

Моя профессиональная
карьера



ISSN
INTERNATIONAL
STANDARD
SERIAL
NUMBER

ISSN
2782-4365

Проверить
номер:



Научно-образовательный электронный журнал

ОБРАЗОВАНИЕ И НАУКА В XXI ВЕКЕ

Выпуск №60-1 (том 1)
(март, 2025)



Проверить индексацию статьи. Сайт: mrcareer.ru/google



Свидетельство
о регистрации СМИ
№ЭЛ ФС 77-77927
от 19.02.2020 г.



РОСКОМНАДЗОР

Периодичность выпуска: 1 раз в неделю
Сайт: mrcareer.ru/oinv21veke. Почта: obrmpcareer@mail.ru



Международный научно-образовательный
электронный журнал
«ОБРАЗОВАНИЕ И НАУКА В XXI ВЕКЕ»

ISSN 2782-4365

УДК 37

ББК 94

**Международный научно-образовательный электронный журнал
«ОБРАЗОВАНИЕ И НАУКА В XXI ВЕКЕ». Выпуск №60-1 (том 1) (март,
2025). Дата выхода в свет: 10.03.2025.**

Сборник содержит научные статьи отечественных и зарубежных авторов по экономическим, техническим, философским, юридическим и другим наукам.

Миссия научно-образовательного электронного журнала «ОБРАЗОВАНИЕ И НАУКА В XXI ВЕКЕ» состоит в поддержке интереса читателей к оригинальным исследованиям и инновационным подходам в различных тематических направлениях, которые способствуют распространению лучшей отечественной и зарубежной практики в интернет пространстве.

Целевая аудитория журнала охватывает работников сферы образования (воспитателей, педагогов, учителей, руководителей кружков) и школьников, интересующихся вопросами, освещаемыми в журнале.

Материалы публикуются в авторской редакции. За соблюдение законов об интеллектуальной собственности и за содержание статей ответственность несут авторы статей. Мнение редакции может не совпадать с мнением авторов статей. При использовании и заимствовании материалов ссылка на издание обязательна.

© ООО «МОЯ ПРОФЕССИОНАЛЬНАЯ КАРЬЕРА»

© Коллектив авторов

РЕДАКЦИОННАЯ КОЛЛЕГИЯ:

Пестерев С.В. – гл. редактор, отв. за выпуск

Абдурасулов Абдуллажон Абдукаримович	доктор философии педагогических наук
Азамов Жасурбек Муродович	доктор философии в области юриспруденции
Артикова Мухайохон Ботиралиевна	доктор педагогических наук, доцент
Ахмедов Ботиржон Равшанович	доктор философии в филолог. науках (PhD), доцент
Батурич Сергей Петрович	кандидат исторических наук, доцент
Бекжанова Айнура Мархабаевна	доктор философии по педагог. наукам (PhD), доцент
Бекжанова Гулнара Мархабаевна	кандидат медицинских наук, преподаватель
Боброва Людмила Владимировна	кандидат технических наук, доцент
Богданова Татьяна Владимировна	кандидат филологических наук, доцент
Ботиров Аминжон Розимбоевич	кандидат биологических наук, доцент
Демьянова Людмила Михайловна	кандидат медицинских наук, доцент
Еремеева Людмила Эмировна	кандидат технических наук, доцент
Жуманова Фатима Ураловна	кандидат педагогических наук, доцент
Засядько Константин Иванович	доктор медицинских наук, профессор
Исломова Саидахон Тургуновна	доктор философии по техническим наукам (PhD), доцент
Кабулова Мехрибан Толыбаевна	доктор философии по педагог. наукам (PhD)
Казакова Раъно Машрабаевна	доктор философии по филологическим наукам (PhD)
Кодиров Хасанбой Орибжонович	доктор философии педагогических наук
Колесников Олег Михайлович	кандидат физико-математических наук, доцент
Коробейникова Екатерина Викторовна	кандидат экономических наук, доцент
Ланцева Татьяна Георгиевна	кандидат экономических наук, доцент
Мухамедова Лола Джураевна	доктор философии по филологическим наукам (PhD)
Нарзикулова Фируза Ботировна	доктор психологических наук
Нобель Артем Робертович	кандидат юридических наук, доцент
Ноздрин Наталья Александровна	кандидат педагогических наук, доцент
Нуржанов Сабит Узакбаевич	доктор историч. наук (dsc), старший научный сотрудник
Олтаев Шавкат Собирович	кандидат экономических наук, доцент
Павлов Евгений Владимирович	кандидат исторических наук, доцент
Петрова Юлия Валентиновна	кандидат биологических наук, доцент
Попов Сергей Викторович	доктор юридических наук, профессор
Расулходжаева Мадина Ахмаджоновна	доктор философии по педагог. наукам (PhD), доцент

Рахматова Фотима Ганиевна	доктор философии по педагог. наукам (PhD), доцент
Рахмонов Азизхон Боситхонови	доктор педагогических наук, доцент
Таспанова Айзада Кенжебаевна	доктор философии (PhD) по экономическим наукам
Таспанова Жыгагул Кенжебаевна	доктор философии по педагог. наукам (PhD), доцент
Табашникова Ольга Львовна	кандидат экономических наук, доцент
Тўрабоева Мадинахон Рахмонжон қизи	кандидат педагогических наук, доцент
Тюрин Александр Николаевич	кандидат географических наук, доцент
Уразова Лариса Карамовна	кандидат исторических наук, доцент
Усубалиева Айнура Абдыжапаровна	кандидат социологических наук, доцент
Утегенова Жамила Джолмурзаевна	доктор философии по эконом. наукам, доцент
Фаттахова Ольга Михайловна	кандидат технических наук, доцент
Ширинов Отабек Тувалович	доктор психологических наук (PhD)
Хамдамова Ситора Сафаровна	Доктор философии в области философских наук, доцент
Ханбабаев Хакимжан Икрамович	доктор педагогических наук (DSc)
Худайкулов Хол Джумаевич	доктор педагогических наук, профессор
Худойбердиева Хурият Каримбердиевна	доктор философии (PhD) в социальной философии
Ширинов Отабек Тувалович	доктор психологических наук (PhD)
Эшназаров Журакул	кандидат педагогических наук, профессор
Эшназарова Фарида Журакуловна	доктор философии по философии (PhD)
Юнусова Бахора Ахтамжоновна	кандидат филологических наук, ассистент
Яхяева Сожида Абдурахимовна	доктор философии (PhD) в социальной философии

Хаджиева Огулджемал Гурбандурдыевна, Амансяхедов Б., Тяшлиев Мекан СОЦИАЛЬНАЯ ОТВЕТСТВЕННОСТЬ БИЗНЕСА (CSR): ПРИНЦИПЫ, ПРАКТИКИ И ПЕРСПЕКТИВЫ	134
Акыев Гурбангелди, Алланазарова Сельби ОРГАНИЗАЦИЯ РАБОТЫ РЕСТОРАНА НА 150 МЕСТ С ИСПОЛЬЗОВАНИЕМ ПОЛУФАБРИКАТОВ (В ДНЕВНОЕ ВРЕМЯ — СТОЛОВАЯ)	143
ДОПОЛНИТЕЛЬНОЕ ОБРАЗОВАНИЕ	
Шаимов Хусеин ИСТОРИЯ ОБОСНОВАНИИ ИСЛАМСКОГО ПРАЗДНИКА НОВРУЗ И ЕГО ЗНАЧИМОСТЬ ДЛЯ ОБЩЕСТВА И НАРОДА	151
Нурлиева М. ОБРАЗОВАНИЕ И НАУКА - ПРИОРИТЕТЫ ГОСУДАРСТВЕННОЙ ПОЛИТИКИ ТУРКМЕНИСТАНА	155
Улугбердиев Юсуп, Орамова Огульшат РОЛЬ ФИНАНСОВОГО ПЛАНИРОВАНИЯ В УПРАВЛЕНИИ ПРЕДПРИЯТИЕМ	160
Гараманова Бахаргуль МАХТУМКУЛИ И ПУШКИН – ДВА ГЕНИЯ МИРОВОГО ЗНАЧЕНИЯ	164
Gochmyradov Juneyithan, Pudakov Berdimyrat THE KÖNIGSBERG BRIDGES PROBLEM	168
Джаналыева Багдагуль, Батырова Камила, Ашырова Мерьем ИЗУЧЕНИЕ ЯЗЫКА С ПОМОЩЬЮ ПЕРЕВОДОВ	172
Бегенч Дурдыев МЕЖДУНАРОДНЫЕ ИНИЦИАТИВЫ ДРУЖЕСКИХ ОТНОШЕНИЙ	177
Мырадова Шасенем, Какаджанов Баймырат, Мамиев Джейхун ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ В РЕКОНСТРУКЦИИ УТРАЧЕННЫХ КУЛЬТУРНЫХ АРТЕФАКТОВ ДЛЯ ВИРТУАЛЬНЫХ МУЗЕЕВ	181
Улугбердиев Юсуп, Сапаров Сапармухаммет ПОДХОДЫ, ИСПОЛЬЗУЕМЫЕ ДЛЯ ТОГО, ЧТОБЫ СДЕЛАТЬ КОМПАНИЮ ФИНАНСОВО ЗДОРОВОЙ	186
Гелдиева Л., Ходжанепесова Х. ДОСТАТОЧНО ЛИ ЗНАТЬ ТОЛЬКО ГРАММАТИКУ ДЛЯ ОСВОЕНИЯ ЯЗЫКА?	191
Ballyyev Charyyar TO PREPARE AN INSTRUCTION MANUAL FOR THE USE OF MEDICAL EQUIPMENT	195
Mametsaliyev Resul THE CONCEPT OF NEURAL ODES AND THEIR MATHEMATICAL DESCRIPTION	200

ФИО автора(-ов): *Mametsaliyev Resul, teacher.*

Oguzhan Engineering and Technology University of Turkmenistan.

Ashgabat, Turkmenistan.

Название публикации: «THE CONCEPT OF NEURAL ODES AND THEIR MATHEMATICAL DESCRIPTION»

Abstract: Neural Ordinary Differential Equations (Neural ODEs) are a powerful class of deep learning models that generalize residual networks (ResNets) by formulating the evolution of hidden states as a continuous-time differential equation. This approach provides benefits such as memory efficiency, adaptability to irregularly sampled data, and improved interpretability. This paper explores the mathematical formulation of Neural ODEs, their relation to classical ODE solvers, and key applications in machine learning. We also discuss numerical methods used for solving Neural ODEs and their challenges in optimization and stability.

Keywords: Neural ODEs, deep learning, differential equations, continuous-depth models, numerical solvers, optimization, machine learning.

1. Introduction

Deep learning models have traditionally been built using discrete-layer architectures, where information is processed through a sequence of transformations. However, recent advances have introduced the idea of treating these transformations as continuous dynamical systems, leading to the development of **Neural Ordinary Differential Equations (Neural ODEs)**.

Neural ODEs were introduced by **Chen et al. (2018)** as a continuous generalization of residual networks (ResNets). Instead of applying a fixed number of layers, Neural ODEs model the transformation of hidden states using an **ordinary differential equation (ODE)**. This enables a more flexible and theoretically grounded approach to deep learning, particularly in problems involving time-series analysis, generative modeling, and physics-informed machine learning.

This paper provides a comprehensive mathematical description of Neural ODEs, including their formulation, numerical solution techniques, and applications in modern machine learning.

2. Mathematical Formulation of Neural ODEs

2.1. From Residual Networks to Continuous Depth Models

Traditional neural networks process data through multiple layers, each applying a transformation to the input. In a **ResNet**, the transformation at layer t can be written as:

$$h_{t+1} = h_t + f(h_t, \theta_t)$$

where $f(h_t, \theta_t)$ is a learned function parameterized by θ_t .

If we take the limit where the step size between layers approaches zero, this discrete transformation converges to a **continuous-time dynamical system** described by an ODE:

$$\frac{dh(t)}{dt} = f(h(t), \theta)$$

where $h(t)$ represents the evolving state of the system over continuous time, and f is a neural network that parameterizes the ODE.

2.2. Neural ODEs as an Initial Value Problem (IVP)

Given an initial state $h(0) = h_0$, solving a Neural ODE requires computing the solution at a later time T , which can be expressed as:

$$h(T) = h(0) + \int_0^T f(h(t), \theta) dt$$

This formulation allows us to treat the depth of the model as a **continuous variable**, rather than a fixed number of layers.

2.3. Computing the Solution Using ODE Solvers

Since most ODEs do not have closed-form solutions, we must approximate $h(T)$ using numerical integration methods. Common numerical solvers include:

- **Euler's Method:**

$$h_{t+1} = h_t + \Delta t \cdot f(h_t, \theta)$$

This method is simple but suffers from stability issues and poor accuracy for stiff ODEs.

- **Runge-Kutta Methods (RK4):**

A more accurate method that evaluates $f(h, \theta)$ at multiple points within each step:

$$h_{t+1} = h_t + \frac{1}{6}(k_1 + 2k_2 + 2k_3 + k_4)$$

where k_i are intermediate evaluations of f .

- **Adaptive Solvers:**

Methods like **Dormand-Prince (Dopri5)** dynamically adjust step sizes to balance accuracy and efficiency. These solvers are commonly used in Neural ODE implementations.

3. Training Neural ODEs: The Adjoint Method

3.1. Challenges in Backpropagation

Unlike traditional neural networks, Neural ODEs do not have a fixed computational graph, making gradient computation challenging. Direct backpropagation through an ODE solver is memory-intensive since it requires storing all intermediate states.

3.2. Continuous Backpropagation with the Adjoint Method

To efficiently compute gradients, Neural ODEs use the **adjoint sensitivity method**, which computes gradients by solving an auxiliary ODE backward in time. Given the loss function L , the adjoint variable $a(t)$ satisfies the equation:

$$\frac{da(t)}{dt} = -a(t) \frac{\partial f(h(t), \theta)}{\partial h}$$

By integrating this equation backward, we can compute gradients with constant memory usage, making Neural ODEs scalable for large models.

4. Applications of Neural ODEs

4.1. Time-Series Modeling

Neural ODEs are well-suited for modeling **irregularly sampled time-series data**. Instead of requiring data at fixed time steps, they can interpolate between observations, making them useful in medical data analysis, weather forecasting, and financial modeling.

4.2. Continuous Normalizing Flows (CNFs)

In generative modeling, Neural ODEs are used in **Continuous Normalizing Flows (CNFs)** to define invertible transformations for probabilistic modeling. CNFs enable efficient density estimation and image generation by modeling probability distributions as continuous transformations.

4.3. Physics-Informed Machine Learning

Neural ODEs provide a natural framework for incorporating **physical laws** into machine learning models. Applications include fluid dynamics, population modeling, and reinforcement learning in physical simulations.

5. Challenges and Future Directions

5.1. Computational Cost

Solving ODEs numerically is computationally expensive, especially for complex models. Future research aims to develop **more efficient solvers** tailored to deep learning.

5.2. Stability and Robustness

Neural ODEs can be sensitive to numerical errors and solver choice. Improving stability through **better regularization techniques** is an active research area.

5.3. Hybrid Discrete-Continuous Models

Recent work explores combining **discrete layers with continuous-depth models** for greater flexibility. This hybrid approach could improve training efficiency while retaining the benefits of Neural ODEs.

6. Conclusion

Neural ODEs represent a significant shift in deep learning, offering a continuous-depth perspective that aligns with dynamical systems theory. Their mathematical formulation enables adaptive computation, memory efficiency, and applicability to a wide range of problems. Despite computational challenges, ongoing

research is making Neural ODEs more practical for large-scale machine learning applications.

References

1. Chen, R. T. Q., Rubanova, Y., Bettencourt, J., & Duvenaud, D. (2018). Neural Ordinary Differential Equations. *Advances in Neural Information Processing Systems (NeurIPS)*.
2. Rackauckas, C., & Nie, Q. (2020). Differentiable Programming for Scientific Machine Learning. *Nature Machine Intelligence*.
3. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
4. Hairer, E., Nørsett, S. P., & Wanner, G. (1993). *Solving Ordinary Differential Equations I: Nonstiff Problems*. Springer-Verlag.
5. Kingma, D. P., & Welling, M. (2013). Auto-Encoding Variational Bayes. *ICLR Proceedings*.

© Mametsaliyev Resul. 2025