

ФИЗИКА. МАТЕМАТИЧЕСКОЕ МОДЕЛИРОВАНИЕ PHYSICS. MATHEMATICAL MODELING

УДК 519.63:004.773
MSC 35K05, 91D30
Оригинальное исследование

DOI 10.52575/2687-0959-2025-57-4-272-278
EDN NBUBRS

Моделирование диффузии информации в социальной сети

Толстых М. А.

(Статья представлена членом редакционной коллегии Virchenko Ю. П.)

Донецкий государственный университет,
Россия, 283001, г. Донецк, ул. Университетская, 24
physicisto@yandex.ru

Аннотация. Целью работы является разработка модифицированной диффузионной модели распространения информации в социальных сетях на основе одномерного параболического уравнения. Ключевым отличием модели является строгое физическое обоснование ее параметров, что позволяет перейти от качественных к количественным оценкам. Информация рассматривается как непрерывная функция числа пользователей, распространяющих новость. Для адекватного учета дискретной структуры социального графа применяется метод интегрального осреднения. Новизна модели заключается в явном задании распределенных источников информации с помощью свободного члена, включающего пороговую функцию Хевисайда, что отражает реальный механизм активации пользователей в качестве вторичных источников. Численные эксперименты проведены на реальных данных Twitter, касающихся распространения новости об открытии бозона Хиггса. Результаты расчетов демонстрируют высокую точность модели: нормализованная среднеквадратическая ошибка между модельными и экспериментальными данными составила 0,7%. Полученные результаты подтверждают гипотезу о применимости законов физической диффузии для описания информационных потоков.

Ключевые слова: математическое моделирование, социальные сети, диффузия информации

Благодарности: Исследование выполнено при финансовой поддержке Азово-Черноморского математического центра (Соглашение от 27.02.2025 № 075–02–2025–1608).

Для цитирования: Толстых М.А. Моделирование диффузии информации в социальной сети. *Прикладная математика & Физика*. 2025;57(4):272–278. DOI 10.52575/2687-0959-2025-57-4-272-278 EDN NBUBRS

Original Research

Mathematical Modeling of Information Diffusion in Social Network

Margarita A. Tolstykh

(Article submitted by a member of the editorial board Virchenko Yu. P.)

Donetsk State University,
24 Universitetskaya St., Donetsk 283001, Russia
physicisto@yandex.ru

Abstract. This work aims to develop a modified diffusion model of information spreading in social networks based on a one-dimensional parabolic equation. The model's key feature is its strict physical basis for all parameters, enabling a transition from qualitative to quantitative estimates. The study treats information as a continuous function of the number of users distributing the news. The method of integral averaging applied in the model ensures an adequate transition to the discrete structure of the social graph. The novelty of the approach lies in the explicit definition of distributed information sources through the free term of the equation, which includes a Heaviside theta function. This formulation reflects the real activation mechanism of users who become secondary sources. We conducted numerical experiments using real Twitter data on the spread of news about the Higgs boson discovery. The test results demonstrate the model's high accuracy: the normalized root-mean-square error between the simulated and experimental data was 0,7%. The obtained results confirm the hypothesis about the applicability of physical diffusion laws for describing information flows in social networks.

Keywords: Mathematical Modeling, Social Networks, Information Diffusion

Acknowledgements: The work was supported by the Azov-Black Sea Mathematical Center (Agreement № 075-02-2025-1608 of February 27, 2025).

For citation: Tolstykh MA. Mathematical Modeling of Information Diffusion in Social Network. *Applied Mathematics & Physics*. 2025;57(4):272–278 (In Russ.). DOI 10.52575/2687-0959-2025-57-4-272-278 EDN NBUBRS

1. Введение. Моделирование распространения информации в социальных сетях – актуальная задача, обусловленная стремительным ростом влияния онлайн-платформ на общественное мнение, политические процессы, экономику и др. Первые работы, заложившие основу для понимания социальных сетей, такие как исследование Грановеттера 1978 года [1], фокусировались на структуре организационных сетей. Однако современные онлайн-социальные сети представляют собой гораздо более сложные системы, характеризующиеся разнообразием структур, алгоритмов и форм взаимодействия пользователей. Распространение информации в таких сетях базируется как на графовой структуре сети (распространение от узла к узлу через подписки, дружеские связи и т. д.), так и на содержании информации (независимые источники информации, плагиат). Этот сложный процесс может быть описан с помощью различных математических моделей, которые позволяют изучать динамику распространения информации, прогнозировать её охват и выявлять ключевые влияющие факторы.

Необходимо отметить, что «информация», «репост», «новость» – это эквивалентные понятия в социальных сетях. Количество информации в социальной сети тождественно равно количеству экземпляров одной новости (репостов, ретвитов).

2. Обзор моделей распространения информации в социальных сетях. Наиболее популярными моделями распространения информации в социальных сетях (далее – РИСС) являются эпидемиологические, каскадные, пороговые, диффузионные модели и модели на основе машинного обучения. Выбор наиболее подходящей модели зависит от конкретных целей исследования и доступных данных. Часто используется комбинированный подход, объединяющий преимущества различных моделей.

Пороговые модели [2] предполагают, что пользователь принимает информацию только тогда, когда количество или интенсивность сигналов от его окружения превышает определенный порог. Эти модели часто используются для изучения коллективного поведения. Для линейной пороговой модели:

$$\sum_{v \in N(u)} w_{uv} \geq \theta_u,$$

где $N(u)$ – соседи узла u , w_{uv} – вес влияния узла v на узел u , θ_u – порог активации узла u . Эти модели учитывают влияние социального давления, подходят для анализа критических точек в распространении информации, однако не учитывают динамику процесса распространения информации.

Каскадные модели [2] описывают распространение информации как последовательность активаций узлов. В модели независимых каскадов (ICM) каждый узел v имеет вероятность p_{uv} активировать соседний узел u . Процесс продолжается до тех пор, пока не будут активированы все доступные узлы. Такие модели учитывают структуру сети, однако не учитывают динамику и сильно упрощают социальные взаимодействия.

Эпидемиологические модели [3], такие как SIR (Susceptible-Infected-Recovered), заимствованы из биологии и описывают распространение информации аналогично распространению заболеваний. В этих моделях множество пользователей (популяция) делится на группы: S – восприимчивые пользователи, которые еще не получили информацию; I – инфицированные пользователи, распространяющие информацию; R – выздоровевшие пользователи, которые больше не распространяют информацию.

$$\frac{dS}{dt} = -\beta SI, \quad \frac{dI}{dt} = \beta SI - \gamma I, \quad \frac{dR}{dt} = \gamma I,$$

где β – скорость передачи информации, γ – скорость «выздоровления».

Данные модели просты и наглядны, учитывают динамику распространения информации, однако не учитывают структуру сети и содержание информации, предполагают однородность популяции, что редко выполняется в реальности.

Модели на основе машинного обучения [4] используют данные для обучения и прогнозирования. Графовые нейронные сети используют структуру социальной сети для прогнозирования распространения информации, учитывают связи между узлами и их свойства. Рекуррентные нейронные сети подходят для моделирования временных зависимостей в распространении информации. Модели на основе обучения с подкреплением оптимизируют стратегии распространения информации, учитывая динамику сети. Такие модели обладают высокой точностью при наличии больших объемов данных, учитывают сложные нелинейные зависимости, однако требуют больших вычислительных ресурсов и данных, сложны в интерпретации (проблема «черного ящика»).

Предложенные в 2012 году диффузионные модели [5], такие как линейная диффузионная, модель диффузионной логистики, описывают распространение информации как процесс, аналогичный диффузии вещества в среде. Их преимущества: универсальность и гибкость, возможность учета пространственных и временных факторов, интерпретируемость. Это важно для создания моделей, не привязанных к специфическим алгоритмам конкретных социальных сетей и способных адаптироваться к изменениям в их функционировании [6]. Однако предложенные модели требуют сложных вычислений, идентификации параметров, а также неясно, какой смысл относительно социальной сети несут входящие в данные

модели параметры. Эти модели могут быть улучшены, если их параметры приобретут физическую интерпретацию.

Параметры моделей в ранних работах [4] приближались некоторыми полиномами с эвристически подобранными коэффициентами, что давало приблизительное соответствие модели реальным данным из социальных сетей. Предполагалось, что коэффициент диффузии $p(x)$ – это некоторая экспоненциальная функция, в некоторых работах $p(x)$ выносилось за знак дифференциала, что некорректно, однако в дальнейших работах авторов моделей эта неточность была устранена. Были попытки идентификации оптимальных параметров диффузионных моделей в виде полиномов [7], а также решалась задача об источнике [8, 9]. Также для соответствия закону Фика данных моделей правая часть домножалась на состояние модели v , на логистическую функцию, зависящую от v . Это обеспечивало соответствие модели закону Фика, однако искажало смысл входящих в модель параметров – было невозможно дать им какую-либо количественную оценку.

В настоящей работе предлагается модификация существующей диффузионной модели распространения информации в социальных сетях, представленной в [2], которая учитывает эти аспекты и позволяет решать широкий круг задач, включая прогнозирование распространения информации, выявление лидеров мнений и обнаружение экстремистских кластеров.

3. Моделирование распространения информации на основе уравнения диффузии. Известно, что распространение информации в сети происходит в основном под действием градиента информации, из областей, где информации больше, в области, где ее меньше. Подобные процессы в физике описываются законом Фика диффузии молекул в среде. Предлагается гипотеза, что распространение информации в глобальных социальных сетях подчиняется физическим законам диффузии. Подобный подход, связывающий динамические процессы в сложных сетях с формализмом теоретической физики использовался в работе [10]. Информация трактуется как непрерывная функция количества распределённых пользователей, участвующих в распространении конкретной новости с течением времени.

Соответствующее параболическое уравнение диффузии имеет вид:

$$\frac{\partial v(x, t)}{\partial t} - \frac{\partial}{\partial x} \left(p \frac{\partial v(x, t)}{\partial x} \right) - \phi = 0, \quad x, t \in \Omega = (x_a, x_b) \times (t_0, t_1), \quad (1)$$

где t – время; x – расстояние в графе сети, на которое распространяется информация, например, в виде репостов какой-либо новости; $v(x, t)$ – количество репостов (количество активных пользователей) рассматриваемой новости к моменту t в точке x ; p – коэффициент диффузии информации, который определяет степень проникновения новости в более глубокие слои социальной сети, возможно $p(x)$; свободный член $\phi(x, t)$ – распределённые источники информации.

Здесь необходимо обсудить, что собой представляет координата x . В реальной сети – это расстояние в графе, измеряемое минимальным набором рёбер $i = 1, 2, 3, \dots$, по которым может быть передана информация из источника с номером $i = 0$. То есть расстояние дискретно, $x = x_i = i$. Физическая диффузия (1) предполагает непрерывность пространства. Поэтому, моделируя поток информации уравнением (1), нам придётся результаты диффузии отображать в дискретное пространство $\{x_i\}_{i=0}^{\infty}$. Это можно делать интегральным осреднением (математическим ожиданием) состояния новости на i -том отрезке единичной длины в виде:

$$v_i(t) = \int_{x_{i-1}}^{x_i} v(x, t) dx, \quad i = 1, 2, 3, \dots \quad (2)$$

Данная проблема перехода между дискретными сетевыми структурами и их непрерывными приближениями рассматривается, например, в работе [11].

В данной работе уравнение (1) будем дополнять следующими граничными и начальными условиями:

$$v = 1 \text{ на } \Gamma_a = x_a \times (t_0, t_1), \quad \frac{\partial v(x, t)}{\partial x} = 0 \text{ на } \Gamma_b = x_b \times (t_0, t_1), \quad v = 0 \text{ на } \Gamma_0 = (x_a, x_b) \times t_0. \quad (3)$$

Одна новость зарождается одним автором в момент t_0 на левой границе Γ_a . Справа на границе Γ_b поток новости равен нулю к моменту t_1 , когда стабилизируется процесс насыщения сети новостью. Предполагается, что изначально рассматриваемой новости в сети нет. При этом полагается, что до точки x_b информация также не доходит. Возможно рассмотрение и других граничных и начальных условий.

Свободный член в уравнении (1)

$$\phi(x, t) = r(t)h(x)\Theta(v - \varepsilon),$$

где $r(t)$ – средняя скорость изменения активности пользователей, $h(x)$ – максимальное количество активных пользователей, участвующих в распространении новости, вплоть до насыщения сети. Функция

$\phi(x, t)$ – это распределённый источник информации в виде действия активных пользователей сети, которые становятся вторичными источниками рассматриваемой новости. Эта функция

$$\Theta(v - \varepsilon) = \begin{cases} 1, & \text{если } v(x, t) \geq \varepsilon; \\ 0, & \text{иначе.} \end{cases}$$

задаёт порог $\varepsilon > 0$, который предотвращает «зарождение» информации в каждой точке x сети, пока до активных пользователей в точке x не дошла новость, т. е. не дошёл фронт потока новости высотой ε .

В рассматриваемой модели (1) её параметры приобретают не только физический смысл, но и понятные, наглядные количественные значения. Разработка подобных интерпретируемых моделей, в противовес «чёрным ящикам», выделяется как одно из ключевых направлений в моделировании социальных сетей [6, 12].

Максимальное количество активных пользователей $h(x)$ характеризует пропускную способность кластера сети, где информация зародилась, была активно поддержана заинтересованной цепочкой пользователей и, достигнув пика распространения, стабилизировалась так, что поток информации вне кластера интересов прекратился. При этом каждый активный пользователь имеет по одному экземпляру новости. Это означает, что

$$h(x) = \max_t v(x, t). \quad (4)$$

Если активные участники не удаляют репосты новости, то, очевидно, $h(x) = v(x, t_1)$. По дискретному значению функции $h_i(x)$ можно судить о количестве узлов кластера, характеризующих глубину и ширину проникновения информации в сеть, можно судить о заинтересованности участников кластера в текущем типе новости, т. е. выделять группы по интересам.

Получается, что распределённые в кластере источники вторичной новостной информации, во-первых, заранее (к моменту t_0) известны и их количество равно $h(x)$. Во-вторых, источники начинают работать после прихода к ним количества новостей $v \geq \varepsilon$. В-третьих, мощность источников определяется параметром $r(t)$, при этом сначала мощность (интерес к новости) постепенно возрастает до максимума, далее убывает до значения, обеспечивающего стабилизацию процесса распространения новости.

Функция $r(t)$ имеет размерность обратную времени и характеризует среднюю в пространстве интенсивность источников h , т. е. активность заинтересованных пользователей кластера. Из уравнения (1) следует

$$\frac{\partial v_{cp}(t)}{\partial t} = r(t)h_{cp},$$

где $h_{cp} = \frac{1}{x_b - x_a} \int_{x_a}^{x_b} h(x) dx$, $v_{cp}(t) = \frac{1}{x_\varepsilon - x_a} \int_{x_a}^{x_\varepsilon} v(x, t) dx$. Здесь $x_\varepsilon(t) \xrightarrow{t \rightarrow t_1} x_b$ – точка фронта потока новости в сети. Проинтегрируем по времени предыдущее выражение:

$$\int_{t_0}^{t_1} r(t) dt = \frac{1}{h_{cp}} v_{cp}(t_1).$$

Здесь было учтено, что $v_{cp}(t_0) = 0$. Если учесть (4) в последний момент времени, когда $x_\varepsilon = x_b$, то $v_{cp}(t_1) = h_{cp}$ и мы получим условие нормировки функции активности пользователей:

$$\int_{t_0}^{t_1} r(t) dt = 1. \quad (5)$$

Таким образом, функция $r(t)$ представляет собой долю от общего количества пользователей, которые будут делиться информацией, в единицу времени.

Обсудим коэффициент диффузии p . Он влияет на накопление новостной информации всеми активными пользователями в каждой точке x с течением времени t . С точки зрения физики, с одной стороны, малое значение коэффициента диффузии приводит к медленному проникновению субстанции в среду, с другой стороны, – к высокой концентрации диффундирующей субстанции возле источника диффузии. В нашем случае мы имеем много источников – это единичный источник на границе Γ_a и распределённые источники переменной мощности вдоль всего кластера сети.

Из натуральных наблюдений известно [13], что распределение $v(x_i, t \approx t_1)$ имеет максимум в нескольких «шагах» $i = 2 - 3$ от первоисточника x_a и затажной «хвост» с $v \rightarrow 0$ в конце кластера x_b . Как на это может влиять коэффициент диффузии?

Если предположить, что коэффициент диффузии не постоянный в пространстве, т. е. $p = p(x)$, то уравнение (1) можно записать в виде:

$$\frac{\partial v}{\partial t} - p \frac{\partial^2 v}{\partial x^2} = \phi + \frac{\partial p}{\partial x} \frac{\partial v}{\partial x} \quad \text{на } \Omega. \quad (6)$$

Поскольку $\frac{\partial v}{\partial x} \neq 0$, то даже при $\phi = 0$ справа в (6) будет присутствовать ненулевой источник (сток) концентрации новости и стабилизировать поток информации будет крайне сложно. Возле Γ_b для формирования «хвоста» необходимо $\frac{\partial v}{\partial x} < 0$. С другой стороны, чтобы там и $v \rightarrow 0$ необходимо существенно усилить диффузию т. е. необходимо $\frac{\partial v}{\partial x} > 0$ для стока (при этом $\frac{\partial p}{\partial x} \frac{\partial v}{\partial x} < 0$) лишней концентрации новости. Это значит, что необходимо $p(x \approx x_b) \rightarrow \infty$. Такое поведение коэффициента диффузии кажется экзотическим, поэтому далее примем $p(x) = p$ и уравнение (1) примет вид:

$$\frac{\partial v}{\partial t} = p \frac{\partial^2 v}{\partial x^2} = rh\Theta(v - \epsilon) \quad \text{на } \Omega. \quad (7)$$

4. Тестовые расчеты моделирования потока информации. Исследуем поведение модели (7) и оценим насколько реалистично она может описать реальные процессы распространения информации в социальной сети. Рассмотрим экспериментальные данные сети twitter.com [13] о распространении новости об открытии бозона Хиггса. Наблюдаемое состояние информации достигло насыщения новостью и приняло значения $v_i(t_1) = \{1, 6370, 136366, 167164, 65276, 396, 38\}$ в узлах $i = 0 \dots 6$ к моменту $t_1 = 175$ (часов).

Для уравнения (7) с граничными условиями (3) были подобраны следующие коэффициенты модели: коэффициент диффузии информации $p = 0.0001$; $h(x) = v(t_1)$ – пропускная способность; скорость реакции пользователей в виде гауссовой функции $r(t) = 0.018e^{\frac{(t-87.5)^2}{1936}}$; порог был принят $\epsilon = 0.001$.

На рис. 1 (а) сплошная линия – это функция $h(x)$, полученная кубической интерполяцией по вершинам дискретных наблюдений в виде столбцов. На рис. 1 (б) показана функция $r(t)$ с пиком активности пользователей в момент $t \approx 87$ (часов). Эти параметры подбирались с учётом условий (4), (5). Расчёт параболического уравнения (7) производился по неявной конечно-разностной схеме Кранка – Николсона на сетке $\{x_i = x_a + i\Delta x, i = 0 \dots n, \Delta x = \frac{x_b - x_a}{n}\}$, $\{t_j = t_0 + j\Delta t, j = 0 \dots m, \Delta t = 0.5 \frac{\Delta x^2}{p}\}$, $n = 60$, $m = 350$.

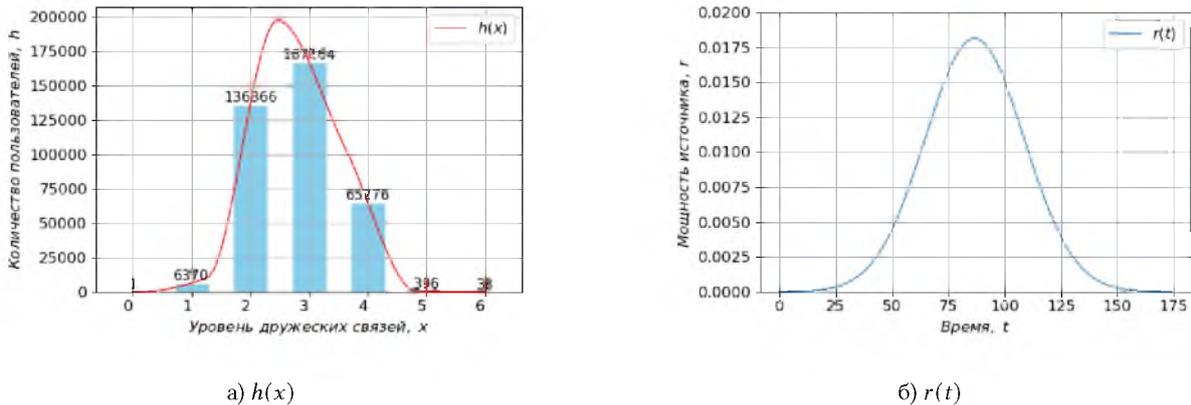


Рис. 1. Подобранные функции: (а) пропускная способность $h(x)$; (б) функция активности $r(t)$

Fig. 1. Fitted functions: (a) capacity $h(x)$; (b) activity function $r(t)$

На рис. 2 показаны результаты моделирования. Сплошная линия – это полученное значение состояния $v(x, t_1)$ модели (7) к моменту стабилизации потока информации. Диаграмма на том же рисунке – это дискретное представление информации в графе кластера сети, полученное осреднением, согласно формуле (2). Как видно, дискретизация состояний модели в точках i визуально совпадает с реальными данными.

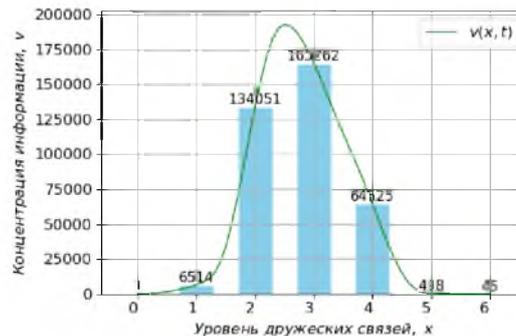


Рис. 2. Моделирование состояния информации в сети в момент t_1

Fig. 2. Simulation of the information state in the network at time t_1

Значения смоделированного состояния $v_i(t_1) = \{1, 6514, 134051, 165262, 64525, 498, 45\}$, нормализованная среднеквадратическая ошибка 0,7%. Это свидетельствует о высокой достоверности модели (7) и справедливости изначальной гипотезы о физических принципах диффузии информации в социальной сети.

Для практического использования диффузионной модели (7) необходимо автоматизировать процесс подбора достоверных коэффициентов модели. Это может реализовываться с помощью параметрической идентификации оптимальных значений коэффициентов. Для её решения целесообразно использовать методы оптимизации с регулируемым направлением спуска [14], которые могут обеспечить равномерную сходимость к оптимальным значениям функций $h(x)$ и $r(t)$ за конечное, небольшое число итераций. Постановка и решение подобной задачи для линейной диффузионной модели имеется в работе [15]. Стоит отметить, что аналогичные подходы к решению коэффициентных обратных задач, основанные на сведении к задаче оптимизации и применении градиентных методов с использованием сопряженных задач, успешно применяются и в других областях, например, в иммунологии и эпидемиологии [16].

5. Заключение. В предложенной модели диффузии информации, в отличие от существующих диффузионных моделей, параметры имеют физическую интерпретацию, что позволяет оценивать источник информации и кластер сети вокруг него, а также позволяет перейти от качественных к количественным оценкам, значимым для прикладного анализа. Также получено условие нормировки функции активности пользователей для предложенной модели.

Результаты тестовых расчётов на реальных данных показали возможность моделирования с высокой точностью. Это подтверждает правомерность исходной гипотезы о применимости законов физической диффузии к описанию информационных потоков в социальных сетях.

Список литературы

1. Granovetter M. Threshold Models of Collective Behavior. *American Journal of Sociology*. 1978;83(6):1420–1443.
2. Kempe D., Kleinberg J., Tardos E. Maximizing the Spread of Influence through a Social Network. *Proceedings of the ninth ACM SIGKDD international conference on Knowledge discovery and data mining*. 2003:137–146.
3. Daley D.J., Gani J. Epidemic Modelling: An Introduction. Cambridge: Cambridge University Press; 1999. 234 p.
4. Dritsas E., Trigka M. Machine Learning in Information and Communications Technology: A Survey. *Information*. 2024;16(1):8. <https://doi.org/10.3390/info16010008>
5. Wang F., Wang H., Xu K. Characterizing Information Diffusion in Online Social Networks with Linear Diffusive Model. *2013 IEEE 33rd International Conference on Distributed Computing Systems*. 2013:307–316. <https://doi.org/10.1109/ICDCS.2013.14>
6. Hu Y., Song R.J., Chen M. Modeling for Information Diffusion in Online Social Networks via Hydrodynamics. *IEEE Access*. 2017;5:128–135. <https://doi.org/10.1109/ACCESS.2016.2605009>
7. Krivorotko O., Zvonareva T., Zyatkov N. Numerical Solution of the Inverse Problem for Diffusion-Logistic Model Arising in Online Social Networks. In: A. Strekalovsky et al. (eds.) MOTOR 2021, CCIS 1476. Cham: Springer; 2021:444–459. https://doi.org/10.1007/978-3-030-86433-0_31
8. Arabov M., Shaydullina A. Identification of the Original Author of a Social Media Post Based on Text Analysis, Time Dependencies, and the Structure of Reposts Using Combined Neural Networks. *2025 International Conference on Industrial Engineering, Applications and Manufacturing (ICIEAM)*. 2025:437–441.
9. Звонарева Т.А., Кабанихин С.И., Криворотько О.И. Численный алгоритм определения источника диффузионно-логистической модели по данным интегрального типа, основанный на тензорной оптимизации. *Журнал вычислительной математики и математической физики*. 2023;63(9):1513–1523. <https://doi.org/10.31857/S0044466923090193>
10. Ben-Avraham D., Barrat A., Barthelemy M., Vespignani A. Dynamical Processes on Complex Networks. *Journal of Statistical Physics*. 2009;135:773–774. <https://doi.org/10.1007/s10955-009-9761-x>
11. Nicosia V., Latora V. Measuring and modeling correlations in multiplex networks. *Physical Review E*. 2015;92:032805. <https://doi.org/10.1103/PhysRevE.92.032805>
12. Lazer D.M.J., Pentland A., Watts D.J., et al. Computational social science: Obstacles and opportunities. *Science*. 2020;369(6507):1060–1062. <https://doi.org/10.1126/science.aaz8170>
13. De Domenico M., Lima A., Mougél P., Musolesi M. The Anatomy of a Scientific Rumor. *Scientific Reports*. 2013;3(2980):1–9. <https://doi.org/10.1038/srep02980>
14. Толстых В.К. Практическая оптимизация, идентификация распределенных систем. М.: Наука; 2025. 355 с.
15. Tolstykh M.A. Identifying the Capacity of a Social Network. *Moscow University Computational Mathematics and Cybernetics*. 2024;48(1):59–64. <https://doi.org/10.3103/S0278641924010084>
16. Кабанихин С.И., Криворотько О.И. Оптимизационные методы решения обратных задач иммунологии и эпидемиологии. *Журнал вычислительной математики и математической физики*. 2020;60(4):590–600. <https://doi.org/10.31857/S0044466920040109>

References

1. Granovetter M. Threshold Models of Collective Behavior. *American Journal of Sociology*. 1978;83(6):1420–1443.
2. Kempe D, Kleinberg J, Tardos E. Maximizing the Spread of Influence through a Social Network. *Proceedings of the ninth ACM SIGKDD international conference on Knowledge discovery and data mining*. 2003:137–146.
3. Daley DJ, Gani J. Epidemic Modelling: An Introduction. Cambridge: Cambridge University Press; 1999. 234 p.
4. Dritsas E, Trigka M. Machine Learning in Information and Communications Technology: A Survey. *Information*. 2024;16(1):8. <https://doi.org/10.3390/info16010008>
5. Wang F, Wang H, Xu K. Characterizing Information Diffusion in Online Social Networks with Linear Diffusive Model. *2013 IEEE 33rd International Conference on Distributed Computing Systems*. 2013:307–316. <https://doi.org/10.1109/ICDCS.2013.14>
6. Hu Y, Song RJ, Chen M. Modeling for Information Diffusion in Online Social Networks via Hydrodynamics. *IEEE Access*. 2017;5:128–135. <https://doi.org/10.1109/ACCESS.2016.2605009>
7. Krivorotko O, Zvonareva T, Zyatkov N. Numerical Solution of the Inverse Problem for Diffusion-Logistic Model Arising in Online Social Networks. In: A. Strekalovsky et al. (eds.) MOTOR 2021, CCIS 1476. Cham: Springer; 2021:444–459. https://doi.org/10.1007/978-3-030-86433-0_31
8. Arabov M, Shaydullina A. Identification of the Original Author of a Social Media Post Based on Text Analysis, Time Dependencies, and the Structure of Reposts Using Combined Neural Networks. *2025 International Conference on Industrial Engineering, Applications and Manufacturing (ICIEAM)*. 2025:437–441.
9. Zvonareva TA, Kabanikhin SI, Krivorotko OI. Numerical Algorithm for Source Determination in a Diffusion-Logistic Model from Integral Data Based on Tensor Optimization *Computational Mathematics and Mathematical Physics*. 2023;63:1654–1663. <https://doi.org/10.1134/S0965542523090166>
10. Ben-Avraham D, Barrat A, Barthelemy M, Vespignani A. Dynamical Processes on Complex Networks. *Journal of Statistical Physics*. 2009;135:773–774. <https://doi.org/10.1007/s10955-009-9761-x>
11. Nicosia V, Latora V. Measuring and modeling correlations in multiplex networks. *Physical Review E*. 2015;92:032805. <https://doi.org/10.1103/PhysRevE.92.032805>
12. Lazer D.M.J., Pentland A., Watts D.J., et al. Computational social science: Obstacles and opportunities. *Science*. 2020;369(6507):1060–1062. <https://doi.org/10.1126/science.aaz8170>
13. De Domenico M, Lima A, Mougél P, Musolesi M. The Anatomy of a Scientific Rumor. *Scientific Reports*. 2013;3(2980):1–9. <https://doi.org/10.1038/srep02980>
14. Tolstykh VK. Prakticheskaya optimizatsiya, identifikatsiya raspredelennykh sistem [Practical optimization, identification of distributed systems]. Moscow: Nauka; 2025. 355 p. (In Russian)
15. Tolstykh MA. Identifying the Capacity of a Social Network. *Moscow University Computational Mathematics and Cybernetics*. 2024;48(1):59–64. <https://doi.org/10.3103/S0278641924010084>
16. Kabanikhin S.I., Krivorotko O.I. Optimization Methods for Solving Inverse Immunology and Epidemiology Problems. *Computational Mathematics and Mathematical Physics*. 2020;60:580–589. <https://doi.org/10.1134/S0965542520040107>

Конфликт интересов: о потенциальном конфликте интересов не сообщалось.

Conflict of interest: no potential conflict of interest related to this article was reported.

Поступила в редакцию 30.09.2025

Received September 30, 2025

Поступила после рецензирования 10.11.2025

Revised November 10, 2025

Принята к публикации 20.11.2025

Accepted November 20, 2025

СВЕДЕНИЯ ОБ АВТОРЕ

Толстых Маргарита Анатольевна – младший научный сотрудник НОМЦ «Математический центр ДонГУ», Донецкий государственный университет, г. Донецк, Россия

INFORMATION ABOUT THE AUTHOR

Margarita A. Tolstykh – Junior Research Assistant of SEMC “Mathematical Center of DonSU”, Donetsk State University, Donetsk, Russia

[К содержанию](#)