

Секция «Искусственный интеллект и цифровая трансформация в бизнесе и
государственном управлении»

**Создания нейросетевой модели для автоматического подбора исполнителей
проектных задач по навыкам и опыту**

Научный руководитель – Игорь Николаевич Скопин

Khairullaev Uchkun Bakhodirovich

Аспирант

Новосибирский государственный университет, Механико-математический факультет,
Новосибирск, Россия

E-mail: u.khairullaev@g.nsu.ru

Современное управление проектами сталкивается с вызовами, связанными с усложнением задач, увеличением объема данных и необходимостью координации многопрофильных команд. Рост числа проектов, особенно в высокотехнологичных отраслях, таких как информационные технологии, машиностроение или биотехнологии, требует от менеджеров быстрого и точного распределения ресурсов. Традиционные подходы, основанные на субъективных оценках руководителей или упрощенных системах рейтингов, часто приводят к неоптимальному выбору исполнителей, что снижает производительность и увеличивает сроки выполнения задач [3]. Например, в крупных проектах с десятками участников и сотнями задач менеджеры могут упустить из виду скрытые компетенции сотрудников или недооценить их совместимость с командой. В условиях ограниченного времени и ресурсов такие ошибки становятся критичными. Оптимизация этого процесса требует применения новых инструментов, способных учитывать множество факторов и обеспечивать объективность решений. Одним из перспективных направлений является использование нейронных сетей, которые благодаря анализу больших данных и построению прогностических моделей могут автоматизировать подбор исполнителей для проектных задач [1].

Нейронные сети обладают рядом преимуществ перед традиционными методами. Они способны обрабатывать сложные массивы данных, включая структурированные (такие как таблицы навыков) и неструктурированные источники (например, текстовые описания опыта), выявлять скрытые закономерности и учитывать широкий спектр параметров: профессиональные компетенции, успешность в аналогичных проектах, адаптивность к изменениям, совместимость с коллегами. Алгоритмы глубокого обучения, такие как архитектура трансформера, эффективно анализируют текстовую информацию — резюме, отчеты, переписку в рабочих чатах — и сопоставляют ее с требованиями задач [2]. Это позволяет минимизировать предвзятость, характерную для человеческих оценок, ускорить процесс принятия решений и адаптировать распределение ресурсов к динамическим условиям проекта. В ИТ-сфере такие системы уже успешно применяются в Agile-методологиях, где гибкость и скорость подбора исполнителей особенно важны [5]. Например, в проектах разработки программного обеспечения нейронные сети помогают определить, какой специалист лучше справится с задачей тестирования, а кто — с написанием кода, учитывая не только их формальные навыки, но и прошлые результаты в схожих условиях.

Однако внедрение нейронных сетей сопряжено с рядом сложностей. Качество работы моделей напрямую зависит от полноты и достоверности входных данных: недостаток информации или наличие ошибок могут привести к некорректным рекомендациям. Кроме того, непрозрачность алгоритмов — так называемая проблема "черного ящика" — затрудняет интерпретацию решений, что вызывает недоверие со стороны менеджеров [4]. Например, если модель рекомендует сотрудника с низким формальным рейтингом, руководителю сложно понять, почему был сделан такой выбор. Также возникают этические дилеммы: автоматизация подбора исполнителей может восприниматься как угроза для роли

человека в управлении. Наконец, системы могут недооценивать трудно формализуемые факторы, такие как текущая мотивация, эмоциональное выгорание или неформальные лидерские качества, которые часто играют решающую роль в успехе проекта. Эти ограничения требуют дополнительных решений для повышения практической применимости таких технологий.

В рамках данного исследования разработана модель на основе многослойной нейронной сети с архитектурой прямого распространения, предназначенная для классификации и ранжирования исполнителей проектных задач. Модель оптимизирована с учетом специфики задачи: для обучения использовалась функция потерь кросс-энтропии, а для предотвращения переобучения применялась L2-регуляризация [1]. Обучение проводилось на синтетическом наборе данных, включающем более 10 000 записей. Каждая запись содержала информацию о компетенциях сотрудников (*технические навыки, опыт, образование*), а также их истории выполнения задач (*успешность, соблюдение сроков, обратная связь от коллег*). Данные были сгенерированы с учетом реальных сценариев управления проектами: например, моделировались ситуации, когда сотрудник с высоким уровнем навыков не справлялся из-за перегрузки, или когда новичок неожиданно демонстрировал высокую эффективность благодаря адаптивности. На этапе предобработки данные нормализовались, а категориальные признаки кодировались методом one-hot encoding для повышения качества обучения.

Тестирование модели проводилось на отдельной выборке, составляющей 20% от общего объема данных. Результаты показали, что модель достигает точности классификации исполнителей на уровне 87%, что значительно превосходит результаты традиционных подходов, таких как экспертные оценки или простые статистические методы [5]. Для оценки качества использовались метрики precision, recall и F1-score, которые подтвердили способность модели корректно ранжировать сотрудников. Например, в тестовом сценарии модель успешно определила, что разработчик с опытом работы в трех схожих проектах лучше подходит для задачи, чем специалист с более высоким общим рейтингом, но без релевантного опыта. Для повышения интерпретируемости применялись методы объяснимого ИИ, такие как SHAP, которые показали, какие факторы (*например, прошлые успехи или совместимость с командой*) оказали наибольшее влияние на рекомендации [4].

Практическое применение модели возможно в различных областях управления проектами. Например, в крупных ИТ-компаниях она может интегрироваться с системами управления задачами, автоматически предлагая исполнителей на основе анализа их профилей и текущей нагрузки. В производственных проектах модель способна учитывать специфику оборудования или технологий, с которыми работал сотрудник. Однако для успешного внедрения требуется доработка: интеграция данных о текущей занятости, повышение прозрачности решений и учет неформальных факторов через дополнительные модули анализа.

Перспективы дальнейших исследований связаны с разработкой гибридных моделей, сочетающих машинное обучение и человеческий интеллект. Например, менеджеры могли бы корректировать рекомендации модели, добавляя экспертные суждения о мотивации или командной динамике. Такой подход позволит компенсировать недостатки автоматизации, сохраняя ее скорость и объективность. Внедрение подобных систем в управление проектами способно повысить эффективность распределения ресурсов и адаптацию организаций к современным вызовам.

Источники и литература

- 1) Goodfellow, I., Bengio, Y., Courville, A. Deep Learning. – MIT Press, 2016.

- 2) Vaswani, A., et al. "Attention is All You Need." – Advances in Neural Information Processing Systems, 2017.
- 3) Project Management Institute. A Guide to the Project Management Body of Knowledge (PMBOK Guide). – 7th Edition, 2021.
- 4) Lundberg, S. M., Lee, S.-I. "A Unified Approach to Interpreting Model Predictions." – Advances in Neural Information Processing Systems, 2017.
- 5) Коваленко, А. П. "Машинное обучение в управлении проектами: новые горизонты." – Журнал управления проектами, 2023, № 4, с. 15–23.