqrt{\rho_\infty}}{\sqrt{L}} V_\infty^3, \quad (1.5)$$

де $L = R_N = R_{eff}$ – еквівалентний радіус носової частини, ρ_∞ і V_∞ – щільність та швидкість вільного потоку. Вона підкреслює, що конвективний тепловий потік зростає з швидкістю та щільністю й спадає зі збільшенням радіуса тупого тіла.

Формула Fay–Riddell [38]

$$q_s = 0.94(\rho_w \mu_w)^{0.1} (\rho_e \mu_e)^{0.4} \left[1 + (Le^{0.52} - 1) \frac{h_D}{h_s} \right] (h_s - h_w) \sqrt{\left(\frac{du_e}{dx} \right)_s}, \quad (1.6)$$

де індекси w , e та s позначають стінку, край пограничного шару, та точку застою відповідно. Le – число Льюїса для суміші атомів і молекул, а h_D – середня енергія дисоціації атомів, помножена на масову частку атомів у

зовнішньому потоці, h – ентальпія, ρ , μ – густина й динамічна в'язкість, du_e/dx – градієнт швидкості на стагнаційній лінії.

Розроблена для оцінки стагнаційного потоку на кулях і циліндрах у дисоційованому повітрі та ґрунтується на інтегруванні рівнянь граничного шару з урахуванням рекомбінації при стінці. Застосовується в ORSAT від Національного управління з аеронавтики і дослідження космічного простору (NASA) [39] і багатьох кодах, особливо коли потрібен точний облік каталізності стінки.

Формула Detra–Kemp–Riddell [40]

$$q_s = \frac{1.1037 \times 10^8}{\sqrt{D_x}} \left(1.1 + 0.9 \sqrt{\frac{D_x}{D_z}} \right)^{0.5} \left(\frac{\rho_\infty}{\rho_{sl}} \right)^{0.5} \left(\frac{V_\infty}{7925} \right)^{3.5} \left[\frac{(h_s - h_w)}{h_s - 3.0145 \times 10^5} \right], \quad (1.6)$$

де D_x , D_z – малі та великі головні радіуси кривизни (для сфери $= 2R_{eff}$), ρ_{sl} – густина на рівні моря.

Формула модифікує базову схему *Fay–Riddell*, інтерполуючи дані ударної труби. Вводить поправку на геометрію через діаметри кривизни D_x , D_z . Діапазон валідності: швидкість – 2-8 км/с, висота – $h \leq 76$ км. Використовується у DRAMA/SESAM Європейської космічної агенції (ESA) [41] і DAS від NASA та інших об'єктно-орієнтовних інструментах для статистичної оцінки згорання уламків.

Формула Scala [42]

$$q_s = \frac{6365}{\sqrt{D_x}} \left(1.1 + 0.9 \sqrt{\frac{D_x}{D_z}} \right)^{0.5} (10,0)^a \left(\frac{V_\infty}{3.0480} \right)^b, \quad (1.7)$$

де коефіцієнти a і b відповідно

$$a = -(0.9689 + 6.998 \times 10^{-5} T_w)(5.626 + 3.228 \times 10^{-5} H_{alt}) \quad (1.8)$$

$$b = (0.9793 + 4.672 \times 10^{-5} T_w)(2.830 + 9.842 \times 10^{-7} H_{alt}) \quad (1.9)$$

де T_w – температура стінки, H_{alt} – висота.

Розширює формулу *Detra–Kemp–Riddell* на 11-компонентну суміш з урахуванням радіації та хімічної нерівноваги, включаючи варіації чисел Прандтля та Льюїса. Коефіцієнти a , b корегують ефект висоти й температури стінки.

Формула *Lees* [43]

$$q_s = \frac{2^{k/2} 0.50 \sqrt{\rho_e \mu_e V_\infty h_s}}{Pr^{2/3} \sqrt{Re_{eff}}} G(M_\infty, \bar{\gamma}, \gamma_\infty), \quad (1.10)$$

де $k = 1$ для осесиметрії, 0 для плоского тіла; безрозмірна функція $G(M_\infty, \bar{\gamma}, \gamma_\infty)$ відображає вплив числа Маха та складу газу.

Формулу отримано з теорії ламінарного пограничного шару для термодинамічної рівноваги. Кореляція задає залежність через середнє число Прандтля, придатна для сфер і конусів, однак схильна до переоцінки q_s при $V_\infty > 7$ км/с.

Формула *Detra–Hidalgo* [44]

$$q_s = \frac{5.423 \times 10^6}{\sqrt{Re_{eff}}} \left(\frac{V_\infty}{3048} \right)^{3.15} \sqrt{\frac{\rho_\infty}{\rho_{sl}}} \left(\frac{h_s - h_w}{h_s - h_{w300K}} \right). \quad (1.11)$$

Запропонована для швидких попередніх оцінок, включає «hot-wall» коефіцієнт $\left(\frac{h_s - h_w}{h_s - h_{w300K}} \right)$, що дає змогу врахувати нагрів поверхні КО.

Формула *Herdrich* [45]

$$q_s = \frac{1.705 \times 10^{-4}}{\sqrt{Re_{eff}}} \sqrt{\rho_\infty} V_\infty^3 \quad (1.12)$$

Спрощена кореляція формули 1.5 створена в IRS-Stuttgart для оцінки теплового потоку під час гіперболічного входу капсули STARDUST (12.8 км/с).

Формула *Tauber* [46]

$$q_s = \frac{1.83 \times 10^{-4}}{\sqrt{Re_{eff}}} \sqrt{\rho_\infty} V_\infty^3 \left(1 - \frac{h_w}{h_s}\right) \quad (1.13)$$

Зберігає залежність $\sqrt{\rho_\infty} V_\infty^3$ та вводить просту поправку $\left(1 - \frac{h_w}{h_s}\right)$ для каталітичних поверхонь без масопереносу. Рекомендована для інженерного етапу вибору теплозахисту.

Формула *Korpenwallner - Lips* [47]

$$q_s = St \rho_\infty V_\infty \frac{V_\infty^2}{2} = St \rho_\infty \frac{V_\infty^3}{2}, \quad (1.14)$$

з мостовим зв'язком між континуальними та вільно-молекулярними областями, де

$$St = \frac{St_{cont}}{\sqrt{1 + (St_{cont}/St_{FM})^2}}, \quad (1.15)$$

$$St_{cont} = \frac{1.63}{\sqrt{Re_{2,Reff}}}, \quad Re_{2,Reff} = \frac{\rho_e u_e Re_{eff}}{\mu_e}, \quad St_{FM} = 1. \quad (1.16)$$

Покриває перехід від континууму до вільно-молекулярного режиму однією аналітичною формулою. Режими течії визначаються відповідно до числа Кнудсена Kn . Використовується в SCARAB від Німецького аерокосмічного центра (DLR/HTG) [48] для оцінки теплового навантаження дрібних уламків.

Формула *Zoby* [49]

$$q_s = K_i \sqrt{\frac{p_e}{1.013 \times 10^5 Re_{eff}}} (h_s - h_w), \quad (1.17)$$

де K_i – коефіцієнт тепловіддачі, що дорівнює 0.1235 для повітря, p_e – тиск на краю примежового шару. Емпірична залежність для довільних високоентальпійних газових сумішей.

Формула Sutton - Graves [50]

$$q_s = K_{41} \sqrt{\frac{p_e}{1.013 \times 10^5 R_{eff}}} (h_s - h_w), \quad (1.18)$$

$$q_s = K_{43} \sqrt{\frac{p_e}{1.013 \times 10^5 R_{eff}}} (h_s - h_w). \quad (1.19)$$

Узагальнює підхід *Fay–Riddell* для сумішей 9 базових газів і 22 комбінацій, вводячи коефіцієнти K_{41} і K_{43} , що залежать від молекулярних мас та транспортного параметра компонентів. Забезпечують хорошу коректність для високих ентальпій і складних атмосфер.

Аналіз кореляцій показав, що найменшу похибку порівняно з експериментом демонструє формула *Fay–Riddell* за умови використання градієнта швидкості *Stokes–Tritutt* [51] тому саме її доцільно обрати базовою для високоточних розрахунків теплового потоку. Для масових та швидких оцінок практичним стандартом залишається інтерполяційна формула *Detra–Kemp–Riddell* із типовою похибкою до 12 %. Кореляції *Tauber*, *Zoby* та узагальнені рівняння *Sutton* забезпечують зіставну точність і корисні, коли слід урахувати нагріту стінку чи змінний склад атмосфери. Інші залежності варто застосовувати як верхню або нижню межу, а також у специфічних режимах, зокрема при переході до вільно-молекулярного потоку (*Korpenwallner*).

1.3.2. Об'єктно-орієнтовані інструменти повторного входу

Космічні агентства (NASA, ESA, Національний центр космічних досліджень Франції (CNES) та ін.) розробили вдосконалені математичні моделі та інструменти моделювання для оцінки швидкості нагрівання, абляції

та руйнування об'єктів. Об'єктно-орієнтовані інструменти широко використовуються для аналізу входу в атмосферу космічних об'єктів та їх уламків. Ці інструменти моделюють космічний апарат як набір спрощених компонентів таких як сфери, пластини, циліндри і імітують їхнє падіння в атмосфері [52]

Серед відомих прикладів: ORSAT [39], від NASA DRAMA/SESAM [41] від ESA, DEBRISK від CNES, SCARAB від DLR/HTG [48].

ORSAT використовує напівемпіричні моделі аеронагріву для примітивів різної форми та одномірну модель теплопровідності/абляції, щоб перевірити, чи кожен компонент плавиться або виживає [53].

SCARAB [54] – це високоточний об'єктно-орієнтований код, розроблений компанією HTG (Німеччина) і використовуваний ESA для моделювання руху фрагментів КО [55].

DEBRISK [56] також є об'єктно-орієнтованим кодом: він спрощує космічний апарат до визначених користувачем примітивних форм при розпаді, обчислює траєкторію і нагрівання кожного фрагмента за допомогою фізичних моделей, а також прогнозує висоту падіння або зону ураження при виживанні.

Китайська система DRAPS використовує триступеневу модель свободи (3-DoF) траєкторії і застосовує мостові методи для обробки переходу від континууму до вільних молекул в аеротермодинаміці [57].

У роботах [58, 35] запропоновані підходи розрахунку процесів нагрівання та руйнування об'єктів, що входять в атмосферу, що дозволяє точніше передбачити досягнення критичних температур.

Додаткову інформацію щодо моделювання входження космічного сміття надає огляд [59], в якому детально порівнюються об'єктно-орієнтовані моделі – стандартний ORSAT, система SCARAB та інструмент DRAPS.

Головним недоліком цих дослідницьких інструментів є доступність лише за прямим запитом чи в рамках інституційної співпраці, їх не можна завантажити у відкритому доступі.

1.3.3. Високоточне моделювання на основі фізичних процесів

З іншого боку, дослідники використовують високоточні чисельні симуляції для детального моделювання аеротермічних середовищ при вході в атмосферу Землі. До них відносяться обчислювальна гідродинаміка (CFD) для суцільного потоку, пряме моделювання Монте-Карло (DSMC) для розрідженого потоку, а також комбінований аналіз рідини-структури-теплоти для моделювання фізики руйнування. За останнє десятиліття розвиток обчислювальних потужностей і алгоритмів дозволив вирішувати проблеми входження в атмосферу з більшою реалістичністю, хоча і з великими витратами.

Так, у дослідженні [60] для моделювання входження в атмосферу китайської космічної станції «Тяньгун-1» було змодельовано розріджений потік навколо складної форми з урахуванням нерівноважних ефектів (вібраційне збудження, дисоціація повітря) для точного розрахунку аеронагріву. Оновлення бази даних реакції матеріалів ESTIMATE [61] покращило базові моделі абляції матеріалів, які використовуються у високоточних кодах. У статті [62] автори використовують дані, що отримані за допомогою методів DSMC, для швидкого та точного прогнозування розподілу теплових навантажень на уламки. У роботі [33] використано чисельні рішення з NEQAIR, HARA та CFD-коду LAURA.

1.4. Новітні підходи до вирішення проблем космічного сміття

Кількість інформації про КО на сьогодні є значною і з часом буде тільки збільшувати. Збільшення комп'ютерних потужностей і поява нових математичних підходів, зокрема машинного навчання та генетичних алгоритмів, надає можливість зміни парадигми – від підходу, що базується на фізиці, до підходу, що базується на даних (рис. 1.5).

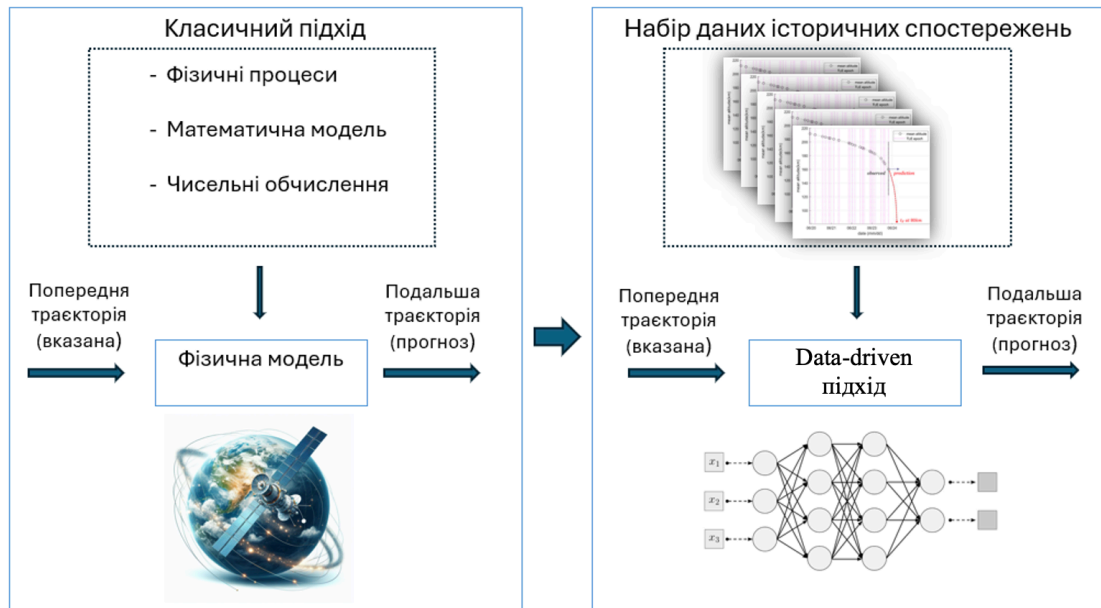


Рисунок – 1.5. Класичний підхід vs підхід на основі даних

Останнім часом підходи на основі даних, такі як глибоке навчання (DL), привертають значну увагу в різних галузях. Ці методи значно покращили сучасний стан розпізнавання мови, розпізнавання візуальних об'єктів, виявлення об'єктів та багатьох інших галузей, таких як пошук ліків та геноміка, автомобільна промисловість і фінанси.

1.4.1. Застосування машинного навчання в задачах космічної тематики

МН – це галузь штучного інтелекту [63], визначається як автоматизований процес який витягує шаблони з даних [64], який дозволяє машині чи системі навчатися та вдосконалюватися на основі даних і досвіду. Загальний огляд сучасних трендів AI у космічних дослідженнях представлено у статті [65], де аналізуються застосування еволюційних алгоритмів, МН, DL та підкріплювального навчання для вирішення задач керування, динаміки та оптимізації траєкторій. Огляд [66] детально описує історію й еволюцію глибокого навчання, підкреслюючи його вплив на сучасні алгоритми для аналізу часових рядів і прогнозування, що є надзвичайно важливим для космічних застосувань. Огляд задач орбітальної балістики, в яких використовуються методи машинного навчання, наведено в статті [67].

1.4.1.1. Прогнозування орбіт і оптимізації траєкторій

Використовуючи імітаційне середовище космічного каталогу автори у [68] запропонували підхід до підвищення точності прогнозування орбіт КО шляхом навчання моделей на основі історичних помилок прогнозів. У подальших дослідженнях [69, 70] вони проаналізували ефективність трьох алгоритмів МН: машини опорних векторів, штучну нейронну мережу та гауссівські процеси. Також ці автори у [71] продемонстрували здатність моделей до узагальнення на майбутні епохи та на різні космічні об'єкти, також було проведено систематичне дослідження впливу випадкової ініціалізації під час навчання моделі. У [72] вони розширюють підхід ML шляхом введення гауссових процесів, які можуть генерувати інформацію про невизначеність точкової оцінки об'єкта. А також розглянули обмеження моделі опорних векторів у прогнозуванні орбіт КО [73].

Дослідження [74] пропонує метод еволюційного нейроконтролю для глобальної оптимізації траєкторій із безперервним керуванням тягою, що інтегрує штучні нейронні мережі з еволюційними алгоритмами. Робота [75] демонструє, як моделі, що навчені на даних з низькоорбітальних місій, дозволяють зменшити середню абсолютну похибку прогнозування густини атмосфери та сонячного випромінювання, що критично для уточнення орбітальних розрахунків. Робота [76] розглядає можливості ML-підходів у глобальній оптимізації.

Для апроксимації умов орбітальних збурень на ННО стаття [77] пропонує швидку сурогатну модель на основі нейронних мереж, що значно спрощує обчислення маневрових приростів. Три роботи [78 - 80] присвячені можливості використання рекурентних нейронних мереж LSTM для прогнозування траєкторії руху супутників в гравітаційному полі Землі. У статті [81] автори дослідили можливість використання підходу на основі даних для розв'язання задачі інверсії кривої блиску КО для пошуку його форми. Навчена модель на основі згорткової нейронної мережі здатна визначити правильну орбіту з точністю 92,2%.

У статті [82] представлено система оцінки пеленгу на основі згорткової нейронної мережі, навченої виявляти і локалізувати вантажний космічний корабель Cygnus за допомогою зображень з монокулярної камери. Система машинного зору була протестована в польоті місії NASA.

Густина атмосфери є найважливішим фактором для точної оцінки сили опору, що діє на космічні апарати на ННО. Емпіричні моделі дають найточнішу оцінку густини на сьогоднішній день, хоча вони все ще страждають від помилок в оцінках. В роботах [83] і [84] представлено нові підходи на основі нейронних мереж для зменшення похибки і отримання більш точних прогнозів густини атмосфери.

В роботі [85] представлено мережу глибокого Q-навчання що дозволяє контролеру супутника приймати послідовні рішення для планування траєкторії маневру, уникаючи перешкод і шукаючи цілі, безпечно орієнтуючись у навколишньому середовищі. А в [86] використане нейронне навчання з підкріпленням для оптимального керування в умовах невизначеності. В [87, 88] пропонується підхід на основі глибоких нейронних мереж для швидкої генерації та модифікації оптимальних траєкторій для орбітальних переходів з малою тягою.

Авторами у [89] досліджено застосування регресорів МН для оцінки кінцевої маси космічного апарату. У статті [90] авторами пропонується новий підхід до визначення орбіти як задача навчання з використанням регресії розподілу. Крім того для сценарію з декількома космічними апаратами розглянуто систему навчання з переносом для класифікації векторів ознак, пов'язаних з цими апаратами.

Дослідження [91] показує, що регресія МН може бути застосована для початкового визначення орбіт невідомих супутників. У роботі [92] модель орбітального поширення розроблена з використанням регресійних методів і штучних нейронних мереж. На основі попередніх орбітальних даних отримана надійна і точна модель розповсюдження орбіти з мінімальними обчислювальними витратами та економією коштів. Прогнозування орбіт на

основі теорії орбітальної механіки страждає від швидкого зростання похибки, тому у роботі [93] пропонується підхід на основі МН для моделювання структури помилок прогнозування руху низькоорбітальних об'єктів.

1.4.1.2. Прогнозування та моделювання повторного входу КО в атмосферу Землі

Важливим типом задач, де методи МН можуть бути ефективно використані для аналізу і прогнозування оптимальних траєкторій руху КО, є задачі входження в атмосферу. З точки зору МН, задача прогнозування входження об'єкта в атмосферу є задачею часового ряду, де мета моделі полягає в прогнозуванні еволюції траєкторії на основі початкового набору умов, щоб можна було визначити епоху входження в атмосферу. У статті [94] запропоновано евристичну модель на базі багат шарових нейронних мереж, що дозволяє точно визначати час повторного входження неконтрольованих космічних об'єктів із аналізом історичних даних відстеження та точка зіткнення (TIP). В [95] досліджено прагматичний метод для характеристики динамічної стійкості модуля входу в атмосферу на низьких дозвукових швидкостях. Ідентифікація аеродинамічних похідних за допомогою нейронних мереж може бути оцінена за допомогою даних в реальному часі. Також у роботі [96] представлено модель, що за допомогою глибокого навчання та ретельної обробки та вибору ознак забезпечує високоточне прогнозування часу повторного входження. Окрім того, в дослідженні [97] представлено застосування різних ML-методів - штучні нейронні мережі (ANN), рекурентні нейронні мережі (RNN) та нейронна мережа прямого поширення (FNN) для прогнозування входу космічних об'єктів, що забезпечує оперативність та стабільність розрахунків.

Набори дворядкових елементів (TLE) наразі є єдиним відкритим джерелом даних, які можна використовувати для прогнозування входу в атмосферу Землі. В наступних трьох роботах авторами було обрано архітектуру Seq2Seq [98]. В [96] представлено розробку моделі глибокого

навчання для прогнозування входу в атмосферу неконтрольованих об'єктів на ННО на основі даних TLE. В статті [99] запропоновано новий підхід до прогнозування траєкторії входу в атмосферу для неконтрольованих КО на основі сетів TLE за допомогою послідовно-рекурентних нейронних мереж (рис. 1.6.).




Рисунок – 1.6. Прогнозування входу в атмосферу за даними [99]

У цій статті [100] оцінюється прогнозування входження в атмосферу ракетних тіл на ексцентричних орбітах на основі даних TLE і з використанням лише оцінки балістичного коефіцієнта.

В роботі [101] розроблено двокрокову стратегію для планування траєкторії гіперзвукового літального апарата (ГЛА) у реальному часі на етапі входу в атмосферу. Глибока нейронна мережа діє як генератор оптимальних команд. Тоді як в [102] представлена архітектура адаптивного керування маневрами ГЛА на вході в атмосферу за допомогою самоорганізаційної рекурентної мережі функціональних зв'язків.

В статті [103] застосовано об'єктно-орієнтований підхід і порівняна точність прогнозування швидкості, довготи і широти точок падіння уламків

космічного апарату для трьох алгоритмів МН. Оцінка ризиків входження дозволяє оперативно визначати потенційні небезпеки для наземної інфраструктури. У роботі [104] розглянуто задачу оптимізації траєкторій виведення космічного сміття в атмосферу Землі з метою визначення таких, які дозволяють забезпечити термічне руйнування конструкції максимально ефективно. Як параметри оптимізації розглянуто температуру нагрівання та інтегральний тепловий потік.

Дослідження [105] фокусується на загальній та часовій ефективності чотирьох методів розроблених авторами для прогнозування повторного входу в атмосферу. У роботі [106] пропонуються сурогатні моделі на основі даних для прогнозування швидкості, тиску, температури, густини і складу повітря вздовж лінії стагнації гіперзвукових потоків.

В [107] розроблено код для аналізу траєкторій входу в атмосферу та живучості КС на основі простих форм, таких як сфера, циліндр і коробка розміром 12,5-50 см. Цей код було перевірено за допомогою результатів ORSAT та SCARAB.

1.4.1.3. Машинне навчання у плануванні місій з видалення космічного сміття та виявленні космічних об'єктів

Машинне навчання відкриває новий рівень автоматизації в космічній сфері: воно дозволяє будувати оптимальні траєкторії місій з активного або пасивного видалення сміття та підвищує точність і швидкість виявлення орбітальних об'єктів, забезпечуючи своєчасне ухвалення рішень для безпеки польотів.

У статті [108] пропонується використання штучних нейронних мереж для швидкої оцінки вартості і тривалості переходів для видалення сміття, щоб можна було визначити оптимальну послідовність об'єктів, яка мінімізує вартість або тривалість місії (рис. 1.7.).

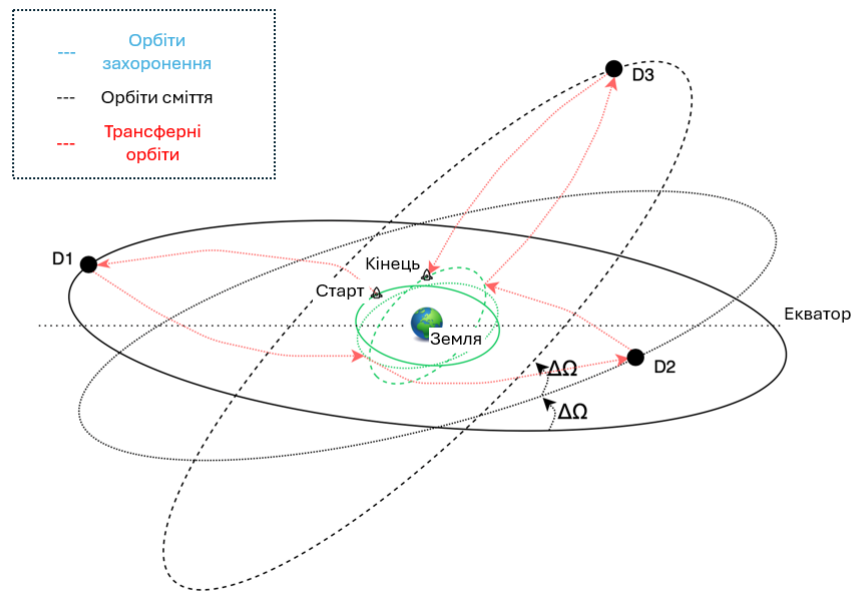


Рисунок – 1.7. Схематичне зображення сценарію місії, згідно з [108]

Стаття [109] розкриває методику планування активної місії прибирання космічного сміття з використанням ML-компонентів, що дозволяє адаптивно обирати послідовність маневрів. В роботі [110] запропоновано алгоритм виявлення КС у реальному часі під назвою SDebrisNet. Використано алгоритм CNN для врахування просторово-часових даних з послідовних відеозображень. Дослідження [62] демонструє можливість використання глибокого навчання за допомогою регресійного моделювання гауссівського процесу для прогнозування аеродинамічних характеристик в потоці зворотного входу.

У роботі [111] авторами представлено новий підхід до обчислення балістичного коефіцієнта (B^*) космічного сміття на основі оптичних кутових вимірювань. У [112] авторами за допомогою комплексу програм для математичного моделювання КС розроблено методику визначення та визначено області просторового розміщення безпечних орбіт утилізації КС в області ННО. Оцінено енергетичні витрати переведення КО на орбіти утилізації.

1.4.1.4. ML для керування, навігації та класифікації космічних об'єктів

Оскільки кількість космічних об'єктів зростає з кожним роком, обізнаність про космічну обстановку відіграє важливу роль у безпеці супутників. Для цих завдань зазвичай використовуються алгоритми класифікації космічних цілей, і ці алгоритми повинні порівнюватися з набором даних про космічні цілі. В статті [113] пропонується поліпшений набір даних космічних цілей для компенсації недоліків існуючого набору даних. В [114] досліджено можливості МН для автоматичного визначення характеристик космічних об'єктів і класифікації на категорії «корисне навантаження», «корпус ракети» і «сміття». Стаття [115] пропонує сучасний огляд застосування глибинного навчання у системах автономного управління космічними апаратами, що адаптуються до змінних умов місії.

Для класифікації космічних об'єктів застосовано методи адаптивного оцінювання, як показано у дослідженні [116], а також глибокі нейронні мережі такі як RNN і згорткові нейронні мережі (CNN) [117].

В роботі [118] синтезовано наближений нейроконтролер на основі динамічного програмування для керування температурним режимом при вході в атмосферу космічного корабля типу "Шаттл". Нелінійна модель враховує теплопровідність, конвекцію та випромінювання при високих температурах. Порівняльний аналіз сучасних підходів та методів класифікації наведено в огляді [119] і статті [120].

1.4.2. Генетичні алгоритми та еволюційні методи

Генетичні алгоритми (ГА) – це евристичні методи оптимізації, основані на механізмах біологічної еволюції. ГА та інші еволюційні методи дають змогу швидко досліджувати величезні простори можливих орбітальних маневрів, відбираючи оптимальні стратегії видалення сміття під багатьма критеріями (паливо, час, ризик зіткнень) і адаптуючись до непередбачуваних умов космічного середовища.

1.4.2.1. Оптимізація траєкторій космічних об'єктів

У статті [121] розглядаються можливості застосування генетичного алгоритму для оптимізації послідовності зустрічей при багатозустрічних траєкторіях, що дозволяє підвищити ефективність маневрів на орбіті Землі. У роботі [122] приділено увагу розробці підходів на основі ГА для знаходження оптимальних траєкторій, що мінімізують витрати пального під час маневрування. Стаття [123] присвячена оптимізації траєкторій для місій з дослідження далеких космічних об'єктів за допомогою поєднання генетичних алгоритмів з гравітаційними маневрами, а в роботі [124] проведено детальний аналіз застосування ГА для визначення економічно вигідних орбітальних траєкторій. У [125] авторами застосовано комбінований підхід оптимального керування та евристичних методів (ГА, метод рою часток (PSO), ГА -PSO) для оптимізації траєкторій входу в атмосферу, що дозволяє мінімізувати інтегральне та пікове теплове навантаження без зміни кінцевих параметрів траєкторії.

Стаття [126] демонструє застосування генетичних алгоритмів для розв'язання задач оптимізації траєкторій входу в атмосферу з урахуванням теплових та аеродинамічних обмежень, що дозволяє провести порівняльний аналіз ефективності ГА з традиційними методами. Нарешті, у статті [127] надано історичний огляд розвитку багатоцільової оптимізації з використанням еволюційних алгоритмів, що демонструє еволюцію концепцій та методів, котрі стали базою для сучасних підходів до оптимізації траєкторій у космічній інженерії.

1.4.2.2. Планування місій з видалення космічного сміття

Автори роботи [128] демонструють використання модифікованого генетичного алгоритму у попередньому плануванні місій з активного видалення космічного сміття, застосовуючи модель, схожу на задачу комівояжера. Далі, в статті [129] представлено покращений генетичний алгоритм для планування ADR-місій, де проблема моделюється як задача

множинного комівояжера. У дослідженні [130] запропоновано трьохетапну стратегію планування місій з активного видалення сміття із застосуванням ГА, що дозволяє знизити витрати пального за рахунок більшої точності розрахунків.

Нарешті, статті [131, 132] присвячені оптимізації місій з видалення космічного сміття. В роботі [131] алгоритм оптимізації клубу часової шкали (ТСО) застосовано з урахуванням часозалежності витрат, тоді як у статті [132] розроблено підхід, що інтегрує методи оптимізації колонії мурах (АСО) та ГА для ефективного дослідження простору рішень та знаходження глобального оптимуму.

1.4.2.3. Гібридні оптимізаційні підходи

У статті [133] представлено новий гібридний генетичний алгоритм для розв'язання задач глобальної оптимізації, що відкриває можливості для пошуку оптимальних рішень у складних системах. Стаття [134] інтегрує методи еволюційних обчислень із класичними алгоритмами оптимізації (послідовне квадратичне програмування (SQP) і метод гомотопії (НМ) для вирішення задачі стикування, що спрямовано на мінімізацію витрат палива та підвищення точності траєкторного планування.

У дослідженні [135] розглянуто багатокритеріальну оптимізацію параметрів низькотягових двигунів із застосуванням штучних нейронних мереж у поєднанні з генетичними алгоритмами, що дає можливість отримувати Парето-оптимальні рішення з мінімальними витратами палива та скороченою тривалістю місії. У роботі [136] запропоновано тристадійний підхід для оптимізації місій зближення між кількома апаратами, де задача розбивається на оптимізацію розподілу цілей, послідовності зустрічей та детальний розрахунок імпульсів переходів.

Висновки до розділу 1

На підставі зробленого в розділі 1 аналітичного огляду проблем космічного сміття і методів знищення КО під час руху в атмосфері Землі означено коло задач які потребують вдосконалення. Найбільший потенціал для швидкого та безпечного очищення орбіт мають комбіновані рішення, які пропонують контроль параметрів входження КО в атмосферу і таким чином є можливість впливу на тепловий режим об'єкту. Наразі для розв'язання низки задач руху тіл в атмосфері активно застосовуються нові методи, що пов'язані з технологіями штучного інтелекту. Було визнано доцільним метод до прогнозування кількості тепла на основі машинного навчання з використанням генетичної оптимізації. Для втілення цього підходу необхідно провести низку досліджень і виконати такі завдання:

- сформулювати постановку задачі про оптимізацію нагріву КО;
- запропонувати гібридну обчислювальну стратегію поєднання машинного навчання і генетичного алгоритму
- сформувати репрезентативний датасет, що охоплює траєкторні, геометричні та фізико-механічні параметри КО;
- забезпечити очищення, нормалізацію та формування розширених комбінацій вхідних ознак для подальшого моделювання;
- розглянути релевантні алгоритми машинного навчання, надати оцінку гіперпараметрам, обрати оптимальну архітектуру МН;
- реалізувати гібридну обчислювальну стратегію для пошуку оптимальних траєкторних параметрів, що максимізують інтегральне теплове навантаження на критичному інтервалі.

Виконання наведених завдань забезпечить науково-методичну основу для інтеграції методів даної аналітики у процедури планування місій деорбітації КО та створить підґрунтя для подальшого розширення застосувань машинного навчання та еволюційних алгоритмів у тепловій оптимізації траєкторій.

РОЗДІЛ 2. ПОСТАНОВКА ЗАДАЧІ ПРО ОПТИМІЗАЦІЮ НАГРІВУ І МЕТОДОЛОГІЯ ДОСЛІДЖЕННЯ

2.1. Постановка задачі про оптимізацію нагріву КО

2.1.1. Фізична постановка задачі

Як вже відзначалося у розділі 1 представленої роботи, під час входу космічного об'єкта в атмосферу Землі на гіперзвукових швидкостях відбувається складна взаємодія між тілом і навколишнім середовищем, що супроводжується аеротермодинамічними і, фізико-хімічними процесами та призводить до нагрівання поверхні КО. Внаслідок інтенсивних динамічних і теплових навантажень на КО може початися процес термічного руйнування об'єкту, який в свою чергу є багатофакторним. Зокрема такий процес обумовлений абляцією та плавленням об'єкту, внаслідок аеродинамічного нагрівання до відповідної температури термічного руйнування матеріалу. З іншого боку, можливо механічне руйнування конструкції внаслідок зниження міцнісних характеристик матеріалу та теплового розширення під впливом інтенсивних теплових потоків.

Згідно даних [137-141] міцнісні характеристики конструкційних матеріалів що використовується в аерокосмічній техніці суттєво залежать від температури і знижується з її зростанням. До основних характеристик, що визначають несучу здатність конструкційних матеріалів в умовах експлуатації за підвищених температур, можна віднести межу міцності σ та модуль Юнга E , які найкраще відображають базові механічні властивості матеріалів у пружній та пластичній зонах деформації. Нижче наведені графіки залежностей σ та E для деяких матеріалів що використовуються в космічних апаратах.

Маркування та позначення матеріалів наведено в таблиці 2.1 відповідно до українського стандарту та найближчих західноєвропейських аналогів [137].

Таблиця 2.1. Інформація про конструкційні матеріали

N	Маркування за українським стандартом ГОСТ 4784-97	Маркування західних аналогів	Європейські стандарти для аналогів
Алюмінієві сплави			
I	AMg6H	A-G6	AFNOR (France)
II	Д16АТ	AlCu4Mg1	ISO 2024
III	B95	AlZn5.5MgCu	ISO 6363-2
Титановий сплав			
IV	BT6C	T-A6V	AFNOR (France)
Сталь			
V	30ХГСА	30HGS	PN (Poland)

На рисунку 2.1 представлено залежність межі міцності для типових сплавів що використовуються для виготовлення оболонок баків [142].




Рисунок – 2.1. Залежність межі міцності від температури для конструкційних матеріалів: 1 – I, 2 – II, 3 – III, 4 – IV, 5 – V.

Для матеріалів спостерігається помітне зниження межі міцності при підвищенні температури. Найбільш термостійким є титан, тоді як алюмінієві сплави втрачають міцність значно швидше, особливо після 200 °С.

Рисунок 2.2 ілюструє зміни модуля пружності з підвищенням температури для тих самих п'яти матеріалів.




Рисунок – 2.2. Залежність модуля Юнга (E) від температури для конструкційних матеріалів: 1 – I, 2 – II, 3 – III, 4 – IV, 5 – V.

Усі конструкційні матеріали демонструють зменшення жорсткості при нагріванні. Сталь має найвищий початковий модуль Юнга, але пружність поступово знижується при підвищенні температури. Алюмінієві сплави стартують з нижчими E та деградують швидше

Отже, наведені дані демонструють, що зміна температури від від'ємних значень -200°C до 400°C і вище супроводжується значним зниженням міцнісних характеристик всіх матеріалів. Тому під час аеродинамічного нагріву в атмосфері створюються передумови для фрагментації КО внаслідок дії механічних навантажень. Сумісний вплив температурних градієнтів та

аеродинамічних навантажень може зумовити структурну деградацію та подальше руйнування об'єктів.

Для оцінки теплового навантаження в точці гальмування на поверхні КО використовуються залежності 1.1. Використано формулу 1.3 для розрахунку теплових навантажень для різних кутів входу в атмосферу Землі гіпотетичного КО що розглянутий в [137] як показано на рисунку 2.3.




Рисунок – 2.3. Зміна теплового навантаження залежно від часу: 1 – кут входу 0°, 2 – 0.5°, 3 – 1°, 4 – 1.5°, 5 – 2°, 6 – 2.5°, 7 – 3°.

З даних на рисунку 2.3 бачимо, що абсолютне значення теплового потоку і інтегральна кількість тепла суттєво залежить від кута входу в атмосферу Землі. Також на цю величину будуть впливати інші параметри такі як початкова швидкість, маса, геометричні розміри тощо. Отже керування траєкторії руху в атмосфері дозволяє впливати на тепловий режим КО і таким чином впливати на його теплове руйнування. В разі використання активних (комбінованих) методів відводу елементів космічного сміття в атмосферу основним інструментом впливу на траєкторію руху є кут введення в

атмосферу. Важливою задачею для оцінки можливості згоряння КО є визначення кількості теплоти що сприймається КО під часу руху в атмосфері.

2.1.2 Математична постановка задачі

Розглянемо рух космічного об'єкта в атмосферу Землі. Приймаємо традиційні припущення для такого роду задач [143]: Земля моделюється як сфера радіусом $R_{\oplus} = 6.371 \cdot 10^6$ м з центральним гравітаційним полем $\mu = 3.986 \cdot 10^{14}$ м³/с²; обертання планети, коріолісові та центрифугальні доданки не враховуються. Траєкторія лежить у площині великого кола, що проходить через початковий вектор швидкості. Аеродинамічне гальмування починається на геометричній висоті $H_0=120$ км, де вплив сил тяжіння та відцентрових сил зміною висоти вважатимемо незначним. Атмосферу моделюємо ізотермічною: її густина спадає за експоненційним законом: $\rho(H) = \rho_0 \exp\left(-\frac{H}{H_m}\right)$, з параметрами $\rho_0 = 1.225$ кг/м³, $H_m = 8.5$ км. Початковий радіус $r_0 = R_{\oplus} + H_0$. Швидкість перебуває в діапазоні $V_0 \in [7.5, 8.5]$ км/с. Початковий кут входу $\theta \in [0^\circ, 3^\circ]$ слугує змінною. Аеродинамічний опір $D = \frac{1}{2} \rho V^2 S_{avg} C_d$ визначається середньою площею поперечного перерізу S_{avg} , коефіцієнтом опору C_d і поточною густиною $\rho(H)$. Радіус носової частини R_n задає масштаб стагнаційної області теплопередачі.

У фронтальній точці тіла (точка гальмування) процеси є найбільш інтенсивними, і саме тут максимальні значення теплового потоку. Миттєве теплове навантаження у стагнаційній точці визначається напівемпіричним виразом 1.3.

Отже, оптимізаційну задачу можна сформулювати так: знайти такий кут входу θ КО в атмосферу Землі за час $0 \leq t \leq \tau$, що забезпечує максимум функціоналу

$$Q(\theta) = \max \int_0^\tau q(H(t), V(t), R_n) dt, \quad (2.1)$$

за таких умов

$$H(0) = H_0, V(0) = V_0, \quad (2.2)$$

а також з урахуванням природного обмеження, яке полягає в тому, що гальмування не може бути більшим за гальмування, яке виникає внаслідок дії максимальної сили опору для заданого тіла на заданій висоті

$$\left| \frac{dV}{dt} \right| \leq \frac{s}{m} \frac{\rho V^2}{2}, \quad (2.3)$$

З виразу 2.1 бачимо що чим більше час руху в атмосфері тим більше тепла отримує КО, але це не гарантує що об'єкт буде руйнуватися внаслідок теплового навантаження, адже потрібно щоб температура відповідала температурі теплового руйнування.




Рисунок – 2.4. Характеристика теплового режиму КО під час проходження щільних шарів атмосфери.

На рисунку 2.4 схематично представлено теплове навантаження на КО під час руху в атмосфері.

На ділянці графіку 1 відбувається процес нагрівання без плавлення, що триває до досягнення температури теплового руйнування T_{crit} в момент часу t_1 , який нам заздалегідь невідомий.

На ділянці 2 починається процес теплового руйнування за постійної температури, який триває до моменту часу t_2 або до повного руйнування об'єкту.

У разі якщо теплове навантаження знижується то температура КО може впасти менше за температуру руйнування і процес теплового руйнування припиниться (ділянка 3). t_2 характеризує час коли теплове навантаження недостатнє для розплавлення матеріалу і температура падає менше за температуру плавлення T_{crit} .

Отже, максимізація повного інтегралу теплового потоку за весь час входу КО може призвести до нераціонального рішення – дуже пологої траєкторії, яка не призводить до температурного руйнування. Таким чином вираз 2.1 запишеться у вигляді

$$Q^*(\theta) = \max \int_{t_1}^{t_2} q(H(t), V(t), R_n) dt, \quad (2.4)$$

Для оцінки температури поверхні об'єкта під час проходження атмосферної фази траєкторії та визначення часу t_1 поставимо таку задачу. За постійних теплофізичних властивостей і за відсутності фізико-хімічних перетворень в товщі матеріалу і на його поверхні температурне поле в середині тіла описується за допомогою класичної задачі теплопровідності. Скористуємося розв'язком такої задачі відносно нагрівання теплозахисного матеріалу що наведено в [144]:

$$\frac{\partial T}{\partial \tau} = a \frac{\partial^2 T}{\partial y^2}, \quad (2.5)$$

де $a = \lambda/(\rho c)$ – коефіцієнт температуропровідності матеріалу, τ – час, y – координата, що відраховується від поверхні нагріву по нормалі, яка направлена всередину матеріалу.

Нехтуючи випромінюванням із зовнішньої поверхні, вдувом та фізико-хімічними перетвореннями, зведемо баланс тепла до найпростішої граничної умови:

$$q_{s\ conv} = q_{\lambda} = -\lambda \left. \frac{\partial T}{\partial y} \right|_{y=0}, \quad (2.6)$$

де q_{λ} – тепловий потік, що йде на прогрів внутрішніх шарів.

У якості другої граничної умови приймемо, що початкова температура T_0 на достатній глибині від поверхні зберігається незмінною $T(y \rightarrow \infty) \rightarrow T_0$.

Припустимо що тепловий потік на поверхні матеріалу описується поліномом n степені:

$$q_{s\ conv}(\tau) = b_n \tau^n + b_{n-1} \tau^{n-1} + \dots + b_1 \tau + b_0, \quad (2.7)$$

За прийнятих умов і припущень в роботі [144] показано, що температура поверхні визначається

$$T_w - T_0 = \frac{2\sqrt{a\tau}}{\lambda\sqrt{\pi}} \sum_{i=0}^n b_i \tau^i \sum_{m=0}^i (-1)^m \frac{c_i^m}{2m+1}, \quad (2.8)$$

$$\text{де } c_i^m = \frac{i(i-1)\dots(i-m+1)}{m!}.$$

І навпаки, якщо відомо, що температура поверхні змінюється з часом за законом

$$T_w = d_n \tau^n + d_{n-1} \tau^{n-1} + \dots + d_1 \tau + d_0, \quad (2.9)$$

то для розрахунку теплового стіку в матеріал придатна формула

$$q_{s\ conv}(\tau) = \frac{2\lambda}{\sqrt{\pi a \tau}} \sum_{i=0}^n d_i \tau^i \sum_{m=0}^i \frac{(-1)^{m+1} c_i^m}{2m-1}, \quad (2.10)$$

На практиці можна обмежитися $n=3$, і тоді формули 2.8 і 2.10 мають наступний вигляд:

$$T_w - T_0 = \frac{2\sqrt{a\tau}}{\lambda\sqrt{\pi}} \left[\frac{16}{35} b_3 \tau^3 + \frac{8}{15} b_2 \tau^2 + \frac{2}{3} b_1 \tau + b_0 \right], \quad (2.11)$$

$$q_{s\ conv}(\tau) = \frac{2\lambda}{\sqrt{\pi a \tau}} \left[\frac{8}{5} d_3 \tau^3 + \frac{4}{3} d_2 \tau^2 + d_1 \tau \right], \quad (2.12)$$

Останню формулу зручно використовувати при обробці калориметричних експериментів для високотемпературних газових потоків.

Наведений розв'язок дозволяє отримати еволюцію температури на поверхні та знайти час t_1 при якому $T(0, \tau)$ досягає T_{crit} і об'єкт зазнає термічного руйнування – через плавлення, абляцію або фрагментацію.

Отже сформулюємо задачу оптимізації

Підсумовуючи наведені залежності, одержуємо таку оптимізаційну задачу:

$$\max_x J(x) = Q^*(x), \quad (2.8)$$

за умов

$$\begin{cases} x = [\theta, V_0, H_0], \\ \theta_{min} \leq \theta \leq \theta_{max}, \\ V_{min} \leq V_0 \leq V_{max}, \\ 0 < t_1 < t_2 \leq \tau, \\ T(0, t_1) = T_{crit} \\ Q^*(\theta) > 0. \end{cases} \quad (2.9)$$

Таким чином, за допомогою виразів 2.8 і 2.9 остаточно сформульовано оптимізаційну задачу теплового нагріву КО під час руху в атмосфері Землі. Вираз 2.8 визначає цільовий функціонал – інтегральне теплове навантаження

$Q^*(x)$, у критичному інтервалі $0 < t_1 < t_2 \leq \tau$, максимізація якого забезпечує досягнення режиму термічного руйнування. Умови 2.9 задають множину припустимих розв'язків, обмежуючи початкові параметри, часові межі та умови матеріальної стійкості. Отже, система (2.8) - (2.9) переводить фізичну модель аеротермодинамічної взаємодії у строгий математичний формат, що може бути ефективно розв'язаний чисельними глобальними методами оптимізації.

2.2. Обчислювальна стратегія

2.2.1. Загальні відомості про методи МН та ГА

2.2.1.1. Основні принципи машинного навчання

Як уже було зазначено в розділі 1, машинне навчання відноситься до напрямку штучного інтелекту та полягає в автоматизованому виявленні закономірностей у даних, що забезпечує системі здатність адаптуватися й удосконалюватися на основі отриманих даних та накопиченого досвіду. У контексті машинного навчання модель уявляється як чорний ящик (black box) (рис. 2.5), здатний самостійно формувати відображення між входами й виходами. Вона намагається апроксимувати невідому функцію залежності, спираючись на емпірично отримані «істинні» дані та вхідні характеристики, що мають фізичне підґрунтя.




Рисунок – 2.5. Концепція «чорної скриньки» моделі глибокого навчання згідно [96].

Іншими словами, система *набирається досвіду з даних* і на основі цього досвіду підвищує якість своїх рішень. Формально це можна описати так: програма *навчається* на досвіді E щодо класу завдань T і показника ефективності P , якщо її ефективність по T , виміряна P , поліпшується з досвідом E [145].

Нижче наведено визначення деяких фундаментальних понять у сфері машинного навчання.

Функція втрат (loss function). Це математична функція, що кількісно вимірює помилку моделі – різницю між передбаченими моделлю значеннями і еталонним значеннями цільової величини та слугує орієнтиром для оптимізації під час навчання.

Валідаційна втрата (validation loss). Значення функції втрат, обчислене на валідаційних даних, яке показує, наскільки добре модель узагальнює знання на нових даних.

Перенавчання (overfitting). Ситуація, коли модель занадто точно підганяється під навчальні дані і втрачає здатність правильно прогнозувати для тестових даних.

Регуляризація (regularization). Техніка, що додає до функції втрат штраф за складність моделі аби зменшити перенавчання й поліпшити узагальнення на нових даних.

Крос-валідація (cross-validation). Багаторазове послідовне навчання / тестування на різних підмножинах даних, а потім усереднення результатів для отримання надійної оцінки продуктивності та здатності узагальнення.

Метрики оцінювання (evaluation metrics). Метрики, що вимірюють якість прогнозів моделі на тестових даних.

Алгоритм оптимізації (optimization algorithm). Процедура ітеративного оновлення параметрів моделі, щоб мінімізувати функцію втрат.

Швидкість навчання (learning rate). Параметр визначає розмір кроку кожної ітерації і впливає на швидкість збіжності та стабільність алгоритму.

Інженерія ознак (feature engineering). Процес створення, перетворення чи відбору інформативних ознак з сирих даних, який прямо впливає на продуктивність моделі.

Розмірність даних (dimensionality). Кількість вхідних ознак, які описують кожен приклад даних.

Основні етапи розробки моделі машинного навчання включають підготовку даних, навчання моделі, оцінювання її продуктивності та забезпечення здатності до узагальнення результатів.

Підготовка даних. Збирання сирих даних та приведення їх до придатного для моделі вигляду. В цей етап входять очищення даних, обробка відсутніх значень, нормалізація та *інженерія ознак*, тобто виділення найбільш інформативних характеристик. Якість і відповідність даних є критично важливими, оскільки модель не може бути кращою за дані, на яких вона навчена [146].

Навчання моделі. На цьому етапі обраний алгоритм машинного навчання налаштовується на тренувальному наборі даних. Алгоритм поступово коригує параметри моделі, мінімізуючи значення певної *loss function* – міри невідповідності між прогнозами моделі і правильними або еталонними значеннями. Оптимізація моделі полягає в підборі параметрів, при яких обрана функція втрат набуває мінімального значення, тобто модель найбільш точно відтворює закономірності в даних [147].

Оцінювання продуктивності. Продуктивність моделі вимірюють на нових даних (*тестовій вибірці*), які не використовувалися під час навчання. Використовуються кількісні метрики – точність, середньоквадратична похибка, коефіцієнт детермінації для вимірювання якості передбачень. Важливо, що оцінювати модель потрібно саме на даних що не використовувалися для навчання – перевірка точності лише на навчальному наборі малоінформативна щодо її реальної ефективності [148].

Узагальнення. Узагальнення є фінальним і ключовим етапом оцінювання моделі: воно полягає в перевірці здатності застосовувати набуті знання до

нових, раніше невідомих даних. Модель повинна демонструвати високу точність прогнозів не лише на тренувальному наборі, а й на тестових вибірках. Значне зниження якості на тестових даних порівняно з тренувальними свідчить про недостатню здатність узагальнювати. Для покращення узагальнення застосовують регуляризацію, спрощення архітектури або розширення обсягу навчальної вибірки. Отже, саме здатність моделі точно передбачати на нових даних визначає її успішність.

2.2.1.2. Основні принципи генетичного алгоритму

Генетичний алгоритм – це евристичний метод оптимізації, натхненний механізмами біологічної еволюції. Ідею ГА вперше запропонував J. H. Holland у 1975 році, заклавши основу для напряму еволюційних алгоритмів в інформатиці [149]. ГА здійснює пошук оптимального або наближеного до оптимального розв’язку шляхом еволюції цілого набору кандидатних рішень (популяції) за аналогією до генетичних процесів в природі – через покоління шляхом схрещування та мутацій. Завдяки здатності ефективно працювати з великими, нерегулярними просторами пошуку, генетичні алгоритми набули великої популярності для розв’язання складних задач оптимізації [150], особливо комбінаційних та нелінійних задач, де традиційні методи пошуку малоефективні.

У ГА кожен потенційний розв’язок кодується у вигляді хромосоми – спеціальної структури даних, що містять усю необхідну інформацію про рішення, головним чином використовується бінарне кодування, але можливі й інші подання: числові вектори, порядкові перестановки, деревоподібні структури тощо [151]. Набір таких хромосом формує популяцію. Кожна хромосома відповідає певному індивіду в популяції і має оцінку якості – значення функції пристосованості (fitness function), яке визначається для розв’язку відповідно до поставленої задачі. Функція пристосованості надає кількісну оцінку якості рішення, тобто ступеня наближення до оптимального значення і використовується як критерій відбору. Саме значення

пристосованості визначає шанси кожного індивіда бути обраним для розмноження та передати інформацію наступному поколінню.

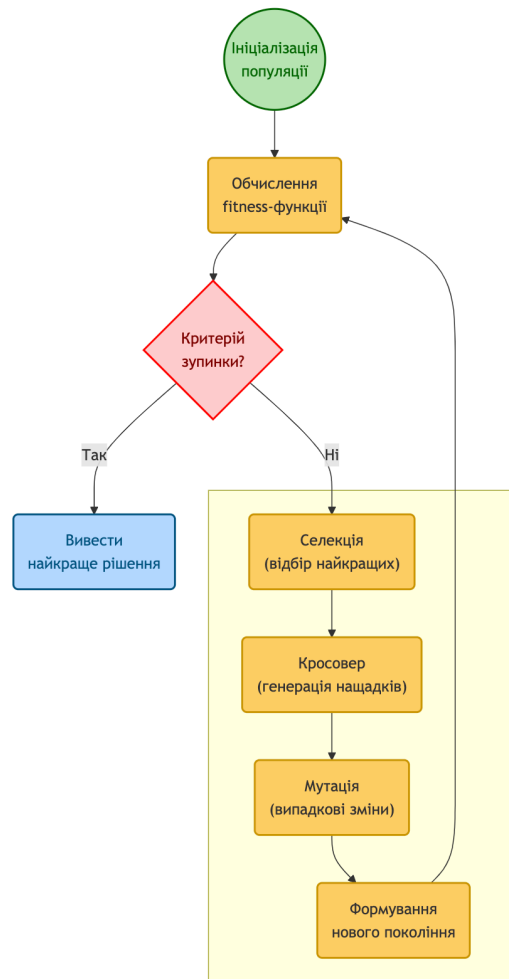


Рисунок – 2.6. Структурна схема і ключові етапи ГА.

На рис. 2.6 наведено послідовність етапів реалізації ГА у вигляді блок-схеми.

Основні етапи ГА можна представити таким чином.

Ініціалізація. Випадковим чином генерується початкова популяція з N хромосом – кандидатних рішень.

Оцінка пристосованості. Для кожного індивіда в популяції обчислюється значення функції пристосованості.

Селекція батьків. Відбираються найпридатніші або випадково зважені за пристосованістю індивіди для відтворення, тобто кращі рішення мають більше шансів на відбір.

Кросовер. Обрані батьківські індивіди випадковим чином спаровуються, і до кожної пари із заданою ймовірністю $0 \leq P_c \leq 1$ застосовується оператор схрещування. В результаті утворюються одна або дві нові хромосоми-нащадки, що успадковують ознаки від обох батьків.

Мутація. Кожен отриманий нащадок піддається мутації з малою ймовірністю P_m - оптимальне значення якої вказано у [152] або у граничному випадку як обернено пропорційну до довжини хромосоми [153]. Мутація випадково змінює значення окремих генів хромосоми, додаючи випадкові варіації до рішень.

Формування нового покоління. На основі отриманих нащадків формується нова популяція. У класичному ГА за схемою генераційної заміни все старе покоління замінюється новими індивідами-нащадками. При використанні елітизму деякі найкращі індивіди старого покоління можуть бути без змін перенесені в нове покоління, замінюючи найгірших нащадків. Критерій зупинки. Якщо виконуються критерії зупинки алгоритму – досягнуто максимальну кількість поколінь, або найкращий індивід має пристосованість, що задовольняє вимогам задачі, або поліпшення відсутні протягом останніх K поколінь, виконання ГА припиняється. Інакше алгоритм повертається до кроку 2 для генерації наступного покоління і пошук продовжується.

Такий цикл повторюється багато разів. Поступово пристосованість популяції зростає – хороші рішення комбінуються і покращуються, з'являються нові перспективні рішення завдяки мутаціям. Через десятки або сотні поколінь генетичний алгоритм може знайти рішення, близьке до глобального оптимуму.

2.2.2 Опис алгоритму розв'язання задачі

З метою розв'язання задачі максимізації інтегрального теплового навантаження $Q^*(\theta)$ (2.8) - (2.9) запропоновано гібридний обчислювальний метод, який поєднує швидку нейромережеву апроксимацію теплового профілю $q(t, \theta)$ вздовж траєкторії входу КО з глобальними пошуковими можливостями ГА для підбору оптимального кута входу θ . Послідовність кроків відображена на рисунку 2.7 та детально описується нижче.

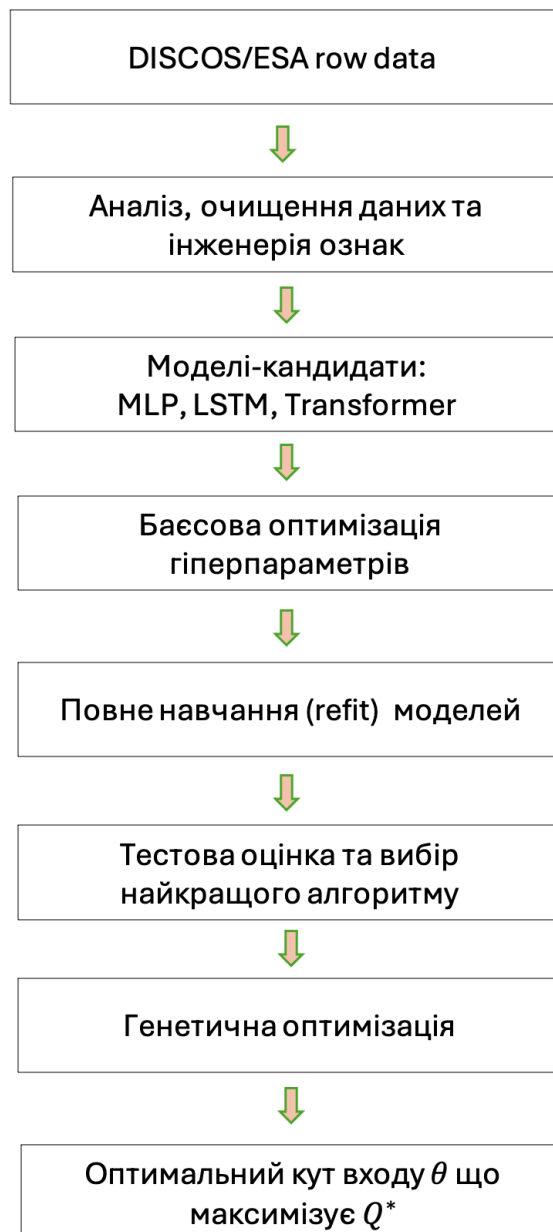


Рисунок – 2.7. Гібридна обчислювальна стратегія ML-прогноз + ГА-пошук

Послідовність етапів методу визначення оптимального кута входу.

Отримання «сирих» даних. Первинні дані отримано з відкритої бази DISCOS Європейського космічного агентства. Вона містить більше 34 тис. записів про об'єкти різних класів, орбіт, геометричних та матеріальних характеристик.

Очищення даних та інженерія ознак. Проведення статистичного аналізу заповненості полів, прийняття рішення видалення дублікатів та записів з нульовими/порожніми полями. Проведення описової статистики та виявлення викидів для ключових записів, що будуть використовуватися в подальшому дослідженні. Ідентифікація статистичних аномалій. Здійснюється формування ознак (feature engineering) шляхом обчислення похідних змінних, бінаризації категоріальних даних, логарифмування та нормалізації числових полів, а також побудови агрегованих показників для груп об'єктів. Застосовуються методи відбору ознак за критеріями варіативності, кореляційної надлишковості та статистичної значущості для забезпечення оптимального представлення даних у подальшому моделюванні.

Отриманий набір слугує єдиним джерелом даних для тренування різних алгоритмів машинного навчання та містить узгоджені фізичні параметри, очищені від інформаційного шуму, а також забезпечує репрезентативне покриття основних форм та масових категорій космічних об'єктів, що входять в атмосферу.

Архітектури-кандидати на навчання. Для апроксимації функції теплового навантаження $q(t, \theta)$ ініціалізовано три архітектури:

- багатошаровий перцептрон MLP,
- рекурентна мережа LSTM,
- послідовна модель уваги Transformer.

Кожна архітектура налаштовується окремо й незалежно від інших.

Баєсова оптимізація гіперпараметрів. Підбір гіперпараметрів виконується за допомогою баєсової оптимізації, яка моделює функцію втрат як стохастичний процес та обирає наступну конфігурацію параметрів на

основі апостеріорного розподілу, забезпечуючи ефективний баланс між експлуатацією відомих оптимальних областей і дослідженням нових. В таблиці 2.2 наведено приклади основних гіперпараметрів для кожної з архітектур у процесі налаштування моделей.

Таблиця 2.2. Параметри пошукового простору

Модель	Гіперпараметри
MLP	кількість шарів 2–6, 64–512 нейронів на шар, learning rate 10^{-5} – 10^{-2}
LSTM	1–4 шари, 64–256 статів, довжина вікна 40–120, бінаправленість
Transformer	d_{model} 64–256, 2–8 голів, 2–6 блоків, warm-up 500–4000

Повне навчання моделей машинного навчання. Після знаходження оптимальної конфігурації гіперпараметрів для кожної архітектури виконується повторне навчання (refit). Результатом є три повністю натреновані моделі машинного навчання.

Тестова оцінка та вибір найкращої моделі. За ключовими кількісними метриками якості, що характеризують точність передбачення та ступінь пояснення варіації цільової змінної, обирається найкраща архітектура для швидкої оцінки теплового навантаження $q(t, \theta)$.

Інтеграція з генетичною оптимізацією. Генетичний алгоритм оперує популяцією кутів входу θ у межах $[0^\circ, 3^\circ]$. Для кожної особини популяції θ_k модель прогнозує $q(t, \theta_k)$. Далі чисельно визначаються $t_1(\theta_k)$ і $t_2(\theta_k)$ і інтегральне тепло $Q^*(\theta_k)$, що слугуватиме фітнес-функцією. ГА здійснюватиме відбір, схрещування та мутацію доти, доки не буде досягнуто збіжності за Q^*_{max} або за кількістю поколінь.

Визначення оптимального кута входу КО під час руху в атмосфері Землі. Після завершення еволюційного циклу алгоритм повертає оптимальний кут входу θ , значення інтегрального теплового навантаження Q^*_{max} і прогнозований профіль $q(t, \theta)$. Отримані параметри використовуються для

порівняння з класичними аналітичними підходами та для оцінки імовірності повного згоряння космічного об'єкта у щільних шарах атмосфери.

До переваг обраного методу можна віднести:

Прискорення оцінки. Модель машинного навчання усуває потребу в повторному інтегруванні балістичних диференціальних рівнянь та використанні напівемпіричних формул при кожній оцінці функції допасованості.

Глобальний пошук. ГА не потребує градієнтів і зменшує ризик застрягання у локальних екстремумах функції $Q^*(\theta)$.

Масштабованість. Оцінки $Q^*(\theta)$ для різних особин незалежні й можуть виконуватися паралельно.

Універсальність. Стратегія не залежить від особливостей матеріалу: достатньо задати його характеристики.

Гнучкість. У разі появи нових даних достатньо донавчити модель, не змінюючи структури оптимізатора.

Таким чином, гібридна схема «модель машинного навчання + генетичний пошук» дозволяє оперативно визначати траєкторні параметри КО та забезпечує обчислювально ефективне та методологічно прозоре розв'язання задачі максимізації інтегрального теплового навантаження, і, відповідно, високу імовірність повного згоряння космічних уламків у щільних шарах атмосфери.

Висновки до розділу 2

У цьому розділі сформульовано повну аеротермодинамічну модель руху КО в атмосфері та показано, що інтегральне теплове навантаження, а отже і ймовірність руйнування, істотно визначаються кутом входу, початковою швидкістю, масо-геометричними параметрами й матеріальними властивостями об'єкта. Продemonстровано, що зростання температури спричиняє різке зниження межі міцності та модуля Юнга для типових алюмінієвих, титанового й сталевих сплавів.

На основі напівемпіричного виразу для теплового потоку у стагнаційній точці (1.3) сформульовано математичну задачу максимізації інтегралу теплового потоку за критичний інтервал часу $[t_1(\theta), t_2(\theta)]$ з урахуванням обмежень на кінематичні та силові параметри траєкторії. Доведено, що пряме максимізування повного інтегралу тепла може призвести до неінформативно «пологих» траєкторій, що не забезпечують досягнення температури руйнування, а тому доцільно оптимізувати функціонал, зв'язаний саме з фазою теплового руйнування. Таким чином, фізична постановка переведена у формалізований набір рівнянь (2.8)–(2.9), придатних до чисельного розв'язання глобальними методами.

Запропоновано гібридну обчислювальну стратегію, що поєднує швидко нейромережеву апроксимацію теплового профілю $q(t)$ (алгоритми MLP, LSTM та Transformer із баєсовим добором гіперпараметрів) з генетичним алгоритмом для глобального пошуку оптимального кута входу. Створено цілісний конвеєр: від отримання та очищення даних ESA DISCOS, через інженерію ознак і навчання моделей, до багатопотокової еволюційної оптимізації. Показано, що такий підхід усуває потребу в повторному інтегруванні балістичних рівнянь при кожній ітерації пошуку, забезпечує масштабованість і знижує ризик потрапляння у локальні екстремуми.

Отже, розділ 2 закладає теоретичну та алгоритмічну основу для подальших досліджень:

- детально обґрунтовує фізичні механізми нагріву та руйнування КО;
- формулює строгий варіаційний критерій оптимізації;
- пропонує ефективний гібридний чисельний метод, який поєднує точність машинного навчання з глобальними пошуковими властивостями еволюційних алгоритмів.

Розроблена методологія відкриває можливості для оперативного визначення траєкторних параметрів, що максимізують можливість теплового руйнування КО, і слугує фундаментом для подальших експериментальних і прикладних розділів дисертації.

РОЗДІЛ 3. АНАЛІЗ ВХІДНИХ ДАНИХ ДЛЯ ПОБУДОВИ ДАТАСЕТУ ТА РОЗГЛЯД АРХІТЕКТУР МАШИННОГО НАВЧАННЯ

У цьому розділі описано процеси відбору та генерування найважливіших вхідних ознак для прогнозування теплового навантаження $q(t)$. Цей процес зазвичай відомий як *feature engineering*. Етап аналізу, відбору і створення не є простим, оскільки необхідно знайти змінні, які корелюють з виходом моделі машинного навчання. Тому важливо проаналізувати кожний параметр з фізичної точки зору, щоб потім ці знання можна було застосувати у виборі моделі машинного навчання. Архітектуру машинного навчання підбирають з урахуванням задачі, аби збалансувати точність і швидкодію. Глибокі нейронні мережі відтворюють складні фізичні залежності й дають вищу точність, а їхній разовий прогін – обчислювально недорогий.

Вирішальну роль у якості прогнозування мають гіперпараметри моделей машинного навчання, які встановлюють на етапі проектування, адже від правильного вибору залежить здатність моделі вчитися та узагальнювати дані. Надані рекомендації до діапазонів гіперпараметрів обраних архітектур машинного навчання.

Для забезпечення високої ефективності генетичного алгоритму досліджуються налаштування, які традиційно класифікують як гіперпараметри, оскільки саме від них залежить продуктивність методу.

3.1. Аналіз та підготовка даних

Джерелом вхідної інформації є відкрита база DISCOS ESA [5]. Каталог містить понад 34 тис. записів про космічні об'єкти (КО) на різних орбітах та забезпечує набір характеристик, необхідних для оцінки теплового навантаження під час входу в атмосферу. Дані було завантажено у форматі CSV, після чого виконано первинну фільтрацію нульових і дубльованих записів та розгортання вкладеного JSON-поля *attributes* у пласку структуру з 26 полів.

Таблиця 3.1. Параметри космічних об'єктів у базі DISCOS

Назва поля	L-55 (YF24)	Najm-1	Опис
id	48152	66557	Унікальний ідентифікатор об'єкта .
cosparId	2018-011E	2021-022R	Ідентифікатор запуску COSPAR.
satno	43173	47947	Каталожний номер NORAD (SATCAT).
name	L-55 (YF24)	Najm-1	Офіційна назва або позначення об'єкта.
objectClass	Rocket Body	Payload	Класифікація космічного об'єкта.
mass	4 000	50	Маса об'єкта, кг.
shape	Cyl	Box	Узагальнена геометрична форма.
width	—	0.30	Ширина об'єкта, м.
height	7.5	0.50	Висота об'єкта, м.
depth	—	0.30	Глибина об'єкта, м.
diameter	3.3	—	Діаметр, м.
span	7.49	0.50	Максимальний характерний лінійний розмір, м.
xSectMax	26.19	0.2304	Максимальна площа поперечного перерізу, м ² .
xSectMin	8.553	0.0900	Мінімальна площа поперечного перерізу, м ² .
xSectAvg	23.72	0.195	Середня (ефективна) площа поперечного перерізу, м ² .

Для ілюстрації повноти та різноманітності набору у таблиці 3.1 наведено два репрезентативні записи: важкий ступінь ракети L-55 (YF24) та невеликий супутник Najm-1. Таблиця показує ключові поля – ідентифікатори, функціональний клас, масу, геометричні розміри та ін., що представляють інтерес для подальшого відбору.

Після видалення пропусків і логічних нулів обчислено статистичні межі для даних, що представляють інтерес для наступного процесу відбору. Таблиця 3.2 подає мінімальні та максимальні значення параметрів, а також кількість об'єктів із заповненим полем.

Таблиця 3.2. Обсяг даних і діапазони геометричних параметрів
представлених в DISCOS

Поле	Мінімум	Максимум	Кількість об'єктів із заповненим полем
mass	0.0015 кг	450 000 кг	34 786
width	0.012 м	72.80 м	19 011
height	0.001 м	60.00 м	33 203
depth	0.012 м	108.50 м	18 988
diameter	0.001 м	41.14 м	14 727
span	0.02 м	19 200 м	32 878
xSectMax	0.00013 м ²	8 319.8484 м ²	33 478
xSectMin	7.85×10^{-7} м ²	1 521.0 м ²	33 478
xSectAvg	0.00010 м ²	5 762.4 м ²	33 426

На діаграмі 3.1 помітно, що параметри height, span і площі поперечного перерізу заповнені більш ніж на 94 %, у той час як width та depth мають заповненість близько 55 %, а diameter – лише 42 %.




Рисунок – 3.1. Діаграма рівня повноти даних обраних полів

Згідно рисунку 3.2 корисне навантаження домінує в наборі даних. Близько двох третин каталогу становлять супутники коробчастих та циліндричних форм масою у діапазоні 200-800 кг. Ракетні ступені – кожен

п'ятий об'єкт, є основним джерелом потенційно небезпечних «надважких» уламків при повторному вході. Компоненти космічних місій займають близько 10 відсотків всього об'єму, і хоча вони суттєво збільшують різноманітність форм і площ поперечного перерізу, але їхня маса, як правило, менше 100 кг. Дрібне космічне сміття займає малу частку в загальній кількості, до того ж часто невідомі геометричні параметри таких об'єктів. Отже, для попереднього аналізу теплових навантажень достатньо моделювати чотири основні класи (1–4). Це спрощує оптимізацію траєкторії без істотної втрати точності.




Рисунок – 3.2. Діаграма розподілу за функціональним типом космічних об'єктів: 1. Payload – корисне навантаження. 2. Rocket Body – ракетний ступінь. 3. Rocket Mission Related Object – предмет, пов'язаний із ракетою. 4.

Payload Mission Related Object – предмет, пов'язаний із корисним навантаженням. 5. Rocket Fragmentation Debris – фрагмент від руйнування ракети. 6. Other Mission Related Object – інший предмет місії. 7. Payload Debris – фрагмент корисного навантаження. 8. Payload Fragmentation Debris – фрагмент від руйнування корисного навантаження. 9. Rocket Debris – фрагмент ракети

У проаналізованому наборі 33 698 об'єктів мають ненульове поле `shape`, що відповідає 387 унікальним геометричним описам (від простих примітивів `Box`, `Cyl`, `Sphere` до складних комбінацій із панелями, соплами, тросами тощо).




Рисунок – 3.3. Десять найпоширеніших геометричних форм космічних об'єктів в датасеті: `Cyl` – циліндр, `Box + 2 Pan` – коробка з двома панелями, `Box + 1 Pan` – коробка з однією панеллю, `Box` – коробка, `Sphere` – сфера, `Cone` – конус, `Cyl + 1 Nozzle` – циліндр з одним соплом, `Sphere + Cyl` – сфера + циліндр, `Trap Box + 2 Pan` – трапецієвидна коробка з двома панелями, `Cyl + 2 Pan` – циліндр з двома панелями

Десять найпоширеніших форм охоплюють 28 120 об'єктів, що становить біля 83 % усіх записів із відомою геометрією. Решта 377 геометричних комбінацій – малочисельні та часто представляють фрагменти або експериментальні апарати та зустрічаються у датасеті від поодиноких випадків до кількох сотень разів.

На рисунку 3.3 видно що комбінації `Box + 1/2 Pan` формують понад 34 % усіх геометрій, що узгоджується з типовою конструктивною схемою малих і

середніх супутників зі складними сонячними батареями. Найчастіша форма Cyl, майже 25%, відображає велику кількість ракетних ступенів та циліндричних супутників, що залишаються на орбіті після виведення корисного навантаження. Хоча Sphere та Cone разом дають лише близько 8 % від усіх об'єктів, їхня присутність важлива для моделювання теплових потоків, оскільки такий профіль генерує максимальні термічні навантаження. Таким чином, при подальшій оптимізації траєкторій за тепловим чинником можна зосередитись на десяти наймасовіших формах – вони статистично репрезентують понад чотири п'ятих усього наявного орбітального переліку, забезпечуючи достатню узагальненість без втрати важливих геометричних особливостей.

Аналізуючи взаємозв'язок маси та середньої площі поперечного перерізу (рис. 3.4) можна виділити такі ключові спостереження:

Глобальний степеневий тренд. На log-графіку точки розташовані вздовж лінії з нахилом $\approx 0.6 - 0.7$, що вказує на емпіричну залежність

$$xSectAvg \propto m^{\alpha}, \alpha \approx 0.65, \quad (3.1)$$

Це узгоджується з теоретичним очікуванням, що характерна площа зростає сублінійно – більші об'єкти щільніше розташовуються в аспекті питомої площі.

Формові кластери. Циліндри (Cyl) та коробчаті супутники з панелями (Box + 1/2 Pan) займають центральний гребінь розподілу ($10^2 - 10^3$ кг, 1 - 30 м²). Конічні та сферичні об'єкти переважно легші й мають менші перерізи, утворюючи нижній лівий «хвіст». Гібридні форми (Cyl + Nozzle, Trap Box + 2 Pan) розташовані трохи вище тренду – додаткові надбудови збільшують площу без істотного приросту маси.

Правий «надмірний» край. Кілька тяжких ($10^3 - 10^4$ кг) ступенів ракет мають незвично великі $xSectAvg > 100$ м² – ймовірно, за рахунок розкритих адаптерних конструкцій або великих обтікачів, що не відокремились.

Низькомасові «точкові» об'єкти. Близько 10 % вибірки лежать нижче 1 кг і мають $xSectAvg < 10^{-2}$ м².




Рисунок – 3.4. Взаємозв'язок маси та середньої площі поперечного перерізу КО

Домінування Cyl і Box + Pan форм підтверджує доцільність кластеризації геометрій: 10 найчастіших форм покривають $\approx 83\%$ каталогу й адекватно репрезентують параметричний простір ($xSectAvg, m$).

Для легких фрагментів менше 1 кг коефіцієнт аеродинамічного опору та тепловий фактор можуть бути суттєво вищими через малий радіус кривизни; їх необхідно враховувати окремими моделями при оцінці ризику та проектуванні траєкторій.

Великі ступені з аномально високим $xSectAvg$ формують вузьку, але критичну підгрупу. Для них рекомендовано використовувати докладніші CFD-моделі або інженерні коди (ORSAT, SCARAB) замість узагальнених кореляцій.

Кумулятивна крива маси представлених космічних об'єктів у датасеті (рис. 3.5) демонструє характерну «S-подібну» форму:

- 10 % об'єктів мають масу < 5 кг, що відповідає дрібним уламкам, болтам, фрагментам ізоляції.
- медіана (50-й перцентиль) розташована на ≈ 520 кг – типовий діапазон маси малих супутників та фрагментів верхніх ступенів.
- 75 % об'єктів легші за 1500 кг, тоді як 90 % – за 4000 кг.




Рисунок – 3.5. Кумулятивна крива для маси космічних об'єктів в датасеті

У діапазоні мас від 100 до 2000 кг спостерігається найкрутіший сегмент кумулятивної функції розподілу (CDF), що охоплює близько 40 % усієї вибірки. Це вказує на високу концентрацію космічних апаратів масових категорій «мікро», «міні» та «малі». З огляду на їхню чисельну перевагу в загальній структурі угруповань, саме для цієї групи супутників доцільно зосередити зусилля з оптимізації траєкторій повторного входу в атмосферу, оскільки це потенційно забезпечить найбільший ефект у контексті мінімізації ризиків утворення уламків.

Для оцінки репрезентативності даних і попередньої перевірки припущень щодо масштабності було сформовано ящикові діаграми (box-plots) шести основних параметрів (рис 3.6). Усі величини попередньо приведені до логарифмічної бази 10, що дає змогу відобразити 5-6 порядків зміни значень у компактному вигляді та уникнути «склеювання» густих областей на лінійній шкалі.




Рисунок – 3.6. Розподіл параметрів об’єктів DISCOS у логарифмічному масштабі

Методика побудови діаграми.

Вибірковий фільтр. Використано лише додатні значення, при цьому пропущені або нульові записи видалено.

Трансформація. $x' = \log_{10} x$ для кожного параметра, що перетворює степеневі-подібні розподіли на квазі-нормальні.

Параметри box-plot. Нижня/верхня межі – 1-й і 3-й квартилі (Q1, Q3), медіана – помаранчева лінія; whiskers (вуса) – Q1-1.5 IQR (міжквартильний розмах) та Q3+1.5 IQR; кружки – статистичні викиди.

Таблиця 3.3. Інтерпретація рисунка 3.6

Параметр	Q1	Медіана	Q3	Коментар щодо викидів
mass	134 кг	520 кг	1 552 кг	Викиди > 10000 кг і < 0.5 кг; підтверджує «довгий хвіст».
diameter	1.4 м	2.4 м	3.0 м	Невелика група < 0.05 м (дрібні уламки) і > 5 м (обтікачі).
height	0.3 м	1.1 м	5.3 м	Два кластери: панельні (≤ 1 м) та ступені (5–8 м).
width	0.4 м	2.5 м	3.7 м	Сплеск викидів $\sim 6-7$ м (великі секції), хвіст < 0.1 м.
span	1.5 м	6.5 м	9.0 м	Поодинокі викиди > 100 м.
xSectAvg	1.26 м ²	11.2 м ²	18.3 м ²	Рідкісні ≥ 100 м ² та $\leq 10^{-3}$ м ² .

Ключові результати.

Маса демонструє $IQR \approx 134-1\,552$ кг і довгий правий хвіст до 450 т; лівий хвіст містить фрагменти < 0.5 кг.

Геометричні розміри (diameter, height, width) мають бімодальну структуру: перший модальний кластер (коробчаті супутники з панелями) концентрується в діапазоні 0.3-3 м, другий (циліндричні ступені та обтікачі) – 5-10 м.

Span та xSectAvg підтверджують ступеневу залежність від маси: whiskers цих параметрів зміщуються синхронно з whiskers маси, а високі викиди ($span > 100$ м та $xSectAvg > 100$ м²) чітко корелюють з невеликою групою експериментальних тросових місій і фрагментів обтікачів.

Наявність викидів $> 3\sigma$ (стандартне відхилення) у всіх шести параметрах свідчить про гетерогенність каталогу. Для моделювання теплових навантажень варто підрізати ці значення (winsorizing)

Після детального та повного аналізу каталогу DISCOS було прийнято три ключові обмеження та додатковий критерій унікальності, що сформували чотири послідовні фільтри, які спрямовані на підвищення точності та стабільності подальших теплових розрахунків (наведені в таблиці 3.4).

Таблиця 3.4. Ключові обмеження вибірки для теплового аналізу об'єктів із каталогу DISCOS

Запроваджене обмеження	Аргументація на користь кожного фільтра
Маса 100 - 1 500 кг	У цьому інтервалі зосереджено $\approx 52\%$ усіх записів. Виключення дрібних космічних об'єктів та надважких ступенів усуває крайові режими тепло-аеродинаміки, що потребують окремих CFD-процедур. Масовий інтервал 100-1 500 кг охоплює місії, для яких термічне руйнування та оптимізація траєкторії є найбільш актуальними.
Видалення статистичних викидів у геометричних полях	Тест IQR-критерію та 3σ показав, що $<2\%$ об'єктів мають екстремальні значення, непропорційні основній популяції. Тросові елементи та фрагменти обтікачів спотворюють регресійні моделі й збільшують дисперсію помилок. Їх вилучення знижує розмах whiskers майже вдвічі, що підтверджує покращення однорідності вибірки.
Обмеження $xSectAvg \leq 20 \text{ м}^2$	Граничне значення $xSectAvg$ в 20 м^2 гарантовано залишає у вибірці 90-перцентильні об'єкти, але відсікає аномально великі площі, характерні лише для кількох ракетних ступенів
Унікальність за масою, формою та геометрією	Унікальність за геометрією забезпечує незалежність вибірки та коректну вагу кожного набору параметрів у регресіях і кластер-аналізі.

Отже, обмеживши масу, усунувши геометричні екстремуми, застосувавши верхню межу середньої площі та гарантуючи унікальність за ключовими ознаками, ми сформували компактний, статистично збалансований датасет (див. рис. 3.7 і 3.8) зі 1995 космічних об'єктів, який:

- має 100 % заповненості параметрів бази космічних об'єктів;
- уникає переорієнтації моделі на крайові режими, залишаючи їх для спеціалізованих CFD-процедур;
- забезпечує коректну вагу кожної геометричної конфігурації, тим самим підвищуючи точність та інтерпретованість оптимізації траєкторій за тепловим чинником у межах дослідження.




Рисунок 3.7. Розподіл маси серед об'єктів датасету (100-1500 кг, $xSectAvg \leq 20 \text{ м}^2$)




Рисунок 3.8. Розподіл середньої площі поперечного перерізу серед об'єктів датасету (100-1500 кг, $xSectAvg \leq 20 \text{ м}^2$)

3.2. Оцінка аеродинамічних і геометричних параметрів C_d та R_n

Після завершення попередньої очистки й відбору даних було сформовано датасет із 1 995 унікальних орбітальних об'єктів, що охоплює основний клас мас 100 – 1 500 кг та репрезентативний спектр поширених геометричних форм. Подальший розрахунок теплового навантаження вимагає двох ключових параметрів – коефіцієнта аеродинамічного опору C_d і характеристичного радіуса точки застою R_n .

Коефіцієнт опору C_d входить у балістичний коефіцієнт та визначає величину гальмівної сили, а отже – максимальну висоту нагріву та час входу:

$$\beta = \frac{m}{C_d A_{ref}}, \quad (3.2)$$

де A_{ref} – референтна або опорна площа $\approx xSectAvg$.

C_d залежить від зовнішньої форми, числа Рейнольдса, режиму потоку та миттєвої орієнтації тіла. Радіус кривизни у точці застою R_n визначає густину конвективного теплового потоку.

Коефіцієнт аеродинамічного опору C_d доцільно задавати за літературними табличними значеннями [154-160], тому що точні перетворення через балістичний коефіцієнт потребують динамічних TLE-спостережень, що виходить за межі статичного набору.

Радіус кривизни носової частини – це геометричний параметр, що позначає ефективний радіус носової частини космічного апарату, який використовується в рівняннях розрахунку нагріву та аеродинамічних характеристик у точці застою.

Характеристичний радіус R_n визначається через підставлення геометричних розмірів космічного об'єкту там, де ці параметри відомі, або з використанням $xSectAvg$ (табл. 3.5).

Таблиця 3.5. Типові геометрії космічних об'єктів: коефіцієнти опору C_d та розрахунок характерного радіуса R_n

Форма КО	Використаний C_d	Використана формула для R_n
Cyl	2.2	$D/2$, де D – діаметр
Box + 2 Pan	2.4	$\frac{1}{2} \sqrt{\frac{wh}{\pi}}$, де w – ширина, h – висота
Box + 1 Pan	2.35	$\frac{1}{2} \sqrt{\frac{wh}{\pi}}$
Box	2.30	$\frac{1}{2} \sqrt{\frac{wh}{\pi}}$
Sphere	2.10	$D/2$
Cone	1.40	$R_{base} = D_{base}/2$, де D_{base} – діаметр основи конуса
Cyl + 1 Nozzle	2.25	$D_{cyl}/2$
Sphere + Cyl	2.15	$\sqrt{\frac{A_{sph}+A_{cyl}}{\pi}}$, де A_{sph} і A_{cyl} – миттєві проекційні площі сферичної і циліндричної частин відповідно
Trap Box + 2 Pan	2.45	$\frac{1}{2} \sqrt{\frac{w_{base}h}{\pi}}$, де w_{base} – ширина основи трапецієподібного корпусу
Cyl + 2 Pan	2.30	$\sqrt{\frac{A_{cyl}+A_{pan}}{\pi}}$, де A_{pan} – миттєва проекційна площа панельної частини

В таблиці суми $A_{sph} + A_{cyl}$ і $A_{cyl} + A_{pan}$ за відсутності повного набору геометричних параметрів космічного об'єкта приймаємо $\approx xSectAvg$.

3.3. Формування фінального датасету для машинного навчання

Після завершення усіх етапів очищення, видалення викидів і розрахунку аеродинамічних і геометричних параметрів C_d та R_n база первинних об'єктів налічує 1 995 записів. Для кожного з них було згенеровано сітку початкових умов – кут входу $\theta \in [0^\circ, 3^\circ]$ з кроком 0.1° та швидкість $V_0 \in [7.5 \text{ км/с}, 8.5 \text{ км/с}]$ з кроком 0.1 км/с . У підсумку сформовано 100 000 комбінацій, що й

становлять фінальний набір для тренування й валідації моделей, структуру якого наведено в таблиці 3.6.

Таблиця 3.6. Структура запису фінального датасету

Поле	Одиниці	Опис	Спосіб одержання
mass	кг	Маса космічного об'єкта	Каталог ESA
xSectAvg	м ²	Середня площа	Каталог ESA
Rn	м	Радіус точки застою	Табл. 3.5
Cd	—	Коефіцієнт аеродинамічного опору	Табл. 3.5
entry_angle	°	Геометричний кут траєкторії на 120 км	Штучна сітка 0...3°
velocity	км/с	Початкова швидкість на 120 км	Штучна сітка 7.5...8.5
q_time_series	Вт/м ²	Ненормалізований профіль теплового потоку $q(t)$ з кроком 0.1 с	Пункт 2.1.2

У таблиці 3.7 наведені основні описові статистики для шести числових ознак фінального датасету. Дані свідчать, що після фільтрації аномально великих перерізів $xSectAvg \geq 20m^2$ інтервал між кuartилями звужено в 2-3 рази порівняно з початковою вибіркою, що забезпечує сталість навчання.

Таблиця 3.7. Розподіл основних характеристик датасету

Ознака	min	Q1	median	Q3	max
mass, кг	100.00	260.00	554.00	891.97	1500.00
xSectAvg, м ²	0.094246	1.957546	4.574504	8.386471	19.792034
Rn, м	0.01	0.55	0.75	1.08	2.00
Cd, —	1.40	2.10	2.20	2.30	2.45
entry_angle, °	0.0	0.8	1.5	2.3	3.0
velocity, км/с	7.5	7.8	8.0	8.2	8.5

На рис. 3.10 подано теплову карту коефіцієнтів Пірсона ρ який вказує на кореляції (силу і напрямок лінійного зв'язку) між двома змінними. Значення 0 – відсутність лінійного зв'язку. Тоді як ρ біля 1 і -1 означає сильну кореляцію.




Рисунок – 3.10. Теплова карта коефіцієнту Пірсона

$xSectAvg \leftrightarrow R_n$, значення $\rho \approx 0.85$ – прямий наслідок визначення радіуса через геометрію КО і його площі. $xSectAvg \leftrightarrow mass$ та $mass \leftrightarrow R_n$ вказують на більші габарити у більш масивних об’єктів. Коефіцієнт опору C_d практично не корельований з іншими змінними, так як залежить від форми КО. Слабкі зв’язки між кінематичними кутами входу КО і його швидкості та геометричними ознаками вказують на відсутність мультиколінеарності, що важливо для стабільності градієнтного навчання.

Фінальний датасет поділено на train / validation у пропорції 80% / 20% та стратифіковано за двома розрізами: масовий інтервал 100-400 кг, 400-800 кг, 800-1 200 кг, 1 200-1 500 кг, та кут входу на 31 рівень. Такий поділ гарантує, що кожна підкомбінація «маса-кут» представлена у валідації, запобігаючи упередженню до переважаючих груп даних.

Отже, сформований датасет об'єднує повну варіативність початкових умов і геометричних характеристик, достатню для навчання моделей машинного навчання, а також для подальшого використання у генетичному оптимізаторі. Продемонстровані статистики й кореляційний аналіз підтверджують збалансованість набору й відсутність надмірних залежностей між ознаками.

3.4. Розробка моделей машинного навчання

Вибір архітектури машинного навчання обумовлений специфікою поставленої задачі та прагненням збалансувати точність моделі з обчислювальною ефективністю. З одного боку, глибокі нейронні мережі здатні засвоювати складні фізичні залежності за наявними даними, забезпечуючи кращу точність порівняно з простими емпіричними методами, а з іншого – разовий прогон навченої моделі є обчислювально недорогим. Такий підхід уже застосовується для швидкого прогнозування аеротермодинамічних навантажень: зокрема, багат шарові перцептрони (MLP) і згорткові нейронні мережі успішно використовувалися для передбачення теплового потоку та тиску на поверхні апаратів замість ресурсомістких CFD-розрахунків [161, 162]. Таким чином, використання нейронних мереж як сурогатних моделей теплових процесів під час входження в атмосферу є перспективним для задач оптимізації траєкторій, де потрібні численні оцінки теплового навантаження в режимі реального часу.

Для дослідження було обрано три архітектури глибокого навчання: MLP (Multilayer Perceptron) – базова глибока нейронна мережа прямого поширення, LSTM (Long Short-Term Memory) – рекурентна нейронна мережа із механізмом довгої короткочасної пам'яті та Transformer – сучасна трансформерна модель із механізмом самоуваги. Кожна з цих моделей пропонує власний підхід до формування часових рядів на основі початкових умов і має свої сильні та слабкі сторони.

3.4.1. Модель MLP

Алгоритм MLP є класичною штучною нейронною мережею прямого поширення. Вперше механізм одношарового персептрону був запропонований Frank Rosenblatt у 1958 році для задач лінійно відокремлюваної класифікації [163]. У 1986 році автори у [164] представили алгоритм зворотного поширення помилки (backpropagation) для навчання багатошарових мереж, що дозволило успішно тренувати нейронні мережі з одним або більше прихованими шарами.

MLP складається з впорядкованих шарів штучних нейронів: вхідного, одного або кількох прихованих шарів та вихідного (рис. 3.11).




Рисунок – 3.11. Схема глибокої нейронної мережі типу MLP з прямим з'єднанням між шарами

Кожен нейрон прихованого або вихідного шару обчислює зважену суму сигналів з попереднього шару та пропускає її через нелінійну активаційну функцію (наприклад, сигмоїду, ReLU тощо). Математично це можна описати як:

$$h_j^{(l)} = \varphi \left(\sum_i w_{ji}^{(l)} \cdot h_i^{(l-1)} + b_j^{(l)} \right), \quad (3.3)$$

де $h_i^{(l-1)}$ – вихід i -го нейрона попереднього шару, $w_{ji}^{(l)}$ – вага з'єднання, $b_j^{(l)}$ – зміщення, φ – активаційна функція.

Формально персептрон складається з наступних рівнянь [165]:

$$h^{(l)} = \varphi(h^{(l-1)}, \theta) = \begin{cases} 1, & \text{якщо } wh - b \geq 0 \\ -1, & \text{інакше} \end{cases}, \quad (3.4)$$

де θ - вектор, що містить ваги та зсув.

Вхідний вектор множиться на вектор ваг для того, щоб отримати зважену суму. Згодом, якщо вищезгадана сума більша за поріг b , пристрій видає 1. В іншому випадку персептрон видає -1. Графічно обчислювальний потік представлено на рис. 3.12.




Рисунок – 3.12. Графічне зображення персептрона (адаптовано з [165])

Навчання MLP здійснюється алгоритмом backpropagation – методом градієнтного спуску, що обчислює похибку між фактичним і цільовим виходом та поступово коригує ваги мережі у напрямку зменшення цієї похибки [164]. Ключова ідея – обчислення градієнтів помилки на виході та їх зворотне поширення через шари мережі з використанням правила ланцюга.

Для $w_{ji}^{(l)}$ вага оновлюється за правилом:

$$\Delta w_{ji}^{(l)} = -\eta \frac{\partial E}{\partial w_{ji}^{(l)}}, \quad (3.5)$$

де E – функція помилки, η – коефіцієнт навчання.

Алгоритм `backpropagation` дозволив багат шаровим мережам автоматично навчати приховані ознаки у внутрішніх шарах, тобто виявляти важливі особливості вхідних даних, що було неможливо для одношарового персептрону. Саме здатність прихованих нейронів витягувати корисні ознаки з даних відрізняє MLP від ранніх моделей і забезпечує йому велику виразну потужність.

MLP має низку важливих *переваг*. Основною перевагою MLP є відносна простота та швидкодія. Також він здатний навчатися нелінійних залежностей між ознаками та виходом, що значно розширює коло розв’язуваних задач порівняно з лінійними моделями. MLP універсальний у застосуванні – його можна використовувати і для задач класифікації, і для регресії, працюючи з різними типами вхідних даних (числовими, бінарними, категоріальними – за умови відповідного кодування). Існують реалізації, що дозволяють навчати MLP у режимі онлайн, поступово оновлюючи ваги при надходженні нових даних [166].

Головним *недоліком* MLP в задачі прогнозування часових рядів є відсутність явного урахування часової структури даних. Модель трактує кожен з моментів часу вихідного профілю як незалежну цільову змінну, тому не має внутрішньої пам’яті про те, як значення теплового навантаження еволюціонують з часом. Результат навчання залежить від початкових ваг та вибору гіперпараметрів, а градієнтний спуск не гарантує знаходження глобального мінімуму. MLP вимагає налаштування численних гіперпараметрів (кількість шарів, нейронів, норма навчання, параметри регуляризації тощо), що потребує обережного підходу, аби запобігти перенавчанню. Мережі з великою кількістю параметрів схильні до перенавчання, особливо на невеликих вибірках. Тому часто застосовують

методи регуляризації (нормалізація ваг, dropout тощо) та ретельно готують дані. Зокрема, масштабування ознак є важливим кроком – MLP чутливий до різних шкал вхідних параметрів, і без нормалізації градієнти можуть затухати або вибухати.

Попри появу глибших і складніших моделей, MLP залишається базовим інструментом і широко використовується в наукових та інженерних дослідженнях. Його популярність зумовлена простотою реалізації та інтерпретації. Завдяки універсальній апроксимаційній здатності та відносно невеликій обчислювальній вартості, багат шаровий перцептрон залишається актуальним інструментом, особливо на ранніх етапах побудови моделей і для порівняння з більш новими підходами.

3.4.2. Модель LSTM

Довга короткострокова пам'ять (LSTM) – це різновид рекурентної нейронної мережі (RNN), розроблений для подолання проблеми затухання градієнтів при навчанні на довгих послідовностях. Класичні рекурентні структури, введені Джоном Хопфілдом у 1982 році [167], мережа Елмана, запропонована у 1990 році [168], та мережа Джордана [169], мають обмежену здатність зберігати інформацію більше ніж на кілька кроків через експоненційне згасання градієнта помилки у часі. У 1997 році автори [170] запропонували архітектуру LSTM як ефективний метод запам'ятовування довготривалих залежностей в послідовностях. Ключовою ідеєю стало введення механізму постійного помилкового потоку (Constant Error Carousel, CEC) через особливі комірки пам'яті та мультиплікативні ворота (gate units) для керування цим потоком. На відміну від стандартних RNN, де стан швидко забувається, LSTM-комірки можуть зберігати інформацію протягом сотень і навіть тисяч кроків часу без значного затухання градієнту. Початковий варіант LSTM було вдосконалено введенням воріт забування (forget gates) [171], що дозволило мережі навчатися також “стирати” непотрібну інформацію з пам'яті. LSTM мережі продемонстрували значно кращі результати ніж

традиційні рекурентні алгоритми на задачах з довгими залежностями, відкривши шлях до їх широкого застосування в обробці послідовних даних.

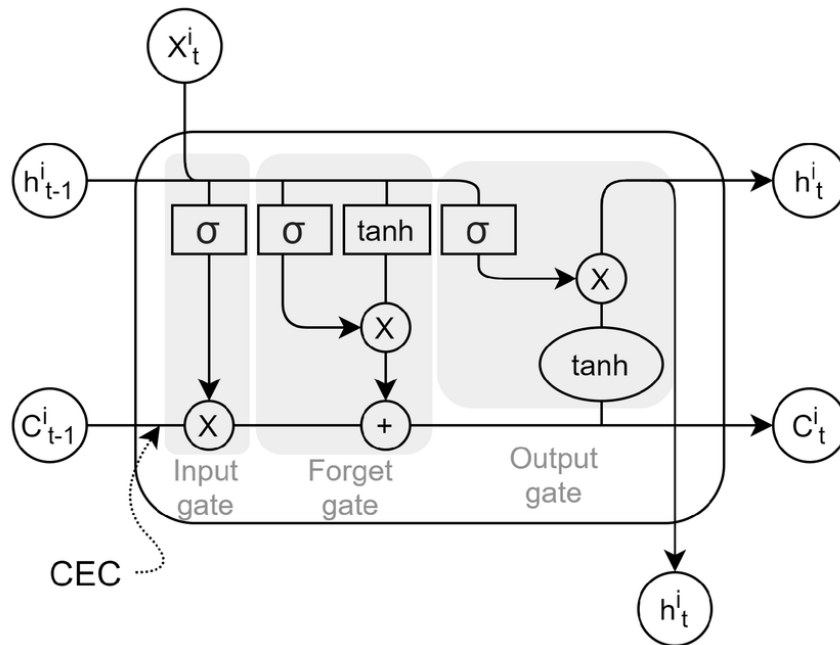


Рисунок – 3.13. Графічне представлення внутрішньої структури LSTM-комірки для j -тої пам'яті [172].

Архітектура LSTM складається з повторюваних модулів – комірок пам'яті (memory cells), кожна з яких на кожному кроці часу отримує на вхід поточний сигнал і попередній прихований стан. Усередині кожної комірки є кілька логічних елементів – воріт, що регулюють потоки інформації. Зокрема, вхідні ворота контролюють, яку частину нового входу записати до пам'яті; ворота забування визначають, яку частину попереднього стану пам'яті зберегти, а яку – забути; вихідні ворота вирішують, яку частину оновленого стану пам'яті передати далі на вихід комірки до прихованого стану [173]. Окрім того, обчислюється кандидат на новий стан пам'яті, також його називають внутрішнім станом, зазвичай через тангенсову активацію (рис. 3.13).

На кожному кроці t LSTM-комірка виконує такі операції для j -тої пам'яті:

Вхідні, ворота забування та вихідні ворота

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + b_i), \quad (3.6)$$

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + b_f), \quad (3.7)$$

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + b_o), \quad (3.8)$$

де $\sigma(\cdot)$ – сигмоїдна функція активації, x_t – вхідний вектор у момент t , h_{t-1} – вихід (прихований стан) попереднього кроку, W – матриці ваг для відповідних воріт, b – їхні заміщення.

Рівняння (3.6-3.8) визначають значення воріт $i_t, f_t, o_t \in [0,1]^h$, що інтерпретуються як фільтри: i_t – регулює кількість нової інформації, що буде інтегрована до комірки пам'яті, f_t – визначає частку наявного стану пам'яті, що зберігається для подальшого використання, o_t – керує обсягом актуалізованої інформації, що передається на вихід моделі для формування поточного прихованого стану.

Кандидат на оновлення стану пам'яті:

$$\tilde{c}_t = \tanh(W_{xc}x_t + W_{hc}x_{t-1} + b_c), \quad (3.9)$$

де \tanh – гіперболічний тангенс.

Процес оновлення стану пам'яті:

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t, \quad (3.10)$$

де \odot - поелементне множення. Якщо $f_t \approx 1$ і $i_t \approx 0$, то $c_t \approx c_{t-1}$ – пам'ять практично повністю зберігається, забезпечуючи СЕС та відсутність затухання градієнта [170].

І, наостанок, обчислюється вихід прихованого стану:

$$h_t = o_t \odot \tanh(c_t), \quad (3.11)$$

Прихований вихід h_t є відфільтрованим через o_t значенням поточного стану пам'яті, пропущеним через функцію активації \tanh активацію. Вихідні ворота можуть блокувати або пропускати інформацію з пам'яті до вихідного сигналу комірки залежно від контексту. Зв'язані разом, ці компоненти дозволяють LSTM вибірково накопичувати інформацію, видаляти її або передавати далі. Завдяки цьому LSTM може навчитися, які саме попередні дані є важливими для прогнозу на поточному кроці, і утримувати довгострокові залежності набагато ефективніше, ніж традиційні RNN.

LSTM-блоки зазвичай об'єднуються в шари, схожі на приховані шари MLP, і можуть будувати глибокі рекурентні моделі. Такі мережі тренуються методом *backpropagation through time* (BPTT) [174] – це розширення алгоритму зворотного поширення, що враховує розгортку мережі в часі.

Головною *перевагою* LSTM є здатність опрацьовувати послідовні дані довільної довжини, зберігаючи інформацію про попередні елементи. На додаток, завдяки механізму воріт, LSTM вирішує основний недолік простих RNN: проблему затухаючих (або вибухаючих) градієнтів під час навчання на довгих послідовностях. Як наслідок, LSTM здатна навчатися довготривалих залежностей. LSTM, на відміну від MLP, не потребує фіксованої довжини входу: вона може працювати зі змінно-довгими послідовностями, що важливо для роботи з реальними даними.

Проте алгоритм LSTM має і *недоліки*. Модель складніша: кожна LSTM-комірка містить кілька параметризованих воріт, тому загальна кількість параметрів істотно більша, а це в свою чергу збільшує обчислювальну складність. Навчання LSTM повільніше, оскільки неможливо повністю паралелізувати процес: стан на кожному кроці залежить від попереднього, тому обчислення здійснюється послідовно, що особливо критично при довгих залежностях. Ще одне обмеження – потреба у великих обсягах даних для навчання та виокремлення корисних патернів. Алгоритм LSTM так само схильний до перенавчання.

3.4.3. Модель Transformer

Модель Transformer – це сучасна неймережна архітектура глибокого навчання представлена у 2017 році командою дослідників Google [175](рис. 3.14).

Стаття [176] ґрунтовно досліджує еволюцію та вплив архітектур Transformer у сучасному штучному інтелекті. Ключова особливість моделі – механізм самоуваги (self-attention), який дозволяє оцінювати важливість різних частин послідовності одна для одної.

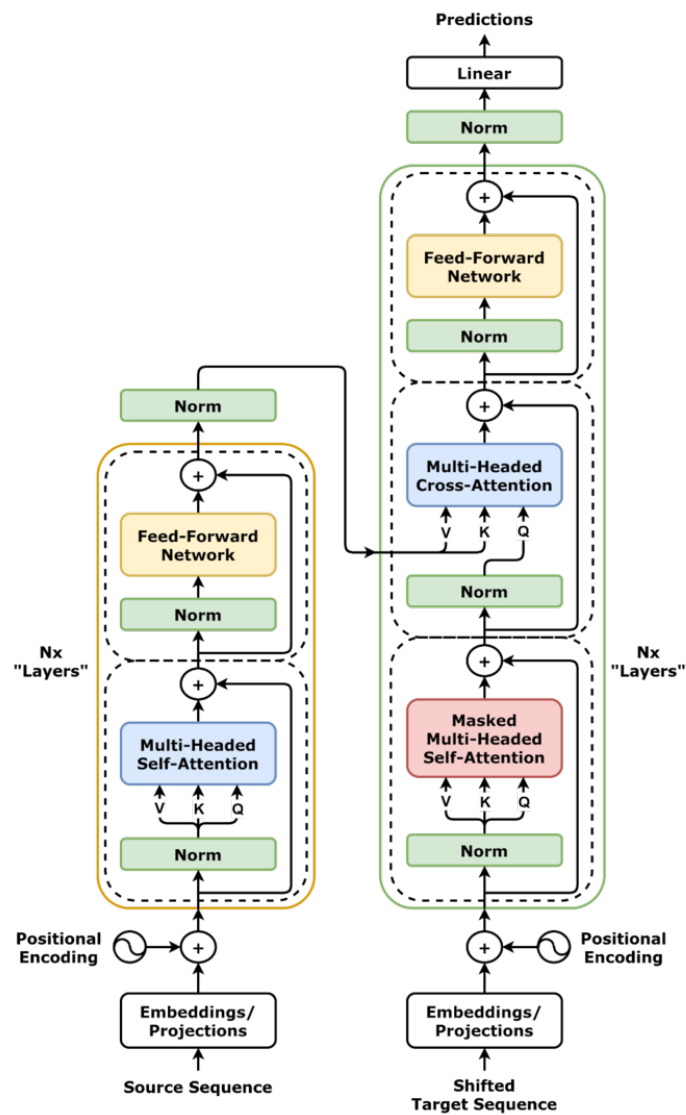


Рисунок – 3.14. Модель архітектури Transformer [175]

На відміну від рекурентних мереж де градієнт впливу згасає з часом, Transformer опрацьовує всю послідовність одночасно, дозволяючи моделі навчатися глобальних залежностей між елементами незалежно від їх позиції у ряду через обчислення скалярних ваг. Крім того, відсутність рекурентних зворотних зв'язків означає, що всю послідовність можна обробляти паралельно, завдяки чому тренування трансформерів значно прискорюється.

Основною ключовою характеристикою архітектури Transformers є те, що вони підтримують модель кодер-декодер (encoder-decoder) (рис. 3.15). Кодер зчитує і обробляє вхідні дані фрагментами одночасно і кодує його в контекстне представлення. Потім декодер послідовно зчитує це представлення і генерує вихідні дані.

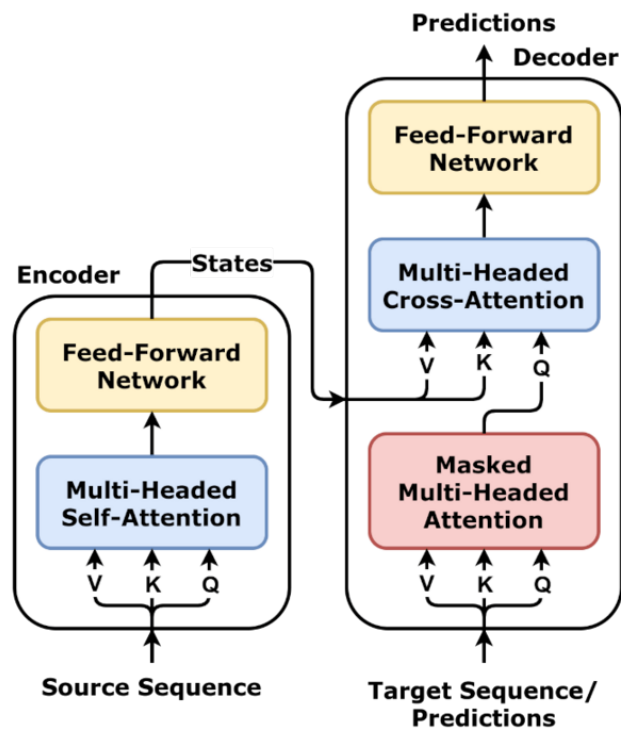


Рисунок – 3.15. Схема encoder-decoder блока [175]

Робочий процес кодера.

Кодер є фундаментальним компонентом архітектури Transformer. Основна функція кодера полягає у перетворенні вхідних токенів у контекстне представлення. На відміну від попередніх моделей, які обробляли токени

незалежно, кодер Transformer фіксує контекст кожного токена по відношенню до всієї послідовності.

Узагальнена послідовність ключових операцій енкодера архітектури Transformer наведена нижче.

Вбудовування вхідних даних (input embeddings). На початковому етапі кожен вхідний токен кодується за допомогою вбудованого шару embeddings у вектор фіксованої розмірності, зазвичай 512. Це перетворює дискретні символи на неперервні числові представлення, придатні для подальших лінійних та нелінійних операцій у мережі.

Позиційне кодування (positional encoding). Оскільки архітектура Transformer не містить рекурентного чи конволюційного механізму для врахування порядку tokenів, до векторів embeddings додаються синусо- та косинусоїдальні позиційні вектори. Кожне таке кодування відображає абсолютну позицію токена в послідовності, що дозволяє моделі уникнути втрати інформації про порядкові відносини між словами.

Масштабована скалярно-добуткова самоувага (scaled dot-product attention) (рис. 3.16, а). На цьому кроці для кожного embedding обчислюються три окремі лінійні відображення: вектори запиту Q, ключа K і значення V. Далі обчислюється матриця самоуваги як:

$$Attention(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V, \quad (3.12)$$

де d_k – розмірність ключів і запитів. Що дає змогу адаптивно зважувати інформацію з усіх позицій вхідної послідовності та формує контекстно залежне представлення кожного токена.

Багатоголова увага (multi-head attention) (рис. 3.16, б). Процес паралельної обробки декількох scaled dot-product attention блоків, а потім кожна група результатів самоуваги з'єднується разом для виконання лінійного

перетворення для отримання кінцевих вихідних результатів. Зокрема, формула її обчислення має вигляд [177]:

$$Multi - Head(Q, K, V) Concat = (head_1, \dots, head_h)W_O, \quad (3.13)$$

$$head_i = Attention(QW_{Q_i}, KW_{K_i}, VW_{V_i}), \quad (3.14)$$

де h – кількість голів самоуваги, W_O – вихідна вагова матриця багатоголової уваги. Крім того, для проведення лінійного перетворення над Q , K та V використовуються вагові матриці QW_{Q_i} , KW_{K_i} і VW_{V_i} .

Залишкові зв'язки (residual connections) та нормалізація (normalization). Вихід multi-head attention доповнюється прямим з'єднанням із вхідним тензором (residual connection), а потім проходить шар нормалізації. Це прискорює зближення навчання та запобігає затухання градієнтів в глибоких мережах.

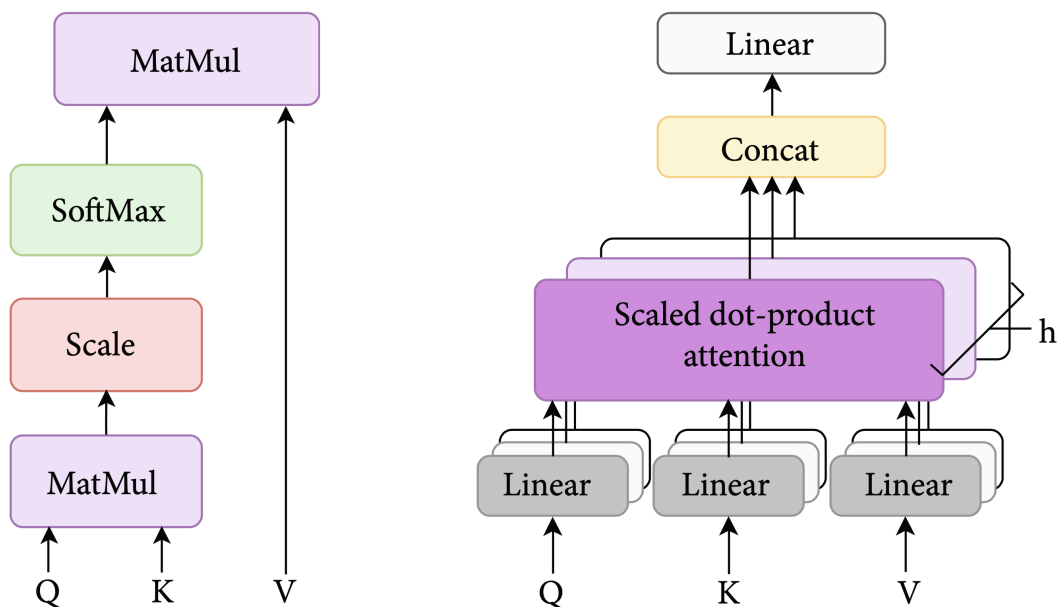


Рисунок – 3.16. (a) scaled dot-product attention blocks (b) multiheaded attention block [178]

Мережа прямого зв'язку (feed-forward network, FFN). Кожен вектор із попереднього кроку проходить через двошарову точкову мережу: лінійний шар \rightarrow ReLU \rightarrow лінійний шар для нелінійного перетворення. Така архітектура забезпечує додаткову обробку та перетворення ознак.

Вихід кодера (encoder's output). Вихід останнього шару кодера – це набір векторів, кожен з яких представляє вхідну послідовність з багатим контекстним розумінням. Цей вихід потім використовується як вхід для декодера в моделі Transformer.

Робочий процес декодера.

Роль декодера полягає у поетапному генеруванні вихідної послідовності токенів. Як і кодер, декодер має схожий набір підшарів.

Узагальнена послідовність ключових операцій декодера архітектури Transformer наведена нижче.

Вбудовування вихідних токенів (output embeddings). На вході декодера кожен згенерований або заданий токен переводиться в вектор фіксованої розмірності, зазвичай 512, за допомогою шару embeddings. Це створює неперервні числові представлення, сумісні з подальшими обчисленнями.

Позиційне кодування (positional encoding). Після вбудовування, так само як і в кодері, вхідний сигнал проходить через шар позиційного кодування. Це забезпечує декодеру інформацію про порядок тих токенів, які він уже створив.

Механізм маскування самоуваги (masked self-attention mechanism). Декодер використовує модифіковану версію self-attention з маскуванням майбутніх позицій. Для кожного токена обчислюються Q, K, V, а маска блокує доступ до пізніших елементів послідовності, гарантуючи авторегресивність:

$$\text{MaskedAttn}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}} + M\right)V, \quad (3.15)$$

де M – матриця-маска:

$$M_{i,j} = \begin{cases} 0, & \text{якщо } j \leq i \\ -\infty, & \text{якщо } j > i \end{cases} \quad (3.16)$$

Багатоголова перехресна увага (multi-head cross attention). У другому блоці уваги запити Q походять із виходу маскованої уваги, а ключі K та значення V – із фінального виходу енкодера. Це дозволяє декодеру інтегрувати інформацію про весь вхідний контекст:

$$\text{CrossAttn}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V, \quad (3.17)$$

Нейронна мережа прямого зв'язку (feed-forward neural network, FFNN). Подібно до кодера, кожен рівень декодера містить двошарову повнозв'язну мережу прямого зв'язку, яка застосовується до кожної позиції окремо та ідентично.

Додатково за кожним підрівнем *masked self-attention* – *cross attention* – *feed-forward network* подібно як і для кодера, слідує крок нормалізації, і кожен з них також включає залишковий зв'язок навколо нього.

Лінійний класифікатор (linear classifier) і функція активації *softmax* для генерації ймовірностей. Вихідні дані останнього шару перетворюються на передбачувану послідовність, зазвичай за допомогою лінійного шару, а потім *softmax* для генерації ймовірностей вибору наступного токена. Запропонована багаторівнева архітектура здатна суттєво підвищити прогностичну точність моделі, оскільки вона забезпечує глибоке й тонке моделювання взаємодії різноманітних конфігурацій механізмів уваги.

Головна *перевага* архітектури – здатність ефективно моделювати довгі послідовності, долаючи обмеження рекурентних мереж. Завдяки самоувазі Transformer може врахувати залежності між будь-якими двома елементами послідовності практично за один крок, тоді як LSTM теоретично теж може, але віддалені впливи проходять через ланцюжок проміжних станів і можуть розмиватися. Transformer позбавлений рекурентності, тому немає затухання градієнта з ростом довжини послідовності – градієнт може протікати прямими шляхами уваги від будь-якої позиції до будь-якої. Інша велика перевага –

паралельне навчання: оскільки немає послідовної залежності, модель може обробляти всі позиції одночасно на GPU, що прискорює навчання в рази. Практично це означає кращу масштабованість на великих даних і довгих послідовностях.

Щодо *недоліків*. За відсутності рекурентності Transformer бракує вбудованого відчуття порядку – він покладається лише на позиційні кодування. Обчислювальна вартість механізму самоуваги зростає квадратично від довжини послідовності. Крім того, трансформери мають дуже багато параметрів і потребують великі набори даних для навчання, щоб показати свою перевагу.

3.4.4 Порівняльний аналіз MLP, LSTM та Transformer

Усі три розглянуті моделі – MLP, LSTM та Transformer – є важливими представниками різних поколінь архітектур глибокого навчання. Кожна з них має свої сильні сторони та обмеження, і доцільність використання тієї чи іншої моделі залежить від характеру задачі та даних. Нижче наведено порівняння за кількома релевантними критеріями

Тип задач та даних.

MLP призначений передусім для задач з фіксованою розмірністю входу та виходу. Алгоритм не має внутрішнього стану і не враховує порядок подачі даних. Ефективний на відносно простих задачах навіть з обмеженим датасетом. Не має вбудованих припущень про структуру даних.

LSTM розроблено для послідовних даних, для задач з урахуванням часових чи позиційних залежностей. Алгоритм добре працює зі змінною довжиною послідовності. У випадку об'ємних датасетів повільний у навчанні.

Модель Transformer також працює з послідовностями, але може ефективно обробляти дуже довгі послідовності і взаємодії в них завдяки механізму глобальної уваги.

Архітектурна складність та параметри.

Алгоритм MLP є концептуально найпростіший: кілька шарів повнозв'язних нейронів, вибір активації, швидкість навчання. Кількість параметрів залежить від розміру шарів, і за великих архітектур може бути значною, але загалом MLP легше аналізувати і реалізувати. Занадто глибокі MLP можуть потребувати спеціальних ініціалізацій/активацій, щоб уникнути згасання градієнтів.

LSTM складніший – кожен нейрон прихованого стану замінено на комірку з трьома воротами і внутрішньою пам'яттю, тому параметрів в чотири рази більше на ту ж розмірність прихованого представлення. Додаткові гіперпараметри – розмір прихованого стану, схема ініціалізації гейтів, тощо. Потребує належної настройки швидкості навчання та застосовується gradient clipping для стабільності.

Transformer – ще більш комплексна модель: вона містить багато шарів, кожен з яких складається з кількох «голів» уваги і feed-forward мереж. Велика кількість гіперпараметрів - кількість шарів, ширина моделі, число голів уваги, розмір позиційних векторів, схема learning rate, коефіцієнти регуляризації тощо. Це підвищує вимоги до пам'яті і обчислювальних ресурсів при навчанні.

Урахування довгострокових залежностей.

MLP не має внутрішньої пам'яті і не може самостійно врахувати довгострокові залежності у вхідних даних.

Алгоритм LSTM спеціально призначений для довгих залежностей. Завдяки стану комірки може зберігати інформацію протягом багатьох тактів, що дозволяє моделювати послідовності на довгих відрізках часу.

Модель Transformer забезпечує теоретично необмежене охоплення контексту в межах довжини вхідної послідовності, оскільки кожне вихідне представлення безпосередньо інтегрує інформацію про всі елементи вхідних даних за допомогою механізму self-attention. Це дозволяє моделі надійно відтворювати дуже далекі залежності всередині заданого контекстного вікна без проблем із затуханням градієнтів. Практичні обмеження на максимальну

довжину таких залежностей визначаються виключно розміром контексту, на якому модель була навчена та наявними обчислювальними ресурсами.

Паралелізація та швидкість навчання.

Навчання алгоритму MLP можна паралелізувати по нейронах і входах. Час роботи росте лінійно з числом параметрів і розміром входу. Доволі швидкий і простий в реалізації.

Для LSTM обчислення розгорнуті у часі: обробка кожного кроку строго залежить від результатів попереднього, що унеможлиблює їх паралелізацію вздовж часової осі.

Модель Transformer має повну паралельність по довжині послідовності.

Адаптація до специфічних вимог і гнучкість.

MLP є універсальним алгоритмом, але потребує інженерії ознак для послідовних/просторових даних.

Алгоритм LSTM більш спеціалізований для послідовностей часу, його можна легко застосувати до будь-якого ряду даних у часі.

Модель Transformer – надзвичайно гнучкий завдяки механізму уваги.

Висновок. У контексті задачі оптимізації траєкторій КО в атмосфері за тепловим чинником, вибір моделі буде залежати від доступних даних і вимог до врахування динаміки. MLP може слугувати базовою моделлю. LSTM здатна безпосередньо працювати з часовим профілем теплового навантаження $q(t)$. Transformer може виявитися ефективним для прогнозування або оптимізації, якщо є достатньо даних для навчання. У підсумку, всі три моделі доповнюють одна одну: MLP забезпечує простоту і інтерпретованість, LSTM – спеціалізовану пам'ять для послідовностей, Transformer – потужність уваги і паралельність.

3.4.5. Гіперпараметри моделей та їхній вплив

Сучасні нейронні мережі мають низку гіперпараметрів – параметрів моделі, які задаються до навчання і визначають архітектуру та поведінку мережі. Від правильного вибору гіперпараметрів залежить здатність моделі

навчатися і узагальнювати закономірності у даних. Нижче наведено основні гіперпараметри для архітектури глибинного навчання – MLP, LST та Transformer. Розглянуто функціональне призначення цих гіперпараметрів, принцип дії модельних компонентів і типову обчислювальну складність.

Кількість шарів або глибина моделі. Кількість шарів визначає глибину нейронної мережі, тобто скільки послідовних нелінійних перетворень застосовується до даних. Глибші моделі потенційно здатні відображати дуже складні функції та закономірності, але їх тренування складніше, а ризик перенавчання вищий при недостатній кількості даних [179].

MLP. З погляду функціональності, один прихований шар вже дозволяє апроксимувати довільну неперервну функцію за достатньої кількості нейронів. Додавання прихованих шарів дозволяє моделі набувати більшої виразності без додавання числа нейронів, поступово витягуючи високорівневі ознаки з даних [180]. При цьому, збільшення числа шарів підвищує потужність моделі, але ускладнює її навчання через проблему згасаючих градієнтів та збільшує ризик перенавчання. Тому глибину мережі обирають, балансуючи між виразністю та складністю моделі. Зазвичай додавання 3 прихованих шарів є оптимальними.

LSTM. У рекурентній мережі LSTM глибина може означати кількість послідовно складених LSTM-шарів, де вихід попереднього шару подається на вхід наступного. Один шар LSTM вже здатен зберігати і передавати інформацію через час завдяки внутрішній пам'яті. Додавання шарів збільшує модельну потужність – нижчі LSTM-рівні можуть вивчати короткострокові патерни, а вищі – більш узагальнені довгострокові залежності. Проте вигода від збільшення глибини проявляється лише за достатньої кількості даних і правильного налаштування – кожен додатковий шар LSTM суттєво збільшує число параметрів і обчислень, ускладнює зникаючий/вибухаючий градієнт та вимагає більш довгого навчання [181]. Рекомендований діапазон – 1-3 LSTM-шар, при цьому варто оцінювати приріст якості і ризик перенавчання.

Transformer. Для цієї архітектури глибиною моделі зазвичай вважають кількість послідовних блоків самоуваги у енкодері та декодері. Класичний Transformer мав по $N=6$ шарів у енкодері і декодері [175], пізніші успішні моделі для обробки текстів містили від 12 до 48 шарів. Кожен шар дозволяє виконати ще один рівень перетворення ознак послідовності, що підвищує виразність моделі. Однак збільшення шарів веде до квадратичного росту витрат, оскільки кожен шар включає самоувагу на всій послідовності. До того ж, кожен шар – це велика кількість параметрів, і надто глибокі трансформери потребують складніших схем навчання для стабільної збіжності. Для невеликих задач часового ряду часто достатньо 2-4 шарів. невеликим датасетом, Автори у [182] для серій середньої складності рекомендують використовувати 2-4 шари і збільшувати при потребі, адже застосування дуже глибоких трансформерів недоцільне та вимагатиме більше ресурсів.

Розмір прихованого стану/шару. Розмір прихованого шару в MLP або прихованого стану в LSTM чи векторних представлень в Transformer визначає кількість нейронів або ознак, які модель може одночасно утримувати у своєму внутрішньому представленні. Ширші шари здатні вмістити більше інформації і вивчити складніші відношення. Якщо малий розмір прихованого простору може призвести до недонавчання, то надто великий – до перенавчання та збільшення обчислювальної складності без істотної вигоди.

MLP. У алгоритму MLP розмір прихованого шару часто підбирається експериментально; загальна рекомендація – починати з величини порядку розміру вхідного чи вихідного векторів і коригувати при необхідності. Типові діапазони для моделей MLP – десятки або сотні нейронів. Ширший шар дозволяє виявити більше ознак та підвищує гнучкість моделі. Водночас занадто великий шар різко збільшить кількість параметрів і ризик перенавчання. Література з глибокого навчання радить збільшувати розмір шарів поступово, слідкуючи за помилкою на валідації [183].

LSTM. У LSTM-мережі розмір прихованого стану – це розмірність вектора h_t і стану пам'яті c_t та відповідно кількість нейронів у кожному

LSTM-шарі. Цей гіперпараметр визначає обсяг інформації, яку LSTM-мережа здатна зберігати про попередні стани послідовності. Малий розмір, менше 32, може бути недостатнім, щоб захопити усі важливі патерни довгої послідовності, тоді як великий, 256 і більше, підвищує модельну потужність, але потребує більше даних для надійного навчання ваг. Є доцільним починати з помірних значень, наприклад, 64 і перевіряти, чи збільшення до 128 дає покращення на валідації.

Transformer. Для даної архітектури аналогом розміру прихованого шару є розмірність модельного простору d_{model} , тобто довжина векторного представлення, з яким оперує кожен шар самоуваги. Наприклад, в оригінальній моделі Transformer розмірність $d_{model} = 512$ [175], тобто кожна позиція кодується 512-вимірним вектором, всі операції уваги й перетворення відбуваються в цьому просторі. Важливо зазначити, що d_{model} пов'язаний з іншими параметрами трансформера: зазвичай вибирають число голів уваги так, щоб d_{model} ділилось на це число. Збільшення d_{model} робить модель більш потужною, але одночасно збільшує параметри всіх шарів самоуваги та проєкцій. Практично, якщо використовується трансформер з 2–4 блоками, $d_{model} = 64$, з внутрішнім розміром прихованого шару у FFN $d_{ff} = 256$ може стати доцільним початковим вибором. При збільшенні значень до 128×512 варто перевіряти на валідації модель на перенавчення.

Функції активації. Нелінійна функція активації визначає вихід нейронів прихованого шару на основі їх лінійної комбінації входів. Активації впливають на здатність мережі моделювати нелінійні залежності, а також на характер поширення градієнтів при навчанні. Вибір активації може суттєво вплинути на швидкість збіжності і кінцеву точність. Класичні сигмоїдальні функції сигмоїда (3.19) та гіперболічний тангенс (3.20) мають обмежений діапазон виходу і схильність до насичення, при великих значеннях x їхня похідна прямує до нуля, що викликає проблему згасання градієнта у глибоких шарах.

$$\sigma(x) = \frac{1}{1+e^{-x}}, \text{ значення в інтервалі } [0,1], \quad (3.19)$$

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}, \text{ значення в інтервалі } [-1,1], \quad (3.20)$$

Натомість кусочно-лінійні функції типу ReLU (Rectified Linear Unit) (3.21) не насичуються для $x > 0$, зберігаючи стабільний градієнт та сприяють швидшому та надійнішому навчанню глибоких мереж.

$$ReLU(x) = \max(0, x), \quad (3.21)$$

MLP. У багатошаровому перцептроні вибір функції активації особливо важливий для прихованих шарів. В прогнозуванні часових рядів MLP з ReLU забезпечують високу гнучкість, моделюючи нелінійні патерни швидше і стійкіше.

LSTM. В архітектурі LSTM функції активації визначені конструкцією самої LSTM-комірки (рис. 3.13). Сигмоїдні функції у воротах обмежують значення між 0 і 1, тим самим виконуючи роль вимикачів, що визначають, яку частку попереднього стану зберегти, скільки нового кандидата записати, і яку частку стану видати на вихід. Гіперболічний тангенс застосовується для обчислення нового кандидата та для виходу, оскільки тангенс видає як позитивні, так і негативні значення. Таким чином, для LSTM-архітектури функції активації фіксовані і є частиною архітектури.

Transformer. Дана архітектура включає декілька типів активацій. В багатоголових механізмах уваги використовуються лише лінійні операції, а основна нелінійність тут забезпечується *softmax*-функцією при обчисленні ваг уваги. Для вектора $x = [x_1, x_2, \dots, x_n]$:

$$Softmax(x_i) = \frac{e^{x_i}}{\sum_{j=1}^n e^{x_j}}, \quad (3.22)$$

Також, кожен блок містить підшар FFN, що використовує активацію ReLU.

Learning Rate. Швидкість навчання η – один з найважливіших гіперпараметрів градієнтного навчання нейронних мереж [183]. Він визначає, на скільки змінюються ваги моделі при кожному кроці під час проходження оптимізації. Надто велике значення η призводить до стрибків у просторі параметрів – модель під час навчання може «перестрибувати» мінімум помилки і навіть збільшувати тренувальну помилку. Навпаки, надто малий η уповільнює збіжність і може призвести до «застрягання» на високому значенні помилки, якщо модель застрягне у плоскому регіоні ландшафту помилки [184] (рис. 3.17).




Рисунок – 3.17. Залежність функції втрат від швидкості навчання (адаптовано [184])

Вибір learning rate сильно впливає на ефективну ємність моделі, оскільки визначає, наскільки добре мінімізується функція втрат. Як зазначають автори у [183] зазначили, що «швидкість навчання є, мабуть, найважливішим гіперпараметром; якщо у вас є час налаштувати лише один, налаштовуйте саме її».

MLP/LSTM. Підхід до вибору η для архітектур MLP і LSTM подібний, оскільки вони часто тренуються схожими методами. Значення learning rate залежить від вибраного оптимізатора. Для класичного градієнтного спуску (SGD) використовується η у діапазоні 0.01-0.1. Сучасні адаптивні методи, такі як Adam, RMSprop, зазвичай потребують менших базових значень. Для MLP значення $\eta = 0.001$ зазвичай забезпечує швидку збіжність. LSTM, через свою

рекурентну природу, може бути більш чутливою до вибору. Занадто велике значення η викличе вибух градієнтів у часі, надто мале зробить навчання дуже повільним. Рекомендація по діапазону значень від 10^{-3} до 10^{-4} .

Transformer. Для цього типу архітектури потребує більш обережного підходу до налаштування η через велику кількість шарів і відсутність рекурентності. У оригінальній роботі [175] використовувався оптимізатор Adam з таким алгоритмом змін: learning rate поступово збільшувався за 4000 кроків, а далі спадав за формулою $1/\sqrt{n}$, де n – номер кроку ітерації. Загалом, типові базові значення η для Transformer знаходяться в діапазоні від 10^{-4} до 5×10^{-4} , часто застосовують поступове зростання (теплий старт) і наступне згасання.

Розмір міні-пакету (batch size). Розмір міні-пакету визначає, скільки навчальних прикладів обробляється моделлю за один крок оновлення ваг. Це компроміс між точністю оцінки градієнта і шумом, а також між швидкістю обчислень і використанням пам'яті. Автори у [185] відзначили, що при збільшенні розміру міні-пакету до дуже великого (кілька тисяч) нейромережі схильні втрачати узагальнюючу здатність – модель показує меншу помилку на тренуванні, але вищу на тесті. На практиці вибирають розмір партії, який відповідає пам'яті графічного процесора. Варто зазначити, що розмір міні-пакету тісно взаємодіє зі швидкістю навчання. Є емпіричне правило, що при збільшенні пакету у k разів, бажано пропорційно збільшити η для збереження темпу збіжності

MLP/LSTM. В задачах прогнозування часових рядів розмір пакету залежить також від структури даних. Загальна рекомендація – використовувати степеневі значення (16, 32, 64, 128), оскільки вони оптимізовані для обчислень на GPU. Для MLP варто обрати розмір 16 або 32. У алгоритмі LSTM додається особливість: оскільки послідовності мають різну довжину, рекомендовано використати маскування, в одному пакеті можна скласти кілька серій, доповнених паддінгом.

Transformer. Для трансформерів вибір batch size теж важливий, але обмеження частіше обмежуються розміром пам'яті. Завдяки розподіленому обчисленню, доцільно використати розмір 64.

Ймовірність виключення (dropout rate). Виключення – це метод регуляризації нейромереж, який полягає в тому, щоб під час навчання випадково «вимикати» виходи окремих нейронів, разом з їхніми зв'язками, з заданою ймовірністю [186]. Dropout суттєво зменшує перенавчання і покращує здатність моделі працювати з новими даними, оскільки модель не може спиратися на точну комбінацію певних нейронів, бо в будь-який момент деякі з них можуть випасти. Таким чином, мережа змушена навчитися більш стійким, розподіленим ознакам [187].

MLP. Виключення в алгоритмі MLP найчастіше застосовується до виходів прихованих шарів. В сучасних застосуваннях часто використовують помірні значення в межах 0.1- 0.2, тобто кожен нейрон прихованого шару має 10-20% шанс бути обнуленим при кожному проході тренування.

LSTM. Рекурентні нейронні мережі потребують особливої уваги щодо dropout. Помилково застосований dropout до виходів LSTM на кожному кроці може руйнувати часову динаміку. Одним з поширених підходів є відсікання неповторюваних з'єднань між шарами мережі, або з'єднань «вхід-прихований» і «прихований-вихід» в межах кожної комірки LSTM [188]. Типовий діапазон для алгоритму LSTM: 0.1–0.3 на входах, 0.1–0.2 на рекурентних зв'язках [187].

Transformer. Велика кількість параметрів у Transformer-моделях зумовлює високу схильність до перенавчання, тому для забезпечення стабільного навчання та покращення узагальнення зазвичай застосовується потужна регуляризація. Виключення застосовується у трансформаторах у декількох точках: після кожного шару самоуваги, після внутрішнього FF шару, на вході до моделі, опційно в механізмі уваги. Автори у [189] наводять значення dropout = 0.1 на всіх рівнях, як таке, що дозволяло отримати оптимальні результати в перших моделях Transformers. Загалом,

трансформери зазвичай тренуються з невеликим виключенням 0.1-0.2. Це пов'язано з тим, що вони самі по собі містять шар нормалізації і багатоголові механізми, які досить стійкі до перенавчання, якщо даних багато.

Кількість голів самоуваги (multi-head attention heads). Цей гіперпараметр характерний тільки для архітектури Transformer. Як вже зазначалося вище бажано синхронізувати кількість голів h з розмірністю простору моделі d_{model} . Бажано, щоб d_{model} ділилося на h без залишку, і щоб розмір кожної голови не був надто малим чи надто великим. Історично склалося співвідношення $d_{model} / h = 64$. Рекомендовано діапазон 4-8 голів для більшості випадків.

Нижче представлено зведену таблицю рекомендованих діапазонів значень ключових гіперпараметрів для MLP, LSTM) та Transformer.

Таблиця 3.8. Рекомендовані діапазони гіперпараметрів для MLP, LSTM та Transformer

Гіперпараметр	MLP	LSTM	Transformer
Кількість шарів	2-3	1-3	2-4
Розмір прихованого шару	128-256	64-128	64-128
Функції активації	ReLU для прихованих шарів, лінійна для виходу	σ і \tanh вбудовано, лінійна для виходу	ReLU для FFN, лінійна для виходу
Швидкість навчання η	Оптимізатор Adam, початково 10^{-3}	Оптимізатор Adam, $10^{-3} - 10^{-4}$	Оптимізатор Adam, 10^{-4} до 5×10^{-4} + warmup
Розмір batch	16-32	8-32 +padding	64
Dropout rate	0.1-0.2	0.1-0.3 на входах, 0.1-0.3 на рекурентах	0.1-0.2
Кількість голів h	—	—	4-8

3.5.3. Налаштування гіперпараметрів ГА

Для успішного застосування генетичного алгоритму потрібно врахувати низку параметрів та зробити дизайн-рішення, від яких залежить ефективність методу. Налаштування генетичного алгоритму часто розглядають як гіперпараметри, які добираються експериментально під конкретну задачу [190]. Також існують різні реалізації та розширення базового алгоритму.

Розмір популяції. Вибір розміру популяції впливає на баланс між різноманітністю рішень і швидкістю роботи алгоритму. Надто мала популяція може призвести до передчасної збіжності, більша популяція забезпечує ширше охоплення простору пошуку і наближає алгоритм до глобального оптимуму. З іншого боку, надто великий розмір популяції значно збільшує обчислювальні витрати. Зазвичай добирається по експериментально - від кількох десятків до кількох сотень індивідів, залежно від складності проблеми [191].

Ймовірність схрещування. Типове значення P_c близьке до 0.8-0.9, оскільки кросовер є головним механізмом комбінування та пошуку нових перспективних рішень [192]. Висока ймовірність схрещування сприяє швидкому комбінуванню ознак різних рішень, однак надто велике значення P_c може призвести до «застрягання» в локальному оптимумі. При застосуванні рівномірного кросоверу рекомендовано зменшувати P_c [193].

Ймовірність мутації. Значення P_m – типowo це 1-5% [194]. Замалий P_m призводить до локального оптимуму без можливості вирватись з нього. З іншого боку, високий рівень мутації перетворює пошук на майже випадковий.

Метод відбору батьків. Різні стратегії селекції визначають, які саме індивіди будуть обрані для розмноження. Найпопулярнішим є пропорційний відбір або метод рулетки. Цей метод простий, але має випадковий характер: дуже слабкі рішення все ж мають невеликий шанс бути обраними, а найкращі – не гарантовано проходять далі [193]. Турнірний відбір, коли випадково вибирається група з K індивідів і з них як батько береться найпридатніший. Чим більше K , тим сильніший тиск відбору. Метод є простим і ресурсно

дешевим. Правильний вибір оператора відбору допомагає забезпечити баланс між збереженням кращих рішень і підтримкою генетичного різноманіття.

Оператор мутації. Окрім вибору ймовірності мутації P_m , потрібно визначити тип мутації, тобто спосіб зміни генів. У простих випадках достатньо використати битову мутацію – випадковий фліп бітів. У завданнях з перестановками слід застосовувати наступні мутації: swap – обмін місцями двох випадково вибраних елементів у послідовності; inversion – обрану підпослідовність генів розвернути у зворотний бік; scramble – випадково перемішати елементи в обраній підпослідовності [195].

Критерії зупинки. Умови, за яких виконання алгоритму завершується. Найчастіше використовується обмеження на максимальну кількість поколінь, після досягнення якого алгоритм припиняється. Також може бути задано порогове значення пристосованості. Також, як вже зазначалося вище, є доцільним стежити за динамікою поліпшення: якщо протягом останніх K поколінь не відбулося помітного підвищення найкращого значення пристосованості, вважається, що алгоритм збігся, і його можна зупинити. Правильне налаштування перелічених параметрів є критичним для успішної роботи ГА [151]. В таблиці 3.9 надано рекомендації щодо використання діапазонів гіперпараметрів.

Таблиця 3.9. Рекомендовані гіперпараметри генетичного алгоритму для задачі оптимізації кута входу космічного об'єкта

Гіперпараметр	Рекомендований діапазон / значення
Розмір популяції	50 - 150
Ймовірність схрещування P_c	0.8 - 0.9
Схрещування	10 - 30
Ймовірність мутації P_m	0.02 - 0.05
Мутація, Polynomial η	15 - 25
Метод селекції	Турнірний відбір, $K = 3 - 5$
Елітизм	1 - 2 % популяції
Критерій зупинки	Більше 50 та/або «без поліпшення 10 генерацій»

Висновки до розділу 3

Розділ 3 системно обґрунтовує увесь ланцюжок підготовки даних і вибору моделей, який надалі забезпечує достовірне та швидке прогнозування теплового навантаження під час входу космічних об'єктів у атмосферу.

Формування репрезентативного датасету. З каталогу ESA DISCOS проаналізовано ≈ 34 тис. записів; шляхом очищення пропусків, відсікання статистичних викидів та застосування фізично вмотивованих обмежень (маса 100 - 1500 кг, $xSectAvg \leq 20$ м², унікальність форми) сформовано компактну вибірку із 1 995 об'єктів, що охоплює > 83 % найпоширеніших геометрій і має 100 % заповненості ключових полів. На базі цієї вибірки, варіюючи кут входу та швидкість, створено 100 000 комбінацій початкових умов, які становлять фінальний тренувальний і валідаційний набір.

Інженерія ознак та аеродинамічні параметри. Для кожного об'єкта обчислено коефіцієнт опору C_d та радіус точки застою R_n , що стандартизує фізичні характеристики та уніфікує подальше моделювання. Кореляційний аналіз Пірсона засвідчив низьку мультиколінеарність між геометричними та кінематичними ознаками, що сприятиме стабільності градієнтного навчання.

Підготовка машинного ядра. Розглянуто три архітектури глибинного навчання—MLP, LSTM і Transformer. Для кожної моделі наведено обґрунтовані діапазони гіперпараметрів, що забезпечують баланс між точністю й обчислювальною ефективністю при помірних обсягах даних.

Інтеграція з генетичним алгоритмом. Запропоновано набір рекомендацій із налаштування популяційних параметрів, що гарантує стійку збіжність при оптимізації кута входу на основі швидких ML-оцінок теплового профілю.

Створений датасет є статистично збалансованим, фізично релевантним і масштабованим; обрані моделі та їхні гіперпараметри дозволяють поєднати високу точність оцінок $q(t)$ з низькими витратами часу, а інтеграція з

еволюційним пошуком відкриває можливість до оперативної оптимізації траєкторій для мінімізації уламкових ризиків.

Таким чином, розділ 3 формує повний методологічний фундамент – від якісних вхідних даних до адаптивного математичного інструментарію – для подальших експериментів і практичних застосувань у дисертаційній роботі.

РОЗДІЛ 4. ПРАКТИЧНА РЕАЛІЗАЦІЯ

4.1. Процес навчання та техніки регуляризації

Навчання всіх нейромереж виконувалося у середовищі Python 3.10 в Google Colab Pro із апаратним прискоренням на графічних процесорах NVIDIA (T4, L4 або A100). Робочий стек складався з TensorFlow 2.15 / Keras, NumPy, Pandas, scikit-learn та Matplotlib.

Для пошуку гіперпараметрів використовувалася Optuna – відкрита бібліотека Bayesian-based оптимізації.

Обчислення здійснювалися у режимі формату `mixed_float16`, що забезпечує підвищену швидкість обробки даних, а керування зростанням пам'яті GPU гарантувало стабільну роботу при великих `batch_size`.

Вхідні ознаки нормалізувалися за допомогою `StandardScaler` із `scikit-learn`. Для згладжування послідовності $q(t)$ використовувалося логарифмування що сприяє стабільнішому та ефективнішому навчанню нейронної мережі. Датасет ділився у пропорції 80% / 20%.

Для всіх архітектур ваги ініціалізувалися схемою `Glorot-Uniform`; функцією втрат обрано `MSE`, тоді як у ролі метрик моніторингу використовувалися `RMSE` та коефіцієнт детермінації R^2 . Оптимізація проводилася алгоритмом `Adam`.

В рамках регуляризації було застосовано механізм ранньої зупинки `Early Stopping` з контролем `validation loss`, `dropout` та `batch normalization`.

Реалізація ГА здійснена у пакеті `rumoo`, що надає стандартизовані оператори еволюції та зручні критерії зупинки.

Детальний вихідний код, використаний для реалізації моделей і проведення обчислень, подано в додатку Б.

4.2. Результати оптимізації гіперпараметрів машинного навчання

Як було зазначено в розділі 3, від правильного підбору вхідних гіперпараметрів залежать здатність моделі ефективно навчатися та коректно узагальнювати закономірності у даних. На жаль, їх вибір не є тривіальним, і часто вони не можуть бути інтерпретовані. Тому для того, щоб отримати відмінні результати від моделей глибокого навчання, можна використовувати алгоритми оптимізації, які дозволяють скоротити обчислювальний час, необхідний для пошуку найкращих значень гіперпараметрів.

У роботі здійснено автоматизоване налаштування гіперпараметрів методом послідовного байєсового пошуку з використанням алгоритму Tree-structured Parzen Estimator (TPE). TPE будує непараметричні апроксимації умовних розподілів «успішних» та «неуспішних» конфігурацій і на кожному кроці обирає наступну точку, що максимізує очікуване поліпшення валідаційної похибки. Для скорочення часу експерименту застосовано раннє усікання спроб за медіанним критерієм: якщо поточна модель після кількох епох відстає від медіанного рівня попередніх запусків, навчання цієї конфігурації достроково зупиняється. Рекомендовані гіперпараметри для оптимізації наведені у таблиці 3.7.

Щоб представити результати цього процесу, проаналізовано значення валідаційних втрат кожного випробування наприкінці його відносного навчання, як показано на рис. 4.1, щоб зрозуміти, чи успішно байєсовий метод знайшов простір з оптимальними результатами. Дійсно, це є основною відмінністю від методу випадкового пошуку, де кожна комбінація вибирається випадково.

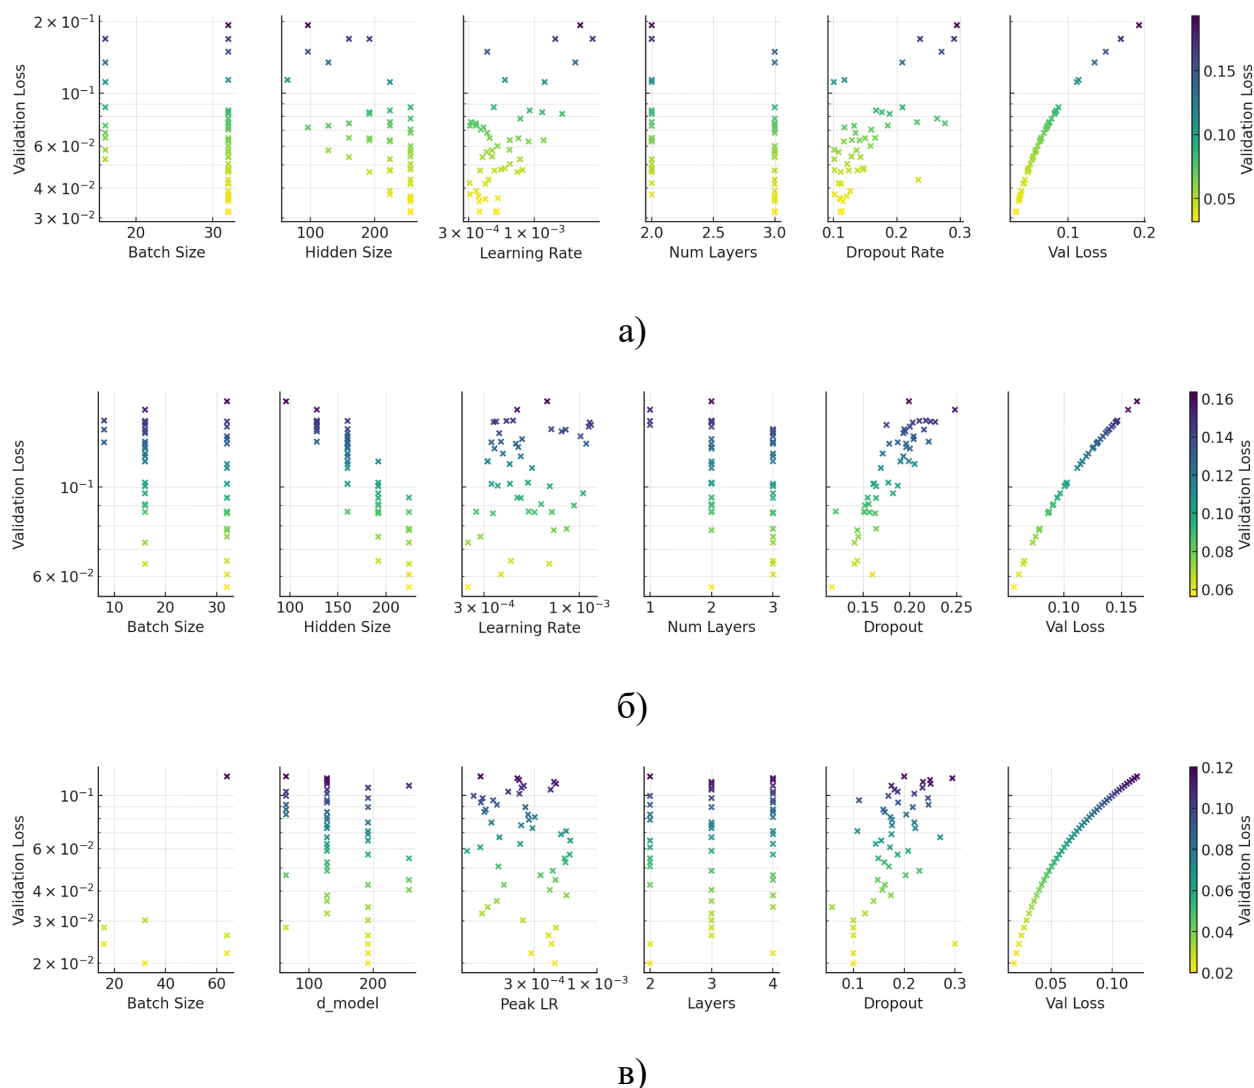




Рисунок 4.1. – Представлення значень втрат валідації (validation losses) кожного випробування в кінці відповідного навчання у вигляді функції гіперпараметрів простору пошуку, де колір пов'язаний з втратою валідації: а) алгоритм MLP, б) алгоритм LSTM, в) алгоритм Transformer


З рисунків 4.1 можна чітко бачити, що dropout у проміжку 0.1-0.15 є найкращим вибором для всіх трьох алгоритмів. Наявність концентрації точок для learning rate для алгоритмів MLP і LSTM та peak learning rate для архітектури Transformer вказує на те, що алгоритм пошуку знайшов оптимальний простір для цього параметру рівним $3 - 5 \times 10^{-4}$. Для розуміння впливу інших гіперпараметрів на продуктивність моделі доцільно розглянути графік паралельних координат (рис 4.2).



a)



б)



в)

Рисунок 4.2. – Візуалізація вибраних комбінацій гіперпараметрів у форматі паралельних координат, де кожна лінія відповідає окремому випробуванню, а колір відображає рівень валідаційної втрати: а) алгоритм MLP, б) алгоритм LSTM, в) алгоритм Transformer

Для алгоритму MLP пошукове дослідження продемонструвало стабільну залежність якості узгодження validation loss від розміру прихованого шару та глибини мережі. Зі збільшенням прихованого шару до 256 елементів середня втрата зменшується майже лінійно; подальше розширення діапазону не дає додаткового виграшу, але істотно збільшує обчислювальну складність. Найнижчі втрати зафіксовано для трьох повнозв'язних шарів, тоді як двошарова конфігурація в середньому демонструє на 17–20 % більшу похибку. Перевагу має batch size = 32, що поєднує стабільність градієнтної оцінки та прийнятні вимоги до пам'яті.

Для LSTM-архітектури домінує розмір прихованого стану: при зростанні hidden від 96 до 224 елементів медіанна втрата зменшилася майже удвічі. Найкращі спроби належать конфігураціям з двома-трьома LSTM-шарами. Третій шар знижує дисперсію результату на валідації, проте приріст точності щодо двошарової моделі невеликий. Найменшу втрату зафіксовано при batch size = 32.

Параметричний аналіз для Transformer показав, що чутливість якості передусім визначається співвідношенням $d_{model} \leftrightarrow h$ d_{model} та розміром внутрішнього FF-блоку d_{ff} . Локальний мінімум val loss досягнуто при $d_{model} = 192$ та $h = 8$ у комбінації з $d_{ff} \approx 6 - 8 \times d_{model}$. Збільшення числа шарів понад два не дало приросту точності на заданій вибірці. Вплив розміру пакету в межах 16–64 не мав статистично значущої різниці, тому batch size = 32 обрано як баланс між швидкістю та пам'яттю.

У таблиці 4.1 наведено оптимізовані значення гіперпараметрів для кінцевого етапу донавчання моделей MLP, LSTM та Transformer з метою забезпечення збалансованого співвідношення між точною апроксимацією даних і ефективністю обчислень.

Таблиця. 4.1. Рекомендовані гіперпараметри для остаточного донавчання моделей MLP, LSTM та Transformer

Гіперпараметр	MLP	LSTM	Transformer
Розмір прихованого шару	hidden_size = 256	hidden = 224	d_model = 192
Кількість шарів	num_layers = 3	n_layers = 2–3	layers = 2
Dropout	dropout = 0.11	drop_in \approx 0.12	dropout = 0.10
Навчальна швидкість	learning_rate \approx 5×10^{-4}	learning_rate \approx 2.5×10^{-4}	peak_lr $\approx 4.5 \times 10^{-4}$ (з warmup_steps \approx 700)
Розмір batch	batch_size = 32	batch_size = 32	batch_size = 32
Кількість голів	—	—	n_heads = 8
Розмір внутрішнього шару FF	—	—	d_ff = $6 \times d_model \approx$ 1152

4.3. Результати фінального навчання алгоритмів MLP, LSTM і Transformer

Перш ніж представити результати роботи моделей глибокого навчання на валідаційному наборі, слід сказати про метрики оцінки точності моделей – формалізовані кількісні показники, що вимірюють ступінь відповідності прогнозів моделі реальним значенням для об’єктивної кількісної оцінки її продуктивності.

Як метрику оцінки точності моделі використано показник R^2 , або коефіцієнт детермінації. Оцінка R^2 відображає частку дисперсії залежної змінної, яка пояснюється незалежними змінними за допомогою регресії. Чим ближче значення до одиниці, тим точніший результат прогнозування. Коефіцієнт R^2 розраховується наступним чином:

$$R^2 = 1 - \frac{SS_{res}}{SS_{tot}} = 1 - \frac{\sum_i (y_i - \hat{y}_i)^2}{\sum_i (y_i - \bar{y}_i)^2}, \quad (4.1)$$

де SS_{res} – сума квадратів різниць між фактичним і прогнозним значеннями, а SS_{tot} – це сума квадратів різниць між цільовим значенням і середнім значенням залежної змінної, y_i – цільове значення залежної змінної, \hat{y}_i – прогнозне значення передбачене моделлю, \bar{y}_i – середнє значення.

Слід зауважити що високе значення R^2 може бути недостатнім для оцінки прогнозу і давати оманливі результати при роботі з невеликими наборами даних. Також коефіцієнт детермінації припускає, що всі змінні в моделі є незалежними, а це не завжди так.

Для більш точного розуміння використано mean absolute percentage error (MAPE), що вимірює середню абсолютну похибку у відсотках, тобто наскільки прогнози моделі відрізняються у відсотках від фактичних даних. MAPE розраховується як:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \cdot 100\%, \quad (4.2)$$

де y_i – реальне значення, \hat{y}_i – передбачене значення моделі, n – кількість спостережень у наборі даних.

Ще однією метрикою додано RMSE — корінь середньоквадратичної похибки:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}, \quad (4.3)$$

Це стандартна метрика, яка обчислює квадратний корінь із середнього значення квадратів різниць між прогнозованими та фактичними значеннями, забезпечуючи посилене покарання за великі відхилення та зберігаючи одиниці вимірювання цільової змінної.

У фінальному експерименті було використано повний набір даних, поділений на train / validation у пропорції 80% / 20%. Для кожної архітектури застосовано оптимізовані гіперпараметри, визначені під час попереднього

Bayesian-пошуку, навчання здійснювалося із раннім зупиненням за критерієм `val_loss`. Порівняльні результати моделювання трьох алгоритмів наведені у таблиці 4.2.

Таблиця 4.2. Результати моделювання алгоритмів MLP, LSTM і Transformer

Алгоритм	Найнижча val loss	RMSE log(q)	R ²	MAPE	Використані ресурси для навчання
MLP	0.0337	0.195	0.923	0.21	Графічний процесор NVIDIA T4, GPU 15g, CPU 22g, час роботи 28 хв.
LSTM	0.0443	0.242	0.887	0.28	Графічний процесор NVIDIA A100, GPU 40g, CPU 83.5g, час роботи 245 хв.
Transformer	0.0285	0.162	0.97	0.12	Графічний процесор NVIDIA L4, GPU 22.5g, CPU 53g, час роботи 160 хв.

Наведені результати демонструють чітку різницю в точності моделей MLP, LSTM і Transformer, а також суттєве розходження в обсязі використаних обчислювальних ресурсів і часу навчання.

Transformer показав найкращу якість апроксимації: найнижче значення валідаційної похибки, найменше значення RMSE на тесті, найвищий коефіцієнт детермінації і найменшу відносну помилку.

Застосування архітектури *LSTM* у цьому контексті не виправдовує витрат ні з точки зору точності, ні з погляду ефективності ресурсів.

Таким чином, для більшості сценаріїв варто використовувати архітектуру *Transformer* з рекомендованими гіперпараметрами. Алгоритм *MLP* — для швидких швидких оцінок або в умовах обмеженого доступу до використання ресурсів.

4.4. Експериментальна валідація моделі Transformer на незалежних даних каталогу DISCOS ESA

У цьому розділі здійснюється зовнішня валідація побудованої Transformer-моделі на незалежних експериментальних даних каталогу DISCOS ESA. Для проведення аналізу відібрано репрезентативну підгрупу з трьох космічних об'єктів, які відрізняються за аеродинамічними, масовими та геометричними характеристиками (див. таблицю 4.3).

Таблиця 4.3. Характеристики репрезентативної підгрупи космічних об'єктів для зовнішньої валідації моделі

Назва поля	Об'єкт 1	Об'єкт 2	Об'єкт 3
id	23462	4068	67928
name	FAISAT	ATS 5	L-14B-res (YF40B-res) (Long March (CZ) 4C)
objectClass	Payload	Payload	Rocket Body
mass, кг	112.9800	429.1400	1000
shape	Oct Cyl + 1 Ant	Cyl	Cyl
xSectAvg, м².	0.5395	3.0920	7.6757
Швидкість, км/с	7.5	8.1	7.9
Кут входу, °	1.3	1.9	2.9

Нижче наведено числові показники точності моделі та візуалізацію порівняння прогнозного й експериментального теплового потоку $q(t)$.

Графічне зіставлення демонструє високу кореляцію між реальними та розрахунковими кривими: модель точно відтворює як фазу монотонного зростання теплового потоку, так і крутий спад після піка, зберігаючи похибку в межах $\pm 10\%$ на всій ділянці інтересу.




Рисунок 4.3. – Порівняння реального та прогнозованого теплового потоку
для об'єкта 1: MAPE – 9.43%, RMSE $\log(q)$ – 0.1736




Рисунок 4.4. – Порівняння реального та прогнозованого теплового потоку
для об'єкта 2: MAPE – 5.22%, RMSE $\log(q)$ – 0.0722




Рисунок 4.5. – Порівняння реального та прогнозованого теплового потоку для об'єкта 3: MAPE – 7.24%, RMSE $\log(q)$ – 0.0337

Таким чином, модель Transformer забезпечує фізично достовірний прогноз і може бути застосована для оперативної оцінки теплового потоку $q(t)$ під час генетичної оптимізації теплового навантаження $Q^*(x)$, у критичному інтервалі $0 < t_1 < t_2 \leq \tau$.

4.5. Результати генетичної оптимізації кута входу КО в атмосфері Землі

У попередньому підпункті 4.3 було проведено зовнішню валідацію побудованої Transformer-моделі на незалежних експериментальних даних каталогу DISCOS ESA. Після підтвердження здатності нейромережі точно відтворювати часові профілі теплового потоку $q(t)$ наступним етапом дослідження стало застосування генетичного алгоритму для пошуку оптимального кута входу входу θ у межах $[0^\circ, 3^\circ]$.

При реалізації генетичного алгоритму було взято за основу рекомендації, наведені в таблиці 3.8. Зокрема, параметри популяції, ймовірності схрещування та мутації, а також налаштування турнірної селекції й рівень елітизму було встановлено відповідно до зазначених у таблиці інтервалів. Таким чином, використовувані в експериментах значення

гіперпараметрів повністю узгоджуються з рекомендаціями, що гарантує баланс між різноманітністю рішень і швидкістю збіжності алгоритму.

У ході етапу *очищення даних та інженерії ознак* підпункту 3.1 було проведено описову статистику й виявлено, що: центральний масовий діапазон (близько 40...75 % прикладів у вибірці) припадає на маси приблизно між 400 та 700 кг. Таким чином, для більшості практичних задач, пов'язаних із оцінкою ймовірності згоряння у щільних шарах атмосфери логічно обмежитися діапазоном мас від 400 до 700 кг.

В цьому було обрано два інтервали $xSectAvg$ [1.6-3.2] м² та [3.4-5.0] м², що забезпечують достатню кількість об'єктів у кожній категорії для достовірного порівняння інтегральних теплових навантажень. Виключено крайні значення $xSectAvg < 1.6$ м² та > 5.0 м² через малу кількість екземплярів, що робить їхній внесок у загальний аналіз незначним і не репрезентативним.

У межах зазначених діапазонів було сформовано матриці «маса-ефективна площа» та для кожної комірки за допомогою генетичного алгоритму визначено:

- оптимальний кут θ входу КО в атмосферу Землі, що максимізує інтегральне теплове навантаження $Q^*(x)$.
- відповідне значення інтегрального теплового навантаження $Q^*(x)$.

Для наочності результати зведено у теплові карти, де тон шкали відповідає величині показника, а всередині комірок надруковано чисельні значення. Використання такої візуалізації дозволяє наочно оцінити залежність найкращого кута входу та досягнутого інтегрального теплового навантаження від розміру та аеродинамічних параметрів об'єкта.




Рисунок 4.6. – Теплова карта оптимального кута входу θ_{opt} ; діапазон $xSectAvg$ [1.6-3.2] m^2




Рисунок 4.7. – Теплова карта інтегрального теплового навантаження Q^* ; діапазон $xSectAvg$ [1.6-3.2] m^2




Рисунок 4.8. – Теплова карта оптимального кута входу θ_{opt} ; діапазон xSectAvg [3.4-5.0] м²




Рисунок 4.9. – Теплова карта інтегрального теплового навантаження Q^* ; діапазон xSectAvg [3.4-5.0] м²

На рисунках 4.6–4.9, що відображають теплові карти оптимального кута входу θ_{opt} КО та відповідного інтегрального теплового навантаження для двох діапазонів ефективної площі, прослідковуються такі закономірності:

Еволюція θ_{opt} . Для об'єктів [1.6–3.2] м² оптимальний кут *зростає* разом із масою: від $\approx 0.7^\circ$ при 400 кг до $\approx 1.35^\circ$ при 700 кг. Більш крутий вхід дозволяє масивнішому апаратові протрапити у щільні шари атмосфери швидше, генеруючи вищі пікові значення q_{max} і, як наслідок, більший інтеграл тепла. Для інтервалу [3.4–5.0] м² картина дзеркальна: θ_{opt} *зменшується* із $2.1\text{--}2.2^\circ \approx 525$ кг до $\approx 0.6^\circ \approx 675$ кг. Значна площа вже створює підвищене аеродинамічне гальмування; аби накопичити максимальне тепло, траєкторію, навпаки, варто збільшити, подовживши фазу інтенсивного нагріву.

Поведінка інтегрального Q^ .* В обох діапазонах спостерігається монотонне зростання Q^* з масою, однак вплив площі протилежний:

- для малих $xSectAvg$ розширення площі підвищує тепловиділення до $\approx +25\%$;
- для великих $xSectAvg$ подальше зростання площі дає лише невеликий приріст Q^* , або навіть зменшення, адже КО інтенсивно гальмується ще на великих висотах.

Таким чином:

для мас КО 450–600 кг, площі 1.8–2.6 м², оптимальним кутом входу θ_{opt} є значення $1.1\text{--}1.3^\circ$, очікуване $Q^* \approx 9 \times 10^8$ Дж/м²;

для мас 550–650 кг, площі 4.2–4.8 м²: $\theta_{opt} \approx 0.9\text{--}1.1^\circ$, $Q^* \approx 6.5 \times 10^8$ Дж/м².

Висновки до розділу 4

У розділі 4 реалізовано повний практичний цикл – від автоматизованого налаштування моделей глибокого навчання до їх інтеграції у генетичну схему оптимізації траєкторії – що підтверджує життєздатність запропонованого гібридного підходу.

Оптимізація гіперпараметрів. Послідовний баєсовий пошук TPE із раннім усіканням конфігурацій забезпечив систематичний добір оптимальних гіперпараметрів для алгоритмів MLP, LSTM та Transformer.

Фінальне навчання моделей. При застосуванні оптимізованих налаштувань Transformer досяг найкращих результатів в прогнозуванні теплового навантаження та був обраний а був обраний референтною прогнозувальною моделлю для інтеграції в гібридний контур «нейромережа – генетичний алгоритм» під час подальшої оптимізації траєкторії за тепловим чинником.

Зовнішня валідація. Перевірка Transformer-моделі на незалежних даних трьох ESA-об'єктів із масою 113–1000 кг та різною аеродинамікою показала високу відтворюваність профілів $q(t)$, що підтверджує добру здатність мережі узагальнювати позавибіркові сценарії.

Генетична оптимізація кута входу θ . Залучивши швидку оцінку $q(t)$ моделлю Transformer, генетичний алгоритм визначив оптимальний кут θ_{opt} у масовому діапазоні 400–700 кг та двох піддіапазонах ефективної площі. Визначені оптимальні кути входу дозволяють максимізувати інтегральне теплове навантаження Q^* , що в свою чергу забезпечує досягнення режиму термічного руйнування.

У підсумку, розділ 4 демонструє ефективність поєднання методів машинного навчання та еволюційної оптимізації:

- баєсовий пошук забезпечує обґрунтовані гіперпараметри;
- архітектура Transformer гарантує найкраще співвідношення точність-витрати;

- валідація підтверджує фізичну достовірність моделі;
- генетичний алгоритм, працюючи у парі з нейромережею, оперативно визначає кут входу, що максимізує Q^* для заданих масово-геометричних характеристик.

Отже, описана практична реалізація є готовою технологічною основою для інженерного проєктування та сценарної оцінки безпечного знищення космічних об'єктів у щільних шарах атмосфери.

ВИСНОВКИ

У дисертаційній роботі було реалізовано інтегрований підхід до задачі керованого відведення космічних об'єктів з орбіти з урахуванням теплового чинника. Поставлена мета – розробити методологію прогнозування максимальних теплових навантажень та вибору траєкторних параметрів руху КО на основі поєднання машинного навчання й генетичного алгоритму – було повністю досягнуто шляхом виконання таких завдань.

- на основі критичного аналізу існуючих математичних моделей та інженерних методик прогнозування аеродинамічного нагріву КО сформовано ґрунтовне розуміння переваг і обмежень класичних алгоритмів. показано що машинне навчання може буде ефективно використано для прогнозування теплових навантажень космічного об'єкту під час руху в атмосфері Землі;

- виконано багатоступеневу процедуру підготовки даних із каталогу ESA DISCOS, що включала очищення, нормалізацію, виявлення й усунення статистичних та геометричних викидів, а також генерацію додаткових ознак. У результаті отримано високозбалансовану множину прикладів, яка адекватно відображає різноманітність фізичних характеристик КО;

- для побудови швидкого й точного апроксиматора теплового потоку $q(t)$ обрано три архітектури та здійснено баєсову оптимізацію їхніх гіперпараметрів. Порівняльний аналіз показав, що Transformer-модель є найефективнішою за показниками точності R^2 , MAPE, RMSE та ресурсної ефективності, що дозволило застосувати її в якості сурогата у процесі оптимізації.

- реалізовано генетичний алгоритм пошуку оптимального кута входу θ з використанням прогнозу теплового потоку нейромережею як функції пристосованості, що забезпечило для різних масово-геометричних конфігурацій КО стабільне й ефективне знаходження кута, який максимізує інтегральну теплоту Q^* на критичному інтервалі.

Одержано нові наукові результати, а саме:

- розроблено модель машинного навчання для оцінки теплових навантажень на об'єкт, що рухається в атмосфері Землі, яка вперше забезпечує комплексний аналіз впливу траєкторних параметрів на формування теплових потоків у атмосферних ділянках траєкторій.
- запроваджено гібридну методику, що поєднує алгоритми машинного навчання для високоточних прогнозів характеристик теплового потоку з генетичним алгоритмом для оптимізації параметрів входження об'єкта в атмосферу.

Розроблена методологія розрахунку та оптимізації траєкторій сходження космічних об'єктів з навколоземної орбіти з урахуванням теплового чинника.

Запропоновану методику доцільно застосовувати при проектуванні місій активного виведення космічних відходів для обґрунтування вибору параметрів входу в атмосферу, які забезпечують повне згоряння об'єкта без утворення небезпечних фрагментів, здатних досягти поверхні Землі або залишитися на орбіті.

Здобуті результати формують основу для розробки автоматизованих програмних комплексів, що інтегрують алгоритми оптимізації, методи машинного навчання та моделі теплової деструкції з метою забезпечення підтримки прийняття рішень у реальному часі під час керування сходженням космічних тіл.

Крім того, розроблена методика може бути використана в освітньому процесі та підготовці фахівців як приклад міждисциплінарної задачі, що інтегрує елементи космічної механіки, термодинаміки, оптимізації та штучного інтелекту.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. ESA's annual space environment report. ESA Space Debris Office, 2023. P 124. URL: https://www.sdo.esoc.esa.int/environment_report/Space_Environment_Report_latest.pdf.
2. URL: <https://www.space-track.org>.
3. Alpatov A. P. Space debris: the aspects of the problem. Technical mechanics. 2018. Vol. 2018, no. 1. P. 30-47. URL: <https://doi.org/10.15407/itm2018.01.030>
4. Kessler D. J., Cour-Palais B. G. Collision frequency of artificial satellites: the creation of a debris belt. *Journal of geophysical research*. 1978. Vol. 83, A6. P. 2637. URL: <https://doi.org/10.1029/ja083ia06p02637>.
5. <https://discosweb.esoc.esa.int/>
6. Adilov N., Alexander P. J., Cunningham B. M. The economics of orbital debris generation, accumulation, mitigation, and remediation. *Journal of space safety engineering*. 2020. Vol. 7, no. 3. P. 447–450. URL: <https://doi.org/10.1016/j.jsse.2020.07.016>.
7. Space debris mitigation guidelines of the committee on the peaceful uses of outer space. United Nations Office for Outer Space Affairs. https://www.unoosa.org/pdf/publications/st_space_49E.pdf.
8. Alpatov A. P., S.V. Khoroshylov S. V., Maslova A. I. Contactless de-orbiting of space debris by the ion beam. *Dynamics and Control*. Akademperiodyka, 2019. URL: <https://doi.org/10.15407/akademperiodyka.383.170> .
9. Ю., Ємець В.В., Пашков А.В. Системи відводу космічних об'єктів з низьких навколоземних орбіт. Дніпро: ЛПРА, 2019. 218 с.
10. Just in time collision avoidance – A review / C. Bonnal et al. *Acta astronautica*. 2020. Vol. 170. P. 637–651. URL: <https://doi.org/10.1016/j.actaastro.2020.02.016> .

11. Bigdeli M., Srivastava R., Scaraggi M. Mechanics of space debris removal: a review. *Aerospace*. 2025. Vol. 12, no. 4. P. 277.
URL: <https://doi.org/10.3390/aerospace12040277>.
12. An overview of methods and technical means of space debris removal from low earth orbits / A. O. Abaturov et al. *System design and analysis of aerospace technique characteristics*. 2022. Vol. 31, no. 2. P. 3–13.
URL: <https://doi.org/10.15421/472209>.
13. Mark C. P., Kamath S. Review of active space debris removal methods. *Space policy*. 2019. Vol. 47. P. 194–206.
URL: <https://doi.org/10.1016/j.spacepol.2018.12.005>.
14. Shen S., Jin X., Hao C. Cleaning space debris with a space-based laser system. *Chinese journal of aeronautics*. 2014. Vol. 27, no. 4. P. 805–811.
URL: <https://doi.org/10.1016/j.cja.2014.05.002>.
15. LightForce photon-pressure collision avoidance: efficiency analysis in the current debris environment and long-term simulation perspective / F. Yang Yang et al. *Acta astronautica*. 2016. Vol. 126. P. 411–423.
URL: <https://doi.org/10.1016/j.actaastro.2016.04.032>.
16. Alpatov A., Khoroshylov S., Bombardelli C. Relative control of an ion beam shepherd satellite using the impulse compensation thruster. *Acta astronautica*. 2018. Vol. 151. P. 543–554.
URL: <https://doi.org/10.1016/j.actaastro.2018.06.056>.
17. Ledkov A. S., Aslanov V. S. Active space debris removal by ion multi-beam shepherd spacecraft. *Acta astronautica*. 2023. Vol. 205. P. 247–257.
URL: <https://doi.org/10.1016/j.actaastro.2023.02.003>.
18. Capture dynamics and control of a flexible net for space debris removal / M. Ru et al. *Aerospace*. 2022. Vol. 9, no. 6. P. 299.
URL: <https://doi.org/10.3390/aerospace9060299>.
19. Dudziak R., Tuttle S., Barraclough S. Harpoon technology development for the active removal of space debris. *Advances in space research*. 2015. Vol. 56, no. 3. P. 509–527. URL: <https://doi.org/10.1016/j.asr.2015.04.012>.

- 20.J.R. Sanmartin, M. Martínez-Sanchez, E. Ahedo. Bare wire anodes for electro-dynamic tethers, *J. Propul. Power*. 1993. Vol. 9, no. 3. P.353–360. URL: <https://doi.org/10.2514/3.23629>.
- 21.Guang Z., Jing-rui Z. Space tether net system for debris capture and removal. *2012 4th international conference on intelligent human-machine systems and cybernetics (IHMSC)*, Nanchang, China, 26–27 August 2012. 2012. URL: <https://doi.org/10.1109/ihmsc.2012.71> .
- 22.Rosengren, Aaron J. Passive Debris Removal using Orbital Resonances. *The Advanced Maui Optical and Space Surveillance Technologies Conference*, Wailea, Maui, Hawaii, September 11-14, 2018. 2018.
- 23.Research and Development of Orbital Debris Removal using Low Density Material / M. TASAKI et al. *Journal of the Japan Society for Aeronautical and Space Sciences*. 2016. Vol. 49, no. 1.
- 24.Romagnoli D., Theil S. De-orbiting satellites in LEO using solar sails. *Journal of aerospace engineering, sciences and applications*. 2012. Vol. 4, no. 2. P. 49–59. URL: <https://doi.org/10.7446/jaesa.0402.05> .
- 25.Ionospheric drag for accelerated deorbit from upper low earth orbit / B. G. A. Smith et al. *Acta astronautica*. 2020. Vol. 176. P. 520–530. URL: <https://doi.org/10.1016/j.actaastro.2020.07.007> .
- 26.RemoveDEBRIS: an in-orbit demonstration of technologies for the removal of space debris / G. S. Aglietti et al. *The aeronautical journal*. 2019. Vol. 124, no. 1271. P. 1–23. URL: <https://doi.org/10.1017/aer.2019.136> .
- 27.Prospects for the use of the combined method for deorbiting of large-scale space debris from near-Earth space / M. M. Dron et al. *Kosmìčna nauka i tehnologiâ*. 2019. Vol. 25, no. 6. P. 61–69. URL: <https://doi.org/10.15407/knit2019.06.061> .
- 28.Park S.-H., Kim H.-D., Park G. Orbit, orbital lifetime, and reentry survivability estimation for orbiting objects. *Advances in space research*. 2018. Vol. 62, no. 11. P. 3012–3032. URL: <https://doi.org/10.1016/j.asr.2018.08.016>.

29. Prospects for the use of the combined method for deorbiting of large-scale space debris from near-Earth space / M. M. Dron et al. *Kosmična nauka i tehnologija*. 2019. Vol. 25, no. 6. P. 61–69.
URL: <https://doi.org/10.15407/knit2019.06.061>.
30. Investigation of aerodynamics heating of space debris object at reentry to Earth atmosphere / Dron M. et al. *69th International Astronautical Congress*, Bremen, Germany, 01-05 October 2018. 2018.
31. F. Fang, L. Zhou, Z. Li. A comprehensive analysis of aerodynamics for spacecraft re-entry Earth's atmosphere surroundings. *Acta Aeronautica et Astronautica Sinica*. 2015. Vol. 36, no. 1. P. 24-38. DOI: 10.7527/S1000-6893.2014.0225
32. Reentry trajectory optimization using gradient free algorithms / G. N. Kumar et al. *IFAC-PapersOnLine*. 2018. Vol. 51, no. 1. P. 650–655.
URL: <https://doi.org/10.1016/j.ifacol.2018.05.109>.
33. Brandis A. M., Johnston C. O. Characterization of stagnation-point heat flux for earth entry. *45th AIAA plasmadynamics and lasers conference*, Atlanta, GA. Reston, Virginia, 2014. URL: <https://doi.org/10.2514/6.2014-2374>.
34. Vinh N., Kim E.-K., Greenwood D. Second-order analytic solutions for re-entry trajectories. *Flight simulation and technologies*, Monterey, CA, U.S.A. Reston, Virginia, 1993. URL: <https://doi.org/10.2514/6.1993-3679>.
35. Sim H.-s., Kim K.-h. Reentry survival analysis of tumbling metallic hollow cylinder. *Advances in space research*. 2011. Vol. 48, no. 5. P. 914–922.
URL: <https://doi.org/10.1016/j.asr.2011.04.036>.
36. Park S.-H., Park G. Reentry trajectory and survivability estimation of small space debris with catalytic recombination. *Advances in space research*. 2017. Vol. 60, no. 5. P. 893–906.
URL: <https://doi.org/10.1016/j.asr.2017.05.004>.
37. A study on heat flux predictions for re-entry flight analysis / S.-H. Park et al. *Acta astronautica*. 2021. Vol. 187. P. 271–280.
URL: <https://doi.org/10.1016/j.actaastro.2021.06.025>.

38. Fay J. A., Riddell F. R. Theory of stagnation point heat transfer in dissociated air. *Journal of the aerospace sciences*. 1958. Vol. 25, no. 2. P. 73–85. URL: <https://doi.org/10.2514/8.7517> .
39. Object Reentry Survival Analysis Tool. URL: <https://orbitaldebris.jsc.nasa.gov/reentry/orsat.html>.
40. L.F. Crabtree, R.L. Dommett, J.G. Woodley. Estimation of Heat Transfer to Flat Plates, Cones and Blunt Bodies. *Reports and Memoranda No. 3637*, Aeronautical Research Council, Ministry of Technology. 1970. 59 p.
41. URL: <https://www.htg-gmbh.com/en/htg-gmbh/software/dramasesam/>
42. Pai S.-I. Heat transfer in radiation gasdynamics. *Radiation gas dynamics*. Vienna, 1966. P. 122–163. URL: https://doi.org/10.1007/978-3-7091-5730-5_9 .
43. Lees L. Laminar heat transfer over blunt-nosed bodies at hypersonic flight speeds. *Journal of jet propulsion*. 1956. Vol. 26, no. 4. P. 259–269. URL: <https://doi.org/10.2514/8.6977> .
44. Detra R. W., Hidalgo H. Generalized heat transfer formulas and graphs for nose cone re-entry into the atmosphere. *ARS journal*. 1961. Vol. 31, no. 3. P. 318–321. URL: <https://doi.org/10.2514/8.5471> .
45. G. Herdrich , M. Fertig , S. Löhle. Experimental Simulation of High Enthalpy Planetary Entries. *The Open Plasma Physics Journal*. 2009. Vol. 2. P. 150–164. DOI: [10.2174/1876534300902010150](https://doi.org/10.2174/1876534300902010150).
46. M.E. Tauber. A Review of High-Speed, Convective, Heat-Transfer Computation Methods. *NASA, Technical Paper, 2914*. 1989, URL [https://ntrs.nasa.gov/citations/19890017745.\(1199\)](https://ntrs.nasa.gov/citations/19890017745.(1199)).
47. Koppenwallner G., Lips T., Abe T. Influence of rarefied gas flow on re-entry survivability of space debris. *RARIFIED GAS DYNAMICS: proceedings of the 26th international symposium on rarified gas dynamics*, Kyoto (Japan). 2008. URL: <https://doi.org/10.1063/1.3076574> .
48. ESA. SCARAB. URL: <https://www.htg-gmbh.com/en/htg-gmbh/software/scarab/>.

49. Zoby E. V., Sullivan E. M. Effects of corner radius on stagnation-point velocity gradients on blunt axisymmetric bodies. *Journal of spacecraft and rockets*. 1966. Vol. 3, no. 10. P. 1567.
URL: <https://doi.org/10.2514/3.59538> .
50. K. Sutton, R.A. Graves. A general stagnation-point convective heating equation for arbitrary gas mixtures. *NASA Technical Report (TR) R-376*. 1971. URL: <https://ntrs.nasa.gov/citations/19720003329>.
51. Truitt R. W. Fundamentals of aerodynamic heating. Ronald, 1960.
52. DEBRISK V3: new generation of object-oriented tools / J. Annaloro et al. *8th european conference on space debris*, Darmstadt, Germany, 20-23 March 2021. 2021.
53. The object reentry survival analysis tool (ORSAT) ... / J. Dobarco-Otero et al. *56th international astronautical congress of the international astronautical federation, the international academy of astronautics, and the international institute of space law*, Fukuoka, Japan. Reston, Virginia, 2005. URL: <https://doi.org/10.2514/6.iac-05-b6.3.06> .
54. URL: <https://www.htg-gmbh.com/en/htg-gmbh/software/scarab/>.
55. L. Grassi. Design for Demise techniques for medium/large LEO satellites reentry. *7th European Conference on Space Debris*, ESA/ESOC, Darmstadt, Germany, 18 – 21 April 2017. 2017.
56. URL: <https://www.connectbycn.es.fr/en/debrisk>.
57. Debris Reentry and Ablation Prediction and Ground Risk Assessment Software System / H. Ruifeng et al. *Acta aeronautica et astronautica sinica*. 2011. Vol. 32. no. 3. P. 390-399.
58. Park S.-H., Kim H.-D., Park G. Orbit, orbital lifetime, and reentry survivability estimation for orbiting objects. *Advances in space research*. 2018. Vol. 62, no. 11. P. 3012–3032.
URL: <https://doi.org/10.1016/j.asr.2018.08.016> .

- 59.Space debris reentry analysis methods and tools / Z. Wu et al. *Chinese journal of aeronautics*. 2011. Vol. 24, no. 4. P. 387–395.
URL: [https://doi.org/10.1016/s1000-9361\(11\)60046-0](https://doi.org/10.1016/s1000-9361(11)60046-0) .
- 60.Monte carlo simulation of spacecraft reentry aerothermodynamics and analysis for ablating disintegration / J. Liang et al. *Communications in computational physics*. 2018. Vol. 23, no. 4.
URL: <https://doi.org/10.4208/cicp.oa-2016-0213> .
- 61.Design for containment techniques to reduce spacecraft re-entry footprint / M. Urriza et al. *2 nd International Conference on Flight Vehicles, Aerothermodynamics and Re-entry Missions & Engineering (FAR)*, Heilbronn, Germany, 19 - 23 June 2022. 2022.
- 62.N. Sia, P. M. Mehta. Next-generation aerothermodynamic modeling for space debris using deep learning. 8th European Conference on Space Debris (virtual), Darmstadt, Germany, 20–23 April 2021. 2021.
- 63.Russell S. J., Norvig P. Artificial intelligence: a modern approach. Pearson Education, Limited, 2020.
- 64.Kelleher J. D., D'Arcy A., Namee B. M. Fundamentals of machine learning for predictive data analytics: algorithms, worked examples, and case studies. MIT Press, 2015. 624 p.
- 65.Izzo D., Märten M., Pan B. A survey on artificial intelligence trends in spacecraft guidance dynamics and control. *Astrodynamics*. 2019. Vol. 3, no. 4. P. 287-299. URL: <https://doi.org/10.1007/s42064-018-0053-6>.
- 66.Schmidhuber J. Deep learning in neural networks: an overview. *Neural networks*. 2015. Vol. 61. P. 85–117.
URL: <https://doi.org/10.1016/j.neunet.2014.09.003> .
- 67.Strembovskiy V. V., Dreus A. Y. Analysis of the practice of using machine learning methods to model the trajectories of space objects. *Journal of Rocket-Space Technology*. 2024. Vol. 33, no. 4. P. 108–117.
URL: <https://doi.org/10.15421/452415>.

68. Peng H., Bai X. Exploring capability of support vector machine for improving satellite orbit prediction accuracy. *Journal of aerospace information systems*. 2018. Vol. 15, no. 6. P. 366-381. URL: <https://doi.org/10.2514/1.i010616>.
69. Peng H., Bai X. Improving orbit prediction accuracy through supervised machine learning. *Advances in space research*. 2018. Vol. 61, no. 10. P. 2628-2646. URL: <https://doi.org/10.1016/j.asr.2018.03.001>.
70. Peng H., Bai X. Comparative evaluation of three machine learning algorithms on improving orbit prediction accuracy. *Astrodynamics*. 2019. Vol. 3, no. 4. P. 325-343. URL: <https://doi.org/10.1007/s42064-018-0055-4>.
71. Peng H., Bai X. Artificial neural network–based machine learning approach to improve orbit prediction accuracy. *Journal of spacecraft and rockets*. 2018. Vol. 55, no. 5. P. 1248-1260. URL: <https://doi.org/10.2514/1.a34171>.
72. Peng H., Bai X. Gaussian Processes for improving orbit prediction accuracy. *Acta astronautica*. 2019. Vol. 161. P. 44-56. URL: <https://doi.org/10.1016/j.actaastro.2019.05.014>.
73. Comparison between two spacecraft-oriented tools: PAMPERO & SCARAB / J. Annaloro et al. *Journal of space safety engineering*. 2017. Vol. 4, no. 1. P. 15–21. URL: <https://doi.org/10.1016/j.jsse.2017.02.004>.
74. Dachwald B., Ohndorf A. Global optimization of continuous-thrust trajectories using evolutionary neurocontrol. *Springer optimization and its applications*. Cham, 2019. P. 33–57. URL: https://doi.org/10.1007/978-3-030-10501-3_2.
75. Improving thermospheric density predictions in low-earth orbit with machine learning / G. Acciarini et al. *Space weather*. 2024. Vol. 22, no. 2. URL: <https://doi.org/10.1029/2023sw003652>.
76. Machine learning for global optimization / A. Cassioli et al. *Computational optimization and applications*. 2010. Vol. 51, no. 1. P. 279–303. URL: <https://doi.org/10.1007/s10589-010-9330-x>.

77. Huang A., Wu S. Neural network-based approximation model for perturbed orbit rendezvous. *Mathematics*. 2022. Vol. 10, no. 14. P. 2489.
URL: <https://doi.org/10.3390/math10142489>.
78. Davide Amato, Aaron Jay Rosengren, Roberto Furfaro. Solving the main problem in satellite theory through recurrent neural networks. 42nd COSPAR Scientific Assembly, Pasadena, California, USA, 4-22 July 2018. 2018. Vol. 42. URL: <https://ui.adsabs.harvard.edu/abs/2018cosp...42E..79A/abstract>.
79. Satellite orbit prediction based on recurrent neural network using two line elements / A. Osama et al. 2022 5th international conference on computing and informatics (ICCI), New Cairo, Cairo, Egypt, 9-10 March 2022. 2022. URL: <https://doi.org/10.1109/icci54321.2022.9756063>.
80. Giridhar Jadala, Gowri Namratha Meedinti, Radhakrishnan Delhibabu. Satellite orbit prediction using a machine learning approach. ICAIW 2022: Workshops at the 5th International Conference on Applied Informatics 2022, Arequipa, Peru, 27-29 October, 2022. 2022. URL: https://ceur-ws.org/Vol-3282/icaiw_waai_3.pdf.
81. Linares R., Furfaro R., Reddy V. Space objects classification via light-curve measurements using deep convolutional neural networks. The journal of the astronautical sciences. 2020. Vol. 67, no. 3. P. 1063-1091. URL: <https://doi.org/10.1007/s40295-019-00208-w>.
82. Applications of machine learning and monocular vision for autonomous on-orbit proximity operations / N. Dhamani et al. AIAA scitech 2020 forum, Orlando, FL. Reston, Virginia, 2020. URL: <https://doi.org/10.2514/6.2020-1376>.
83. Barton, K.E., McLaughlin, C.A. Long short term memory neural networks for the prediction of localized atmospheric density for orbit determination. 2018 AAS/AIAA Astrodynamics Specialist Conference, Snowbird, UT, USA, 19-23 August 2018. P. 19-23. Google Scholar. URL: <https://surl.li/fniyhd>.

84. Pérez D., Bevilacqua R. Neural Network based calibration of atmospheric density models. *Acta astronautica*. 2015. Vol. 110. P. 58-76. URL: <https://doi.org/10.1016/j.actaastro.2014.12.018>.
85. Q-learning algorithm for path-planning to maneuver through a satellite cluster / Chu, X et al. *2018 AAS/AIAA Astrodynamics Specialist Conference*, Snowbird, UT, USA, 19-23 August 2018. P. 2063-2082. URL: <https://scholars.library.tamu.edu/vivo/display/n404784SE/Documents/Overview>.
86. Willis, S., Izzo, D., Hennes, D. Reinforcement learning for spacecraft maneuvering near small bodies. *AAS/AIAA Space Flight Mechanics Meeting*, Napa, CA, USA, 14-18 February 2016. P. 1351-1368. URL: <https://www.esa.int/gsp/ACT/doc/MAD/pub/ACT-RPR-MAD-2016-NAPA-HoveringOnSmallBodies.pdf>.
87. Yin S., Li J., Cheng L. Low-thrust spacecraft trajectory optimization via a DNN-based method. *Advances in space research*. 2020. Vol. 66, no. 7. P. 1635-1646. URL: <https://doi.org/10.1016/j.asr.2020.05.046>.
88. Parrish, N. L., Scheeres, D. J. Optimal low-thrust trajectory correction with neural networks. *2018 AAS/AIAA Astrodynamics Specialist Conference*, Snowbird, UT, USA, 19-23 August 2018. P. 1483-1502. URL: https://experts.colorado.edu/display/pubid_269115.
89. Alessio Mereta, Dario Izzo, Alexander Wittig. Machine learning of optimal low-thrust transfers between near-earth objects networks. *12th International Conference, HAIS 2017, La Rioja, Spain, June 21-23, 2017*. P. 543-553. URL: https://doi.org/10.1007/978-3-319-59650-1_46.
90. Sharma S., Cutler J. Robust orbit determination and classification: A learning theoretic approach. *IPN Progress Report 42*. 2015. V. 42-203. P. 1-20. URL: https://ipnpr.jpl.nasa.gov/progress_report/42-203/203D.pdf.
91. Machine learning approach to initial orbit determination of unknown LEO satellites / B.-s. Lee et al. *15th international conference on space operations*,

- Marseille, France. Reston, Virginia, 2018. URL: <https://doi.org/10.2514/6.2018-2566>.
92. Salleh N., Yuhani S. S., Mohd Azmi N. F. Modeling orbital propagation using regression technique and artificial neural network. *International journal on advanced science, engineering and information technology*. 2022. Vol. 12, no. 3. P. 1279. URL: <https://doi.org/10.18517/ijaseit.12.3.15366>.
 93. A machine learning-based approach for improved orbit predictions of LEO space debris with sparse tracking data from a single station / B. Li et al. *IEEE transactions on aerospace and electronic systems*. 2020. Vol. 56, no. 6. P. 4253-4268. URL: <https://doi.org/10.1109/taes.2020.2989067>.
 94. Balamurugan C., Mukherjee B., Anil Kumar A. K. Heuristics Based Re-Entry Prediction Model for Uncontrolled Space Objects. *2nd International Orbital Debris Conference*, Sugar Land, Texas, 4-7 December, 2023. 2023.
 95. Mark C. P., Srinivasan K. Identification of aerodynamic derivatives of a re-entry module. *Lecture notes in mechanical engineering*. Singapore, 2020. P. 289–299. URL: https://doi.org/10.1007/978-981-15-5432-2_25.
 96. Salmaso F., Trisolini M., Colombo C. A machine learning and feature engineering approach for the prediction of the uncontrolled re-entry of space objects. *Aerospace*. 2023. Vol. 10, no. 3. P. 297. URL: <https://doi.org/10.3390/aerospace10030297>.
 97. A. Panico, P. DiLizia. Machine Learning techniques applied to space object sun controlled reentry predictions. *9th European conference for aeronautics and space sciences*, Lille, France, 27 June - 1 July 2022. URL: <https://doi.org/10.13009/EUCASS2022-6137>.
 98. Sutskever I., Vinyals O., Le Q.V. Sequence to Sequence learning with Neural Networks. *27th International Conference on Neural Information Processing Systems*, Montreal, Canada, 8-13 December 2014. 2014. Vol. 2. P. 3104-3112. URL: <https://doi.org/10.48550/arXiv.1409.3215>.
 99. Recurrent neural network model to predict re-entry trajectories of uncontrolled space objects / O. Jung et al. *Advances in space research*. 2021.

- Vol. 68, no. 6. P. 2515–2529.
 URL: <https://doi.org/10.1016/j.asr.2021.04.041>
100. Gondelach D. J., Armellin R., Lidtke A. A. Ballistic coefficient estimation for reentry prediction of rocket bodies in eccentric orbits based on TLE data. *Mathematical problems in engineering*. 2017. Vol. 2017. P. 1–13. URL: <https://doi.org/10.1155/2017/7309637>.
 101. Real-Time reentry trajectory planning of hypersonic vehicles: a two-step strategy incorporating fuzzy multiobjective transcription and deep neural network / R. Chai et al. *IEEE transactions on industrial electronics*. 2020. Vol. 67, no. 8. P. 6904–6915.
 URL: <https://doi.org/10.1109/tie.2019.2939934> .
 102. Adaptive maneuver control of hypersonic re-entry flight via self-organizing recurrent functional link network / Y. Du et al. 2016 international joint conference on neural networks (IJCNN), Vancouver, BC, Canada, 24–29 July 2016. 2016. URL: <https://doi.org/10.1109/ijcnn.2016.7727841>
 103. Reentry risk and safety assessment of spacecraft debris based on machine learning / H. Gao et al. *International journal of aeronautical and space sciences*. 2023. URL: <https://doi.org/10.1007/s42405-023-00652-x>.
 104. Thermal Optimization of Trajectories of Space Debris Removal into the Earth's Atmosphere / Dreus A. et al. 73rd International Astronautical Congress, IAC 2022, Paris, France, 18–22 September 2022. 2022. ISSN 00741795.
 105. Assessment of in-house algorithms on re-entry time prediction of uncontrolled space objects / P. Dutt et al. *Advances in space research*. 2022. URL: <https://doi.org/10.1016/j.asr.2022.12.025>.
 106. Data-Driven modeling of hypersonic reentry flow with heat and mass transfer / L. Gkimitis et al. *AIAA journal*. 2023. P. 1–18. URL: <https://doi.org/10.2514/1.j062332>.
 107. Park S.-H., Park G. Reentry trajectory and survivability estimation of small space debris with catalytic recombination. *Advances in space research*.

2017. Vol. 60, no. 5. P. 893-906. URL: <https://doi.org/10.1016/j.asr.2017.05.004>.
108. Design of multiple space debris removal missions using machine learning / G. Viavattene et al. *Acta astronautica*. 2022. Vol. 193. P. 277–286. URL: <https://doi.org/10.1016/j.actaastro.2021.12.051>.
 109. Active debris removal mission planning method based on machine learning / Y. Xu et al. *Mathematics*. 2023. Vol. 11, no. 6. P. 1419. URL: <https://doi.org/10.3390/math11061419>.
 110. Tao J., Cao Y., Ding M. SDebrisNet: a spatial–temporal saliency network for space debris detection. *Applied sciences*. 2023. Vol. 13, no. 8. P. 4955. URL: <https://doi.org/10.3390/app13084955>.
 111. Ballistic coefficient calculation based on optical angle measurements of space debris / Y. Ding et al. *Sensors*. 2023. Vol. 23, no. 18. P. 7668. URL: <https://doi.org/10.3390/s23187668>.
 112. Alpatov A. P., Holdshtein Y. M. Choice of orbits for space debris utilization. *Technical mechanics*. 2019. Vol. 2019, no. 2. P. 5-15. URL: <https://doi.org/10.15407/itm2019.02.005>.
 113. Zhang Z., Deng C., Deng Z. A diverse space target dataset with multi-debris and realistic on-orbit environment. *IEEE journal of selected topics in applied earth observations and remote sensing*. 2022. P. 1–14. URL: <https://doi.org/10.1109/jstars.2022.3203042>.
 114. Bennette W. D., Zeliff K., Raquepas J. Classification of objects in geosynchronous earth orbit via light curve analysis. 2017 IEEE symposium series on computational intelligence (SSCI), Honolulu, HI, 27 November - 1 December 2017. 2017. URL: <https://doi.org/10.1109/ssci.2017.8280966>.
 115. Khoroshylov S. V., Redka M. O. Deep learning for spacecraft guidance, navigation, and control. *Kosmična nauka i tehnologija*. 2021. Vol. 27, no. 6. P. 38–52. URL: <https://doi.org/10.15407/knit2021.06.038>.
 116. R. Linares, J. L. Crassidis, M. K. Jah. Space object classification and characterization via Multiple Model Adaptive Estimation. *17th International*

- Conference on Information Fusion (FUSION)*, Salamanca, Spain , 07-10 July 2014. 2014.
117. Space object classification using deep neural networks / B. Jia et al. *2018 IEEE aerospace conference*, Big Sky, MT, 3–10 March 2018. 2018. URL: <https://doi.org/10.1109/aero.2018.8396567> .
 118. Yadav V., Padhi R., Balakrishnan S. N. Robust/Optimal temperature profile control of a high-speed aerospace vehicle using neural networks. *IEEE transactions on neural networks*. 2007. Vol. 18, no. 4. P. 1115-1128. URL: <https://doi.org/10.1109/tnn.2007.899229>.
 119. Space objects classification techniques: a survey / S. Jahirabadkar et al. *2020 international conference on computational performance evaluation (compe)*, Shillong, India, 2–4 July 2020. 2020. URL: <https://doi.org/10.1109/compe49325.2020.9199996> .
 120. Khalil M., Fantino E., Liatsis P. Classification of space objects using machine learning methods. *2019 IEEE first international conference on cognitive machine intelligence (cogmi)*, Los Angeles, CA, USA, 12–14 December 2019. 2019. URL: <https://doi.org/10.1109/cogmi48466.2019.00021> .
 121. Federici L., Zavoli A., Colasurdo G. Evolutionary optimization of multirendezvous impulsive trajectories. *International journal of aerospace engineering*. 2021. Vol. 2021. P. 1–19. URL: <https://doi.org/10.1155/2021/9921555> .
 122. Angarita J. E., Black J. Trajectory planning optimization using genetic algorithms. *Aiaa space 2016*, Long Beach, California. Reston, Virginia, 2016. URL: <https://doi.org/10.2514/6.2016-5357> .
 123. Fritz S., Turkoglu K. Optimal trajectory determination and mission design for asteroid/deep-space exploration via multibody gravity assist maneuvers. *International journal of aerospace engineering*. 2017. Vol. 2017. P. 1–12. URL: <https://doi.org/10.1155/2017/6801023> .

124. Cacciatore F., Toglia C. Optimization of orbital trajectories using genetic algorithms. *Journal of aerospace engineering, sciences and applications*. 2008. Vol. 1, no. 1. P. 58–69.
URL: <https://doi.org/10.7446/jaesa.0101.06> .
125. Ekrami Kivaj A., Basohbat Novinzadeh A., Pazooki F. Spacecraft reentry trajectory optimization by heuristic optimization methods and optimal control theory. *International journal of dynamics and control*. 2022.
URL: <https://doi.org/10.1007/s40435-022-01033-0> .
126. J-A. Désidéri, S. Peigin, S. Timchenko. Application of genetic algorithms to the solution of the space vehicle reentry trajectory optimization problem. *Institut national de recherche en informatique et en automatique*. Vol. 3843. 1999.
127. Coello Coello C. A. Evolutionary multi-objective optimization: a historical view of the field. *IEEE computational intelligence magazine*. 2006. Vol. 1, no. 1. P. 28–36.
URL: <https://doi.org/10.1109/mci.2006.1597059> .
128. Multi-objective optimal preliminary planning of multi-debris active removal mission in LEO / Y. Liu et al. *Science china information sciences*. 2017. Vol. 60, no. 7. URL: <https://doi.org/10.1007/s11432-016-0566-7> .
129. Wang D., Li L., Chen L. An efficient genetic algorithm for active space debris removal planning. *2019 IEEE congress on evolutionary computation (CEC)*, Wellington, New Zealand, 10–13 June 2019. 2019.
URL: <https://doi.org/10.1109/cec.2019.8790081> .
130. Optimal mission planning of active space debris removal based on genetic algorithm / Y. Chen et al. *IOP conference series: materials science and engineering*. 2020. Vol. 715. P. 012025.
URL: <https://doi.org/10.1088/1757-899x/715/1/012025> .
131. Zhang N., Zhang Z., Baoyin H. Timeline Club: an optimization algorithm for solving multiple debris removal missions of the time-

- dependent traveling salesman problem model. *Astrodynamics*. 2021.
URL: <https://doi.org/10.1007/s42064-021-0107-z> .
132. Li H., Baoyin H. Optimization of multiple debris removal missions using an evolving elitist club algorithm. *IEEE transactions on aerospace and electronic systems*. 2020. Vol. 56, no. 1. P. 773–784.
URL: <https://doi.org/10.1109/taes.2019.2934373> .
 133. Avramenko S. E., Zheldak T. A., Koriashkina L. S. Guided hybrid genetic algorithm for solving global optimization problems. *Radio electronics, computer science, control*. 2021. No. 2. P. 174–188.
URL: <https://doi.org/10.15588/1607-3274-2021-2-18> .
 134. Hybrid QPSO and SQP algorithm with homotopy method for optimal control of rapid cooperative rendezvous / G. Liu et al. *Journal of aerospace engineering*. 2019. Vol. 32, no. 4. P. 04019030.
URL: [https://doi.org/10.1061/\(asce\)as.1943-5525.0001021](https://doi.org/10.1061/(asce)as.1943-5525.0001021) .
 135. Viavattene G., Grustan-gutierrez E., Ceriotti M. Multi-Objective Optimization of Low-Thrust Propulsion Systems for Multi-Target Missions using ANNs. *Advances in space research*. 2022.
URL: <https://doi.org/10.1016/j.asr.2022.07.039> .
 136. Huang A.-y., Luo Y.-z., Li H.-n. Global optimization of multiple-spacecraft rendezvous mission via decomposition and dynamics-guide evolution approach. *Journal of guidance, control, and dynamics*. 2021. P. 1–8. URL: <https://doi.org/10.2514/1.g006101> .
 137. Dreus, A.; Strembovskyi, V.; Dubovik, L.; Dron, M.; Golubek, A. Thermal optimization of trajectories of space debris removal into the earth's atmosphere. *Proceedings of the International Astronautical Congress, IAC*, 2022. ISSN: 00741795.
 138. R. F. Muraca, J. S. Whittick. Materials data handbook. Titanium 6Al-4V. *NASA-CR-123775*. 1972.
 139. Temperature-Dependent Material Modeling for Structural Steels: Formulation and Application / Seif, M. Et al. *Technical Note (NIST TN)*.

- National Institute of Standards and Technology. Gaithersburg. 2016.
URL: <https://doi.org/10.6028/NIST.TN.1907>.
140. Energy and force analysis of ti-6al-4v linear friction welds for computational modeling input and validation data / A. R. McAndrew et al. *Metallurgical and materials transactions A*. 2014. Vol. 45, no. 13. P. 6118–6128.
URL: <https://doi.org/10.1007/s11661-014-2575-8>.
 141. Shao-Hsien C., Tsai K.-T. Predictive analysis for the thermal diffusion of the plasma-assisted machining of superalloy inconel-718 based on exponential smoothing. *Advances in materials science and engineering*. 2018. Vol. 2018. P. 1–9.
URL: <https://doi.org/10.1155/2018/9532394>.
 142. Лінник А. К. Конструювання корпусів рідинних балістичних ракет. Дніпропетровськ : ДГУ, 1994. 78 с.
 143. Martin J. J. Atmospheric reentry: an introduction to its science and engineering. Englewood Cliffs, N.J : Prentice-Hall, 1966. 264 p.
 144. Полежаев Ю. В. Тепловая защита. М., 1976. 391 с.
 145. Mitchell T. M., Carbonell J. G., Michalski R. S. Machine learning. Boston, MA : Springer US, 1986. URL: <https://doi.org/10.1007/978-1-4613-2279-5>.
 146. Machine Learning Lens: AWS Well-Architected Framework. URL: <https://docs.aws.amazon.com/pdfs/wellarchitected/latest/machine-learning-lens/wellarchitected-machine-learning-lens.pdf>.
 147. Bergmann D., Stryker C. What is loss function? | IBM. *IBM - United States*. URL: <https://www.ibm.com/think/topics/loss-function#:~:text=In%20machine%20learning%20,output%20of%20some%20loss%20function>.
 148. Domingos P. A few useful things to know about machine learning. *Communications of the ACM*. 2012. Vol. 55, no. 10. P. 78–87.
URL: <https://doi.org/10.1145/2347736.2347755>.
 149. H H. J. Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence. MIT Press, 2019. 232 p.
 150. A comparison on the performance of crossover techniques in video game / G. K. Soon et al. *2013 IEEE international conference on control system, computing and engineering (ICCSCE)*, Penang, Malaysia, 29 November – 1 December 2013. 2013.
URL: <https://doi.org/10.1109/iccsce.2013.6720015>.

151. Katoch S., Chauhan S. S., Kumar V. A review on genetic algorithm: past, present, and future. *Multimedia tools and applications*. 2020.
URL: <https://doi.org/10.1007/s11042-020-10139-6> .
152. Greenwell R. N., Angus J. E., Finck M. Optimal mutation probability for genetic algorithms. *Mathematical and computer modelling*. 1995. Vol. 21, no. 8. P. 1–11.
URL: [https://doi.org/10.1016/0895-7177\(95\)00035-z](https://doi.org/10.1016/0895-7177(95)00035-z) .
153. DeJong, K. An analysis of the behavior of a class of genetic adaptive systems. University of Michigan, 1975. 266 p.
154. Kussoy, M. I. Hypersonic viscous drag on cones in rarefied flow. *NASA-TN-D-4036*. 1967.
155. Supersonic and hypersonic drag coefficients for a sphere / E. Loth et al. *AIAA journal*. 2021. P. 3261–3274. URL: <https://doi.org/10.2514/1.j060153> .
156. Penland, Jim A. Aerodynamic Characteristics of a Circular Cylinder at Mach Number of 6.86 and Angles of Attack up to 90 Degrees. *NACA-RM-L54A14*. 1954.
157. F. E. Gowen, E. W Perkins. Drag of Circular Cylinders for a Wide Range of Reynolds Numbers and Mach Numbers. *NACA-RM-A52C20*. 1952.
158. Spacecraft aerodynamic torques - Space vehicle design criteria /guidance and control/. *NASA-SP-8058*. 1971.
159. K. W. Mc Alister, V. L. Peterson, D. A. Stewart. Aerodynamic characteristics of a large-angle blunt cone with and without fence-type afterbodies. *NASA-TN-D-6269*. 1971.
160. Omar S. R., Wersinger J. M. Satellite formation control using differential drag. *53rd AIAA aerospace sciences meeting*, Kissimmee, Florida. Reston, Virginia, 2015. URL: <https://doi.org/10.2514/6.2015-0002> .
161. J. Graham, M. Fossati. Deep-learning Neural Networks for predicting aerothermodynamic loads during atmospheric re-entry. *ATD3 Workshop*, 6–7 June 2024 p. 2024.
162. Prediction of aerothermal heating: from numerical simulations to machine learning models / Y. Wang et al. *Aerospace research communications*. 2025. Vol. 3.
URL: <https://doi.org/10.3389/arc.2025.14274> .

163. Rosenblatt F. Principles of neurodynamics: perceptrons and the theory of brain mechanisms. Spartan, 1962.
164. Rumelhart D. E., Hinton G. E., Williams R. J. Learning representations by back-propagating errors. *Nature*. 1986. Vol. 323, no. 6088. P. 533–536.
URL: <https://doi.org/10.1038/323533a0>.
165. Python machine learning: unlock deeper insights into machine learning with this vital guide to cutting-edge predictive analytics. Packt Publishing, 2015. 425 p.
166. URL: https://scikit-learn.org/stable/modules/neural_networks_supervised.html.
167. Hopfield J. J. Neural networks and physical systems with emergent collective computational abilities. *Proceedings of the national academy of sciences*. 1982. Vol. 79, no. 8. P. 2554–2558. URL: <https://doi.org/10.1073/pnas.79.8.2554>.
168. Elman J. L. Finding structure in time. *Cognitive science*. 1990. Vol. 14, no. 2. P. 179–211. URL: https://doi.org/10.1207/s15516709cog1402_1.
169. Jordan M. I., Rumelhart D. E. Forward models: supervised learning with a distal teacher. *Cognitive science*. 1992. Vol. 16, no. 3. P. 307–354.
URL: https://doi.org/10.1207/s15516709cog1603_1.
170. Hochreiter S., Schmidhuber J. Long Short-Term Memory. *Neural computation*. 1997. Vol. 9, no. 8. P. 1735–1780. URL: <https://doi.org/10.1162/neco.1997.9.8.1735>.
171. Gers F. A. Learning to forget: continual prediction with LSTM. *9th international conference on artificial neural networks: ICANN '99*, Edinburgh, UK. 1999.
URL: <https://doi.org/10.1049/cp:19991218>.
172. Ensemble models of cutting-edge deep neural networks for blood glucose prediction in patients with diabetes / F. Tena et al. *Sensors*. 2021. Vol. 21, no. 21. P. 7090. URL: <https://doi.org/10.3390/s21217090>.
173. URL: https://d2l.ai/chapter_recurrent-modern/lstm.html.
174. URL: https://d2l.ai/chapter_recurrent-neural-networks/bptt.html.
175. Attention is all you need / A. Vaswani et al. *NIPS'17: Proceedings of the 31st International Conference on Neural Information Processing Systems*, Long Beach California, USA, December 4 - 9, 2017. 2017. URL: <https://doi.org/10.48550/arXiv.1706.03762>.

176. Palaniappan N. N. Demystifying generative ai and transformer architectures. *International journal of advanced research in engineering and technology*. 2025. Vol. 16, no. 2. P. 15–28. URL: https://doi.org/10.34218/ijaret_16_02_002 .
177. A systematic review for transformer-based long-term series forecasting / L. Su et al. *Artificial intelligence review*. 2025. Vol. 58, no. 3. URL: <https://doi.org/10.1007/s10462-024-11044-2> .
178. A convolutional self-attention network for CSI reconstruction in MIMO system / Q. Liu et al. *Wireless communications and mobile computing*. 2023. Vol. 2023. P. 1–10. URL: <https://doi.org/10.1155/2023/2922232> .
179. N. Lavesson, P. Davidsson. Quantifying the Impact of Learning Algorithm Parameter Tuning. *The Twenty-First National Conference on Artificial Intelligence and the Eighteenth Innovative Applications of Artificial Intelligence Conference*, Boston, Massachusetts, USA, July 16–20, 2006. 2006.
180. URL: https://d2l.ai/chapter_multilayer-perceptrons/mlp.html .
181. Y. Goldberg. A primer on neural network models for natural language processing. *Journal of Artificial Intelligence Research*. 2016. Vo. 57, no. 1. P. 345–420.
182. P. Michel, O. Levy, G. Neubig. Are sixteen heads really better than one? *Proceedings of the 33rd International Conference on Neural Information Processing Systems*. December 2019. Vol. 1257. P. 14037–14047.
183. Bengio Y., Courville A., Goodfellow I. Deep learning. MIT Press, 2016. 800 p.
184. Jordan J. Setting the learning rate of your neural network. *Jeremy Jordan*. URL: <https://www.jeremyjordan.me/nn-learning-rate/> .
185. On Large-Batch Training for Deep Learning: Generalization Gap and Sharp Minima / Nitish Shirish Keskar et al. *5th International Conference on Learning Representations (ICLR)*, Toulon, France, April 24–26, 2017. 2017.
186. Dropout: A Simple Way to Prevent Neural Networks from Overfitting / Nitish Srivastava et al. *Journal of Machine Learning Research*. 2014. Vol. 15. P. 1929–1958.

187. Yarín Gal, Zoubin Ghahramani. A Theoretically Grounded Application of Dropout in Recurrent Neural Networks. *30th International Conference on Neural Information Processing Systems*, Barcelona, Spain December 5 - 10, 2016. 2016. P. 1027–1035.
188. W. Zaremba, I. Sutskever, O. Vinyals. Recurrent Neural Network Regularization. URL: <https://doi.org/10.48550/arXiv.1409.2329>.
189. Muhan Zhang. Neural Attention: Enhancing QKV Calculation in Self-Attention Mechanism with Neural Networks. URL: <https://doi.org/10.48550/arXiv.2310.11398>.
190. Crossover and mutation: an introduction to two operations in genetic algorithms. *The DO Loop*. URL: <https://blogs.sas.com/content/iml/2021/10/18/crossover-mutation.html>.
191. Genetic Algorithm: Complete Guide With Python Implementation. URL: <https://www.datacamp.com/tutorial/genetic-algorithm-python>.
192. Choosing mutation and crossover ratios for genetic algorithms—a review with a new dynamic approach / A. Hassanat et al. *Information*. 2019. Vol. 10, no. 12. P. 390. URL: <https://doi.org/10.3390/info10120390>.
193. Andrew J. scholand, GA parameters. *Georgia Tech Engineering Information Systems Lab*. URL: [https://www.eislab.gatech.edu/people/scholand/gapara.htm#:~:text=The%20crossover%20method%20is%20assumed,50\)](https://www.eislab.gatech.edu/people/scholand/gapara.htm#:~:text=The%20crossover%20method%20is%20assumed,50)).
194. Choosing mutation and crossover ratios for genetic algorithms—a review with a new dynamic approach / A. Hassanat et al. *Information*. 2019. Vol. 10, no. 12. P. 390. URL: <https://doi.org/10.3390/info10120390>.
195. Lucy Linder. Genetic algorithms with PyGAD: selection, crossover, mutation. URL: <https://blog.derlin.ch/genetic-algorithms-with-pygad>.

ДОДАТОК А

Список публікацій автора за темою дисертації

5. Strembovskyi V., Dreus A. Identification of heat loads on space objects re-entering the Earth's atmosphere using machine learning methods. *Journal of Rocket-Space Technology*. 2024. Vol. 33, no. 4-29. P. 65–73. URL: <https://doi.org/10.15421/452452>. **(фахове видання, категорія Б)** (особистий внесок авторів: Стрембовський В.В.: побудовано моделі машинного навчання та виконано розрахунки, Дреус А.Ю.: постановка задачі).
6. Strembovskyi V. V., Dreus A. Y. Аналіз практики використання методів машинного навчання для моделювання траєкторій руху космічних об'єктів. *Journal of Rocket-Space Technology*. 2024. Т. 33, № 4. С. 108–117. URL: <https://doi.org/10.15421/452415>. **(фахове видання, категорія Б)** (особистий внесок авторів: Стрембовський В.В.: проведено аналіз та систематизацію світових практик використання методів машинного навчання для вирішення задач космічних місій, Дреус А.Ю.: постановка задачі).
7. A. Yu. DREUS, M. M. DRON, L. G. DUBOVIK, V. V. STREMBOVSKIYI Assessment of the possibility of using polymers in the bodies of promising launch vehicles based on the heat resistance factor. *Kosmìčna nauka ì tehnologiâ*. 2023. Vol. 29, no. 6. P. 03–12. URL: <https://doi.org/10.15407/knit2023.06.003>. **(фахове видання, категорія А, Scopus, Q4)** (особистий внесок авторів: Стрембовський В.В.: аналіз впливу теплових навантажень на характеристики матеріалів, Дреус А.Ю.: математична модель, Дронь М.М.: результати експериментальних досліджень, Дубовик Л.Г.: обговорення результатів).
8. Dreus, A.; Strembovskyi, V.; Dubovik, L.; Dron, M.; Golubek, A. Thermal optimization of trajectories of space debris removal into the earth's atmosphere. *Proceedings of the International Astronautical Congress, IAC, 2022*. ISSN: 00741795. | **(Scopus)** (особистий внесок авторів: Стрембовського В.В.: розроблено алгоритм генетичної оптимізації, Дреус А.Ю.: концептуалізація, Дронь М.М.: математична модель, результати експериментальних досліджень, Дубовик Л.Г.: обчислювальні експерименти, Голубек О.В.: опис комбінованого методу відведення КО).

ДОДАТОК Б

Програмний код моделі Transformer та реалізації ГА

Реалізація моделі Transformer

```

=====
# 3) Transformer Model Definition with multiple encoder blocks, Masking,
and Dropout=0.2
=====

class PositionalEncoding(layers.Layer):
    def __init__(self, sequence_length, d_model):
        super(PositionalEncoding, self).__init__()
        self.sequence_length = sequence_length
        self.d_model = d_model
        self.pos_encoding =
self.compute_positional_encoding(sequence_length, d_model)

    def compute_positional_encoding(self, position, d_model):
        angle_rads = self.get_angles(
            np.arange(position)[:, np.newaxis],
            np.arange(d_model) [np.newaxis, :],
            d_model
        )
        # apply sin to even indices, cos to odd
        angle_rads[:, 0::2] = np.sin(angle_rads[:, 0::2])
        angle_rads[:, 1::2] = np.cos(angle_rads[:, 1::2])
        pos_encoding = angle_rads[np.newaxis, ...]
        return tf.cast(pos_encoding, dtype=tf.float32)

    def get_angles(self, pos, i, d_model):
        angle_rates = 1 / np.power(10000, (2 * (i//2)) /
np.float32(d_model))
        return pos * angle_rates

    def call(self, inputs):
        return self.pos_encoding[:, :tf.shape(inputs) [1], :]

def create_transformer_model(
    input_dim,
    output_seq_length,
    d_model=128,
    num_heads=8,
    ff_dim=256,
    num_layers=3,
    dropout_rate=0.2,
    pad_value=PAD_VALUE
):
    inputs = layers.Input(shape=(input_dim,), name="input_features")

```

```

    # Repeat input vector to form a sequence
    x = layers.RepeatVector(output_seq_length)(inputs) # shape: (batch,
seq_len, input_dim)
    x = layers.Dense(d_model)(x)

    # Add positional encoding
    pos_encoding = PositionalEncoding(output_seq_length, d_model)
    x = x + pos_encoding(x)

    # Apply mask for padding
    x = layers.Masking(mask_value=pad_value)(x)

    # Build several transformer encoder blocks
    for i in range(num_layers):
        # MultiHead Attention with padding mask
        attn_output = layers.MultiHeadAttention(
            num_heads=num_heads,
            key_dim=d_model
        )(x, x, attention_mask=None) # Keras Masking layer handles mask
internally
        attn_output = layers.Dropout(dropout_rate)(attn_output)
        x = layers.LayerNormalization(epsilon=1e-6)(x + attn_output)

        # Feed-forward
        ffn_output = layers.Dense(ff_dim, activation="relu")(x)
        ffn_output = layers.Dense(d_model)(ffn_output)
        ffn_output = layers.Dropout(dropout_rate)(ffn_output)
        x = layers.LayerNormalization(epsilon=1e-6)(x + ffn_output)

    # Final TimeDistributed output: predict log(q(t)) at each timestep
    outputs = layers.TimeDistributed(
        layers.Dense(1, activation="linear"), name="q_log_output"
    )(x)

    model = tf.keras.Model(inputs=inputs, outputs=outputs,
name="Transformer_qt")
    return model

input_dim = X_train_scaled.shape[1]
transformer_model = create_transformer_model(
    input_dim=input_dim,
    output_seq_length=max_seq_length,
    d_model=128,
    num_heads=8,
    ff_dim=256,
    num_layers=3,
    dropout_rate=0.2
)
#
=====

```

```

# 4) Learning Rate Scheduler (Polynomial Decay) and Compile with RMS and
R2 if desired
#
=====

# Polynomial decay: from 1e-4 down to 1e-6 over 10000 steps
lr_schedule = tf.keras.optimizers.schedules.PolynomialDecay(
    initial_learning_rate=1e-4,
    decay_steps=10000,
    end_learning_rate=1e-6,
    power=1.0
)

optimizer = Adam(learning_rate=lr_schedule, clipnorm=1.0)

# Custom R2 metric
def r2_metric(y_true, y_pred):
    y_true_flat = tf.reshape(y_true, [-1])
    y_pred_flat = tf.reshape(y_pred, [-1])
    ss_res = tf.reduce_sum(tf.square(y_true_flat - y_pred_flat))
    ss_tot = tf.reduce_sum(tf.square(y_true_flat -
    tf.reduce_mean(y_true_flat)))
    return 1 - ss_res / (ss_tot + tf.keras.backend.epsilon())

transformer_model.compile(
    optimizer=optimizer,
    loss="mean_squared_error",
    metrics=[tf.keras.metrics.RootMeanSquaredError(name="rmse"),
    r2_metric]
)

transformer_model.summary()

# Save architecture separately
with open("transformer_architecture.json", "w") as f:
    f.write(transformer_model.to_json())
print("Saved Transformer architecture to 'transformer_architecture.json'")
#
=====

# 5) Train the model with EarlyStopping
#
=====

early_stop = EarlyStopping(patience=5, restore_best_weights=True,
monitor="val_loss")

history = transformer_model.fit(
    X_train_scaled,
    Y_train_log,
    validation_split=0.2,
    epochs=50,

```

```

batch_size=32,
callbacks=[early_stop],
verbose=1
)

```

Реалізація генетичної оптимізації

```

# -----
# 4) Клас задачі GA, що приймає параметри mass та xSectAvg
# -----
class ReentryTrajectoryProblem(Problem):
    def __init__(self, mass_val, xSectAvg_val):
        self.mass_val = mass_val
        self.xSectAvg_val = xSectAvg_val
        super().__init__(
            n_var=1,          # Оптимізуємо лише  $\theta$ 
            n_obj=1,          # Цільова функція - максимізація  $Q_{total}$ 
            n_constr=0,
            xl=np.array([THETA_MIN]),
            xu=np.array([THETA_MAX])
        )

    def _evaluate(self, X, out, *args, **kwargs):
        F = [] # Значення цільової функції для кожного кандидата
        t_array = create_time_vector(T_max, target_seq_length)

        for i in range(X.shape[0]):
            theta_i = X[i, 0]

            # Формуємо вхідний вектор: [mass, xSectAvg, Rn, Cd,
            entry_angle, velocity, q_max]
            X_input = np.array([[
                self.mass_val,
                self.xSectAvg_val,
                Rn_fixed,
                Cd_fixed,
                theta_i,
                velocity_fixed,
                q_max_fixed
            ]], dtype=np.float32)

            X_input_scaled = scaler_qt.transform(X_input)
            q_log = mlp_qt_model.predict(X_input_scaled, verbose=0)[0]
            q_log_clipped = np.clip(q_log, -50, 50)
            q_pred = np.exp(q_log_clipped)

            metrics = compute_integral_metrics(t_array, q_pred,
I_THRESHOLD)
            if metrics is None:
                Q_total_star = -1e6

```

```

        else:
            t_star, t_star2, delta_t, Q_total_star = metrics
            if delta_t <= 0:
                Q_total_star = -1e6

            F.append(-Q_total_star)

    out["F"] = np.column_stack(F)
# -----
# 5) Функція для запуску GA для заданих mass та xSectAvg
# -----
def run_GA_for_parameters(mass_val, xSectAvg_val):
    problem = ReentryTrajectoryProblem(mass_val, xSectAvg_val)
    algorithm = GA(
        pop_size=30,
        sampling=FloatRandomSampling(),
        crossover=SimulatedBinaryCrossover(prob=0.9, eta=15),
        mutation=PolynomialMutation(prob=0.3, eta=20),
        eliminate_duplicates=True
    )
    termination = get_termination("n_gen", 20)

    res = minimize(
        problem,
        algorithm,
        termination,
        seed=42,
        save_history=False,
        verbose=False
    )

    best_theta = res.X[0]
    best_Q_total_star = -res.F[0] # оскільки F = -Q_total_star
    return best_theta, best_Q_total_star
# -----
# 6) Grid Search: перебір значень mass та xSectAvg
# -----
mass_values = [400, 425, 450, 475, 500, 525, 550, 575, 600, 625, 650,
675, 700] # кг
xSectAvg_values = [0.2, 0.4, 0.6, 0.8, 1.0, 1.2, 1.4, 1.6] # м²

results = []
for mass_val in mass_values:
    for xSectAvg_val in xSectAvg_values:
        best_theta, best_Q_total_star = run_GA_for_parameters(mass_val,
xSectAvg_val)
        results.append({
            'mass': mass_val,
            'xSectAvg': xSectAvg_val,
            'optimal_theta': best_theta,
            'Q_total_star': best_Q_total_star

```

```
    ))  
    print(f"mass={mass_val}, xSectAvg={xSectAvg_val} -> "  
          f"optimal theta = {best_theta:.3f}, Q_total* =  
{best_Q_total_star:.3e}")
```