

Научная статья  
УДК 004.8  
EDN MDTJBC  
DOI 10.17150/2713-1734.2023.5(3).239-250



П.А. Головинский

*Воронежский государственный технический университет,  
г. Воронеж, Российская Федерация*

### **Дорожная карта реализации оптических машин экстремального обучения**

**Аннотация.** Обсуждаются принципы машинного обучения с точки зрения нелинейных отображений и смешения сигналов. Дана характеристика возможностей алгоритмических резервуарных компьютеров, основанных на программной реализации искусственных нейронов со случайными весами входных сигналов, и физических резервуарных компьютеров, использующих различные случайные и нелинейные явления. Изложены основные элементы концепции машин экстремального обучения, описаны их особенности и алгоритм обучения линейного выхода с гребенчатой регуляризацией методом псевдообратных матриц Мура-Пенроуза. Отмечено распределение оптических резервуарных компьютеров по видам и пространственным масштабам используемых физических процессов. В качестве перспективного направления реализации выделены оптические машины экстремального обучения (OELM). Описана структура дифракционной OELM, ее принцип действия, использующий рассеяние на случайных элементах, и присущие ей ограничения. Предложено использование плазмонных металлических наноструктур для снижения размеров оптических резервуарных процессоров. Для реализации квантовой версии OELM, обрабатывающей сигналы с частотной модуляцией, сформулирован новый подход к процессорам, работающим на системах искусственных атомов со случайными взаимодействиями. Возбуждение и считывание сигналов предлагается осуществлять с помощью трехимпульсной фемтосекундной спектроскопии возбуждения с зондированием. Отмечается необходимость низкого уровня релаксации за такт процессора для устойчивой работы схемы. В качестве фундаментального квантового предела процессора обсуждается отдельный атом, генерирующий высокие гармоники в сильном лазерном поле, и описан физический механизм, обеспечивающий этот эффект. Для каждого из трех вариантов OELM сформулированы критически важные задачи, последовательное решение которых позволит существенно приблизить создание технологически значимых OELM.

**Ключевые слова.** Машина экстремального обучения, оптический процессор, рассеяние света, шероховатая поверхность, квантовая система, искусственные атомы, случайный спектр, спектроскопия возбуждения с зондированием, генерация высоких гармоник.

**Информация о статье.** Дата поступления: 30 апреля 2023 г.; дата принятия к публикации: 19 июня 2023 г.; дата онлайн-размещения: 28 сентября 2023 г.

P.A. Golovinsky  
Voronezh State Technical University,  
Voronezh, Russian Federation

## Roadmap for Implementation Optical Extreme Learning Machines

**Abstract.** The principles of machine learning are discussed in terms of non-linear mappings and signal mixing. We considered the characteristics of the capabilities of algorithmic reservoir computers based on the software implementation of artificial neurons with random weights of input signals, and physical reservoir computers using various random and non-linear phenomena. The main elements of the concept of extremal learning machines are outlined, their features and the algorithm for learning a linear output with comb regularization by the method of pseudo-inverse Moore-Penrose matrices are described. The study found the subdivision of optical reservoir computers by types and spatial scales of the physical processes used. Optical Extreme Learning Machines (OELM) are identified as a promising area of implementation. The structure of the diffractive OELM, its principle of operation based on the scattering by random elements, and its inherent limitations are described. The use of plasmonic metal nanostructures to reduce the size of such processors is proposed. To implement the quantum version of the OELM signal with frequency modulation, a new approach to processors operating on systems of artificial atoms with random interactions has been formulated. The study proposed to incite and read signals using the methods of three-pulse femtosecond pump-probe spectroscopy. The need for a low level of relaxation during the processor cycle is noted for stable operation of the circuit. The study discussed an individual atom generating high harmonics in a strong laser field as the fundamental quantum limit of the processor, and described the physical mechanism providing this effect. For each of the three OELM options, critically important tasks are formulated, the consistent solution of which will significantly bring the creation of technologically significant OELM closer.

**Keywords.** Extreme learning machine, optical processor, light scattering, rough surface, quantum system, artificial atoms, random spectrum, pump-probe spectroscopy, high harmonic generation.

**Article info.** Received 30 April 2023; Accepted 19 June, 2023; Available online 28 September, 2023.

## Введение

Впечатляющие достижения в области применения искусственного интеллекта (AI) за последнее десятилетие напрямую связаны с бурным прогрессом технологий машинного обучения. Машинное обучение представляет собой совокупность методов и алгоритмов обучения многопараметрических математических моделей на основе данных. В результате процедуры обучения устанавливается связь между моделируемыми данными, которая для других наборов данных может оказаться совершенно иной. Тем самым, машинное обучение кардинально отличается от обычных алгоритмических программ, в которых логика и последовательность работы с данными прописывается в программном коде в

виде набора неизменяемых инструкций. Наиболее значительные достижения машинного обучения связаны с глубоким обучением многослойных искусственных нейронных сетей (ANN) [1], которые позволили реализовать целый ряд интеллектуальных функций, и создать, в частности, системы распознавания образов, переводчики в режиме реального времени и человекоподобные голосовые роботы. Характерной чертой наиболее успешных проектов AI стало использование сверточных и рекуррентных ANN с миллионами настраиваемых параметров с их обучением методом обратного распространения ошибки на больших базах размеченных данных.

Имея очевидные достижения, технологии AI породили новые сложные проблемы, решение которых в настоящее время далеко не очевидно. Часть возникших вопросов связана с тем, что обучение на примерах больших данных не предполагает наличие у систем AI каких-либо базовых ограничителей, которые для человека имеют вид традиций, морали, совести или закона. Разрешение этих трудностей представляется уже сейчас исключительно актуальной задачей, но серьезная общественная и научная дискуссия по этому поводу только начинается. Более техническим по своей природе препятствием является ограниченная доступность ресурсов AI, которые в настоящее время сосредоточены в руках нескольких крупнейших IT компаний, обладающих необходимыми базами данных, технологиями машинного обучения и мощностями суперкомпьютеров для обеспечения настройки крупномасштабных моделей. Решение проблемы доступности позволило бы исключить монополизацию рынка технологий AI, которая потенциально губительна для интересов общества. На этом пути, радикальное удешевление используемых решений и аппаратной реализации машинного обучения позволит резко расширить объемы и сферы применения AI. Для увеличения производительности компьютерных систем происходит неуклонный переход на нанoeлектронные и нанoфотонные чипы, но, несмотря на достигнутые результаты, создание недорогих и высокопроизводительных нейроморфных процессоров для обеспечения повсеместного AI остается актуальной потребностью [2].

Заманчиво найти решение, существенно упрощающее алгоритм обучения, повышающее быстродействие процессора и, в то же время, не требующее создания и освоения принципиально новых и сложных технологических схем. В данной работе мы анализируем в таком качестве возможности резервуарных вычислений и показываем пути реализации линейки оптических процессоров разных пространственных масштабов в рамках экстремального подхода к машинному обучению. Статья не является обзорной и не претендует на отражение истории, приоритетов в исследованиях резервуарных вычислений или исчерпывающий список литературных источников.

### Резервуарные компьютеры

Компьютерные эксперименты демонстрируют, что при случайной инициализации полносвязной рекуррентной ANN может достигаться эффект достаточного обучения за счет настройки лишь одного выходного линейного слоя [3]. При этом сама ANN должна удовлетворять двум основным условиям. Первое условие состоит в том, чтобы отображение было нелинейным и производилось вблизи границы области устойчивости системы. Второе условие заключается в том, что после завершения такта вычислений система должна возвращаться в исходное состояние для воспроизводимости всего вычислительного процесса. Такая сеть имеет случайные и фиксированные веса нейронов, а сам подход называется резервуарными вычислениями (RC), поскольку имеет необучаемую часть, функционирующую согласно собственным внутренним законам, в то время как обучению подлежит только линейный выходной слой, считывающий значения параметров внутреннего состояния системы. Тем самым, в RC вся сложность машинного обучения сводится к решению линейной задачи оптимизации выходных значений по отношению к обучающим данным. Первоначально RC были предложены в виде нейронных сетей с эхо-состояниями и машин жидкого состояния, генерирующих стохастические отображения [4; 5].

Объединение и развитие этих подходов привело к пониманию того, что в качестве резервуара вычислений могут использоваться самые разнообразные математические и физические системы, обеспечивающие необходимые нелинейные преобразования [6]. Использование идеи последовательной обработки сигналов позволило реализовать RC на одном физическом нелинейном элементе с замкнутой петлей задержки и набором промежуточных узлов, что показало возможность минимизации архитектуры RC. Другим существенным шагом стало использование нескольких последовательных процессоров для обучения на сложных данных, когда одного RC оказывается недостаточно. Поскольку в качестве физических RC могут выступать механические, электрические, гидродинамические, оптические и другие системы [7], то большой практический интерес представляет использование в качестве резервуаров вычислений разнообразных технических устройств и сенсоров для управления системами конечного пользователя в энергетических и информационных сетях, а также для других случаев автоматического управления удаленными объектами, например, роботами [8; 9].

### Машины экстремального обучения

Фундаментальная теорема Колмогорова-Арнольда показывает принципиальную возможность представления произвольного отображения многих переменных с помощью двухслойной ANN

прямого распространения с линейным выходным слоем [10], что породило идею сократить требуемую сложность резервуара до одного скрытого слоя нейронов со случайными весами. В такой сети каждый из нейронов осуществляет нелинейное преобразование скалярного произведения входных данных со случайно назначенными и не обновляемыми весами, а выходной сигнал является настраиваемой линейной комбинацией откликов всех нейронов. Несмотря на предельную простоту такой модели, оказалось, что она является универсальным компьютером, в результате чего нейросеть с подобной структурой получила название машины экстремального обучения (ELM) [11]. Линейный выход обеспечивается отображением матрицы сигналов нейронов  $\mathbf{x}$  в матрицу выходных сигналов  $\mathbf{y}$  с помощью настраиваемой матрицы  $\mathbf{R}$ . Обучение с гребневой регуляризацией для поиска оптимальной матрицы  $\mathbf{R}$  означает минимизацию функционала

$$J = \|\mathbf{y} - \mathbf{x}\mathbf{R}\|^2 + \lambda \|\mathbf{R}\|^2 \quad (1)$$

на множестве обучающих данных, а  $\lambda$  является гиперпараметром регуляризации. Требуемая минимизация  $J$  достигается применением к линейной задаче определения матрицы  $\mathbf{R}$  псевдообратных матриц Мура-Пенроуза [12] в виде

$$\mathbf{R} = (\mathbf{x}^T \mathbf{x} + \lambda \mathbf{I})^{-1} \mathbf{x}^T \mathbf{y}. \quad (2)$$

Как и в общей картине RC для ELM существуют многочисленные возможности физической реализации. С точки зрения быстродействия и минимальных потерь энергии в процессе обработки сигналов особый интерес представляют оптические машины экстремального обучения (OELM), использующие в качестве сигнала оптическое излучение [13]. Важно отметить, что если для производства стандартных оптических процессоров требуется высокая точность изготовления всех элементов, то случайный разброс параметров структур процессоров для OELM не только не является существенным, но становится необходимым условием их успешной работы.

### **Вычисления на основе рассеяния случайными структурами**

Если использовать для ELM пространственное кодирование оптического излучения, то входная и выходная информация будет иметь вид 2D полей с комплексными значениями, несущими в себе информацию о локальной амплитуде и фазе сигнала. Это фактически означает голографическое представление данных, независимо от их исходной природы. Преимущества такого представления наиболее ощутимы при обработке когерентных сигналов в оптическом и радио диапазоне [14]. Соответствующая OELM оперирует комплексными величинами.

Для образования скалярного произведения исходного оптического сигнала с некоторыми случайными весами можно воспользоваться плоским амплитудно-фазовым модулятором [15]. Если матрица распределения исходного поля  $E(a, b)$  по поверхности  $a$ ,  $b$  модулируется случайным комплексным множителем  $M(a, b)$ , то при дифракции в параллельных лучах поле в дальней зоне определяется преобразованием Фурье произведения  $E(a, b)M(a, b)$ . Поскольку преобразование Фурье произведения эквивалентно свертке спектров сомножителей, то дифракция Фраунгофера обеспечивает первую часть процедуры EML в виде скалярного произведения спектра матрицы входных значений на случайную фиксированную матрицу. Так реализуется случайное смешивание оптических сигналов. В качестве простейшей нелинейности на выходе может быть взята квадратичная по амплитуде нелинейность фотодетектора, регистрирующего интенсивность оптического излучения.

В роли случайного модулятора целесообразно применять стационарные рассеивающие поверхности с подходящими случайными шероховатостями, а также различные случайно неоднородные среды, в том числе специально подготовленные оптические волокна [16; 17]. Ограничения подобного дифракционного подхода к OEML связаны с необходимостью использовать устройства с размерами существенно больше длины волны оптического излучения. Возможности нанوفотоники [18] позволяют преодолеть указанный дифракционный предел, поскольку наноплазмонные резонаторы в виде металлических частиц обеспечивают локализацию электромагнитного поля на нанометровых масштабах. Однако и в этом случае остаются определенные трудности, связанные с вводом и выводом информации в массивы плазмонных наночастиц, что предполагает обеспечение нанофокусировки пространственно модулированного сигнала.

### **Квантовые резервуары экстремального обучения**

Несмотря на впечатляющие возможности нанوفотоники по уменьшению размеров оптических процессоров различной архитектуры, дальнейшая миниатюаризация OEML может быть достигнута только за счет перехода от пространственной модуляции сигнала к его частотному кодированию. В таком случае, для смешения сигналов становится возможным использовать квантовые системы, обладающие случайными волновыми функциями и случайным дискретным спектром [19; 20]. В качестве подходящей квантовой системы можно использовать массив искусственных атомов, взаимодействующих между собой случайным образом. Воздействие на такую систему спектрально модулированным фемтосекундным оптическим импульсом, являющимся носителем информации и накрывающим энергетический спектр группы случайных резонансных уровней,



приведет к образованию волнового пакета возбужденных состояний. Формируемые в слабом поле амплитуды отдельных стационарных состояний в таком волновом пакете будут пропорциональны спектральным значениям входного сигнала со случайными весами, обусловленными структурой квантовой системы.

Для полной реализации схемы случайного смещения сигналов и их измерения можно воспользоваться методом спектроскопии возбуждения с зондированием [21]. В рамках квантового подхода к ОЕЛМ для этого следует произвести дополнительное нерезонансное импульсное перемешивание уровней волнового пакета за счет динамического эффекта Штарка, что осуществимо, когда спектральная ширина второго уже нерезонансного лазерного импульса вновь перекрывает спектр перемешиваемых уровней. Волновой пакет  $\Psi(t)$ , описывающий квантовую систему после ее возбуждения и перемешивания состояний, может быть представлен в виде суперпозиции основного состояния  $|0\rangle$  с нулевой энергией и возбужденных состояний  $|n\rangle$  зоны случайных уровней с энергиями  $\omega_n$ :

$$\Psi(t) = \sum_{n=0}^N a_n(t) \exp(-i\omega_n t) |n\rangle. \quad (3)$$

Последующее детектирование отображения компонент входного сигнала в амплитуды квантовых состояний можно осуществить по регистрации поглощения слабого пробного импульса. Нестационарный дипольный момент системы

$$z(t) = \langle \Psi(t) | z | \Psi(t) \rangle, \quad (4)$$

определяет поглощение энергии за импульс поля  $F_p(t)$  через его спектр  $\tilde{F}_p(\omega)$  в виде [22]

$$\begin{aligned} \Delta E &= \int_{-\infty}^{\infty} z(t) \frac{\partial F_p(t)}{\partial t} dt = 2\pi \int_{-\infty}^{\infty} i\omega \tilde{z}(\omega) \tilde{F}_p^*(\omega) d\omega = \\ &= \int_0^{\infty} \omega S(\omega) d\omega. \end{aligned} \quad (5)$$

с помощью спектральной функции отклика

$$S(\omega) = -4\pi \text{Im} [\tilde{z}(\omega) \tilde{F}_p^*(\omega)]. \quad (6)$$

Функция  $S(\omega)$  определяет вероятность поглощения излучения на единичный интервал частоты  $\omega$ , а  $\tilde{z}(\omega)$  представляет собой спектр дипольного момента системы.

Предлагаемая нами трехимпульсная схема работы квантовой OEML позволяет использовать в качестве субстрата физического резервуара, в частности, полупроводниковые квантовые точки, близко расположенные случайным образом на поверхности прозрачного диэлектрика. Необходимым условием для ее применения является короткая длительность возбуждающих и зондирующих лазерных импульсов на фоне релаксации физической системы.

### Одноатомные процессоры

Идея использовать квантовую систему для случайного смешивания спектральных компонент сигнала может быть реализована с помощью различных нелинейно-оптических явлений. Одним из наиболее ярких проявлений нелинейности является генерация высоких гармоник (ННГ) излучения на одиночном атоме. Сам процесс генерации гармоник носит трехступенчатый характер [23]. На первом этапе происходит нелинейная ионизация атома с образованием активного свободного электрона в непрерывном спектре. Далее оторвавшийся от атома электрон совершает колебание во внешнем лазерном поле и возвращается к родительскому атому со значительной набранной энергией. На третьем этапе электрон излучает фотон и рекомбинирует в исходное связанное состояние. Таким образом, возникают фотоны с частотами, кратными частоте падающего на атом лазерного излучения. Для осуществления OEML на механизме ННГ было предложено использовать частотное кодирование информации [24]. При этом возбуждающее поле представляет собой сумму частотно модулированного сигнала и добавочного поля, обеспечивающего высокую степень нелинейности процесса. Измеряемые интенсивности отдельных гармоник служат вектором выходных параметров обучаемого линейного интерфейса. Приведенная в работе [24] иллюстрация метода, использовала одномерную модель ННГ и решала простейшую задачу классификации трех классов объектов. Однако сам подход представляет фундаментальный интерес с точки зрения его реализации на реальных атомах и применения к более сложным задачам машинного обучения.

### Заключение

Мы рассмотрели три направления реализации OEML, действующих на различных масштабах и физических принципах. Первый вид OEML относится к классическим устройствам с пространственным кодированием сигнала. Для их разработки главным является оптимальный выбор рассеивающей среды и ее параметров. Перспективным представляется использование для этого в качестве микро-неоднородностей плазмонных наночастиц. Второе направление реализует частотное кодирование сигнала и опира-



ется на технологию фемтосекундного оптического возбуждения с зондированием массивов искусственных атомов, обладающих случайным спектром. Этот новый предложенный нами квантовый подход позволяет избежать проблем больших размеров процессоров, характерных для дифракционных OELM. Третий вид OELM реализуется на отдельных атомах за счет нелинейного преобразования исходного сигнала в высокие гармоники, что обеспечивает его отображение в пространство более высокой размерности. Одноатомный процессор представляет принципиальный интерес с точки зрения получения максимального быстродействия при минимальных размерах OELM.

Отметим задачи, стоящие на пути дальнейшего развития каждого из этих направлений. В реализациях, основанных на рассеянии в случайных средах, предстоит как поиск оптимальных систем и определение их параметров, так и применение готовых природных или технологических рассеивающих структур. Схема, основанная на импульсном возбуждении с зондированием квантовых систем со случайным спектром, требует развернутого компьютерного моделирования и экспериментального осуществления. Для фактического воплощения одноатомного процессора необходимо выйти за рамки имеющейся условной одномерной модели и определить рекомендуемые рабочие параметры лазерного излучения. При экспериментальной реализации одноатомного процессора с NHG предстоит также решить задачу частотного кодирования лазерных импульсов высокой интенсивности. Сформулированные проблемы определяют направление, предмет и последовательность дальнейших исследований.

### Список использованной литературы

1. Гудфеллоу Я. Глубокое обучение / Я. Гудфеллоу, И. Бенджио, А. Курвилль. — 2-е изд. — Москва : ДМК Пресс, 2018. — 652 с.
2. Photonic neuromorphic information processing and reservoir computing / A. Lugnan, A. Katumba, F. Laporte [et al.] // APL Photonics. — 2020. — No. 5. — P. 020901.
3. Reservoir Computing. Theory, Physical Implementations, and Applications / ed. K. Nakajima, I. Fischer. — Singapore, 2021. — 457 p.
4. Jaeger H. The "echo state" approach to analysing and training recurrent neural networks : GMD Report 148 / H. Jaeger. — German National Research Center for Information Technology, 2001. — 47 p.
5. Maass W. Real-Time Computing Without Stable States: A New Framework for Neural Computation Based on Perturbations / W. Maass, T. Natschl"ager, H. Markram // Neural Computation. — 2020. — No. 14. — P. 2531–2560.
6. Nakajima K. Physical reservoir computing — an introductory perspective / K. Nakajima // Jpn. J. Appl. Phys. — 2020. — No. 59. — P. 060501.
7. Recent advances in physical reservoir computing: A review / G. Tanaka, T. Yamane, J.B. Heroux, R. Nakane // Neural Networks. — 2019. — No. 115. — P. 100–123.

8. Dai J. An Introduction to the Echo State Network and its Applications in Power System / J. Dai, G.K. Venayagamoorthy, R.G. Harley // *Intelligent System Applications to Power Systems : 15th International Conference, Curitiba, December 2009*. — Curitiba, 2009. — P. 1–7.
9. Konkoli Z. On developing theory of reservoir computing for sensing applications: the state weaving environment echo tracker (SWEET) algorithm / Z. Konkoli // *International Journal of Parallel, Emergent and Distributed Systems*. — 2018. — No. 33. — P. 121–143.
10. Khavinson S.Ya. Best Approximation by Linear Superpositions (Approximate Nomography). AMS Translations of Mathematical Monographs / S.Ya. Khavinson. — American Mathematical Society, 1997. — 175 p.
11. Guang-Bin Huang. Extreme learning machine: Theory and applications / Guang-Bin Huang, Qin-Yu Zhu, Chee-Kheong Siew // *Neurocomputing*. — 2006. — No. 70. — P. 489–501.
12. Хасти Т. Основы статистического обучения. Интеллектуальный анализ данных, логический вывод и прогнозирование / Т. Хасти, Р. Тибширани, Д. Фридман. — 2-е изд. — Москва : Диалектика, 2020. — 768 с.
13. Van der Sande G. Advances in photonic reservoir computing / G. Van der Sande, D. Brunner, M.C. Soriano // *Nanophotonics*. — 2017. — No. 6. — P. 561–576.
14. An optical neural chip for implementing complex-valued neural network / H. Zhang, M. Gu, X. Jiang, J. Thompson // *Nat Commun*. — 2021. — No. 12. — P. 457.
15. Pierangeli D. Photonic extreme learning machine by free-space optical propagation / D. Pierangeli, G. Marcucci, C. Conti // *Photon. Res*. — 2021. — No. 9. — P. 1446–1454.
16. Programming multi-level quantum gates in disordered computing reservoirs via machine learning / G. Marcucci, D. Pierangeli, W.H. Pinkse [et al.] // *Opt. Express*. — 2020. — No. 28. — P. 14018–14027.
17. Unravelling an optical extreme learning machine / D. Silva, N.A. Silva, T. Ferreira, C.C. Rosa // *EPJ Web of Conferences EOSAM*. — 2022. — No. 266. — P. 13034.
18. Novotny L. Principles of Nano-Optics / L. Novotny, B. Hecht. — 2nd ed. — Cambridge : Cambridge University Press, 2012. — 568 p.
19. Quantum reservoir processing / S. Ghoshi, A. Opala, M. Matuszewski, T. Paterek // *npj Quantum Information*. — 2019. — No. 35. — P. 1–6.
20. Reconstructing Quantum States With Quantum Reservoir Networks / S. Ghosh, A. Opala, M. Matuszewski, T. Paterek // *IEEE Transactions on Neural Networks and Learning Systems*. — 2021. — No. 32. — P. 3148–3155.
21. Ищенко А.А. Методы детектирования ультрабыстрой динамики вещества / А.А. Ищенко, Г.В. Фетисов, С.А. Асеев. — Москва : Физматлит, 2022. — 520 с.
22. Theory of strong-field attosecond transient absorption / M. Wu, S. Chen, S. Camp, K. Schafer // *Journal of Physics B Atomic Molecular and Optical Physics*. — 2016. — No. 49. — P. 062003.
23. Kern C. Limitations of Extreme Nonlinear Ultrafast Nanophotonics / C. Kern, M. Zürch, C. Spielmann // *Nanophotonics*. — 2015. — No. 4. — P. 303–323.
24. Mccaul K. Towards single atom computing via high harmonic generation / G. Mccaul, K. Jacobs, D.I. Bondar // *European Physical Journal Plus*. — 2023. — No. 138. — P. 123.

## References

1. Goodfellow I., Bengio Y., Courville A. *Deep Learning*. London, 2016. 800 p. (Russ. ed.: Goodfellow I., Bengio Y., Courville A. *Deep Learning*. 2<sup>nd</sup> ed. Moscow, DMK Press Publ., 2018. 652 p.).

2. Lugnan A., Katumba A., Laporte F. Freiburger M., Sackesyn S. Photonic Neuromorphic Information Processing and Reservoir Computing. *APL Photonics*, 2020, no. 5, pp. 020901.
3. Nakajima K., Fischer I. (eds.). *Reservoir Computing. Theory, Physical Implementations, and Applications*. Singapore, 2021. 457 p.
4. Jaeger H. *The "Echo State" Approach to Analysing and Training Recurrent Neural Networks : GMD Report 148*. German National Research Center for Information Technology, 2001. 47 p.
5. Maass W., Natschl"ager T., Markram H. Real-Time Computing Without Stable States: A New Framework for Neural Computation Based on Perturbations. *Neural Computation*, 2020, no. 14, pp. 2531–2560.
6. Nakajima K. Physical Reservoir Computing — an Introductory Perspective. *Jpn. J. Appl. Phys*, 2020, no. 59, pp. 060501.
7. Tanaka G., Yamane T., Heroux J.B., Nakane R. Recent Advances in Physical Reservoir Computing: A Review. *Neural Networks*, 2019, no. 115, pp. 100–123.
8. Dai J., Venayagamoorthy G.K., Harley R.G. An Introduction to the Echo State Network and its Applications in Power System. *Intelligent System Applications to Power Systems, 15th International Conference, Curitiba, December, 2009*. Curitiba, 2009, pp. 1–7.
9. Konkoli Z. On Developing Theory of Reservoir Computing for Sensing Applications: the State Weaving Environment Echo Tracker (SWEET) Algorithm. *International Journal of Parallel, Emergent and Distributed Systems*, 2018, no. 33, pp. 121–143.
10. Khavinson S.Ya. *Best Approximation by Linear Superpositions (Approximate Nomography)*. AMS Translations of Mathematical Monographs. American Mathematical Society. American Mathematical Society, 1997. 175 p.
11. Guang-Bin Huang, Qin-Yu Zhu, Chee-Kheong Siew. Extreme learning machine: Theory and applications. *Neurocomputing*, 2006, no. 70, pp. 489–501.
12. Hastie T., Tibshirani R., Friedman J. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. New York, Springer Science, 2016. 767 p. (Russ. ed.: Hastie T., Tibshirani R., Friedman J. *Osnovy Statisticheskogo Obucheniya: Intellekual'nyi Analiz Danykh, Logicheskii V"yvod i Prognozirovaniye*. Moscow, Williams, 2020. 768 p.).
13. Van der Sande G., Brunner D., Soriano M.C. Advances in Photonic Reservoir Computing. *Nanophotonics*, 2017, no. 6, pp. 561–576.
14. Zhang H., Gu M., Jiang X., Thompson J. An Optical Neural Chip for Implementing Complex-Valued Neural Network. *Nat Commun*, 2021, no. 12, pp. 457.
15. Pierangeli D., Marcucci G., Conti C. Photonic Extreme Learning Machine by Free-Space Optical Propagation. *Photon. Res*, 2021, no. 9, pp. 1445–1454.
16. Marcucci G., Pierangeli D., Pinkse W.H., Malik M., Conti C. Programming Multi-Level Quantum Gates in Disordered Computing Reservoirs via Machine Learning. *Opt. Express*, 2020, no. 28, pp. 14018–14027.
17. Silva D., Silva N.A., Ferreira T., Rosa C.C. Unravelling an Optical Extreme Learning Machine. *EPJ Web of Conferences EOSAM*, 2022, no. 266, pp. 13034.
18. Novotny L., Hecht B. *Principles of Nano-Optics*. 2<sup>nd</sup> ed. Cambridge, Cambridge University Press, 2012. 568 p.
19. Ghoshi S., Opala A., Matuszewski M., Paterek T. Quantum Reservoir Processing. *npj Quantum Information*, 2019, no. 35, pp. 1–6.
20. Ghoshi S., Opala A., Matuszewski M., Paterek T. Reconstructing Quantum States with Quantum Reservoir Networks. *Ieee Transactions On Neural Networks And Learning Systems*, 2021, no. 32, pp. 3148–3155.
21. Ishchenko A.A., Fetisov G.V., Aseev S.A. *Methods for Detecting Ultrafast Dynamics of Matter*. Moscow, Fizmatlit Publ., 2022. 520 p.

22. Wu M., Chen S., Camp S., Schafer K. Theory of Strong-Field Attosecond Transient Absorption. *Journal of Physics B Atomic Molecular and Optical Physics*, 2016, no. 49. pp. 062003.

23. Kern C., Zürch M., Spielmann C. Limitations of Extreme Nonlinear Ultrafast Nanophotonics. *Nanophotonics*, 2015, no. 4, pp. 303–323.

24. Mccaul G., Jacobs K., Bondar D.I. Towards Single Atom Computing Via High Harmonic Generation. *European Physical Journal Plus*, 2023, no. 138, pp. 123.

### Информация об авторе

**Головинский Павел Абрамович** — доктор физико-математических наук, профессор кафедры инноватики и строительной физики им. И.С. Суровцева, Воронежский государственный технический университет, г. Воронеж, Российская Федерация, e-mail: golovinski@bk.ru.

### Information about the Author

**Pavel A. Golovinski** — D.Sc. in Physical and Mathematical Sciences, Professor of the Department of Innovation and Building Physics named after I.S. Surovtsev, Voronezh State Technical University, Voronezh, Russian Federation, e-mail: golovinski@bk.ru.

### Для цитирования

Головинский П.А. Дорожная карта реализации оптических машин экстремального обучения / П.А. Головинский. — DOI 10.17150/2713-1734.2023.5(3).239-250. — EDN MDTJBC // *System Analysis & Mathematical Modeling*. — 2023. — Т. 5, № 3. — С. 239–250.

### For Citation

Golovinsky P.A. Roadmap for Implementation Optical Extreme Learning Machines. *System Analysis & Mathematical Modeling*, 2023, vol. 5, no. 3, pp. 239–250. (In Russian). EDN: MDTJBC. DOI: 10.17150/2713-1734.2023.5(3).239-250.