

Міністерство освіти і науки України
Національний технічний університет України
“Київський політехнічний інститут імені Ігоря Сікорського”
Міністерство освіти і науки України
Національний технічний університет України
“Київський політехнічний інститут імені Ігоря Сікорського”

Кваліфікаційна наукова праця на правах рукопису

Ярошенко Максим Олександрович

УДК 621.3

ДИСЕРТАЦІЯ
МОДИФІКОВАНИЙ НЕЙРОМЕРЕЖНИЙ МЕТОД РЕЙТРЕСИНГОВОЇ
АБЕРОМЕТРІЇ ОКА

17 Електроніка та телекомунікації
172 Телекомунікації та радіотехніка

Подається на здобуття наукового ступеня доктора філософії

Дисертація містить результати власних досліджень. Використання ідей, результатів і текстів інших авторів мають посилання на відповідне джерело

_____/Ярошенко М.О

Науковий керівник: Яганов Петро Олексійович, кандидат технічних наук,
доцент

Київ – 2025

АНОТАЦІЯ

Ярошенко М.О. Модифікований нейромережний метод рейтресингової аберометрії ока. – Кваліфікаційна наукова праця на правах рукопису.

Дисертація на здобуття наукового ступеня доктора філософії за спеціальністю 172 “Телекомунікації та радіотехніка”. – Національний технічний університет України “Київський політехнічний інститут імені Ігоря Сікорського”, Київ, 2025.

Дисертаційна робота присвячена вирішенню важливої та актуальної науково-прикладної задачі – вдосконалення рейтрейсингового методу аберометрії ока шляхом застосування методів машинного навчання, зокрема штучних нейронних мереж, задля підвищення його точності.

Дисертаційне дослідження складається зі вступу та п’яти розділів, які відображають та обґрунтовують основні результати роботи.

У вступі обґрунтовано актуальність дисертаційної роботи, висвітлено зв’язок роботи з науковими програмами, планами та темами НДР КПІ ім. Ігоря Сікорського. Сформульовано мету та вказані задачі, вирішення яких передбачає досягнення мети дослідження. Визначено об’єкт, предмет та методи дослідження, надано інформацію про наукову новизну та практичне значення отриманих результатів. Наведено інформацію про висвітлення результатів роботи в періодичних наукових виданнях та їх апробацію на наукових конференціях.

Перший розділ присвячено розгляду рейтрейсингового методу аберометрії ока людини, його обмежень та переваг. В результаті огляду літературних джерел виявлено можливості для вдосконалення рейтрейсингового методу аберометрії ока та проблеми, які можуть супроводжувати дослідження. Виходячи з цього, сформовано перелік завдань, результатом виконання яких є створення модифікованого нейромережного методу рейтрейсингової аберометрії. По-перше, пропонується розв’язати проблему нестачі вибірок вимірювань аберацій, оскільки ця проблема

ускладнює досягнення мети не тільки даної роботи, але і подальші дослідження та розробку методів офтальмологічної aberометрії загалом. По-друге, заплановано розробку та аналіз модифікації рейтрейсингового методу із використанням наявної вдосконаленої конструкції рейтрейсингового aberометра. Втім, у випадку виявлення недоліків, третім завданням визначено розробку модифікації методу, яка б потребувала, за необхідності, іншого способу вимірювання та, відповідно, іншої оптичної системи для імплементації методу. В якості четвертого завдання виділено дослідження та розробку способів корекції визначення аберацій в складі модифікованого нейромережного методу aberометрії. Розробку методу надроздільної здатності абераційних мап обрано п'ятим завданням, оскільки, у випадку практичної реалізації розробленого в ході роботи модифікованого методу рейтрейсингової aberометрії, створення серійних вимірювальних приладів цілком ймовірно може стикнутися з неможливістю вимірювання певних коефіцієнтів Церніке, що описують аберації вищих порядків.

У другому розділі описано розробку методу для генерації офтальмологічних aberометричних даних у вигляді наборів коефіцієнтів Церніке із застосуванням генеративно-змагальної нейронної мережі. Враховуючи те, що для навчання використовувалася вибірка розміром в 50 наборів, приділено увагу пошуку спеціалізованих методів аугментації даних з метою покращення навчання мережі. Використано метод аугментації, що ґрунтується на застосуванні обернених перетворень. Застосовано перетворення, що охоплюють не тільки маніпуляції зі значеннями коефіцієнтів у векторі, а й операції над піксельними зображеннями викривлень хвильового фронту за наборами коефіцієнтів. Для перевірки працездатності методу створено архітектуру генеративно-змагальної нейронної мережі, проведене її навчання. Результат навчання оцінено за метриками творчості, спадковості та різноманіття.

Третій розділ містить в собі опис модифікації методу рейтрейсингової aberометрії для одночасного сканування декількох точок зіниці шляхом

одночасного засвічування декількох випромінювачів. Для розв'язання проблеми, що постає в такому випадку, а саме проблеми некоректного зіставлення координати відбитка та позиції променя сканування, розроблено метод на основі нейронної мережі класифікації та угорського алгоритму. Наведено відомості щодо шарів довгої короткочасної пам'яті як основних для запропонованого методу. Проведено навчання нейронної мережі та оцінку результатів. Виходячи з наявності обмежень, обумовлених складнощами імплементації, обґрунтовано рішення для розробки нейромережної модифікації рейтрейсингового методу аберометрії, яка б використовувала інший спосіб вимірювання, який потребує іншої оптичної системи.

У четвертому розділі представлено опис оптичної системи для реалізації запропонованої нейромережної модифікації рейтрейсингового методу, приклад первинної обробки даних, спосіб розрахунку першого наближення для визначення аберацій за допомогою нейронної мережі, а також опис агента та середовища навчання з підкріпленням, призначеного для уточнення результатів. Розділ містить опис симуляції в спеціалізованому програмному забезпеченні, за результатами якої запропоновано приклад алгоритму отримання інформації про форму світлової плями на детекторах, отриманої шляхом підсвічування ока аналогічно до методу Гартмана-Шека – шляхом створення точкового джерела світла на сітківці в місці перетину із головною оптичною віссю. Описано штучну нейронну мережу прямого розповсюдження, яка за сигнатурами світлових плям на детекторах оцінює набір коефіцієнтів Церніке, що описують викривлення хвильового фронту відбитого від сітківки випромінювання, яке пройшло крізь оптичну систему ока. Проведено навчання нейронних мереж та наведено його результати. Невелику частину (10 примірників) використано для перевірки працездатності та навчання агента для уточнення результату. Розроблено середовище для роботи агента, яке імітує оптичну систему, що використовується для вимірювань. Створено агента на базі методу глибокого Q-навчання. Додатково створено агент на базі методу оптимізації проксимальної політики та проведено його

навчання з метою дослідження доцільності його використання як модифікації глибокого Q-навчання.

П'ятий розділ містить в собі опис методу на основі штучної нейронної мережі для надроздільної здатності викривлень хвильового фронту. Для визначення коефіцієнтів Церніке вищих порядків за значеннями коефіцієнтів нижчих порядків, розроблено штучну згорткову нейронну мережу, проведено її навчання та наведено результати. Використано вибірку, яка складається з зображень хмарного неба, фрагменти яких перетворено на нормовані зображення викривлень хвильових фронтів, за якими розраховано коефіцієнти Церніке для створення навчаючої вибірки.

У дисертаційній роботі отримано наступні нові наукові результати дослідження:

1. Набув подальшого розвитку рейтрейсинговий метод аберометрії ока шляхом модифікації із застосуванням нейронних мереж на різних етапах функціонування методу: перше наближення визначення характеристик аберацій, уточнення результату та оцінка аберацій вищих порядків. Це дозволило підвищити точність методу. Зокрема за оцінками в симуляції точність при визначенні дефокусу підвищено на 25% порівняно з існуючим аберометром iTrace у випадку викривлень зображення на детекторі не більше ніж 0.1 за відстанню Жаккара. Також запропонована модифікація дозволяє знизити вимоги до оптичної системи, необхідної для реалізації приладу, пришвидшити процес вимірювання шляхом одночасного сканування, а також надає можливість прогнозувати значення коефіцієнтів Церніке високих порядків на основі коефіцієнтів аберацій нижчих порядків (при апроксимації коефіцієнтів 6 та 7 порядків похибка становить не більше 4% за метрикою SMAPE).
2. Набуло подальшого розвитку генерування аберометричних даних у вигляді векторів коефіцієнтів Церніке. Це досягнуто шляхом застосування розробленої в рамках роботи генеративно-змагальної

нейронної мережі. Використання перетворення наборів коефіцієнтів Церніке у двовимірне зображення розширило можливості аугментації вхідних даних, що є особливо актуальним в умовах низької доступності клінічних даних та значних потреб у навчаючих вибірках для розробки рішень на основі штучних нейронних мереж для використання в офтальмологічній aberометрії. Розроблений метод придатний до синтеза даних, що мають розподіл, схожий з навчаючою вибіркою (відстань Фреше дорівнює 0.7), і які одночасно не є копією реальних примірників (92% за метрикою творчості) та примірники яких є різноманітними (значення відповідної метрики дорівнює 3.64, оптимальним є значення 3.83).

3. Запропоновано модифікацію рейтрейсингового методу aberометрії для одночасного сканування декількох зіничних координат із застосуванням масиву лазерних випромінювачів. Використання нейронної мережі для класифікації стало розв'язанням проблеми некоректного зіставлення променів сканування та їхніх відбитків на сітківці. Результатом застосування модифікації є зменшення довірчого інтервалу, що позитивно впливає на прецизійність: наприклад, при скануванні одночасно 16 зіничних координат довірчий інтервал зменшується в 4.4 рази для часового бюджету aberометра iTrace. Визначені в ході цієї роботи обмеження, які супроводжуватимуть імплементацію методу, показали необхідність у розробці модифікації, яка б потребувала, за необхідності, іншого методу вимірювання та, відповідно, іншої оптичної системи.

Отримано практичні результати досліджень:

1. Розроблена дослідна реалізація моделі процесу вимірювань для запропонованої нейромережної модифікації рейтрейсингового методу aberометрії ока в середовищі Zemax. Для моделі розроблено алгоритм обробки зображень в програмному пакеті MATLAB, який

- використовується для підготовки даних для подальшого визначення коефіцієнтів хвильового фронту відбитого від сітківки світла.
2. Розроблена нейронна мережа для визначення коефіцієнтів Церніке хвильового фронту по сигнатурах світлових плям на фотодетекторах для нейромережної модифікації методу рейтрейсингової аберометрії. Розробка та тренування нейронної мережі здійснювалося в середовищі Kaggle мовою програмування Python із залученням бібліотек функцій TensorFlow, SciPy та ін.
 3. Розроблена програма-агент навчання з підкріпленням (метод Deep Q-Network) для уточнення першого наближення при визначенні коефіцієнтів Церніке. Підготовка агента та його навчання, а також розробка середовища здійснювались в програмному пакеті MATLAB.
 4. Розроблена генеративно-змагальна нейронна мережа для генерації аберометричних даних. Створення та навчання мережі здійснювались в середовищі Kaggle мовою програмування Python із залученням бібліотек функцій TensorFlow, SciPy та ін.
 5. Розроблена нейронна мережа для прогнозування коефіцієнтів Церніке вищих порядків на основі значень коефіцієнтів нижчих порядків. Створення та навчання мережі здійснювались в середовищі Kaggle мовою програмування Python із залученням бібліотек функцій TensorFlow, SciPy та ін.
 6. Для модифікації методу із масивом лазерних випромінювачів розроблено класифікаційну нейронну мережу для встановлення відповідностей між променями сканування та відбитками на сітківці. Створення та навчання мережі здійснювались в середовищі Google Colaboratory мовою програмування Python із залученням бібліотек функцій TensorFlow, SciPy та ін.
 7. Результати дисертаційних досліджень використані як матеріали при підготовці та викладанні курсу лекційних і практичних занять (комп'ютерного практикуму) з дисципліни “Основи нейромережних

технологій” та викладанні курсу лекційних і лабораторних занять з дисципліни “Системи комп’ютерного зору” другого (магістерського) рівня вищої освіти спеціальності 172 «Електронні комунікації та радіотехніка» освітньо-професійної програми «Інформаційно-обчислювальні засоби радіоелектронних систем», що засвідчено відповідним актом.

Ключові слова: рейтресинговий метод аберометрії, штучні нейронні мережі, генерування даних, генеративно-змагальні нейронні мережі, навчання з підкріпленням, надроздільна здатність, комп’ютерне моделювання, обробка зображень.

ABSTRACT

Yaroshenko M.O. Modified Neural Network Method for Ray Tracing Aberrometry of the Eye. – Qualification scientific work as a manuscript.

Dissertation for the degree of Philosophy Doctor in the specialty 172 "Telecommunications and Radio Engineering." – National Technical University of Ukraine "Igor Sikorsky Kyiv Polytechnic Institute", Kyiv, 2025.

The dissertation addresses an important and relevant scientific and applied problem—improving the ray-tracing method of eye aberrometry by applying machine learning methods, particularly artificial neural networks, to enhance its accuracy. The dissertation research consists of an introduction and five chapters, which present and substantiate the main findings of the study.

The introduction establishes the relevance of the dissertation and highlights its connection with scientific programs, plans, and research topics of Igor Sikorsky Kyiv Polytechnic Institute. The objectives of the research are formulated, and the tasks necessary for achieving these objectives are outlined. The object, subject, and methods of the research are defined, and information about the scientific novelty and practical significance of the obtained results is provided. Information about the publication of the research findings in peer-reviewed journals and their presentation at scientific conferences is also included.

The first chapter examines the ray-tracing method of eye aberrometry, its limitations, and its advantages. A review of the literature reveals opportunities to improve the ray-tracing method for eye aberrometry and identifies challenges that may arise during research. Based on this review, a list of tasks is formulated, the completion of which aims to develop a modified neural network-based ray-tracing method for aberrometry. First, the issue of insufficient datasets for aberration measurements is proposed to be addressed, as this problem complicates not only the achievement of this research's objectives but also the future study and development of ophthalmic aberrometry methods in general. Second, the development and analysis of a modification to the ray-tracing method using an existing, improved design of a ray-tracing aberrometer are planned. However, if shortcomings are

identified, the third task focuses on developing a modification of the method that may require an alternative measurement approach and, consequently, a different optical system for implementing the method. As the fourth task, the research and development of correction methods for determining aberrations within the proposed neural network-based aberrometry method are outlined. The development of a super-resolution method for aberration maps is identified as the fifth task. This is motivated by the possibility that, during the practical implementation of the modified ray-tracing aberrometry method developed in the study, the creation of serial measuring instruments may face challenges in measuring certain Zernike coefficients that describe higher-order aberrations.

The second chapter describes the development of a method for generating ophthalmic aberrometric data in the form of Zernike coefficient sets using a generative adversarial network (GAN). Given that the training dataset consisted of only 50 sets, attention was devoted to identifying specialized data augmentation methods to improve network training. A data augmentation method based on inverse transformations was employed. The transformations included not only manipulations of coefficient values in the vector but also operations on pixel images of wavefront distortions generated from the sets of coefficients. To verify the method's feasibility, a GAN architecture was created and trained. The training results were evaluated using creativity, heredity, and diversity metrics.

The third chapter provides a description of the modification of the ray-tracing aberrometry method for simultaneous scanning of multiple pupil points through the use of multiple light emitters. To address the challenge posed in this scenario, specifically the problem of incorrect matching of reflection coordinates and beam scanning positions, a method based on a classification neural network and the Hungarian algorithm was developed. Information about long short-term memory (LSTM) layers as the core components of the proposed method is presented. The neural network was trained, and the results were evaluated. Given the constraints imposed by implementation challenges, a solution was justified to develop a neural

network modification of the ray-tracing aberrometry method that would use a different measurement approach requiring an alternative optical system.

The fourth chapter presents a description of the optical system designed for implementing the proposed neural network-based modification of the ray-tracing method, an example of initial data processing, a method for calculating the first approximation for aberration determination using a neural network, as well as a description of the agent and the reinforcement learning environment designed for refining the results. The chapter includes a description of a simulation performed in specialized software, which provided the basis for proposing an algorithm to extract information about the shape of light spots on detectors. This process involves illuminating the eye in a manner similar to the Hartmann-Shack method—by creating a point light source on the retina at the intersection with the principal optical axis. A feedforward artificial neural network is described, which evaluates a set of Zernike coefficients based on the signatures of light spots on detectors. These coefficients describe the wavefront distortions of the light reflected from the retina and passing through the optical system of the eye. The neural networks were trained, and the results are presented. A small subset of samples (10 instances) was used to verify the functionality and train the agent for result refinement. An environment simulating the optical system used for measurements was developed for the agent. An agent based on the Deep Q-Learning method was created, along with an additional agent based on the Proximal Policy Optimization method, which was trained to explore its feasibility as a modification of Deep Q-Learning.

The fifth chapter describes a method based on artificial neural networks to achieve super-resolution for wavefront distortions. To determine higher-order Zernike coefficients from lower-order coefficient values, a convolutional artificial neural network was developed, trained, and the results were presented. A dataset comprising images of cloudy skies was used, with fragments of these images transformed into normalized representations of wavefront distortions. These representations were then utilized to calculate Zernike coefficients and create the training dataset.

In the dissertation, the following new scientific results have been obtained:

1. The ray-tracing method of eye aberrometry has been further developed through modifications involving the application of neural networks at various stages of the method's functionality: initial approximation of aberration characteristics, result refinement, and the evaluation of higher-order aberrations. These modifications significantly enhanced the method's accuracy. Specifically, simulation evaluations showed a 25% improvement in defocus accuracy compared to the existing iTrace aberrometer when image distortions on the detector did not exceed 0.1 in terms of Jaccard distance. Additionally, the proposed modification reduces the requirements for the optical system necessary to implement the device, accelerates the measurement process through simultaneous scanning, and enables the prediction of higher-order Zernike coefficients based on lower-order aberration coefficients (with a prediction error not exceeding 4% for 6th- and 7th-order coefficients using the SMAPE metric).
2. The generation of aberrometric data in the form of Zernike coefficient vectors has been further developed. This was achieved through the application of a generative adversarial neural network developed within the scope of this work. Transforming Zernike coefficient sets into two-dimensional images expanded the possibilities for input data augmentation, which is especially relevant given the limited availability of clinical data and the significant demand for training datasets in developing artificial neural network-based solutions for ophthalmic aberrometry. The proposed method is suitable for generating data with a distribution similar to the training dataset (Fréchet distance of 0.7), while simultaneously ensuring that the generated data are not copies of real samples (92% creativity metric) and exhibit diversity (corresponding metric value of 3.64, with an optimal value of 3.83).

3. A modification of the ray-tracing aberrometry method for simultaneous scanning of multiple pupil coordinates using an array of laser emitters has been proposed. The use of a neural network for classification solved the problem of incorrect matching between scanning beams and their reflections on the retina. The application of this modification resulted in a reduced confidence interval, positively impacting precision: for instance, when scanning 16 pupil coordinates simultaneously, the confidence interval decreased by a factor of 4.4 within the time budget of the iTrace aberrometer. The limitations identified during this study, which accompany the implementation of the method, demonstrated the necessity of developing a modification that, if required, would involve an alternative measurement approach and, accordingly, a different optical system.

Practical results of the research obtained:

1. An experimental implementation of the measurement process model for the proposed neural network-based modification of the ray-tracing method of eye aberrometry was developed in the Zemax environment. For this model, an image processing algorithm was created in the MATLAB software package to prepare data for determining the wavefront distortion coefficients of light reflected from the retina.
2. A neural network for determining Zernike coefficients of the wavefront based on the signatures of light spots on photodetectors was developed for the neural network-based modification of the ray-tracing method of aberrometry. The development and training of the neural network were carried out in the Kaggle environment using Python programming language with the inclusion of libraries such as TensorFlow, SciPy, and others.
3. A reinforcement learning agent (Deep Q-Network method) was developed to refine the initial approximation in determining Zernike coefficients. The

preparation, training of the agent, and environment development were performed in the MATLAB software package.

4. A generative adversarial neural network (GAN) was developed for generating aberrometric data. The creation and training of the network were conducted in the Kaggle environment using Python programming language with the inclusion of libraries such as TensorFlow, SciPy, and others.
5. A neural network for predicting higher-order Zernike coefficients based on the values of lower-order coefficients was developed. The network's creation and training were performed in the Kaggle environment using Python programming language with the inclusion of libraries such as TensorFlow, SciPy, and others.
6. For the modification of the method using an array of laser emitters, a classification neural network was developed to establish correspondences between scanning beams and their reflections on the retina. The network's creation and training were performed in the Google Colaboratory environment using Python programming language with the inclusion of libraries such as TensorFlow, SciPy, and others.
7. The results of the dissertation research have been utilized as materials in the preparation and delivery of lecture and practical sessions (computer-based workshops) for the course “Fundamentals of Neural Network Technologies” and in the delivery of lecture and laboratory sessions for the course “Computer Vision Systems” at the second (master's) level of higher education in the specialty 172 “Electronic Communications and Radio Engineering” within the educational and professional program "Information and Computing Tools for Radio Electronic Systems," as documented by the corresponding report.

Keywords: ray-tracing aberrometry method, artificial neural networks, data generation, generative adversarial neural networks, reinforcement learning, super-resolution, computer modeling, image processing.

Список публікацій здобувача

1. Ярошенко М. О., Варфоломєєв А. Ю., Яганов П. О. Ієрархічна згорткова нейронна мережа для підвищення роздільної здатності інфрачервоних зображень. Мікросистеми, електроніка та акустика. 2021. Том 26, вип. 1. С. 230603.1-230603.7, DOI: <https://doi.org/10.20535/2523-4455.mea.230603> (фахове видання категорії Б).
2. Ярошенко М. О. Збільшення кількості одночасно задіяних променів зондування у рейтрейсинговій аберометрії ока шляхом застосування нейронної мережі. Таврійський національний університет імені В. І. Вернадського, Вчені записки ТНУ імені В. І. Вернадського. Серія: Технічні науки. 2022. Том 33 (72), № 5. С. 176-182, DOI: <https://doi.org/10.32782/2663-5941/2022.5/26> (фахове видання категорії Б).
3. Ярошенко М. О. Генерування аберометричних даних шляхом застосування генеративно-змагальної нейронної мережі. Мікросистеми, електроніка та акустика. 2023. Том 28, вип. 3. С. 286366.1–286366.8, DOI: <https://doi.org/10.20535/2523-4455.mea.286366> (фахове видання категорії Б).
4. Ярошенко М.О., Яганов П.О. Вимірювання нейромережею хвильового фронту на основі форми світлового відбитку. Вісник Хмельницького національного університету. Серія: Технічні науки. 2024. Том 341, № 5. С. 264–269, DOI: 10.31891/2307-5732-2024-341-5-38 (фахове видання категорії Б).
5. Ярошенко М. О., Яганов П. О. Модифікація методу рейтрейсингової аберометрії ока. Тези доповідей міжнародної наукової інтернет-конференції "Світ наукових досліджень. Випуск 10". Тернопіль, 23-24 червня 2022 р. С. 63-68 (0,6 ECTS credits), ISSN 2786-6823, URL:

- <https://www.economy-confer.com.ua/full-article/3793/> (матеріали конференції)
6. Ярошенко М. О., Яганов П. О. Збільшення обсягу одночасних вимірювань рейтрейсинговим методом аберометрії ока з використанням нейронної мережі. Тези доповідей міжнародної наукової інтернет-конференції "Світ наукових досліджень. Випуск 12". Тернопіль, 29-30 вересня 2022 р. С. 125-131 (0,6 ECTS credits). ISSN 2786-6823. URL: <https://www.economy-confer.com.ua/full-article/3932/> (матеріали конференції)
 7. Ярошенко М.О., Яганов П.О. Апроксимація аберацій вищих порядків шляхом застосування нейронної мережі: тези доповідей міжнародної наукової інтернет-конференції "Світ наукових досліджень. Випуск 22". Тернопіль, 27-28.09.2023, С. 81-85 (0,6 ECTS credits). ISSN 2786-6823 (print), URL: <https://www.economy-confer.com.ua/full-article/4756/> (матеріали конференції)
 8. Ярошенко М. О., Яганов П. О. Оцінка коефіцієнтів Церніке в рейтрейсинговій аберації ока з використанням згорткової нейронної мережі. Штучний інтелект у науці та освіті (AISE 2024): збірник матеріалів міжнародної наукової конференції, Київ, 1-2 березня 2024 р. С. 588-592 (0,6 ECTS credits), DOI: <http://doi.org/10.35668/978-966-479-141-7> (матеріали конференції)
 9. Ярошенко М. О. Визначення хвильового фронту нейронною мережею за сигнатурою світлової плями. Тези доповідей міжнародної наукової інтернет-конференції "Світ наукових досліджень. Випуск 33". Тернопіль, 19-20 вересня 2024 р. С. 63-67 (0,6 ECTS credits). ISSN 2786-6823 (print), URL: <https://www.economy-confer.com.ua/full-article/5702/> (матеріали конференції)

ЗМІСТ

ПЕРЕЛІК СКОРОЧЕНЬ.....	20
ВСТУП	22
РОЗДІЛ 1. Загальні відомості про аберометрію, аналіз рейтрейсингового методу та можливості його вдосконалення	32
1.1. Загальна інформація про око людини.....	33
1.2. Аберації.....	38
1.3. Наявні методи аберометрії.....	40
1.4. Розрахунок коефіцієнтів Церніке за поперечними аберациями	41
1.5. Метод із використанням датчика Гартмана-Шека	43
1.6. Рейтрейсинговий метод аберометрії.....	44
1.7. Аналіз можливостей вдосконалення рейтрейсингового методу аберометрії	46
Висновок до Розділу 1	56
РОЗДІЛ 2. Генерація аберометричних даних	58
2.1. Аналіз існуючих досліджень і публікацій.....	59
2.1.1. Існуючі вибірки офтальмологічних досліджень	59
2.1.2. Генеративно-змагальні нейронні мережі.....	60
2.2. Запропонований метод для генерування аберометричних даних.....	65
2.2.1. Структура методу навчання	65
2.2.2. Архітектура мереж	67
2.2.3. Навчання нейронних мереж	68
2.3. Результати навчання та їх оцінка	69
Висновок до Розділу 2	72
РОЗДІЛ 3. Одночасне сканування масивом випромінювачів для рейтрейсингового методу аберометрії	73

3.1. Одночасне сканування	74
3.2. Представлення даних та навчаюча вибірка.....	75
3.3. Класифікаційна нейронна мережа	78
3.4. Навчання нейронної мережі	82
3.5. Результати.....	83
Висновок до Розділу 3	86
РОЗДІЛ 4. Нейромережна модифікація методу рейтрейсингової абераметрії	88
4.1. Процес вимірювань	89
4.2. Первинна обробка вимірювань	91
4.3. Визначення коефіцієнтів Церніке за зображеннями	93
4.4. Визначення навчання з підкріпленням.....	96
4.5. Середовище для навчання з підкріпленням.....	101
4.6. Дані для моделювання	106
4.7. Нейронна мережа першого наближення	108
4.8. Застосування DQN для корекції першого наближення	111
4.9. Застосування PPO для корекції першого наближення.....	114
4.10. Оцінка точності модифікованого методу	120
4.11. Можливості адаптації методу для практичного застосування.....	123
Висновок до Розділу 4	124
РОЗДІЛ 5. Надроздільна здатність для хвильового фронту аберацій	126
5.1. Надроздільна здатність засобами штучних нейронних мереж	127
5.2. Нейронна мережа для надроздільної здатності хвильового фронту	127
5.3. Навчання нейронної мережі та його результат.....	130
Висновок до Розділу 5	132
ВИСНОВКИ	133
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ	138
ДОДАТОК А. ДОВІДКИ ПРО ВПРОВАДЖЕННЯ	149
ДОДАТОК Б. АКТ ВПРОВАДЖЕННЯ	151

ПЕРЕЛІК СКОРОЧЕНЬ

МПВ – Марківський процес вирішування

СКВ – середнє квадратичне відхилення

ФАР – фазова антенна решітка

BCLSR – Bidirectional Convolutional LSTM Neural Network for Image Super-Resolution

CIFAR-10 – вибірка даних, зібрана Canadian Institute For Advanced Research (CIFAR)

DAG - Data Augmentation Optimized for Generative-Adversarial Neural Networks

DDPG – Deep Deterministic Policy Gradient

DQN – Deep Q-Network

ELU – Exponential Linear Unit

FID - Frechet Inception Distance

GAN – Generative-Adversarial Neural Network

GDM – Gradient Descent with Momentum

GELU – Gaussian Error Linear Unit

LSTM – Long Short-Term Memory

MDP – Markov Decision Process

MNIST – вибірка даних, зібрана Mixed National Institute of Standards and Technology

PID - Proportional–Integral–Derivative (Controller)

PPO – Proximal Policy Optimization

ReLU – Rectified Linear Unit

RMSP – Root Mean Square Propagation

SMAPE – Symmetric Mean Absolute Percentage Error

SS-GAN – Self-Supervised Generative-Adversarial Neural Network

SSIM – Structural Similarity Index Measure

SWIMSEG – Singapore Whole Sky Imaging Segmentation Database

WGAN – Wasserstein Generative-Adversarial Neural Network

WGAN GP - Wasserstein Generative-Adversarial Neural Network with Gradient Penalty

ВСТУП

Актуальність роботи. Аберації оптичної системи ока являють собою відхилення від ідеального зображення, яке формується на сітківці через оптичні недосконалості ока. Вони можуть бути викликані різними чинниками, такими як неправильна форма рогівки, неоднорідність кришталика або інших елементів оптичної системи. Існує кілька видів аберацій, включаючи сферичні, коматичні, астигматичні та ін. Кожен із цих типів аберацій має свої характеристики та впливає на якість зображення, яке бачить людина. Наприклад, сферичні аберації виникають через неправильну форму ока, що призводить до розфокусування зображення, тоді як астигматичні аберації спричиняють перекручування зображення.

Вплив аберацій на якість життя людини є значним, оскільки зір є одним із найважливіших сенсорних відчуттів, що забезпечує орієнтацію в просторі, виконання повсякденних завдань та взаємодію з навколишнім середовищем. Наприклад, аберації можуть спричиняти такі проблеми зі зором, як розмитість зображення, подвоєння та гало. Зі свого боку, це може призвести до труднощів у читанні, роботі за комп'ютером, водінні автомобіля та виконанні інших завдань, що вимагають високої гостроти зору. В результаті, якість життя людини значно знижується, оскільки погіршення зору може призвести до психологічного дискомфорту, зниження продуктивності праці та обмеження фізичної активності. Також аберації можуть викликати підвищену втому очей, головні болі та інші симптоми. У випадку серйозних аберацій, таких як кератоконус, потрібне спеціальне лікування, включаючи хірургічні втручання.

Тому питання виявлення та корекції аберацій є надзвичайно важливим для сучасної офтальмології. Це не тільки покращує якість життя пацієнтів, їхню здатність до виконання важливих задач, але й сприяє запобіганню розвитку серйозних ускладнень, пов'язаних з порушеннями зору. Якісна діагностика аберацій дозволяє розробляти індивідуальні плани лікування, що враховують унікальні особливості кожного пацієнта та забезпечують максимальну ефективність корекції зору.

Аберометрія є галуззю офтальмології, яка спрямована на вимірювання та аналіз аберацій оптичної системи ока. Вона стає все більш актуальною завдяки зростаючій потребі у високоточній діагностиці та корекції зору. Історично, перші методи аберометрії базувалися на суб'єктивних показаннях пацієнтів, однак з розвитком технологій з'явилися більш складні та точні методи. Перші спроби вимірювання аберацій датуються ще часами Кристофера Шейнера, який займався розробкою телескопів, астрономією та дослідженням ока.

Сучасні методи аберометрії дозволяють не лише виявляти аберації, але й кількісно оцінювати їхній вплив на якість зору. Це важливо для розробки індивідуальних планів корекції, що враховують унікальні характеристики кожного пацієнта. Точність і детальність методів та систем, які використовуються в сучасній аберометрії, дозволяють значно підвищити ефективність корекції зору, зокрема за допомогою лазерної хірургії, контактних лінз та окулярів. Тому аберометрія є невіддільною частиною сучасної офтальмологічної практики, спрямованої на покращення якості життя пацієнтів з порушеннями зору.

Одним із важливих аспектів розвитку аберометрії є поєднання її з іншими методами діагностики та корекції зору. Наприклад, сучасні технології дозволяють інтегрувати дані аберометрії з результатами топографії рогівки, що забезпечує більш комплексний підхід до діагностики та лікування аберацій. Також важливим напрямком є використання методів машинного навчання та штучного інтелекту для автоматизації процесу аналізу даних, що дозволяє значно підвищити точність та швидкість діагностики.

Існує декілька методів аберометрії, які дозволяють виміряти аберації ока з різним рівнем точності та складності. Одним із найпоширеніших є метод з використанням сенсора Гартмана-Шека [1], який застосовується в аналізі викривлень хвильового фронту випромінювання, що проходить через око. Цей метод базується на фокусуванні відбитого від сітківки лазерного випромінювання з допомогою масиву лінз на світлочутливому детекторі. Отримані дані

використовуються для розрахунку аберацій за допомогою математичних методів, спрямованих на визначення коефіцієнтів Церніке [2], що описують викривлення хвильового фронту. Метод Гартмана-Шека є відносно простим у реалізації та забезпечує високу точність вимірювань, що робить його популярним у сучасній офтальмологічній практиці. Втім, він також має недоліки, зокрема складнощі зі збільшенням роздільної здатності через обмеженість вдосконалення самого сенсора.

Іншим важливим методом є рейтрейсинговий метод аберометрії [3, 4], який заснований на покроковому скануванні оптичної системи ока. Цей метод забезпечує широкий діапазон вимірюваних аберацій, на відміну від методів одночасного вимірювання. Він передбачає відстеження шляху світлових променів, що дозволяє визначати найсильніші відхилення. Рейтрейсинговий метод є більш складним у реалізації та вимагає швидкого обладнання, оскільки покрокове сканування має відбуватися швидше, ніж несвідомі мікрорухи ока, проте забезпечує точніші результати, особливо у випадках складних аберацій, які важко виявити іншими методами.

Рейтрейсинговий метод аберометрії в сучасному стані має потенціал до вдосконалення та особливості, які обмежують результативність методу. Зокрема похибка вимірювання дефокусу (сфери) сучасними рейтрейсинговими аберометрами сягає значень, сумірних середнім значенням коефіцієнтів Церніке вищих порядків. Також існує проблема високої ціни оптичного обладнання, потрібного для керування променем сканування. Кожне вимірювання здійснюється окремо для кожної точки на зіниці, що може збільшувати час проведення діагностики та накладає обмеження на подальше збільшення обсягу вимірювальних положень лазерного променя. Малий обсяг вимірювань протягом однієї процедури діагностики збільшує довірчий інтервал, що негативно впливає на прецизійність вимірювань [5].

Для розв'язання цих проблем необхідно розробляти нові алгоритми обробки даних, які дозволять підвищити точність та швидкість діагностики. Це може включати використання методів штучного інтелекту, як-от машинне

навчання, для покращення процесу аналізу даних. Вдосконалення рейтрейсингового методу аберометрії засобами нейронних мереж може значно покращити якість зору пацієнтів та підвищити ефективність корекції зору, що є важливим завданням сучасної офтальмології. Це не лише покращить якість життя пацієнтів, але й сприятиме розвитку нових технологій та методик у цій галузі. Інтеграція вдосконалених алгоритмів обробки даних у сучасні діагностичні системи дозволить створити більш якісні та доступні методи діагностики аберацій ока.

Зв'язок роботи з науковими програмами, планами, темами. Дисертаційна робота виконувалась згідно з тематичними планами НДР КПІ ім. Ігоря Сікорського і кафедри КЕОА в межах НДР «Підвищення роздільної здатності інфрачервоного зображення з використанням згорткової нейронної мережі», РК №0121U111107, а також НДР «Модифікований нейромережний метод рейтрейсингової аберометрії ока», РК №0124U005087, згідно з основними науковими напрямками діяльності КПІ ім. Ігоря Сікорського та пріоритетним напрямом розвитку науки і техніки України «Інформаційні та комунікаційні технології» (Додаток А). Також результати дисертаційних досліджень використані як матеріали при підготовці та викладанні курсу лекційних і практичних занять (комп'ютерного практикуму) з дисципліни “Основи нейромережних технологій” та викладанні курсу лекційних і лабораторних занять з дисципліни “Системи комп'ютерного зору” другого (магістерського) рівня вищої освіти спеціальності 172 «Електронні комунікації та радіотехніка» освітньо-професійної програми «Інформаційно-обчислювальні засоби радіоелектронних систем», що затверджено відповідним актом (Додаток Б).

Мета і завдання дослідження. Метою дисертаційної роботи є вирішення актуальної та важливої науково-прикладної задачі – вдосконалення рейтрейсингового методу аберометрії засобами машинного навчання, зокрема штучними нейронними мережами, задля підвищення точності вимірювань.

Досягнення мети передбачає розв'язання наступних завдань:

1. Аналіз рейтресингового методу аберометрії задля актуалізації можливостей для його вдосконалення.
2. Пошук наявних модифікацій як основи для подальших досліджень.
3. Вивчення аспектів рейтресингового методу аберометрії, які можуть бути покращені застосуванням штучних нейронних мереж.
4. Створення методів, що уможливають або поліпшують використання штучних нейронних мереж в контексті даної роботи.
5. Розробка дослідної реалізації модифікованого нейромережного методу рейтрейсингової аберометрії.

Об'єкт дослідження: аберометрія оптичної системи ока людини.

Предмет дослідження: модифікація рейтрейсингового методу аберометрії засобами машинного навчання, зокрема – застосуванням штучних нейронних мереж.

Методи дослідження: методологія роботи загалом складається з методів машинного навчання, а саме штучних нейронних мереж для генерації, класифікації та перетворення даних, та методів визначення, представлення та обробки даних про аберації людського ока.

Наукова новизна отриманих результатів полягає в наступному:

1. Набув подальшого розвитку рейтрейсинговий метод аберометрії ока шляхом модифікації із застосуванням нейронних мереж на різних етапах функціонування методу: перше наближення визначення характеристик аберацій, уточнення результату та оцінка аберацій вищих порядків. Це дозволило підвищити точність методу. Зокрема за оцінками в симуляції точність при визначенні дефокусу підвищено на 25% порівняно з існуючим аберометром iTrace у випадку викривлень зображення на детекторі не більше ніж 0.1 за відстанню Жаккара. Також запропонована модифікація дозволяє знизити вимоги до оптичної системи, необхідної для реалізації приладу, пришвидшити процес вимірювання шляхом одночасного сканування, а також надає можливість прогнозувати

значення коефіцієнтів Церніке високих порядків на основі коефіцієнтів аберацій нижчих порядків (при апроксимації коефіцієнтів 6 та 7 порядків похибка становить не більше 4% за метрикою SMAPE).

2. Набуло подальшого розвитку генерування aberометричних даних у вигляді векторів коефіцієнтів Церніке. Це досягнуто шляхом застосування розробленої в рамках роботи генеративно-змагальної нейронної мережі. Використання перетворення наборів коефіцієнтів Церніке у двовимірне зображення розширило можливості аугментації вхідних даних, що є особливо актуальним в умовах низької доступності клінічних даних та значних потреб у навчаючих вибірках для розробки рішень на основі штучних нейронних мереж для використання в офтальмологічній aberометрії. Розроблений метод придатний до синтеза даних, що мають розподіл, схожий з навчаючою вибіркою (відстань Фреше дорівнює 0.7), і які одночасно не є копією реальних примірників (92% за метрикою творчості) та примірники яких є різноманітними (значення відповідної метрики дорівнює 3.64, оптимальним є значення 3.83).
3. Запропоновано модифікацію рейтрейсингового методу aberометрії для одночасного сканування декількох зіничних координат із застосуванням масиву лазерних випромінювачів. Використання нейронної мережі для класифікації стало розв'язанням проблеми некоректного зіставлення променів сканування та їхніх відбитків на сітківці. Результатом застосування модифікації є зменшення довірчого інтервалу, що позитивно впливає на прецизійність: наприклад, при скануванні одночасно 16 зіничних координат довірчий інтервал зменшується в 4.4 рази для часового бюджету aberометра iTrace. Визначені в ході цієї роботи обмеження, які супроводжуватимуть імплементацію методу, показали необхідність у розробці модифікації, яка б потребувала, за необхідності, іншого методу вимірювання та, відповідно, іншої оптичної системи.

Практична значущість отриманих результатів визначається, зокрема такими результатами:

1. Розроблена дослідна реалізація моделі процесу вимірювань для запропонованої нейромережної модифікації рейтрейсингового методу аберометрії ока в середовищі Zemax. Для моделі розроблено алгоритм обробки зображень в програмному пакеті MATLAB, який використовується для підготовки даних для подальшого визначення коефіцієнтів хвильового фронту відбитого від сітківки світла.
2. Розроблена нейронна мережа для визначення коефіцієнтів Церніке хвильового фронту по сигнатурах світлових плям на фотодетекторах для нейромережної модифікації методу рейтрейсингової аберометрії. Розробка та тренування нейронної мережі здійснювалося в середовищі Kaggle мовою програмування Python із залученням бібліотек функцій TensorFlow, SciPy та ін.
3. Розроблена програма-агент навчання з підкріпленням (метод Deep Q-Network) для уточнення першого наближення при визначенні коефіцієнтів Церніке. Підготовка агента та його навчання, а також розробка середовища здійснювались в програмному пакеті MATLAB.
4. Розроблена генеративно-змагальна нейронна мережа для генерації аберометричних даних. Створення та навчання мережі здійснювались в середовищі Kaggle мовою програмування Python із залученням бібліотек функцій TensorFlow, SciPy та ін.
5. Розроблена нейронна мережа для прогнозування коефіцієнтів Церніке вищих порядків на основі значень коефіцієнтів нижчих порядків. Створення та навчання мережі здійснювались в середовищі Kaggle мовою програмування Python із залученням бібліотек функцій TensorFlow, SciPy та ін.
6. Для модифікації методу із масивом лазерних випромінювачів розроблено класифікаційну нейронну мережу для встановлення

відповідностей між променями сканування та відбитками на сітківці. Створення та навчання мережі здійснювались в середовищі Google Colaboratory мовою програмування Python із залученням бібліотек функцій TensorFlow, SciPy та ін.

7. Результати дисертаційних досліджень використані як матеріали при підготовці та викладанні курсу лекційних і практичних занять (комп'ютерного практикуму) з дисципліни “Основи нейромережних технологій” та викладанні курсу лекційних і лабораторних занять з дисципліни “Системи комп'ютерного зору” другого (магістерського) рівня вищої освіти спеціальності 172 «Електронні комунікації та радіотехніка» освітньо-професійної програми «Інформаційно-обчислювальні засоби радіоелектронних систем», що засвідчено відповідним актом.

Отримані в дисертації результати дослідження можуть бути використані:

1. При розробці програмно-апаратних комплексів для визначення аберацій ока.
2. В навчальному процесі вищих навчальних закладів України при підготовці фахівців у галузі конструювання електронно-обчислювальної та оптико-електронної апаратури, а також фахівців із розробки ІТ-рішень, зокрема програмних та апаратних обчислювальних засобів.
3. В результатах науково-дослідних робіт за суміжною тематикою.

Особистий внесок здобувача. Основні ідеї та наукові результати дисертаційної роботи отримані автором особисто і висвітлено у дев'яти наукових працях, представлених відповідному списку, серед яких роботи [2,3,9] виконані одноосібно.

У наукових роботах, опублікованих у співавторстві, здобувачем особисто належить: [3] – підготовка середовища для використання методів навчання, [1,4-7] – підготовка архітектур нейронних мереж.

Апробація результатів дисертації. Основні результати дисертації пройшли апробацію на наступних конференціях:

1. Ярошенко М. О., Яганов П. О. Модифікація методу рейтрейсингової аберометрії ока. Тези доповідей міжнародної наукової інтернет-конференції "Світ наукових досліджень. Випуск 10". Тернопіль, 23-24 червня 2022 р. С. 63-68 (0,6 ECTS credits), ISSN 2786-6823, URL: <https://www.economy-confer.com.ua/full-article/3793/>
2. Ярошенко М. О., Яганов П. О. Збільшення обсягу одночасних вимірювань рейтрейсинговим методом аберометрії ока з використанням нейронної мережі. Тези доповідей міжнародної наукової інтернет-конференції "Світ наукових досліджень. Випуск 12". Тернопіль, 29-30 вересня 2022 р. С. 125-131 (0,6 ECTS credits), URL: <https://www.economy-confer.com.ua/full-article/3932/>
3. Ярошенко М.О., Яганов П.О. Апроксимація аберацій вищих порядків шляхом застосування нейронної мережі: тези доповідей міжнародної наукової інтернет-конференції "Світ наукових досліджень. Випуск 22". Тернопіль, 27-28.09.2023, С. 81-85 (0,6 ECTS credits). ISSN 2786-6823 (print), URL: <https://www.economy-confer.com.ua/full-article/4756/>
4. Ярошенко М. О., Яганов П. О. Оцінка коефіцієнтів Церніке в рейтрейсинговій аберометрії ока з використанням згорткової нейронної мережі. Штучний інтелект у науці та освіті (AISE 2024): збірник матеріалів міжнародної наукової конференції, Київ, 1-2 березня 2024 р. С. 588-592 (0,6 ECTS credits), DOI: <http://doi.org/10.35668/978-966-479-141-7>
5. Ярошенко М. О. Визначення хвильового фронту нейронною мережею за сигнатурою світлової плями. Тези доповідей міжнародної наукової інтернет-конференції "Світ наукових досліджень. Випуск 33". Тернопіль, 19-20 вересня 2024 р. С. 63-67 (0,6 ECTS credits). ISSN 2786-6823 (print), URL: <https://www.economy-confer.com.ua/full-article/5702/>

Публікації. За темою дисертації опубліковано 9 наукових праць, із них 4 статті у наукових фахових виданнях України, 5 тез доповідей у збірниках матеріалів науково-технічних конференцій.

Структура та обсяг дисертаційної роботи. Дисертація складається зі вступу, п'яти розділів основної частини, висновків, списку використаних джерел і додатків. Загальний об'єм дисертації складає 151 сторінку, з них 116 сторінок основного тексту, 4 таблиці, 52 рисунків, 96 літературних джерел та 2 додатки.

РОЗДІЛ 1. Загальні відомості про aberометрію, аналіз рейтрейсингового методу та можливості його вдосконалення

У сучасній офтальмології та оптометрії точність діагностики оптичних характеристик ока є критично важливою для якісної корекції зору та запобігання серйозним захворюванням. Одним із ключових елементів зорової системи людини є око, складна оптична система, яка складається з рогівки, кришталика, склоподібного тіла та сітківки. Рогівка і кришталик є основними компонентами, що заломлюють світло, тоді як у сітківці світлові сигнали перетворюються на нервові імпульси, що передаються до мозку.

Одним із завдань сучасної офтальмології є зменшення або усунення аберацій в оптичній системі ока. Аберації – це відхилення від ідеального зображення, яке формується на сітківці через оптичні недосконалості ока. Вони можуть бути викликані неправильною формою рогівки, неоднорідністю кришталика або іншими оптичними елементами. Ці відхилення призводять до погіршення якості зору, що вимагає ретельного аналізу і корекції.

Для визначення аберацій використовуються різні методи aberометрії. Aberометрія – це сукупність методів та технік, призначених для вимірювання оптичних аберацій ока. Основними методами є аналіз викривлень хвильового фронту сенсором Гартмана-Шека та рейтрейсинговий метод. Кожен із цих методів має свої особливості, переваги та обмеження, які розглядаються в даному розділі.

В останні роки значна увага приділяється використанню штучних нейронних мереж для вдосконалення методів aberометрії. Штучні нейронні мережі, які є основою сучасних систем штучного інтелекту, здатні аналізувати великі обсяги даних та виявляти складні залежності. Їх використання у сфері aberометрії дозволяє підвищити точність діагностики та розробити нові підходи до корекції зору.

Цей розділ присвячений огляду теоретичних основ та методологічних підходів, що стосуються вищезазначених тем. Розглядається будова ока та аберації оптичної системи, наводиться аналіз різних методів aberометрії та

можливості вдосконалення з використанням штучних нейронних мереж для методу рейтрейсингової aberометрії. Такий підхід дозволяє не лише поглибити розуміння основних аспектів, але й показати перспективи розвитку сучасної офтальмології.

1.1. Загальна інформація про око людини

Око людини — це складний орган, який відповідає за сприйняття світла і передачу візуальної інформації до мозку. Воно складається з декількох систем, які взаємодіють для формування чіткого зображення. Око не лише забезпечує можливість бачити, а також активно адаптується до різних умов освітлення і відстаней. Завдяки своїй високій чутливості та здатності до швидкої адаптації, око є одним з найважливіших органів чуття людини.

Структура людського ока показана на Рис.1.1. Зовнішня частина оптичної системи складається з двох частин: рогівки та склери. Рогівка прозора і приблизно сферична з радіусом кривизни близько 8 мм [6]. Склера є щільною, білою, непрозорою, волокнистою тканиною, яка головним чином виконує захисну функцію і є приблизно сферичною з радіусом кривизни близько 12 мм. Центри кривизни склери та рогівки розділені приблизно на 5 мм.




Рис.1.1. – Структура людського ока. Вузлові точки P, P', N, N' наведено для розслабленого ока [6].

Середня частина оптичної системи ока – це увеальний тракт. Він складається з райдужки спереду, хороїду ззаду та циліарного тіла між ними. Райдужка виконує важливу оптичну функцію, регулюючи розмір свого отвору – зіниці, а циліарне тіло важливе для процесу акомодатії. Циліарне тіло та хороїд підтримують важливі вегетативні процеси.

Внутрішня частина оптичної системи ока – це сітківка, яка є продовженням центральної нервової системи та з'єднана з мозком через зоровий нерв.

Око можна поділити на три камери:

1. Передня камера, між рогівкою та райдужкою, яка містить водянисту рідину.
2. Задня камера, між райдужкою, циліарним тілом та кришталиком, яка містить водянисту рідину.
3. Склоподібна камера, між кришталиком та сітківкою, яка містить прозору безбарвну та желеподібну масу, що називається склоподібним тілом або склоподібною рідиною.

Принципи формування зображення оком аналогічні до тих, що використовуються в оптичних системах, таких як об'єктив камери [6]. Світло, яке формує зображення, потрапляє в око через рогівку, де заломлюється рогівкою та кришталиком та фокусується на сітківці (Рис.1.2). З двох елементів, що заломлюють, рогівка має більшу оптичну силу. Однак, у той час як у рогівки вона є постійною, оптична сила кришталика може змінюватися, коли око потребує фокусування на різних відстанях. Цей процес називається акомодатією і відбувається завдяки зміні форми кришталика. Діаметр вхідного пучка світла контролюється райдужкою, яка утворює апертурну діафрагму ока. Як і у всіх оптичних системах, апертурна діафрагма є дуже важливим компонентом системи, що впливає на широкий спектр оптичних процесів.




Рис.1.2. – Спрощена схема формування зображення на сітківці [6].

Світлочутлива тканина ока – це сітківка (Рис.1.3), яка складається з ряду клітинних та пігментованих шарів і шару нервових волокон. Ці шари мають різний ступінь оптичної значущості, причому кількість відбитого та розсіяного кожним шаром світла має особливе значення. Товщина сітківки варіюється від 0,05 мм в центрі фовеї до близько 0,6 мм біля зорового диска. На задній частині сітківки є шар світлочутливих клітин, які світло повинно досягти, пройшовши через інші шари. Ці рецепторні клітини бувають двох типів, відомих як палички та колбочки. Назви посилаються на їхні форми, але значні варіації у формі трапляються залежно від розташування, і не завжди можливо розрізнити ці два типи на цій основі.




Рис.1.3. – Будова задньої стінки ока [6].

Загалом, палички довші та вужчі за колбочки. Палички іноді описують як високочутливі детектори низького рівня освітленості, у порівнянні з колбочками. Однак багато в чому це пов'язано з нейронними зв'язками, а не з відмінностями між рецепторами. Нейронна мережа паличок така, що вихід приблизно 100 паличок може комбінуватися на шляху до мозку, тому система паличок має дуже високу чутливість до світла, але низьку просторову роздільну здатність. Навпаки, вихід меншої кількості колбочок комбінується, тому система колбочок функціонує на вищих рівнях освітленості і здатна до вищої просторової роздільної здатності. Колбочки відновлюються після впливу світла швидше, ніж палички. Перший етап у кольоровому зорі – це існування трьох типів колбочок, кожна з яких має різні властивості чутливості до довжини хвилі: L (довгі), M (середні) та S (короткі) колбочки. Колбочки переважають у фовеї, яка має розмір 1,5 мм або приблизно 5° ширини, як це видно з задньої вузлової точки N' ока. Фовея вільна від паличок у своєму центральному полі 1° . На високих рівнях освітленості найкраща роздільна здатність досягається колбочками у фовеї, яка займає лише близько 1/1000 загальної площі сітківки. Попри переважання колбочок у фовеї, вона містить лише невелику частку (1%) від загальної кількості колбочок, і ще менша частка (0,05%) колбочок знаходиться у високороздільній фовеолі. Тому більшість колбочок розподілені по всій периферійній сітківці. При низьких рівнях світла, колбочки у фовеї не працюють; таким чином, центр фовеї є «сліпою зоною» вночі, і для розрізнення об'єктів використовуються здебільшого палички. При дуже низьких рівнях світла максимальна візуальна гострота та здатність до виявлення відбуваються приблизно на $10-15^\circ$ від фовеї.

Розташування фовеї показано на Рис.1.1. Коли око фіксується на об'єкті інтересу, центр його зображення формується на фовеальному центрі, який нахилений приблизно на 5° від «найкращої» оптичної осі. У фовеї шари, що покривають рецепторні клітини, тонші, ніж в інших місцях сітківки (Рис.1.3), і в результаті фовеа має ямкову структуру. Дно цієї ямки має ширину приблизно 1° , і відповідає зоні паличок. Фовеола – це приблизно $0,5^\circ$ широка

аваскулярна зона в центрі фовеальної ямки, і є зоною найвищої роздільної здатності [6].

Кожна центрована оптична система, яка має деяку еквівалентну силу (тобто не є афокальною), має шість кардинальних точок, які лежать на оптичній осі. Вони розділені на три пари. Дві з них є фокальними точками, які позначаються символами F і F' , дві є головними точками, позначеними символами P і P' , і дві є вузловими точками, позначеними символами N і N' . Положення цих кардинальних точок в оці залежить від його структури та рівня акомодатії. Для ока, сфокусованого на нескінченність, приблизні положення цих кардинальних точок показані на Рис.1.1. Ці кардинальні точки є наступними:

1. Фокальні точки (F і F'). Світло, що виходить з передньої фокальної точки F та проходить оптичну систему ока, відображалася б на нескінченності після остаточного заломлення лінзою, якщо припустити, що сітківки не існує. Світло, паралельне осі і що входить в око з нескінченної відстані, збирається у задній фокальній точці F' . Для ока, сфокусованого на нескінченність, сітківка збігається з задньою фокальною точкою.
2. Головні точки (P і P'). Якщо об'єкт розташований в одній з цих точок, пряме зображення того ж розміру буде утворене в іншій точці. Тобто, їх поперечне збільшення дорівнює $+1$.
3. Вузлові точки (N і N'). Це також зображення або кон'югати одне одного, але мають особливу властивість, таку що промінь від позаосьової точки, що проходить через N , проходить через N' на стороні зображення системи, при цьому нахилений під тим же кутом до осі з кожного боку системи. Такий промінь називається вузловим променем, а коли позаосьова точка є точкою фіксації, промінь називається візуальною віссю.

Згідно [6], типові структурні та оптичні параметри ока наведені на Рис.1.4.




Рис.1.4. – Типові структурні та оптичні параметри ока: n – коефіцієнти заломлення, R – радіус кривизни в мм [6].

1.2. Аберації

Аберация оптичної системи – це викривлення зображення предмета, створене оптичною системою. У людському оці, як і в будь-якій реальній оптичній системі, присутні аберації, які спричиняють дискомфорт та загалом погіршують якість життя. Точна діагностика цих аберацій є ключем до успішного лікування або корекції за допомогою зовнішніх засобів, таких як окуляри або контактні лінзи. Протягом останніх десятиліть значного розвитку набули aberометри – пристрої для об'єктивного визначення похибок оптичної системи ока. Сучасна aberометрія – це одна з найпередовіших галузей офтальмології, яка застосовує складні оптико-електронні системи, що постійно вдосконалюються.

Аберації поділяються на два види: хроматичні та монохроматичні [5]. Хроматичні аберації виникають через різницю в розповсюдженні світлових хвиль різної довжини, що входять в око. Монохроматичні аберації проявляються під час проходження світлових хвиль однакової довжини (Рис.1.5). Саме монохроматичні аберації становлять більший інтерес для офтальмології.

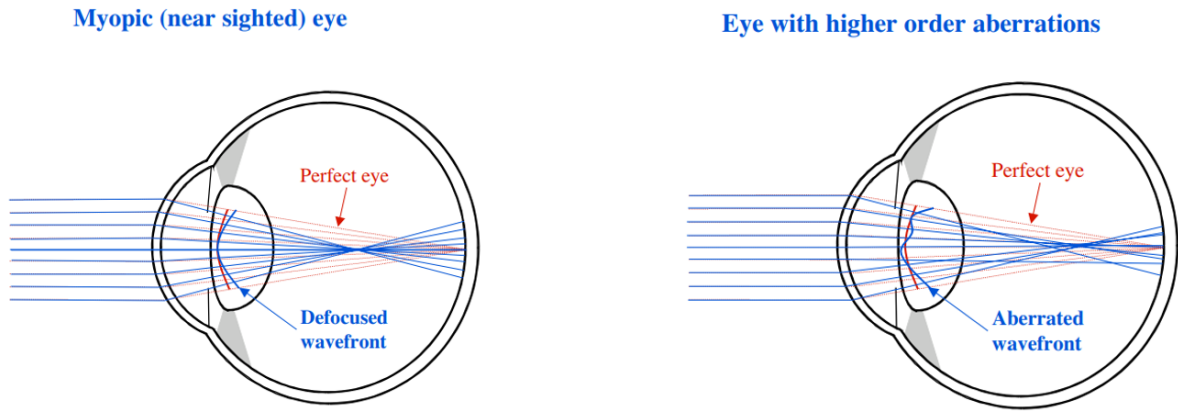


Рис.1.5. – Приклад впливу аберацій на кути заломлення вхідних променів [7].

Загальну інформацію про похибки оптичної системи надають абераційні мапи – поверхні викривлень хвильових фронтів світлових потоків, що проходять крізь цю систему. Хвильові fronti найчастіше представлені зваженою сумою поверхонь, описаних модами Церніке, що дозволяють з певною точністю відтворити будь-які поверхні, визначені в межах одиничного кола [2]:

$$W(\rho, \varphi) = \sum_n \sum_m N_n^m R_n^m(\rho) (C_n^m \cos|m|\varphi + C_n^{-m} \sin|m|\varphi) \quad (1.1)$$

де $W(\rho, \varphi)$ – значення хвильового фронту для точки на одиничному колі з полярними координатами (ρ, φ) , N_n^m – значення нормалізуючого фактору n -го радіального порядку (англ. radial order) m -ї кутової частоти (англ. angular frequency), $R_n^m(\rho)$ – значення поліному Церніке, C_n^m – коефіцієнт Церніке, який дорівнює середньоквадратичному відхиленню моди. В свою чергу N_n^m визначається як:

$$N_n^m = \sqrt{\frac{2(n+1)}{1+\delta}}, \delta = \begin{cases} 1, m=0 \\ 0, m \neq 0 \end{cases}$$

А $R_n^m(\rho)$ дорівнює

$$R_n^m(\rho) = \sum_{k=0}^{\frac{n-|m|}{2}} \frac{(-1)^k (n-k)!}{k! \left(\frac{n+|m|}{2} - k\right)! \left(\frac{n-|m|}{2} - k\right)!} \rho^{n-2k}.$$

Найбільш розповсюджений розподіл радіальних порядків та кутових частот наведений на Рис.1.6.




Рис.1.6. – Візуалізація поліномів Церніке до 4 радіального порядку включно [2]

Зазвичай хвильовий фронт описують вектором коефіцієнтів C_n^m , подібно до того, як зображення визначається зваженою сумою двовимірних гармонік. Заведено розділяти поліноми Церніке на поліноми низького ($n < 3$) та високого порядку ($n \geq 3$). В офтальмології розглядаються аберації до 6-го порядку включно. Однак, зазвичай, аберації 5-го та 6-го порядків мають незначні амплітуди.

1.3. Наявні методи аберометрії

На сьогодні існує декілька методів аберометрії зі своїми перевагами та недоліками. В роботах [3,5] перелічені основні види методів аберометрії з прикладами реальних пристроїв, що їх імплементують:

- Метод з використанням датчика Гартмана-Шека,
- Метод Чернінга,
- Метод лазерного рейтрейсинга,
- Метод автоскіаскопії,

- Метод на основі ефекту Тальбота.

Усі наведені методи аберометрії в [5] умовно поділяються на 2 групи: серійного та одночасного вимірювання. Одночасні вимірювання здійснюються аберометрами на базі сенсора Гартмана-Шека, за методом Чернінга, на ефекті Тальбота. Серійні вимірювання здійснюються за методом автоскіаскопії та лазерного рейтрейсинга. Перевагою одночасного вимірювання є стійкість до помилок, викликаних динамічними процесами в оці (рухи, акомодация та ін.). Зазвичай, для аберометрів на базі сенсора Гартмана-Шека та тих, що застосовують метод Чернінга, одне вимірювання здійснюється протягом захоплення одного відеокадру, тобто за 25-30 мс, в той час як сканування рейтрейсинговим аберометром ока в 64 точках займає 50 мс. Істотним недоліком методів одночасного вимірювання є обмежена щільність точок сканування, причому як апаратно, оскільки збільшення щільності масиву лінз здорожчує пристрій і має певні ліміти, так і з точки зору обробки вимірювань – за істотних аберацій промені можуть перехрещуватись і їхня ідентифікація стає неможливою. Водночас, аберометри серійного вимірювання мають можливість робити сканування з різною роздільною здатністю загалом та для окремих, найбільш цікавих, регіонів ока.

1.4. Розрахунок коефіцієнтів Церніке за поперечними абераціями

Для методів, що найчастіше використовуються в сучасних аберометрах, а саме методів на основі використання сенсора Гартмана-Шека та рейтрейсингу, в процесі визначення коефіцієнтів Церніке викривлень хвильового фронту здійснюються вимірювання поперечних аберацій (Рис.1.7.).




Рис.1.7. – Відхилення хвильового фронту [8]

У випадку ідеального ока із фокусом на сітківці, реальний точковий об'єкт A , який знаходиться в прямій видимості ока, матиме відображення на сітківці в точці A' як це показано на Рис.1.7а. Також, точка A' є центром сферичного хвильового фронту W_E , який є дотичним до рогівки ока. В реальному оці (Рис.1.7б) через наявність дефектів, які спотворюють хвильовий фронт, роблячи його не сферичним (фронт W_A на Рис.1.7б), існує різниця W як відстань вздовж радіусу R фронту W_E (Рис.1.7в). Якщо вважати точку перетину поверхні W_E з лінією прямої видимості z в площині, перпендикулярній осі z , за початок ортогональної координатної системи, то W , для малих апертурних кутів σ_a , може бути визначено як $W = W(x, y)$. Для полярної системи це може бути представлено як $W = W(\rho, \varphi)$, де $x = \rho \cdot \cos \varphi$, $y = \rho \cdot \sin \varphi$. [8] Згідно із [9], поперечні аберації δx та δy розраховується за формулами

$$\delta x = \frac{R}{n'} \cdot \frac{\partial W(x, y)}{\partial x} \quad (1.2)$$

та

$$\delta y = \frac{R}{n'} \cdot \frac{\partial W(x, y)}{\partial y} \quad (1.3)$$

де $n' = 1.336$ – коефіцієнт заломлення склоподібного тіла.

З урахуванням (1.1) в формулах (1.2) та (1.3) утворюється система рівнянь

$$\mathbf{F} = \mathbf{C}\mathbf{A}, \quad (1.4)$$

де \mathbf{C} – вертикальний вектор з невідомих коефіцієнтів Церніке, \mathbf{A} – матриця доданків, що множаться на коефіцієнти Церніке в (1.1), \mathbf{F} – вертикальний вектор, що складається з вимірених відхилень δx та δy .

Система (1.4) розв'язується методом найменших квадратів

$$\mathbf{C} = (\mathbf{A}^T \mathbf{E} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{E} \mathbf{F}, \quad (1.5)$$

де \mathbf{E} – одинична матриця. Варто звернути увагу, що з одного зміщення ($\delta x, \delta y$) можна розрахувати 2 коефіцієнти Церніке. Таким чином, мінімальна кількість точок сканування має бути вдвічі меншою за кількість коефіцієнтів, значення яких треба розрахувати. Очевидно, що не тільки кількість точок впливає на точність визначення хвильового фронту, а й їхній розподіл по зіниці. Зокрема в дослідженні, проведеному в [10], для рейтрейсингової аберометрії наведено метод покриття зіниці точками сканування з метою зменшення відстані між променями.

1.5. Метод із використанням датчика Гартмана-Шека

Найбільш розповсюдженими сьогодні є аберометри на основі метода із застосуванням сенсора хвильового фронту Гартманна-Шека [1], принцип дії яких полягає у створенні точкового джерела світла на сітківці шляхом її підсвічування лазерним променем, з подальшим фокусуванням відбитого світла, що пройшло оптичну систему ока у зворотному напрямку, масивом лінз на фоточутливій матриці (Рис.1.8).




Рис.1.8. – Спрощена схема роботи аберометра Гартманна-Шека [1].

Утворення точкового джерела випромінення в точці потрапляння лазерного променя на сітківку обумовлене тим, що сітківка є майже ідеальним дзеркальним дифузором. За відхиленнями світлових точок на матриці розраховується хвильовий фронт аберацій. Використання аберометра на основі сенсора Гартмана-Шека дозволяє протягом одного вимірювання оцінити похибки оптичної системи, що важливо за наявності несвідомих мікрорухів ока, які можуть спотворити отриманий результат. Однак цей метод також має свої недоліки: по-перше, одним з визначальних факторів його точності є щільність лінз в масиві, яка є обмеженою, а, по-друге, за значних аберацій, існує ймовірність некоректного визначення положення світлових точок через перетин пучків світла, що їх утворюють.

1.6. Рейтрейсинговий метод аберометрії

Згідно з описаним в [3] методом рейтрейсингової аберометрії, сканування ока здійснюється лазерним променем, а точка сканування змінюється відхиленням променя акустооптичним дефлектором з наступною колімацією з оптичною віссю ока (Рис.1.9). Якщо око має аберації, то точка відбиття променя від сітківки є зміщеною. Саме цей зсув, який надалі детектується фоточутливим елементом, і є поперечною аберацією променя на

сітківці. На сьогодні єдиним серійним рейтрейсинговим aberометром є iTrace від американської компанії Tracey Technologies [11], особливістю якого є поєднання із топографом [12] з метою відокремлення аберацій, спричинених поверхнею рогівки [8].




Рис.1.9. – Спрощена структурна схема рейтрейсингового aberометру [3].

Згідно з аналізом, проведеним в [4], метод рейтрейсинової aberометрії має високі вимоги до оптичної системи, а саме потребу у наявності дефлектора та світлоподільної пластини. Дефлектор значно здорожчує конструкцію та потребує складного алгоритму керування. Світлоподільні пластини вносять додаткові втрати потужності для відбитого від сітківки променя (50% для відбитого променя) на додачу до втрат при проходженні оптичної системи ока, які сягають 95%.

Автори [4] запропонували модифікацію конструкції для імплементації методу рейтрейсингової aberометрії, в якій сканування здійснюється не одним лазерним променем, який відхиляється дефлектором, а почерговим увімкненням лазерних випромінювачів, встановлених в блоці (Рис. 1.10). Також, задля зменшення кількості використаних світлоподільників в оптичній системі, фотоприймач має бути встановлений в конструктивному елементі, що здійснює сканування ока. Такий підхід до позиціонування фотоприймача

прибирає необхідність у спрямуванні відбитого від сітківки випромінення в окремий канал.




Рис.1.10. – Структурна схема пристрою для рейтрейсингової аберометрії ока.

Позначення: 1 – блок світлових випромінювачів; 2 – вхідна оптика; 3 – багатоканальна оптоволоконна лінія; 4 – вихідна оптика; 5 – оптична система ока; 6 – фотоприймач; 7 – блок управління; 8 – пристрій обробки даних [4]

Таким чином, зменшуються втрати потужності променя в оптичній системі приладу, а також зменшується ціна приладу, оскільки відсутній дефлектор, який коштує в середньому \$2500. Від світлоподільника вдалось відмовитись шляхом встановлення фотоприймача посередині багатоканальної оптоволоконної лінії. Розроблений підхід було втілено у конструкції пристрою, захищеного патентом №109513 “Пристрій для зондування ока людини” (МПК А61В 3/10, 25.08.2016) за авторством В. В. Молебного, П. О. Яганова та ін.

1.7. Аналіз можливостей вдосконалення рейтрейсингового методу аберометрії

Наявні відомості про розрахунок абераційного хвильового фронту апаратними системами за рейтрейсинговим методом аберометрії можна підсумувати шляхом створення функціональної схеми, наведеної на Рис.1.12.

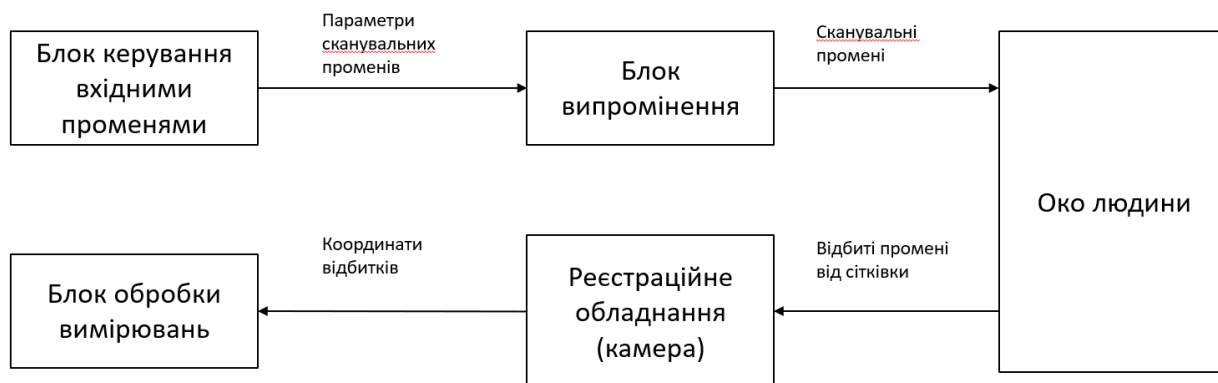


Рис.1.12. – Функціональна схема роботи рейтрейсингового аберометра.

Позиції вхідних променів визначаються Блоком керування вхідними променями у вигляді електричних сигналів: команда для дефлектора або подання живлення для відповідного лазерного діода залежно від модифікації. Вимірювання здійснюються за заздалегідь визначеними зіничними координатами. Сприймаючи команди від Блоку керування вхідними променями, Блок випромінення надсилає лазерний промінь в око. Промені сканування, утворені Блоком випромінення, проходять крізь зіницю в оптичну систему ока, відбиваються від сітківки, а потім покидають око крізь зіницю і потрапляють до реєстраційного обладнання. Реєстраційне обладнання – камера – детектує відбиті промені та передає їхні координати у Блок обробки вимірювань, який розраховує аберацийний хвильовий фронт.

Виходячи з огляду обробки та перетворення даних у рейтрейсинговому методі аберометрії, можна виділити такі особливості:

- 1) Безпосередньо робота з даними відбувається в блоках керування вхідними променями та обробки вимірювань.
- 2) Не знайдено підтвердження наявності та, відповідно, опису зворотного зв'язку для керування скануванням, хоча теоретично така можливість існує для рейтрейсингового аберометра.
- 3) Для реєстраційного обладнання також мають застосовуватись певні способи обробки зображень з метою виділення координат перетину відбитим променем світлочутливої матриці камери. Однак не знайдено

наявних прикладів обробки відеокадрів з метою відокремлення відбитка променю сканування від інших відблисків на кадрі.

З цього можна зробити висновок, що існує можливість вдосконалення методу рейтрейсингової аберометрії із застосуванням певного зворотного зв'язку, який би міг коригувати процес вимірювання. Автоматичне керування зі зворотним зв'язком може бути реалізоване як розповсюдженими засобами на кшталт PID з оцінкою похибки фільтром Калмана [13], так і новітніми засобами штучного інтелекту, як-от навчання з підкріпленням (Reinforcement Learning) [14]. Застосування останнього є потенційно більш результативним підходом, оскільки, на відміну від інших методів керування, навчання з підкріпленням передбачає засвоєння особливостей оперування в спеціалізованому середовищі, що призводить до кращих кінцевих результатів. Також слід враховувати, що керування скануванням, у випадку складного алгоритму, може подовжити час вимірювання по всій зіниці, тож, до застосування засобів на кшталт навчання з підкріпленням варто вдаватися або за малої очікуваної кількості сканувань, або для інших цілей, наприклад, для уточнення результатів. Додатковим можливим покращенням методу є оптимізація кількості сканувань по зіниці з подальшим збільшенням роздільної здатності розрахованого викривлення хвильового фронту нейронною мережею для надроздільної здатності.

Втім, для усіх методів на базі нейронних мереж необхідні значні об'єми даних для якісного навчання. В офтальмології існує нестача вибірок з інформацією про розподіл та характеристики аберацій серед населення. Як показує дослідження з пошуку відкритих навчаючих вибірок для потреб обробки зображень в офтальмології, проведене в [15], не існує централізованих агрегаторів наборів даних, а самі набори є нечисельними та містять відносно невелику кількість вимірювань. Найбільшим знайденим дослідженням з відкритими вимірюваннями аберацій є [16] з даними про аберації 50 очей. Очевидно, що цього недостатньо для якісного навчання

нейронних мереж. Цю проблему можливо вирішити залученням генеративно-змагальних мереж. Запропонований в [17], цей клас штучних нейронних мереж ґрунтується на «суперництві» двох нейронних мереж: генератора та дискримінатора. Під час тренування, задачею дискримінатора є покращення розрізнення зображень з реальної навчаючої вибірки та штучних зображень, створених мережею-генератором. В свою чергу, під час тренування, завданням генератора є перетворення вхідних даних з т. зв. латентного простору – неявних змінних, що характеризують зображення (наприклад, кут повороту обличчя на фотографії) – у настільки реалістичні зображення, що їх дискримінатор не може відрізнити від реальних. Зазвичай вхідними даними для генератора є вектори, що містять випадкові числа. Можливим розв’язанням проблеми нестачі даних є запит анонімізованих даних пацієнтів офтальмологічних клінік, однак в цьому випадку існують певні складнощі:

- не усі клініки погоджуються надавати дані пацієнтів;
- вибір обмежується клініками, які пропонують операції з корекції зору методами лазерної хірургії, в іншому випадку вимірювання аберацій високого порядку не здійснюватиметься через недоцільність;
- цих даних може бути замало для якісного тренування GAN.

З усіх наведених вище ризиків технічними засобами можливо зменшити лише останній. Очевидно, що єдиним способом збільшити навчаючий набір даних в такому випадку є його аугментація (англ. data augmentation) – штучне збільшення вибірки шляхом внесення змін в реальні приклади. Після підготовки наборів вимірювань (як реальних, так і синтезованих), відкриваються можливості для моделювання майже усіх етапів рейтрейсингового методу аберометрії.

Як вже було зазначено раніше, природним недоліком серійних методів аберометрії є довший час проведення вимірювання. Водночас, повна процедура діагностики обмежується періодом між мікро-рухами ока, який сягає від 10 мс до 300 мс [18]. Таким чином, більший час вимірювань з одного

боку та обмеження на час діагностики з іншого боку призводять до меншого обсягу вимірювань протягом однієї процедури. Таке поєднання факторів призводить до збільшення довірчого інтервалу, оскільки зменшується кількість повторних сканувань для кожної зіничної координати. Наприклад, для рейтрейсингового аберометра iTrace кількість повторюваних вимірювань сягає не більше 5 залежно від версії програмного забезпечення [11]. Тому, цілком логічним є пошук методичного або технічного рішення для прискорення повного сканування ока. Одним із можливих підходів для пришвидшення вимірювання є аналогія з принципом роботи фазових антенних решіток (ФАР), а саме застосування масиву елементів сканування (Рис.1.13). ФАР, використовують множинні елементи для створення керованого випромінювання яке може бути спрямоване з високою точністю. Це дозволяє виключити необхідність механічного впливу на окремі елементи, що керують скануванням, а саме потребу у русі антен. Під час сканування простору використовуються усі комірки, а фронт випромінювання спрямовується за допомогою фазообертачів, які є в складі кожної комірки.




Рис.1.13. – Спрощена схема роботи ФАР.

Для методу рейтрейсингової аберометрії аналогом кожної комірки ФАР можна вважати лазерний випромінювач. Прискорення вимірювання можна досягнути використовуючи декілька випромінювачів одночасно, як це і зроблено у ФАР. Виходячи з пропозицій в [4], керування відхиленням випромінювання для сканування не є необхідним – достатньо заздалегідь встановити випромінювачі відповідно до зіничних координат (Рис.1.14).




Рис.1.14. – Порівняльна візуалізація масивів елементів сканування ФАР та пристрою для рейтрейсингової аберометрії.

Однак в такому випадку за істотних рефракційних похибок ока постає проблема ідентифікації відбитків та сканувальних лазерних променів, тобто встановлення відповідності між ними. Як вже було розглянуто раніше, за значних аберацій неможливість такої ідентифікації обмежує діапазон вимірювання аберацій, а рейтрейсинговий метод вирішує це шляхом використання суто серійних вимірювань. Отже, впровадження режиму одночасного сканування без додаткових заходів з метою встановлення точної відповідності відбитків до променів, зведе нанівець основну перевагу методу рейтрейсингової аберометрії. Потенційним способом розв'язання задачі ідентифікації є використання класифікаційних нейронних мереж. Дійсно,

встановлення відповідності є нічим іншим як задачею класифікації, де вхідними даними класифікатора є координати відбитків, а класами є номери сканувальних променів. Саме розв'язання задачі класифікації нейронними мережами є доволі розповсюдженим і, зазвичай, не становить проблеми для дослідницьких та комерційних застосувань. На сьогодні багато джерел містять інформацію про розробку класифікаційних нейронних мереж, зокрема такі вичерпні посібники як [19] та [20]. Втім, кожна задача має унікальні особливості, як-от обсяги наявних даних, спосіб їхнього представлення, та ін. У випадку класифікації відбитків можна застосувати мережу для класифікації типу «послідовність-послідовність» із застосуванням шарів довгої короткочасної пам'яті, прикладом застосування якої є [21]. Таким чином, через певні особливості, а саме: відносну простоту оптичної системи та конструкції загалом для імплементації, можливість працювати в одночасному режимі, та можливість збереження широкого діапазону вимірювань, притаманну саме рейтрейсинговому методу, це вдосконалення обрано як базове для даної роботи з можливістю покращення або відхилення за результатами подальших досліджень. Адекватним для базового вдосконалення є використання конструкції [4] для імплементації.

Доволі часто виробники аберометрів не вказують інформацію ані щодо точності, ані щодо прецизійності їхніх виробів. В такому випадку складно порівнювати точність рейтрейсингових аберометрів з аберометрами на основі інших методів. Додатковим ускладнюючим фактором є розбіжності у результатах вимірювань аберометрами різних виробників [22]. Тим не менше, фірмою Tracey Technologies для аберометра iTrace декларуються точність та прецизійність при вимірюванні дефокусу (сфери) по ± 0.1 дптр, що еквівалентно ± 0.130 мкм та є сумірним до коефіцієнтів Церніке високих порядків.

Таким чином, покращення точності рейтрейсингового методу аберометрії є важливим завданням, оскільки цей аспект діагностики залишається одним із ключових викликів для сучасних аберометрів. Точність

вимірювань викривлень хвильового фронту є надзвичайно важливою для забезпечення надійності даних, оскільки навіть невеликі похибки можуть мати значний вплив на визначення аберацій, особливо вищих порядків. Це, своєю чергою, впливає на якість і точність корекції зору, що є важливим для успішного лікування пацієнтів.

Також, підвищення точності рейтрейсингового методу відкриває нові можливості для наукових досліджень у сфері офтальмології. Точніші методи забезпечують більшу достовірність даних і сприяють розробці нових технологій та підходів, орієнтованих на покращення діагностики та лікування пацієнтів. Таким чином, вдосконалення цього аспекту aberометрії може мати значний позитивний вплив як на клінічну практику, так і на наукову спільноту.

Як вже зазначалося раніше, обмежена роздільна здатність загалом та лімітована нормами потужність лазерного випромінювання, спрямованого в око, зменшують можливості вимірювання аберацій в режимі одночасного сканування. Саме тому, при застосуванні алгоритмів автоматичного керування процесом aberометрії, необхідність додаткових ітерацій сканування або накладатиме додаткові вимоги на швидкість обробки даних, або призведе до неточного кінцевого результату. Відповідно, актуальним завданням є отримання якомога точнішої інформації за найменшої кількості вимірювань. Через те, що хвильовий фронт, описаний коефіцієнтами Церніке, перетворюється в зображення і навпаки, інформацію про аберації високого порядку, визначення яких потребує великої кількості вимірювань, можна покращувати за допомогою методів надроздільної здатності зображень засобами штучних згорткових нейронних мереж. Наявні методи охоплюють як способи для збільшення роздільної здатності окремих зображень [23] (Single-Image Super Resolution), так і для відеопослідовності [24]. Обмежувальним фактором застосування як нейронної мережі для надроздільної здатності, так і будь-якого засобу глибокого навчання, окрім наявності навчаючої вибірки, також є вимоги для апаратного забезпечення. Зокрема, ці вимоги стосуються обсягу оперативної пам'яті та швидкодії обчислювального обладнання.

Потреби у межах цих характеристик апаратного забезпечення визначаються обраною архітектурою нейронної мережі. Так, покращення кінцевого результату роботи шляхом «розгортки» архітектури нейронної мережі BCLSR [25] в роботі [26], тобто застосування декількох однакових за архітектурою блоків шарів замість циклічної обробки одним блоком, призвело до пришвидшення майже у 2 рази та збільшення кількості параметрів в ~ 5 разів. Отже, важливим етапом є пошук оптимальної конфігурації шляхом моделювання всього процесу вимірювань.

Попри розглянуті до цього вдосконалення способів обробки даних в методі рейтрейсингової аберометрії, які можна налаштувати та перевірити шляхом моделювання, залучаючи лише набори коефіцієнтів Церніке, є один етап, який промоделювати значно складніше або неможливо у деяких випадках. Мова про первинну обробку відеокадрів з реєстраційного обладнання з метою виявлення відбитків сканувальних променів, відділення їх від інших світлових плям, визначення зіниці на кадрі та ін. Наприклад, для ізоляції від інших джерел випромінення, око в процесі аберометрії має бути прикрите спеціальним кожухом, однак, водночас в аберометрії має бути реалізована підсвітка з метою отримання більш чітких фотографій для виявлення зіниці. Підсвічування ока ймовірно створюватиме відблиски, які треба відрізнити від відбитків променів сканування. Для вирішення такого роду задач застосовуються методи обробки зображень [27], вибір та налаштування яких для рейтрейсинового аберометра найбільш доцільно робити експериментально.

Одним з обмежувальних факторів для розробки та застосування вищеописаних вдосконалень є зростаючі вимоги до апаратного забезпечення аберометра на базі нейромережевого рейтрейсингового методу, а саме до електронно-обчислювальної складової. Втім, варто зазначити, що, з високою ймовірністю, більш швидкодійні обчислювальні засоби обійдуться дешевше, ніж оптична система для імплементації немодифікованого рейтрейсингового методу аберометрії.

Враховуючи вищезазначене, дослідження в даній роботі можна розділити на певні етапи:

- Розробка методу генерації синтетичних aberометричних даних – є необхідною через низьку доступність клінічних вибірок офтальмологічних даних та потребу нейронних мереж, як одного з основних засобів модифікації рейтрейсингового методу aberометрії.
- Аналіз можливостей модифікації рейтрейсингового методу із впровадженням одночасного сканування шляхом застосування масиву випромінювачів. Використання декількох випромінювачів одночасно потенційно здатне підвищити прецизійність методу рейтрейсингової aberометрії.
- У випадку виявлення обмежень із застосуванням наявної конструкції для імплементзації одночасного сканування – актуальною стає розробка нового способу сканування для модифікованого нейромережного методу рейтрейсингової aberометрії ока, який би дозволив зберегти переваги підходу із відслідковуванням променів та забезпечував високу точність та прецизійність.
- Через застосування нейронних мереж для модифікації методу рейтрейсингової aberометрії, які хоч і є універсальними апроксиматорами, втім, не обділені недоліками, як-от незадовільна точність результату для деяких значень вхідних сигналів, необхідно провести дослідження та розробку методів їхньої корекції. Це набуває більшої актуальності через застосування методів на основі нейронних мереж в медицині, що підвищує вимоги до точності вимірювань.
- У випадку практичної реалізації розробленого в ході роботи модифікованого методу рейтрейсингової aberометрії, створення серійних вимірювальних приладів цілком ймовірно може стикнутися з неможливістю вимірювання певних коефіцієнтів Церніке, що описують аберації вищих порядків. В такому випадку варто розглянути розробку

методу, який, по суті, має здійснювати збільшення роздільної здатності отриманого набору коефіцієнтів Церніке. Дійсно, визначення коефіцієнтів Церніке, а, отже, і підвищення точності інформації про хвильовий фронт, можна віднести до методів надроздільної здатності (англ. Super Resolution).

Виконання наведених етапів по суті являтиме собою розробку модифікованого нейромережного методу рейтрейсингової аберометрії ока, як вдосконалення оригінального методу із застосуванням сучасних засобів обробки даних – штучних нейронних мереж, яке було б неможливе без наявних здобутків у сфері розробки електронно-обчислювального обладнання. Дійсно, оптимізація мільйонів параметрів нейронних мереж за результатами обробки тисяч наборів вхідних даних на сьогодні займає мілісекунди, що забезпечує швидко підготовку мереж, враховуючи той факт, що само по собі створення нейронної мережі зазвичай супроводжується великою кількістю невдалих спроб. Таким чином, вдосконалення методу рейтрейсингової аберометрії ока впровадженням штучних нейронних мереж є актуальною та важливою задачею, вирішення якої дозволить підвищити точність та прецизійність методу, позбавити його наявних обмежень, а саме тривалого часу повного сканування ока та потреби у складних елементах керування (дефлектор).

Висновок до Розділу 1

1. Проведено огляд наявного методу рейтрейсингової аберометрії ока, його обмеження та переваги. В результаті проведеного огляду літературних джерел встановлено, що вже існуючі методи обробки даних з певною адаптацією та у незмінному вигляді можуть використовуватись в усуненні знайдених обмежень. Зокрема, залучення методів на базі нейронних мереж надає можливості по вирішенню задачі зіставлення відбитків та променів сканування, збільшення роздільної здатності визначення викривлень хвильового фронту та керування скануванням або уточнення вимірювань.

2. Серед ризиків, що супроводжуватимуть дослідження, відокремлено нестачу даних для навчання нейронних мереж. Після аналізу літературних джерел, ризик пропонується вирішувати застосуванням генеративно-змагальних нейронних мереж, які широко застосовуються зокрема і для синтезу навчаючих вибірок для нейромереж медичного призначення.

3. Виділено наступні етапи дослідження, результатом виконання яких є створення модифікованого нейромережного методу рейтрейсингової аберометрії ока:

- 1) Розробка методу генерації синтетичних аберометричних даних.
- 2) Аналіз можливостей модифікації рейтрейсингового методу аберометрії із застосуванням масиву випромінювачів.
- 3) У випадку виявлення обмежень із застосуванням наявної конструкції для імплементації одночасного сканування – розробка нового способу сканування.
- 4) Розробку методів корекції результатів роботи нейронних мереж в складі модифікованого нейромережного методу рейтрейсингової аберометрії.
- 5) Розробка методу надроздільної здатності хвильового фронту аберацій.

РОЗДІЛ 2. Генерація aberометричних даних

Очевидно, що для розробки нового обладнання та методів лікування на етапі моделювання, доцільною є наявність якомога більшої кількості прикладів наборів аберацій людського ока. Зважаючи на розвиток нейронних мереж та їхній потенціал у сфері діагностики різних захворювань, доступність даних про набори аберацій набуває ще більшої актуальності. Втім, наявні на сьогодні складнощі стоять на заваді отримання подібних вибірок для досліджень. По-перше, це сама природа цих даних – набори аберацій людського ока є медичною конфіденційною інформацією, яка до того ж має високий ступінь унікальності та може використовуватись для ідентифікації осіб, що накладає обмеження на її розповсюдження. По-друге, детальне вимірювання аберацій вищих порядків є спеціалізованим і не розповсюдженим видом обстеження, а, отже, відносно невелика кількість людей проходить таку діагностику. Остання причина є критичною для розробки методів діагностики та лікування на основі нейронних мереж, оскільки малий розмір навчаючої вибірки ускладнює розробку архітектури та може призвести до перенавчання мережі.

Отже, актуальним є розв'язання проблеми малих об'ємів доступних наборів аберацій людського ока. Оскільки екстенсивне збільшення таких вибірок шляхом масового офтальмологічного обстеження населення супроводжуватиметься значними фінансовими витратами та вимагає суто організаційних заходів, резонним є пошук рішень для штучного розширення існуючих вибірок даних.

Цей розділ присвячений методу генерації aberометричних даних із застосуванням штучної нейронної мережі та особливостям її навчання. Розглянуто теоретичні основи, на яких базуються компоненти методу, а також їхнє практичне застосування. Особливу увагу буде приділено методам оцінки якості згенерованих даних за сукупністю різних метрик.

2.1. Аналіз існуючих досліджень і публікацій

2.1.1. Існуючі вибірки офтальмологічних досліджень

Як вже зазначалося раніше, навчаючі вибірки, які містять офтальмологічні дані, є доволі рідкісними, а на момент написання цієї роботи знайдено лише одну статтю [15], головним фокусом якої є дослідження і пошук таких наборів вимірювань. Однак, попри те, що цей огляд є вичерпним, він не може бути застосований для розв’язання проблеми малої кількості публічних аберометричних даних, оскільки фокусом цього дослідження є пошук вибірок з графічною інформацією, а серед знайдених дослідниками нема жодної, з якої можна отримати аберометричні дані. В роботі [28] проведено пошук і аналіз статей, в яких проблему малих розмірів офтальмологічних вибірок з графічною інформацією пропонується розв’язувати шляхом застосування генеративно-змагальних нейронних мереж (англ. Generative-Adversarial Network, GAN), які вперше було представлено в [17]. Аналогічно до [15], в [28] відсутня інформація про застосування GAN для генерування вибірок аберометричних даних. Одним з найбільших наборів з аберометричними даними є набір з вимірюваннями 50 очей для дослідження [16]. З метою перевірки розробленого в даній роботі методу, застосовуватиметься саме ця вибірка, втім, очевидно, що абераційні дані, згенеровані на основі обраного набору, можуть мати невисокі показники подібності до реальних даних через дуже малий розмір вибірки, тоді як для навчання успішної генеративної нейронної мережі зазвичай необхідно сотні або тисячі реальних вимірювань. Отже, виходячи з [15, 28], можна прийти до висновку, що, по-перше, з нечисельних офтальмологічних вибірок для дослідників більший інтерес становить графічна інформація (фотографії очного дна, райдужки і т.д.), а, по-друге, застосування GAN для генерації офтальмологічних даних є відомим результативним підходом, що активно розвивається. Саме тому, цілком резонною та актуальною є розробка методів розширення наявних навчаючих вибірок аберометричних даних саме шляхом застосування генеративно-

змагальних нейронних мереж з урахуванням малих розмірів існуючих відкритих наборів.

2.1.2. Генеративно-змагальні нейронні мережі

Навчання GAN є змаганням двох нейронних мереж: генератора G та дискримінатора D . Під час тренування завданням дискримінатора D є якомога точне розрізнення, тобто класифікація, реальних даних x та «штучних» $G(z)$, створених генератором G на базі вхідних випадкових значень z . Шум в якості вхідних даних генератора забезпечує різноманітність згенерованих даних, і, згідно з припущеннями, є набором змінних з латентного простору, що містить неявні параметри, які характеризують примірники з вибірки. Прикладом цього може бути кут повороту обличчя на фотографії. В найпростішому випадку приймається, що дискримінатор має позначати як 1 реальні дані, а 0 – згенеровані.

Формально, завдання на тренування GAN визначається як [17]:

$$\min_G \max_D \mathcal{V}(D, G) = \log(D(x)) + \log(1 - D(G(z))).$$

Навчання та підбір архітектури GAN є непростю задачею, оскільки, на відміну від інших видів нейронних мереж, функції втрат генератора та дискримінатора залежать одна від одної та змінюються протягом навчання. Особливо актуальним цей факт є і для завдання генерації медичних даних за малої наявної вибірки, що збільшує ризик перенавчання. З метою стабілізації процесу навчання в [29] запропоновано модифікацію GAN – Wasserstein GAN (WGAN) – основною відмінністю якої є змінений підхід до розрізнення реальних та згенерованих даних, а саме: застосування необмеженого значення як показника реалістичності згенерованих даних, жорсткого обмеження на значення ваг та використання інших функцій втрат дискримінатора L_D та генератора L_G на основі відстані Васерштейна:

$$L_D = \mathbb{E}[D(G(z))] - \mathbb{E}[D(x)], \quad L_G = -\mathbb{E}[D(G(z))].$$

Втім, попри кращу стабільність під час навчання, WGAN не позбавлений недоліків. В [30] розглянуто негативні ефекти застосування жорсткого

обмеження ваг, а саме: «схильність» дискримінатора (або критика, як його називають в межах WGAN) до вивчення більш простих функцій, та необхідність тонкого налаштування межі ваг, оскільки в іншому випадку значно зростає ризик вибуху або зникнення градієнтів. З метою усунення цих недоліків, в тій самій роботі запропоновано додавання градієнтного штрафу до функції втрат критика:

$$L_D = \mathbb{E}[D(G(z))] - \mathbb{E}[D(x)] + \lambda \mathbb{E}[(\|\nabla_{\hat{x}} D(\hat{x})\|_2 - 1)^2],$$

де:

$$\hat{x} = tx + (1 - t)G(z), \quad t - \text{випадкове число в межах } [0, 1],$$

λ – коефіцієнт, що налаштовується, зазвичай рівний 10. Експериментальне дослідження запропонованого способу навчання довело кращу збіжність навчання WGAN та отримання більш реалістичних згенерованих зображень.

У випадку малих розмірів вибірок, розробники часто вдаються до доповнення даних (т.зв. аугментації даних), яке має на меті збільшення навчаючого набору шляхом застосування до нього нескладних перетворень, як-от, у випадку графічних даних, обертання на 90° , віддзеркалення, обрізка, та ін. Очевидно, що використання аугментації даних не замінить повноцінне наповнення вибірки більшою кількістю реальних вимірювань, втім, воно здатне покращити кінцевий результат навчання нейронної мережі. Однак, для GAN застосування аугментації даних під час навчання несе певні ризики – генератор може інтегрувати способи доповнення даних в синтезовані зображення. В [31] експериментально показано негативний вплив застосування засобів аугментації даних для тренування GAN, який призводить до збільшення відстані між розподілами реальних і згенерованих зображень за метрикою Frechet Inception Distance (FID) [32] з 6.8 до 47.3 для відомої вибірки MNIST [33]. Автори [31] пропонують застосовувати реверсивні перетворення (англ. invertible transformations) одночасно до реальних та згенерованих зображень, причому для кожного перетворення T_k використовується окремий дискримінатор D_k . З метою кращої регуляризації, усі дискримінатори

використовують одні й ті самі ваги, окрім останніх шарів. В [31] теоретично та експериментально доведено, що запропонований метод додавання аугментацій, названий аугментацією даних, оптимізованої для GAN (англ. Data Augmentation Optimized for GAN, DAG), не вносить спотворень в розподіл згенерованих зображень. Таким чином, за рахунок збільшеної кількості зворотних зв'язків від декількох дискримінаторів D_k , генератор отримує більше інформації під час навчання. Запропоноване в [31] завдання на тренування GAN матиме вигляд:

$$\max_{D, \{D_k\}} \mathcal{V}(D, \{D_k\}, G) = \mathcal{V}(D, G) + \frac{\lambda_u}{K-1} \sum_{k=2}^K \mathcal{V}(D_k, G),$$

$$\min_G \mathcal{V}(D, \{D_k\}, G) = \mathcal{V}(D, G) + \frac{\lambda_v}{K-1} \sum_{k=2}^K \mathcal{V}(D_k, G),$$

де λ_u та λ_v – константи для налаштування навчання, K – загальна кількість перетворень, причому за $k = 1$ вважається фактична відсутність перетворень. Схематично метод навчання зображено на Рис.2.1. Згідно з експериментальними випробуваннями методу, для навчання мережі SS-GAN [34] на вибірці CIFAR-10 [35] із використанням 25% зображень (~5 мільйонів), застосування DAG поліпшило метрику FID з 46.2 до 30.3-35.2 залежно від типів перетворення T_k . Таким чином, DAG є ефективним методом з точки зору отримання реалістичності згенерованих GAN зображень.

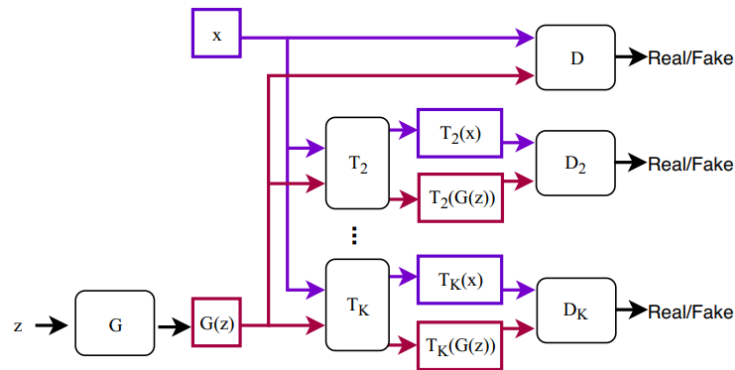


Рис.2.1. – Схема навчання за методом DAG. Фіолетовим кольором позначено потік перетворення та обробки реальних даних, червоним – згенерованих.

Не існує єдиної всеосяжної оцінки якості згенерованих GAN даних. Згідно з [36], оптимальний GAN має генерувати дані, які мають однаковий з навчаючими примірниками розподіл, однак не є їхніми копіями, та є різноманітними. Таким чином, результати генерації даних пропонується оцінювати за метриками спадковості (inheritance в [36]), творчості (creativity в [36]) та різноманітності (diversity в [36]) відповідно.

Для визначення спадковості графічної інформації часто використовується раніше згадана метрика FID, що залучає відому нейронну мережу для класифікації зображень Inception [37], яка відображає схожість між реальними та згенерованими зображеннями на основі відгуку Inception на обидва набори. В такому випадку, зазвичай, з мережі Inception прибирається останній шар, необхідний для класифікації, а на основі виходів передостаннього шару розраховується відстань Фреше [38] між відгуками на реальні та синтезовані дані:

$$FID(X, Y) = \|\mu_X - \mu_Y\|^2 + Tr(\Sigma_X + \Sigma_Y - 2\sqrt{\Sigma_X \Sigma_Y}),$$

де X та Y – відгуки передостаннього шару Inception на реальні та синтезовані дані відповідно, μ_X та μ_Y – середні значення X та Y відповідно, Σ_X та Σ_Y – матриці коваріації X та Y відповідно, $Tr(.)$ – слід матриці (сума усіх елементів діагоналі матриці).

Творчість згенерованих результатів визначається шляхом розрахунку відношення кількості копій реальних примірників серед згенерованих зображень до їхньої загальної кількості. Для цього, згідно [36], розраховується значення індексу структурної подібності (англ. Structural Similarity Index Measure, SSIM) [39] між усіма парами реальних та згенерованих зображень і, у випадку $SSIM > 0.8$, синтезований примірник вважається копією реального. Розрахунок SSIM для двох зображень x та y має вигляд:

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)},$$

де μ_x – середнє значення x , μ_y – середнє значення y , σ_x^2 – дисперсія x , σ_y^2 – дисперсія y , σ_{xy} – коваріація x та y , $c_1 = (k_1 L)^2$ та $c_2 = (k_2 L)^2$ – змінні для стабілізації ділення за малого значення знаменника, коефіцієнти k_1 та k_2 зазвичай дорівнюють 0.01 та 0.03, L – динамічний діапазон сигналів.

При розрахунку різноманітності синтезованих зображень також використовується метрика SSIM: після виключення згенерованих зображень, які є копіями реальних примірників при визначенні творчості, відбувається їхня послідовна кластеризація за взаємною SSIM. В такий спосіб відбувається виключення зображень-дублікатів вже всередині набору згенерованих зображень. Поріг значення SSIM, за перетину якого примірники вважаються копіями, так само дорівнює 0.8.

Попри те, що вищеописані GAN та способи їхнього навчання розроблено саме для графічної інформації у вигляді зображень, цей факт не може запобігти застосуванню цього набору методів для задачі генерування наборів аберацій людського ока, описаних коефіцієнтами Церніке. Це можливо за двох причин. По-перше, GAN здатні генерувати інформацію не тільки у вигляді зображень залежно від навчаючої вибірки та архітектури. По-друге, хвильовий фронт $W(\rho, \varphi)$ може бути представлений у вигляді монохромного зображення зі значеннями $W(\rho, \varphi)$. Загалом, перетворення «коефіцієнти Церніке – зображення хвильового фронту» можна вважати реверсивним перетворенням, оскільки існує інше перетворення, за яким з матриці значень (якою є зображення) можна відновити вектор коефіцієнтів Церніке. Таким чином, перетворення «коефіцієнти Церніке – зображення хвильового фронту» має можливість інтеграції в DAG без додавання спотворень до оригінального методу.

Виходячи з вищеописаного, мережі WGAN із застосуванням градієнтного штрафу (Wasserstein Generative Adversarial Network with Gradient Penalty, WGAN GP) є одним з найкращих рішень серед генеративних нейронних мереж з точки зору стабільності навчання та якості кінцевого

результату, що є корисним для розв'язання задачі з генерування медичних даних, враховуючи їхню обмежену доступність та малі розміри навчаючих вибірок. З метою покращення генерації, доцільно використовувати аугментацію даних, однак її прямолінійне застосування під час навчання GAN спотворює кінцевий результат. Ця проблема вирішується використанням методів, які враховують особливості GAN. Таким методом є DAG, ефективність якого підтверджена теоретично та практично. Оцінка результатів генерації за критеріями спадковості, творчості та різноманітності дозволяє отримати краще уявлення про результат навчання GAN, і, відповідно, відкоригувати його. Отже, розробка методу на основі WGAN GP із застосуванням методу аугментації DAG з подальшою оцінкою за критеріями спадковості, творчості та різноманітності, є адекватною для вирішення проблеми низької доступності аберометричних даних.

2.2. Запропонований метод для генерування аберометричних даних

Запропоноване в даній роботі розв'язання проблеми генерації аберометричних даних містить в собі застосування WGAN GP у поєднанні з DAG. Для випробувань запропонованого методу застосовуватимуться коефіцієнти з [16] для мод Церніке з 1 по 6 радіальний порядок – ті, що найчастіше використовуються в офтальмології, а оцінка результатів здійснюватиметься за метриками спадковості, творчості та різноманітності.

2.2.1. Структура методу навчання

З метою пришвидшення навчання та виключення складних залежностей, які GAN має генерувати, пряме $W(C)$ та зворотне $W^{-1}(w)$ перетворення набору коефіцієнтів C у зображення хвильового фронту w і навпаки здійснюватиметься тільки для застосування реверсивних перетворень на основі методів обробки зображень, в усіх інших випадках дані представлені у вигляді векторів коефіцієнтів Церніке з нормованими у $[0;1]$ значеннями (Рис. 2.2).

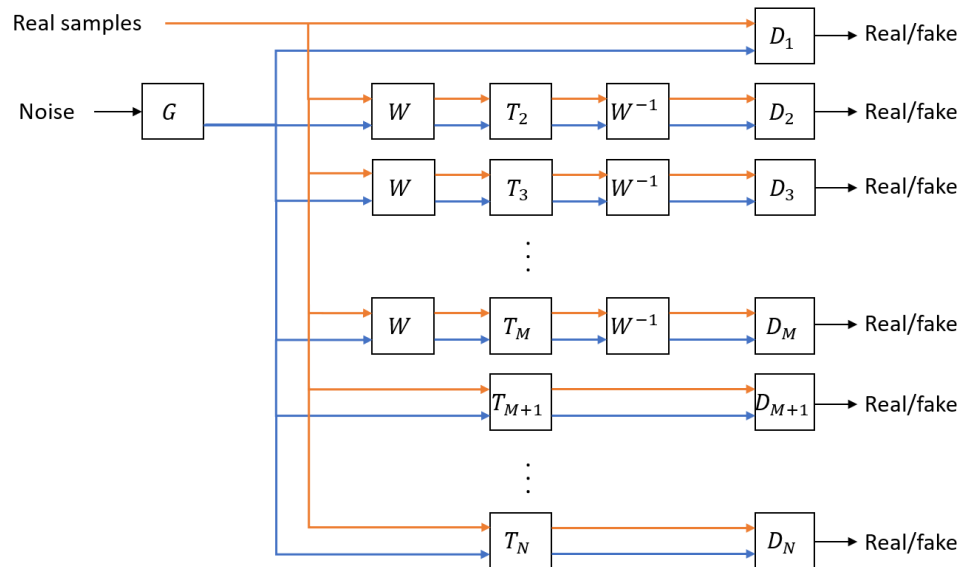


Рис.2.2. – Спрощена схема навчання WGAN GP шляхом аугментації даних за методом DAG.

Перетворення T_1 є фактичною передачею набору коефіцієнтів без змін, перетворення від T_2 до T_M потребують застосування $W(C)$ та $W^{-1}(w)$ і охоплюють класичні способи аугментації зображень як-от віддзеркалення, поворот на 90° та ін., а аугментації з T_{M+1} по T_N – стосуються перетворень векторів, тобто перемішування, масштабування та ін. Повний список перетворень T_k наведений у Таблиці 2.1.

Таблиця 2.1. Перетворення для аугментації даних

№, k	Тип даних	Перетворення, T_k
1	Набір коефіцієнтів Церніке	Відсутність перетворення
2	Зображення хвильового фронту	Обертання на 180° за годинниковою стрілкою
3	Зображення хвильового фронту	Віддзеркалення по осі X (верх-низ)
4	Зображення хвильового фронту	Обертання на 90° за годинниковою стрілкою, а потім віддзеркалення по осі Y (ліво-право)

5	Набір коефіцієнтів Церніке	Обмін місцями першої та другої половини кожного вектора
6	Набір коефіцієнтів Церніке	Розташування елементів вектора у зворотному порядку

Згідно з обраним способом WGAN GP, функції втрат для критиків матимуть вигляд:

$$L_{D_k} = \mathbb{E}[D_k(T_k(x))] - \mathbb{E}[D_k(T_k(G(z)))] + \lambda \mathbb{E}[(\|\nabla_{\hat{x}} D_k(\hat{x})\|_2 - 1)^2],$$

де:

$$\hat{x} = tT_k(x) + (1 - t)T_k(G(z)), \quad t - \text{випадкове число в межах } [0, 1].$$

Але, через те, що критик за DAG є однією мережею з $N = 6$ «кінцівок» у вигляді одного класифікуючого шару, то його загальна функція втрат розраховується як:

$$L_D = L_{D_1} + \frac{\lambda_u}{K - 1} \sum_{k=2}^{K=6} L_{D_k}, \quad \lambda_u = 0.4$$

Для генератора функція втрат враховуватиме відгуки усіх критиків:

$$L_{G_k} = -\mathbb{E}[D_k(T_k(G(z)))].$$

Аналогічно до критика, загальна функція втрат генератора:

$$L_G = L_{G_1} + \frac{\lambda_v}{K - 1} \sum_{k=2}^{K=6} L_{G_k}, \quad \lambda_v = 0.4$$

2.2.2. Архітектура мереж

Генератор та критик мають доволі просту структуру багат шарових персептронів (Рис.2.3) з поступовим збільшенням (для генератора) та зменшенням (для критика) елементів в кожному шарі.

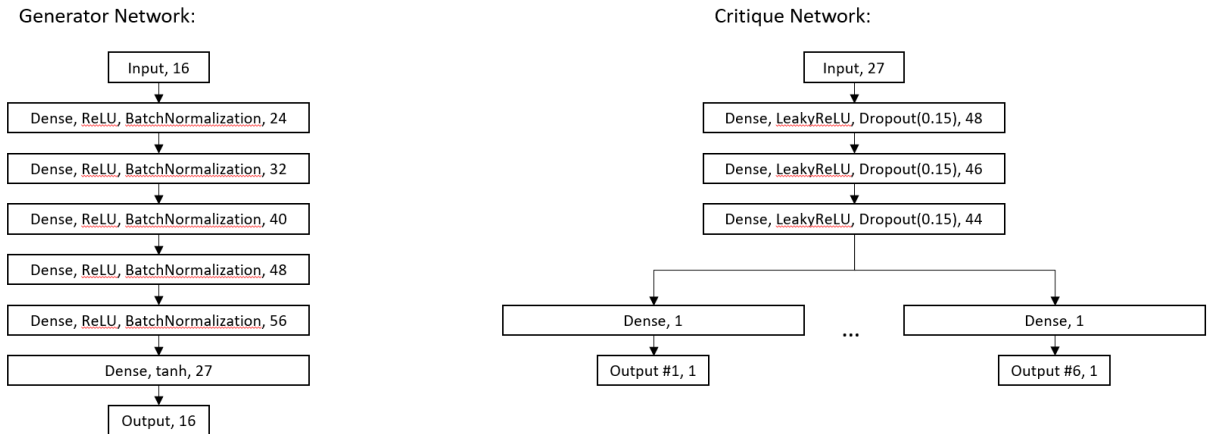


Рис.2.3. – Архітектури мереж генератора та критика.

Згідно з методом DAG, критик є мережею з одним входом та декількома виходами – по одному виходу D_k на кожне перетворення T_k . Надалі буде показано, що вибір архітектури мереж є вдалим, але варто зазначити, що застосування більш сучасних мереж здатне забезпечити кращий результат, втім, вимагатиме значно більших зусиль та витрат часу на підбір гіперпараметрів та налаштувань навчання.

2.2.3. Навчання нейронних мереж

Згідно з алгоритмом тренування WGAN GP, перед кожною ітерацією оновлення ваг генератора, відбувається декілька ітерацій оптимізації ваг критика. В даній роботі ця кількість дорівнює 8. Розмір мінівибірки (т.зв. minibatch) дорівнює 8. Для оновлення ваг використовується оптимізатор Adam [40]. Він поєднує два методи градієнтного спуску: градієнтний спуск з моментом (англ. Gradient Descent with Momentum, GDM) та середньоквадратичне розповсюдження (англ. Root Mean Square Propagation, RMSProp):

$$\begin{aligned}
 m_l &= \beta_1 m_{l-1} + (1 - \beta_1) \nabla E(\theta_l), \\
 v_l &= \beta_2 v_{l-1} + (1 - \beta_2) [\nabla E(\theta_l)]^2, \\
 \hat{m}_l &= \frac{m_l}{(1 - \beta_1^l)}, \\
 \hat{v}_l &= \frac{v_l}{(1 - \beta_2^l)},
 \end{aligned}$$

$$\theta_{l+1} = \theta_l - \frac{\alpha \hat{m}_l}{\sqrt{\hat{v}_l} + \varepsilon},$$

де: l – номер поточної ітерації, m_l – ковзне середнє значення градієнта функції втрат (оцінка), \hat{m}_l – ковзне середнє значення градієнта функції втрат (кориговане значення), ∇E – градієнт функції втрат на даній навчальній підмножині (англ. mini-batch) навчальної вибірки, v_l – ковзне середнє значення квадрата градієнта функції втрат (оцінка), \hat{v}_l – ковзне середнє значення квадрата градієнта функції втрат (кориговане значення), β_1 – фактор затухання градієнта, β_2 – фактор затухання квадрата градієнта, θ_l – вектор параметрів нейронної мережі на l -тому кроці алгоритму, α – швидкість навчання, ε – параметр для запобігання діленню на 0.

Використовуються значення параметрів, запропоновані в оригінальній роботі [40], окрім коефіцієнта навчання: 1×10^{-4} для генератора та 2×10^{-4} для критика. Параметр λ для функції втрат критика дорівнює 10. Кількість епох навчання обрано 1000. Значення k_1 та k_2 для розрахунку SSIM обрано 0.01.

2.3. Результати навчання та їх оцінка

Підготовка, навчання та оцінка мереж здійснювалась в середовищі Kaggle [41] із застосуванням поширених бібліотек TensorFlow [42], SciPy [43], Matplotlib [44] для мови програмування Python.

Для відслідковування якості згенерованих даних, протягом навчання застосовується значення відстані Фреше між згенерованими 50 наборами коефіцієнтів Церніке та реальною вибіркою з 50 наборів (Рис.2.4).




Рис.2.4. – Відстань Фреше між згенерованими та реальними даними протягом навчання.

Як можна побачити з Рис.2.4, застосування DAG до навчання WGAN GP забезпечує збіжність та стабільність якості генерації. Отримане значення відстані Фреше, яка в даному випадку є метрикою спадковості, дорівнює 0.7. Оскільки поки не існує порогових значень цієї відстані, за якими можна визначити, наскільки дотримана спадковість при генерації, для даної роботи пропонується візуально оцінити якість згенерованих значень (Рис.2.5, 2.6).




Рис.2.5. – Нормальні розподіли згенерованих (вузькі стовпці - ± 1 СКВ, хрестик – середнє значення, мкм) та реальних (широкі стовпці - ± 1 СКВ, коло – середнє значення, мкм) коефіцієнтів Церніке: а) усі коефіцієнти з $n = 1.6$; б) коефіцієнти з C_3^1 по C_6^6 .

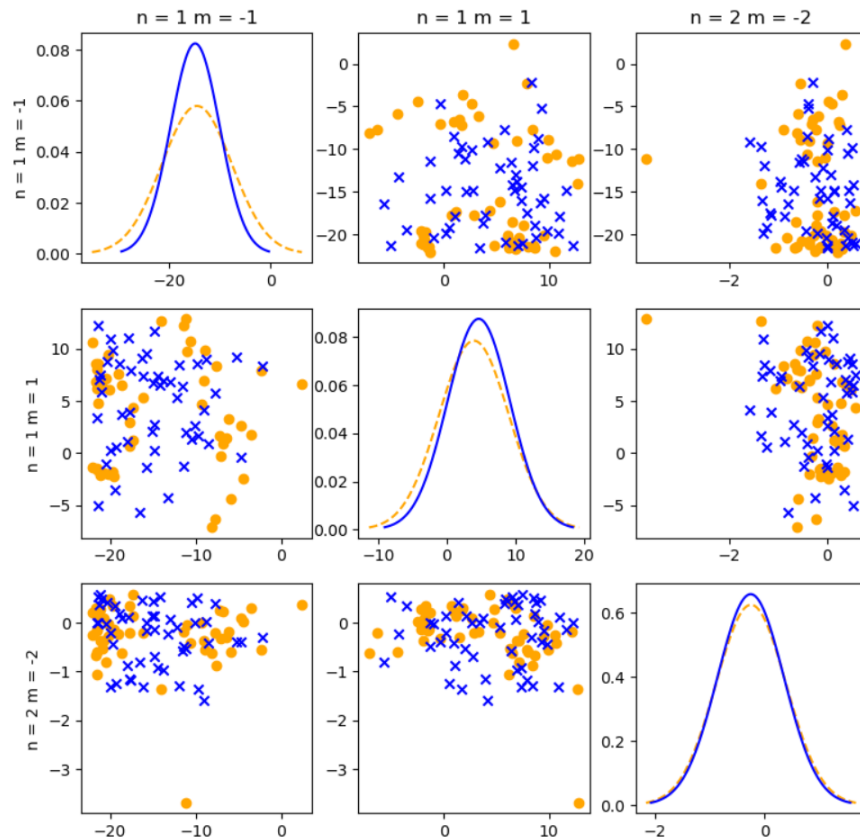


Рис.2.6. – Демонстрація парних відношень значень згенерованих (хрестик) та реальних (коло) коефіцієнтів Церніке в мкм. По діагоналі розташовані розподіли згенерованих (суцільна лінія) та реальних (пунктирна лінія) значень окремих коефіцієнтів.

Значення метрики творчості для згенерованого набору дорівнює 0.92, що вказує на те, що значна частина згенерованих векторів не є копіями примірників з навчаючої вибірки. Для синтезованих векторів значення метрики різноманітності є 3.64, що є близьким до оптимального показника у 3.83 (коли у кожному кластері лише по одному вектору).

Отже, запропонований метод придатний для генерації штучних навчаючих вибірок аберацій людського ока у вигляді коефіцієнтів Церніке. Згенеровані дані якісно наслідують оригінальні розподіли даних, при цьому не є копіями реальних примірників та мають малу кількість самоповторень.

Висновок до Розділу 2

1. В даній роботі запропоновано метод генерації аберометричних даних, який полягає у створенні архітектури нейромереж, що складають WGAN GP, із подальшим їхнім навчанням із використанням методу аугментації DAG, який застосовується для представлення коефіцієнтів Церніке у графічній та векторній формах.

2. За результатами навчання WGAN GP можна стверджувати, що запропонований метод придатний до синтеза даних, що мають розподіл, схожий з навчаючою вибіркою (відстань Фреше дорівнює 0.7), і які одночасно не є копією реальних примірників (92% за метрикою творчості) та примірники яких є різноманітними (значення відповідної метрики дорівнює 3.64, оптимальним є значення 3.83).

РОЗДІЛ 3. Одночасне сканування масивом випромінювачів для рейтрейсингового методу аберометрії

З метою підвищення прецизійності вимірювань методом рейтрейсингової аберометрії, пропонується, за аналогією з ФАР, використовувати масив сканувальних випромінювачів, які працюють одночасно та заздалегідь спрямовані на відповідні зіничні координати, а, для фотофіксації відбитого випромінення – світлочутливу матрицю. Підхід може бути імплементований, в конструкції, запропонованій в [4] (Рис.1.10). Поліпшення конструкції шляхом встановлення камери поруч з вихідною оптикою випромінювачів призвело до зменшення кількості світлоподілювачів, що забезпечує більшу потужність променів, які потрапляють до фотоприймача, і, як наслідок, покращує точність визначення відхилень. Варто відмітити, що фотоприймач в такому випадку також по-суті працює аналогічно ФАР, з тією різницею, що, по-перше, пікселі не розміщуються поруч із кожним випромінювачем, а, по-друге, кількість приймачів набагато більша за кількість випромінювачів. Отже, проблема збільшення кількості просканованих позицій під час однієї процедури вимірювання, вже попередньо вирішена на рівні оптичної системи, необхідної для реалізації методу. Очевидно, що розрахунок коефіцієнтів Церніке в рамках запропонованої модифікації виконується так само, як і для оригінального методу рейтрейсингової аберометрії, оскільки вдосконалення впливає лише на кількість одночасно виміряних поперечних аберацій. Однак, у випадку застосування декількох зондуючих променів, все ще залишається проблема співставлення вхідних променів та їхніх відбитків.

У контексті розробки методів вдосконалення аберометрії актуальним є визначення та аналіз аберацій шляхом застосування сучасних технологій, зокрема штучних нейронних мереж. Після отримання фотофіксації координат відбитків та розрахунку їхнього положення на сітківці, необхідно встановити точну відповідність між променями та їхніми відбитками. Для цього було розроблено нейронну мережу, яка виконує розрахунок вірогідності належності кожного відбитку до певного променя.

Після обчислення вірогідності застосовується угорський алгоритм [45] для максимізації сум вірогідностей, що дозволяє визначити однозначну відповідність між відбитками і зондуючими променями. Це забезпечує більш точне та надійне визначення аберацій.

Для навчання нейронної мережі та перевірки роботи алгоритму були згенеровані набори коефіцієнтів Церніке та координат відбитків на сітківці. Ці набори даних були створені за допомогою спеціалізованого програмного забезпечення для рейтрейсингової симуляції оптичних систем, що забезпечує високу точність і реалістичність отриманих даних.

Цей розділ присвячений вдосконаленню існуючої модифікації рейтрейсингового методу шляхом встановлення відповідності між променями та їхніми відбитками за допомогою штучних нейронних мереж та Угорського алгоритму. Окрім того, в розділі розглядаються недоліки модифікації та обґрунтовується потреба у розробці нового способу проведення вимірювань.

3.1. Одночасне сканування

В якості шаблону для засвічування на зіниці обрано набір концентричних кіл (Рис.3.1). Перевагою саме цього набору є можливість утворення більших за кількістю точок шаблонів шляхом повороту та накладання, оптимальний розрахунок яких наведений в [10]. Сканувати око пропонується лазерними променями із довжиною хвилі 0.67 мкм, як це зроблено в [4].




Рис.3.1. - Шаблон сканування ока шляхом засвічування точок на зіниці.
Усі одиниці в 1/радіус зіниці.

3.2. Представлення даних та навчаюча вибірка

Відбитки від сітківки формують зображення на фотоприймальному обладнанні, які, очевидно, доречно обробляти згортковою нейронною мережею. Однак, наявність великих за розміром «пустих місць» на знімку – областей зі значенням, близьким до 0 – негативно впливатиме на результат класифікації згортковими шарами, оскільки вони навчаються реагувати на певні шаблони на зображенні, а світлові плями на однорідному темному фоні не здатні зформувати якийсь безперервний шаблон. Тому інформація про відбитки надходитиме до нейронної мережі у вигляді координат на сітківці.

Через те, що для нейронних мереж порядок запису вхідних даних має значення, його уніфіковано шляхом сортування відбитків по осі Oy. Тому, інформація про відбитки променів подається в формі матриці:

$$\mathbf{X} = \begin{bmatrix} x_0 & y_0 \\ x_1 & y_1 \\ \vdots & \vdots \\ x_N & y_N \end{bmatrix},$$

де N – кількість точок в шаблоні, (x_0, y_0) - координати відбитку на сітківці із найменшим значенням по осі Oy, (x_N, y_N) - координати відбитку на сітківці із найбільшим значенням по осі Oy. Значення x та y зберігаються у мікрометрах.

Навчаючу та валідаційну вибірки підготовлено у спеціалізованому програмному забезпеченні для оптичних рейтрейсингових симуляцій Zemax [46] із використанням спрощеної моделі релаксованого ока (фокус оптичної системи ока майже збігається з сітківкою) за авторством Н.-Л. Liou та N.A. Brennan [47, 48] (Рис.3.2), до якої включено віртуальний шар для додавання аберацій.




Рис.3.2. - Використана модель ока в програмі Zemax.

Для генерування вхідних даних (координати точок сканування, набори коефіцієнтів Церніке, і т.д.) розроблено програму на мові MATLAB. Коефіцієнти поліномів Церніке (Рис.3.3) згенеровано як набори випадкових чисел за нормальним розподілом із середнім значенням 0, зі стандартними відхиленнями та максимальними і мінімальними значеннями, які є збільшеними відносно клінічних даних, наведених у [49]. Розрахунок координат відбитків променів на сітківці здійснюється у середовищі Zemax за програмою на мові Zemax Programming Language. Файл із вхідними даними зберігається у .dat форматі, вихідний файл зберігається в форматі .csv для подальшого навчання нейронної мережі.




Рис.3.3. - Налаштування генерування наборів коефіцієнтів Церніке. Червоним кольором позначено межі 1 СКВ, чорним – межі мінімального та максимального значень коефіцієнтів. Нумерація коефіцієнтів за Ноллом [50].

Синтетична генерація навчаючої вибірки має певну перевагу над застосуванням вимірювань в якості навчаючої вибірки, а саме – гнучкість і контрольованість її налаштувань: кількість вхідних наборів, межі значень параметрів, та ін. Втім, очевидно, така вибірка не є точним відображенням реального розподілу аберацій людського ока серед населення. З іншого боку, для навчання нейронної мережі може знадобитися більше вхідних наборів, ніж доступно реальних вимірювань. Тож, штучне урізноманітнення та генерування даних доволі часто є необхідністю. Таким чином, генерування цілком синтетичної навчаючої вибірки в даній роботі хоч і не є точним відображенням реальності, втім, може бути прийнятним до отримання навчаючої вибірки зібраної виключно з клінічних вимірювань. Застосування розробленої в ході роботи над дослідженням мережі-генератора зі складу GAN було б виправданим, втім, як це зазначено в роботі [15], не покриває значну кількість розповсюджених рефракційних похибок ока, тому, для перевірки працездатності методу співставлення променів та відбитків, випадкова генерація залишається більш актуальною опцією.

3.3. Класифікаційна нейронна мережа

Для визначення ймовірності належності відбитку зондуєчому променю, розроблено нейронну мережу, структуру якої наведено на Рис.3.4. Імплементацию мережі виконано на мові програмування Python із використанням спеціалізованої бібліотеки TensorFlow [42]. Програмним

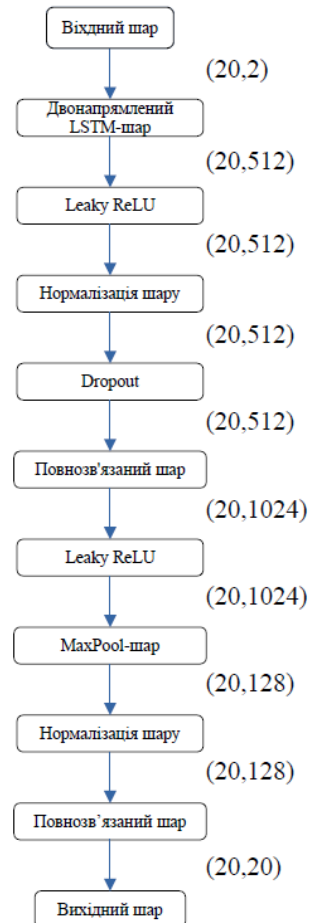


Рис.3.4. - Структура нейронної мережі для визначення відповідностей променів та відбитків. Окрім видів шарів наведено також розміри матриць даних.

середовищем для навчання та аналізу виступає Google Colaboratory [51] – спеціальний ресурс, який надає віддалений доступ до високопродуктивних графічних прискорювачів.

Проблему, яка має вирішуватись нейронною мережею в даній роботі, можна сформулювати як класифікацію кожного елементу певного вхідного набору даних із урахуванням інформації про інші елементи у тому ж наборі.

У розв'язанні цієї задачі доцільним є використання LSTM-шарів [52], характерною особливістю яких є збереження інформації про довгострокові залежності між елементами послідовності. Основна ідея LSTM полягає у використанні спеціальних комірок (Рис.3.5), які дозволяють додавати або видаляти інформацію через керуючі механізми, що називаються вентилями. Сама LSTM-комірка працює як конвеєр, через який проходить інформація з мінімальними змінами, що дозволяє зберігати важливі дані протягом тривалого часу.




Рис.3.5. – Рекурентна LSTM-комірка [53].

Роботу комірок доцільно розглядати у розгорнутій формі (Рис.3.6), де кожна комірка представляє собою ітерацію роботи по відношенню до елементу послідовності, яку в даному випадку складають координати точок в шаблоні.




Рис.3.6. – Робота LSTM-комірки у вигляді розгортки [53].

Як можна побачити з Рис.3.6, вхідними елементами виступають елементи послідовності x_t , вихідні значення позначені h_t . Внутрішній стан комірки C_t оновлюється та передається знов в комірку за допомогою зворотного зв'язку (Рис.3.7).




Рис.3.7. – Зворотний зв'язок за станом в LSTM-комірці [53].

Кожна LSTM-комірка складається з т.зв. вентилів – функцій, які керують потоком інформації в модулі. Як і для інших типових шарів, які застосовуються в машинному навчанні, параметрами комірок, що будуть оновлюватися під час навчання, є ваги та зміщення:

$$W = \begin{bmatrix} W_i \\ W_f \\ W_g \\ W_o \end{bmatrix}, \quad R = \begin{bmatrix} R_i \\ R_f \\ R_g \\ R_o \end{bmatrix}, \quad b = \begin{bmatrix} b_i \\ b_f \\ b_g \\ b_o \end{bmatrix},$$

де, W – вхідні ваги, R – рекурентні ваги, b – зміщення, а індекси i, f, g та o позначають відповідність до вентилів: вхідного (англ. input gate), забування (англ. forget gate), визначення стану-кандидата (англ. cell candidate) та вихідного вентиля відповідно.

Перед початком обробки кожного елемента послідовності, вентилям забування «відфільтровується» інформація, а саме попереднє вихідне значення, тобто його вплив на розрахунок наступного вихідного значення (Рис.3.8) [54]:

$$f_t = \sigma(W_f x_t + R_f h_{t-1} + b_f),$$

де $\sigma(\cdot)$ – функція сигмоїда.




Рис.3.8. – Задіяний вентиль забування [53].

Результатом першого кроку є число від 0 до 1, де 0 відповідає повному відкиданню минулого стану, а 1 – повному збереженню. Надалі розраховується значення вхідного вентиля i_t та стану-кандидата \tilde{C}_t :

$$i_t = \sigma(W_i x_t + R_i h_{t-1} + b_i),$$

$$\tilde{C}_t = \tanh(W_g x_t + R_g h_{t-1} + b_g).$$

Загальну схему роботи цього етапу розрахунку наведено на Рис.3.9.




Рис.3.9. – Етап розрахунку значення вхідного вентиля i_t та стану-кандидата \tilde{C}_t [53].

Внутрішній стан C_t розраховується як комбінація попередніх етапів роботи LSTM-комірки (Рис.3.10):

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t,$$

де \odot - оператор по-елементного перемноження векторів.




Рис.3.10. – Розрахунок стану C_t [53].

Вихідне значення h_t є комбінацією роботи вихідного вентиля та раніше розрахованого стану:

$$o_t = \sigma(W_o x_t + R_o h_{t-1} + b_o),$$

$$h_t = o_t \odot \tanh(C_t).$$

З метою охоплення всього вхідного набору при класифікації кожного відбитку, застосовано двонапрявлений LSTM-шар [55]. Потім, дані оброблюються повнозв'язним шаром, за яким йде MaxPool-шар задля зменшення кількості параметрів для навчання без втрати інформації. Наступним повнозв'язним шаром розраховуються остаточні вірогідності. В ході випробувань виявилось, що використання функції активації Leaky ReLU [56] та шарів нормалізації [57] покращує точність розпізнавання, тому їх додано після двонапрявленого LSTM-шару та одного з повнозв'язаних шарів. Шар dropout, який з налаштованою частотою множить на 0 виходи попереднього шару, додано з метою запобігання перенавчанню (англ. overfitting) – ситуації, за якої нейронна мережа значно краще класифікує навчаючу вибірку, ніж валідаційну.

3.4. Навчання нейронної мережі

Для навчання нейронної мережі використовується бінарна кросентропійна функція (англ. Binary Crossentropy) втрат:

$$L = - \sum_i^M y_i \log(p_i),$$

де L – значення функції втрат, M – кількість класів, y_i – очікувана вірогідність належності вхідного набору до i -го класу, p_i – передбачувана нейронною мережею вірогідність належності вхідного набору до i -го класу.

Оптимізатором обрано Adam [40], для даної роботи коригуючі параметри β_1 та β_2 дорівнюють значенням, запропонованим в [40] – 0.9 та 0.999 відповідно. Коефіцієнт навчання експоненційно зменшується за формулою:

$$\alpha_t = \alpha_0 \cdot decay_{rate}^{\frac{t}{t_{decay}}} \quad (3.1)$$

де α_0 – початкове значення коефіцієнту навчання (в даній роботі обраний 0.001), $decay_{rate}$ – параметр, який вказує, у скільки разів зменшиться α після t_{decay} ітерацій роботи оптимізатора. Для даної нейронної мережі дослідним шляхом обрано $decay_{rate} = 0.95$, t_{decay} дорівнює кількості міні-вибірок (mini-batch) в одній епосі навчання, оскільки на одній ітерації роботи оптимізатора ваги мережі оновлюються по усередненій функції втрат по всій міні-вибірці, розмір якої обрано 128.

3.5. Результати

Експериментально встановлено, що 10 епох достатньо для навчання нейронної мережі. Оскільки, в даному випадку, навчаюча вибірка отримана не шляхом реальних вимірювань, а є штучно згенерованою і може налаштовуватись, то адекватним є пошук достатньої кількості наборів вхідних даних у вибірці. Залежність між розміром навчаючої вибірки та якістю класифікації наведено в Таблиці 3.1.

Таблиця 3.1. Залежність якості класифікації від розміру навчаючої вибірки.

Кількість наборів навчачий/тестовий вибірки, шт.	вх. в	Середня точність співставлення нейр.мережею, %	Середня точність співставлення після застосування Угорського алгоритму, %	Найбільша кількість некоректно класифікованих точок в одній вибірці, шт.
14400/3600		83.33	84.91	20
28800/7200		85.54	86.92	19
57600/14400		87.46	88.56	20
115200/28800		96.15	96.48	20
144000/36000		100	100	0

Як можна побачити, найвища точність класифікації досягається за 144000 вхідних наборів координат на сітківці.

Збільшення кількості одночасно просканованих зіничних координат шляхом використання запропонованого вдосконалення дозволяє значно зменшити довірчий інтервал, підвищуючи прецизійність вимірювань. Наприклад, для іTrase заявлено виконання максимум 5 вимірювань кожної з 256 зіничних координат, тобто за весь сеанс аберометрії здійснюється сканування 1280 точок. При збільшенні кількості одночасно відсканованих точок до 16, з'являється можливість підняти кількість вимірювань кожної точки до 80. В такому випадку, якщо приймати 95%-довірчий інтервал як

$$CI = 2 \times 1.96 \times SE,$$

де CI – довірчий інтервал, SE – стандартна похибка:

$$SE = \frac{s_w}{\sqrt{2n(m-1)}},$$

де s_w – дисперсія вимірювань в межах одного вимірюваного екземпляру, n – кількість вимірюваних екземплярів у вибірці, m – кількість повторюваних

вимірювань, то зменшення довірчого інтервалу розраховуватиметься за формулою

$$\frac{CI_1}{CI_2} = \sqrt{\frac{m_2 - 1}{m_1 - 1}}.$$

При збільшенні кількості повторюваних вимірювань з $m_1=5$ до $m_2=80$, довірчий інтервал зменшиться в 4.4 рази, що є суттєвим показником.

Загальна точність класифікації є високою, що вказує на ефективність запропонованого методу. Втім, існує ймовірність того, що протягом застосування запропонованого методу з'являться окремі випадки з певною кількістю некоректно класифікованих відбитків. Це можна подолати кількома шляхами, серед яких:

- вдосконалення архітектури нейронної мережі;
- збільшення розміру навчальної вибірки;
- корекція результату класифікації іншими методами після застосування нейронної мережі.

Таким чином, розроблена в рамках дослідження модифікація, яка використовує конструкцію, запропоновану в [4], впроваджує одразу декілька вдосконалень до існуючої версії методу рейтрейсингової абераметрії, а саме: істотне зменшення довірчого інтервалу, усунення потреби у складному елементі керування скануючим променем, позбавлення необхідності у великій кількості оптичних елементів включно із світлоподільником, що вимагає більш чутливого сенсора через зменшення яскравості падаючого на детектор випромінення. Втім, практична реалізація методу вимагає більш складної оптики для фотоприймача, яка здатна перетворити розсіяний потік відбитого від сітківки світла в невеликого розміру світлову пляму та загалом бути відносно малого розміру, щоб, при збірці кінцевого приладу, дозволити монтаж достатньої кількості лазерних випромінювачів. В свою чергу кількість точок сканування визначається розмірами вихідної оптики (4 на Рис.1.10) і обмежена

(в запропонованій в [4] версії) середнім діаметром зіниці, тобто для сканування ока лазерними променями, що падають на нього паралельно головній оптичній осі системи «блок випромінення – око», треба в колі, діаметром в 6 мм (середній діаметр зіниці) розмістити вхідну оптичну систему фотодетектора та вихідні оптичні елементи випромінювачів.

Отже, запропоноване вдосконалення є працездатним та дозволяє поліпшити можливості рейтрейсингового методу аберометрії шляхом зміни підходу до сканування ока. Дослідження результативності модифікації показало можливість точного співставлення променів сканування та їхніх відбитків, і, як наслідок, можливість надійного одночасного сканування. В свою чергу, використання існуючої модифікованої конструкції підтверджує можливість практичної реалізації вдосконаленого методу аберометрії. Однак виявлені складнощі, пов'язані з вимогами до мініатюризації елементів оптичних систем аберометрів, які вказують на обмежені можливості по збільшенню точок сканування або його високу ціну за наявної елементної бази. Таким чином, залучення нових способів обробки та вимірювання для забезпечення можливості одночасного сканування з відслідковуванням променів є пріоритетним при вирішенні актуальної та важливої задачі вдосконалення рейтрейсингового методу аберометрії ока.

Висновок до Розділу 3

1. Запропоновано модифікацію методу рейтрейсингової аберометрії ока, яка полягає в тому, що масив випромінювачів використовується для одночасного сканування ока в декількох зіничних координатах, а встановлення відповідності «зондуючий промінь – відбиток на сітківці» здійснюється шляхом застосування нейронної мережі класифікації, із подальшим уточненням угорським алгоритмом.

2. Створено нейронну мережу для встановлення відповідності «зондуючий промінь – відбиток на сітківці» для збільшення кількості сканованих позицій під час вимірювань модифікованим рейтрейсинговим

методом аберометрії в одночасному режимі, що має на меті збільшення роздільної здатності визначеного хвильового фронту похибок та пришвидшення вимірювання.

3. За результатами навчання нейронної мережі встановлено, що запропонована модифікація методу є ефективною – середня точність класифікації дорівнює 100 %. Цього вдалося досягти використанням штучної генерації навчаючої вибірки у спеціалізованому програмному забезпеченні, що, у випадку обмеженості реальних вимірювань у відкритому доступі, можна вважати прийнятним.

4. Потенційна імплементація запропонованого вдосконалення здатна значно зменшити довірчий інтервал, підвищуючи прецизійність. Наприклад, для аберометра iTrace одночасне сканування 16 точок замість 1 зменшує довірчий інтервал у 4.4 рази.

5. Виявлені складнощі, пов'язані з вимогами до мініатюризації елементів оптичних систем аберометрів, які вказують на обмежені можливості по збільшенню кількості точок сканування або його високу ціну за наявної елементної бази. Таким чином, залучення нових способів обробки та вимірювання даних для забезпечення можливості одночасного сканування з відслідковуванням променів є пріоритетним при вирішенні актуальної та важливої задачі вдосконалення рейтрейсингового методу аберометрії ока.

РОЗДІЛ 4. Нейромережна модифікація методу рейтрейсингової аберометрії

Як вже було згадано раніше, недоліки наявних методів аберометрії ока значною мірою залежать від технологічних обмежень оптичної складової вимірювальних приладів. Дійсно, роздільна здатність сенсора Гартмана-Шека обмежується наявними на даний момент виробничими можливостями, на додачу до цього, при збільшенні кількості субапертур збільшується ризик перехрещення сфокусованих світлових потоків, що призводитиме до некоректних вимірювань. В свою чергу вдосконалення для імплементації існуючої модифікації рейтрейсингового методу аберометрії також залежить від мініатюризації детектора та оптичної складової апаратного комплексу приладу. Цілком логічним в такому випадку є пошук рішень для спрощення оптичної складової, яка б, з одного боку, була нескладною, бо кожен оптичний елемент може вносити похибки, обумовлені власними дефектами, та зменшувати інтенсивність світлового потоку, а з іншого – надавала можливість отримувати якомога точну інформацію про аберації. Також актуальним покращенням є пришвидшення процесу вимірювання для запобігання спотворень, викликаних мікро-рухами ока, та підвищення прецизійності вимірювань. Зважаючи на перераховані потреби, які мають бути задоволені вдосконаленими методами, логічним є синтез нового методу на основі існуючих.

Цей розділ містить опис модифікації методу рейтрейсингової аберометрії, яка використовує нову оптичну систему. Очевидно, що зміна способу вимірювання та оптичної системи вимагає відповідних змін у процесі обробки даних. У зв'язку з цим, у розділі розглядається перше наближення визначення результатів аберометрії штучною нейронною мережею. Особливу увагу приділено засобами корекції, які дозволяють покращити якість отриманих результатів аберометрії та забезпечити точність діагностики. У розділі детально описуються різні підходи до корекції із використанням методів машинного навчання. Ці підходи дозволяють врахувати специфічні

особливості нової оптичної системи та забезпечити корекцію визначення аберацій.

4.1. Процес вимірювань

Перевагою методу Гартмана-Шека є доволі простий спосіб виявлення аберацій шляхом створення на сітківці точкового джерела світла лазером, спрямованим на сітківку в точці її перетину з головною оптичною віссю ока. Водночас відслідковування окремих променів є сильною стороною рейтрейсингового методу, що дозволяє вимірювати найсильніші аберації. Оскільки створення оптичної системи, яка втілює в собі ці окремі переваги методів аберометрії, є доволі складним процесом, логічним є вдосконалення саме способів обробки вимірювань, тобто визначення аберацій за інформацією, отриманою з фотодетекторів. Очевидно, що найпростішим рішенням буде наслідування методу Гартмана-Шека, тобто підсвічування ока лазерним променем. В такий спосіб отримується інформація одночасно про всі аберації ока. Кути нахилу відбитих променів, що розповсюджуються від сітківки назовні, є корисною інформацією для розрахунку аберацій. Логічно, що неможливо відслідкувати кожен промінь в світловому потоці, однак цілком можливо отримати «переріз» світлового потоку, просто спрямовуючи його на фотодетектор. Однак, в такому випадку світлова пляма на фотодетекторі є інтегральною інформацією, оскільки одну й ту саму фотографію на фоточутливій матриці можна отримати різними наборами кутів нахилу променів. Для вирішення цієї проблеми можна залучити ще один або більше фотодетекторів, таким чином отримуючи більше одного «перерізу» світлового потоку, а його розподіл здійснити шляхом використання світлоподільної пластини. Запропонована оптична система наведена на Рис.4.1.




Рис.4.1. – Запропонована оптична система для модифікованого методу.

Очевидно, що довжина оптичного шляху також впливає на можливість розрізнення впливу найменших аберацій на форму світлової плями, і, відповідно, має бути достатньою для їх виявлення. Втім, для реалізації цих умов неоптимальним буде просте збільшення відстані між детекторами та оком, оскільки такий підхід може значно збільшити лінійні розміри аберометра на основі модифікованого рейтрейсингового методу. Для подолання цього обмеження існують оптичні структури, що складаються з дзеркал. Прикладом такої структури комірка, описана в [58], яка дозволяє збільшити оптичний шлях до 50 м, використовуючи два циліндричних дзеркала діаметром 40 мм на відстані 88.9 мм. В даній роботі для перевірки працездатності методу шляхом моделювання, регулювання довжини оптичного шляху, з метою спрощення моделювання, здійснюється фактичною зміною відстані від ока до детекторів. Втім, на практиці, вибір способу збільшення оптичного шляху відбитого від сітківки випромінення залежатиме від декількох факторів, які мають бути враховані під час проектування аберометра на основі модифікованого рейтрейсингового методу, зокрема:

- діапазону значень коефіцієнтів Церніке, які прилад має бути здатен виміряти;
- обмежень на розміри приладу.

В даній роботі пропонується використовувати знімки світлових плям, що утворюються на детекторі відбитим від сітківки розсіяним випроміненням, форму яких обумовлюють наявні в оптичній системі ока аберації.

4.2. Первинна обробка вимірювань

З метою відокремлення корисної для визначення аберацій інформації з кадрів, необхідне застосування фільтрації та інших методів обробки зображень. В даній роботі працездатність методу перевірялась в програмному пакеті Zemax [46] в системі, зображеній на Рис.4.2. Використовується модель людського ока, заснована на роботі [47] та імплементована для використання в Zemax в [48]. Аберації моделюються шляхом викривлення рогівки, сітківка моделюється як ідеальний рефлектор, що відбиває 5% падаючого випромінення. В свою чергу світлоподільники складаються з двох трикутних 45°-призм, з матеріалу, який пропускає 95% падаючого випромінення, а відбиває 5%, а, в свою чергу, безпосередньо світлоподільна пластина пропускає та відбиває по 50% падаючого випромінення. Підсвічування ока здійснюється лазерним променем з довжиною хвилі 0.67 мкм як і в попередніх симуляціях.




Рис.4.2. – Моделювання запропонованої оптичної системи в середовищі Zemax.

В Zemax здійснюється моделювання окремих променів, тому набір перетворень для зображень, отриманих шляхом симуляції, відрізнятиметься від необхідних перетворень для реального пристрою. В даній роботі, на додачу до обробки зображень з детекторів з метою відфільтровування, необхідним кроком є наближення знімків до реальних шляхом додаткового застосування морфологічних перетворень. Для відокремлення світлової плями, що утворюється на детекторах, застосовується порогова обробка, причому залежно від наявності відбитку самого скануючого променю – один або два рази. Також, у випадку потрапляння віддзеркалення лазерного променю на детектор, застосовується операція заповнення отворів, описана в [59], з метою заповнення простору на зображенні, що залишився після видалення відбитку променю. Відфільтровування шуму у вигляді окремо підсвічених пікселів, а також з'єднання в одну світлову пляму, здійснюється послідовним застосуванням операцій замикання та розмикання. Приклад результату перетворення зображення, отриманого в середовищі Zemax, в зображення для подальшого визначення аберацій, наведено на Рис.4.3.




Рис.4.3. – Приклад перетворення результату рейтрейсингової симуляції в Zemax (а) в зображення для подальшого визначення аберацій (б).

Оскільки форма світлових плям повністю визначається набором аберацій в людському оці, тому даній роботі пропонується використовувати бінарні зображення.

4.3. Визначення коефіцієнтів Церніке за зображеннями

Цілком природно, що використання спрощеної апаратної частини вимагатиме розробки більш складних алгоритмів для визначення викривлень хвильового фронту. Втім, за наявності точних моделей та достатніх розрахункових потужностей, існує можливість статистичної апроксимації складних алгоритмів, причому, через стрімкий розвиток методів штучного інтелекту, для цього все частіше пропонується використовувати методи на основі одного з найбільш популярних його видів – штучних нейронних мереж.

В роботі [60] наведено огляд методів для вимірювання хвильового фронту із застосуванням нейронних мереж. Зокрема, в роботі [61], запропоновано метод категорії визначення хвильового фронту на основі зображення (англ. image-based), в рамках якого використовується згортова нейронна мережа для визначення аберацій шляхом аналізу зображення інтенсивності випромінення від підсвічування досліджуваної оптичної системи точковим джерелом випромінення. Основним компонентом обробки даних виступає адаптована для задач регресії згортова мережа для класифікації зображень Xception [62].

Метод для визначення коефіцієнтів Церніке за одним зображенням на детекторі розроблено в [63]. В роботі розглянуто застосування згорткової нейронної мережі для оптичної системи з одним детектором (Рис.4.4).




Рис.4.4. – Оптична система для визначення коефіцієнтів Церніке за знімком з одного детектора [63].

Підхід, запропонований в [64] для вирішення схожої до аберометрії ока задачі - визначення коефіцієнтів Церніке для фронту аберацій, пов'язаних з турбулентністю – полягає у розробці нейронної мережі, яка базується на відомій архітектурі AlexNet [65] для класифікації зображень. Втім, існують інші ефективні архітектури. Саме тому в роботі [63] для побудови архітектури нейронної мережі використовується підхід, запропонований в [25], а саме зведення результатів декількох згорткових шарів в послідовність та їхня подальша обробка двонапрямленим згортковим шаром LSTM (Long-Short Time Memory). Також застосовано конкатенацію результатів попередніх шарів та одночасну обробку згортковими шарами з різними розмірами ядра (Рис.4.5).

Отримані результати дають можливість стверджувати, що використання такого підходу є релевантним та таким, що дозволяє вимірювати хвильовий фронт доволі точно лише за інформацією з одного детектора. Однак застосування згорткових мереж високої ємності та точності призводить до необхідності використання більш продуктивного, і, як наслідок, дорожчого обладнання, що прямо впливає на можливість інтеграції подібних рішень в оптико-електронні прилади. Таким чином, постає необхідність розробки більш ефективних способів визначення хвильового фронту на основі зображення з детектора.

В даній роботі пропонується подолати необхідність використання двовимірних згорткових шарів шляхом представлення даних на детекторі у вигляді одновимірної сигнатури світлової плями, що утворюється після проходження через досліджувану оптичну систему. Сигнатура являє собою два вектори, що складаються з координат пікселів (X та Y) на детекторі, що обрамляють світлову пляму, яку можна отримати шляхом фільтрації та порогової обробки двовимірного зображення інтенсивності падаючого світла. Саме таке представлення сигнатури, а не у вигляді Фур'є-розкладу [66], обумовлено двома причинами. По-перше, це значно спрощує процес підготовки зображення перед обробкою нейронною мережею. По-друге, через потенційно велику абсолютну різницю між амплітудами гармонік, постає потреба у пошуку способу нормалізації вхідних значень для нейронної мережі з метою покращення стабільності навчання.

4.4. Визначення навчання з підкріпленням

Втім, варто пам'ятати, що вкрай складно гарантувати точний результат роботи нейронної мережі, а медичне застосування запропонованого методу потребує наявності механізму корекції оцінок аберацій. Загалом, уточнення вектору коефіцієнтів Церніке можна звести до задачі багатокритеріальної оптимізації функції схожості реального вимірювання з результатом моделювання. Однак, розробка алгоритму розв'язання цієї задачі може

виявитися складною, а застосування вимагатиме великої кількості ітерацій, що для рейтрейсингового моделювання може призвести до збільшення часу отримання кінцевих результатів. В такому випадку цілком релевантним є пошук та адаптація іншого класу засобів на основі штучних нейронних мереж – навчання з підкріпленням [67]. Наприклад, в роботі [68] для визначення аберацій по хвильовому фронту та їхньої компенсації розглянуто методи, в тому числі із застосуванням методів навчання з підкріпленням, що дозволяє збільшити число Штреля в деяких випадках з 85% до 91%. Порівняно із методами на основі нейронних мереж прямого розповсюдження, використання навчання з підкріпленням не потребує великих вибірок, а, натомість, вимагає наявності середовища (реального або програмного), з яким агент, в складі якого міститься відповідна нейронна мережа, взаємодіє та отримує зворотний зв'язок у вигляді значення нагороди та спостереження, за якими він коригує свою поведінку. Через контроль над параметрами середовища та визначеність розрахунку очікуваної нагороди на кожній ітерації, підвищується робастність навченого агента без необхідності збору вибірок. Для отримання тренувальних даних для середовища також можна використовувати генератори на основі нейронних мереж. Втім, недоліком класу методів навчання з підкріпленням є довгий час навчання, що насправді не завжди є проблемою, бо стосується лише підготовки агента, в той час як швидкість роботи вже навченого агента є більшою.

Загалом, навчання з підкріпленням як розділ машинного навчання спрямоване на дослідження та створення агентів, що оперують в певному середовищі, з метою отримання найбільшої нагороди за свої дії (Рис.4.7).




Рис.4.7. – Діаграма взаємодії агента та середовища в навчанні з підкріпленням [67].

Зазвичай, в якості середовища виступає марківський процес вирішування (МПВ, англ. Markov decision process, MDP) – модель для послідовного обрання дій, результат яких є лише частково контрольованим з боку виконавця.

МПВ описується кортежем

$$(S, A, P(\cdot, \cdot), R(\cdot, \cdot), \gamma),$$

де:

- S – скінченна множина станів,
- A – скінченна множина дій,
- $P_a(s, s') = \Pr(s_{t+1} = s' \mid s_t = s, a_t = a)$ – ймовірність переходу до стану s' в момент кроку $t + 1$ за виконання дії a в стані s ,
- $R_a(s, s')$ - безпосередня нагорода за виконання дії a при переході зі стану s до стану s' ,
- γ – коефіцієнт знецінення, що відображає зменшення важливості майбутніх очікуваних нагород, приймає значення в проміжку $[0, 1]$.

Стратегія π (англ. policy) ухвалення рішень визначає дію a , що її виконання в стані s призводитиме до максимізації кумулятивної функції винагород

$$R_{max} = \sum_{t=0}^{\infty} \gamma^t R_{a_t}(s_t, s_{t+1})$$

де

$$a_t = \pi(s_t).$$

Зазвичай, пошук оптимальної стратегії вимагає введення функції цінності V , що відображає очікувану нагороду при слідуванні стратегії π з початкового стану s :

$$V^\pi(s) = E[R|s, \pi].$$

В такому випадку, стратегія та функція цінності записуються як рекурсивні рівняння:

$$\begin{aligned} \pi(s) &:= \arg \max_a \left\{ \sum_{s'} P_a(s, s') (R_a(s, s') + \gamma V(s')) \right\}, \\ V^\pi(s) &:= \sum_{s'} P_{\pi(s)}(s, s') (R_{\pi(s)}(s, s') + \gamma V(s')). \end{aligned}$$

Методи навчання з підкріпленням здатні розв'язувати МПВ без необхідності явного визначення ймовірностей переходу, але вивчаючи його з досвіду. В такому випадку агент попередньо має зробити певну кількість взаємодій з МПВ.

Прикладом розробки системи для корекції та визначення хвильового фронту аберацій є метод, запропонований в [69]. Сутність методу полягає в покроковому підлаштуванні гнучкого дзеркала всередині оптичної системи за командами (набір коефіцієнтів Церніке) від агента для підвищення якості зображення на детекторі. Після тренування протягом 2×10^5 епізодів, імплементований метод досягає 95% від максимального значення якості зображення за менше ніж 800 кроків налаштовуючи гнучке дзеркало, яке відтворює 5 аберацій нижчих порядків. Отже, методи навчання з підкріпленням здатні визначати хвильовий фронт в оптичних системах із заданою точністю. Також, вагомою перевагою цього класу методів, порівняно зі звичайними нейронними мережами прямого розповсюдження, є здатність уточнення результату, що є актуальним для вимірювальної апаратури.

В даній роботі, на відміну від [69], пропонується використовувати не метод на основі градієнту глибокої детермінованої стратегії (англ. Deep Deterministic Policy Gradient, DDPG) [70], а Q-навчання (англ. Q-Learning) [71]. Цей вибір обумовлений значно швидшою збіжністю та меншими вимогами до апаратного забезпечення під час навчання, що є важливим для проведення дослідження та швидкого прототипування з метою пошуку кращого набору гіперпараметрів та перевірки працездатності алгоритму загалом.

Для Q-навчання вводиться функція оцінювання оптимальності Q , яка відображає оцінювану винагороду при виконанні дії a в стані s та подальшого виконання дій згідно поточної стратегії:

$$Q(s, a) = \sum_{s'} P_a(s, s') (R_a(s, s') + \gamma V(s')).$$

Через те, що функція $Q(s, a)$ заздалегідь не відома, вона апроксимується за допомогою навчання агента на основі досвіду взаємодії з середовищем. Перед початком навчання, $Q(s, a)$ ініціалізується випадковими значеннями. Протягом кожного кроку t агент обирає дію a_t , отримує винагороду R_{t+1} і вступає в новий стан s_{t+1} залежно від поточного стану s_t , після чого $Q(s, a)$ оновлюється. В основі алгоритму лежить рівняння Беллмана як ітераційне уточнення за цінністю, для якого використовується зважене усереднення старої оцінки цінності та нової інформації:

$$Q^{new}(s_t, a_t) \leftarrow Q(s_t, a_t) + \alpha \left(R_{t+1} + \gamma \cdot \max_a Q(s_t, a) - Q(s_t, a_t) \right).$$

Таким чином, $Q^{new}(s_t, a_t)$ є сумою трьох факторів:

- $(1 - \alpha)Q(s_t, a_t)$ – зважене поточне значення $Q(s_t, a_t)$,
- αR_{t+1} – зважена нагорода R_{t+1} за виконання дії a_t в стані s_t ,
- $\alpha \gamma \max_a Q(s_t, a)$ – максимальна нагорода, що може бути отримана зі стану s_{t+1} .

Епізод роботи алгоритму завершується у випадку, якщо агент виконав задачу або досягнуто максимальної кількості кроків.

Одним з очевидних способів представлення $Q(s, a)$ є таблиця, що у відповідність набору станів S та дій A ставить оцінку нагороди Q . Втім, за великої кількості можливих станів та дій, таке представлення є неоптимальним та потребує значних ресурсів для збереження на обчислювальних пристроях. Іншим, кращим за багатьма параметрами, способом представлення функції Q є штучні нейронні мережі [72]. Перевагою в такому випадку також є набагато кращі властивості нейромереж до узагальнення.

Q-навчання із застосуванням глибоких нейронних мереж (англ. Deep Q-Learning), схильне до нестабільності під час навчання через чутливість функції Q навіть до незначних оновлень. З метою поліпшення стабільності широко використовуються два механізми: буфер досвіду [73] та подвійне Q-навчання [74]. Перше покращення пропонує зберігати результати та передумови попередніх дій агента і використовувати саме їх для навчання, а не інформацію з поточних кроків. Друге – пропонує боротися з переоцінкою майбутнього максимуму оцінки нагороди застосуванням двох однакових мереж, одна з яких використовується для обрання дії, а інша – для оцінки функції Q за виконання обраної дії. Параметри θ' цільової мережі в такому випадку є зваженою сумою попередніх значень та параметрів мережі для оцінки дій θ :

$$\theta' \leftarrow \tau\theta + (1 - \tau)\theta',$$

де τ – коефіцієнт усереднення.

4.5. Середовище для навчання з підкріпленням

Робота середовища для роботи агенту на основі глибокої нейронної Q-мережі (англ. Deep Q-Network, DQN) ґрунтується на оптичній системі для отримання зображень на детекторах. Ключовим завданням середовища має стати перетворення набору коефіцієнтів Церніке хвильового фронту випромінювання оберненого ходу в зображення на детекторах. Як вже було зазначено раніше, через високі вимоги до апаратного забезпечення для рейтрейсингу та необхідність багатократного проведення моделювання, доцільним є проведення симуляцій для обмеженої кількості променів, які

розповсюджуються із зіниці ока. В такому випадку обрано набір променів, що виходять із зіниці, точки розповсюдження яких складають 6 концентричних кіл як це показано на Рис.4.8. З метою спрощення подальших розрахунків приймається, що промені виходять з площини, перпендикулярної головній оптичній осі та розташованій в крайній зовнішній точці рогівки.




Рис.4.8. – Точки початку розповсюдження променів на зіниці в середовищі для навчання з підкріпленням. За початок координат обрано центр зіниці.

Оскільки розроблена оптична система вимірювання спрямована на отримання «перерізу» потоку променів в декількох місцях, то, під час ітерацій навчання з підкріпленням, має виконуватись розрахунок перетину світлового потоку на певній відстані від ока. Кути нахилу променів є кутами нахилу нормалей \vec{n} до хвильового фронту, які визначатимуться за загальною формулою:

$$\vec{n} = \nabla W(x, y) = \left(-\frac{\partial W}{\partial x}, -\frac{\partial W}{\partial y}, 1 \right).$$

Для цього та подальших розрахунків вісь Oz лежить на головній оптичній осі та має позитивний напрям, спрямований від ока. Значення W в точці A з полярними координатами (ρ_A, φ_A) або декартовими координатами (x_A, y_A)

визначається набором коефіцієнтів Церніке C , при цьому для кожної моди ця залежність лінійна, що дозволяє представити нормаль в заданій точці як

$$\begin{aligned} \vec{n}_A &= \nabla W_A(C) = \\ &= \left(\sum_n \sum_m \left(-\frac{\partial W_n^m(x_A, y_A)}{\partial x} \cdot C_n^m \right), \sum_n \sum_m \left(-\frac{\partial W_n^m(x_A, y_A)}{\partial y} \cdot C_n^m \right), 1 \right), \end{aligned} \quad (4.1)$$

де W_n^m – значення окремої моди для n -го радіального порядку та m -ї кутової швидкості, а C_n^m – значення коефіцієнту Церніке біля моди.

Через те, що значення похідних $\frac{\partial W_n^m}{\partial x}$ та $\frac{\partial W_n^m}{\partial y}$ можуть бути заздалегідь розраховані з формули (1.1), то координати нормалі (4.1) в окремій точці можна представити як

$$\vec{n}_A = \left(-\frac{\partial W_A}{\partial x} \cdot C, -\frac{\partial W_A}{\partial y} \cdot C, 1 \right),$$

де $\frac{\partial W_A}{\partial x}$ та $\frac{\partial W_A}{\partial y}$ – вектори значень похідних мод в певній точці A .

Таким чином, визначення координат нормалей при ітерації моделювання середовища зводиться до векторного перемноження, що значно пришвидшує отримання результату. Візуалізацію отриманих нормалей наведено на Рис.4.9.




Рис.4.9. – Візуалізація променів зворотного ходу у вигляді нормалей: а) ізометричний вид; б) вид згори.

Точки, де випромінення потрапляє на детектори, моделюються визначенням перетину променів із площиною детектора, тобто

$$\begin{cases} x_{A'} = n_{Ax} \cdot h + x_A \\ y_{A'} = n_{Ay} \cdot h + y_A' \end{cases}$$

де h - відстань від зіниці до детектора, а

$$n_{Ax} = -\frac{\partial W_A}{\partial x} \cdot C,$$

$$n_{Ay} = -\frac{\partial W_A}{\partial y} \cdot C.$$

Очевидно, що для наближення до реального кадру, необхідно з точок перетину променів площини детектора створити зображення суцільної світлової плями. В даній роботі пропонується моделювати світлову пляму шляхом описування кривої навколо набору точок перетину, формуючи навколо нього альфа-форму [75], розрахунок якої базується на результатах виконання триангуляції Делоне [76] – об'єднанні точок в мережу трикутників, описані кола яких не містять жодних інших точок, окрім тих, що складають самі трикутники. Налаштування α -параметру дає можливість фільтрувати ребра та трикутники, які формуватимуть альфа-форму. Приклад утворення контуру світлової плями навколо набору точок падіння променів на детектор наведено на Рис.4.10.




Рис.4.10. – Приклад альфа-форми, якою апроксимується світлова пляма на детекторі.

Наступним кроком після визначення набору прямих, що утворюють контур світлової плями, є формування піксельного зображення. Для растеризації прямих використовується відомий алгоритм Брезенхема [77], який визначає пікселі, що найточніше представлятимуть пряму на піксельному екрані, базуючись на відстані від центрів пікселів до ідеальних координат прямої. Незважаючи на те, що алгоритми растеризації в наш час утворюють окремий клас (до якого належить, наприклад, алгоритм Ву [78] з підтримкою згладжування), саме оригінальний алгоритм Брезенхема є доречним для використання в ітераційному моделюванні середовища через свою простоту, що є важливим для швидкості отримання кінцевого результату. Отриманий контур світлової плями заповнюється за алгоритмом заповнення отворів, описаним в [59]. Приклад апроксимованої світлової плями на детекторі наведено на Рис.4.11.




Рис.4.11. – Приклад світлової плями на детекторі, отриманої шляхом моделювання в середовищі для навчання з підкріпленням.

Нагородою в описаному середовищі є значення метрики схожості – відстані Жаккара [79] – порівняння результату моделювання у вигляді бінарного зображення з реальним вимірюванням. Значення метрики розраховується як відношення кількості пікселів, що дорівнюють 1 на обох зображеннях (аналог логічної операції ТА), до загальної кількості пікселів, що дорівнюють 1 на обох зображеннях (аналог логічної операції АБО):

$$J = \frac{1}{N} \sum_{k=1}^N \frac{pixel_sum_{AND}}{pixel_sum_{OR}},$$

де N – кількість детекторів, $pixel_sum_{AND}$ – кількість пікселів, де згенерована та реальна світлові плями перетинаються, $pixel_sum_{OR}$ – загальна кількість пікселів, яка покривається обома плямами на детекторі.

З метою посилення впливу успішних дій під час тренування агента, нагорода за дію, що призвела до 100% співпадіння зображень світлових плям, дорівнюватиме різниці 1 та кумулятивній сумі за кроки протягом епізоду, в той час як сама нагорода за кожен інший крок додатково ділитиметься на максимально дозволenu кількість кроків в епізоді.

Як вже було відмічено раніше, з метою спрощення нейронних мереж, що застосовуватимуться в модифікованому методі рейтрейсингової абераметрії, як і для розрахунку першого наближення, вхідні дані представлятимуться у вигляді вектору, що складається з набору координат по осях Ox та Oy для згенерованих та реальних зображень на детекторах. Задля уніфікації розмірності даних, а саме кількості елементів у векторі сигнатури світлових плям, застосовується кубічна інтерполяція Акіма [80], перевагами якої є відносно низька кількість розрахунків та більша стабільність, тобто відсутність значних неприродних коливань за радикальних змін другої похідної кривої, що інтерполюється. Ці особливості також обумовлюють її часте використання в сфері комп'ютерної графіки, а саме в галузі растеризації [81].

4.6. Дані для моделювання

Для перевірки працездатності запропонованих вдосконалень визначення аберацій в симуляціях використано сім коефіцієнтів Церніке, що описують хвильовий фронт відбитого та розсіяного сітківкою лазерного випромінення, а саме: C_2^{-2} , C_2^0 , C_2^2 , C_3^{-3} , C_3^{-1} , C_3^1 , C_3^3 . Такий набір обумовлений наступним набором факторів:

- Коефіцієнти C_0^0 , C_1^{-1} , C_1^1 зазвичай не використовуються в аберометрії людського ока;
- Даний набір покриває аберації низького ($n = 2$) та високого порядків ($n > 2$);
- Через те, що більша кількість коефіцієнтів збільшує складність функції, яку мають апроксимувати нейронні мережі, використання лише 7 коефіцієнтів є сприятливим для швидкого прототипування та визначення оптимальних гіперпараметрів, що є особливо критичним для методів на основі навчання з підкріпленням, які зазвичай потребують $\sim 10^3$ - 10^5 епізодів для навчання.

Також протягом симуляцій значення коефіцієнтів Церніке (Таблиця 4.1) нормуються до діапазону $[0; 1]$, а для формування вибірок використовуються їхні дискретні нормовані значення з кроком 0.1. Такий спосіб представлення даних покликаний спростити моделювання, а також обумовлений застосуванням DQN в основі агента, взаємодія якого з середовищем здійснюється шляхом дискретних дій додавання або віднімання значення кроку дискретизації від коригованого вектору коефіцієнтів Церніке. Для перевірки першого наближення та корекції набори коефіцієнтів Церніке згенеровано випадковим чином з рівномірним розподілом.

Таблиця 4.1. Максимальні та мінімальні значення коефіцієнтів Церніке

Коефіцієнт	Значення	
	Мінімальне	Максимальне
C_2^{-2}	-1 мкм	1 мкм
C_2^0	-4 мкм	4 мкм
C_2^{-2}	-1 мкм	1 мкм
C_3^{-3}	-0.4 мкм	0.4 мкм
C_3^{-1}	-0.4 мкм	0.4 мкм
C_3^1	-0.4 мкм	0.4 мкм
C_3^3	-0.4 мкм	0.4 мкм

Для навчання згенеровано вибірку в $8 \cdot 10^4$ примірників, кожен з яких складається з 4 послідовностей по 40 нормалізованих координат пікселів по осях Ox та Oy в сигнатурі світлової плями для двох детекторів розмірами 25x25 мм та кількістю пікселів 512x512, оптичний шлях до яких від зіниці сягає 80 та 160 мм. Зображення на детекторах отримано шляхом моделювання в середовищі MATLAB утворенням світлових плям, яке використовується в тому числі для середовища навчання з підкріпленням. Координати пікселів отримано шляхом інтерполяції Акіми для 40 точок, розподілених рівномірно по сигнатурі.

4.7. Нейронна мережа першого наближення

Як вже було описано раніше, в даній роботі представлення даних здійснюється шляхом визначення сигнатури світлової плями та приведення її до визначеної довжини. Таким чином, нейронна мережа першого наближення та DQN мають бути спроектовані для обробки одновимірних послідовностей. Найкращими претендентами на роль основних шарів є LSTM та одновимірний згортка. Однак, через значно більшу кількість параметрів для кожного елемента шарів LSTM та різноманіття операцій для однієї ітерації його роботи, перевагу надано саме одновимірним згортковим шарам. Для надання нейронній мережі кращої здатності до апроксимації нелінійних функцій, в якості функції активації обрано ELU [82]. Архітектуру нейронної мережі представлено на Рис.4.12.

Layer (type)	Output Shape	Param #
input_layer (InputLayer)	(None, 40, 4)	0
conv1d (Conv1D)	(None, 40, 16)	592
conv1d_1 (Conv1D)	(None, 40, 16)	2,320
conv1d_2 (Conv1D)	(None, 40, 16)	2,320
conv1d_3 (Conv1D)	(None, 40, 16)	2,320
conv1d_4 (Conv1D)	(None, 40, 16)	2,320
conv1d_5 (Conv1D)	(None, 40, 16)	2,320
conv1d_6 (Conv1D)	(None, 40, 16)	2,320
conv1d_7 (Conv1D)	(None, 40, 16)	2,320
conv1d_8 (Conv1D)	(None, 40, 16)	2,320
conv1d_9 (Conv1D)	(None, 40, 16)	2,320
conv1d_10 (Conv1D)	(None, 40, 16)	2,320
conv1d_11 (Conv1D)	(None, 40, 16)	2,320
flatten (Flatten)	(None, 640)	0
dense (Dense)	(None, 256)	164,096
dense_1 (Dense)	(None, 7)	1,799

Total params: 192,007 (750.03 KB)

Trainable params: 192,007 (750.03 KB)

Non-trainable params: 0 (0.00 B)

Рис.4.12. – Архітектура мережі першого наближення, виконано в середовищі Kaggle.

Для вихідного шару нейронної мережі обрано сигмоїд в якості функції активації. Також цей вибір обґрунтовано необхідністю масштабування очікуваних результатів до діапазону [0; 1].

Поступове навчання забезпечує обрання середньоквадратичної помилки як функції втрат. Оптимізатор Adam застосовується для оновлення параметрів мережі протягом навчання з налаштуваннями:

- $\beta_1=0.9$
- $\beta_2=0.999$

- Коефіцієнт навчання експоненційно зменшується за формулою (3.1), початковий коефіцієнт навчання дорівнює 10^{-4} , $decay_{rate} = 0.95$, а $t_{decay} = 10^4$
- Розмір міні-вибірки дорівнює 128 екземплярів.

Нейронну мережу створено та навчено в середовищі Kaggle на мові Python із залученням бібліотек функцій TensorFlow та SciPy [43]. Результати навчання у вигляді графіків функції втрат та середньої помилки для кожного коефіцієнту наведено на Рис.4.13.




Рис.4.13. – Результати навчання нейронної мережі першого наближення: а) графік зміни середніх значень функції втрат протягом навчання; б) середня помилка визначення коефіцієнту Церніке.

Як можна побачити з Рис.4.13а, загалом значення функції втрат на валідаційній вибірці (20% від загальної кількості екземплярів) незначно відрізняється від значень для навчаючої вибірки, що свідчить про відсутність проблемних станів нейронної мережі, як-от недонавчання або перенавчання. Середні значення помилки (Рис.4.13б) вказують на загальну високу точність визначення коефіцієнтів Церніке, адже значення помилок, менші за крок дискретизації в 0.1, свідчать про те, що некоректно визначені коефіцієнти трапляються не в кожному результаті розрахунку. Таким чином, можна стверджувати, що розроблена нейронна мережа виконує задачу першого

наближення коефіцієнтів аберацій за сигнатурами світлових плям на детекторах. Важливим аспектом отриманого результату є істотне спрощення тренування агента на основі DQN, оскільки, як про це було зазначено раніше, вони вимагають значної кількості епізодів навчання, а наявність незначної кількості помилок значно скорочує шлях між початковим та бажаним станами середовища, який агент має знайти.

4.8. Застосування DQN для корекції першого наближення

Для подальшого коригування результату визначення коефіцієнтів Церніке застосовано агента на базі DQN. Підхід до представлення вхідних даних у нейронної мережі оцінювання Q -значення той самий, що застосовувалося для розрахунку першого наближення, а саме використання сигнатур світлових плям на детекторах. Однак протягом налаштування гіперпараметрів та підбору оптимальної архітектури було виявлено, що застосування лише повнозв'язних шарів призводить до кращої збіжності DQN, що вимагає представлення вхідних даних у вигляді одного вектора, який є конкатенацією 8 послідовностей нормованих індексів пікселів по обох осях зображень, які складають сигнатури світлових плям, отриманих протягом моделювання в середовищі та шляхом реальних вимірювань, на двох детекторах. Архітектуру мережі апроксимації функції $Q(s, a)$ наведено на Рис.4.14.




Рис.4.14. – Архітектура глибокої Q -мережі.

Особливістю DQN в даній роботі є використання функції активації *swish* [83]:

$$\text{swish}_\beta = x \cdot \text{sigmoid}(x) = \frac{x}{1 + e^{-\beta x}},$$

де β – константа, для даної роботи $\beta = 1$.

Згідно дослідження [84], в деяких випадках використання *swish* замість ReLU покращує результати класифікації та збільшує робастність мереж до зміни гіперпараметрів: наприклад, кількості шарів.

З метою перевірки працездатності корекції першого наближення засобами навчання з підкріпленням, а також його робастності, обрано 10 примірників, які мають помилку визначення одного коефіцієнту в один крок дискретизації. Така мала кількість прикладів обумовлена загальною особливістю тренування DQN-агентів, а саме потребою у великій кількості ітерацій, загальною складністю середовища, яка включає в себе як операції над векторами, так і графічні перетворення, та відносно великою кількістю дій – по 2 дії (збільшення та зменшення значення) на кожен коефіцієнт Церніке. Через дійсно малу кількість необхідних для корекції дій та для «заохочення» агента до швидких правильних дій, а також для формування прикладів під час тренування, бо спроби агента є єдиним джерелом навчальних даних, максимальну кількість кроків обрано 2. Дослідження агентом простору дій на ранніх етапах навчання забезпечується обранням випадкової дії з вірогідністю

$$\varepsilon_{t+1} = \varepsilon_t(1 - \varepsilon_{\text{decay}}),$$

де ε_{t+1} – ймовірність виконання випадкової дії на $t + 1$ -му кроці, ε_t – ймовірність виконання випадкової дії на t -му кроці, $\varepsilon_{\text{decay}}$ – коефіцієнт затухання ε . Для навчання агента $\varepsilon_{\text{decay}} = 0.01$, а початкове значення $\varepsilon = 0.5$.

Як вже було описано раніше, для додаткової стабілізації застосовується підхід із використанням двох Q -мереж для оцінки винагороди та обрання дії. Оновлення параметрів цільової мережі здійснюється кожні 4 кроки, з параметром $\tau = 1$, тобто копіювання параметрів відбувається кожні 4 кроки.

Коефіцієнт згасання обрано рівним 0.95, а розмір буферу для навчання мережі – 10^5 кроків. Для оновлення параметрів Q -мережі протягом навчання використано оптимізатор Adam з такими налаштуваннями:

- $\beta_1=0.9$
- $\beta_2=0.999$
- Коефіцієнт навчання дорівнює $5 \cdot 10^{-5}$
- Розмір міні-вибірки дорівнює 32 кроки.

З метою стабілізації навчання та запобігання значних змін ваг та зсувів повнозв'язних шарів, застосовано усічення градієнту та L2-регуляризацію [85]. Перша міра спрямована на обмеження максимального значення градієнту, що використовується в алгоритмі зворотного поширення під час оновлення параметрів нейронної мережі. Для даної роботи значення градієнту обмежується 1. Другий механізм запобігає значним змінам параметрів шляхом додавання до функції втрат регуляризаційного терму:

$$Loss_{regularized}(\theta) = Loss(\theta) + \lambda \Omega(w),$$

де $Loss_{regularized}(\theta)$ – функція втрат для нейронної мережі з параметрами θ з регуляризацією, $Loss(\theta)$ – функція втрат для нейронної мережі з параметрами θ , λ – фактор регуляризації (для даної роботи обраний 10^{-6}), $\Omega(w)$ – регуляризаційний терм для ваг мережі w , який в свою чергу дорівнює

$$\Omega(w) = \frac{1}{2} w^T w.$$

Імплементацію середовища та навчання агента виконано в середовищі MATLAB, імплементацію алгоритма Брезенхема обрано з джерела [86]. Результат навчання наведено на Рис.4.15. Максимальна кількість епізодів обрана 20000, усереднення винагороди виконується по 20 епізодам, навчання припиняється, коли усереднена винагорода за епізод сягатиме 1.



Рис.4.15. – Графік навчання агента для корекції першого наближення.

Як можна побачити, агент досягає коректного результату за ~9000 епох, що є доволі протяжним в часі, порівняно, наприклад, з тренуванням мережі першого наближення.

4.9. Застосування PPO для корекції першого наближення

Іншим, більш досконалим методом категорії навчання з підкріпленням є оптимізація проксимальної політики (англ. Proximal Policy Optimization, PPO), запропонована в [87]. Значною перевагою цього методу є більша стабільність навчання за рахунок менших оновлень нейронних мереж під час навчання, менша чутливість до налаштувань гіперпараметрів, та, як наслідок, краща збіжність. Іншим вагомим фактором на користь агентів на базі PPO є кращі результати в комплексних середовищах, яким можна вважати середовище для рейтрейсингу та моделювання утворення зображень на детекторах, яке використовується в даній роботі. Саме тому доречним є дослідження застосування PPO в модифікованому нейромережному методі рейтрейсингової аберометрії ока людини.

На відміну від DQN, PPO базується на підході із застосуванням двох нейронних мереж: актора (або діяча від англ. actor) та критика. Загалом, актор є уособленням стратегії $\pi(s)$, а критик є засобом оцінки того, наскільки вона відповідає очікуваній нагороді.

PPO досягає стабільності навчання агента за допомогою механізму обмеження (англ. clipping). Метод полягає в обмеженні коефіцієнта в цільовій функції, якою для PPO є обмежена у певному діапазоні сурогатна цільова функція.

Навчання PPO-агента здійснюється наступним чином. Після ініціалізації актора $\pi(s)$, та критика $V(s)$, випадковими параметрами (вагами та зміщеннями) θ та φ відповідно, генерується досвід у вигляді набору:

$$S_{ts}, a_{ts}, R_{ts+1}, S_{ts+1}, a_{ts+1}, R_{ts+2}, \dots, a_{ts+N-1}, R_{ts+N}, S_{ts+N},$$

де S_{ts} – стан системи, який є вхідною інформацією агента, a_{ts} – дія, виконана агентом в цьому стані, а R_{ts+1} – нагорода, отримана за перехід від S_{ts} до S_{ts+1} , ts – номер тренувального кроку. Спираючись на поточний стан S_{ts} , агент виконує дію a_{ts} з ймовірністю, визначеною за $\pi(S_{ts})$.

За підсумками отриманого досвіду, розраховується функція переваги [88] – затухаюча сума помилок:

$$D_t = \sum_{k=t}^{ts+N-1} (\gamma\lambda)^{k-t} (R_t + b\gamma V(S_t|\varphi)),$$

де b – показник того, що стан S_{ts+N} є термінальним, тобто останнім в епізоді (через ліміт на кількість кроків або виконання задачі агентом), який дорівнює 1 при задоволенні цієї умови, λ – згладжуючий фактор, γ – фактор затухання.

В свою чергу, очікувана майбутня нагорода розраховується за формулою:

$$G_t = D_t + V(S_t|\varphi).$$

Оновлення параметрів мереж актора та критика відбувається за інформацією з міні-вибірок (стандартний підхід при навчанні нейронних мереж загалом), випадковим чином відібраних з поточного досвіду, який складається з наборів S_{ts}, a_{ts}, R_{ts+1} , а також відповідних ним G_{ts} та D_{ts} .

Для критика функція втрат L_{critic} для міні-вибірки розміром з M елементів визначається як:

$$L_{critic}(\varphi) = \frac{1}{M} \sum_{i=1}^M (G_i - V(S_t|\varphi))^2,$$

Для актора, в свою чергу, функція втрат L_{critic} має вигляд:

$$L_{actor}(\theta) = \frac{1}{M} \sum_{i=1}^M (-\min(r_i(\theta) \cdot D_i, c_i(\theta) \cdot D_i) + w\mathcal{H}_i(\theta, S_i)),$$

$$r_i(\theta) = \frac{\pi_i(S_i|\theta)}{\pi_i(S_i|\theta_{old})},$$

$$c_i = \max(\min(r_i(\theta), 1 + \varepsilon), 1 - \varepsilon),$$

де

- $\pi_i(S_i|\theta)$ – ймовірність здійснення дії a_i в стані S_i
- $\pi_i(S_i|\theta_{old})$ – ймовірність здійснення дії a_i в стані S_i для актора з параметрами θ_{old} , отриманими за результатами попереднього оновлення
- ε – фактор обмеження (або кліпінговий фактор)
- $\mathcal{H}_i(\theta, S_i)$ – втрата ентропії, w – ваговий фактор втрати ентропії.

З метою поліпшення досвіду та покращення навчання агента, додається втрата ентропії як доданок для функції втрат актора. Логічно, що ентропія тим більша, чим більша невизначеність щодо наступної дії актора. Відповідно, максимізація доданку $w\mathcal{H}_i(\theta, S_i)$ заохочує агента до застосування різних дій під час навчання, впливаючи на баланс дослідження та експлуатації (англ. exploration-exploitation balance). Для даної роботи, в якій планується, що агент РРО здійснюватиме дискретні дії, втрата ентропії розраховується за наступною формулою:

$$\mathcal{H}_i(\theta, S_i) = - \sum_{k=1}^P \pi_k(S_i|\theta) \ln(\pi_k(S_i|\theta)),$$

де P – кількість дискретних дій, $\pi_k(S_i|\theta)$ – ймовірність виконання дії a_k в стані S_i .

Для дослідження роботи агента на основі PPO для визначення аберацій, в даній роботі використано те ж середовище, що й для агента DQN, однак використано меншу кількість коефіцієнтів Церніке з метою попередньої оцінки та прийняття рішення про необхідність та можливість подальшого пошуку оптимального набору гіперпараметрів. Обрано саме такий поступовий підхід, бо алгоритми навчання з підкріпленням загалом є доволі чутливими до значень гіперпараметрів та такими, що потребують значної кількості ітерацій для навчання, порівняно з іншими класами методів на основі штучних нейронних мереж. Використання меншої кількості коефіцієнтів також спрощує дослідження ефективності PPO за гірших умов роботи агента, а саме більшої необхідної кількості виконаних дій за рахунок зменшення кроку квантування нормованого діапазону коефіцієнтів Церніке та постійного значення першого наближення для усіх примірників навчаючої вибірки. Такі умови надають можливість дослідити, наскільки добре проявить себе метод машинного навчання, відмінний по структурі (наявність двох нейронних мереж, і т.д.) та модифікований з акцентом на введення обмежень на оновлення параметрів під час навчання з метою покращення його стабільності.

Як вже було зазначено раніше, для дослідження агента PPO використовуються лише 3 коефіцієнти, діапазони яких наведено в Таблиці 4.2. Дослідження проведено в середовищі MATLAB.

Таблиця 4.2. Максимальні та мінімальні значення коефіцієнтів Церніке

Коефіцієнт	Значення	
	Мінімальне	Максимальне
C_1^{-1}	-0.020 мкм	0.020 мкм
C_1^1	-0.020 мкм	0.020 мкм
C_2^{-2}	-3 мкм	3 мкм

Як і в середовищі для DQN, у якості джерела хвильового фронту використовується кругла апертура діаметром 6 мм, а промені розповсюджуються з точок на ній, які утворюють 6 концентричних кіл. Оптичний шлях променів, перпендикулярних апертурі, до двох детекторів дорівнює 65 та 115 мм відповідно. Самі детектори моделюються квадратними матрицями 20x20 мм по 128x128 пікселів кожен.

Максимальна кількість ітерацій в одному епізоді дорівнює 80. Функцією нагороди є усереднена відстань Жаккара для детекторів, поділена на максимальну кількість ітерацій, однак у випадку, якщо відстань Жаккара більше або дорівнює 0.9, визначення коефіцієнтів Церніке вважається успішним, а нагорода за таку ітерацію дорівнює різниці між поточною кумулятивною нагородою та 1. Для оптимізації використовується оптимізатор Adam, коефіцієнти навчання для нейромереж актора та критика дорівнюють 10^{-3} . Горизонт досвіду N для функції переваги дорівнює 8000 кроків. Розмір міні-вибірки обрано 128, фактор усічення – 0.2, фактор втрати крос-ентропії – 0.01, кількість епох навчання нейромереж з кожного набору досвіду – 3. Архітектури нейромереж актора та критика наведені на Рис.4.16.




Рис.4.16. - Архітектури нейронних мереж: а) мережі-критика; б) мережі-актора. В скобках вказана кількість нейронів, поруч – функція активації (якщо її передбачено).

Характерною особливістю архітектури мереж актора та критика є застосування функції активації *softplus* [89]:

$$\text{softplus}(x) = \frac{1}{1 + e^{-x}}.$$

Softplus, будучи «згладженою» версією ReLU має ряд переваг, а саме: надає більшу стабільність мережі при навчанні, має ненульовий градієнт за негативного x , а також зниження негативного ефекту «зникнення градієнту» через те, що похідна *softplus* наближається до 1 при збільшенні вхідного значення.

Навчання мережі здійснювалось допоки середнє значення нагороди за 20 епізодів не становило 0.95. Очевидно, що отриманий агент є демонстраційним, і, для покращення робастності, слід проводити навчання з більшою кількістю епізодів, за якими усереднюється нагорода. Динаміка зміни значення нагороди протягом навчання наведена на Рис.4.17.




Рис.4.17. – Зміна значення нагороди за епізод протягом навчання в середовищі MATLAB. По осі X наведена кількість епізодів, по осі Y – значення нагороди (блакитний графік – реальна нагорода, жовтий – попередня оцінка на початку кожного епізоду).

Незважаючи на те, що агент на базі методу PPO отримав здатність визначати коефіцієнти Церніке з точністю 95%, з графіку навчання на Рис.4.17 можна зробити висновок, що навчання є менш стабільним, ніж для агента DQN, що може свідчити про:

- Загалом меншу доцільність використання PPO для задачі визначення хвильового фронту аберацій відбитого від сітківки світла. Така поведінка може пояснюватись менш стабільною функцією навчання актора, яка залежить від результативності мережі-критика, яка в свою чергу навчається разом мережею-актором. Схожі складнощі спіткають дослідження, що спираються на розробку інших мереж з архітектурою «актор-критик», таких як GAN і його похідні.
- Більша кількість гіперпараметрів є додатковим ускладнюючим фактором при пошуку оптимальної конфігурації агента та його навчання. Дійсно, на відміну від DQN, необхідно налаштовувати архітектури двох нейронних мереж замість однієї, а сам алгоритм навчання має більшу кількість параметрів.

4.10. Оцінка точності модифікованого методу

Цілком очевидно, що точність та прецизійність пристроїв на основі запропонованого в роботі модифікованого методу рейтрейсингової аберометрії обумовлюються не тільки особливостями самого методу, а й безліччю факторів, що характеризують кожну конкретну імплементацію. Але, враховуючи той факт, що в складі модифікованого нейромережного методу рейтрейсингової аберометрії є етап корекції засобами навчання з підкріпленням, можна стверджувати, що точність кінцевого результату є контрольованою та, в теорії, існує можливість досягнення 100% співпадіння першого наближення та вимірювання у вигляді бінарного зображення світлової плями. В такому випадку, на точність впливатимуть похибки, які вносить оптична система пристрою, обмеженість роздільної здатності

фоточутливої матриці та спотворення, викликані недосконалістю обраного алгоритму фільтрації зображення. Сукупний вплив цих факторів також можна оцінити метрикою схожості ідеального та реального бінарних зображень світлових плям.

Залежність можливих помилок визначення викривлень хвильового фронту від похибок імплементації та первинної обробки вимірювань пропонується виконати методом Монте-Карло. Випадковим чином генеруються набори коефіцієнтів Церніке викривлень хвильових фронтів та моделюються бінарні зображення, які вони утворюють на детекторах. Ця вибірка вважається ідеальною та такою, що не містить спотворень. Для кожного примірника ідеальної вибірки генерується набір зображень, утворених на детекторах (на відстанях 0.5 м та 1 м) викривленнями хвильових фронтів, які описуються «ідеальним» набором коефіцієнтів Церніке із додаванням шуму (від -10% до +10% від повного діапазону значень). Шум в даному випадку моделює викривлення, які вносять особливості можливої імплементації методу. Значення метрики схожості – відстані Жаккара – є мірою викривлення зображення. Для коефіцієнтів Церніке, описаних обмеженнями з Таблиці 4.1, залежність середніх нормованих значень помилок визначення коефіцієнтів наведена на Рис.4.18.




Рис.4.18. – Середні значення помилок визначення коефіцієнтів Церніке залежно від значення відстані Жаккара.

Як видно з Рис.4.18, для значень відстані Жаккара більших за 0.9, середня помилка визначення коефіцієнтів Церніке становить не більше 4%. Середні значення помилок визначення для значень відстані Жаккара більших за 0.9, наведені на Рис.4.19.




Рис.4.19. - Середні значення помилок визначення коефіцієнтів Церніке для значень відстані Жаккара більших за 0.9.

За проведеною оцінкою, середня помилка при визначенні дефокусу (сфери) сягає 0.098 мкм, що на ~25% краще за задекларовану точність аберометра iTrace в 0.13 мкм. Попри позитивний результат з точки зору точності, варто враховувати той факт, що в даній роботі наведена приблизна оцінка, а більш релевантна оцінка може бути отримана при роботі з реальною імплементацією модифікованого рейтрейсингового методу аберометрії.

В свою чергу прецизійність, яка визначається як ступінь варіативності результатів за повторних вимірювань, залежить від фізичних або експериментальних факторів, які неможливо повністю відобразити в симульованому середовищі. У результаті оцінка прецизійності на основі симуляційних даних може бути неадекватною, оскільки не враховуються суттєві аспекти реальних умов, що впливають на результати. Однак можна

стверджувати, що одночасне вимірювання відхилень хвильового фронту сприяє зменшенню довірчого інтервалу, оскільки дозволяє збільшити кількість повторюваних вимірювань, як це було описано в Розділі 3.

4.11. Можливості адаптації методу для практичного застосування

Отже, можна стверджувати, що підхід із послідовним застосуванням нейронної мережі прямого розповсюдження для першого наближення з подальшою корекцією засобами навчання з підкріпленням є працездатним.

Таким чином, для реалізації підходу, що полягає в застосуванні DQN агента із мережею першого наближення, при розробці аберометрів масового виробництва необхідно здійснити перетворення наведеного в роботі методу на основі DQN з дискретними значеннями коефіцієнтів Церніке в модифікацію, здатну до роботи з безперервними значеннями коефіцієнтів аберацій. Цього можна досягти двома шляхами: зменшенням кроку дискретизації або застосуванням DDPG. Перший підхід, в разі розробки аберометрів для масового виробництва, потребуватиме кількісних змін, а саме: збільшення кількості дій для агента (зазвичай в офтальмології використовуються аберації по $n = 6$ включно, що вимагатиме 54 дії) та зменшення кроку дискретизації. Такі зміни значно збільшуватимуть час навчання Q -мережі, однак застосування більш потужного обладнання здатне зменшити негативний вплив цих факторів для процесу розробки програмної складової аберометра. У випадку застосування агенту для реалізації DDPG, час, потрібний для навчання нейронних мереж актора та критика, які є складовими агента, може виявитись набагато більшим, ніж підготовка агента на базі глибокої Q -мережі. З одного боку, використання DDPG потенційно може завершувати корекцію за набагато меншу кількість кроків, ніж DQN, через можливість оновлення усіх коефіцієнтів одночасно, втім, така можливість може бути досягнута налаштуванням більшої кількості гіперпараметрів навчання та архітектури двох нейронних мереж. До того ж, як показує приклад схожого застосування навчання з підкріпленням на основі DDPG в [69], визначення набору коефіцієнтів Церніке триває протягом 800

кроків, що вказує на можливу повільність цього методу для визначення аберацій людського ока. Однак, важливим є те, що загалом питання підготовки програмного комплексу обробки даних, що складається з мережі першого наближення та агента для його корекції, здебільшого зводиться до вирішення технічних складнощів навчання нейронних мереж, які потенційно можна подолати екстенсивним залученням більш продуктивного обладнання у більшій кількості, та меншою мірою стосуються програмної складової кінцевих пристроїв.

Висновок до Розділу 4

1. Запропоновано нейромережну модифікацію методу рейтрейсингової аберометрії ока, яка полягає у підсвічуванні ока шляхом створення лазерним променем віртуального точкового джерела випромінення на очному дні, спрямуванні випромінення на фотодетектори (фоточутливі матриці) із подальшим першим наближенням визначення характеристик хвильового фронту випромінення штучною нейронною мережею та його уточненням засобами навчання з підкріпленням, які, зокрема, включають в собі відслідковування окремих променів, що виходять з ока, в моделі оптичної системи. Запропоновані вдосконалення дозволяють значно спростити оптичну систему для імплементації рейтрейсингового методу та забезпечують одночасне вимірювання аберацій в усіх зіничних координатах, що дозволяє збільшити кількість повторюваних вимірювань залежно від імплементації та, як наслідок, зменшити довірчий інтервал.

2. Проведено попередню оцінку точності запропонованого модифікованого методу. Встановлено, що за відстанню Жаккара не більше ніж 0.1 між ідеальним зображенням та викривленим потенційною імплементацією методу, точність визначення дефокусу (сфери) сягає 0.098 мкм, що на 25% краще за задекларовану точність визначення аберометром іTrase. Втім, варто враховувати той факт, що в даній роботі наведена приблизна оцінка на основі симуляції.

3. Створено нейронну мережу для отримання першого наближення визначення характеристик хвильового фронту випромінення, відбитого від сітківки. Нейромережу було перевірено на дослідній реалізації, в рамках якої застосовувалися хвильові фронти відбитого випромінення, які описуються нормованими дискретними значеннями коефіцієнтів Церніке. Середні значення помилок, менші за крок дискретизації в 0.1, свідчать про те, що некоректно визначені коефіцієнти трапляються не в кожному результаті розрахунку. Таким чином, можна стверджувати, що розроблена нейронна мережа виконує задачу першого наближення визначення коефіцієнтів аберацій за сигнатурами світлових плям на детекторах.

4. Досліджено доцільність використання агентів на основі методів DQN та PPO. За результатами дослідження виявлено, що використання DQN забезпечує більш стабільне навчання, а менша кількість гіперпараметрів для налаштування значно спрощує підготовку агента. DQN-агент досягає коректного результату за ~9000 епох у дослідній реалізації, в рамках якої застосовувалися 10 хвильових фронтів відбитого випромінення, які описуються нормованими дискретними значеннями коефіцієнтів Церніке.

РОЗДІЛ 5. Надроздільна здатність для хвильового фронту аберацій

Як вже було зазначено раніше, збільшення точності та кількості вимірних коефіцієнтів Церніке цілком можливо досягти шляхом екстенсивного доопрацювання запропонованої в даній роботі нейромережної модифікації рейтрейсингового методу аберометрії, а саме: залучити краще апаратне забезпечення в складі оптичної системи, більш продуктивну елементну базу для подальшого обрахунку для її імплементації, і т.д. Втім, у випадку неможливості залучення більших ресурсів для вирішення задачі визначення аберацій, резонним є залучення в тому числі і статистичних методів на основі штучних нейронних мереж. Таким чином, покращення точності визначення абераційних хвильових фронтів шляхом засування штучних нейронних мереж є актуальною задачею. Такі методи є доволі ефективним за різними параметрами, але для підготовки такого типу нейронних мереж необхідна велика кількість (сотні і тисячі) навчаючих даних. Однак, як показав досвід розробки методу із застосуванням GAN для створення штучної вибірки наборів коефіцієнтів Церніке для навчання та симуляції аберацій ока, для створення дійсно комплексного набору векторів коефіцієнтів аберацій, реальна навчаюча вибірка має бути репрезентативною та включати в собі приклади з різними видами розповсюджених та рідкісних аберацій. Втім, через малу кількість наявних наборів даних у відкритому доступі, актуальним є застосування випадкових значень з певним розподілом. Як і при розробці методу для генерації аберометричних даних, пропонується скористатися можливістю перетворення вектору коефіцієнтів Церніке в зображення і навпаки для розширення можливостей при пошуку датасетів. Тому, з метою підготовки та перевірки запропонованого методу, замість офтальмологічних даних, використовуватиметься вибірка фотографій хмарного неба SWIMSEG [90], перетворена у вибірку коефіцієнтів Церніке.

Цей розділ присвячено збільшенню точності визначення абераційних хвильових фронтів шляхом використання штучних нейронних мереж. Дослідження також включає генерацію навчальних даних з використанням

наборів фотографій хмарного неба SWIMSEG, що допомагає розширити можливості по навчанню штучних нейронних мереж для аберометрії із застосуванням альтернативних джерел даних.

5.1. Надроздільна здатність засобами штучних нейронних мереж

Збільшення роздільної здатності зображень шляхом застосування згорткових нейронних мереж вперше запропоновано в [91]. На даний момент розробки для надроздільної здатності одиничних зображень включають в себе застосування генеративних змагальних мереж [92], спеціалізованих шарів для обробки послідовностей [25] та ін. Загалом ці методи можуть бути адаптовані до збільшення роздільної здатності хвильових фронтів аберацій, оскільки їх можна представити у вигляді піксельних зображень. Однак, як це вже було зазначено раніше, відсутність великої кількості навчаючих примірників вимірювань є істотною перепорою для розробки рішень для надроздільної здатності зображень фронтів. Цей фактор також змушує проводити пошук існуючих базових рішень серед розробок для збільшення роздільної здатності даних, представлених в інших форматах з меншою кількістю вимірів, наприклад, аудіо-сигналів. В [93] запропоновано метод надроздільної здатності аудіо-сигналу за допомогою нейронної мережі, що включає в себе одновимірні згорткові шари. Іншим прикладом є метод [94], який базується на використанні частотного представлення аудіо-сигналів. Таке рішення обумовлено високим навантаженням на апаратне забезпечення у випадку збільшення роздільної здатності довгих аудіо-записів. Таким чином, для збільшення роздільної здатності хвильових абераційних фронтів доречно застосовувати нейронні мережі для обробки одновимірних сигналів, таких як вектори коефіцієнтів Церніке, замість використання їхнього двовимірного представлення у вигляді піксельних зображень.

5.2. Нейронна мережа для надроздільної здатності хвильового фронту

Виходячи з того, що у відкритому доступі не знайдено великих за обсягом наборів аберометричних даних, в даній роботі пропонується

використати набір фотографій хмарного неба SWIMSEG в якості зображень хвильових фронтів аберацій. Такий підхід обумовлений тим, що вибірка складається з відносно великої кількості зображень – 861 фотографія 600х600 пікселів, а самі зображення хмар є різноманітними та такими, що не містять візуальних шаблонів. Варто зазначити також, що у зображеннях хмар високочастотна складова виражена значно менше, ніж низькочастотна – це також релевантно для абераційних хвильових фронтів людського ока [49] (Рис.5.1).




Рис.5.1. –Розподіли згенерованих (стовпці - ± 1 СКВ, коло – середнє значення) коефіцієнтів Церніке отриманих із зображень хмар: а) усі коефіцієнти з $n = 1..7$; б) коефіцієнти з C_3^1 по C_6^6 .

Підхід з використанням для навчання даних, отриманих не зі сфери застосування нейронної мережі, є доволі розповсюдженим. Також може бути застосоване додаткове навчання на невеликій кількості даних зі сфери використання кінцевого рішення. Приклади використання підходу описано в [95] та охоплюють використання відомих нейронних мереж Inception, AlexNet та ін. для визначення ракових пухлин та аналізу захворювань шкіри.

З метою збільшення навчаючої вибірки, до SWIMSEG застосовано поширені методи аугментації графічних даних, а саме: випадкове «вирізання» фрагментів 41×41 піксель, випадкове віддзеркалення по осях X та Y , випадкові зміни яскравості та контрасту. Таким чином розмір вибірки збільшено до 15498 примірників. Наступним кроком з кожного зображення виділяється коло радіусом у 20 пікселів, яке представляється у вигляді вектору коефіцієнтів Церніке заданої розмірності. Для даної роботи обрано 36 перших мод Церніке – по 7 радіальний порядок включно, як ті, що часто використовуються в офтальмології. Мода з радіальним порядком 0 та кутовою частотою 0 приймається завжди рівною 0, оскільки ця мода у випадку людського ока не вносить викривлень у зображення на сітківці. В якості вхідних даних обрано коефіцієнти біля мод 1-5 порядків (20 коефіцієнтів) за якими апроксимуватимуться 15 коефіцієнтів 6 та 7 радіальних порядків. Усі значення коефіцієнтів масштабовано до діапазону $[0; 1]$.

Для апроксимації вихідних даних запропоновано нейронну мережу, яка складається з 12 згорткових шарів для одновимірних сигналів та одного повнозв'язного шару (Рис.5.2). Задля стабілізації навчання на вхід кожного згорткового та повнозв'язного шару подаються також виходи усіх попередніх шарів. Подібний підхід використано для підвищення роздільної здатності інфрачервоного зображення з використанням згорткової нейронної мережі [26], яке виявилось результативним для двовимірних зображень. Дійсно, через схожість вхідних та вихідних даних, з метою уникнення проблеми зникаючого градієнта, підхід із встановленням зв'язків між шарами, ближчими до вхідного та вихідного шарів, є адекватним. Через подальший розвиток підходів до обробки аберометричних даних, вдалося спростити їхнє представлення до одновимірного, та, як наслідок, прибрати необхідність у додаткових шарах у т.зв. залишкових зв'язках, які поєднують непослідовні шари. Усі функції активації в мережі – лінійні.

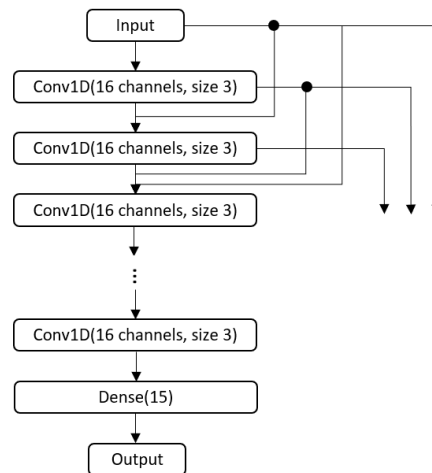


Рис.5.2. – Запропонована нейронна мережа.

5.3. Навчання нейронної мережі та його результат

Запропонований метод імплементовано на мові програмування Python з використанням бібліотек TensorFlow [42], Scipy [43], Matplotlib [44] в середовищі Kaggle [41]. Нейронну мережу навчено протягом 60 епох за допомогою оптимізатора Adam з такими параметрами:

- $\beta_1=0.9$
- $\beta_2=0.999$
- Коефіцієнт навчання експоненційно зменшується за формулою (3.1), початковий коефіцієнт навчання дорівнює 10^{-3} , $decay_{rate} = 0.99$, а $t_{decay} = 10^3$
- Розмір міні-вибірки дорівнює 256 екземплярів.

80% вибірки складають тренувальні примірники, 20% - валідаційні.

Функція втрат – середня абсолютна помилка.

Задля кращої інтерпретабельності результату роботи нейронної мережі скористаємось симетричною середньою абсолютною відсотковою похибкою [96] (англ. Symmetric Mean Absolute Percentage Error, SMAPE):

$$SMAPE = \frac{100}{n} \sum_{t=1}^n \frac{|F_t - A_t|}{(|A_t| + |F_t|)/2},$$

де n – кількість примірників, якість прогнозування яких треба визначити, A_t – реальне значення t -го елемента, F_t – прогнозоване значення t -го елемента.

Зміна значення функції втрат для тренувального та валідаційного наборів наведена на Рис.5.3а. На Рис.5.3б можна побачити, що за метрикою SMAPE, похибка апроксимованих значень на усій вибірці коефіцієнтів сягає не більше як 4%, що можна вважати доволі точним результатом. Таким чином, запропонований метод є ефективним з точки зору точності отриманого результату.

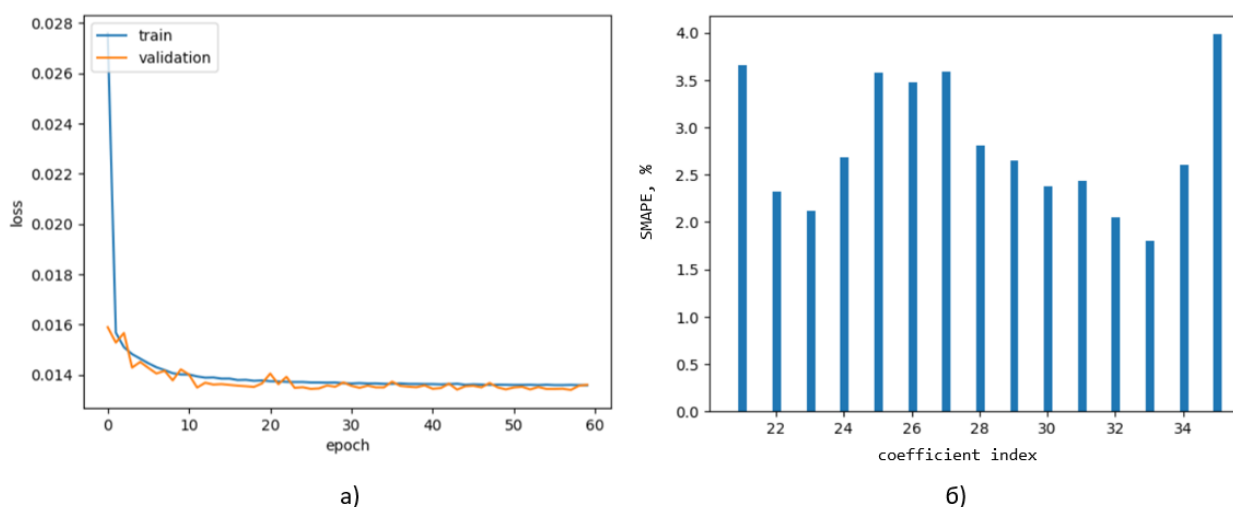


Рис.5.3. – Результати навчання запропонованої нейронної мережі: а) значення функції втрат протягом навчання; б) середні похибки визначення коефіцієнтів (масштабованих до $[0; 1]$) у відсотках.

Таким чином, за наявності репрезентативної вибірки достатнього обсягу, штучні нейронні мережі можуть використовуватись в якості засобів надроздільної здатності абераційного фронту, оскільки, як показує проведене дослідження, їхнє застосування здатне забезпечити відносно високу точність оцінки аберацій високих порядків. Також варто відмітити, що запропонований метод є окремим від безпосередньо процесу вимірювання, тож може використовуватись для обробки результатів будь-якого методу вимірювання аберацій. Втім, при розробці нейронної мережі для конкретного застосування в складі апаратно-програмного комплексу для визначення аберацій людського

ока, поставатиме проблема точності отриманих результатів та прийняття подальших рішень на їхній основі. Цю проблему можна розв'язати або розробкою механізму уточнення, за прикладом наведеного раніше методу вимірювання аберацій із застосуванням навчання з підкріпленням, або врахуванням неточності результатів при подальшій роботі із інформацією щодо діагностованих аберацій.

Висновок до Розділу 5

В даній роботі запропоновано метод збільшення точності визначення відхилень хвильових фронтів, який полягає у розрахунку згортковою нейронною мережею коефіцієнтів вищих порядків на основі коефіцієнтів нижчих порядків. Для перевірки роботи методу використано набір фотографій хмарного неба SWIMSEG, з якого створено навчаючу вибірку шляхом аугментації графічних даних та подальшого розрахунку коефіцієнтів Церніке з отриманих зображень. Таким чином фотографії використано в якості зображень хвильових фронтів. Отримана середня похибка апроксимації коефіцієнтів для 6 та 7 радіальних порядків на основі значень для 1-5 порядків за метрикою SMAPE становить не більше ніж 4%, що вказує на високу точність запропонованого методу.

ВИСНОВКИ

В даній роботі результатом виконання вдосконалення методу рейтрейсингової aberометрії ока стала розробка його нейромережної модифікації, яка підвищує точність вимірювань. Серед інших позитивних результатів модифікації є пришвидшення процедури aberометрії та виключення необхідності у складній оптичній системі для імплементації методу. Розроблено метод генерації aberометричних даних із застосуванням генеративно-змагальної нейронної мережі. Запропоновано метод надроздільної здатності хвильових фронтів із застосуванням згорткової нейронної мережі. Запропоновано модифікацію методу шляхом використання масиву випромінювачів для одночасного сканування із подальшим розрізненням світлових відбитків нейронною мережею класифікації та уточненням угорським алгоритмом.

В результаті проведення досліджень отримано наступні наукові результати:

1. Запропоновано метод генерування офтальмологічних даних aberометрії ока людини у вигляді наборів коефіцієнтів Церніке на основі алгоритму машинного навчання WGAN GP у поєднанні із алгоритмом DAG для аугментації даних під час навчання. Особливістю застосування аугментації даних для навчання генеративно-змагальної нейронної мережі є одночасні перетворення aberометричних даних як у вигляді одновимірного вектора, так і двовимірного зображення хвильового фронту – такий підхід дозволяє значно поліпшити різноманіття використаних даних під час навчання і, водночас, не призводить до «запам'ятовування» викривлень, якими по суті є аугментовані примірники навчаючої вибірки, оскільки усі перетворення є зворотними. Оцінки за метриками спадковості, творчості та різноманітності вказують на високу якість синтезованих даних. Цей науковий результат є актуальним не лише в контексті даної роботи, а й моделювання для

офтальмологічних досліджень загалом, оскільки існує нестача aberометричних даних у відкритому доступі, що сповільнює прогрес у впровадженні сучасних методів на основі штучних нейронних мереж, якість результату яких залежить від якості та розмірів навчаючих вибірок.

2. Запропоновано вдосконалення рейтрейсингового методу aberометрії з використанням масиву випромінювачів, що дозволило одночасне сканування ока в декількох точках зіниці без необхідності відхилення лазерних променів дефлектором. Для запобігання некоректному співставленню скануючих променів та їхніх відбитків на сітківці, використано нейронну мережу класифікації. При перевірці працездатності вдосконаленого методу, за значного розміру навчаючої вибірки для нейронної мережі, досягнуто 100% коректного визначення пар «промінь – відбиток». Потенційне впровадження цієї модифікації, наприклад, в aberометр iTrace для підняття кількості одночасно відсканованих зіничних координат до 16 здатне зменшити довірчий інтервал в 4.4 рази, що є вагомим позитивним результатом. Однак подальший розгляд модифікації виявив певний набір особливостей які ускладнюють подальші роботи щодо імплементації цієї модифікації. Таким чином, результати цього етапу дослідження показали потребу у розробці іншої модифікації, яка включає інший спосіб вимірювання та, відповідно, іншу оптичну систему для імплементації методу.
3. Запропоновано нейромережну модифікацію методу рейтрейсингової aberометрії ока. Вдосконалення наслідують особливості двох методів aberометрії – із застосуванням сенсору Гартмана-Шека та безпосередньо рейтрейсингового методу. Від першого методу запозичено загальну структуру оптичної системи та спосіб сканування ока, від другого – визначення абераций шляхом відслідковування окремих променів. Перше наближення визначення параметрів хвильового фронту абераций та його уточнення здійснюється засобами на основі нейронної мережі прямого

розповсюдження та навчання з підкріпленням відповідно. Проведено симуляцію в спеціалізованому програмному забезпеченні для оптичних систем Zemax та наведено приклад алгоритму обробки первинних вимірювань. З метою перевірки працездатності, нейронні мережі першого наближення та подальша корекція здійснювались на дискретних наборах нормованих коефіцієнтів Церніке. Моделювання в середовищі MATLAB показало працездатність запропонованого алгоритму. В симуляції проведено попередню оцінку точності, за результатами якої виявлено, що точність визначення дефокусу краща на 25%, ніж задекларовано для аберометра iTrace (помилка 0.098 мкм проти 0.13 мкм), у випадку викривлення зображення на детекторах не більше ніж 0.1 за відстанню Жаккара. Це є позитивним результатом, але більш релевантну інформацію про точність можна отримати в роботі з реальною імплементацією модифікованого рейтрейсингового методу аберометрії. Перевірено роботу засобу корекції коефіцієнтів Церніке на основі агентів DQN та PPO. Визначено, що агент DQN є більш стабільним в навчанні. Запропоновані вдосконалення дозволяють значно спростити оптичну систему для імплементації рейтрейсингового методу та забезпечують точне одночасне вимірювання аберацій в усіх зіничних координатах.

4. Розроблено метод для надроздільної здатності хвильових фронтів, який дозволяє з доволі високою точністю (~4% за метрикою SMAPE) визначати коефіцієнти Церніке високих порядків на основі коефіцієнтів нижчих порядків. Визначення відбувається штучною нейронною мережею, навченою на перетворених у зображення хвильових фронтів фотографіях хмарного неба з датасету SWIMSEG. Отримана висока точність алгоритму вказує на його працездатність та на можливість використання навчаючих вибірок різного походження для підготовки нейронних мереж для роботи з коефіцієнтами Церніке.

Виконання етапів дослідження, наведених в Розділі 1, забезпечує нейромережну модифікацію рейтрейсингового методу аберометрії ока. Однак наведені наукові результати, в свою чергу, можна також розглядати як окремі вдосконалення, які можуть бути застосовані для інших методів аберометрії. Дійсно, генерація аберометричних даних є актуальною для оптичного моделювання різних пристроїв та алгоритмів визначення рефракційних похибок ока. Застосування нейронної мережі класифікації з метою встановлення відповідностей між скануючими променями та відбитками може бути адаптована для інших методів одночасного вимірювання, таких як, наприклад, метод із застосуванням сенсора хвильового фронту Гартмана-Шека. Підхід уточнення результатів вимірювання засобами навчання з підкріпленням можна вважати універсальним, однак він потребуватиме значних зусиль по адаптації до конкретних конструкцій приладів. Ефективність (по багатьох параметрах – точність, потреба в кількості даних для навчання і т.д.) оцінки коефіцієнтів Церніке вищих порядків за значеннями коефіцієнтів нижчих порядків не залежить від методу вимірювання аберацій, тому його можна вважати таким, що підходить для обробки вимірювань, отриманих будь-яким методом аберометрії ока.

Таким чином, можна стверджувати, що поставлені задачі вирішені, а основна мета роботи досягнута.

Отримані в дисертації результати дослідження можуть бути використані:

1. При розробці програмно-апаратних комплексів для визначення аберацій ока.
2. В навчальному процесі вищих навчальних закладів України при підготовці фахівців у галузі конструювання електронно-обчислювальної та оптико-електронної апаратури, а також фахівців із розробки ІТ-рішень, зокрема програмних та апаратних обчислювальних засобів.
3. В результатах науково-дослідних робіт за суміжною тематикою.

Дисертаційна робота виконувалась згідно з тематичними планами НДР КПІ ім. Ігоря Сікорського і кафедри КЕОА в межах НДР «Підвищення роздільної здатності інфрачервоного зображення з використанням згорткової нейронної мережі», РК №0121U111107, а також НДР «Модифікований нейромережний метод рейтрейсингової абераметрії ока», РК №0124U005087, згідно основних наукових напрямків діяльності КПІ ім. Ігоря Сікорського та пріоритетного напрямку розвитку науки і техніки України «Інформаційні та комунікаційні технології» **(Додаток А)**. Також результати дисертаційних досліджень використані як матеріали при підготовці та викладанні курсу лекційних і практичних занять (комп'ютерного практикуму) з дисципліни “Основи нейромережних технологій” та викладанні курсу лекційних і лабораторних занять з дисципліни “Системи комп'ютерного зору” другого (магістерського) рівня вищої освіти спеціальності 172 «Електронні комунікації та радіотехніка» освітньо-професійної програми «Інформаційно-обчислювальні засоби радіоелектронних систем», що затверджено відповідним актом **(Додаток Б)**.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Thibos L. N. Principles of Hartmann-Shack Aberrometry. *Journal of Refractive Surgery*. 2000. Vol. 16, no. 5. URL: <https://doi.org/10.3928/1081-597x-20000901-14>
2. Lakshminarayanan V., Fleck A. Zernike polynomials: a guide. *Journal of Modern Optics*. 2011. Vol. 58, no. 7. P. 545–561. URL: <https://doi.org/10.1080/09500340.2011.554896>
3. Аберометрія оптичної системи ока людини: моногр. / І.Г. Чиж, Г.С. Тимчик, Т.О. Шиша та ін. – К.: НТУУ «КПІ», 2013. – 292 с. URL: <https://kafvp.kpi.ua/book/aberometrija-optichnoi-sistemi-oka-ljud/>
4. Ковальський В.І., Яганов П.О. Пристрій для рейтрейсингової аберометрії ока. *Вісник Київського політехнічного інституту. Серія : Приладобудування*. 2018. Вип. 56(2). С. 103–111. URL: [https://doi.org/10.20535/1970.56\(2\).2018.152462](https://doi.org/10.20535/1970.56(2).2018.152462)
5. Mohammadpour M. Diagnostics in Ocular Imaging: Cornea, Retina, Glaucoma and Orbit. Springer International Publishing AG. 2020. P. 752. URL: <https://doi.org/10.1007/978-3-030-54863-6>
6. Atchison D. A., Smith G. Optics of the Human Eye. Oxford, 2003. P. 498. URL: <https://doi.org/10.1201/9781003128601>
7. G. Yoon. Aberration Theory. URL: https://cfao.ucolick.org/pubs/presentations/eyedesign/05_aberrations_GY.pdf (date of access: 02.11.2021).
8. Retina ray-tracing technique for eye-refraction mapping / V. V. Molebny et al. *BiOS '97, Part of Photonics West*, San Jose, CA / ed. by P. O. Rol, K. M. Joos, F. Manns. 1997. URL: <https://doi.org/10.1117/12.275118>
9. Wolf E., Born M. Principles of Optics: 60th Anniversary Edition. University of Cambridge ESOL Examinations, 2019. 992 p.
10. Ковальський В. І. Метод розміщення променів зондування при рейтрейсинговій аберометрії. Перспективи телекомунікацій: збірник матеріалів Міжнародної науково-технічної конференції, м.Київ, 16-20

- квітня 2018 р. Київ, 2018. URL: <http://conferenc.its.kpi.ua/proc/article/view/131975>
11. Tracey Technologies. URL: <https://www.traceytechnologies.com/> (date of access: 10.11.2021).
 12. Wang M. Corneal Topography in the Wavefront Era: A Guide for Clinical Application. Slack Incorporated, 2006. 336 p.
 13. Study on a Kalman Filter based PID Controller / S. Wakitani et al. IFAC-PapersOnLine. 2018. Vol. 51, no. 4. P. 422–425. URL: <https://doi.org/10.1016/j.ifacol.2018.06.131>
 14. Handbook of Reinforcement Learning and Control / ed. by K. G. Vamvoudakis et al. Cham : Springer International Publishing, 2021. URL: <https://doi.org/10.1007/978-3-030-60990-0>
 15. A global review of publicly available datasets for ophthalmological imaging: barriers to access, usability, and generalisability / S. M. Khan et al. *The Lancet Digital Health*. 2021. Vol. 3, no. 1. P. e51-e66. URL: [https://doi.org/10.1016/s2589-7500\(20\)30240-5](https://doi.org/10.1016/s2589-7500(20)30240-5)
 16. High temporal resolution aberrometry in a 50-eye population and implications for adaptive optics error budget / J. Jarosz et al. *Biomedical Optics Express*. 2017. Vol. 8, no. 4. P. 2088. URL: <https://doi.org/10.1364/boe.8.002088>
 17. Generative adversarial networks / I. Goodfellow et al. *Communications of the ACM*. 2020. Vol. 63, no. 11. P. 139–144. URL: <https://doi.org/10.1145/3422622>
 18. Mahanama B., Jayawardana Y., Rengarajan S., Jayawardana G., Chukoskie L., Snider J., Jayarathna S. (2022). Eye Movement and Pupil Measures: A Review. *Frontiers in Computer Science*. Vol. 3. 2022. URL: <https://doi.org/10.3389/fcomp.2021.733531>
 19. Aggarwal C. C. Neural Networks and Deep Learning. Cham : Springer International Publishing, 2018. URL: <https://doi.org/10.1007/978-3-319-94463-0>

20. Goodfellow I., Bengio Y., Courville A. Deep Learning. MIT Press, 2017. 800 p. URL: <https://doi.org/10.1007/s10710-017-9314-z>
21. Sequence-to-Sequence Classification Using Deep Learning – MATLAB & Simulink. URL: <https://www.mathworks.com/help/deeplearning/ug/sequence-to-sequence-classification-using-deep-learning.html> (accessed Jun. 13, 2022).
22. Jung Bin Won, Sun Woong Kim, Eung Kweon Kim, Byung Jin Ha, Taeim Kim. Comparison of Internal and Total Optical Aberrations for 2 Aberrometers: iTrace and OPD Scan. Korean Journal of Ophthalmology. Vol. 22. 2008. P. 210 – 213. URL: <https://doi.org/10.3341/kjo.2008.22.4.210>
23. A Systematic Survey of Deep Learning-based Single-Image Super-Resolution / J. Li et al. *ACM Computing Surveys*. 2024. URL: <https://doi.org/10.1145/3659100>
24. Video super-resolution based on deep learning: a comprehensive survey / H. Liu et al. *Artificial Intelligence Review*. 2022. URL: <https://doi.org/10.1007/s10462-022-10147-y>
25. Chang Y., Luo B. Bidirectional Convolutional LSTM Neural Network for Remote Sensing Image Super-Resolution. *Remote Sensing*. 2019. Vol. 11, no. 20. P. 2333. URL: <https://doi.org/10.3390/rs11202333>
26. Yaroshenko M. O., Varfolomeiev A. Y., Yaganov P. O. Hierarchical Convolutional Neural Network for Infrared Image Super-Resolution. *Microsystems, Electronics and Acoustics*. 2021. Vol. 26, no. 1. URL: <https://doi.org/10.20535/2523-4455.mea.230603>
27. R. C. Gonzalez, R. E. Woods, and S. L. Eddins, Digital image processing using MATLAB. Knoxville: Gatesmark Publishing, 2020. 362 p.
28. Application of generative adversarial networks (GAN) for ophthalmology image domains: a survey / A. You et al. *Eye and Vision*. 2022. Vol. 9, no. 1. URL: <https://doi.org/10.1186/s40662-022-00277-3>

- 29.Arjovsky M., Chintala S., Bottou L. Wasserstein Gan. *ICML'17: Proceedings of the 34th International Conference on Machine Learning*. Vol. 70. 06 August 2017. P. 214 – 223. URL: <https://dl.acm.org/doi/10.5555/3305381.3305404>
- 30.Improved Training of Wasserstein GANs. / Gulrajani I. et al. *NIPS'17: Proceedings of the 31st International Conference on Neural Information Processing Systems*. 04 December 2017. P. 5769 – 5779. URL: <https://dl.acm.org/doi/10.5555/3295222.3295327>
- 31.On Data Augmentation for GAN Training / N.-T. Tran et al. *IEEE Transactions on Image Processing*. 2021. Vol. 30. P. 1882–1897. URL: <https://doi.org/10.1109/tip.2021.3049346>
- 32.Heusel M., Ramsauer H., Unterthiner T., Nessler B., Hochreiter S. GANs trained by a two time-scale update rule converge to a local Nash equilibrium. *NIPS'17: Proceedings of the 31st International Conference on Neural Information Processing Systems*. 04 December 2017. URL: <https://dl.acm.org/doi/10.5555/3295222.3295408>
- 33.Gradient-based learning applied to document recognition / Y. Lecun et al. *Proceedings of the IEEE*. 1998. Vol. 86, no. 11. P. 2278–2324. URL: <https://doi.org/10.1109/5.726791>
- 34.Self-Supervised GANs via Auxiliary Rotation Loss / T. Chen et al. *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Long Beach, CA, USA, 15–20 June 2019. 2019. URL: <https://doi.org/10.1109/cvpr.2019.01243>
- 35.Main page. *The CIFAR-10 dataset*. URL: <https://www.cs.toronto.edu/~kriz/cifar.html> (date of access: 02.04.2023).
- 36.Guan S., Loew M. A novel measure to evaluate generative adversarial networks based on direct analysis of generated images. *Neural Computing and Applications*. 2021. Vol. 33. P. 13921–13936. URL: <https://doi.org/10.1007/s00521-021-06031-5>

37. Going deeper with convolutions / C. Szegedy et al. *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Boston, MA, USA, 7–12 June 2015. 2015. URL: <https://doi.org/10.1109/cvpr.2015.7298594>
38. Dowson D. C., Landau B. V. The Fréchet distance between multivariate normal distributions. *Journal of Multivariate Analysis*. 1982. Vol. 12, no. 3. P. 450–455. URL: [https://doi.org/10.1016/0047-259x\(82\)90077-x](https://doi.org/10.1016/0047-259x(82)90077-x)
39. Wang Z., Simoncelli E. P., Bovik A. C. Multiscale structural similarity for image quality assessment. Conference Record of the 37th Asilomar Conference on Signals, Systems and Computers, Pacific Grove, CA, USA. URL: <https://doi.org/10.1109/acssc.2003.1292216>
40. Kingma D. P., Ba J. L. Adam: A method for stochastic optimization. *ICLR 2015: International Conference on Learning Representations*. San Diego. May 7-9 2015. URL: <https://doi.org/10.48550/arXiv.1412.6980>
41. Main page. *Kaggle*. URL: <https://www.kaggle.com> (date of access: 04.08.2023)
42. Main page. *TensorFlow*. URL: <https://www.tensorflow.org> (date of access: 04.08.2023)
43. Main page. *SciPy*. URL: <https://scipy.org> (date of access: 04.08.2023)
44. Main page. *Matplotlib*. URL: <https://matplotlib.org> (date of access: 04.08.2023)
45. Assessment of Assignment Problem using Hungarian Method. / Tanvir A. et al. *The 1st Australian Conference on Industrial Engineering and Operations Management in Sydney*. Sydney, Australia. 20–22 December 2022. URL: <https://doi.org/10.46254/au01.20220498>
46. Zemax. *An Ansys Company*. URL: <https://www.zemax.com/> (date of access: 22.08.2022)
47. Liou H.-L., Brennan N. A. Anatomically accurate, finite model eye for optical modeling. *Journal of the Optical Society of America A*. 1997. Vol. 14, no. 8. P. 1684. URL: <https://doi.org/10.1364/josaa.14.001684>

48. OpticStudio models of the human eye. *An Ansys Company*. URL: <https://support.zemax.com/hc/en-us/articles/1500005575082-OpticStudio-models-of-the-human-eye> (date of access: 22.09.2022)
49. Wave front aberrations induced from biomechanical effects after customized myopic laser refractive surgery in finite element model / Du R. et al. *International Ophthalmology*. 2022. V. 42(1). P. 81-94. DOI: 10.1007/s10792-021-02003-9
50. Noll R.J. Zernike polynomials and atmospheric turbulence. *Journal of the Optical Society of America*. 1976. V. 66. P. 207-211. URL: <https://doi.org/10.1364/JOSA.66.000207>
51. Google Colaboratory. *Google Research*. URL: <https://colab.research.google.com/> (date of access: 22.09.2022)
52. Hochreiter S., Schmidhuber J. Long Short-term Memory. *Neural computation*. 1997. V. 9. P. 1735-1780. URL: <https://doi.org/10.1162/neco.1997.9.8.1735>
53. Understanding LSTM Networks. URL: <http://colah.github.io/posts/2015-08-Understanding-LSTMs/> (date of access: 22.09.2022)
54. Long Short-Term Memory Networks. URL: <https://www.mathworks.com/help/deeplearning/ug/long-short-term-memory-networks.html> (date of access: 22.09.2022)
55. Graves A., Schmidhuber J. Framewise phoneme classification with bidirectional LSTM networks. *Proceedings of the 2005 IEEE International Joint Conference on Neural Networks*. 2005. V. 4. P. 2047–2052. URL: <https://doi.org/10.1109/IJCNN.2005.1556215>
56. Maas A.L., Hannun A.Y., Ng A.Y. Rectifier Nonlinearities Improve Neural Network Acoustic Models. *Proceedings of the 30th International Conference on Machine Learning*. 2013. V. 28(3). URL: https://ai.stanford.edu/~amaas/papers/relu_hybrid_icml2013_final.pdf
57. Ba J. L., Kiros J. R., Hinton G. E. Layer Normalization. *arXiv*. 2016. URL: <https://doi.org/10.48550/arXiv.1607.06450> (date of access: 10.09.2022)

- 58.Das D., Wilson A. C. Very long optical path-length from a compact multi-pass cell. *Applied Physics B*. 2010. Vol. 103, no. 3. P. 749–754. URL: <https://doi.org/10.1007/s00340-010-4337-7>
- 59.Soille P. Morphological Image Analysis. Berlin, Heidelberg : Springer Berlin Heidelberg, 2004. 392 P. URL: <https://doi.org/10.1007/978-3-662-05088-0>
- 60.Machine learning for wavefront sensing / A. Wong et al. *Adaptive Optics Systems VIII*, Montréal, Canada, 17–23 July 2022 / ed. by D. Schmidt, L. Schreiber, E. Vernet. 2022. URL: <https://doi.org/10.1117/12.2628869>
- 61.Deep learning wavefront sensing / Y. Nishizaki et al. *Optics Express*. 2019. Vol. 27, no. 1. P. 240. URL: <https://doi.org/10.1364/oe.27.000240>
- 62.Chollet F. Xception: Deep Learning with Depthwise Separable Convolutions. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, HI, 21–26 July 2017. 2017. P. 1800-1807. URL: <https://doi.org/10.1109/cvpr.2017.195>
- 63.Ярошенко М.О., Яганов П.О. Оцінка коефіцієнтів Церніке в рейтрейсинговій аберометрії ока з використанням згорткової нейронної мережі. *Матеріали Міжнародної науково-технічної конференції «Artificial Intelligence in Science and Education» (AISE 2024)*, 1-2 березня 2024, с.584-587, URL: <http://doi.org/10.35668/978-966-479-141-7>
- 64.Deep Learning Estimation of Modified Zernike Coefficients for Image Point Spread Functions / A. B. Siddik et al. *Optics Express*. 2023. P. 22903-22913. URL: <https://doi.org/10.1364/oe.493229>
- 65.Krizhevsky A., Sutskever I., Hinton G. E. ImageNet classification with deep convolutional neural networks. *Communications of the ACM*. 2017. Vol. 60, no. 6. P. 84–90. URL: <https://doi.org/10.1145/3065386>
- 66.Description of shape characteristics through Fourier and wavelet analysis / Z. Yuan et al. *Chinese Journal of Aeronautics*. 2014. Vol. 27, no. 1. P. 160–168. URL: <https://doi.org/10.1016/j.cja.2013.07.011>
- 67.Sutton R. S., Barto A. G. Reinforcement Learning: An Introduction. A Bradford Book, 2018. 552 p.

- 68.Fowler J., Landman R. Tempestas ex machina: a review of machine learning methods for wavefront control. *Techniques and Instrumentation for Detection of Exoplanets XI*, San Diego, United States, 20–25 August 2023 / ed. by G. J. Ruane. 2023. URL: <https://doi.org/10.1117/12.2676536>
- 69.Wavefront sensor-less adaptive optics using deep reinforcement learning / E. Durech et al. *Biomedical Optics Express*. 2021. Vol. 12, no. 9. P. 5423. URL: <https://doi.org/10.1364/boe.427970>
- 70.Continuous control with deep reinforcement learning / Lillicrap T.P. et al. arXiv. 2015. URL: <https://arxiv.org/abs/1509.02971>
- 71.Watkins C. J. C. H. Learning from delayed rewards : thesis. 1989. URL: <http://ethos.bl.uk/OrderDetails.do?uin=uk.bl.ethos.330022>
- 72.Tesauro G. Temporal difference learning and TD-Gammon. *Communications of the ACM*. 1995. Vol. 38, no. 3. P. 58–68. URL: <https://doi.org/10.1145/203330.203343>
- 73.Li S. E. Reinforcement Learning for Sequential Decision and Optimal Control. Singapore : Springer Nature Singapore, 2023. URL: <https://doi.org/10.1007/978-981-19-7784-8>
- 74.Van Hasselt H., Guez A., Silver D. Deep Reinforcement Learning with Double Q-Learning. *Proceedings of the AAAI Conference on Artificial Intelligence*. 2016. Vol. 30, no. 1. URL: <https://doi.org/10.1609/aaai.v30i1.10295>
- 75.Edelsbrunner H. A Short Course in Computational Geometry and Topology. Cham : Springer International Publishing, 2014. URL: <https://doi.org/10.1007/978-3-319-05957-0>
- 76.Aurenhammer F., Klein R., Lee D.-T. Voronoi Diagrams and Delaunay Triangulations. World Scientific Publishing Company, 2013. 337 p. URL: <https://doi.org/10.1142/8685>
- 77.Bresenham J. E. Algorithm for computer control of a digital plotter. *IBM Systems Journal*. 1965. Vol. 4, no. 1. P. 25–30. URL: <https://doi.org/10.1147/sj.41.0025>

78. Wu X. An efficient antialiasing technique. *ACM SIGGRAPH Computer Graphics*. 1991. Vol. 25, no. 4. P. 143–152. URL: <https://doi.org/10.1145/127719.122734>
79. Investigating Jaccard Distance similarity measurement constriction on handwritten pen-based input digit / Noor Aznimah Abdul Aziz et al. *2010 International Conference on Science and Social Research (CSSR)*, Kuala Lumpur, Malaysia, 5–7 December 2010. 2010. URL: <https://doi.org/10.1109/cssr.2010.5773712>
80. Akima H. A New Method of Interpolation and Smooth Curve Fitting Based on Local Procedures. *Journal of the ACM*. 1970. Vol. 17, no. 4. P. 589–602. URL: <https://doi.org/10.1145/321607.321609>
81. Salomon D. Raster Graphics. *Texts in Computer Science*. London, 2011. P. 29–134. URL: https://doi.org/10.1007/978-0-85729-886-7_2
82. Clevert D.-A., Unterthiner T., Hochreiter S. Fast and accurate deep network learning by exponential linear units (ELUs). arXiv. 2016. URL: <https://doi.org/10.48550/arXiv.1511.07289> (date of access: 11, 2024).
83. Hendrycks D., Gimpel K. Gaussian error linear units (GELUs). arXiv. 2016. URL: <https://doi.org/10.48550/arXiv.1606.08415> (date of access: 11, 2024).
84. Ramachandran P., Zoph B., Le Q. V. Searching for activation functions. arXiv. 2017. URL: <https://doi.org/10.48550/arXiv.1710.05941> (date of access: Nov. 11, 2024).
85. Cortes C., Mohri M., Rostamizadeh A. L2 regularization for learning kernels. *UAI '09: Proceedings of the Twenty-Fifth Conference on Uncertainty in Artificial Intelligence*. 18 June 2009. P. 109–116. URL: <https://dl.acm.org/doi/10.5555/1795114.1795128>
86. Aaron Wetzler (2024). Bresenham optimized for Matlab. *MATLAB Central File Exchange*. URL: <https://www.mathworks.com/matlabcentral/fileexchange/28190-bresenham-optimized-for-matlab> (date of access: 21.06.2024).

87. Proximal policy optimization algorithms / Schulman J. et al. arXiv. 2017.
URL: <https://doi.org/10.48550/arXiv.1707.06347> (date of access: 11.04.2024).
88. High-Dimensional Continuous Control Using Generalized Advantage Estimation / Schulman J. et al. arXiv. 2018. URL: <https://doi.org/10.48550/arXiv.1506.02438>
89. Incorporating second-order functional knowledge for better option pricing / Dugas C. et al. *Proceedings of the 13th International Conference on Neural Information Processing Systems (NIPS'00)*. 01 January 2000. P. 451–457.
URL: <https://dl.acm.org/doi/10.5555/3008751.3008817>
90. Dev S., Lee Y. H., Winkler S. Color-Based Segmentation of Sky/Cloud Images From Ground-Based Cameras. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 2017. Vol. 10, no. 1. P. 231–242. URL: <https://doi.org/10.1109/jstars.2016.2558474>
91. Image Super-Resolution Using Deep Convolutional Networks / C. Dong et al. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2016. Vol. 38, no. 2. P. 295–307.
URL: <https://doi.org/10.1109/tpami.2015.2439281>
92. Photo-Realistic Single Image Super-Resolution Using a Generative Adversarial Network / C. Ledig et al. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, HI, 21–26 July 2017. 2017. URL: <https://doi.org/10.1109/cvpr.2017.19>
93. Kuleshov V., Enam S. Z., Ermon S. Audio Super Resolution Using Neural Networks. arXiv. 2017. URL: <https://doi.org/10.48550/arXiv.1708.00853> (accessed Sep. 7, 2023).
94. Mandel M., Tal O., Adi Y. AERO: Audio Super Resolution in the Spectral Domain. *ICASSP 2023 - 2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, Rhodes Island, Greece, 4–10 June 2023. 2023. URL: <https://doi.org/10.1109/icassp49357.2023.10095382>

95. Kim H.E., Cosa-Linan A., Santhanam N. et al. Transfer learning for medical image classification: a literature review. *BMC Med Imaging*. Vol. 22. No. 69. 2022. URL: <https://doi.org/10.1186/s12880-022-00793-7>
96. Makridakis S. Accuracy measures: theoretical and practical concerns. *International Journal of Forecasting*. 1993. Vol. 9, no. 4. P. 527–529. URL: [https://doi.org/10.1016/0169-2070\(93\)90079-3](https://doi.org/10.1016/0169-2070(93)90079-3)

ДОДАТОК А. ДОВІДКИ ПРО ВПРОВАДЖЕННЯ



НАУКОВО-ДОСЛІДНИЙ ІНСТИТУТ ЕЛЕКТРОНІКИ ТА МІКРОСИСТЕМНОЇ ТЕХНІКИ

НАЦІОНАЛЬНИЙ ТЕХНІЧНИЙ УНІВЕРСИТЕТ УКРАЇНИ «КИЇВСЬКИЙ
ПОЛІТЕХНІЧНИЙ ІНСТИТУТ імені ІГОРЯ СІКОРСЬКОГО»

03056, Україна

м. Київ, вул. Політехнічна, 16

Тел. +380 (44) 204-96-76

ЗАТВЕРДЖУЮ

А.О. Воронько

29.01.2020 р.

ДОВІДКА

про практичне впровадження результатів дисертаційної роботи Ярошенка Максима Олександровича “Модифікований нейромережний метод рейтресингової аберометрії ока” на здобуття наукового ступеня доктора філософії за спеціальністю 172 – Телекомунікації та радіотехніка

Аберації оптичної системи ока являють собою відхилення від ідеального зображення, яке формується на сітківці через оптичні недосконалості ока. Вплив аберацій на якість життя людини є значним, оскільки зір є одним із найважливіших сенсорних відчуттів, що забезпечує орієнтацію в просторі, виконання повсякденних завдань та взаємодію з навколишнім середовищем. Тому питання виявлення та корекції аберацій є надзвичайно важливим для сучасної офтальмології. Одним із сучасних методів діагностики є рейтресинговий метод аберометрії, який, попри широкий діапазон вимірювань, має ряд недоліків та обмежень. Дисертаційна робота Ярошенка М.О. присвячена вдосконаленню методу рейтресингової аберометрії ока застосуванням штучних нейронних мереж на різних етапах його роботи.

Результати наукової роботи Ярошенка М.О. застосовано для розробки рішення для збільшення роздільної здатності зображень. Зокрема, здійснено адаптацію підходів збільшення роздільної здатності для зображень хвильових фронтів під роботу із зображеннями в інфрачервоному спектрі. Реалізація такого методу на практиці дозволяє додати високочастотні деталі до інфрачервоного зображення на основі зображення із низькою роздільною здатністю. Запропоновано дослідну реалізацію штучної нейронної мережі для збільшення роздільної здатності в 2 рази зі швидкістю в 1.9 разів більшою, ніж інше відоме рішення BCLSR. Розробку та перевірку працездатності здійснено в середовищі Google Colaboratory на мові програмування Python засобами бібліотеки функцій TensorFlow.

Отримані результати використано під час виконання науково-дослідної роботи “Ієрархічна згорткова нейронна мережа для підвищення роздільної здатності інфрачервоних зображень” (№0222U004908). В межах цієї роботи також розроблено практичні рекомендації щодо розробки архітектур згорткових нейронних мереж для збільшення роздільної здатності зображень.

Науковий керівник

 /П.О. Яганов

 Ярошенко М.О.



**НАУКОВО-ДОСЛІДНИЙ ІНСТИТУТ ЕЛЕКТРОНІКИ ТА
МІКРОСИСТЕМНОЇ ТЕХНІКИ**

**НАЦІОНАЛЬНИЙ ТЕХНІЧНИЙ УНІВЕРСИТЕТ УКРАЇНИ «КИЇВСЬКИЙ
ПОЛІТЕХНІЧНИЙ ІНСТИТУТ імені ІГОРЯ СІКОРСЬКОГО»**

03056, Україна

м. Київ, вул. Політехнічна, 16

Тел. +380 (44) 204-96-76



ДОВІДКА

про практичне впровадження результатів дисертаційної роботи Ярошенка Максима Олександровича “Модифікований нейромережний метод реїтресингової аберометрії ока” на здобуття наукового ступеня доктора філософії за спеціальністю 172 – Телекомунікації та радіотехніка

Оптична система ока має свої аберації — це відхилення від ідеального зображення, яке повинно формуватися на сітківці через оптичні недосконалості ока. Такі аберації значно впливають на якість життя людини, адже зір є одним із головних сенсорних відчуттів, що дозволяє орієнтуватися в просторі, виконувати щоденні завдання та взаємодіяти з навколишнім середовищем. Саме тому виявлення та корекція аберацій мають велике значення для сучасної офтальмології. Одним із провідних методів діагностики є реїтресинговий метод аберометрії, який, попри широкий діапазон вимірювань, має свої недоліки та обмеження. Дисертаційна робота Ярошенка М.О. присвячена вдосконаленню методу реїтресингової аберометрії ока застосуванням штучних нейронних мереж на різних етапах його роботи.

Результати наукової роботи Ярошенка М.О. застосовано для розробки нейромережного методу реїтресингової аберометрії ока як модифікації існуючого методу. Зокрема, вдосконалено оптичну систему для вимірювання аберацій, розроблено штучну нейронну мережу для визначення характеристик хвильового фронту та програму для корекції результатів. Реалізація цих вдосконалень на практиці дозволяє одночасне вимірювання аберацій в усіх зіничних координатах ока із застосуванням відносно простої оптичної системи. Також для уможливлення тренування нейронних мереж шляхом збільшення існуючих навчаючих вибірок запропоновано метод генерації аберометричних даних застосуванням генеративно-змагальної нейронної мережі. Запропоновано дослідну реалізацію оптичної системи для імплементації методу у спеціалізованому програмному забезпеченні Zemax, а також реалізацію штучних нейронних мереж в середовищах Google Colaboratory, Kaggle та MATLAB.

Отримані результати використано під час виконання науково-дослідної роботи “Модифікований нейромережний метод реїтресингової аберометрії ока” (№0124U005087). В межах цієї роботи також розроблено практичні рекомендації щодо розробки оптичних систем та архітектур нейронних мереж для визначення аберацій та генерації аберометричних даних.

Науковий керівник

/П.О. Яганов

Ярошенко М.О.

ДОДАТОК Б. АКТ ВПРОВАДЖЕННЯ



ЗАТВЕРДЖУЮ
Проректорка з навчальної роботи
КПІ ім. Ігоря Сікорського
к.т.н., доц.,
Тетяна ЖЕЛІАСКОВА

АКТ ВПРОВАДЖЕННЯ

результатів дисертаційної роботи

Ярошенка Максима Олександровича


у навчальний процес кафедри конструювання електронно-обчислювальної апаратури
Національного технічного університету України "Київський політехнічний інститут імені
Ігоря Сікорського"

Ми, що нижче підписалися, представники Національного технічного університету України "Київський політехнічний інститут імені Ігоря Сікорського" – заступник декана з наукової роботи факультету електроніки (ФЕЛ), к.т.н., доцент Попович П.В, завідувач кафедри конструювання електронно-обчислювальної апаратури (КЕОА), д.т.н., професор Лисенко О.М.; професор кафедри КЕОА, д.ф.-м.н., професор Редько І.В.; завідувач навчально-наукової лабораторії мікроелектроніки, робототехніки і телекомунікацій (МРТ), доцент кафедри КЕОА к.т.н., Іваннік Г.В. – склали цей акт про те, що результати дисертаційного дослідження здобувача кафедри КЕОА Ярошенка М.О. використані як матеріали при підготовці та викладанні курсу лекційних і практичних занять (комп'ютерного практикуму) з дисципліни "Основи нейромережних технологій" та викладанні курсу лекційних і лабораторних занять з дисципліни "Системи комп'ютерного зору" другого (магістерського) рівня вищої освіти спеціальності 172 «Електронні комунікації та радіотехніка» освітньо-професійної програми «Інформаційно-обчислювальні засоби радіоелектронних систем».

Для дисципліни "Основи нейромережних технологій" підготовлено лекційні матеріали та практичне заняття по основам роботи зі штучними нейронними мережами довгої короткочасної пам'яті для обробки даних у вигляді часових послідовностей. Для дисципліни "Системи комп'ютерного зору" підготовлено лекційні матеріали та лабораторну роботу по створенню та практичному застосуванню штучних нейронних мереж для визначення параметрів об'єкта за його зображенням. Лекційні, практичні та лабораторні матеріали створено на основі запропонованого в дисертації модифікованого нейромережного методу рейтрейсингової абераметрії ока, алгоритмічних та програмних рішень його реалізації.

Це дозволило підвищити рівень підготовки студентів у сфері обробки інформації у вигляді послідовностей та зображень засобами штучних нейронних мереж, що є актуальним для створення інтелектуальних систем, які забезпечують нові можливості для автоматизації та аналітики даних.


заст. декана з наукової роботи ФЕЛ, к.т.н., доц.

 Павло ПОПОВИЧ

зав. кафедри КЕОА, д.т.н., проф.

 Олександр ЛИСЕНКО

проф. кафедри КЕОА, д.ф.-м.н., проф.

 Ігор РЕДЬКО

зав. лаб. МРТ, доц. кафедри КЕОА, к.т.н.

 Геннадій ІВАННІК