

Усольцев Дмитрий Андреевич

**Методы вероятностной кластеризации для интерпретации
матричной и графовой информации в разнородных базах данных**

Диссертация на соискание учёной степени кандидата технических наук
Специальность 2.3.8.


«Информатика и информационные процессы (технические науки)»

Научный руководитель: доктор техн. наук, профессор Шалыто Анатолий Абрамович



Санкт-Петербург – 2025

Актуальность 1/10

Проблема: ранняя диагностика рисков хронических заболеваний



Для определения этих факторов хронических заболеваний необходимо создание больших баз данных с помощью специальных методов.



Матричная информация

Популяционная выборка большого числа индивидов

- Генотипирование ДНК
- демография
- анкеты
- лабораторные показатели

Исходная информация
для формирования
медицинской генетической базы
данных

Графовая информация


- взаимосвязи между генами или белками

Современные медико-генетические базы данных представляют собой гибридные хранилища, объединяющие матричные и графовые форматы данных.

Аннотация (интерпретация) является важным процессом при формировании медико-генетической базы данных.

Аннотация – процесс присвоения объектам базы данных стандартизованных функциональных значений, обладающих смыслом. Например, если в строке указан идентификатор пациента, аннотация заключается в сопоставлении ему группы (контрольной или тестовой). Обычно аннотация выполняется вручную, однако в диссертации предлагаются методы, автоматизирующие этот процесс. Одна из трудностей аннотации состоит в том, что база данных может содержать десятки тысяч строк.


Этапы формирования медико-генетической базы данных



1. Отбор контрольной группы для проведения сравнения между больными и здоровыми индивидами.
2. Статистический тест между контрольной и тестовой группами по частотам мутаций или уровню клинических показателей.
3. Присвоение генов мутациям и биомаркерам, выявленным в ходе статистического теста.

Аннотация информации. Примеры

Примеры аннотирования информации




Методы кластеризации

Аннотация может быть выполнена методами кластеризации.


Актуальна разработка и улучшение точности **методов вероятностной кластеризации** для аннотирования матричной и графовой информации в медико-генетических базах данных.

Виды методов кластеризации

Дискретная кластеризация



Вероятностная кластеризация



Вершины однозначно распределены по кластерам:
каждая вершина принадлежит только одному
кластеру

Каждой вершине соответствует распределение
вероятностей принадлежности к кластерам

Требования к методам кластеризации

1. Масштабируемость – эффективная работа с большими объемами данных.
2. Наличие вероятностной оценки – наличие вероятностной интерпретации полученных результатов.
3. Устойчивость к шумным данным – корректная работа при наличии выбросов и аномальных наблюдений в реальных данных.
4. Возможность интеграции априорных знаний – возможность учитывать экспертную информацию и внешние источники знаний.

Недостатки существующих методов кластеризации

Подходы	Масштабируемость	Вероятностная оценка	Устойчивость к шуму	Возможность интеграции априорных знаний
k-means ¹	Да	Нет	Нет	Нет
DBSCAN ²	Да	Нет	Да	Нет
метод Монте-Карло по схеме марковских цепей (МЦМК) (Markov Chain Monte Carlo – MCMC) ³	Да	Да	Да	Частично (начальное распределение вероятностей на вершинах)
Подход на основе поиска подграфа максимального веса (Maximum Weight Connected Subgraph – MWCS) ⁴	Да	Нет	Нет	Нет
Метод графовой кластеризации для совместного анализа результатов генотипирования и экспрессии генов (диссертация Александра Лободы) ⁵	Да	Нет	Нет	Нет

1. MacQueen J. Some methods for classification and analysis of multivariate observations // In Proceedings of the fifth Berkeley symposium on mathematical statistics and probability. 1967. V. 1. N 14. P. 281–297.
2. Ester M., Kriegel H.P., Sander J., Xu X. A Density-Based Algorithm for Discovering Clusters in Large Spatial Databases with Noise // In Proceedings of the Second International Conference on Knowledge Discovery and Data Mining (KDD-96). AAAI Press. 1996. P. 226–231.
3. Alexeev N., Isomurodov J., Sukhov V., et al. Markov chain Monte Carlo for active module identification problem // BMC Bioinformatics. 2020. V. 21. Article number: 261.
4. Dittrich M.T., Klau G.W., Rosenwald A., Dandekar T., Müller T. Identifying functional modules in protein-protein interaction networks: an integrated exact approach // Bioinformatics. 2008. V. 24. P. 223–231.
5. Лобода А.А. Метод графовой кластеризации для совместного анализа данных генотипирования и экспрессии генов Диссертация на соискание ученой степени кандидата технических наук / Лобода А.А. Университет ИТМО. 2022.

Цель и задачи диссертационной работы

Повышение качества кластеризации в задачах матричного и графового анализа разнородных баз данных за счет использования априорных знаний, что позволит в таблице, приведенной на предыдущем слайде во всех столбцах ответить “Да”.

Задачи, решаемые в диссертации:

- обзор современных методов вероятностной кластеризации матричных и графовых данных, а также статистических методов, применяемых для разработки медико-генетических баз данных с разнородной информацией;
- разработка вероятностного метода матричной кластеризации на основе априорного распределения признаков для формирования несмешенного набора данных;
- разработка вероятностного метода графовой кластеризации на основе методов Монте-Карло по схеме марковских цепей и априорной информации, интегрируемой с помощью машинного обучения, для выявления кластеров, обладающих целевыми признаками;
- апробация и внедрение результатов исследования на основе методики, использующей предложенные вероятностные методы для учёта априорных знаний с целью повышения качества кластеризации при анализе баз данных с разнородной информацией.

Положения, выносимые на защиту

1. **Вероятностный метод кластеризации для формирования набора данных**, использующий сингулярное разложение матриц, отличающийся тем, что **с целью снижения вероятности ложноположительных результатов при сравнении двух наборов данных**, в нём применяются расстояние Махalanобиса и априорное распределение признаков.
2. **Вероятностный метод графовой кластеризации**, использующий метод Монте-Карло по схеме марковских цепей, отличающийся тем, что **с целью повышения точности кластеризации**, в нем используется априорная информация, учитываемая с помощью машинного обучения, и несколько источников априорных знаний.
3. **Методика анализа данных в разнородных базах**, основанная на сравнительном анализе и последующей графовой кластеризации его результатов, отличающаяся тем, что **с целью повышения качества кластеризации**, она включает предложенные вероятностные методы матричной и графовой кластеризации.

Научной новизной обладают первые два положения, а третье – имеет важное практическое значение.

Тринадцатый пункт паспорта специальности: «Разработка и применение методов распознавания образов, кластерного анализа, нейро-сетевых и нечетких технологий, решающих правил, мягких вычислений при анализе разнородной информации в базах данных».

Предложен **вероятностный метод матричной кластеризации** с априорным распределением признаков, сокращающий систематические смещения при формировании контрольных выборок.

Разработан **вероятностный метод графовой кластеризации** с использованием методов Монте-Карло по схеме марковских цепей и машинного обучения. Разработанные методы были применены автором, в том числе к разработанной в ходе диссертационного исследования медико-генетической базе данных Российской популяции (МГБД-Р), и показали более высокое качество кластеризации в сравнении с аналогами.

Вероятностный метод кластеризации для формирования набора данных, использующий сингулярное разложение матриц, отличающийся тем, что с целью снижения вероятности ложноположительных результатов при сравнении двух наборов данных, в нём применяются расстояние Махalanобиса и априорное распределение признаков.

Задача

Предположим, имеется два набора данных – тестовый и контрольный. В тестовом наборе собрана информация о пациентах, у которых наблюдается определённое заболевание или особый фенотип, а в контрольном наборе данные большой популяции людей без данного диагноза. Возникает задача найти в обширном контрольном наборе подгруппу, которая будет максимально похожа на тестовую группу по ключевым факторам, чтобы избежать систематических искажений при сравнительном анализе.

Аналоги: метод ближайшего соседа¹, DBSCAN²

Прототип: метод ближайшего соседа

Недостатки прототипа: отсутствует вероятностная оценка, не учитывается априорное предположение о распределении признаков в тестовом наборе данных

1. Ikotun A. M., Ezugwu A. E., Abualigah L., Abuhaija B. and Heming J. K-means clustering algorithms: a comprehensive review, variants analysis, and advances in the era of big data // Inf. Sci. 2023. V. 622. P. 178–210.
2. Jianwei Li, Anna Zheng, Wei Guo, Nairwita Bandyopadhyay, Yanji Zhang & Qianfeng Wang Urban flood risk assessment based on DBSCAN and K-means clustering algorithm // Geomatics, Natural Hazards and Risk. 2023. V. 14. N. 1. Article Number: 2250527.

Метод состоит из двух этапов:

1. Снижение размерности тестового и контрольного наборов данных.
2. Вероятностная кластеризация в пространстве признаков главных компонент.


Снижение размерности тестового и контрольного наборов данных (1/2)

Пусть A_1 и A_2 – матрицы признаков; $\dim(A_1) = n_1 \times m$, $\dim(A_2) = n_2 \times m$, где m – число различных характеристик (например, возраст, пол, различные лабораторные показатели, социальные факторы), n_1 – число участников в тестовой группе, n_2 – в контрольной.

- 1.1. В тестовом наборе $A_1 \in \mathbb{R}^{n_1 \times m}$ вычисляются средние значения по каждому столбцу. Эти средние значения затем вычитываются из обеих матриц A_1 и $A_2 \in \mathbb{R}^{n_2 \times m}$, что обеспечивает выравнивание выборок по среднему значению признаков и устраняет глобальные линейные смещения.
- 1.2. К матрице A_1 применяется сингулярное разложение¹: $A_1 = U \Sigma V^T$, где $U \in \mathbb{R}^{n_1 \times n_1}$ – матрица левых сингулярных векторов, Σ – диагональная матрица сингулярных чисел, $V \in \mathbb{R}^{m \times m}$ – матрица правых сингулярных векторов. Из матрицы U выбираются первые k столбцов, соответствующих наибольшим сингулярным числам. Полученная матрица $\hat{U} \in \mathbb{R}^{n_1 \times k}$ определяет проекцию в подпространство наибольшей дисперсии.
- 1.3. Проекции обоих наборов данных вычисляются следующим образом: $\hat{A}_1 = \hat{U}A_1$ и $\hat{A}_2 = \hat{U}A_2$, соответственно. Каждая строка матрицы \hat{A}_1 и \hat{A}_2 теперь представляет наблюдение в новом пространстве признаков размерности k общем для обеих выборок. Это обеспечивает сопоставимость обоих наборов данных.

1. Brunton S.L., Kutz J.N. Singular Value Decomposition (SVD) // Data-Driven Science and Engineering: Machine Learning, Dynamical Systems, and Control. Cambridge: Cambridge University Press. 2019. P. 3–46.

Снижение размерности тестового и контрольного наборов данных (2/2)



2.1. Оценка априорного распределения признаков в тестовой выборке. После проекции на пространство главных компонент \hat{A}_1 , компоненты тестовой выборки рассматриваются как реализация случайной величины, подчиняющейся многомерному нормальному распределению. Оцениваются вектор математических ожиданий $\mu \in \mathbb{R}^k$ и ковариационная матрица $\Sigma \in \mathbb{R}^{k \times k}$, задающие априорное распределение признаков: $\hat{A}_1 \sim N(\mu, \Sigma)$.


2.2. Формулировка вероятностного критерия принадлежности. Для каждого объекта $x \in \hat{A}_2$ вычисляется расстояние Махalanобиса¹ как мера правдоподобия его принадлежности к распределению тестовой выборки: $D_M(x) = \sqrt{(x - \mu)^T \Sigma^{-1} (x - \mu)}$. Таким образом, каждый объект из контрольной выборки получает количественную оценку степени принадлежности к априорному распределению.

2.3. Выделение вероятностного кластера. В отличие от детерминированного отнесения объектов к кластерам, используется вероятностный критерий: объект включается в кластер \hat{S}_2 , если значение $D_M(x)$ не превышает порог, соответствующий 95 %-квантилю распределения хи-квадрат с k степенями свободы. Это соответствует включению в доверительную область уровня 0.95 для многомерного нормального распределения. Таким образом, кластер $\hat{S}_2 \subseteq A_2$ формируется как $\hat{S}_2 = \{x \in A_2 \mid D_M(\hat{U}^T x) \leq \chi_{k, 1-\alpha}^2\}$.

1. Ghosh A., Ghosh A.K., SahaRay R., Sarkar S. Classification using global and local Mahalanobis distances // Journal of Multivariate Analysis. 2025. V. 207. Article number: 105417.

2.1

Вычисление средних значений и
ковариационной матрицы
первых k компонент




2.2

Формулировка
вероятностного
критерия
принадлежности



2.3

Выделение вероятностного кластера




PC1

PC1 – первая главная компонента
PC2 – вторая главная компонента

- 2.1. Оценка априорного распределения признаков в тестовой выборке.
- 2.2. Формулировка вероятностного критерия принадлежности.
- 2.3. Выделение вероятностного кластера.

Экспериментальная валидация метода

Контрольная и тестовая группы симулируются из одного нормального распределения



А. Метод ближайшего соседа отбирает заданное число контрольных образцов, в то время как предлагаемый метод отбирает все контрольные образцы из распределения, соответствующего тестовой выборке.

Контрольная и тестовая группы симулируются из разных нормальных распределений




- Тестовая выборка
- Отобранные контрольные образцы
- Остальные контрольные образцы

PC1 – первая главная компонента
PC2 – вторая главная компонента


Б. Метод ближайшего соседа отбирает ложно-положительные контрольные образцы из распределения, не соответствующего тестовому распределению, в то время как предложенный метод не отбирает такие контрольные образцы.

Первое положение, выносимое на защиту 9/10

Практическое применение метода



Исследование потомков жителей блокадного Ленинграда



Клиническое исследование:

1. Тестовая группа (желтая) – потомки жителей блокадного Ленинграда с особым паттерном питания (Рисунок А).
2. Контрольная группа (серая), подобранная без предложенного метода (отличалась от тестовой группы по распределению факторов питания) (Рисунок А)
3. Контрольная группа (зеленая) – выборка из популяции с помощью предложенного метода (схожая с тестовой группой по распределению факторов питания) (Рисунок Б).
4. **Предложенный метод позволил подтвердить отсутствие ложно-положительных результатов в сравнительном анализе работы почек между потомками жителей блокадного Ленинграда и контрольной популяцией.**

Метод позволяет подобрать контрольный набор данных с минимизацией систематических отличий по ключевым признакам относительно тестового набора данных. При сравнении этих наборов данных результирующая статистическая значимость (*p*-значение) является более достоверной.

Выводы по первому положению, выносимому на защиту

1. Предлагаемый метод позволяет подобрать контрольный набор данных с минимизацией систематических отличий по выбранным признакам относительно тестового набора данных за счет учета априорных знаний о распределении признаков в тестовом наборе данных и вероятностной оценки принадлежности наблюдений к кластерам. Это особенно важно в медицинских исследованиях (например, в эпидемиологических), где точность статистических выводов имеет первостепенное значение.
2. Предлагаемый метод был использован при исследовании межпоколенческих эффектов потомков жителей блокадного Ленинграда на особенности их физиологии. Исследование проведено в Национальном медицинском исследовательском центре имени В.А. Алмазова.

Научные результаты опубликованы в:

1. Усольцев Д.А. Вероятностный метод матричной кластеризации с априорным распределением признаков для формирования несмещенной контрольной группы // Научно-технический вестник информационных технологий, механики и оптики. 2025. Т. 25, № 5. С. 999–1001.
2. Usoltsev D., Tolkunova K., Moguchaia E. et al. Transgenerational and intergenerational effects of early childhood famine exposure in the cohort of offspring of Leningrad Siege survivors // Scientific Reports. 2023. V. 13. Article number: 11188.

Вероятностный метод графовой кластеризации, использующий метод Монте-Карло по схеме марковских цепей, отличающийся тем, что **с целью повышения точности кластеризации**, в нем используется априорная информация, учитываемая с помощью машинного обучения, и несколько источников априорных знаний.


Второе положение, выносимое на защиту 2/14

Задача графовой кластеризации

Графовая кластеризация состоит в том, чтобы по заданному множеству взаимосвязанных объектов выделить группы (кластеры) вершин, которые максимально похожи друг на друга и существенно отличаются от вершин других групп.

Задача графовой кластеризации сводится к задаче поиска в графе функционального подграфа (кластера) – активного модуля, вершины которого выполняют конкретную совместную функцию. Важно повысить точность нахождения этого модуля.


Схема активного модуля внутри белковой сети



Как правило, заранее известны некоторые вершины функционального кластера

- Carbone M., Yang H., Pass H.I., Krausz T., Testa J.R., Gaudino G. BAP1 and cancer // Nat Rev Cancer. 2013. V. 13. N 3. P. 153–159.

Пример активного модуля. Bap1-комплекс¹, участвующий в восстановлении ДНК. Красным показаны белки, образующие Bap1-комплекс.



Bap1 – белковый комплекс, центральным компонентом которого является белок Bap1

Текущие решения задачи графовой кластеризации

Аналоги: метод Монте-Карло по схеме марковских цепей¹, метод подграфа наибольшего веса^{2,3}, метод Фишера⁴

Прототип: метод Монте-Карло по схеме марковских цепей

Недостаток прототипа: прототип не в полной мере учитывает априорную информацию об известных вершинах

1. Alexeev N., Isomurodov J., Sukhov V., Korotkevich G., Sergushichev A. Markov chain Monte Carlo for active module identification problem // BMC Bioinformatics. 2020. V. 21. Article number: 261.
2. Лобода А.А. Метод графовой кластеризации для совместного анализа данных генотипирования и экспрессии генов Диссертация на соискание ученой степени кандидата технических наук / Лобода А.А. Университет ИТМО. 2022.
3. Dittrich M.T., Klau G.W., Rosenwald A., Dandekar T., Müller T. Identifying functional modules in protein-protein interaction networks: an integrated exact approach // Bioinformatics. 2008. V. 24. P. 223–231.
4. Ham H., Park T. Combining p-values from various statistical methods for microbiome data // Front Microbiol. 2022. V. 13. Article number: 990870.


1. Учет нескольких источников экспериментов

1.1. Для каждого набора p -значений, соответствующих вершинам графа, применяется метод Фишера:

вычисляется $X^2 = -2\sum_{i=1}^n \ln(p_i)$, $0 < p_i \leq 1$, и результирующие p -значения по формуле $p_{comb} = P(\chi^2 \geq X^2, df = 2*n)$,

n – число экспериментов

Статистическая значимость из одного эксперимента



Метод Фишера¹




$$X^2 = -2\sum_{i=1}^n \ln(p_i), \quad 0 < p_i \leq 1,$$

$$p_{comb} = P(\chi^2 \geq X^2, df = 2n)$$

p_i – p -значение i -го эксперимента;
 X^2 – статистика хи-квадрат;
 χ^2 – распределение хи-квадрат;
 p_{comb} – результирующее p -значение;
 P – вероятность;
 df – степень свободы.

Результирующая статистическая значимость



- Ham H., Park T. Combining p -values from various statistical methods for microbiome data // Front. Microbiol. 2022. V. 13. Article number: 990870.

Описание метода (2/6). Вычисление признаков каждой вершины (1/4). ИТМО

Первый признак (1/3)



2.1. **Первый признак** – вероятность вхождения вершины в функциональный кластер, определяется по p -значениям. Для каждой вершины вероятность определяется посредством аппроксимации p -значений с помощью бета-равномерного распределения. Далее вероятность того, что подграф является функциональным кластером, рассчитывается как произведение вероятностей того, что каждая вершина принадлежит этому кластеру. Для получившегося вероятностного пространства на множестве связных подграфов набирается выборка размера 100 с помощью алгоритма Монте-Карло по схеме марковских цепей (МЦМК)¹, реализованного в R-библиотеке mcmcRanking (v0.1.0)², используя 10 000 итераций МЦМК. После этого для каждой вершины определяется эмпирическая вероятность вхождения в функциональный кластер – доля подграфов из выборки, которые включают в себя эту вершину.

1. Alexeev N., Isomurodov J., Sukhov V., Korotkevich G., Sergushichev A. Markov chain Monte Carlo for active module identification problem // BMC Bioinformatics. 2020. V. 21. Article number: 261.
2. GitHub – ctlab/mcmcRanking: Tool To Solve The Active Module Problem. [Электронный ресурс] – Режим доступа: <https://github.com/ctlab/mcmcRanking>, свободный. Яз. англ. (дата обращения 15.12.2024).

Описание метода (3/6). Вычисление признаков каждой вершины (2/4).


Первый признак (2/3)

Эмпирическое распределение р-значений аппроксимируется бета-равномерным распределением¹



1. $f(p) = \lambda + (1 - \lambda)\alpha p^{\alpha-1}, 0 \leq \lambda, \alpha \leq 1, 0 < p \leq 1,$
2. $pFDR = \left(\frac{\lambda + (1 - \lambda)\alpha - FDR * \lambda}{FDR(1 - \lambda)} \right)^{\frac{1}{\alpha-1}}, 0 \leq \lambda, \alpha \leq 1,$
3. $w(p) = \left(\frac{p}{pFDR} \right)^{\alpha-1}, 0 \leq \alpha \leq 1, 0 < p \leq 1$

Аппроксимация р-значений (p) с помощью бета-равномерного распределения¹ с параметрами:
 λ – вес равномерной компоненты;
 α – параметр формы бета-компоненты для заданного уровня ложноположительных результатов (FDR).
 $pFDR$ – вероятность того, что р-значение принадлежит равномерному распределению;
 w_i – вес i -ой вершины




1. Dittrich M.T., Klau G.W., Rosenwald A., Dandekar T., Müller T. Identifying functional modules in protein-protein interaction networks: an integrated exact approach // Bioinformatics. 2008. V. 24. P. 223–231.


Описание метода (4/6). Вычисление признаков каждой вершины (3/4). **УИТМО**

Первый признак (3/3)

Вероятность того, что подграф является функциональным кластером, рассчитывается как произведение вероятностей того, что каждая вершина принадлежит этому кластеру. Для получившегося вероятностного пространства на множество связных подграфов набирается выборка размера 100 с помощью алгоритма МЦМК, реализованного в R-библиотеке mcmcRanking (v0.1.0), используя 10 000 итераций МЦМК. После этого для каждой вершины определяется эмпирическая вероятность вхождения в функциональный кластер – доля подграфов из выборки, которые включают в себя эту вершину.




Метод Монте-Карло по схеме
марковских цепей (МЦМК)



Вывод: применение метода МЦМК позволяет определить вероятность принадлежности вершины функциональному кластеру, однако метод не учитывает уже известные вершины. Поэтому на следующих слайдах этот недостаток устранен.

2.2. Три признака, описывающие каждую вершину, определяются как расстояния до трех ближайших известных вершин функционального кластера.



Вершины	Расстояние ₁	...
Вершина ₁	2	...
Вершина ₂	3	...
Вершина ₃	1	...
...

Описание метода (6/6)

3. Обучение модели градиентного бустинга для предсказания принадлежности вершины функциональному кластеру

Используя полученные признаки, обучается модель градиентного бустинга – xgboost¹. Она реализована в R-библиотеке xgboost (v1.5.0.2)². Максимальная глубина каждого дерева в модели равняется трем. Параметр скорости обучения – 0.1. Число итераций обучения равно трем. Известные вершины в функциональных кластерах исключаются. При тренировке модели вершинам, включенным в функциональный кластер, присваивается единица, а остальным вершинам – ноль.

Вершины	Расстояние ₁	МЦМК	...
Вершина ₁	2	0.4	...
Вершина ₂	3	0.2	...
Вершина ₃	1	0.6	...
...

Модель градиентного бустинга



Вершины	Скор
Вершина ₁	0.8
Вершина ₂	0.7
Вершина ₃	0.9
...	...

- Chen T., Guestrin C. XGBoost: A Scalable Tree Boosting System // In Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York. NY. USA. ACM. 2016. P. 785–794.
- Chen T., He T., Benesty M., Khotilovich V., et al. xgboost: Extreme Gradient Boosting. R package version 1.5.0.2. [Электронный ресурс] – Режим доступа: <https://CRAN.R-project.org/package=xgboost>, свободный. Яз. англ. (дата обращения 17.08.2024)

Валидация метода (1/4)


Валидация метода на симулированных данных

1. Для получения графов с топологией, встречающейся в реальных данных, выбираются 100 случайных подграфов из графа белок-белковых взаимодействий InWeb_InBioMap (InWebIM)¹ с числом вершин равным 1000.
2. В каждом подграфе InWebIM из пункта 1.1 равновероятно среди всех возможных связных подграфов заданного размера выбирается активный модуль с использованием метода МЦМК из R-библиотеки mcmcRanking (v0.1.0) при условии, что все вершины имеют одинаковый вес. Модули выбираются после 1000 итераций МЦМК, чтобы гарантировать их независимость от подграфов, использованных для инициализации МЦМК.
3. Для каждой вершины симулируются *p*-значения эксперимента, проверяющего принадлежность вершины активному модулю. Для вершин вне активного модуля *p*-значения выбираются из равномерного распределения, для вершин из активного модуля – из бета-распределения.
4. Так как общее число функциональных модулей равняется 100, то 50 используются для тренировки модели, а оставшиеся 50 – для тестирования.

1. Li T., Wernersson R., Hansen R.B., Horn H., et al. A scored human protein-protein interaction network to catalyze genomic interpretation // Nat Methods. 2017. V. 14. N 1. P. 61–64.


Валидация метода (2/4)

Активные модули симулированы поиском в ширину



А-Б – активные
модули размера 100;
В-Г – активные
модули размера 50

Активные модули симулированы равномерно




А-Б – активные
модули размера 100;
В-Г – активные
модули размера 50

Предлагаемый метод **позволяет повысить точность графовой кластеризации по сравнению с методом только на основе МЦМК** за счет учета априорных знаний с помощью машинного обучения в случае симметричных кластеров от пяти до 20% ROC AUC (от шести до 30% Recall@100) и сохраняет точность в случае кластеров со случайной структурой. (ROC AUC – это стандартная метрика качества бинарных классификаторов в машинном обучении, где значение варьируется от нуля до одного, где один – идеальное разделение классов, а 0,5 – случайное угадывание. Recall@100 – доля правильно определенных вершин активного модуля в первой сотне вершин, ранжированных по уменьшению предсказанной с помощью модели вероятности вхождения в активный модуль).

Валидация метода (3/4)

Активные модули симулированы случайным поиском в белок-белковом графе InWebIM.





А-Г – активные модули
размера 100;
Д-З – активные модули
размера 50

Предложенный метод работает также или лучше, чем метод Фишера без учета графовой структуры (значения критерия ROC AUC выше от одного до 30%, значения критерия Recall@100 выше от одного до 100% на симулированных данных).

Валидация метода (4/4)

Валидация метода на реальных данных исследования шизофрении¹



Предлагаемый метод в среднем на 13 % точнее (согласно метрике качества ROC AUC для одного эксперимента) определил причинные гены шизофрении, чем метод Фишера без учета графовой структуры.

- Pardiñas A.F., Holmans P., Pocklington A.J. et. al. Common schizophrenia alleles are enriched in mutation-intolerant genes and in regions under strong background selection // Nat Genet. 2018. V. 50. N 3. P. 381–389.

Выводы по второму положению, выносимому на защиту

1. Метод позволяет повысить точность графовой кластеризации за счет учета априорных знаний с помощью машинного обучения в случае симметричных кластеров и сохраняет точность в случае кластеров со случайной структурой. Это обеспечивает его устойчивость по сравнению с использованием только метода на основе МЦМК или классических методов, таких как метод Фишера, не учитывающих графовые зависимости.
2. Метод позволяет интегрировать результаты нескольких экспериментов. Это позволяет значительно повысить точность определения кластеров.

Научные результаты опубликованы в:

1. Усольцев Д.А., Молотков И.И., Артемов Н.Н., Сергуничев А.А., Шалыто А.А. Применение марковских цепей Монте-Карло и машинного обучения для нахождения активного модуля в биологических графах // Научно-технический вестник информационных технологий, механики и оптики. 2024. Т. 24, № 6. С. 962–971.
2. Усольцев Д.А., Молотков И.И., Артемов Н.Н., Сергуничев А.А., Шалыто А.А. Метод определения активного модуля в биологических графах с многокомпонентными весами вершин // Научно-технический вестник информационных технологий, механики и оптики. 2025. Т. 25, № 3. С. 487–497.

Заключение по первому и второму положениям, выносимым на защиту

Подходы	Масштабируемость	Вероятностная оценка	Устойчивость к шуму	Возможность интеграции априорных знаний
k-means	Да	Нет	Нет	Нет
DBSCAN	Да	Нет	Да	Нет
метод Монте-Карло по схеме марковских цепей (МЦМК) (Markov Chain Monte Carlo – MCMC)	Да	Да	Да	Частично (начальное распределение вероятностей на вершинах)
Подход на основе поиска подграфа максимального веса (Maximum Weight Connected Subgraph – MWCS)	Да	Нет	Нет	Нет
Метод графовой кластеризации для совместного анализа результатов генотипирования и экспрессии генов (диссертация Александра Лободы)	Да	Нет	Нет	Нет
Предложенный метод вероятностной кластеризации матричных данных	Да	Да	Да	Да
Предложенный метод вероятностной кластеризации графовых данных	Да	Да	Да	Да

Методика анализа данных в разнородных базах, основанная на сравнительном анализе и последующей графовой кластеризации его результатов, отличающаяся тем, что с целью повышения качества кластеризации, она включает предложенные вероятностные методы матричной и графовой кластеризации.

Задача

Создание Российской медико-генетической базы данных и повышение качества анализа медико-генетической информации в ней, а также интегрирование России в международные генетические исследования для того, чтобы повысить вероятность обнаружения новых генетических рисков хронических заболеваний. Российская медико-генетическая база отсутствовала.

Описание методики

Методика включает в себя три пункта:

- разработка базы данных с разнородной информацией – медико-генетической базы данных российской популяции (МГБД-Р), состоящей из двух модулей (МГБД-Р-1 и МГБД-Р-2);
- проведение сравнительного анализа между двумя наборами данных – контрольным и тестовым, причем контрольный набор данных, находящийся в модуле МГБД-Р-1, сформирован **первым методом, выносимым на защиту**;
- аннотация результатов сравнительного анализа, хранящихся в модуле МГБД-Р-2, выполнена с использованием **второго метода, выносимого на защиту**.

Модуль МГБД-Р-1 (1/6)

Суверенная база данных с уникальной медико-генетической информацией Российской популяции

А Географическая карта сбора информации



Б



В

Структура первого модуля МГБД-Р

Закрытый вычислительный сервер с персональной информацией

Клиническая информация				Генетическая информация			
Фенотипы	Индивид ₁	Индивид ₂	...	Ген.вариант	Индивид ₁	Индивид ₂	...
Показатель ₁	10	20	...	Вариант ₁	0 0	0 0	...
Показатель ₂	0	1	...	Вариант ₂	0 0	1 0	...
Показатель ₃	0,2	0,9	...	Вариант ₃	1 0	0 0	...
...

Матрица клинических признаков

556 признаков
4 800 индивидов

Генетическая информация

Ген.вариант	Индивид ₁	Индивид ₂	...
Вариант ₁	0 0	0 0	...
Вариант ₂	0 0	1 0	...
Вариант ₃	1 0	0 0	...
...

Матрица генетических признаков

11 077 392 генетических ДНК-варианта
4 800 индивидов

Матрица является основой для определения генетической структуры, проведения статистических тестов и хранится в форматах vcf¹, hail², plink³


- Danecek P., Auton A., Abecasis G., Albers C.A., Banks E., DePristo M.A., Handsaker R.E., Lunter G., Marth G. T., Sherry S. T., et al. The Variant Call Format and VCFtools // Bioinformatics. 2011. V.27. N 15. P. 2156–2158.
- Chang C.C., Chow C.C., Tellier L.C. et al. Second-generation PLINK: rising to the challenge of larger and richer datasets // GigaScience. 2015. V. 4. Article number: 7.
- Hail Team. Hail: an open-source framework for scalable genetic data analysis // Genome Biology. 2017. V. 18. Article number: 99.

Применение первого метода, выносимого на защиту

Для построения модуля МГБД-Р-1 был применен **первый метод, выносимый на защиту**, позволяющий подобрать несмещенную контрольную группу для полногеномного ассоциативного исследования¹ (статистического теста).

Клинико-генетическое исследование:


1. Тестовая группа – индивиды с высоким уровнем липопротеина А.
2. Контрольная группа (синяя) – индивиды со схожим липидным профилем (Рисунок А).
3. Полногеномное сравнительное исследование выявило независимое влияние ДНК-варианта (rs186696265) на уровень липопротеина А (Рисунок Б).



1. Uffelmann E., Huang Q.Q., Munung N.S., et al. Genome-wide association studies // Nat Rev Methods Primers. 2021. V. 1. Article number: 59.

Новизна модуля МГБД-Р-1

Впервые для научного сообщества представлена генетическая структура Российской популяции



Автором впервые была проанализирована генетическая структура Российской популяции, показано ее генетическое родство с другими популяциями. Выявленное высокое сродство Российской популяции к финской позволяет сделать **вывод о возможности использования Российской популяции в валидационных генетических исследованиях**, проводимых в крупнейшем финском биобанке – Финнгене.

Модуль МГБД-Р-1 совместно с зарубежными МГБД лег в основу построения моделей для предсказания риска хронических заболеваний.

Входные клинико-генетические данные

История болезни, биохимия крови, генетические риски

Обученная AFT (Accelerated Failure Time) модель¹

Disease Prediction

Sex: Male

Current Age: 50

Select disease: E4_DM2

ICD-10 codes (comma/space separated): A,A1,A19,A191

Ages for ICD-10 codes (same order, comma/space separated): 34,41,55,55,29

p30010_i0 – Red blood cell (erythrocyte) count, 10 ¹² cells/Litre 4.52	p30070_i0 – Red blood cell (erythrocyte) distribution width, % 13.49	p30620_i0 – Alanine aminotransferase, U/L 23.56
p30740_i0 – Glucose, mmol/L 5.12	p30760_i0 – HDL cholesterol, mmol/L 1.45	p30780_i0 – LDL direct, mmol/L 3.56
p30840_i0 – Total bilirubin, umol/L 9.11	p30870_i0 – Triglycerides, mmol/L 1.75	p21001_i0 – BMI, kg/m ² 27.42

Smoking Status: Never smoked


Include Polygenic Risk Score (PRS)

Polygenic Risk Score: -0.000471607077805283

For E4_DM2, the model uses PGS000832.

Матрицы клинической и генетической информации служат основой для построения клинико-генетических моделей предсказания времени возникновения заболеваний.

Выходные данные: риски получения заболевания (например, диабета второго типа) в следующие 12 лет



1. Parvej M., Ali Khan A. Bayesian extension of the Weibull AFT shared frailty model with generalized family of distributions for enhanced survival analysis using censored data // J Appl Stat. 2024. V. 51. N. 15. P. 3125–3153.

Третье положение, выносимое на защиту 8/14

Модуль МГБД-Р-1 (5/6)


На основе модуля МГБД-Р-1 были построены калькуляторы рисков сердечно-сосудистых инцидентов и диабета второго типа для диагностики пациентов в ФГБУ «НМИЦ им. В. А. Алмазова»

Было получено два свидетельства о регистрации результатов интеллектуальной деятельности

Предикторы модели:

- общий холестерин;
- холестерин высокой плотности;
- систолическое артериальное давление;
- статус диабета второго типа;
- статус курения;
- статус приема антигипертензивных препаратов;
- статус приема статинов;
- скорость гломерулярной фильтрации;
- Chinese Visceral Adiposity Index (CVAI);
- значение NT-proBNP – мозгового натрийуретического гормона;
- частота употребления алкоголя;
- частота употребления сыра.

Калькуляторы основаны на модели градиентного бустинга



Предикторы модели:

- глюкоза;
- LAP (индекс накопления липидов);
- Cw2 (ожирение в соответствии с объемом талии АТРИ);
- Adn (Адипонектин);
- IAGT (Статус применения препаратов для снижения арт. давл.);
- ген FTO;
- TAG (те, кто принимает антигипертензивную терапию или арт. давл. выше 140/90 мм рт ст);
- статус нарушения сердечного ритма;
- СОМ (кто имеет арт. гиперт. и принимает терапию).


Модуль МГБД-Р-1 лег в основу клинико-генетических исследований в России

Примеры клинико-генетических исследований с участием автора:

1. Описан фенотип сосудистой жёсткости в Российской популяции, отсутствующий в крупных мировых МГБД.
2. Найдены новые патогенные ДНК-варианты для целиакии.
3. Написаны медицинские рекомендации для использования зарубежной клинической шкалы сердечно-сосудистых заболеваний в Российской популяции.
4. Найдены новые патогенные ДНК-варианты для аортального стеноза.

По всем этим исследованиям имеются публикации с участием автора.

Модуль МГБД-Р-1 суверенный



Для каждого из 556 клинических признаков, хранящихся в модуле МГБД-Р-1 был проведен полногеномный поиск ассоциаций (GWAS)¹:

Для непрерывных признаков (Y) построена линейная модель для каждого из ~8млн ДНК-вариантов (G), с учетом ковариат (C_i): пол, возраст, 10 первых принципиальных компонент генетической структуры

$$Y = \beta_0 + \beta_1 G + \beta_2 C_1 + \beta_3 C_2 + \cdots + \beta_p C_p + \epsilon$$

Для бинарных признаков (Y) построена логистическая модель для каждого из ~8млн ДНК-вариантов (G), с учетом ковариат (C_i): пол, возраст, 10 первых принципиальных компонент генетической структуры

$$P(Y = 1|G, C) = \frac{1}{1-e^{-(\beta_0 + \beta_1 G + \beta_2 C_1 + \beta_3 C_2 + \cdots + \beta_p C_p)}}$$

Из каждой модели были сохранены:



- размер эффекта,
- статистическая значимость (p-значение)
- z-статистика

Модуль МГБД-Р-2 Структура модуля МГБД-Р-2

Модуль МГБД-Р-2 (2/4)

Для модуля МГБД-Р-2 был применен **второй метод, выносимый на защиту**

Статистическая значимость ДНК-вариантов
для ассоциации со статусом курения



Предлагаемый метод в среднем на 7 % точнее (согласно метрике качества ROC AUC для трех экспериментов) определил причинные гены пристрастия к курению, чем метод Фишера без учета графовой структуры.


Модуль МГБД-Р-2 (3/4)

Новизна модуля МГБД-Р-2

Репликация
Биобанка
Великобритании

Значимые ассоциации в
модуле МГБД-Р-2
(могут быть реплицированы в
Биобанке Великобритании)

Специфичные
значимые ассоциации
в модуле МГБД-Р-2



Полногеномные клинико-генетические модели ранее не строились в Российской популяции. Автором впервые были построены такие модели. Модели позволили выявить новые ДНК-варианты для рисков заболеваний.

Модуль МГБД-Р-2 (4/4)


Модуль МГБД-Р-2 доступен онлайн по адресу <https://biobankrus.almazovcentre.ru/>.

Модуль МГБД-Р-2 включен в крупнейшие мировые консорциумы по изучению генетических заболеваний.

The Global Lipids Genetics Consortium:
<https://www.lipidgenetics.org/>



Global Biobank Meta-analysis Initiative:
без публичного доступа



Выводы по третьему положению, выносимому на защиту

1. Разработана методика анализа данных в разнородных базах, которая включает создание такой базы на примере медико-генетической базы Российской популяции (МГБД-Р), состоящей из двух модулей, а также аннотацию данных модуля МГБД-Р-2. Модуль МГБД-Р-2 доступен по адресу <https://biobank.almazovcentre.ru/>.
2. Разработанная методика реализована в виде программного обеспечения на языке R: <https://github.com/11Dmitriy11/mgc>. Пакет позволяет проводить отбор контрольной группы из модуля МГБД-Р-1 с использованием предлагаемого вероятностного метода матричной кластеризации и интерпретацию (аннотацию) результатов сравнительного анализа с использованием предлагаемого вероятностного метода графовой кластеризации.
3. Применение методики повышает качество аннотирования медико-генетической информации в МГБД-Р.
4. Россия интегрирована в международные генетические исследования хронических заболеваний.

Научные результаты опубликованы в:

1. Usoltsev D., Kolosov N., Rotar O., Sergushichev A. O., Artomov N.N. *et al.* Complex trait susceptibilities and population diversity in a sample of 4,145 Russians // Nature Communications. 2024. V. 15. Article number: 6212.
2. Zlotina A., Barashkova S., Zhuk S., Skitchenko R., Usoltsev D., Sokolnikova P., Artomov M., Alekseenko S., Simanova T., Goloborodko M., Berleva O., Kostareva A. Characterization of pathogenic genetic variants in Russian patients with primary ciliary dyskinesia using gene panel sequencing and transcript analysis // Orphanet Journal of Rare Diseases. 2024. V. 19. Article number: 310.

1. Разработан вероятностный метод кластеризации для подбора статистически сопоставимого контрольного набора данных, основанного на априорном распределении признаков и сингулярном разложении матриц. Метод был применен автором к модулю МГБД-Р-1 с целью формирования контрольной группы для проведения полногеномного ассоциативного исследования.
2. Разработан вероятностный метод кластеризации в графовых структурах, учитывающий топологию сети и интеграцию нескольких источников экспериментальных данных через многокомпонентные веса. Метод реализует комбинированный подход на основе МЦМК и машинного обучения для учета априорной информации. Метод был применен автором к модулю МГБД-Р-2 с целью повышения качества кластеризации графовой информации.
3. Разработана методика для аннотации разнородной информации в базах данных. Методика использует предложенные вероятностный метод кластеризации для подбора несмешенного набора данных и вероятностный метод графовой кластеризации, учитывающий априорные знания для повышения качества аннотации данных, которая заключается в поиске подграфа с целевыми признаками. В среднем качество нахождения такого подграфа повышенено на 13 % относительно метода Фишера, который не использует графовую кластеризацию.

Опубликованные работы

1. Усольцев Д.А., Молотков И.И., Артемов Н.Н., Сергушичев А.А., Шалыто А.А. Метод определения активного модуля в биологических графах с многокомпонентными весами вершин // Научно-технический вестник информационных технологий, механики и оптики. 2025. Т. 25, № 3. С. 487–497.
2. Усольцев Д.А., Молотков И.И., Артемов Н.Н., Сергушичев А.А., Шалыто А.А. Применение марковских цепей Монте-Карло и машинного обучения для нахождения активного модуля в биологических графах // Научно-технический вестник информационных технологий, механики и оптики. 2024. Т. 24, № 6. С. 962–971.
3. Усольцев Д.А. Вероятностный метод матричной кластеризации с априорным распределением признаков для формирования несмещенной контрольной группы // Научно-технический вестник информационных технологий, механики и оптики. 2025. Т. 25, № 5. С. 999–1001.
4. Usoltsev D., Tolkunova K., Moguchaia E. *et al.* Transgenerational and intergenerational effects of early childhood famine exposure in the cohort of offspring of Leningrad Siege survivors // Scientific Reports. 2023. V. 13. Article number: 11188.
5. Usoltsev D., Kolosov N., Rotar O., Sergushichev A. O., Artomov N.N. et al. Complex trait susceptibilities and population diversity in a sample of 4,145 Russians // Nature Communications. 2024. V. 15. Article number: 6212.
6. Zlotina A., Barashkova S., Zhuk S., Skitchenko R., Usoltsev D., Sokolnikova P., Artomov M., Alekseenko S., Simanova T., Goloborodko M., Berleva O., Kostareva A. Characterization of pathogenic genetic variants in Russian patients with primary ciliary dyskinesia using gene panel sequencing and transcript analysis // Orphanet Journal of Rare Diseases. 2024. Т. 19, № 310. Open access.

Заключение 3/5

Акты внедрения

Медико-генетическая база данных российской популяции (<https://biobank.almazovcentre.ru/>), а также предложенные вероятностные методы матричной и графовой кластеризации применяются в качестве примеров анализа больших биомедицинских данных при подготовке магистров по специальности «Bioinformatics and systems biology» на курсе «Introduction to Linux».

ИТМО



АКТ
об использовании в учебном процессе результатов диссертационного
исследования Усольцева Дмитрия Андреевича на тему «Методы
вероятностной кластеризации для интерпретации матричной и графовой
информации в разнородных базах данных»

Настоящий акт подтверждает выполнение научно-исследовательской работы, выполненной
Усольцевым Дмитрием Андреевичем в рамках диссертационного исследования на тему «Методы
вероятностной кластеризации для интерпретации матричной и графовой информации в
разнородных базах данных», используемых в учебном процессе Университета ИТМО на
магистерской программе «Биоинформатика и системная биология» института прикладных
разработаний Усольевым Д. А. медико-генетическая база данных российской популяции (<https://biobank.almazovcentre.ru/>), а также предложенные вероятностные методы матричной и
графовой кластеризации примененные в качестве примеров анализа больших биомедицинских
данных. Использование данных методов в учебном процессе Университета ИТМО на курсе «Introduction to Linux» позволяет решать практические задачи по интеграции и анализированию медико-генетической
информации с использованием инструментов операционной системы Unix и специализированных
пакетов анализа данных.

Указанные результаты включены в:
«Введение в Linux в 2022-2024 годы».

Жук Анастасия
руководитель образовательной программы
«Биоинформатика и системная биология»,
Университет ИТМО



29.08.2025

Жук

Разработанный автором ресурс (<https://biobank.almazovcentre.ru/>), используется при чтении лекции по курсу «Биоинформационные методы анализа геномных данных» в научном центре мирового уровня «Центр персонализированной медицины» Федерального государственного бюджетного учреждения «Национальный медицинский исследовательский центр имени В. А. Алмазова» Министерства здравоохранения Российской Федерации.



АКТ О ВНЕДРЕНИИ РЕЗУЛЬТАТОВ
В ПРАКТИКУ ЧУЧЕЛЬНОЙ РАБОТЫ

1. Название проекта: Медико-генетическая база данных российской популяции (Биобанк Российской Федерации, далее – БиоБанк, р/д).

2. Краткая аннотация: Разработанная база данных предназначена для систематизированного хранения и анализа клинико-генетической информации жителей России. Ресурс обеспечивает возможность профориентации, формирования научных кадров, выявления с междисциплинарными концептуизациями, а также создания статистически достоверных зависимостей между генами и различными характеристиками российской популяции. База состоит из двух модулей: (1) хранения первичных клинико-генетических данных; (2) вторичного статистического блока, поддеряжающего распределенный обмен информацией.

3. Эффект от внедрения: Использование базы данных позволяет формировать новые работы с большими объемами данных, обработка которых требует специальных алгоритмов и методов статистической информации, осваивать современные подходы к интерпретации и обработке данных. Внедрение базы в образовательный процесс позволит сформировать у обучающихся компетенции в области биоинформатики, статистической обработки данных и их интерпретации.

4. Место и время использования: Предложенное внедрено в рамках программы дополнительного профессионального образования, программа повышения квалификации «Современные стратегии и технологии в области генетики и геномики» на 144 академических часа. Научный центр мирового уровня «Центр персонализированной медицины» Федерального государственного бюджетного учреждения «Национальный медицинский исследовательский центр имени В. А. Алмазова» Министерства здравоохранения Российской Федерации.

5. Название темы: докторант в форме материалов семинарских и лекционных занятий.

6. Название темы диссертационной работы и инф специальности: «Методы вероятностной кластеризации для интерпретации матричной и графовой информации в разнородных базах данных», специальность 2.3.8 – «Информатика и информационные процессы».

Андреев Дмитрий Андреевич, аспирант Университета ИТМО.

Руководитель: Усольцев Дмитрий Андреевич, кандидат биологических наук.

Заведующий лабораторией патогенетического професионального разряда ИМЦ ФГБУ «НМИЦ им. В. А. Алмазова» Минздрава России.

Заведующий центром развития образовательной среды ИМЦ ФГБУ «НМИЦ им. В. А. Алмазова» Минздрава России.

Заведующий центром развития образовательной среды ИМЦ ФГБУ «НМИЦ им. В. А. Алмазова» Минздрава России.

Голубева И.С.
Пегрова Н.Л.
Кузарин Г.А.

Внедрение МГБД-Р в международные исследования


Россия стала участником крупнейших международных генетических исследований

The Global Lipids Genetics Consortium:
<https://www.lipidgenetics.org/>

Consortium Participants



Global Biobank Meta-analysis Initiative:
без публичного доступа



Апробация результатов

Конференции

- XIV Конгресс молодых ученых, 2025, Университет ИТМО, Санкт-Петербург, Россия // Биобанк России – онлайн-платформа для хранения и анализа результатов GWAS-исследований полигенных заболеваний, а также разработка фенотипических предсказательных моделей на базе когорты Биобанка России.
- American Society of Human Genetics, 2024, Denver, CO, USA // A meta-predictor for causal gene identification in GWAS overcomes limitations of existing computational approaches.
- Cold Spring Harbor Laboratory Conference, 2024, Laurel Hollow, NY, USA // Understanding complex trait susceptibilities and ethnic diversity in a sample of 4,145 Russians through analysis of clinical and genetic data.
- American Society of Human Genetics, 2023, Washington, D.C., USA // Understanding complex trait susceptibilities and ethnic diversity in a sample of 4,145 Russians through analysis of clinical and genetic data.

Награда

- **Reviewers' Choice Abstract** (10 % лучших работ на American Society of Human Genetics, 2024, Denver, CO, USA). Постерный доклад: A meta-predictor for causal gene identification in GWAS overcomes limitations of existing computational approaches

Reviewers' Choice Abstracts: Your submission has been selected as a Reviewers' Choice Abstract because reviewers scored your abstract in the top 10% of poster abstracts. It will be highlighted in the Exhibit & Poster Hall with a Reviewers' Choice ribbon. **Congratulations** on this achievement! Please be sure to add this to your C.V.

СПАСИБО ЗА ВНИМАНИЕ!

Усольцев Дмитрий Андреевич

dusoltsev.27@gmail.com