



<http://dx.doi.org/10.35596/1729-7648-2026-24-1-13-20>

УДК 535.8

ГИБРИДНЫЙ МЕТОД ГЛУБОКОГО ОБУЧЕНИЯ ДЛЯ РЕШЕНИЯ ОБРАТНОЙ ЗАДАЧИ ДЕТЕКТИРОВАНИЯ ГЕТЕРОГЕННЫХ СИСТЕМ ПО МНОГОМЕРНЫМ ДАННЫМ ОПТИЧЕСКИХ СЕНСОРОВ

И. В. САЕЧНИКОВ, Э. А. ЧЕРНЯВСКАЯ, А. В. САЕЧНИКОВ

Белорусский государственный университет (Минск, Республика Беларусь)

Аннотация. Современные методы машинного и глубокого обучения эффективно справляются с прямыми задачами обработки данных с сенсоров и с выявлением сложных зависимостей, обеспечивая устойчивость к шумам и вариациям в данных. Наиболее актуальной является задача синтеза результатов обработки многомерных данных гибридными методами обучения для решения обратных задач, таких как определение компонент динамически изменяющихся сложных гетерогенных систем без нарушения их свойств в мультисенсорных измерительных платформах. В статье рассмотрен гибридный метод глубокого обучения, интегрированный в платформу на основе оптических сенсоров и сочетающий сверточные нейронные сети, двунаправленные сети долгой краткосрочной памяти и трансформерные энкодеры, что обеспечивает динамический мониторинг компонент гетерогенных систем. Гибридный метод применительно к биосенсорной платформе демонстрирует точность классификации более 98 % по типу раствора и восстановление значений концентрации белковых компонентов с медианной точностью до 2 нг/мл.

Ключевые слова: гибридное глубокое обучение, обратная задача, многомерные данные, детектирование, оптический сенсор, динамический мониторинг.

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Для цитирования. Саечников, И. В. Гибридный метод глубокого обучения для решения обратной задачи детектирования гетерогенных систем по многомерным данным оптических сенсоров / И. В. Саечников, Э. А. Чернявская, А. В. Саечников // Доклады БГУИР. 2026. Т. 24, № 1. С.13–20. <http://dx.doi.org/10.35596/1729-7648-2026-24-1-13-20>.

HYBRID DEEP LEARNING METHOD FOR SOLVING THE INVERSE PROBLEM OF HETEROGENEOUS SYSTEMS DETECTION USING MULTIDIMENSIONAL OPTICAL SENSOR DATA

IVAN SAETCHNIKOV, ELINA TCHERNIAVSKAIA, ANTON SAETCHNIKOV

Belarusian State University (Minsk, Republic of Belarus)

Abstract. Modern machine and deep learning methods effectively handle direct sensor data processing tasks and identify complex dependencies, ensuring robustness to noise and data variations. The most pressing problem is the synthesis of the results of processing multidimensional data using hybrid learning methods to solve inverse problems, such as determining the components of dynamically changing complex heterogeneous systems without violating their properties in multisensory measurement platforms. This paper presents a hybrid deep learning method integrated into an optical sensor platform that combines convolutional neural networks, bidirectional long short-term memory networks, and transformer encoders to enable dynamic monitoring of heterogeneous system components. The hybrid method, when applied to a biosensor platform, demonstrates classification accuracy of over 98 % by solution type and recovery of protein component concentration values with a median accuracy of up to 2 ng/ml.

Keywords: hybrid deep learning, inverse problem, multidimensional data, detection, optical sensor, dynamic monitoring.

Conflict of interests. The authors declare that there is no conflict of interests.

For citation. Saetchnikov I., Tcherniavskaia E., Saetchnikov A. (2026) Hybrid Deep Learning Method for Solving the Inverse Problem of Heterogeneous Systems Detection Using Multidimensional Optical Sensor Data. *Doklady BGUIR*. 24 (1), 13–20. <http://dx.doi.org/10.35596/1729-7648-2026-24-1-13-20> (in Russian).

Введение

Современные сенсорные технологии занимают фундаментальное место в процессах сбора данных для систем мониторинга, автоматизации и аналитики, охватывающих широкий спектр прикладных областей – от биомедицины [1] до роботизированных систем [2]. Интеграция методов машинного и глубокого обучения существенно повышает точность интерпретации сенсорных сигналов, способствует выявлению сложных паттернов в данных и обеспечивает устойчивость моделей к шумам и вариациям данных [3]. Современные архитектуры глубокого обучения, включая сверточные нейронные сети (СНС) и рекуррентные нейронные сети, демонстрируют высокую эффективность при анализе многомерных данных и временных рядов. [4] В частности, последние работы по данной тематике подтверждают успешное применение СНС для задач детектирования динамических объектов в системах компьютерного зрения, в том числе при обработке многомерных данных с мультиспектральных сенсоров [5]. По сравнению с первоначальными одностадийными методами глубокого обучения, решающими прямые задачи, комбинированные модели, включая гибридные архитектуры, объединяющие различные типы нейросетей и физически обоснованные модели, открывают новые возможности для решения сложных обратных задач в сенсорике. Одним из таких направлений являются оптические системы, основанные на резонансе мод шепчущей галереи (МШГ) [6–8], применяемые в биосенсорике. Здесь обратная задача заключается в определении характеристик биохимических растворов в многокомпонентных гетерогенных системах на основе анализа изменений спектрального сдвига МШГ, зарегистрированного сенсорной системой [9–13].

Особую актуальность представляют методы разработки подходов для определения параметров динамически изменяющихся комбинированных биохимических растворов без нарушения их свойств, реализуемые в мультисенсорных измерительных системах с использованием гибридного глубокого обучения. В статье рассматривается применение гибридного метода глубокого обучения к микрорезонаторному датчику, состоящему из более чем тысячи сферических микрополостей с выраженными спектральными вариациями, сгруппированных в одном чипе, состоящем из чувствительных областей (до десяти) с возможностью параллельного измерения.

При облучении сенсорной платформы лазером с фиксированной длиной волны обеспечивается одновременный сбор динамических откликов от различных групп микрополостей. С учетом спектральной изменчивости выполняется детектирование в реальном времени малых концентраций биохимических растворов гибридным методом глубокого обучения. Разработанный метод объединяет архитектуры СНС, двунаправленные сети долгой краткосрочной памяти (BiLSTM) и модули трансформерного энкодера для детектирования типов и прецизионных концентраций компонент. На примере задачи иммуноанализа показана точность классификации типов растворов на уровне 98 %, определена концентрация с медианной точностью до 2 нг/мл. Это подтверждает высокую эффективность предложенного метода.

Материалы и методика измерений

Оптический сенсор. В качестве сенсорного устройства, формирующего непрерывные потоки многомерных данных, выступает фотонный чип с интегрированными кластерами микрорезонаторов – микросферы размерами 90:120 мкм [14–16]. Выбранные структуры обеспечивают компромисс между сложностью изготовления, компактностью, стабильностью и добротностью резонансных мод. Для формирования фотонного чипа (10×10 мм) микросферы закреплялись на подложке с использованием тонкой плетки с низким показателем преломления. Методика изготовления обеспечивала возможность интеграции тысяч микросфер на единой стеклянной

подложке с обеспечением оптической добротности 10^6 . Кластер микрорезонаторов представляет собой изолированную на подложке группу микросфер со случайным расположением. Была выполнена интеграция до 16 отдельных кластеров в рамках одной подложки, где каждый содержал не менее 100 микрорезонаторов. Исходные кластеры использовались в качестве каналов регистрации объемных изменений физических параметров либо как контрольные каналы. Для обеспечения селективности регистрации растворы функциональных объектов наносили на кластеры микрорезонаторов. Функционализация включала несколько этапов очистки, активацию для формирования –ОН-функциональных групп и связывание с аминогруппами, где агентом был выбран (3-Аминопропил)триметоксисилан (APTMs). Таким образом, с учетом возможности интеграции множества кластеров, каналов при учете экспериментальных, технических повторений и временного фактора и в контексте масштабирования в статье апеллировано к многомерным данным.

Измерительный прибор. Одновременный сбор сигналов с тысяч микрорезонаторов осуществлялся с помощью схемы оптической связи затухающего поля с использованием призмы. Благодаря соотношению размеров призмы (~10 мм) и микрорезонатора (~100 мкм) данный подход обеспечивает масштабируемость. Пространственное разделение сигналов отдельных микрорезонаторов и их одновременная регистрация камерой позволяют выполнять параллельный сбор данных [17, 18]. Фотонный чип управлялся диодным лазером с длиной волны 685 нм и контролируемой линейной поляризацией. Регистрация сигналов осуществлялась как в режиме сканирования длины волны, так и при облучении на фиксированной длине волны. Интенсивность свечения каждого микрорезонатора измерялась монохромной камерой с частотой съемки до 500 кадров/с и глубиной цвета 12 бит. Записанные данные подвергались нормализации для компенсации вариаций внешнего освещения, при этом уровень шума при 12-битной разрядности оказался достаточным для отказа от дополнительного покадрового шумоподавления.

В качестве модельной среды выступали водные растворы с растворенными биохимическими объектами, которые непрерывно прокачивались через измерительный чип со скоростью 100 мкл/мин. Одна фаза измерений длилась 2000 с, в течение которых чип находился в идентичных биохимических условиях. Эксперимент мог включать множество фаз измерений (до 40) и длиться до 24 ч. При анализе сложных сред с растворенными биохимическими объектами необходимо производить регенерацию сенсорной поверхности после каждой фазы измерений. Щелочь гидроксида натрия (NaOH) была определена как наиболее эффективный раствор для регенерации функционализированных кластеров стеклянных микрорезонаторов.

Гибридный метод глубокого обучения

Использование аналитических моделей для идентификации типа и концентрации биохимических соединений в растворах оказалось затруднительным по нескольким причинам. Во-первых, такие модели плохо справляются с описанием сложных, коррелированных характеристик при анализе динамических процессов в сложных биохимических средах. Изучение многокомпонентных растворов, учет температурных нестабильностей, а также перспектива расширения спектра исследуемых объектов потребовали бы постоянного уточнения аналитической модели. Во-вторых, локальные возмущения и пропущенные данные вносят нестационарный шум, который значительно снижает точность интерпретации. Нелинейная природа откликов сенсоров тоже ограничивает масштабируемость таких моделей. В итоге это приводит к невозможности полноценного описания всех совокупностей процессов, происходящих в сложных системах в рамках единой аналитической модели. Поэтому для задачи анализа динамических компонент сложных биохимических растворов предлагается использование гибридных модульных методов глубокого обучения. Подобные методы обладают встроенной способностью к улучшению точности по мере накопления данных. Это делает их более надежным, гибким и масштабируемым решением для мультиплексного анализа биохимических систем.

Предлагаемый гибридный метод решает задачу мультиплексного анализа сложных биологических растворов за счет сочетания классификатора для определения типа раствора и регрессионной модели для оценки отдельных концентраций. В качестве классификатора использовалась комбинированная архитектура, объединявшая сверточные слои CNN и BiLSTM. А именно,

метод включал два последовательных одномерных сверточных модуля с 16 и 32 фильтрами, при этом размер ядра уменьшался с 5 до 3 с сохранением размерности. Каждый сверточный блок дополнялся активационной функцией LeakyReLU, пакетной нормализацией и слоем dropout с вероятностью 0,3 для предотвращения переобучения. Выделенные признаки затем подавались на слой BiLSTM с 32 скрытыми блоками, за которым следовали дополнительный слой dropout (0,3) и финальный выход классификатора. Такой подход к построению модели позволял на первом этапе эффективно выделять локальные пространственные зависимости и фильтровать шум с помощью сверточных операций, а на втором – изучать сложные временные взаимосвязи в обоих направлениях благодаря BiLSTM.

Регрессионная часть метода базировалась на блоках трансформерных энкодеров. Входные отклики каналов сначала проходили через блоки проекции и позиционного кодирования, через модуль кросс-модального внимания, после чего применялась серия блоков трансформерных энкодеров. Проекционный слой выполнял преобразование входных данных в 16-мерное пространство, а позиционное кодирование создавало уникальные 16-мерные векторные представления для каждой временной позиции поканально. Результаты проекции и позиционного кодирования объединялись в модуле внимания с двумя головами для обработки как внутриканальных, так и межканальных корреляционных зависимостей. Сформированные признаки проходили через три последовательных блока трансформера-кодера, каждый из которых содержал модуль внимания с четырьмя головами, двухслойную сеть с активацией GELU и dropout, а также слой нормализации. Между блоками применялись пакетная нормализация и активация LeakyReLU, а также пулинг с ядром размером 2, уменьшающий длину последовательностей. В свою очередь, категориальные выходы классификационной части метода проходили через два линейных слоя размерами 16 и 32, сопровождаемые BatchNorm, LeakyReLU и dropout (0,1). Впоследствии извлеченные признаки из каналов и категориальные объединялись и обрабатывались двумя полносвязными слоями (в дополнение к BatchNorm, LeakyReLU и dropout).

Спрогнозированные результаты концентраций вышеописанного гибридного метода сравнивались с регрессором на базе исключительно блоков СНС. Регрессор на основе СНС состоял из трех модулей СНС с 32, 64 и 128 фильтрами (размеры ядер 5, 5 и 3), за каждым из которых следовали слои BatchNorm, LeakyReLU и MaxPooling, и завершался глобальным усреднением пулинга.

Предложенный гибридный метод обучался и тестировался на базе платформы 14-ядерного процессора Intel Xeon W-2275 и 128 ГБ оперативной памяти и графического процессора NVIDIA Quadro RTX 6000 с 24 ГБ видеопамати. В качестве программных сред разработки применялись Python и CUDA для поддержки вычислений на GPU с фреймворком глубокого обучения PyTorch.

Результаты исследований и анализ многомерных данных

Различия в положении, размерах и локальные неоднородности отдельных микрорезонаторов в кластере приводят к разбросу в динамике их откликов на процессы осаждения биохимических объектов. С использованием откликов микрорезонаторов в качестве признаков для метода главных компонент может быть определен обобщенный отклик кластеров в пространстве адаптированных признаков (АП1) [13, 14]. Однако для корректного многоканального анализа необходимо также обеспечение согласованности сигналов различных кластеров. Данный вопрос исследовался на примере детектирования альбумина (BSA – bovine serum albumin), разведенного в фосфатном буферном растворе (PBS – phosphate buffer solution), с концентрациями от 0,02 до 0,10 %. Измерения проводились двумя функционализированными кластерами, интегрированными на одном чипе, где между циклами измерений выполнялась регенерация кластера.

Приведенные на рис. 1 результаты экспериментальных измерений указывают на высокую степень согласованности обобщенных спектральных откликов для всех стационарных состояний. На рис. 1, а показана согласованность откликов в воде (0), фосфатном буфере PBS (1), в регенерирующем растворе NaOH (2) и в растворе альбумина BSA (для 0,02 % (3), 0,06 % (4) и 0,10 % (5)). Это подтверждает воспроизводимость, а также корректность процедур измерений и адаптации доменов кластеров.

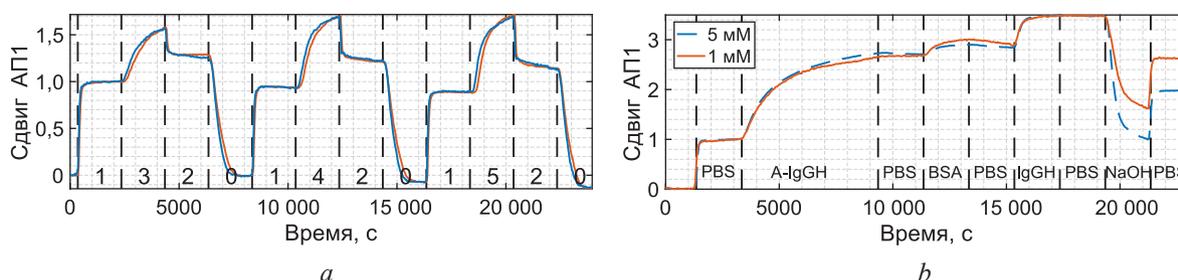


Рис. 1. Полученные результаты: *a* – согласованности откликов в воде (0), в PBS (1), NaOH (2) и в BSA (для 0,02 % (3), 0,06 % (4), 0,10 % (5)); *b* – влияния концентрации регенерационного раствора (1 и 5 мМ NaOH) на определение человеческого иммуноглобулина (IgGH)
Fig. 1. The obtained results: *a* – consistency of responses in water (0), in PBS (1), NaOH (2) and in BSA (for 0.02 % (3), 0.06 % (4), 0.10 % (5)); *b* – the effect of the concentration of the regeneration solution (1 and 5 mM NaOH) on the determination of human immunoglobulin (IgGH)

Динамические отклики при различных концентрациях альбумина согласуются с аналитической моделью осаждения малых молекул, а незначительное (<5 %) уменьшение уровня воды для обоих кластеров в течение 24 000 с связано с температурным фактором. Постоянная разница во времени начала отклика между кластерами в 60 с связана с их различным положением на чипе, где для одного наблюдается ускорение процесса осаждения. Для всех измеренных концентраций различие в величине обобщенного отклика по прошествии 2000 с между кластерами не превышало уровень шума. Таким образом, подтверждена согласованность результатов измерений, полученных с использованием гетерогенных кластеров, что обеспечивает возможность формирования масштабируемых и разнообразных наборов данных с учетом вариативности различных кластерных конфигураций.

Применение кластерной архитектуры позволяет в рамках единого чипа выполнять отдельный анализ множества физических, биохимических реакций, а также неспецифических объемных характеристик, без привлечения внешних эталонных приборов. В качестве характерной и методологически показательной задачи многопараметрического детектирования был выбран иммуноанализ. Исследовали возможность детектирования двух типов иммуноглобулина G, взятого из кроличьей (IgGR) и человеческой (IgGH) сыворотки. Подходящий для данной задачи чип содержал как минимум два кластера. Они были функционализированы комплементарными молекулами (A-IgGR и A-IgGH), которые избирательно взаимодействовали с IgGR и IgGH. Результаты измерений откликов кластеров микрорезонаторов в процессе функционализации, формирования связки A-IgG-IgG и регенерации сенсора для удаления осажденных биохимических объектов представлены на рис. 1, *b*.

Функционализация в течение 4000 с не приводит к достижению уровня насыщения для обобщенного сдвига, где при дальнейшей прокачке 5 мкг/мл IgGH наблюдается схожая динамика (рис. 1, *b*). Полученный результат указывает на присутствие свободных аминогрупп после выполнения функционализации. Регенерация чипа раствором 5 мМ NaOH показала снижение уровня сигнала базового раствора относительно уровня, достигнутого при функционализации, что связано с частичным разрушением функционального слоя. На основании данных результатов предложено увеличить длительность функционализации до 6000 с. Также введена процедура блокировки аминогрупп 0,01%-ным раствором альбумина для связывания со свободными аминогруппами (рис. 1, *b*).

В процессе функционализации достигается стационарное состояние, а в ходе прокачки альбумина регистрируется малый сдвиг, что указывает на его связывание с остаточными аминогруппами. При прокачке 5 мкг/мл IgGH наблюдался динамичный отклик, который достигал уровня насыщения в течение 2000 с и характеризовался многократным ростом кинетического коэффициента связывания по сравнению с ранее полученными результатами. Регенерация 5 мМ NaOH приводит к частичному разрушению функционального слоя. Однако при уменьшении концентрации до 1 мМ достигается восстанавливаемость сигнала в базовой среде. Данная последовательность фаз масштабировалась для других концентраций и типов иммуноглобулинов, что позволило сформировать согласованный набор измерений для растворов IgGR и IgGH с концентрациями в диапазоне 0,1–5,0 мкг/мл.

Набор измеренных данных состоял из более 200 тыс. наблюдений, включая технические повторения, для которых определялись три класса (IgGH, IgGR и Mix). В ходе экспериментов установлено, что классификационные модели с более глубокими сверточными слоями, а также с добавлением дополнительных сверточных слоев или BiLSTM, делали модель более чувствительной к выбору фрагмента для валидации, в конечном счете не улучшая итоговую точность. Особенно это проявлялось при ограничении временного диапазона обработки, когда фиксировалось переобучение. Также отмечалась чувствительность классификационного метода к уровню регуляризации, заданному через слой dropout. Исходя из заранее принятой стратегии в рамках гибридного метода, для обучения и тестирования использовалась легковесная модель. Результаты классификации типов биохимических растворов показали возможность обеспечения точности более 99 %, что приводит к пренебрежимо малой вероятности переноса ошибки на следующую фазу регрессии. Наименьшая точность (98 %) выявлена для смешанных растворов, что в первую очередь связано с ограниченностью повторений всех возможных комбинаций смесей. Матрица точности для классификационного модуля гибридного метода глубокого обучения приведена в табл. 1.

Таблица 1. Матрица точности для классификационного модуля гибридного метода глубокого обучения
Table 1. Confusion matrix for the classification module of the hybrid deep learning method

Целевой класс	IgGH	98,90	0	1,10
	IgGR	0	99,99	0,01
	Mix	1,41	0,01	98,58
	IgGH		IgGR	Mix
	Предсказанный класс			

В рамках задачи определения концентрации биохимических компонент в растворах было установлено шесть ее уровней: 0,1, 0,2, 0,5, 1, 2 и 5 мкг/мл. Модель обучалась и подтверждалась с использованием адаптивной k -блочной кросс-валидации. В рассматриваемом случае из-за добавления технических повторений были ограничения как в выборе количества k -блоков, так и в возможности перемешивания наблюдений. Поэтому количество блоков жестко привязывалось к числу фаз наблюдений со всеми техническими повторениями. Тестирование модели по каждой фазе, с одной стороны, предотвращало риск утечки данных из обучения в тест, но с другой – результаты валидации были более зависимы от рассматриваемой фазы в рамках блока. Каждая фаза измерений вместе с техническими повторениями рассматривалась как отдельный блок, а все остальные фазы использовались в качестве обучающей выборки. Стратегия обучения предполагала продолжение обучения до тех пор, пока в течение последних 50 эпох не прекращалось улучшение точности. Флуктуации на наблюдаемом валидационном наборе были связаны с некоторым смещением, заложенным в принятой стратегии кросс-валидации и вызванным спецификой обрабатываемых данных.

Предложенный гибридный метод эффективно анализирует коррелированные отклики с кластеров микрорезонаторов, а также учитывает флуктуации внешних параметров в мультиплексном биохимическом анализе, основанном на концепции решения обратной задачи определения концентрации компонент растворов. Модель полностью исключает ошибки определения уровня концентрации при временной выборке динамических откликов менее 5 мин. При этом сеть на основе гибридного метода глубокого обучения показала медианную точность определения концентрации 2 нг/мл для всей совокупности измеренных экспериментальных данных. Таким образом, точность гибридного метода глубокого обучения ограничена фундаментальным пределом детектирования оптического сенсора.

Заключение

1. Представлен гибридный метод глубокого обучения для решения обратной задачи детектирования типа и концентрации компонентов биохимического раствора. Данный метод, интегрированный в биосенсорную систему с более чем тысячей микрополостей, сгруппированных

в чувствительные области на едином чипе, позволяет выполнять высокопроизводительный мультиплексный оптический биосенсорный анализ. Гибридный метод сочетает модули сверточных нейронных сетей, двунаправленные сети долгой краткосрочной памяти и трансформерные энкодеры, таким образом обеспечивая динамический мониторинг сложных комбинированных растворов.

2. В ходе многочисленных циклов зондирования предлагаемый метод на примере многокомпонентной гетерогенной системы из девяти чипов продемонстрировал определение классификационного типа биохимического соединения с точностью более 98 % и концентрации с медианной точностью до 2 нг/мл. Модульность структуры гибридного метода глубокого обучения обеспечивает возможность масштабирования решения на другие типы компонентов биохимических растворов, которые могут быть использованы в режиме реального времени.

Список литературы / References

1. Zou H., Zhou Z., Huang M., Li W., Yang M., Zhao X., et al. (2025) NFC/RFID-Enabled Wearables and Implants for Biomedical Applications. *Microsystems & Nanoengineering*. 11. <https://doi.org/10.1038/s41378-025-01010-5>.
2. Pfeiffer M., Schaeuble M., Nieto J., Siegart R., Cadena C. (2017) From Perception to Decision: A Data-Driven Approach to End-to-End Motion Planning for Autonomous Ground Robots. *IEEE International Conference on Robotics and Automation*. DOI: 10.1109/ICRA.2017.7989182. 1527–1533.
3. Han Gr., Goncharov A., Eryilmaz M., Ye S., Palanisamy B., Ghosh R., et al. (2025) Machine Learning in Point-of-Care Testing: Innovations, Challenges, and Opportunities. *Nature Communications*. 16. <https://doi.org/10.1038/s41467-025-58527-6>.
4. Fei N., Lu Z., Gao Y., Yang G., Huo Y., Wen J., et al. (2022) Towards Artificial General Intelligence Via a Multimodal Foundation Model. *Nature Communications*. 13. <https://doi.org/10.1038/s41467-022-30761-2/>.
5. Saetchnikov I., Tcherniavskaia E., Skakun V. (2021) Object Detection for Unmanned Aerial Vehicle Camera Via Convolutional Neural Networks. *IEEE Journal on Miniaturization for Air and Space Systems*. 2 (2), 98–103. DOI: 10.1109/JMASS.2020.3040976.
6. Vollmer F., Arnold S. (2008) Whispering-Gallery-Mode Biosensing: Label-Free Detection Down to Single Molecules. *Nature Methods*. 5 (7), 591–596.
7. Foreman M. R., Swaim J. D., Vollmer F. (2015) Whispering Gallery Mode Sensors. *Advances in Optics and Photonics*. 7 (2), 168–240.
8. Jiang X., Qavi A. J., Huang S. H., Yang L. (2020) Whispering-Gallery Sensors. *Matter*. 3 (2), 371–392.
9. Arnold S., Khoshima M., Teraoka I., Holler S., Vollmer F. (2003) Shift of Whispering-Gallery Modes in Microspheres by Protein Adsorption. *Optics Letters*. 28 (4), 272–274.
10. Baaske M. D., Foreman M. R., Vollmer F. (2014) Single-Molecule Nucleic Acid Interactions Monitored on a Label-Free Microcavity Biosensor Platform. *Nature Nanotechnology*. 9 (11), 933–939.
11. Liao J., Yang L. (2021) Optical Whispering-Gallery Mode Barcodes for High-Precision and Wide-Range Temperature Measurements. *Light: Science & Applications*. 10.
12. Bianchetti A., Federico A., Vincent S., Subramanian S., Vollmer F. (2017) Refractometry-Based Air Pressure Sensing Using Glass Microspheres as High-Q Whispering-Gallery Mode Microresonators. *Optics Communications*. 394, 152–156.
13. Eryürek M., Tasdemir Z., Karadag Y., Anand S., Kilinc N., Alaca B. E., et al. (2017) Integrated Humidity Sensor Based on SU-8 Polymer Microdisk Microresonator. *Sensors and Actuators B: Chemical*. 242 (10), 1115–1120.
14. Saetchnikov A., Tcherniavskaia E., Saetchnikov V., Ostendorf A. (2020) Deep-Learning Powered Whispering Gallery Mode Sensor Based on Multiplexed Imaging at Fixed Frequency. *Opto-Electronic Advances*. 3 (11).
15. Saetchnikov A., Tcherniavskaia E., Saetchnikov V., Ostendorf A. (2021) Intelligent Optical Microresonator Imaging Sensor for Early Stage Classification of Dynamical Variations. *Advanced Photonics Research*. 7.
16. Saetchnikov I., Tcherniavskaia E., Ostendorf A., Saetchnikov A. (2024) Induced Eccentricity Splitting in Disordered Optical Microspheres for Machine Learning Enabled Wavemeter. *Arxiv 2412.08339*.
17. Saetchnikov A., Tcherniavskaia E., Saetchnikov V., Ostendorf A. (2023) Detection of Per- and Polyfluoroalkyl Water Contaminants with a Multiplexed 4D Microcavities Sensor. *Photonics Research*. 11.
18. Saetchnikov A., Tcherniavskaia E., Saetchnikov V., Ostendorf A. (2024) Two-Photon Polymerization of Optical Microresonators for Precise pH Sensing. *Light: Advanced Manufacturing*. 5.

Поступила 12.12.2025

Принята в печать 20.01.2026

Received: 12 December 2025

Accepted: 20 January 2026

Вклад авторов

Саечников И. В. разработал и реализовал гибридный метод глубокого обучения, провел анализ многомерных результатов с оптических сенсоров.

Чернявская Э. А. выполнила теоретический анализ.

Саечников А. В. разработал и реализовал концепцию модульной сенсорной платформы на основе кластеров оптических микрорезонаторов.

Authors' contribution

Saetchnikov I. developed and implemented a hybrid deep learning method and conducted an analysis of multidimensional results from optical sensors.

Tcherniavskaia E. performed the theoretical analysis.

Saetchnikov A. developed and implemented the concept of a modular sensor platform based on clusters of optical microresonators.

Сведения об авторах

Саечников И. В., ст. преп., Белорусский государственный университет (БГУ)

Чернявская Э. А., д-р физ.-мат. наук, проф., БГУ

Саечников А. В., канд. физ.-мат. наук, науч. сотр., БГУ

Адрес для корреспонденции

220064, Республика Беларусь,
Минск, ул. Курчатова, 1
Белорусский государственный университет
Тел.: +375 17 398-70-42
E-mail: saetchnikovivan@gmail.com
Саечников Иван Владимирович

Information about the authors

Saetchnikov I., Senior Lecturer, Belarusian State University (BSU)

Tcherniavskaia E., Dr. Sci. (Phys. and Math.), Professor, BSU

Saetchnikov A., Cand. Sci. (Phys. and Math.), Researcher, BSU

Address for correspondence

220064, Republic of Belarus,
Minsk, Kurchatova St., 1
Belarusian State University
Tel.: +375 17 398-70-42
E-mail: saetchnikovivan@gmail.com
Saetchnikov Ivan