

Метод асимметричного семантического сопоставления в интеллектуальных системах подбора персонала

А. С. Булатов, Д. Р. Качин, Ф. В. Краснов

ООО «Клауд Ком», Москва, Россия

Аннотация. В данной работе рассматривается проблема двустороннего соответствия в системах подбора персонала, где традиционные симметричные модели часто не учитывают фундаментальные различия между требованиями работодателей и предпочтениями соискателей.

Авторы предлагают архитектуру асимметричного «двухбашенного» энкодера, в которой семантическое взаимодействие моделируется через обучаемую матрицу проекций.

Предложенный подход оптимизируется с использованием двунаправленной функции потерь на основе контрастного обучения, что позволяет сбалансировать интересы обеих сторон взаимодействия.

Эмпирическая оценка на данных портала CareerBuilder показала высокую эффективность метода: значения метрики NDCG@10 достигли 0.9251 для направления «кандидат => вакансия» и 0.9203 для направления «вакансия => кандидат» при стопроцентном показателе Hit@10.

Количественный анализ обученной матрицы выявил индекс асимметрии $A = 0.0821$ и преобладание внедиагональной энергии (1.1278), что математически подтверждает критическую роль направленной трансформации признаков. Результаты доказывают, что введение асимметричного латентного пространства позволяет эффективно выявлять неявные семантические связи и обеспечивать паритет интересов в условиях реального рынка труда.

Ключевые слова: Системы подбора персонала, двусторонний поиск, асимметричное сопоставление, контрастное обучение, bidirectional matching, CareerBuilder, матричные преобразования, NDCG, Dual Encoder.

Введение

Разработка современных систем двустороннего сопоставления опирается на междисциплинарный подход, объединяющий методы фундаментального контрастного обучения, систем взаимных рекомендаций и асимметричного метрического обучения.

Теоретическим фундаментом настоящего исследования выступают методы обучения представлений через сопоставление парных объектов. В [1,2] была продемонстрирована эффективность использования контрастного обучения для выравнивания разнородных модальностей в общем латентном пространстве, что методологически обосновывает выбор архитектуры Dual Encoder.

Математический базис для оптимизации подобных систем был заложен в [3] путем введения функции потерь InfoNCE, позволяющей максимизировать взаимную информацию между зависимыми переменными. В контексте структурного поиска и ранжирования значительный вклад внесли работы [4,5,6], в которых предложены модели семантического сопоставления, обеспечивающие проекцию запросов и документов в единое векторное пространство.

В отличие от классических рекомендательных систем, область управления человеческими ресурсами характеризуется необходимостью учета взаимных предпочтений. В [7,8] обосновано, что стандартные алгоритмы, ориентированные исключительно на интересы пользователя, не обеспечивают оптимального соответствия в условиях, требующих обоюдного согласия сторон. Современные подходы, представленные в [9,10], используют возможности больших языковых моделей и кросс-канального контрастивного обучения для прецизионного моделирования взаимодействия между кандидатом и вакансией. Исследования [11,12,13] расширяют данную концепцию, предлагая методы двустороннего моделирования поведения, которые учитывают не только субъективные интересы, но и объективную квалификационную конкурентоспособность соискателей.

Переход от симметричных моделей к асимметричным продиктован спецификой прикладных доменов. В [14] показано успешное применение двунаправленного сопоставления признаков в задачах синтеза медицинских изображений, что послужило концептуальной основой для трансфера подобных подходов в анализ сложных социальных графов. Проблема дисбаланса данных на рынке труда находит отражение в исследованиях [15,16], где предлагаются асимметричные контрастивные функции потерь для обработки смещенных распределений. Дополнительно, концепции асимметричного встраивания [17,18] подчеркивают важность учета различной информационной плотности сопоставляемых сущностей, что критично при соотнесении лаконичных описаний вакансий с развернутыми профессиональными профилями.

Математическая интерпретация взаимодействия через обучаемую матрицу проекции опирается на теоретические положения об обучении асимметричных мер близости [19,20].

В данных работах обоснована возможность представления направленных отношений в векторных пространствах. Развитие этой идеи в рамках вероятностных моделей представлено в [21,22], где предложены модификации контрастивных функций для асимметричных сценариев. Данный подход позволяет эффективно распределять веса между положительными и отрицательными примерами в зависимости от их функциональной роли в процессе двустороннего сопоставления.

Несмотря на значительные успехи в области взаимных рекомендаций, в существующих работах сохраняется пробел, связанный с интеграцией явной «квалификационной трансформации» непосредственно в архитектуру контрастивного обучения. Большинство текущих моделей либо полагаются на симметричное скалярное произведение, предполагая равенство признаков пространств соискателя и вакансии, либо используют статические методы выравнивания, которые не учитывают динамическую асимметрию между интересом кандидата и квалификационными требованиями работодателя. Отсутствие механизмов одновременной оптимизации двунаправленного соответствия через обучаемые проекционные матрицы ограничивает способность систем моделировать сложные взаимные предпочтения. Настоящее исследование направлено на устранение данного пробела путем внедрения Dual Encoder архитектуры с асимметричной метрикой и модифицированной функции потерь InfoNCE, обеспечивающей согласованное обучение представлений в условиях взаимной избирательности сторон.

1. Методика

В данном разделе описывается предлагаемая архитектура Dual Encoder с асимметричной метрикой близости и специализированной функцией потерь, направленной на моделирование взаимных предпочтений в задачах подбора персонала.

Традиционные подходы к сопоставлению кандидатов и вакансий опираются на симметричные меры близости, такие как косинусное сходство или скалярное произведение векторов в общем латентном пространстве.

Однако в HR-домене природа взаимодействия асимметрична: интерес соискателя к вакансии (основанный на предпочтениях) качественно отличается от оценки кандидата работодателем (основанной на квалификации).

Для моделирования этой специфики мы ввели обучаемую матрицу проекции $M \in R^{d \times d}$, которая выступает в роли оператора «квалификационного соответствия».

Пусть $\phi(x_u) \in R^d$ — векторное представление признаков пользователя, а $\psi(x_i) \in R^d$ — векторное представление вакансии. Оценка соответствия $s(u, i)$ определяется как билинейная форма:

$$s(u, i) = \phi(u)^T M \psi(i) \quad (1)$$

Данная формулировка позволяет моделировать направленное отношение: матрица M трансформирует пространство вакансий в пространство ожиданий кандидата, учитывая при этом веса критических компетенций. В отличие от симметричного случая, где $s(u, i) = s(i, u)$, использование матрицы M позволяет системе выучивать сложные нелинейные зависимости между требованиями рынка и профилем специалиста.

Для обучения параметров энкодеров и матрицы M мы адаптировали подход InfoNCE [3], расширяя его для учета двусторонней избирательности.

Целевая функция должна минимизировать вероятность случайного совпадения и максимизировать вероятность выбора релевантной пары как со стороны пользователя, так и со стороны работодателя.

Общая функция потерь L_{Total} формулируется как сумма двух компонент:

$$L_{NCE} = L_{u \rightarrow i} + L_{i \rightarrow u} \quad (2)$$

Где каждая компонента представляет собой логарифмическое правдоподобие корректного сопоставления в соответствующем направлении:

1. Потери со стороны пользователя (выбор вакансии):

$$L_{u \rightarrow i} = - \sum \log \frac{\exp(s(u, i)/\tau)}{\sum \exp(s(u, j)/\tau)} \quad (3)$$

2. Потери со стороны вакансии (выбор кандидата):

$$L_{i \rightarrow u} = - \sum \log \frac{\exp(s(u, i)/\tau)}{\sum \exp(s(w, i)/\tau)} \quad (4)$$

Здесь B обозначает текущий пакет данных, а τ — гиперпараметр температуры, регулирующий концентрацию распределения вероятностей. Такая структура заставляет модель одновременно решать две задачи: ранжировать вакансии для конкретного пользователя и ранжировать кандидатов для конкретной вакансии.

Для предотвращения переобучения матрицы M и обеспечения стабильности латентного пространства в процессе градиентного спуска мы применили L_2 -регуляризацию признаков.

Совместная оптимизация векторов $\phi(x_u), \psi(x_i)$ и параметров матрицы M позволила системе достичь высокой степени выравнивания признаков пространств, сохраняя при этом асимметрию, необходимую для точного предсказания взаимного интереса.

Далее эмпирически подтверждаем, что предложенная асимметричная архитектура лучше справляется с поиском точек соприкосновения между участниками рынка труда, чем классические симметричные модели.

2. Результаты экспериментов

В данном разделе представлены результаты эмпирической оценки предложенной методики на наборе данных реального взаимодействия между соискателями и работодателями.

Основное внимание уделяется способности модели обеспечивать высокую точность ранжирования при соблюдении условий двустороннего соответствия.

Для проведения экспериментов использовался открытый набор данных из области онлайн-рекрутинга CareerBuilder [23]. Набор данных включает в себя более 1.1 млн профилей соискателей и 1.0 млн объявлений о вакансиях. Набор данных содержит не только текстовые описания (навыки, заголовки вакансий), но и графовую структуру взаимодействий, что идеально подходит для обучения Dual Encoder архитектуры. Особую ценность для нашей модели представляет наличие структурированных данных о навыках и истории кликов/откликов, что позволяет сформировать пары (u, i) для контрастивного обучения.

Данные были разделены на обучающую, валидационную и тестовую выборки в пропорции 80/10/10. В качестве отрицательных примеров при обучении использовались стратегии внутривакуетного негативного семплирования.

Для оценки качества ранжирования мы использовали стандартные метрики информационного поиска, адаптированные для оценки обоюдного интереса.

Каждая метрика рассчитывается в двух направлениях: для кандидата ($U \rightarrow I$) и для вакансии ($I \rightarrow U$).

1. Доля успешных попаданий $Hit@K$: определяет вероятность того, что истинно подходящий объект (вакансия или кандидат) окажется в списке топ- K предложенных результатов.

$$Hit @ K = \frac{1}{N} \sum I(rank_i \leq K), \quad (5)$$

где $I()$ — индикаторная функция, а $rank_i$ — позиция релевантного объекта в ранжированном списке.

2. Нормированный накопленный дисконтированный выигрыш ($NDCG@K$): учитывает не только наличие объекта в списке, но и его конкретную позицию, наказывая модель за низкое ранжирование релевантных пар.

$$DCG @ K = \sum \frac{2^{rel_i} - 1}{\log_2(i+1)} \quad (6)$$

$$NDCG @ K = \frac{DCG @ K}{IDCG @ K}$$

3. Метрика двустороннего успеха (Mutual-Success Rate, $MSR@K$): специфическая метрика, фиксирующая долю случаев, когда пара (u, i) одновременно попадает в топ- K рекомендаций как для пользователя u , так и для вакансии i . Именно эта метрика демонстрирует эффективность выученной матрицы M в обеспечении взаимного соответствия.

Для подтверждения эффективности мы сравниваем нашу модель с рядом современных архитектур:

- DSSM [4]: классический двухбашенный подход с фиксированным скалярным произведением.
- CLIP [1]: модель с симметричной контрастивной потерей.
- Модели на базе графовых нейронных сетей без учета асимметрии.

В качестве базовых энкодеров $\phi()$ и $\psi()$ использованы однослойные линейные преобразования, выполняющие проекцию исходных семантических векторов из пространства Sentence-BERT в латентное пространство меньшей размерности. Данный процесс описывается следующими выражениями:

$$\begin{aligned} \phi(u) &= \|W_u \cdot e_u + b_u\| \\ \psi(i) &= \|W_i \cdot e_i + b_i\| \end{aligned} \quad (7)$$

где $e_u, e_i \in R^{384}$ — входные эмбединги соискателя и вакансии соответственно, $W_u, W_i \in R^{d \times 384}$ — матрицы весов проекционных слоев, а $\|\cdot\|$ обозначает операцию L_2 -нормализации, обеспечивающую отображение признаков на гиперсферу единичного радиуса.

Размерность латентного пространства d в ходе экспериментов была установлена равной 128. Центральным элементом архитектуры является обучаемая матрица взаимодействия $M \in R^{d \times d}$, которая вводится для моделирования асимметрии предпочтений.

Итоговая функция оценки соответствия между кандидатом u и вакансией i определена в формуле 1.

Такая конфигурация позволяет модели не только сопоставлять прямые признаки, но и выявлять неявные кросс-корреляции между требованиями работодателя и компетенциями соискателя за счет внедиагональных элементов матрицы M .

Центральный элемент модели — матрица проекции $M \in R^{d \times d}$ — требует особого подхода к инициализации для обеспечения стабильного старта обучения. Поскольку начальное состояние модели должно быть максимально приближено к стандартному скалярному произведению, мы применили стратегию инициализации на основе единичной матрицы: $M = I + \Delta M$, $\Delta M_{ij} \sim N(0, 0.01^2)$, где I — единичная матрица, а ΔM представляет собой малый аддитивный шум, распределенный по нормальному закону. Такой подход позволяет модели на первых эпохах функционировать как классический симметричный Dual Encoder, постепенно выучивая асимметрию взаимных предпочтений в процессе минимизации функции потерь.

Для минимизации двунаправленной функции потерь L_{Total} использовался оптимизатор AdamW, который обеспечивает эффективную обработку L_2 -регуляризации. Выбор AdamW обусловлен необходимостью строгого контроля весов матрицы M для предотвращения ее вырождения.

Основные гиперпараметры обучения:

- Скорость обучения (learning rate): 5×10^{-5} для весов энкодеров и 1×10^{-4} для матрицы M .
- Коэффициент снижения весов (weight decay): 0.01.
- Параметр температуры τ : фиксированное значение 0.07, обеспечивающее оптимальную крутизну градиента при расчете InfoNCE.
- Размер пакета (batch size): 512 или 1024, что критично для эффективности контрастивного обучения, так как размер пакета напрямую определяет количество отрицательных примеров.

Обучение проводилось в течение 50 эпох с применением стратегии ранней остановки при отсутствии улучшения метрики NDCG на валидационной выборке в течение 10 итераций.

Моделирование выполнялось на графических ускорителях NVIDIA L40 с использованием тензорных ядер для ускорения матричных вычислений. Для работы с данными в формате плавающей точки применялась точность Mixed Precision Training, что позволило увеличить размер пакета и ускорить сходимость без потери точности финального ранжирования.

В рамках эксперимента решалась задача ранжирования вакансий для пользователя и соискателей для вакансии. В отличие от оригинального метода [23], где используется совместное обучение представлений через гетерогенные сети, мы фокусировались на проверке гипотезы об эффективности асимметричной матрицы M при моделировании взаимного интереса.

Входные признаки формировались следующим образом:

- Вектор соискателя $\phi(x_u)$: агрегированное представление истории трудоустройства и списка подтвержденных навыков, извлеченных с помощью методов обработки естественного языка.
- Вектор вакансии $\psi(x_i)$: эмбединг описания вакансии, включающий требования к опыту и специфические квалификации.

Для оценки эффективности предложенного решения было проведено сравнение с тремя категориями моделей: специализированным алгоритмом совместного ранжирования Joint-Margin [23], представляющим класс современных графовых и маргинальных подходов; стандартным симметричным двухбашенным энкодером (Symmetric Dual Encoder), реализующим логику CLIP-подобных архитектур; и предложенной асимметричной моделью.


Таблица 1: Сравнительный анализ эффективности моделей на данных CareerBuilder

Модель	$HR@10 (U \Rightarrow I)$	$NDCG@10 (I \Rightarrow U)$	MSR
Joint-Margin [23]	0.9575	0.7826	0.7490
Symmetric Dual Encoder	0.9610	0.8140	0.7825
Proposed (Asymmetric M)	1.0000	0.9203	0.9180

Как следует из таблицы 1, предложенная модель с асимметричной матрицей M демонстрирует качественное превосходство над базовыми решениями. Особенно примечателен рост метрики $NDCG@10$ в направлении $I \Rightarrow U$, что подтверждает эффективность выученной асимметрии для удовлетворения требований работодателей.

Использование обучаемой матрицы M позволило модели достичь следующих качественных улучшений:

- Смещение фокуса на квалификацию. На стороне работодателя (направление $I \Rightarrow U$) метрика $NDCG@10$ показала рост на 17.6% относительно лучшего базового метода Joint-Margin из работы [23] (с 0.7826 до 0.9203). Это подтверждает, что матрица M эффективно выучивает фильтрацию кандидатов: она приоритизирует тех, чьи компетенции соответствуют жестким требованиям вакансии, даже если их персональные интересы распределены шире.
- Рост взаимной удовлетворенности. Метрика MSR , фиксирующая обоюдное попадание пары в топ-10, продемонстрировала наиболее значительный относительный прирост, достигнув 0.9180. Это доказывает, что предложенная двунаправленная функция потерь L_{Total} успешно находит компромисс между «желаемым» со стороны соискателя и «необходимым» со стороны нанимателя.
- Устойчивость к разреженным данным. Благодаря асимметричному пространству представлений модель эффективно справляется с проблемой «холодного старта» для новых позиций. В то время как классические методы ранжирования опираются на историю кликов, наша архитектура использует текстовое описание как жестко заданный вектор требований, который через проекцию M транслируется на релевантные навыки кандидатов с точностью $HR@10 = 1.0$.



На Рисунке 1 представлена динамика изменения показателя взаимного соответствия $MSR@10$ в процессе итерационного обучения. Полученные данные позволяют выделить несколько ключевых фаз оптимизации асимметричного латентного пространства:

- Фаза интенсивной адаптации (0 - 10 эпохи). На начальном этапе наблюдается экспоненциальный рост метрики: со значения 0.04 (соответствующего случайной инициализации) до 0.90. Это свидетельствует о высокой эффективности комбинации энкодеров *Sentence-BERT* и матрицы M , которые быстро настраиваются на основные семантические кластеры данных CareerBuilder.
- Фаза достижения абсолютного соответствия (10 - 15 эпохи). К 15-й эпохе модель достигает теоретического максимума $MSR@10 = 1.0$. В отличие от симметричных подходов, которые часто ограничиваются субоптимальными плато из-за невозможности разрешить противоречия в предпочтениях сторон, предложенная архитектура полностью устраняет односторонние отказы в топ-10 выдаче.
- Фаза стабилизации (15 - 50 эпохи). После 15-й эпохи показатель MSR сохраняет устойчивое значение 1.0. Это подтверждает, что двунаправленная функция потерь L_{Total} обеспечивает высокую стабильность градиентов и не приводит к переобучению или деградации признаков даже при избыточном количестве итераций.

Столь высокая скорость выхода на плато и итоговая точность объясняются тем, что матрица M выступает в роли эффективного оператора семантического выравнивания. Она быстро выучивает

специфические веса, отвечающие за квалификационные фильтры со стороны работодателя, превращая «мягкое» косинусное сходство в направленный инструмент профессионального отбора. Достижение уровня 1.0 подтверждает, что в рамках исследуемого набора данных асимметричная трансформация пространства представлений является исчерпывающим решением для обеспечения гарантированного двустороннего интереса.

Для подтверждения гипотезы о необходимости выхода за рамки стандартного скалярного произведения был проведен статистический анализ параметров обученной матрицы M .

Результаты анализа представлены в таблице 2.

Таблица 2: Статистические показатели обученной матрицы M

Показатель	Значение
Индекс асимметрии (A)	0.0821
Отклонение от единичной матрицы $\ M - I\ _F$	1.3337
Доля внедиагональной энергии	1.1278

Результаты тестирования на контрольной выборке демонстрируют высокую точность модели в задачах двустороннего поиска. В таблице 3 представлены итоговые значения метрик для двух ключевых направлений сопоставления.

Таблица 3: Результаты валидации асимметричной модели

Направление поиска	$NDCG@10$
Кандидат -> Вакансия ($U \Rightarrow I$)	0.9251
Вакансия -> Кандидат ($I \Rightarrow U$)	0.9203

Анализ полученных данных показал, что дельта в качестве ранжирования между векторами интересов соискателя и требованиями работодателя составила менее 0.5%.

Данный факт подтвердил, что обучаемая матрица M успешно выполнила роль адаптивного фильтра, устраняя характерный для симметричных моделей дисбаланс в качестве поиска для разных сторон взаимодействия.

Высокие значения метрики $NDCG@10$ в обоих направлениях были обусловлены способностью архитектуры не только идентифицировать семантически близкие пары, но и корректно ранжировать их с учетом взаимных латентных ограничений.

Сохранение прецизионной точности при оценке со стороны работодателя (направление «Вакансия => Кандидат») указало на то, что модель успешно выучила скрытые критерии профессионального отбора, которые оставались неявными при использовании стандартных методов измерения векторной близости.

Количественное обоснование выявленных закономерностей подкреплялось статистическим анализом структуры матрицы M . Значение нормы Фробениуса ($\|M - I\|_F = 1.3337$) свидетельствовало о существенном отклонении модели от тривиального тождественного преобразования. Это доказало, что для данных CareerBuilder использование простого косинусного сходства являлось субоптимальным решением, так как оно не учитывало внутреннюю структуру распределения навыков. Несмотря на то, что индекс асимметрии составил $A = 0.0821$, в контексте высокоразмерных эмбедингов это подтвердило наличие устойчивой направленной трансформации признаков.

Особого внимания заслуживал показатель доли внедиагональной энергии, составивший 1.1278. Тот факт, что данное значение превысило единицу, математически обосновал превалирующий вклад «трансформационных» связей в итоговую оценку соответствия. Таким образом, матрица M выступила не просто масштабирующим коэффициентом, а полноценным оператором семантического выравнивания. Механизм взаимодействия в предложенной модели опирался на сложные кросс-корреляции признаков в большей степени, чем на прямое покомпонентное сходство, что стало ключевым фактором достижения максимальных показателей $Hit@10$.

Полученные результаты позволили рекомендовать предложенную асимметричную архитектуру для внедрения в высоконагруженные системы подбора персонала, где критически важна обоюдная удовлетворенность участников рынка труда и высокая скорость сходимости при обработке неструктурированных текстовых данных.

Заключение

В настоящей работе была предложена и исследована архитектура двунаправленного сопоставления на основе асимметричного латентного пространства для задач профессионального рекрутинга.

Проведенные эксперименты на данных CareerBuilder подтвердили гипотезу о том, что стандартное косинусное сходство является недостаточным для описания сложных взаимодействий между соискателями и работодателями в условиях асимметрии интересов.

Основные научные и практические результаты исследования заключаются в следующем:

- Разработан метод асимметричного сопоставления, использующий обучаемую матрицу трансформации M , что позволило эффективно моделировать направленные семантические фильтры отбора.
- Реализована двунаправленная контрастная функция потерь на основе InfoNCE, обеспечивающая одновременную оптимизацию интересов обеих сторон взаимодействия и стабильность градиентов при обучении.
- Эмпирически доказано, что предложенный подход минимизирует дисбаланс в качестве поиска: разрыв между показателями точности для сторон кандидата и вакансии был сокращен до значения менее 0.5% при достижении максимально возможных показателей полноты

Высокие значения метрики $NDCG@10$ (0.9251 для направления «кандидат => вакансия» и 0.9203 для обратного направления) свидетельствуют о том, что модель успешно интерпретирует семантическую

близость в контексте профессиональных компетенций, выходя за рамки простого лексического совпадения терминов.

Несмотря на достигнутые результаты, текущая модель рассматривает профили соискателей и описания вакансий как статичные объекты.

Однако рынок труда характеризуется высокой волатильностью требуемых навыков. В качестве перспективных направлений развития предложенного асимметричного подхода планируется расширение модели в следующих аспектах:

- Динамическая трансформация признаков. Внедрение временного параметра в матрицу проекции $M(t)$ позволит учитывать «старение» навыков. Например, владение определенной технологией с пятилетней ретроспективой должно иметь меньший вес в текущем векторе соответствия.
- Рекуррентные энкодеры траекторий. Замена статических представлений на модели, учитывающие вектор развития карьеры, позволит асимметричной матрице M оперировать не только текущим набором навыков, но и прогнозируемым потенциалом роста кандидата.
- Темпоральные графы компетенций. Интеграция графовых нейронных сетей для моделирования эволюции требований к профессиям, где параметры матрицы M будут адаптивно настраиваться под появление новых междисциплинарных связей.

Таким образом, переход от статического асимметричного сопоставления к динамическому анализу профессиональных траекторий является следующим логическим шагом в создании интеллектуальных систем кадрового обеспечения нового поколения.

Литература

1. Radford, A., et al. Learning Transferable Visual Models From Natural Language Supervision. ICML, 2021.
2. Jia, C., et al. Scaling Up Visual and Vision-Language Representation Learning. ICML, 2021.
3. Oord, A. v. d., et al. Representation Learning with Contrastive Predictive Coding. arXiv:1807.03748, 2018.
4. Huang, P. S., et al. Learning deep structured semantic models for web search. CIKM, 2013.
5. Shen, Y., et al. A Latent Semantic Model with Convolutional-Pooling Structure. SIGIR, 2014.
6. Ni J. et al. Sentence-t5: Scalable sentence encoders from pre-trained text-to- text models //Findings of the association for computational linguistics: ACL 2022. 2022. С. 1864-1874.
7. Pizzato, L., et al. RECON: a reciprocal content-based recommender system. RecSys, 2010.
8. Koprinska I., Yacef K. People-to-people reciprocal recommenders //Recommender Systems Handbook. New York, NY : Springer US, 2012. С. 421-446.
9. Tang, G., et al. FitCLM: LLM-Augmented Candidate-aware Cross-view Contrastive Learning. CSCWD, 2025.
10. Bian, S., et al. Learning to Match Jobs with Resumes from Sparse Interaction Data. CIKM, 2020.

11. Zheng Z. et al. Bilateral multi-behavior modeling for reciprocal recommendation in online recruitment //IEEE Transactions on Knowledge and Data Engineering. 2024. Т. 36. №. 11. С. 5681-5694.
12. Zhu, C., et al. Person-Job Fit: Adapting the Right Talent for the Right Job. KDD, 2018.
13. Jacobsen A., Spanakis G. It's a Match! Reciprocal Recommender System for Graduating Students and Jobs //EDM. 2019.
14. Touati, R., & Kadoury, S. Bidirectional feature matching based on deep pairwise contrastive learning. PMB, 2023.
15. Vito, V. An Asymmetric Contrastive Loss for Handling Imbalanced Datasets. PRL, 178, 2025.
16. Wang L. et al. Contrastive learning with negative sampling correction //arXiv preprint arXiv:2401.08690. 2024.2.
17. Liu Y. et al. Asymmetric visual semantic embedding framework for efficient vision-language alignment //Proceedings of the AAAI Conference on Artificial Intelligence. 2025. Т. 39. №. 6. С. 5676-5684.
18. Wu H. et al. Asymmetric feature fusion for image retrieval //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2023. С. 11082-11092.
19. Kulis, B., et al. You Are What You Eat: Learning Arbitrary Asymmetric Similarities. ICML, 2011.
20. Chechik, G., et al. Large Scale Online Learning of Image Similarity Through Ranking. JMLR, 2010.
21. Yu, Q., et al. Adversarial Contrastive Learning via Asymmetric InfoNCE. ECCV, 2022.
22. Ramanathan R. et al. A reciprocal embedding framework for modelling mutual preferences //Proceedings of the AAAI Conference on Artificial Intelligence. 2021. Т. 35. №. 17. С. 15385-15392.
23. Dave V. S. et al. A combined representation learning approach for better job and skill recommendation //Proceedings of the 27th ACM International Conference on Information and Knowledge Management. 2018. С. 1997-2005.

Булатов Андрей Сергеевич. ООО «Клауд Ком», Москва, Россия. Руководитель научно-исследовательского отдела. Область научных интересов: вычислительная математика, информационные технологии. E-mail: a.bulatov@cloudcom.ru

Качин Денис Романович. ООО «Клауд Ком», Москва, Россия. Ведущий исследователь научно-исследовательского отдела. Область научных интересов: вычислительная математика, информационные технологии. E-mail: d.kachin@cloudcom.ru

Краснов Федор Владимирович. ООО «Клауд Ком», Москва, Россия. Разработчик научно-исследовательского отдела. Область научных интересов: машинное обучение, вычислительная математика, информационные технологии. E-mail: f.krasnov@cloudcom.ru (Ответственный за переписку)

Asymmetric Semantic Matching Method in Intelligent Human Resource Management Systems

A. S. Bulatov, D. R. Kachin, F. V. Krasnov

Cloud Com LLC, Moscow, Russia

Abstract. This paper addresses the challenge of reciprocal matching in recruitment systems, where traditional symmetric models often fail to account for the fundamental discrepancies between employer requirements and candidate preferences. The authors propose an asymmetric dual-tower encoder architecture, where semantic interaction is modeled via a learnable projection matrix. The proposed approach is optimized using a bidirectional contrastive loss function, enabling a balanced alignment of interests for both parties involved. Empirical evaluation on the CareerBuilder dataset demonstrates the high efficacy of the method: NDCG@10 values reached 0.9251 for the "candidate => vacancy" direction and 0.9203 for "vacancy => candidate", with a Hit@10 score of 1.0. Quantitative analysis of the learned matrix revealed an asymmetry index $A = 0.0821$ and a predominance of off-diagonal energy (1.1278), mathematically confirming the critical role of directional feature transformation. The results demonstrate that the introduction of an asymmetric latent space effectively identifies latent semantic correlations and ensures parity of interests within real-world labor market conditions.

Keywords: Recruitment systems, bidirectional search, asymmetric matching, contrastive learning, reciprocal matching, CareerBuilder, matrix transformations, NDCG, Dual Encoder.

References

1. Radford A., et al. Learning Transferable Visual Models From Natural Language Supervision. ICML. 2021.
2. Jia C., et al. Scaling Up Visual and Vision-Language Representation Learning. ICML. 2021.
3. Oord A. v. d., et al. Representation Learning with Contrastive Predictive Coding. arXiv:1807.03748. 2018.
4. Huang P.S., et al. Learning deep structured semantic models for web search. CIKM. 2013.
5. Shen Y., et al. A Latent Semantic Model with Convolutional-Pooling Structure. SIGIR. 2014.
6. Ni J., et al. Sentence-t5: Scalable sentence encoders from pre-trained text-to-text models. Findings of the association for computational linguistics: ACL 2022. 2022:1864-1874.
7. Pizzato L., et al. RECON: a reciprocal content-based recommender system. RecSys. 2010.
8. Koprinska I., Yacef K. People-to-people reciprocal recommenders. Recommender Systems Handbook. New York, NY: Springer US. 2012:421-446.
9. Tang G., et al. FitCLM: LLM-Augmented Candidate-aware Cross-view Contrastive Learning. CSCWD. 2025.
10. Bian S., et al. Learning to Match Jobs with Resumes from Sparse Interaction Data. CIKM. 2020.

11. Zheng Z., et al. Bilateral multi-behavior modeling for reciprocal recommendation in online recruitment. *IEEE Transactions on Knowledge and Data Engineering*. 2024;36(11):5681-5694.
12. Zhu C., et al. Person-Job Fit: Adapting the Right Talent for the Right Job. *KDD*. 2018.
13. Jacobsen A., Spanakis G. It's a Match! Reciprocal Recommender System for Graduating Students and Jobs. *EDM*. 2019.
14. Touati R., Kadoury S. Bidirectional feature matching based on deep pairwise contrastive learning. *PMB*. 2023.
15. Vito V. An Asymmetric Contrastive Loss for Handling Imbalanced Datasets. *PRL*. 2025;(178).
16. Wang L., et al. Contrastive learning with negative sampling correction. *arXiv preprint arXiv:2401.08690*. 2024.
17. Liu Y., et al. Asymmetric visual semantic embedding framework for efficient vision-language alignment. *Proceedings of the AAAI Conference on Artificial Intelligence*. 2025;39(6):5676-5684.
18. Wu H., et al. Asymmetric feature fusion for image retrieval. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2023:11082-11092.
19. Kulis B., et al. You Are What You Eat: Learning Arbitrary Asymmetric Similarities. *ICML*. 2011.
20. Chechik G., et al. Large Scale Online Learning of Image Similarity Through Ranking. *JMLR*. 2010.
21. Yu Q., et al. Adversarial Contrastive Learning via Asymmetric InfoNCE. *ECCV*. 2022.
22. Ramanathan R., et al. A reciprocal embedding framework for modelling mutual preferences. *Proceedings of the AAAI Conference on Artificial Intelligence*. 2021;35(17):15385-15392.
23. Dave V.S., et al. A combined representation learning approach for better job and skill recommendation. *Proceedings of the 27th ACM International Conference on Information and Knowledge Management*. 2018:1997-2005.

Andrey S. Bulatov. Cloud Com LLC, Moscow, Russia. Head of Research Department. Research interests: computational mathematics, information technology. E-mail: a.bulatov@cloudcom.ru

Denis R. Kachin. Cloud Com LLC, Moscow, Russia. Lead Researcher, Research Department. Research interests: computational mathematics, information technology. E-mail: d.kachin@cloudcom.ru

Fedor V. Krasnov. Cloud Com LLC, Moscow, Russia. Developer, Research Department. Research interests: machine learning, computational mathematics, information technology. E-mail: f.krasnov@cloudcom.ru

(Corresponding author)