

## Психология

УДК 159.9.07 : 004.738.5(045)

*Г.З. Вахитов, П.Н. Устин, Л.М. Попов, Ф.М. Гафаров*

### ПРЕДИКТОРЫ СЕТЕВОЙ СОЦИАЛЬНОЙ УСПЕШНОСТИ ЛИЧНОСТИ

Сетевая социальная успешность проявляется в способности личности поддерживать широкие связи в социальной сети и влиять на других ее пользователей. Это связано как с собственной активностью пользователя социальной сети, так и с вниманием других пользователей к содержанию его персонального профиля, что отражается в виде лайков и репостов, а также во времени, проведенном на его странице и желании транслировать его позицию другим пользователям. Цель исследования – выделить предикторы сетевой социальной успешности личности. Гипотеза исследования – в качестве предикторов сетевой социальной успешности могут быть метрики персонального профиля пользователя социальной сети и метрики его социального графа. Выборку в объеме 30 950 испытуемых составили девушки (18 304) и юноши (12 645) в возрастном диапазоне от 18 до 26 лет ( $Me=20,3$ ), обучающиеся на разных курсах бакалавриата (25 835) и магистратуры (5 114) по гуманитарному (69 %), техническому (19 %) и естественно-научному (12 %) направлениям. В исследовании были использованы анонимизированные данные персональных профилей испытуемых в социальной сети ВКонтакте. Они были разделены на несколько групп по степени их сетевой социальной успешности. Для ее прогнозирования были использованы модели на основе машинного обучения и нейронных сетей. Это позволило выявить ряд метрик профиля пользователя и метрик его социального графа, которые можно рассматривать в качестве предикторов его сетевой социальной успешности. Наличие таких предикторов позволяет, не выявляя репостов сообщений и степени активности в сети пользователя, оценивать его реальные связи в социальной сети и его влияние. Результаты исследования могут быть использованы при прогнозировании сетевой социальной успешности пользователей через нейросетевой анализ метрик их персонального профиля в социальной сети ВКонтакте, отражающих особенности их виртуальной активности в цифровой среде.

*Ключевые слова:* социальная сеть, нейронная сеть, сетевая социальная успешность, машинное обучение.

DOI: 10.35634/2412-9550-2023-33-4-344-355

### Введение

В данной статье представлены данные, полученные в результате выполнения одной из задач в рамках междисциплинарного исследовательского проекта, который был направлен на создание и апробацию нейросетевой психометрической модели когнитивно-поведенческих предикторов жизненной активности личности на базе социальных сетей. В данном проекте психологи и специалисты в области информационных технологий совместно проводят исследование, которое направлено на изучение особенностей взаимосвязи реального и виртуального поведения личности. В качестве показателей виртуального поведения личности выступает ряд характеристик ее персонального профиля в социальной сети ВКонтакте. Проблема прогнозирования поведения человека через особенности его виртуальной активности в цифровой среде привлекает все большее число исследователей, что связано с особенностями трансформации социально-психологического пространства в сторону его виртуализации и цифровизации. В частности, попытки решения частных задач обозначенной проблемы находят свое отражение в работах G. Seidman [17], C.J. Blomfield Neira и B.L. Barber [1], M. Kosinski и Y. Wang [24], где авторы показывают, как метрики персонального профиля пользователя социальной сети Фейсбук соотносятся с личностными и поведенческими показателями, такими как экстраверсия, самооценка, сексуальные ориентации и др.

В Казанском университете проведены серии исследований, направленных на анализ взаимосвязей метрик персонального профиля пользователей социальной сети ВКонтакте с их академической и профессиональной успешностью [13; 14]. Проведенные работы выявили потребность в изучении социальной успешности пользователей социальных сетей. В данном исследовании социальная успешность в контексте сетевой среды определяется как способность пользователя виртуального пространства со-

здавать широкую сеть контактов, обмениваться информацией, проявлять интерес к другим пользователям и вовлекать их в свои интересы, создавать собственные группы пользователей, а также оказывать влияние на других участников.

В настоящее время к одному из перспективных инструментов анализа и интерпретации сетевой социальной успешности пользователей социальных онлайн-платформ относят анализ социальных графов. Социальные графы являются математическими моделями, состоящими из вершин и ребер, которые соединяют определенные пары вершин и позволяют отражать особенности межличностных отношений пользователей социальных сетей через различные параметры [2; 21]. Эти параметры включают количество и плотность связей между вершинами, меры центральности по близости и по степени, коэффициенты кластеризации, взаимность, сплоченность и т. д. Путем анализа этих параметров можно определить такие характеристики, как статус, влияние на других пользователей, структура и динамика отношений в группе, принадлежность пользователя к сплоченной или разобщенной группе, скорость распространения информации в группе и т. д.

В работе [12] дан обзор современных достижений в идентификации наиболее значимых членов сообществ при их представлении в виде элементов графа, а также алгоритмов, позволяющих выявлять структуру сообществ и значимость его членов.

Подробное исследование различных мер центральности в социальной сети с математическими определениями представлено в обзоре [2]. В статье [8] показано современное состояние понимания применимости мер центральности при анализе социальных сетей. Также авторы анализируют наиболее популярные меры центральности. В [21] авторы раскрывают различные математические методы анализа сообществ в социальных сетях и представляют свою модель оценки сходства членов различных сообществ на основе исследования графов этих сообществ.

В работе [9] представлены модель регулярного графа, модель экспоненциально случайного графа, модель сети малого мира и модель безмасштабной сети для анализа структуры графа на трех уровнях: микроуровень, мезоуровень и макроуровень. В работе [18] раскрываются свойства известных социальных сетей, таких как Facebook и Twitter, а также анализируются их основные параметры, такие как коэффициент кластеризации, степень узла, диаметр сети.

Одним из наиболее активно развивающихся направлений является моделирование социальных сетей на основе современных методов машинного обучения и искусственных нейронных сетей, а также выявление предикторов на основе такого моделирования [3; 4; 6; 7; 20].

В работе [7] авторы раскрывают результаты использования основных методов машинного обучения для анализа социальных сетей. Глубокое обучение с точностью 99 % и 93 % превзошло другие модели. При этом обобщенная линейная модель позволила обеспечивать точность 90 % и 85 %. В [6] предложен новый подход на основе машинного обучения для прогнозирования будущих влиятельных узлов в социальной сети с учетом структурных и семантических характеристик узлов. Кроме того, платформы социальных сетей часто используют нейронные сети с упором на социальный анализ для прогнозирования контента, соответствующего предпочтениям пользователей [20], позволяют распознавать эмоции, соответствующие определенному контенту, загружаемому пользователями в социальные сети. В [4] модели искусственных нейронных сетей были реализованы для изучения возможных взаимосвязей между удовлетворенностью жизнью, самооценкой, тревогой, депрессией и интенсивностью использования Instagram. Модели в 71–82 % случаях смогли правильно предсказать наличие связи между анализируемыми психологическими состояниями и интенсивностью использования Instagram.

В настоящее время становится популярным использование объяснимых методов искусственного интеллекта (ХАИ) для обретения уверенности в моделях машинного обучения, а также для обеспечения объяснимости решений, принимаемых с использованием этих моделей [16]. Наиболее популярными методами являются локальное интерпретируемое независимое объяснение модели (LIME) [15], аддитивное объяснение формы (SHAP) [10] и интегрированных градиентов (IG) [19]. Постепенно набирают популярность при анализе социальных сетей методы ХАИ [5; 22].

Цель исследования состояла в том, чтобы идентифицировать предикторы сетевой социальной успешности личности на основе нейросетевых алгоритмов анализа особенностей ее виртуального поведения в социальной сети ВКонтакте. Гипотезой исследования выступило предположение, что в качестве предикторов социальной успешности выступает ряд показателей персонального профиля и социального графа пользователя социальной сети, отражающих особенности его виртуального поведения в цифровой среде.

Научная новизна представленного исследования связана с выделением основных маркеров виртуального поведения пользователей в социальной сети ВКонтакте, определяющих направленность (по дружелюбию и доминированию) и степень их социальной успешности как одного из показателей жизненной активности личности.

Теоретическая значимость исследования определяется вкладом в разработку проблемы прогнозирования поведения личности на основе особенностей ее виртуального поведения в социальных сетях. В частности, показаны закономерности проявления сетевой социальной успешности личности на основе ее репродуктивного (метрика «Посты») и коммуникативного характера (метрика «Друзья») взаимодействия с другими пользователями.

### Методы и методики исследования

Исследование основано на данных, полученных из открытых профилей пользователей социальной сети ВКонтакте с помощью специально разработанной в рамках данного исследования информационно-аналитической системы. В выборку вошли студенты, обучающиеся на всех курсах в бакалавриате (25 835 испытуемых) и в магистратуре (5 114 испытуемых) по гуманитарному (69 %), техническому (19 %) и естественно-научному (12 %) направлениям. Общий объем выборки составил 30 949 испытуемых, из них 18 304 девушек и 12 645 юношей в возрасте от 18 до 26 лет ( $M_e=20,3$ ). В итоге мы получили данные более чем 30 000 таких пользователей, которые были анонимизированы. Ранее на этих же данных нами были выявлены предикторы академической успешности студентов, что описано в работах [13; 14].

Для каждого пользователя также была получена информация, описывающая локальные графы взаимосвязей (друзья и друзья друзей), а также рассчитывались некоторые базовые характеристики графа, то есть метрики социального графа: коэффициент кластеризации, центральность по близости, центральность по степени, плотность. В результате была создана база данных, каждая запись которой содержит поля, являющиеся метриками профиля пользователя социальной сети или метриками социального графа: «Друзья» (количество друзей на странице пользователя); «Подписчики» (количество у пользователя подписчиков); «Фото» (количество фотографий с персональной страницы и стены пользователя); «Видео» (количество у пользователя видеозаписей); «Аудио» (количество аудиозаписей пользователя); «Интересные страницы» (количество у пользователя интересных страниц); «Лайки личных постов» (количество лайков к личным постам пользователя, которые получены от других пользователей); «Репосты» (количество всех репостов на странице пользователя); «Лайки репостов» (общее количество лайков всех репостов на странице пользователя); «Фото профиля» (количество фотографий пользователя в альбоме «профиль» пользователя его страницы в соцсети); «Лайки аватара» (общее количество лайков к фотографиям в альбоме профиля его страницы (на аватаре), сделанных любыми другими пользователями); «Видео на странице» (количество видеороликов на странице пользователя); «Лайки видео» (количество лайков к видео пользователя); «Заемствование постов пользователя» (общее количество заимствований постов пользователя любыми другими пользователями); «Заемствование пользователем постов» (количество постов и других элементов, заимствованных пользователем у других пользователей, с комментариями пользователя); «Лайки заимствованных постов с комментариями» (общее количество лайков на посты и другие объекты, заимствованные пользователем у других пользователей, с комментариями пользователя); «Просмотры» (общее количество просмотров постов на странице пользователя); «Онлайн» (количество раз, когда пользователь был онлайн во время проведения сбора данных); «Посты, заимствованные пользователем без комментариев» (количество постов и других объектов, заимствованных пользователем у других пользователей, без комментариев пользователя); «Лайки заимствованных постов без комментариев» (общее количество лайков к постам и другим объектам, заимствованным пользователем у других пользователей, без комментариев пользователя); «Лайки постов» (количество лайков личных сообщений на странице пользователя); «Заполненность профиля» (степень завершения профиля пользователя); «Коэффициент кластеризации» (показатель, характеризующий тенденцию вершин графа группироваться вместе); «Центральность по близости» (показатель того, насколько близок данный узел ко всем другим узлам в социальном графе); «Центральность по степени» (отношение количества связей конкретного узла к общему количеству других узлов в одном социальном графе).

Для анализа и обработки данных мы использовали распространенные библиотеки Python, такие как pandas, пакет numpy для научных вычислений и библиотеку визуализации данных Seaborn на основе matplotlib.

Как уже было уточнено, под сетевой социальной успешностью мы понимаем способность пользователя социальной сети поддерживать широкие связи в социальной сети и влиять на ее других пользователей. В соответствии с этим определением для каждого пользователя социальной сети мы рассчитали показатели сетевой социальной успешности по дружелюбию (далее ССУДр) и сетевой социальной успешности по доминированию (далее ССУДом) [23].

Индикатор ССУДр строится на основе следующих метрик: «Центральность по близости», «Онлайн», «Посты, заимствованные пользователем без комментариев», «Лайки постов», «Заполненность профиля». Данный набор обоснован необходимостью снижения влияния эффекта социальной желательности. Часть метрик («Онлайн», «Посты, заимствованные пользователем без комментариев», «Заполненность профиля») не рассматривается пользователем в качестве значимых для демонстрации своей социальной успешности по дружелюбию, а другая часть («Центральность по близости», «Лайки постов») не подвергается влиянию пользователя из-за зависимости от других участников социальной сети.

Индикатор ССУДом строится на основе следующих метрик: «Коэффициент кластеризации», «Центральность по степени», «Просмотры», «Заимствование постов пользователя», «Лайки заимствованных постов с комментариями», «Заимствование пользователем постов». Использование данного набора метрик также обусловлено их низкой зависимостью от сознательного желания пользователя продемонстрировать свое влияние на других участников социальной сети.

Для построения формулы расчета индикаторов ССУДр и ССУДом были использованы коэффициенты (рейтинги), значения которых были рассчитаны численными методами по следующему алгоритму. На основе проведенного исследования на выборке более 900 испытуемых с использованием опросника межличностных отношений Т. Лири (в адаптации Л.Н. Собчик) были рассчитаны 2 интегральных показателя – «Дружелюбие» и «Доминирование». Далее для каждого испытуемого (имеющего открытый персональный профиль в социальной сети ВКонтакте) методом перебора были рассчитаны разности реальных значений ССУДр и ССУДом и значений, рассчитанных по формуле с различными вариантами коэффициентов. Результатом полученных разностей для использованных наборов коэффициентов на всем объеме исследовательской выборки выступил набор суммарных ошибок. Итоговые коэффициенты формул социальной успешности по дружелюбию и доминированию были определены исходя из тех наборов, которые показали минимальную ошибку.

В рамках нейросетевого анализа все записи были разделены на пять групп, как по признаку ССУДр, так и по ССУДом. В каждую группу вошли по 20 % лиц с низкими, средне-низкими, средними, средневысокими и высокими значениями ССУДр и ССУДом. Далее 20 % записей лиц со средними значениями при обучении нейросетей не использовались. Остальные 80 % данных, состоящих из метрик профиля и метрик социального графа пользователя, использовались для обучения нейронных сетей идентифицировать предикторы ССУДр и ССУДом.

Алгоритмы машинного обучения были реализованы с использованием библиотек sklearn и torch языка программирования Python. Библиотека sklearn предназначена для машинного обучения, включает в себя различные алгоритмы, в том числе предназначенные для задач классификации, регрессионного и кластерного анализа данных и т. д. Библиотека torch использовалась для обучения моделей на основе нейронных сетей.

Далее были определены класс многослойного перцептрона MLP, функции train и test. В качестве функции потерь была использована CrossEntropyLoss. В качестве оптимизатора использован Adam – один из самых эффективных алгоритмов оптимизации в обучении нейронных сетей. Его скорость обучения была установлена равной  $5e-4$ .

В качестве альтернативного метода прогнозирования, основанного на использовании нескольких деревьев решений, использовался алгоритм классификатора машинного обучения RandomForest. Исходный набор данных был сбалансированным, то есть содержал одинаковое количество записей с высоким и низким ССУДр или ССУДом.

Поэтому в качестве основного показателя для оценки работы обученных моделей машинного обучения мы использовали ассигасу (точность).

Набор данных был разделен на обучающую и тестовую выборку отдельно для ССУДр и ССУДом. Доли обучающей и тестовой выборок составили 70 % и 30 % от общего объема данных.

Для интерпретации модели машинного обучения мы использовали алгоритм SHAP [10]. Для лучшей наглядности графики были построены на основе значений SHAP. Он предназначен для отображения информативной сводки о том, как основные входные данные в наборе данных влияют на выходные данные модели. На этих графиках точки представляют собой значение SHAP соответствующего входного параметра. Мы также использовали методы Integrated Gradients [19] и Feature Ablation [11] для расчета и визуализации важности функций.

## Результаты и обсуждение

Для случая обучения нейронной сети на данных ССУДр результат обучения показан на рис. 1. Обучение проводилось в течение 300 эпох.

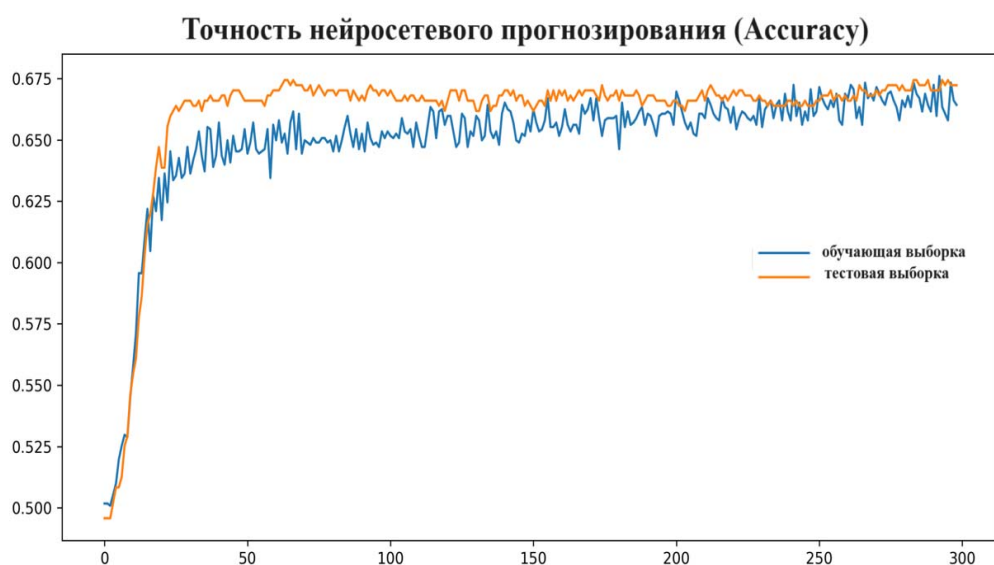


Рис. 1. Точность нейросетевого прогнозирования (Accuracy) сетевой социальной успешности по дружелюбию (ССУДр)

Результаты использования алгоритма SHAP на обученной нейронной сети для ССУДр показаны на рис. 2. Метрики на рисунке имеют наибольшую значимость среди всех остальных, а их значимость раскрывается с помощью алгоритма SHAP.

Чем больше значение SHAP для конкретного параметра, тем правее этот входной параметр расположен на горизонтальной оси координат. На вертикальной оси координат входные параметры расположены в порядке важности (чем она выше, тем большее влияние параметр оказывает на результаты модели). Цвет используется для отображения значений исходных параметров (красный – наибольшие значения исходного параметра, синий – наименьшие значения).

Настройка параметров перебором для классификатора RandomForest осуществлялась при помощи инструмента GridSearchCV. Настраивались такие параметры, как `n_estimators` (количество деревьев в лесу), `max_depth` (максимальная глубина дерева).

Для интерпретации важности входных признаков были использованы методы Integrated Gradients [20] и Feature Ablation [24]. Также для сглаживания результатов метода атрибуции Integrated Gradients был применен шумовой туннель. Для каждого из методов интерпретации был построен график, который отражает важность каждого входного признака.

Результаты применения методов Integrated Gradients (IG), Integrated Gradients с использованием шумового туннеля (IG with Noise Tunnel) и Feature Ablation приведены для случая сетевой социальной успешности по дружелюбию ССУДр на рис. 3.

Представленные результаты свидетельствуют о том, что на этом этапе достигается точность не более 67%. В качестве основных предикторов ССУДр могут использоваться такие метрики персонального профиля пользователя ВКонтакте, как «Репосты», «Подписчики», «Друзья», «Лайки личных постов», «Фото». Метрика «Репосты» имеет наибольшую значимость в качестве предиктора.




Рис. 2. Результаты применения алгоритма SHAP на нейронной сети ССУДр

Условные обозначения: *friends* – «Друзья», *followers* – «Подписчики», *photos* – «Фото», *videos* – «Видео», *audios* – «Аудио», *pages* – «Интересные страницы», *post\_likes* – «Лайки личных постов», *all\_repost\_count* – «Репосты», *photos\_count* – «Фото профиля», *photos\_likes* – «Лайки аватара».

Для случая ССУДом результаты показаны на рис. 4. Он показывает изменение точности в зависимости от количества эпох. Обучение нейронной сети также проводилось в течение 300 эпох. Точность полученных результатов достигла 86 %.

Результаты использования алгоритма SHAP при обучении нейронной сети для ССУДом показаны на рис. 5. Значимость входных параметров представлена на рис. 6.

Основными предикторами ССУДом являются: «Друзья», «Лайки личных постов», «Лайки аватара», «Фото профиля», Интересные страницы. Метрика «Друзья» имеет наибольшую значимость в качестве предиктора.

Основными направлениями повышения практической значимости результатов мы видим совершенствование методов расчета показателей ССУДр и ССУДом.

В результате выявления предикторов сетевой социальной успешности мы получили результаты на уровне 67 % для ССУДр и 86 % для ССУДом. Результаты ССУДом позволяют делать прогнозы. Однако результаты для ССУДр нельзя признать удовлетворительными. По нашему мнению, повышение качества прогнозирования ССУДр может быть связано с поиском более точных параметров профиля пользователя социальной сети, что можно объяснить его дружелюбием в социальной сети. Стоит отметить, что данные были собраны о студентах университета с целью выявления предикторов академической успешности. То есть данные относятся к молодым людям из разных стран и получающим разные специальности. Поэтому для повышения качества предикторов планируется провести дополнительное исследование, в ходе которого разделить студентов на несколько групп с точки зрения того, что считается проявлением дружелюбия в социальной сети представителями разных стран.

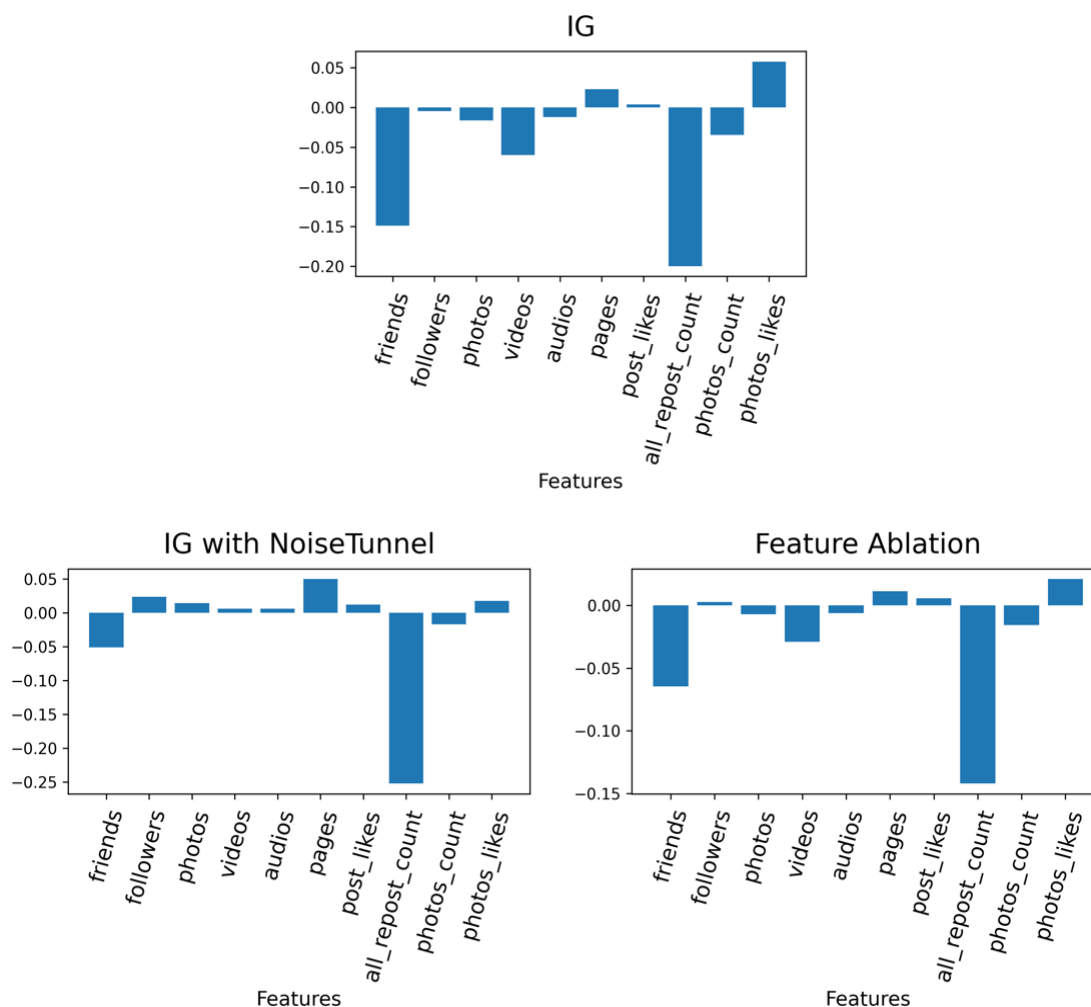


Рис. 3. Результаты применения метода Integrated Gradients, метода Integrated Gradients с использованием шумового туннеля и метода Feature Ablation для интерпретации работы нейронной сети по определению ССУДр

Условные обозначения: *friends* – «Друзья», *followers* – «Подписчики», *photos* – «Фото», *videos* – «Видео», *audios* – «Аудио», *pages* – «Интересные страницы», *post\_likes* – «Лайки личных постов», *all\_repost\_count* – «Репосты», *photos\_count* – «Фото профиля», *photos\_likes* – «Лайки аватара».



Рис. 4. Точность нейросетевого распознавания (Ассурасу) ССУДом




Рис. 5. Результаты применения алгоритма SHAP при обучении нейронной сети для ССУДом

Условные обозначения: *friends* – «Друзья», *followers* – «Подписчики», *photos* – «Фото», *videos* – «Видео», *audios* – «Аудио», *pages* – «Интересные страницы», *post\_likes* – «Лайки личных постов», *all\_repost\_count* – «Репосты», *photos\_count* – «Фото профиля», *photos\_likes* – «Лайки аватара».

Следует также отметить, что существует разница между выявлением предикторов академической успешности и выявлением предикторов сетевой социальной успешности. В случае академической успешности мы имели объективные данные в виде оценок студентов, выставленных преподавателями в процессе обучения. В случае сетевой социальной успешности имеет значение эффект социальной желательности. То есть проявление дружелюбия – это норма публичного общения, под которой подразумевается открытое общение в социальных сетях. Также в нашем исследовании мы использовали данные только из открытых профилей.

Что касается выявления признаков, объясняющих классификацию данных, то можно отметить, что результаты, полученные с помощью методов SHAP, Integrated Gradients, Integrated Gradients с использованием шумового туннеля и Feature Ablation, достаточно схожи с точки зрения выявления первого признака. Однако следующие признаки могут уже не быть одинаковыми. По мере развития исследования можно оценить вклад в результат не отдельных признаков, а их групп, поскольку возможно, что некоторые группы признаков оказываются более значимыми, чем каждый из них в отдельности.

Однако на данный момент в исследовании определен ряд предикторов, которые позволяют достаточно точно прогнозировать ССУДом без проведения дополнительного сбора данных и сложных расчетов метрик социальных сетей.



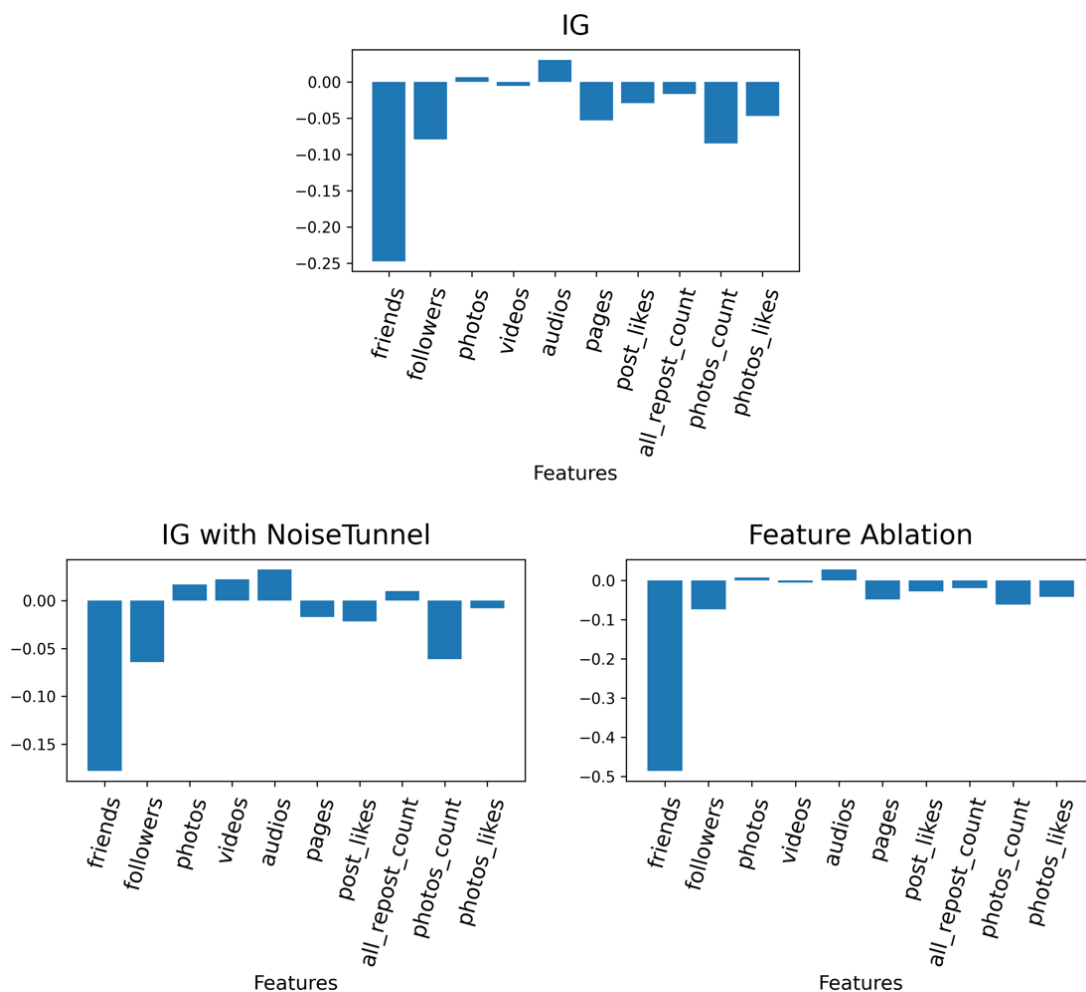


Рис. 6. Результаты применения метода Integrated Gradients, метода Integrated Gradients с использованием шумового туннеля и метода Feature Ablation для интерпретации работы нейронной сети по определению ССУДом

Условные обозначения: *friends* – «Друзья», *followers* – «Подписчики», *photos* – «Фото», *videos* – «Видео», *audios* – «Аудио», *pages* – «Интересные страницы», *post\_likes* – «Лайки личных постов», *all\_repost\_count* – «Репосты», *photos\_count* – «Фото профиля», *photos\_likes* – «Лайки аватара».

## Выводы

В данном междисциплинарном исследовании было осуществлено обучение нейронной сети для распознавания степени сетевой социальной успешности по дружелюбию и сетевой социальной успешности по доминированию. Обучение проводилось по анонимизированным данным метрик открытых профилей пользователей социальной сети ВКонтакте и метрик их социальных графов. Точность обученной нейронной сети для сетевой социальной успешности по дружелюбию составила до 67 %, а точность обученной нейронной сети для сетевой социальной успешности по доминированию – до 86 %.

В результате показаны возможности прогнозирования сетевой социальной успешности личности с помощью анализа ее виртуального поведения. В качестве маркеров виртуального поведения пользователя выступают метрики социальных сетей. В цифровой среде пользователи взаимодействуют друг с другом напрямую или через разнообразные продукты виртуальной активности, в качестве которых в социальных сетях выступают метрики их персонального профиля (например: посты, репосты, лайки, подписчики и др.). Данные метрики, в свою очередь, характеризуют особенности виртуального образа человека, который отражает его «Я-реальное». Следовательно, такие метрики имеют прогностический потенциал и могут быть использованы для анализа и прогнозирования поведения человека в реальной жизни.

Также на основе анализа результатов с использованием методов Integrated Gradients и Feature Ablation определены основные предикторы двух основных показателей социальной успешности: по дружелюбию и по доминированию. Для сетевой социальной успешности по дружелюбию основным предиктором является метрика «Репосты», то есть количество всех репостов на странице пользователя. Для сетевой социальной успешности по доминированию основным предиктором является метрика «Друзья», то есть количество друзей пользователя, перечисленных на его странице.

Выделение обозначенных метрик в качестве основных предикторов демонстрирует, что они имеют наибольший вес (наибольшую роль) при прогнозировании социальной успешности личности. Однако объяснение причин ведущей роли данных метрик при прогнозировании социальной успешности связано с необходимостью дальнейшей психологической интерпретации и видится одной из новых исследовательских перспектив в рамках реализуемого проекта. Кроме того, исходя из логики нейросетевого анализа, точность прогностики определяется совокупностью всех метрик, выступавших в качестве предикторов («Друзья», «Последователи» и др.).

Практическая значимость проведенного исследования состоит, прежде всего, в демонстрации потенциальных возможностей нейросетевых технологий, интеграция которых в арсенал психодиагностических методов значительно расширяет возможности современной психологии в прогнозировании характеристик личности. Результаты, непосредственно описанные в данной работе, раскрывают алгоритмы нейросетевого прогнозирования сетевой социальной успешности личности (по двум интегральным показателям: дружелюбию и доминированию) на основе ряда метрик ее персонального профиля в социальной сети ВКонтакте, отражающих особенности ее активности в виртуальной среде.

## Благодарность

Исследование (все теоретические и эмпирические задачи исследования, представленные в данной статье) выполнено за счет гранта Российского научного фонда, проект № 19-18-00253, «Нейросетевая психометрическая модель когнитивно-поведенческих предикторов жизненной активности личности на базе социальных сетей», <https://rscf.ru/project/19-18-00253/>

## СПИСОК ЛИТЕРАТУРЫ

1. Blomfield Neira C.J., Barber B.L. Social networking site use: Linked to adolescents' social self-concept, self-esteem, and depressed mood // *Australian Journal of Psychology*. 2014. № 66(1). p. 56–64. <https://doi.org/10.1111/ajpy.12034>
2. Das K., Samanta S., Pal M. Study on centrality measures in social networks: a survey // *Social Network Analysis and Mining*. 2018. № 8(1), p. 13. <https://doi.org/10.1007/s13278-018-0493-2>
3. Gafarov F., Berdnikov A., Ustin P. Online social network user performance prediction by graph neural networks // *International Journal of Advances in Intelligent Informatics*. 2022. № 8(3). p. 285–298. <https://doi.org/10.26555/ijain.v8i3.859>
4. Jabłońska M.R., Zajdel R. Artificial neural networks for predicting social comparison effects among female instagram users // *PLOS ONE*. 2020. № 15(2), p. 1–18. <https://doi.org/10.1371/journal.pone.0229354>
5. Johs A.J., Agosto D.E., Weber R.O. Explainable artificial intelligence and social science: Further insights for qualitative investigation // *Applied AI Letters*. 2022. № 3(1). <https://doi.org/10.1002/ail2.64>
6. Karoui W., Hafiene N., Ben Romdhane L. Machine learning-based method to predict influential nodes in dynamic social networks // *Social Network Analysis and Mining*. 2022. № 12(1), p.108. <https://doi.org/10.1007/s13278-022-00942-4>
7. Khan N.U., Wan W., Riaz R., Jiang S., Wang X. Prediction and classification of user activities using machine learning models from location-based social network data // *Applied Sciences* 2023. № 13(6), 3517. <https://doi.org/10.3390/app13063517>
8. Landherr A., Friedl B., Heidemann J. A critical review of centrality measures in social networks // *Business & Information Systems Engineering*. 2010. № 2(6). p. 371–385. <https://doi.org/10.1007/s12599-010-0127-3>
9. Li N., Huang Q., Ge X., He M., Cui S., Huang P., Li S., Fung S.F. A review of the research progress of social network structure // *Complexity* 2021, 2021. 6692210 <https://doi.org/10.1155/2021/6692210>
10. Lundberg S.M., Lee S.I. A unified approach to interpreting model predictions // *Proceedings of the 31st International Conference on Neural Information Processing Systems. NIPS'17*, Curran Associates Inc., Red Hook, NY, USA. 2017. p.4768–4777. <https://doi.org/10.48550/arXiv.1705.07874>
11. Merrick L. Randomized ablation feature importance. 2019. <https://doi.org/10.48550/arXiv.1910.00174>
12. Ou Y., Guo Q., Liu J. Identifying spreading influence nodes for social networks // *Frontiers of Engineering Management*. 2022. № 9(4). p. 520–549. <https://doi.org/10.1007/s42524-022-0190-8>

13. Prokopyev N., Vakhitov G., Ustin P., Mamadjanova S. Usage of social media text topic analysis for student's academic success prediction // ICERI2020 Proceedings. 13th annual International Conference of Education, Research and Innovation, IATED 9-10 November 2020. 2020. pp. 5466–5470. <https://doi.org/10.21125/iceri.2020.1184>
14. Prokopyev N., Vakhitov G., Ustin Indexing of social network texts for psychometric model of academic success prediction // Proceedings of the International Scientific Conference “Digitalization of Education: History, Trends and Prospects” (DETP 2020). 2020. Atlantis Press. pp. 807–812. <https://doi.org/10.2991/assehr.k.200509.143>
15. Ribeiro M.T., Singh S., Guestrin C. “Why should I trust you?”: Explaining the predictions of any classifier // Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. KDD '16, Association for Computing Machinery, New York, NY, USA. 2016. p.1135–1144. <https://doi.org/10.1145/2939672.2939778>
16. Saleem R., Yuan B., Kurugollu F., Anjum A., Liu L. Explaining deep neural networks: A survey on the global interpretation methods // Neurocomputing. 2022. № 513, p. 165–180. <https://doi.org/10.1016/j.neucom.2022.09.129>
17. Seidman G. Self-presentation and belonging on Facebook: How personality influences social media use and motivations // Personality and Individual Differences. 2013. № 54(3), с. 402–407. <https://doi.org/10.1016/j.paid.2012.10.009>
18. Shirzadian P., Antony B., Gattani A.G., Tasnina N., Heath L.S. A time evolving online social network generation algorithm // Scientific Reports. 2023. № 13(1), p. 2395. <https://doi.org/10.1038/s41598-023-29443-w>
19. Sundararajan M., Taly A., Yan Q. Axiomatic attribution for deep networks // Precup, D., Teh, Y.W. (eds.) Proceedings of the 34th International Conference on Machine Learning. Proceedings of Machine Learning Research. 2017. vol. 70, pp. 3319–3328. PMLR. <https://doi.org/10.48550/arXiv.1703.01365>
20. Taherdoost H. Enhancing social media platforms with machine learning algorithms and neural networks // Algorithms. 2023. № 16(6). <https://doi.org/10.3390/a16060271>
21. Truong Q.D., Truong Q.B., Dkaki T. Graph methods for social network analysis // Vinh, P.C., Barolli, L. (eds.) Nature of Computation and Communication. 2016. Springer International Publishing, Cham. pp. 276–286. [https://doi.org/10.1007/978-3-319-46909-6\\_25](https://doi.org/10.1007/978-3-319-46909-6_25)
22. Ucer S., Ozyer T., Alhadj R. Explainable artificial intelligence through graph theory by generalized social network analysis-based classifier // Scientific Reports. 2022. № 12(1). <https://doi.org/10.1038/s41598-022-19419-7>
23. Ustin P., Gafarov F., Berdnikov A. Analysis of Interpersonal Relationships of Social Network Users Using Explainable Artificial Intelligence Methods // OBM Neurobiology. 2023. № 7(3) pp. 1–14. doi:10.21926/obm.neurobio.2303180
24. Wang Y., Kosinski M. Deep neural networks are more accurate than humans at detecting sexual orientation from facial images // Journal of Personality and Social Psychology. 2018. № 114(2). С. 246–257. <https://doi.org/10.1037/psp0a000098>

Поступила в редакцию 10.11.2023

Вахитов Галим Зарибзянович, кандидат экономических наук, доцент,  
доцент кафедры анализа данных и технологий программирования  
Института вычислительной математики и информационных технологий  
E-mail: asdzxc0303@mail.ru

Устин Павел Николаевич, кандидат психологических наук, доцент,  
заведующий кафедрой общей психологии Института психологии и образования  
E-mail: ravust@mail.ru

Попов Леонид Михайлович, доктор психологических наук, профессор,  
профессор кафедры клинической психологии и психологии личности  
Института психологии и образования  
E-mail: leonid.porov@inbox.ru

Гафаров Файль Мубараквич, кандидат физико-математических наук, доцент,  
заведующий кафедрой информационных систем  
Института вычислительной математики и информационных технологий  
E-mail: fail.gafarov@kpfu.ru

Казанский (Приволжский) федеральный университет  
420008, Россия, г. Казань, ул. Кремлёвская, 18

*G.Z. Vakhitov, P.N. Ustin, L.M. Popov, F.M. Gafarov*

**PREDICTORS OF NETWORK SOCIAL SUCCESS OF AN INDIVIDUAL**

DOI: 10.35634/2412-9550-2023-33-4-344-355

Network social success is the ability of an individual to maintain extensive ties in a social network and influence its other users. It is related both to the user's own activity in the social network and the attention of other users to the content of his/her personal profile, which is reflected in the form of likes and reposts, as well as the time spent on his/her page and the desire to spread his/her position to other users. The purpose of the study is to identify predictors of an individual's online social success. The hypothesis of the study is that metrics of a social network user's personal profile and metrics of his/her social graph can be used as predictors of online social success. The study used anonymized profile data from more than 30,000 users of the VKontakte social network. They were divided into several groups according to their online social success. Machine learning and neural network-based models were used to make predictions. This allowed us to identify a number of user profile metrics and metrics of their social graph that can be used as predictors of their online social success. The presence of such predictors allows, without revealing the reposts of messages and the degree of activity in the user's network, to assess user's real connections in the social network and his/her influence.

*Keywords:* network social success, social network, predictor, neural network, machine learning.

Received 10.11.2023

Vakhitov G.Z., Candidate of Economics, Associate Professor  
of the Data Analysis and Programming Technologies Department,  
Institute of Computational Mathematics and Information Technologies  
E-mail: asdzxc0303@mail.ru

Ustin P.N., Candidate of Psychology, Head of the General Psychology Department,  
Institute of Psychology and Education  
E-mail: pavust@mail.ru

Popov L.M., Doctor of Psychology, Professor of the Clinical Psychology and Personality Psychology Department,  
Institute of Psychology and Education  
E-mail: leonid.popov@inbox.ru

Gafarov F.M., Candidate of Physics and Mathematics, Head of the Information Systems Department,  
Institute of Computational Mathematics and Information Technologies  
E-mail: fail.gafarov@kpfu.ru

Kazan (Volga Region) Federal University  
Kremlevskaya st., 18, Kazan, Russia, 420008