

Геном успеха в науке*

СЯНЦЗЕ КУН
(Xiangjie KONG)

Чжэцзянский технологический университет, Китай

Цзюнь ЧЖАН
(Jun ZHANG)

Даляньский технологический университет, Китай

Да ЧЖАН
(Da ZHANG)

Университет Майами, США

И БУ
(Yi BU)

Пекинский университет, Китай

ИН ДИН
(Ying DING)

Техасский университет в Остине, США

ФЭН СЯ
(Feng XIA)

Федеральный университет Австралии, Австралия

ВВЕДЕНИЕ

Прогресс нашего общества в значительной степени связан с неустанными комментариями исследований учеными. Чтобы признать и поддержать

*В этом документе описывается, как выявлять и оценивать причинно-следственные факторы для улучшения научного влияния. В настоящее время анализ научного влияния может быть полезен для различных видов научной деятельности, включая заявку на финансирование, рекомендации наставников, а также поиск потенциальных коллег и т.д. Общеизвестно, что высококвалифицированные ученые часто имеют больше возможностей получить награды в качестве поощрения за свою усердную работу. Поэтому ученые тратят огромные усилия на создание научных достижений и улучшение научного влияния в течение своей научной жизни. Однако каковы определяющие факторы, которые контролируют академический успех ученого? Ответ на этот вопрос может помочь ученым более эффективно проводить свои исследования. Под таким углом в нашей статье представлены и проанализированы причинно-следственные факторы, которые имеют решающее значение для академического успеха ученых. Сначала мы предлагаем пять основных факторов ориентированных на: статью, автора, место проведения, учреждение, и факторы времени. Затем мы применяем новейшие передовые алгоритмы машинного обучения и метод складного ножа для оценки важности каждого причинно-следственного фактора. Наши эмпирические результаты показывают, что факторы, ориентированные на автора и статьи, имеют наибольшее значение для будущего успеха ученых в области компьютерных наук. Кроме того, мы обнаруживаем интересный феномен: *h*-индекс ученых в одном и том же учреждении или университете на самом деле очень близки друг к другу.*

их вклад, этим выдающимся исследователям предоставляется ряд наград и возможностей для проведения исследований. В последнее время многие исследователи сосредоточены на том, как определить выдающихся ученых и как стать успешным ученым, а также предлагается множество показателей с разных аспектов для количественной оценки этого научного успеха [19, 25]. Однако в числе этих разнообразных показателей еще предстоит выяснить, какой фактор (факторы) является решающим и спо-

* Перевод Kong X., Zhang J., Zhang D., Bu Y., Ding Y., Xia F. The gene of scientific success // ACM Trans. Knowl. Discov. Data. — 2020. — <https://arxiv.org/pdf/2202.08461.pdf>

способствует научному успеху. Более того, изучение причинно-следственных связей является фундаментальной проблемой в машинном обучении с применениями в различных областях, таких как биология, экономика, эпидемиология и информатика [31, 38]. Инспирированная приведенными выше наблюдениями, наша статья сосредоточена на изучении причинно-следственных связей, которые играют жизненно важную роль в академическом успехе ученых.

Количественная оценка научного успеха ученых всегда была интересной темой, привлекающей к своему изучению исследователей с разным опытом [13, 30, 37, 40]. Цель науки о достижении успеха состоит в том, чтобы сначала понять лежащий в основе механизм, а затем найти генеративную модель для прогнозирования того, какие ценности научного успеха будут приняты во внимание вне причинно-следственных факторов. На основе количества цитирований был предложен ряд оценочных показателей, таких как импакт-фактор журнала [14], g -индекс [12], h -индекс [16] и т.д. Б. Ван Хаутен [34] определяет научное влияние как экспертную оценку коллегами исследований, академических работ и других достижений, важность научного влияния зависит от того, насколько их исследовательские достижения ценятся, признаются и цитируются другими. Для измерения научного влияния исследователи определили различные контролируемые факторы, чтобы отразить ряд особенностей субъектов науки. В числе этих факторов подсчет цитирований рассматривался как основной фактор для оценки научного влияния из-за его простоты и эффективности.

Помимо метрик, основанных на цитировании, ученые также исследуют этот вопрос с точки зрения сетевых топологий. Изначально алгоритмы ранжирования по важности, такие как PageRank [27] и HITS [17], предназначены для ранжирования важности веб-страниц. В последнее время, вдохновленные этими алгоритмами ранжирования по важности, исследователи также широко используют их для оценки научного влияния в академических сетях [2, 11]. Учитывая достоинства как алгоритмов PageRank, так и алгоритмов HITS, Ван и др. [36] предлагают метод MRCoRank для измерения влияния научных субъектов в гетерогенных академических сетях путем взаимной системы поощрений.

Более того, развитие социальных сетей позволяет ученым регулярно обмениваться своими статьями в Twitter или Facebook. Этот эффект обмена информацией больше не ограничивается академическими социальными сетями. Он распространился на многие цифровые библиотеки и широко используется на платформах социальных сетей. Наряду с этой тенденцией, альтметрия предлагается в качестве еще одного критерия для измерения популярности ученых и их публикаций путем оценки полученного ими общественного внимания. Исследователи, тем временем, начинают использовать альтметрию для

количественной оценки научного влияния ученого, поскольку она может быстро фиксировать раннее влияние. Например, Борнманн и др. [6] нормализуют количество публикаций в Twitter, чтобы измерить влияние исследований, а затем используют его для межобластных сравнений. Притом, многие методы исследования изучают корреляцию между альтметрией и методами, основанными на подсчете цитирования, путем статистического анализа их взаимосвязи [9, 39].

Оценка научного влияния может пролить свет на различные практические вопросы, такие как заявки на получение премий или финансирования, трудоустройство и выбор консультанта [24]. Как правило, успешные ученые получают дополнительную возможность приобретать ресурсы для исследований, получать гранты и распространять свои исследовательские идеи более широко. Поэтому ученые стремятся постоянно повышать свое научное влияние. Однако какие факторы имеют причинно-следственную связь с научным успехом? А именно, какие факторы наиболее подходят для оценки научного успеха? Вышеуказанные вопросы до сих пор остаются нерешенными. Поэтому в этой статье мы сначала проводим исследования, выявляя причинно-следственные факторы, которые способствуют научному успеху, а затем оцениваем важность причинно-следственных связей этих факторов. Мы берем наиболее часто используемый индекс h в качестве показателя для оценки влияния ученых и выявляем причинно-следственные факторы, которые приводят к высокому индексу h у ученых.

Из-за проблем с конфиденциальностью и технологических ограничений доступ к информации о публикациях гораздо проще предоставить по сравнению с другими источниками данных. Она (информация) также может в значительной степени отражать академические способности или вклад соответствующих ученых. Как правило, название, ключевые слова, авторы, учреждения, место проведения, страницы, и опубликованные даты издания могут быть получены напрямую. На основе этих данных можно извлечь и рассчитать множество импакт-факторов, как это делается в большинстве текущих работ. Хотя, в отличие от предыдущей работы, наш метод не фокусируется на улучшении показателей оценки, а стремится на выявление причинно-следственных факторов, влияющих на академические успехи ученых по их публикациям. Чтобы ответить на этот вопрос, мы разделили факторы влияния на несколько категорий, как показано на рис. 1. Это фактор статьи, фактор автора, фактор места проведения, фактор учреждения и фактор времени. Для каждого фактора мы предлагаем конкретные и интуитивно понятные показатели, отражающие академические качества каждого ученого. После этого, используя алгоритмы машинного обучения и метод складного ножа, мы исследуем влияние каждого фактора на академические успехи ученых.



Рис. 1. Иллюстрация факторов, воздействующих на влияние ученого

Вклад. Наше исследование в основном сосредоточено на выявлении причинно-следственных факторов академической эффективности ученых. В целом, в этой статье мы вносим следующий вклад:

- *Новые функции.* Мы представляем пять потенциальных причинно-следственных факторов с учетом нового коэффициента Джини для институтов.
- *Выявление причинно-следственных связей.* Используя алгоритмы машинного обучения и метод складного ножа, мы обнаружили, что факторы, ориентированные на автора и статьи, сильно коррелируют с их академическими успехами.
- *Новое понимание.* Наши результаты предоставляют исследователям новый и эффективный метод повышения их научного влияния.

Статья организована следующим образом. После раздела **ВВЕДЕНИЕ** обсуждается связанная работа. Далее в разделе **ИДЕНТИФИКАЦИЯ ПРИЧИННО-СЛЕДСТВЕННЫХ ФАКТОРОВ** указаны предлагаемые факторы научного влияния. В разделе проверяются причинно-следственные факторы, оценивается их значимость, и они подтверждаются на большом наборе данных об ученых. Затем мы завершаем нашу работу разделом **ЗАКЛЮЧЕНИЕ И ДАЛЬНЕЙШАЯ РАБОТА.**

СВЯЗАННАЯ РАБОТА

Научное влияние изучалось на протяжении десятилетий исследователями из самых разных дисциплин. В течение долгого времени подсчет цитирования широко применялся для измерения научного влияния. Наряду с этой тенденцией исследователи предложили различные показатели,

основанные на цитировании. С развитием академических сетей ученые также рассматривают проблему научного влияния с точки зрения важности сети. Эти показатели могут быть использованы как для оценки влияния, так и для прогнозирования будущих успехов в науке. В этом разделе мы представим связанную работу по вышеупомянутым аспектам.

Подсчет цитирований впервые был использован для количественной оценки влияния журналов. С тех пор исследователи предложили множество основанных на цитировании методов для измерения научного влияния [33], таких как h-индекс [16] и g-индекс [12]. Некоторые ученые утверждают, что цитирования не следует рассматривать как равнозначные [5]. Еще один пример, который следует упомянуть здесь: и А, и В цитируют С. Ранее цитаты из А и В считались одинаковыми, но, если А - из высокоцитируемой статьи, а В - нет, цитирования следует различать. Это похоже на идеи, связанные с алгоритмом PageRank. Был предложен ряд подходов для определения важности цитирования [33]. Все эти методы применяли подсчет цитирования как важную часть метрики оценки, но все они вносят некоторые улучшения, так как простая опора на подсчет цитирования является неадекватной для оценки влияния [35].

Помимо использования цитирования для количественной оценки научного влияния, научные сети в настоящее время часто применяются для изучения подобных проблем, поскольку сети содержат различные типы субъектов и отношений [23]. Алгоритмы PageRank и HITS широко используются

для измерения научного влияния в академических сетях. На основе этих двух алгоритмов был предложен ряд сетевых оценочных показателей [42]. Учитывая влияние различных академических сетевых структур, ученые применяют модифицированные алгоритмы ранжирования по важности для оценки влияния различных научных субъектов [3]. Кроме рассмотрения сетевых топологий, некоторые исследователи также обнаруживают новые функции и взаимосвязи для оценки научного влияния. Ван и др. [36] оценивают влияние научных субъектов, исследуя особенности текста в разнородных академических сетях. Из-за развивающегося характера академических сетей некоторые исследования также учитывают динамику цитирования и появление новых объектов или отношений для оценки научного влияния [4, 43].

В дополнении к использованию основанных на цитировании и сети возможностей для оценки научного влияния, ученые также пытаются изучить соответствующие факторы, которые очень важны для будущей академической успеваемости, и предсказать будущее влияние [15, 26]. Ван и др. [35] проверяют эффективность ранних цитирований в прогнозировании потенциальных цитирований статей [7, 18]. Стегехьюс и др. [32] используют два важных фактора, а именно историческую информацию о цитировании и импакт-фактор журнала, для прогнозирования распределения цитирования статей.

Прогнозирование потенциального влияния ученых, h -индекс и предстоящие цитирования – все это входит в сферу прогнозирования будущего влияния [8, 35]. Акуна и др. [1] используют количество статей, h -индекс и академический возраст ученого, чтобы предсказать его влияние. Метод линейной регрессии используется для прогнозирования будущего влияния выдающихся ученых в области математики, физики и биологии. И эти авторы обнаружили, что академический возраст ученых на самом деле играет значительную роль в прогнозировании научного влияния [22]. Кроме того, другие авторы [10] изучили вопрос о том, какая статья может увеличить h -индекс ученого с помощью метода линейной регрессии. Они обнаружили, что в числе шести факторов тема и место проведения имеют очень важное значение для прогнозов.

Прогнозирование научных последствий с помощью причинно-следственных связей – это недавно появившаяся область исследований. В отличие от предыдущих методов [1, 8, 35], методы, основанные на причинно-следственных выводах, сначала выявляют потенциальные причинные факторы, а затем используют их для прогнозирования научного влияния. Более того, предыдущие методы рассматривали только одну сторону для оценки научного влияния, пренебрегая анализом и ранжированием важности каждого причинного фактора.

ИДЕНТИФИКАЦИЯ ПРИЧИННО-СЛЕДСТВЕННЫХ ФАКТОРОВ

Исследователи десятилетиями изучали проблему научного влияния и предлагают различные факторы влияния. Однако до сих пор не существует формального определения научного влияния и общепринятого стандарта его оценки. Какие из этих ранее изученных импакт-факторов наиболее важны для академического успеха ученых? Получение ответа на этот вопрос может помочь исследователям проводить свои исследования более эффективно. В этом разделе мы представим несколько новых факторов влияния, упорядочим существующие факторы и классифицируем их по различным категориям.

Факторы, ориентированные на статьи

Как правило, большинство предыдущих работ предпочитают использовать подсчет цитирований и число статей для количественной оценки научного влияния. Хотя помимо этих двух показателей существуют различные факторы, основанные на статьях, которые влияют на динамику научного влияния. Чтобы определить репрезентативные возможности статей, мы сначала анализируем элементы, связанные с факторами, ориентированными на статьи.

Подсчет цитирований ($Cits$) и число публикаций (Num_{pub}) являются основой факторов, основанных на статьях. Средние ссылки для каждого ученого (Ave_{ci}^{ai}), самые высокие ссылки (Hi_{ci}^{ai}), самые низкие ссылки (Lo_{ci}^{ai}) могут быть получены непосредственно через значения их общего количества ($Cits$) и (Num_{pub}). Более того, качество статьи зависит не только от ее содержания, но и от популярности темы. Например, ранее широкий спектр данных не мог быть собран и обработан из-за технических ограничений. В то время как с развитием технологий обработки данных и продвижением эры больших данных все больше внимания уделяется документам, связанным с тематикой больших данных. Следовательно, темы статьи также могут касаться ее влияния. Чтобы это учесть, мы предлагаем показатель степень популярности темы статьи (article's topic popular degree- ATP), которая может быть рассчитана в соответствии со следующим уравнением.

$$ATP(p_i) = \frac{\sum_{w=1}^m Num(w)^{p_i}}{\sum_{i=1}^n Num(i)} \quad , \quad (1)$$

где (p_i) представляет статью, w -ключевое слово статьи p_i , $Num(w)$ - количество w , m - количество ключевых слов в статье p_i , $Num(i)$ - количество ключевых слов в статьях и (n) - общее количество публикаций.

Помимо вышеупомянутых факторов, основанных на цитировании, при измерении научного влияния также необходимо учитывать качество источников ссылок. Как правило, у каждого ученого есть список публикаций, и каждая публикация содержит ряд источников ссылок. Цитаты могут рассматриваться как академические признания от других исследователей. Точно так же авторы статьи также получают информацию из ее источников ссылок. Таким образом, источники ссылок могут повлиять на качество статьи. Прежде всего, наибольшее (Hi_{ci}^{ref}), среднее ($Ave_{ci}^{a_i}$), наименьшее (Lo_{ci}^{ref}) количество цитирований и среднее количество источников (Ave_{num}^{ref}) являются наиболее прямыми измерениями для количественной оценки качества источников. Помимо цитирования, влияние источников ссылок также используется для оценки влияния ссылок, поскольку многие исследователи склонны цитировать статьи из источников с высоким влиянием, независимо от релевантности между статьями.

Чтобы измерить релевантность между статьями (Rel_{ref}), мы сначала решаем эту проблему с точки зрения авторов. В соответствии с публикациями каждого автора, области их исследований могут быть представлены через ключевые слова конкретных статей. Поэтому мы используем различия между ключевыми словами авторов для расчета релевантности между статьями и источниками. Для ее количественной оценки применяется информационная энтропия, и формула расчета выглядит следующим образом:

$$Rel_{ref}^{p \rightarrow q} = - \sum_{i=1}^r W_i \log_2 (W_i) , \quad (2)$$

где ($Rel_{ref}^{p \rightarrow q}$) представляет релевантность между статьей q и ее источником ссылки p, (W_i) - частота слов в статье q и p - информация о ключевых словах в p, а r - общее количество слов.

Кроме того, необходимо также учитывать взаимосвязь между статьями и их источниками. Из-за отсутствия полных текстов статей мы используем косинусное сходство для измерения релевантности между статьями и названиями и ключевыми словами источников и ссылок на них. Для каждой статьи и ее источника мы извлекаем последовательность слов ($m_1, m_2, m_3, \dots, m_n$) из их названий и ключевых слов. Затем вектор может быть получен на основе приведенной выше последовательности для каждой статьи. В соответствии с этими векторами релевантность между статьей и ее ссылкой может быть рассчитана следующим образом:

$$Sim(p_1, p_2) = \frac{\sum_{i=1}^n (V_{p_1,i} * V_{p_2,i})}{\sqrt{\sum_{i=1}^n V_{p_1,i}^2} * \sqrt{\sum_{i=1}^n V_{p_2,i}^2}} , \quad (3)$$

где $Sim(p_1, p_2)$ представляет собой соответствие между статьями p_1 и p_2 , V_{p_1} является вектором p_1 и V_{p_2} - вектором p_2 .

Факторы, связанные с местом проведения

Помимо показателя, основанного на цитировании, PageRank также может использоваться для измерения качества места проведения, что отражает научный успех автора. Чтобы оценить важность мест проведения, сначала вычисляются значения PageRank (PR (v_i)) в сети места проведения. Затем среднее количество цитирований статей, опубликованных в местах проведения ($Ave_{ci}^{v_i}$), используется для измерения качества мест проведения. Кроме того, с помощью концепции h-индекса ученого мы вычисляем h-индекс места проведения ($h(v_i)$). В частности, определение h-индекса места проведения похоже на обычный порядок расчета h-индекса, и значение h-индекса места проведения равняется h, у которого, по крайней мере, h статей в месте проведения имеет h ссылок

$$PR(v_i) = \sum_{j=1}^n Ave_{cj}^{v_i} . \quad (4)$$

Факторы, ориентированные на автора

Кроме факторов, ориентированных на статьи, факторы, представляющие признаки ученых, также жизненно важны для их влияния. h-индекс каждого ученого (h_{ai}) и значение PageRank (PR $_{ai}$) в сети сотрудничества (коллоборации) являются интуитивными факторами, указывающими на влияние ученого. Между тем, импакт-фактор журнала (JIF) может быть рассчитан на их основе и широко применяется для измерения влияния журналов из-за его простоты. В соответствии с концепцией JIF предлагается авторский импакт-фактор (AIF). Аналогично, AIF ученого в год t - это AIF ученого (Ave_{ci}) за Δt годы до года t. Помимо подсчета цитирований, сумма оценок PageRank статей ученых в сети цитирования (PR $_{pub}$) также может указывать на их важность.

В дополнение к этим двум факторам ученые предложили несколько хорошо известных факторов для количественной оценки динамики влияния ученых. Значение Q широко применяется для выявления процесса взаимного усиления влияния ученых на их статьи [30] и остается стабильным на протяжении всей академической карьеры ученых. Формула расчета значения Q выглядит следующим образом:

$$Q(a_i) = e^{\langle \log_{cia} \rangle} - \mu_p , \quad (5)$$

где $Q(a_i)$ представляет значение Q ученого, $\langle \log c_{ia} \rangle$ - среднее количество цитирований a_i в логарифмическом порядке, (α) - статья α от автора a_i и (μ_p) - среднее потенциальное влияние статей.

На протяжении своей карьеры каждый ученый взаимодействует с множеством исследователей из разных дисциплин. Ученые получают выгоду от академических обменов и дискуссий с другими исследователями, а также улучшают свое собственное научное влияние. Следовательно, способности соавторов также могут повлиять на качество их статей и влияние ученых. Чтобы определить влияние соавторов, предлагается несколько факторов. Как правило, h -индекс соавторов отражает их способности. Основываясь на этом, можно легко получить ряд факторов. Максимальные ($h \max_{ci}^{a_i}$) и средние значения ($h_{ave}^{a_i}$) соавторов ученых могут быть получены непосредственно через h -индекс каждого автора. Затем мы используем различия между h_{a_i} -индексом и $h \max_{co}^{a_i} (hdif_{a_i})$, чтобы представить расстояние между влиятельными соавторами и (a_i).

Затем мы рассматриваем влияние разнообразного исследовательского опыта соавторов на влияние ученых. Поскольку взаимодействия между исследователями становятся все более частыми, интеграция ученых из разных дисциплин также оказывает положительное влияние на продвижение достижений науки и технологий. Чтобы измерить диапазон дисциплин соавторов, мы применяем теорию энтропии. Подробную информацию о конкретных дисциплинах и институтах ученых можно получить из набора данных. Для каждого ученого мы количественно оцениваем разнообразие его соавторов ($Div(a_i)$), используя теорию энтропии. Разнообразие вычисляется в соответствии со следующими уравнениями:

$$Div(a_i)_{inst} = - \sum_{m=1}^r w_m \log_2 (w_m) \quad (6)$$

$$Div(a_i)_{key} = - \sum_{p=1}^q k_p \log_2 (k_p) \quad (7)$$

$$Div(a_i) = Div(a_i)_{inst} + Div(a_i)_{key} \quad (8)$$

где $(Div(a_i)_{inst})$ и $(Div(a_i)_{key})$ представляют разнообразие a_i ученых из институтов коллег автора и ключевые слова их статей для автора a_i , $(Div(a_i))$ указывает на разнообразие a_i всех коллег. (w_m) - частота слова m в общей информации учреждений коллег a_i и общее количество слов m в уравнении (9). (k_p) - частота слова p во всех ключевых словах статей коллег a_i и общее количество слов p .

Институционально-ориентированные факторы

Воздействие институтов на влияние ученых также необходимо учитывать, поскольку вопросы финансирования исследований или политики могут существенно повлиять на прогресс исследователей в их исследованиях. Академические достижения ученых также могут зависеть от способностей их коллег, поскольку они часто могут обмениваться исследовательскими идеями и методами. Как правило, мы исследуем влияние институтов с двух основных точек зрения: академическая среда ученых и экономические факторы.

Мы оцениваем академическую среду с точки зрения коллег. При проведении исследования люди, как правило, обмениваются идеями со своими соавторами или коллегами. Кроме того, исследователи также подвержены влиянию влиятельной группы или отдельных лиц в их учреждении. Это влияние обычно определяется как давление со стороны коллег (или социальное давление). Принимая во внимание такое давление, мы пытаемся определить значение давления со стороны коллег на академическую производительность ученых. Другими словами, существует ли между ними реальная связь? Чтобы ответить на указанные вопросы, мы предложили несколько факторов, чтобы выявить корреляцию между академическими успехами ученых и их коллегами. Первоначально мы оцениваем исследовательские способности коллег ученых. Для каждого ученого по набору данных можно рассчитать h -индекс его коллеги (h_{col}), количество публикаций (Num_{pub}^{col}), количество ссылок ($Cits_{col}$) и рейтинг PageRank (PR_{col}).

Кроме того, мы используем концепцию коэффициента Джини из экономической области для описания академической репутации учреждения. В коэффициенте Джини первоначально используется определение глобальных кривых Лоренца для вычисления распределения доходов в экономической области. Его значение колеблется от 0 до 1. Чем больше значение, тем больше экономическое неравенство. В нашей статье мы количественно оцениваем коэффициент Джини учреждений, используя значения h -индекса ученого, цитирования и количества статей. Коэффициент Джини учреждения может быть рассчитан следующим образом:

$$G(i) = 1 - \frac{1}{n} \left(2 \sum_{m=1}^{n-1} P_m + 1 \right), \quad (9)$$

где $G(i)$ представляет значение коэффициента Джини учреждения i и n представляет собой количество исследовательских групп внутри учреждения i . Для исследовательской группы m указывается групповой индекс среди групп. Кроме того, (P_m) - это доля суммы групп m во всех значениях учре-

ждения i . Следовательно, в соответствии со значениями h -индекса ученого, цитирований и количества статей, репутация каждого учреждения рассчитывается с использованием трех значений коэффициента Джини, которыми являются $G(i)^h$, $G(i)^{Cit}$ и $G(i)^{pub}$.

Факторы времени

Предыдущие исследования подтвердили влияние временной динамики на научное влияние, например, на предсказание восходящих звезд в академических кругах. Что касается молодых исследователей, то у них может быть этап быстрого роста после начала академической карьеры. Производительность в этот период очень важна для их будущих академических успехов. Мы предлагаем два фактора времени, чтобы отразить это явление. Первый из них - академический возраст ($N_{im,years}$), который представляет собой годы с момента публикации учеными своих первых научных работ. Другим фактором является динамика h -индекса ученых в течение Δt лет. В этой статье мы устанавливаем $\Delta t = 3, 5, 7$, а затем вычисляем разницу ($Hindex-dif$) между прогнозируемым временем и Δt годами в прошлом.

$$\rho = \frac{cov(X, Y)}{\sigma_X \sigma_Y} = \frac{E(XY) - E(X)E(Y)}{\sqrt{E(X^2) - E^2(X)}\sqrt{E(Y^2) - E^2(Y)}}, \quad (10)$$

где cov - ковариация между двумя группами результатов и указывает на их стандартное отклонение. Его значение колеблется от -1 до 1, а корреляция ва-

рируется от самой отрицательной до самой положительной.

Исходя из вышеупомянутых факторов, мы стараемся как можно полнее перечислить актуальные показатели академической эффективности ученых. Эти показатели подразделяются на пять основных категорий: факторы, ориентированные на статью, факторы, ориентированные на автора, факторы, ориентированные на место проведения, факторы, ориентированные на учреждение, и факторы времени. Эти факторы описаны в табл. 1. Между тем, мы в первую очередь исследуем корреляцию между этими факторами и h -индексом ученого самым прямым способом. Коэффициент корреляции Пирсона применяется для измерения релевантности (соотношения) между двумя результатами ранжирования. Процедура расчета коэффициента корреляции Пирсона показана следующим образом.

Согласно табл. 1, мы видим, что факторы, ориентированные на автора и статью, являются наиболее коррелирующими факторами в числе всех предложенных показателей, за которыми следуют факторы, ориентированные на время. Чтобы дополнительно представить явление линейной корреляции между h -индексом и другими факторами, мы затем приводим результаты четырех наиболее значимых факторов. Как показано на рис. 2, количество цитирований и публикаций ученых, академические годы и различия h -индекса в Δt годах сильно коррелируют с будущим h -индексом ученых. С увеличением академического возраста индекс h продолжает увеличиваться до достижения академического возраста 15 лет, после чего остается стабильным.

Таблица 1

Описания причинно-следственных факторов и корреляции

	Функция	Описание	Корреляция
Статья	$Cits$	Количество цитирований ученых.	0,7629
	Num_{pub}	Количество публикаций ученых.	0,7782
	Ave_{ci}	Средняя цитируемость каждого ученого.	0,2772
	Hi_{ci}	Самая высокая цитируемость каждого ученого.	0,2349
	Lo_{ci}	Наименьшая цитируемость каждого ученого.	0,2067
	ATP	Степень популярности темы статьи.	0,0134
	Hi_{ci}^{ref}	Наибольшее количество ссылок.	0,1648
	Ave_{ci}^{ref}	Среднее количество ссылок.	0,1439
	Lo_{ci}^{ref}	Наименьшее количество ссылок.	0,0648
	Ave_{num}^{ref}	Среднее количество ссылок.	0,2496
	Rel_{ref}	Релевантность между статьями.	0,0174
	$Sim(p_1, p_2)$	Косинусное сходство между статьями.	0,1437
Место проведения	$PR(vi)$	Значения PageRank места проведения в сети места нахождения статьи	0,2146
	Ave_{ci}^{vi}	Среднее количество цитирований статей, опубликованных в их местах проведения.	0,1924
	$h(vi)$	h -индекс места проведения	0,2081

	Функция	Описание	Корреляция
Автор	$h(a_i)$	Значение h -индекса каждого ученого.	0,9782
	PRa_i	Значение PageRank каждого ученого в сети соавторов.	0,6274
	AIF	Импакт-фактор автора.	0,3826
	$Qvalue$	Значение Q автора.	0,5394
	$hmax_{co}^{a_i}$	Максимальное значение h -индекса соавторов ученого.	0,8253
	$Num_{co}^{a_i}$	Количество соавторов ученого.	0,426
	$have_{co}^{a_i}$	Среднее значение h -индекса соавторов ученого.	0,482
	$hlo_{co}^{a_i}$	Наименьшее значение h -индекса соавторов ученого.	0,275
	$hdif_{a_i}$	Разница между максимальными и наименьшими значениями h -индекса соавторов ученого.	0,538
	$Div(a_i)$	Разнообразие соавторов.	0,1743
Учреждение	h_{col}	h -индекс коллег ученых.	0,2947
	Num_{pub}^{col}	Количество публикаций коллеги ученого.	0,1368
	$Cits_{col}$	Количество цитирований коллеги ученого.	0,1937
	PR_{col}	Оценка PageRank коллеги ученого.	0,0264
	$G(i)^h$	Коэффициент Джини по h -индексу учреждения.	0,0937
	$G(i)^{Cit}$	Коэффициент Джини по количеству цитирований учреждения.	0,0153
	$G(i)^{pub}$	Коэффициент Джини по количеству публикаций учреждения	0,1632
	GNP	Величина ВВП страны учреждения.	0,1937
Фактор времени	Num_{years}	Академический возраст ученого	0,5683
	$Hindex-dif$	Разница между h -индексом ученого и Δ годы в прошлом.	0,6248




Рис. 2. Явления линейной регрессии между h -индексом и четырьмя наиболее значимыми факторами

Нетрудно понять высокое значение ($Cites$, Num_{pub} и h_{a_i}). В то время как факторы, ориентированные на место проведения, и факторы, ориентированные на учреждение, по-видимому, отрицательно коррелируют с h -индексом ученого. Однако эта таблица не может точно отразить эффективность этих факторов в прогнозировании будущего академического успеха ученых, поскольку эти факторы могут вместе выявлять одно и то же явление. Из этой таблицы можно увидеть только линейную корреляцию между ними, и их эффективность в прогнозировании h -индекса ученого анализируется в следующем разделе.

Проверка причинно-следственных факторов

В этом разделе мы исследуем влияние вышеупомянутых факторов на прогнозирование h -индекса ученого. Чтобы исследовать их производительность, мы используем передовые методы машинного обучения. В их числе мы применяем XGBoost, линейную регрессию, деревья решений с градиентным бустингом, а также дерево классификации и регрессии по отдельности на наборе данных. Затем, сравнивая производительность, мы находим наиболее подходящий метод машинного обучения.

Построение структурированной причинно-следственной модели

В основе структурной теории причинности лежит "модель структурной причинности (SCM) [21, 29, 41]". Поэтому в нашей статье мы сначала представляем простую причинно-следственную модель, как показано на рис. 3. Здесь S - коллаيدر: стрелки «сталкиваются» в точке S . Путь $A \rightarrow S \leftarrow B$ заблокирован. Другими словами, A не связан с B через S . С учетом коллаидера S , причинные факторы независимы друг от друга. Мы называем эту структуру V-структурой [20]. В этой V-структуре A и B являются потомками (родительскими элементами) для S . Однако в нашей статье научный успех может определяться и зависеть от множества причинно-следственных факторов. Поэтому мы расширяем рис. 3(а) до гетерогенной структурированной причинно-следственной модели, как показано на рис. 3(б), сформулированной в виде следующего уравнения (рис. 4).

$$P(S) = P(S|F_1) \dots P(S|F_n) \quad (11)$$

Обнаружение причинного фактора




Рис. 3. Модель причинно-следственного вывода V-образной структуры




Рис. 4. Структура причинно-следственного вывода

Модель SCM, состоящая из двух наборов переменных, X и Y , и набора функций F , которые определяют, как присваиваются значения каждой переменной $(X_i) \in X$. Здесь мы предполагаем, что, учитывая результат прогнозирования, функция представляет влияние как функцию прямых причин и предельных потерь с параметрами обучения (θ_1) . После того, как мы определим факторы, способствующие нашему научному успеху, нам нужно измерить значимость для каждого причинного фактора. Что касается большого научного набора данных наблюдений, то мы применяем передовые методы машинного обучения, чтобы выявить причинно-следственные связи и то, как различные причинно-следственные факторы, включая автора, статью, место проведения, учреждение и время, способствуют пониманию научного успеха.

$$S = F(X, Y, \epsilon; \theta_1) \quad (12)$$

Потеря функции

В этом разделе мы применяем следующие четыре передовых метода машинного обучения для оценки причинно-следственных связей.

XGBoost: XGBoost – это масштабируемая непрерывная система бустинга деревьев, которая работает быстрее, чем самые современные широко используемые методы. Идея алгоритма абустинга состоит в том, чтобы объединить множество слабых классификаторов вместе, чтобы сформировать сильный классификатор, а XGBoost – это поддерживающая модель дерева, которая объединяет множество моделей дерева регрессии CART для формирования сильного классификатора. Ее дерево бустинга в основном состоит из двух частей, которые представляют собой объект изучения регуляризации и процесс градиентного бустинга дерева.

Линейная регрессия (LR): Регрессионный анализ широко используется для прогнозирования и предсказания, а также может быть использован для определения того, какие из всех независимых переменных связаны с зависимой переменной. Линейная регрессия требует, чтобы модель была линейной по параметрам регрессии. Функция прогнозирования используется для моделирования данных, и данные могут быть использованы для оценки неизвестных параметров. Линейная регрессия быстра в моделировании и запускается в случае больших объемов данных.

Деревья решений с градиентным бустингом (GBDT): GBDT – это итеративный алгоритм дерева решений, который включает в себя множество деревьев решений, а конечный результат равен сумме решений всех деревьев. Суть GBDT заключается в том, что каждое дерево усваивает остаток от суммы всех предыдущих выводов дерева, кото-

рый представляет собой сумму реальных значений после добавления прогнозируемых значений. Он может обнаруживать множество отличительных особенностей и их комбинаций.

Деревья классификации и регрессии (CART): Его можно использовать для создания дерева классификации или дерева регрессии. Когда CART используется в качестве дерева классификации, атрибуты объектов могут быть непрерывными или дискретными, а дерево классификации CART использует коэффициент Джини при разделении узлов. Когда CART используется в качестве дерева регрессии, атрибуты наблюдения должны быть непрерывного типа. Поскольку метод наименьшего абсолютного отклонения (LAD) или наименьшего квадратного отклонения (LSD) обычно используется при выборе атрибутов объектов путем разделения узлов, атрибуты объектов также имеют непрерывный тип. В нашей статье мы применяем его в качестве дерева регрессии для прогнозирования будущего влияния ученого на основе входных переменных.

Набор данных

В этой статье мы используем два набора данных из разных дисциплин. Одним из них является вспомогательный набор данных, извлеченный из Microsoft Academic Graph (MAG). Набор данных MAG содержит подробную информацию о документе, включая название, ключевые слова, авторов, учреждения, места проведения, дату публикации и цитаты из 27 макрообластей и 306 подобластей. Весь набор данных включает более 35 миллионов статей, 38 миллионов авторов и свыше 324 миллионов взаимосвязей ссылок. Мы используем вспомогательный набор данных, включающий 79321 профиль ученых и 105123 статьи, посвященные области компьютерных наук от ученых с завершенной академической карьерой.

Другой является подмножеством Американского физического общества (APS). Набор данных APS содержит информацию о статье по физике с указанием названия, авторов, учреждений, мест проведения, даты публикации и цитирования. Весь набор данных включает 540232 статьи, 394801 автора и более 6 миллионов взаимосвязей ссылок на 12 журналов APS. Мы используем вспомогательный набор данных, включающий статьи PRC и PRE, 80360 профилей ученых и в общей сложности 98011 статей.

Показатели оценки

Чтобы оценить производительность различных алгоритмов и факторов обучения, мы используем четыре типичных показателя, включая MAE (Средняя абсолютная ошибка), MAPE (Средняя абсолютная процентная ошибка), MSE (Среднеквадратичная ошибка), ACC (Точность) и R^2 . Учитывая истинное

значение y и прогностическое значение \hat{y} , вышеупомянутые оценочные показатели могут быть рассчитаны следующим образом:

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (13)$$

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (14)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i|^2 \quad (15)$$

$$ACC = \frac{1}{n} \sum_{i=1}^n I(f(y_i) = \hat{y}_i) \quad (16)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n |y_i - \hat{y}_i|^2}{\sum_{i=1}^n |y_i - \bar{y}|^2} \quad (17)$$

Проверка с помощью экспериментов

С помощью алгоритмов обучения и факторов, которые мы представили выше, можно предсказать h -индекс ученого. Мы используем информацию за предыдущие Δt годы для обучения и реальные данные за 2015 год (MAG) или 2013 год (APS) для проверки. На тренировочном наборе мы выполняем 5-кратную перекрестную проверку, чтобы настроить гиперпараметр моделей. Для XGBoost и GBDT основные гиперпараметры, которые мы настроили, включают скорость обучения, максимальную глубину деревьев, частоту под-выборок, частоту под-признаков и коэффициент регуляризации. Для CART основные гиперпараметры, которые мы настроили, включают скорость обучения, максимальную глубину деревьев. Для LR основные гиперпараметры, которые мы настроили, включа-

ют скорость обучения и коэффициент регуляризации. Все гиперпараметры настраиваются с помощью поиска по сетке в пространстве параметров. Результаты проиллюстрированы с точки зрения MAE, MAPE, MSE, ACC и (R^2).

В табл. 2 показаны прогностическая эффективность различных методов для показателей оценки, упомянутых выше, в наборе данных MAG. MSE, MAE и MAPE используются для сравнения результатов прогнозирования и истинных значений. В таблице указывается корреляция между прогнозируемыми результатами и истинными значениями, а также указывается точность. Следовательно, по их значениям можно сделать вывод о лучшей производительности прогнозирования. Очевидно, что производительность XGBoost является лучшей среди всех методов, использующих разные периоды времени, потому что она превосходит другие методы по 4 из 5 показателей, которые получают наименьшие MAPE и MSE и самые высокие оценки и оценки в трех группах экспериментов. В то время как для разных значений Δt существуют различные результаты прогнозирования. Производительность $\Delta t = 7$ достигает наилучшего результата, а результаты $\Delta t = 10$ являются худшими. Однако существует лишь небольшая разница между результатами $\Delta t = 5$ и $\Delta t = 7$. В следующих частях мы анализируем результаты $\Delta t = 7$ в наборе данных MAG.

Прогностическая эффективность этих методов для набора данных Американского физического общества APS показана в табл. 3. В таблице мы заметили, что общие показатели прогнозирования на точках доступа лучше, чем на MAG, что имеет меньшие погрешности и более высокую степень подгонки (R^2). Мы заметили, что производительность XGBoost также является лучшей. В отличие от результатов по MAG, все методы работают лучше на периоде $\Delta t = 10$, чем в других группах. В следующих частях мы анализируем результаты при $\Delta t = 10$ в наборе данных APS.

Таблица 2

Производительность алгоритмов разностного обучения на MAG

		MAE	MAPE	MSE	ACC	(R^2)
$\Delta t=5$	XGBoost	0,73	0,07	1,09	0,86	0,99
	LR	0,82	0,10	1,18	0,80	0,92
	GBDT	0,69	0,08	1,16	0,84	0,95
	CART	0,96	0,18	2,30	0,79	0,81
$\Delta t=7$	XGBoost	0,79	0,07	1,19	0,86	0,99
	LR	0,83	0,11	1,30	0,79	0,90
	GBDT	0,73	0,09	1,25	0,85	0,94
	CART	0,98	0,20	2,49	0,78	0,80
$\Delta t=10$	XGBoost	0,81	0,09	1,27	0,83	0,91
	LR	0,84	0,13	1,43	0,73	0,86
	GBDT	0,74	0,10	1,32	0,81	0,84
	CART	0,99	0,29	2,68	0,74	0,63

Производительность алгоритмов разностного обучения на точках доступа APS

		MAE	MAPE	MSE	ACC	(R ²)
$\Delta t=5$	XGBoost	0,54	0,06	0,62	0,81	0,97
	LR	0,57	0,08	0,65	0,80	0,96
	GBDT	0,55	0,06	0,63	0,80	0,96
	CART	0,56	0,09	0,73	0,78	0,95
$\Delta t=7$	XGBoost	0,51	0,07	0,55	0,82	0,97
	LR	0,53	0,10	0,55	0,80	0,96
	GBDT	0,51	0,07	0,56	0,81	0,97
	CART	0,54	0,08	0,70	0,80	0,96
$\Delta t=10$	XGBoost	0,45	0,06	0,46	0,85	0,98
	LR	0,47	0,07	0,48	0,83	0,97
	GBDT	0,45	0,08	0,47	0,84	0,97
	CART	0,46	0,07	0,60	0,80	0,96

Оценка причинно-следственных факторов

Приведенный выше анализ подтверждает причинно-следственные связи между различными факторами и общими результатами h -индекса. Однако вклад и важность факторов все еще нуждаются в изучении. Чтобы решить этот вопрос, мы сначала применили метод "складного ножа" [28] для проверки функции факторов каждой группы в отдельности. Метод "складного ножа" включает в себя две фазы: Добавление и удаление. На этапе добавления мы каждый раз используем одну группу факторов для прогнозирования результата. На этапе удаления мы удаляем группу факторов и обучаем модель с помощью остальных факторов. После этих двух этапов можно изучить индивидуальный вклад фактора в общую задачу прогнозирования.

Как показано на рис. 5, в экспериментах с набором данных MAG снижение значений ACC за счет удаления факторов, ориентированных на статьи, в четырех методах демонстрирует, что они имеют большое значение для прогнозирования h -индекса. Напротив, при устранении других типов факторов снижение прогностической эффективности не так очевидно. Этот факт может показать важность факторов, ориентированных на статьи, для прогнозирования будущего успеха ученых. Что касается дополнительных факторов, то факторы, ориентированные на статьи, по-прежнему играют важную роль в прогнозировании будущего научного влияния. Более того, факторы, ориентированные на автора и факторы времени, также демонстрируют свою эффективность для прогнозирования h -индекса ученого.

Те же анализы выполняются для набора данных APS, как показано на рис. 6. В отличие от результатов для MAG, снижение значений ACC из-за удаления факторов, ориентированных на автора, сильно влияет на прогнозирование h -индекса, что указывает на то, что факторы, ориентированные на

автора, имеют большое значение в наборе данных APS. Как и в предыдущих экспериментах, при устранении других типов факторов снижение прогностической эффективности не столь очевидно. Что касается факторов добавления, то факторы, ориентированные на автора, по-прежнему играют свою важную роль. Более того, факторы, ориентированные на статьи, также показывают свою эффективность для прогнозирования h -индекса ученого в наборе данных APS, но другие функции не имеют очевидных эффектов, что отличается от результатов эксперимента на MAG.

Кроме того, мы проанализировали важность функции, придаваемую XGBoost результатам в наборе данных MAG и APS. В XGBoost важность объекта может быть рассчитана как время, в течение которого объект использовался для разделения выборок на листьях деревьев в модели. Чем чаще использовалась функция, тем важнее это для модели. Как показано на рис. 7, в обоих наборах данных основные влияющие факторы по-прежнему совпадают с приведенными выше выводами, где факторы, ориентированные на статьи, по-прежнему являются наиболее важными для прогнозирования будущего академического успеха в MAG, который набирает 41,67% баллов важности; а факторы, ориентированные на автора, важны в APS, который набирает 42,33% баллов по важности.

Помимо этого, мы также анализируем коэффициент Джини различных учреждений. Коэффициент Джини, меньший 0,2, указывает на абсолютное равенство учреждений. Коэффициент Джини от 0,2 до 0,3 указывает на то, что учреждения относительно равны. Коэффициент Джини от 0,3 до 0,4 указывает на то, что учреждения относительно «нормальны». Наконец, коэффициент Джини, превышающий 0,4, указывает на большое неравенство между учреждениями.




Рис. 5. Анализ факторного вклада на MAG. Четыре модели, обученные только с указанными факторами или без них. F: полный набор функций; A: Факторы автора; P: Факторы статьи; V: Факторы места проведения; I: Факторы учреждения; T: Факторы времени.




Рис. 6. Анализ факторного вклада на APS. Четыре модели, обученные только с указанными факторами или без них. F: полный набор функций; A: факторы автора; P: факторы статьи; V: факторы места проведения; I: факторы учреждения; T: факторы времени.




Рис. 7. Оценка важности различных факторов

Таблица 4

Средние коэффициенты Джини высших учебных заведений по MAG

	Количество статей	Цитирование	h-индекс
Наивысшие 5 %	0,102418	0,161101	0,042667
Наивысшие 10 %	0,191524	0,277041	0,091791
Наивысшие 20 %	0,230564	0,327122	0,121142
Наименьшие 10 %	0,351485	0,452952	0,200423

Таблица 5

Средние коэффициенты Джини высших рейтинговых учреждений Американского физического общества (APS)

	Количество статей	Цитирование	h-индекс
Наивысшие 5 %	0,011092	0,070037	0,015215
Наивысшие 10 %	0,169559	0,205179	0,145778
Наивысшие 20 %	0,216014	0,249943	0,184754
Наименьшие 10 %	0,266891	0,297307	0,228714

Чтобы получить всеобъемлющий коэффициент Джини для учреждения, мы сначала ранжируем учреждения в соответствии с количеством ученых. Затем в соответствии с рейтинговым списком можно получить коэффициент Джини по цитированию, количеству публикаций и h -индексу. Мы показываем коэффициент Джини для первых 5%, 10%, 20% и последних 10%. Как показано в таблицах 4 и 5, существуют некоторые интересные явления. Для топ-5% рейтинговых учреждений, как в MAG, так и в APS, их значения коэффициента Джини составляют менее 0,2, что указывает на то, что h -индекс ученых очень близок к их коллегам в том же учреждении. В топ-10% рейтинговых институтов, за исключением цитирования, коэффи-

циенты Джини для количества статей и h -индекса составляют менее 0,2, что по-прежнему показывает равенство ученых по этим двум аспектам. В то время как для учреждений, входящих в топ-20% и последние 10%, их коэффициент Джини для количества статей и цитирования превышает 0,2. Очевидно, что существуют некоторые различия в количестве статей и цитируемости исследователей в этих учреждениях. Однако уровень h -индекса ученых во всех упомянутых выше учреждениях очень похож на уровень их коллег. Это явление показывает, что ученые в одном и том же учреждении – это люди одного склада. И это явление одинаково в информатике и физике. Причина этого заключается в том, что научное общение между ними очень

удобное и частое, и они могут в какой-то степени непосредственно ощущать давление со стороны своих коллег. Поэтому ученые стараются не отставать от своих коллег в академических исследованиях, и их общее научное воздействие весьма похоже друг на друга. Кроме того, при предоставлении преподавательских должностей для исследователей могут существовать стандартные требования к найму для одного и того же учреждения. Как следствие, ученые в одном и том же учебном заведении находятся на одном и том же академическом уровне.

ЗАКЛЮЧЕНИЕ И ДАЛЬНЕЙШАЯ РАБОТА

В этой статье мы стремимся выявить причинно-следственные факторы, которые играют решающую роль в прогнозировании академических успехов ученых. Чтобы решить эту проблему, мы сначала предлагаем пять потенциальных причинно-следственных факторов, которые являются факторами, ориентированными на статью, факторами, ориентированными на автора, факторами, ориентированными на место проведения, факторами, ориентированными на учреждение, и факторами времени. Затем, используя самые современные алгоритмы машинного обучения, мы обнаружили, что факторы, ориентированные на автора и статью, являются наиболее значимыми причинно-следственными факторами для прогнозирования будущего успеха ученых.

Кроме того, мы анализировали вклад каждого фактора, используя метод "складного ножа" и оценивая факторы в процессе прогнозирования. Результаты еще раз демонстрируют важность факторов, ориентированных на статью и автора. Далее мы анализировали конкретный рейтинг важности этих пяти групп факторов, используемых в наших экспериментах. После этого процесса мы обнаружили, что в наборе данных MAG факторы, ориентированные на статью, имеют важность 41,47%, факторы, ориентированные на автора, имеют важность 25%, факторы, ориентированные на время, имеют важность 16,67%, а факторы, ориентированные на место и учреждение, имеют важность 8,33%, в то время как в наборе данных APS факторы, ориентированные на статью, имеют важность 33,42%, факторы, ориентированные на автора, имеют важность 42,33%, факторы, ориентированные на время, имеют важность 6,39%, факторы, ориентированные на место, имеют важность 8,50%, а факторы, ориентированные на учреждение, имеют важность 9,36%. Между тем, мы также обнаружили, что *h*-индекс ученых в одних и тех же учреждениях, как правило, очень близок друг к другу.

В дальнейшем мы планируем выявить больше факторов и провести наши эксперименты с другими наборами данных из различных дисциплин, чтобы продемонстрировать обоснованность нашей работы.

ЛИТЕРАТУРА

1. *Acuna D. E., Allesina S., Kording K. P.* Future impact: Predicting scientific success // *Nature*. — 2012. — Vol. 489, No. 7415. — P. 201.
2. *Amjad T., Daud A., Che D., AtiaAkram.* MuICE: Mutual influence and citation exclusivity author rank // *Information Processing & Management*. — 2016. — Vol. 52, No 3. — P. 374–386.
3. *Amjad T., Ding Y., Daud A., Xu J., Malic V.* Topic-based heterogeneous rank // *Scientometrics*. — 2015. — Vol. 104, No. 1. — P. 313–334.
4. *Amjad T., Ding Y., Xu J., Zhang C., Daud A., Tang J., Min Song M.* Standing on the shoulders of giants // *Journal of Informetrics*. — 2017. — Vol. 11, No. 1. — P. 307–323.
5. *Bai X., Ivan Lee I., Ning Z., Tolba A., Xia F.* The role of positive and negative citations in scientific evaluation // *IEEE Access*. — 2017. — Vol. 5, No. 99. — P. 17607–17617.
6. *Bornmann L., Haunschild R.* How to normalize Twitter counts? A first attempt based on journals in the Twitter index // *Scientometrics*. — 2016. — Vol. 107, No. 3. — P. 1405–1422.
7. *Cao X., Yan Chen Y., Ray Liu K. J.* A data analytic approach to quantifying scientific impact // *Journal of Informetrics*. — 2016. — Vol. 10, No. 2. — P. 471–484.
8. *Clauset A., Larremore D. B., Sinatra R.* Data-driven predictions in the science of science // *Science*. — 2017. — Vol. 355, No. 6324. — P. 477–480.
9. *Costas R., Zabedi Z., Wouters P.* Do "altmetrics" correlate with citations? Extensive comparison of altmetric indicators with citations from a multidisciplinary perspective // *Journal of the Association for Information Science & Technology*. — 2015. — Vol. 66, No 10. — P. 2003–2019.
10. *Dong Y., Johnson R., Chawla N.* Can scientific impact be predicted? // *IEEE Transactions on BigData*. — 2016. — Vol. 2, No. 1. — P. 18–30.
11. *Dunaiski M., Visser W., Geldenhuys J.* Evaluating paper and author ranking algorithms using impact and contribution awards // *Journal of Informetrics*. — 2016. — Vol. 10, No. 2. — P. 392–407.
12. *Egghe E.* Theory and practise of the g-index // *Scientometrics*. — 2006. — Vol. 69, No. 1. — P. 131–152.
13. *Fortunato S., Bergstrom C. T., Børner K., J. A. Evans J. A., Helbing D., Milojević S., Petersen A. M., Radicchi F., Sinatra R., Uzzi B.* Science of science // *Science*. — 2018. — Vol. 359, No. 637. — P. 1007–1007.
14. *Garfield E.* The history and meaning of the journal impact factor // *Jama*. — 2006. — Vol. 295, No. 1. — P. 90–93.
15. *Heiberger R. H., Wiecek O. J.* Choosing collaboration partners. How scientific success in Physics depends on network positions. — 2016. — [arXiv:1608.03251 abs/1608.03251 (2016), p.201–207].
16. *Hirsch J. E.* An index to quantify an individual's scientific research output // *Proceedings of the Nation-*

- al academy of Sciences of the United States of America. — 2005. — Vol. 102, No. 46. — P. 16569–16572.
17. *Kleinberg J. M.* Authoritative sources in a hyper-linked environment // *J. ACM.* — 1999. — Vol. 46, No. 5 (Sept. 1999). — P. 604–632.
18. *Klimek P., Jovanovic A. S., Eglhoff R., Schneider R.* Successful fish go with the flow: Citation impact prediction based on centrality measures for term document networks // *Scientometrics.* — 2016. — Vol. 107, No. 3. — P. 1265–1282.
19. *Kong X., Shi Y., W., Kai Ma, Wan L., Xia F.* The evolution of Turing Award Collaboration Network: Bibliometric-level and network-level metrics // *IEEE Transactions on Computational Social Systems.* — 2019. — Vol. 6, No. 6. — P. 1318–1328. — <https://doi.org/10.1109/TCSS.2019.2950445>
20. *Le T., Liu L., Tytkin A., Goodall G. J., Liu B., Sun B. -Y., Li J.* Inferring microRNA–mRNA causal regulatory relationships from expression data // *Bioinformatics.* — 2013. — Vol. 29, No. 6. — P. 765–771.
21. *Li J., Le T., Liu L., Liu J., Jin Z., Sun B., Ma S.* From observational studies to causal rule mining // *ACM Transactions on Intelligent Systems and Technology (IIST).* — 2016. — Vol. 7, No. 2. — P. 14.
22. *Li L., Tong H.* The child is father of the man: Foresee the Success at the early stage / *AcmSigkdd International Conference on Knowledge Discovery & Data Mining// ACM, Sydney, NSW.* — 2015. — P. 655–664.
23. *Liang R., Jiang X.* Scientific ranking over heterogeneous academic hyper-network // *Proceedings of the Thirtieth AAAI Conference on Artificial Intelligence.* AAAI, AAAI Press, Phoenix, Arizona, USA. — 2016. — P. 20–26.
24. *Liu J., Xia F., Wang L., Xu B., Kong X., Tong H., King I.* Shifu2: A network representation learning based model for advisor–advisee relationship mining // *IEEE Transactions on Knowledge and Data Engineering.* — 2019. — Vol. 33, No. 4. — P. 1763–1777. — <https://doi.org/10.1109/TKDE.2019.2946825>
25. *Liu L., Wang Y., Sinatra R., Lee Giles C., Song C., Wang D.* Hot streaks in artistic, cultural, and scientific careers // *Nature.* — 2018. — Vol. 559, No. 7714. — P. 396–399. — <https://doi.org/10.1038/s41586-018-0315-8>
26. *Liu Y., Zhang L., Nie L., Yan Y., Rosenblum D. S.* Fortune teller: Predicting your career path / *Proceedings of the Thirtieth AAAI Conference on Artificial Intelligence.* — 2016. — Vol. 2016. — AAAI Press, Phoenix, Arizona, USA. — P. 201–207.
27. *Page L., Brin S., Motwani R., Winograd T.* The PageRank citation ranking: Bringing order to the Web. Technical Report 1999-66. — Stanford InfoLab, 1999. — [http://ilpubs.stanford.edu:8090/422/Previous number =SIDL-WP-1999-0120](http://ilpubs.stanford.edu:8090/422/Previous%20number%20-%20SIDL-WP-1999-0120).
28. *Severiano A., Carriço J. A., Robinson D. A., Ramirez M., Pinto F. R.* Evaluation of jackknife and bootstrap for defining confidence intervals for pairwise agreement measures // *PLoS One.* — 2011. — Vol. 6, No. 5, e19539.
29. *Shiffrin R. M.* Drawing causal inference from Big Data // *Proceedings of the National Academy of Sciences.* — 2016. — Vol. 113, No. 27. — P. 7308–7309.
30. *Sinatra R., Wang D., Deville P., Song C., Barabási A.-L.* Quantifying the evolution of individual scientific impact // *Science.* — 2016. — Vol. 354, No. 6312. — P. aaf5239–aaf5239.
31. *Spirtes P., Zhang K.* Causal discovery and inference: Concepts and recent methodological advances // *Applied Informatics.* — 2016. — Vol. 3, No. 1 (02 2016). — P. 1–28.
32. *Stegehuis C., Litvak N., Waltman L.* Predicting the long-term citation impact of recent publications // *Journal of Informetrics.* — 2015. — Vol. 9, No.3. — P. 642–657.
33. *Valenzuela M., Ha V., Etzioni O.* Identifying meaningful citations / *Workshops at the Twenty-Ninth AAAI Conference on Artificial Intelligence,* Vol. WS-15-13. — AAAI, AAAI Press, Austin, Texas, USA, 2015. — P. 21–26.
34. *Van Houten B., Phelps J., Barnes M., Suk W. A.* Evaluating scientific impact // *Environmental health perspectives.* — 2000. — Vol. 108, No. 9. — P. A392–A393.
35. *Wang D., Chaoming Song C., Barabási A.-L.* Quantifying long-term scientific impact // *Science.* — 2013. — Vol. 342, No. 6154. — P. 127–132.
36. *Wang S., Xie S., Zhang S., Li Z., He Y., He Y.* Coranking the future influence of multiobjects in bibliographic network through mutual reinforcement // *ACM Transactions on Intelligent Systems & Technology.* — 2016. — Vol. 7, No. 4. — P. 64:1–64:28.
37. *Wang W., Yu S., Bekele T. M., Kong X., Xia F.* Scientific collaboration patterns vary with scholars' academic ages // *Scientometrics.* — 2017. — Vol. 112, No. 1. — P. 329–343.
38. *Wu H., Sun M., Mi P., Tatti N., Chris North C., Ramakrishnan N.* Interactive discovery of coordinated relationship chains with maximum entropy models // *ACM Transactions on Knowledge Discovery from Data (TKDD).* — 2018. — Vol. 12, No. 1. — P. 7.
39. *Xia F., Su X., Wei W., Zhang C., Ning Z., Lee I.* Bibliographic analysis of Nature based on Twitter and Facebook altmetrics data // *Plos One.* — 2016. — Vol. 11, No. 12.
40. *Xia F., Wang W., Bekele T. M., Liu H.* Big Scholarly Data: A survey // *IEEE Transactions on Big Data.* — 2017. — Vol. 3, No. 1. — P. 18–35.
41. *Yang Y., Tang J., Li J.* Learning to infer competitive relationships in heterogeneous networks // *ACM Transactions on Knowledge Discovery from Data (TKDD).* — 2018. — Vol. 12, No.1. — P. 12.
42. *Yu D., Wang W., Zhang S., Zhang W., Liu R.* A multiple-link, mutually reinforced journal-ranking model to measure the prestige of journals // *Scientometrics.* — 2017. — Vol. 111, No.1. — P. 521–542.
43. *Zhang J., Ning Z., Bai X., Kong X., Zhou J., Xia F.* Exploring time factors in measuring the scientific impact of scholars // *Scientometrics.* — 2017. — Vol. 112, No. 3. — P. 1301–1321.