

МОДЕЛЬ ПОДДЕРЖКИ ПРИНЯТИЯ ИНТУИТИВНО-ОПЫТНЫХ РЕШЕНИЙ

Кулинич А.А.

Институт проблем управления им. В.А. Трапезникова РАН, Москва, Россия
alexkul@rambler.ru

Аннотация. Рассмотрена математическая модель системы поддержки принятия решений направленная на стимулирование интеллектуальной деятельности субъекта для принятия интуитивно-опытных решений. Модель основана на семиотической модели ментального пространства. Предложены методы решения обратной задачи для поиска формальных решений достижения цели. Для интерпретации решений предложено применить векторные модели языка, полученные путем обучения нейронных сетей корпусом текста. Рассмотрены примеры интерпретации решений с помощью векторных моделей языка и проанализированы их возможности для принятия интуитивно-опытных решений.

Ключевые слова: неструктурированные данные, семиотическая модель, модель языка, векторная модель языка, интерпретация решений.

Введение

В теории принятия решений принято выделять три способа принятия решений: рациональный, интуитивный и основанный на суждениях. Рациональные решения принимаются на основе алгоритма принятия решений, в котором выделяется проблема, определяются альтернативы ее преодоления, а также критерии и их веса, которые используются для оценивания альтернатив. Далее линейная свертка альтернатив и весов критериев позволяет получить числовую оценку альтернативы и выбирать альтернативу, имеющую лучшую оценку.

Интуитивный способ основан на личных ощущениях, что решение верно. Здесь не происходит оценивание альтернатив решений на основе критериев, которым должно удовлетворять решение. Такие решения получаются без особых усилий и могут быть как верными, так и ошибочными. Решение, основанное на суждениях близко по содержанию к интуитивному решению. Здесь решение обдумывается с учетом личного опыта лица принимающего решение.

Обычно эти два способа объединяют и называют интуитивно-опытным методом принятия решений. Такие решения основаны на шаблонах, эвристиках личного опыта или опыта других людей (например, выполняется принцип - делай как все). В поддержке принятия решений разработаны методы, направленные на стимулирование эвристических интуитивных решений. Это групповые и индивидуальные методы, такие как морфологический ящик, гирлянды ассоциаций, мозговой штурм, синектика и др. направлены на активизацию мышления аналитика для получения интуитивно-опытного решения.

Считается, что интуитивно-опытные решения получаются в сознании человека в так называемом ментальном пространстве. Лингвист Ж. Фоконье [1] определил ментальное пространство как психическое образование, в котором осуществляется процесс мышления. Он считает, что это среда концептуализации и категоризации наблюдаемой действительности, представленной с помощью элементов языка (слов) и отношений между ними.

Считается, что ментальное пространство образуется в сознании субъекта в результате внешнего воздействия, под которым понимается слова, утверждения, тексты которые называются строителями ментального пространства. Строители ментального пространства «разворачивают» концептуальные и категориальные структуры в сознании человека, отражающие его знания о действительности, которыми он может манипулировать в процессах поиска решения. Механизм мышления Ж. Фоконье и М. Тернер [2] представляют как процесс концептуальной интеграции двух и более ментальных пространств, активированных разными строителями. В результате смешивания (blending) этих ментальных пространств образуется новое ментальное пространство, в котором происходит поиск решения.

В лингвистике существует иерархическая уровневая модель языка, в которой выделены фонетический, морфологический, лексический, синтаксический и семантический уровни. Элементы языка нижних уровней используются при построении элементов языка верхних уровней. Такая иерархическая модель отражает структуру языка, но не отражает механизм его функционирования.

В модели языка функциональной грамматики [3] вводится понятие функционально-семантического поля. Функционально-семантическое поле включает ядро и периферийные элементы языка, выполняющие одну и ту же функцию, например, определяю объект или действие. Периферийные элементы языка определяют свою функцию в различных контекстах. Множество функционально-

семантических полей взаимодействуют с помощью периферийных элементов, образуя разнообразные фразы, утверждения, выражающие некоторую мысль. Так образуется среда мышления из слов с разными функциями для поиска возможных решений в разных контекстах.

Американский лингвист Н. Хомским [4] пытался формализовать модель языка в виде теории лингвистической структуры. Он считает, что способность к языку является врожденной и существует универсальная грамматика в виде набора синтаксических правил встроенных в мозг. Структура этой грамматики включает синтаксический, семантический и фонологический компоненты. Главным центральным компонентом, является синтаксис, а семантика и фонология выполняют по отношению к синтаксису интерпретирующие функции.

Хомский считает, что существуют глубинные синтаксические структуры, которые отражают с помощью языковых конструкций самые общие закономерности реальности и поверхностные синтаксические структуры, которые могут быть получены из глубинной структуры с применением трансформационных правил (добавление, стирание, перестановка и замена символов или слов). Грамматика Н. Хомского известна как генеративная или порождающая грамматика. Механизм мышления в этом случае заключается в том, что в глубинные синтаксические структуры добавляются слова из лексического словаря, а затем семантическая компонента проверяет, полученный текст на сочетаемость слов.

Рассмотренные системные модели языка сложны для формализации. Сложность связана с тем, смысл решения (идеи) можно передать, используя множество самых разнообразных словоформ. По мнению психолога Р. Глазера [5], при манипулировании элементами структуры языка могут образовываться семантические структуры, способные привести к решению задачи, «озарению» или инсайту.

1. Семиотическая модель ментального пространства

Для поддержки интеллектуального процесса для поиска решений строится субъективная семиотическая модель, описывающая ситуацию как знаковую систему на ограниченном естественном языке [6]. В модели предметная область задана кортежем: $DF = \langle D, F \rangle$, где D – множество понятий и F – множество параметров предметной области. Определено имя моделируемой ситуации (объекта) – $d \in D$ и множество имен параметров $F^* = \{f_i\}$, $F^* \subset F$, $i = 1, \dots, N$ этой ситуации.

Для каждого параметра f_i задано множество значений, $Z = \{Z_i\}$ в виде упорядоченного множества лингвистических значений, т.е. $Z_i = \{z_{i1}, \dots, z_{iq}\}$, $z_{iq+1} \succ z_{iq}$, $q = 0 \dots n-1$. Вектор параметров ситуации в момент времени t , $Z(t) = (z_{1t}, \dots, z_{nt})$ называется ее состоянием. Для начального состояния $Z(0)$ ($t=0$) определено имя $d^0 = d$, $Z(0) \leftrightarrow d^0$. Определены причинно-следственные отношения на множествах значений $\times_i Z_i$ всех параметров, а динамика изменения состояния ситуации определено как отображение:

$$W: Z(t) \rightarrow Z(t+1), \quad (1)$$

где $Z(t) \in \times_i Z_i$.

Семиотическая модель включает семантическую модель [6], в которой представлены возможные состояния динамической системы (1) в виде частично упорядоченного множества имен классов состояний. Пространство возможных состояний динамической системы (1) $SS = \times_i Z_i$ интерпретируется как признаковое семантическое пространство (*Semantic Space*).

В работе [7] был предложен метод структуризации пространства состояний SS динамической системы (1) на вложенные области возможных состояний $SS(d^H) \subset SS$, имеющие имена d^H , $SS(d^H) \leftrightarrow d^H$, определяющие класс состояний системы (1). При структуризации семантического пространства эксперт определяет область толерантности $SS(d^0) = \times_i \{z_{ir}, \dots, z_{im}\}$, $z_{ir}, \dots, z_{im} \in Z_i$ базового понятия d^0 , $SS(d^0) \subset SS$ и строятся обобщения этой области в виде рекурсивно вложенных областей пространства состояний SS , т.е. $SS(d^H) \subset SS$, $SS(d^0) \subset SS(d^H)$, см. Рис 1.

Всего могут быть получены 3^N обобщений базового понятия d^0 по разным признакам в разных сочетаниях, где N – число признаков понятия d^0 . Отметим, что любая область помечена именами d^H , $H = 0, \dots, 3^N$. Полученные имена d^H по вложению областей состояний $SS(d^H)$ образуют частично упорядоченное множество имен $\{d^H\}$ классов состояний $CF = (\{d^H\}, \leq)$, которое называется качественным концептуальным каркасом (*Conceptual Framework*) предметной области. На рисунке (см.

Рис 2) показана диаграмма Хассе, в узлах которой показаны имена областей, а структура связей показывает порядок вложения их областей.




Рис. 1. Структурированное семантическое пространство для двух признаков




Рис. 2. Концептуальный каркас для понятия, содержащего два признака

В концептуальном каркасе определено имя базового понятия d^0 , остальные имена d^H - это математические символы обозначающие имя класса состояний.

В работе [6] было предложено именовать эти классы состояний искусственными составными именами. Для этого формируется вспомогательный вектор $A=(a_1, \dots, a_n)$, $a_i \in \{-1, 0, 1\}$, где $a_i = -1$, если значение i -го признака z_i меньше его базового значения ($z_i < z_{ir}$), $a_i = 1$, если больше его базового значения ($z_i > z_{im}$), $a_i = 0$, если значение признака попадает в область базового понятия $z_i \in SS(d^0)$.

На рисунке Рис.2 рядом с узлами имен классов состояний указаны такие вектора. Например, для имени d^4 этот вектор равен (0, -1) означает, имя этого класса может быть образовано из известного имени базового понятия d^0 , однако значения второго признака будет меньше, чем его значение для базового понятия, или отсутствовать вовсе. Составное имя может быть образовано по следующему правилу $d_i^H = d^0 \& z_i^*$, где $z_i^* = f_i \& Es$ включает имя параметра f_i и оценку его значения $Es = \{\text{Большой, малый}\}$.

Для поддержки мыслительной деятельности в процессах поиска решений предложен алгоритм решения обратной задачи в семиотической модели ментального пространства. Задача заключается в том, чтобы изменить вектор начального состояния $Z(0)$, который соответствует базовому понятию d^0 на целевой вектор параметров U_{goal} . Формально решение этой задачи запишется так:

$$U = W^T \circ U_{goal} \tag{2}$$

где \circ процедура обратного вывода описана в работах [8].

Решение обратной задачи представляется как множество решений $U = \{U_i\}$, где $U_i = (u_{1e}^i, \dots, u_{nq}^i)$ - вектор состояния, $u_{ij} \in Z_i$. Эти решения в виде точек с координатами элементов векторов представляются в концептуальном пространстве SS . Точки, характеризующие решения в концептуальном пространстве попадают в разные области $SS(d^H)$, характеризующие классы состояний с разными именами d^H . Таким образом, формальные решения обратной задачи U представляются как множество имен классов решений $\{d^{H*}\}$, которое представляется в виде частично упорядоченного множества имен классов состояний $CF^* = (\{d^{H*}\}, \leq)$, $CF^* \subset CF$.

Такая структуризация семантического пространства согласуется представлениями когнитивного психолога [9], который считает, что ментальные пространства это рекурсивно вложенные пространства.

2. Интерпретация имен классов решений в векторных моделях языка

Решения, получаемые с помощью семиотической модели, отражают язык автора этой модели и не отражают все многообразие возможных языковых форм выражения решения. Разнообразные языковые формы решения могут служить стимуляторами мыслительной деятельности, направленной на поиск интуитивно-опытного решения. Для представления решения в альтернативных языковых формах необходима системная модель языка. Ранее рассмотренные системные модели лингвистов-теоретиков сложны для формализации, поэтому рассмотрим возможность применения для интерпретации

решений векторных моделей языка, получаемых в результате обучения нейронных сетей текстовым корпусом.

Векторные модели делят на статические и динамические модели. Статические модели основаны на дистрибутивном анализе корпуса текста, основанном на изучении окружения (распределения) отдельных единиц текста и не использующего сведения о лексическом или грамматическом значении этих единиц. При этом каждому слову в корпусе текста присваивается свой контекстный вектор, который характеризует совместную встречаемость слов корпуса текста. Множество контекстных векторов формирует векторное пространство, в котором определено семантическое расстояние между векторами слов этого пространства. В статических векторных моделях векторы слов, после обучения модели остаются неизменны для данного корпуса текста. Для получения контекстных векторов, текст нормализуется и используется для обучения нейронной сети с целью получения характеристик совместной встречаемости слов в тексте.

При таком подходе разрушается синтаксическая структура текста. Несмотря на это, предполагается, что такое векторное пространство сохраняет семантику предметной области. Это предположение основано на дистрибутивной гипотезе, согласно которой лингвистические единицы, встречающиеся в схожих контекстах, имеют близкие значения.

Статические векторные модели языка представляет собой компактную вероятностную форму системной модели языка, поскольку позволяет извлечь из векторной модели различные элементы системных моделей языка, разработанных лингвистами.

Недостаток статических векторных моделей – это невозможность определить контекст, в котором слова встречаются совместно. Т.е., мы получаем векторы совместного употребления слов, однако не знаем, в каком контексте эти слова совместно употреблялись.

В динамических векторных моделях контекстный вектор слова может изменяться в зависимости от контекста его употребления. В отличие от статических моделей, в которых обучение нейронной сети строится на основе вычисления вектора совместной встречаемости слов в предложении в окрестности 3-10 слов, в динамических моделях для обучения используется целое предложение. Нейросетевые архитектуры на основе трансформеров – это многослойные сети глубокого обучения. В архитектуру трансформера встроены так называемый механизм внимания, который вычисляет важность каждого слова в предложении. Нейросеть глубокого обучения – это нейросеть представления (структуры) данных, в данном случае структуры предложения.

Считается [10], что обученная глубинная нейросеть выделяет синтаксическую структуру предложений в статистическом представлении. При этом части слов или слова предметной области словаря нейросети подставляются в синтаксическую структуру, выделенную обученной нейросетью, получая новое предложение. Нейросеть на основе трансформеров работает аналогично модели порождающей грамматики языка Н. Хомского [4], в которой в глубинную синтаксическую структуру подставляются слова из лексического словаря, образуя поверхностные синтаксические структуры, т.е. предложения, описывающие действительность.

3. Интерпретация имен классов решений в статических векторных моделях языка (Word2Vec)

Для интерпретации пользовалась статическая модель word2vec [11]. Корпус текста формировался под конкретную задачу путем скачивания текстовой информации с множества сайтов Интернета, включающих имя базового понятия d^0 . Для построения векторной модели языка с помощью word2vec текст нормализуется. Множество всех неповторяющихся слов в предложениях образует словарь предметной области, $V_c = \{v_i\}$, $i = 1, \dots, q$. В технологии word2vec определены операции с векторами слов, позволяющие определить частоту совместного употребления сочетания отдельных слов из словаря V_c другими словами предметной области. Операции в технологии word2vec можно представить в виде отображения:

$$w2v:((\bullet)(v_1/r_{p1}, \dots, v_m/r_{pm})) \rightarrow R_w^*$$

где $R_w^* = (v_1/r_{p1}, \dots, v_q/r_{pq})$, $p = 1, \dots, q$, – результирующий вектор, который характеризует частоту (r_{pi}) совместного употребления слов (v_1, \dots, v_q) с другими словами предметной области; (\bullet) – операции, определенные в word2vec как `positive()` и `negative()`.

Операция `positive()` определяет вектор R_w^* , характеризующий частоту совместного употребления слов в аргументе этой операции с другими словами предметной области, а операция `negative()` определяет вектор R_w^* , характеризующий частоту слов предметной области, которые не употребляются со словами, включенными в аргумент операции `negative()`.

Для интерпретации искусственного составного имени решений обратной задачи (2), вспомогательный вектор этого решения $A_k = (a_{k1}, \dots, a_{kn})$, $a_{ki} \in \{-1, 0, 1\}$ подставляется в обученную модель по следующему правилу:

$$w2v(\text{positive}(d^0, f_i/a_{ki} = 1, \dots, f_s/a_{ks} = 1); \text{negative}(f_q/a_{kq} = -1, \dots, f_n/f_{kn} = -1)) = R_w^*$$

где f_i, f_s – имена параметров модели, для которых элемент вектора решений $a_{ki} = 1$ включается в аргумент операции $\text{positive}()$, а f_q, f_n – имена, для которых $a_{kq} = -1$, включаются в аргумент операции $\text{negative}()$. В аргумент операции $\text{positive}()$ добавляется также и имя базового класса (d^0).

В векторе слов $R_w^* = (v_i/r_{i1}, \dots, v_n/r_{in})$ слова корпуса текста $v_i \in V$ упорядочены по частоте встречаемости с именами параметров модели, включенными в решение обратной задачи. Слова с большой частотой встречаемости рассматриваются как возможные имена классов решений.

Для примера использовалось базовое понятие $d^0 = \langle \text{«Бизнесмены»} \rangle$ в семиотической модели, формализованной, описанным выше способом. В результате решения обратной задачи в семиотической модели $\langle \text{«Бизнесмены»} \rangle$ было получено решение в виде составного имени: $\langle \text{«Недовольные бизнесмены»} \rangle$. Для нахождения интерпретации решения $\langle \text{«Недовольные бизнесмены»} \rangle$ нормализуем и подставляем его в обученную векторную модель языка:

$$w2v(\text{positive}(\langle \text{«Бизнесмены»} \rangle, \langle \text{«Недовольство»} \rangle)) = R_w^*$$

В результате получаем вектор слов R_w^* , отражающий частоту совместного употребления слов $\langle \text{«Бизнесмены»} \rangle$ и $\langle \text{«Недовольство»} \rangle$:

$R_w^* = (\text{Вред}/0,904; \text{Факт}/0,885; \text{Респондент}/0,873; \text{Эксперт}/0,872; \text{Аннексия}/0,866; \text{Сожаление}/0,863; \text{Положение}/0,852; \text{Фактор}/0,844; \text{Тренд}/0,833; \text{Претензия}/0,830; \text{Недоверие}/0,817; \text{Эффективность}/0,813; \text{Преимущество}/0,808; \text{Характер}/0,806; \text{Запрос}/0,805; \text{Причина}/0,805; \dots;)$

Статические векторные модели позволяют получить вектор совместного употребления слов, однако, неизвестно в каком контексте эти слова употребляются. Контекст позволяет понять смысл имени класса возможного решения.

Контекст совместного употребления слов можно найти в корпусе текста с использованием лексико-синтаксических шаблонов [12]. Лексико-синтаксический шаблон определяет последовательность элементов (слов), из которых должна состоять описываемая языковая конструкция, и задает условия грамматического согласования этих элементов. Мы будем отыскивать родовидовые отношения, т.е. отношение $\langle \text{«Гипероним-Гипоним»} \rangle$.

Применение лексико-синтаксических шаблонов позволяет сформировать словарь гиперонимов – гипонимов предметной области [6], в который включены предложения, в которых были выделены родовидовые отношения. Добавление контекста в словарь гиперонимов – гипонимов помогает выбрать гипероним в качестве имени класса решений, ориентируясь на контекст его употребления в предметной области.

Таким образом, определена структура словаря в виде кортежа:

$$\langle \text{HYPER}, \text{HYPO}, \text{Context} \rangle \quad (3)$$

где HYPER, HYPO – это множества гипонимов и гиперонимов предметной области, Context – это предложение, в котором родовидовые отношения были определены.

Для получения альтернатив классов решений находим пересечение гиперонимов из словаря (3) и слов в векторе решения R_w^* :

$$\langle (V \cap \text{HYPER}); \text{Context} \rangle,$$

где пересечение множества $V = \{v_i\} \in R_w^*$ слов векторной модели языка и множества гиперонимов из словаря (3) дает множество имен классов решений, а Context (текст предложения) поможет выбрать нужное имя.

Для нашего примера получаем возможные имена классов решений путем пересечения вектора слов R_w^* с гиперонимами предметной области:

$(V \cap \text{HYPER}) = (\text{Вред}/0,904; \text{Факт}/0,885; \text{Сожаление}/0,863; \text{Положение}/0,852; \text{Претензия}/0,830; \text{Недоверие}/0,817; \text{Характер}/0,806; \dots;)$

Таким образом, для формального решения обратной задачи с составным именем $\langle \text{«Недовольные бизнесмены»} \rangle$ в векторной модели языка выделяются два новых класса решений – это $\langle \text{«Вредные бизнесмены»} \rangle$ и $\langle \text{«Недоверчивые бизнесмены»} \rangle$. Для класса $\langle \text{«Недоверчивые бизнесмены»} \rangle$ имеем следующий контекст: $\langle \text{«Ну да, а наши нынешние бизнесмены не доверяют никому и ничему - ни своим партнерам, ни чьим-либо обещаниям»} \rangle$ [13].

Статические векторные модели языка позволяют связать параметры семиотической модели, построенной экспертом ассоциативно-вербальной сетью со словами предметной области. Ассоциативно-вербальная сеть сохраняет семантические отношения в тексте и поэтому может быть использована для стимулирования интеллектуальной деятельности в процессах поиска интуитивно-опытных решений.

4. Интерпретация имен классов решений с помощью динамических векторных моделей (ruBERT, ruGPT)

Большинство векторных моделей, которые показывают высокое качество решения языковых задач, строятся на архитектуре трансформеров с механизмом внимания. Нейронная сеть на трансформерах является сетью представления данных, поскольку выделяет структуру данных (считается, что выделяются синтаксические структуры языка).

В настоящее время существует большое количество предобученных векторных моделей языка на трансформерах для решения различных языковых задач. Для работы с языковыми моделями используются предобученные векторные модели и библиотеки Transformers [14].

Основные задачи, которые решаются с помощью таких векторных моделей языка следующие: Классификация текста (Text Classification), Классификация токенов (слов) (Token Classification), Ответы на вопросы (Question Answering), Классификация без подготовки (Zero-Short Classification), Перевод (Translation), Аннотирование (Summarization), Диалоговый помощник (Conversational), Генерация текста (Text Generation), Схожесть предложений (Sentence Similarity).

Рассмотрим только часть этих задач на примерах в контексте принятия интуитивно-опытных решений, на основе активизации мышления. Все рассматриваемые далее векторные модели языка представлены на сайте [14].

Ответы на вопросы (Question Answering). Ранние вопросно-ответные системы строились на основе правил продукции и ответ на простые вопросы, как правило, был предсказуем или отсутствовал вовсе. Использование в вопросно-ответных системах векторных моделей языка на основе трансформеров расширило их возможности.

При работе таких систем задается некоторый текст, а затем вопрос по этому тексту. Желательно получить развернутый ответ, не содержащий прямые цитаты из представленного текста. В качестве текста мы будем использовать предложение контекста класса решений «Недоверчивые бизнесмены».

Рассмотрим пример системы на основе векторной модели **rugpt_medium_turbo_instructed**, созданной по технологии GPT (Generative Pre-trained Transformer). Здесь формулируется вопрос без определения контекста, в котором может содержаться ответ.

Вопрос: *Почему бизнесмены вредные?*

Ответ: *Бизнесмены, которые наносят вред своим клиентам и окружающей среде, могут быть опасными для общества. Они могут использовать незаконную рекламу или мошеннические схемы в своей работе, а также нарушать экологические нормы и правила.*

Вопрос: *Почему бизнесмены недоверчивые?*

Ответ: *Бизнесмены могут быть не уверены в том, что их компания или продукт будут приняты рынком. Они также могут сомневаться в качестве продукта и его эффективности на рынке.*

Эта векторная модель дает развернутый ответ, опираясь на «знания», которые не содержатся в вопросе. Полученный контекст для классов решений «Вредные бизнесмены» и «Недоверчивые бизнесмены» позволяет понять их смысл, не извлекая из текста родовидовых отношений с помощью шаблонов.

Классификация без подготовки (Zero-Short Classification). Обычно задача классификации требует создания обучающей выборки с указанием для каждого предложения имени класса, к которому его нужно отнести. При решении векторной моделью языка задачи классификации без подготовки обучающая выборка не создается. Векторные модели этого класса решают две задачи: определение причинно-следственных отношений в двух предложениях; определение вероятности принадлежности предложения к классу, имена которого задаются экспертом.

Рассмотрим предобученную векторную модель **rubert-base-cased-nli-threeway**, для решения первой задачи. Определим причинно-следственные отношения между именем класса решений и контекста этого решения из задачи со статической векторной моделью Word2Vec.

Предложение 1: *Недоверчивые бизнесмены.*

Предложение 2: *Ну да, а наши нынешние бизнесмены не доверяют никому и ничему - ни своим партнерам, ни чьим-либо обещаниям.*

Ответ: *Следование: 0.014; Противоречие: 0.017; Нейтральное: 0.97.*

Эта векторная модель языка показала, что имя класса решений и контекст этого класса не связано причинно-следственным отношением.

Для решения второй задачи необходимо определить имена классов, в которые будет классифицироваться, рассмотренный в предыдущем примере контекст класса решений с именем «Недоверчивые бизнесмены». В качестве имен классов возьмём часть вектора совместного употребления слов «Недовольство» и «Бизнесмены», т.е. имена классов следующие: {Факт, Респондент, Эксперт, Аннексия, Сожаление}.

С помощью векторной модели **rubert-base-cased-nli-threeway** получаем следующую классификацию: Факт - 0.51, Респондент - 0.29, Эксперт - 0.044, Аннексия - 0.023, Сожаление - 0.12.

В данном эксперименте векторная модель с большей вероятностью классифицировала модальность предложения как *Факт* - 0.51.

Генерация текста (Text Generation). Задача генерации текста на заданную тему привлекает большое внимание разработчиков, которые представляют в открытый доступ обученные векторные модели языка на трансформерах. В качестве примера генерации текста рассмотрим предложение, которое мы рассматривали ранее. В конце предложения была добавлена фраза *потому, что*. Часть предложения до этой фразы считается темой, а векторная модель языка должна сгенерировать продолжения этой темы. Рассмотрим генерацию текста векторной моделью **ruLM_gpt_neo_small**.

Тема и ее развитие: Ну да, а наши нынешние бизнесмены не доверяют никому и ничему - ни своим партнерам, ни чьим-либо обещаниям *потому, что* они просто хотят обезопасить свой бизнес от мошенничества. А в наше непростое время даже самые серьезные проблемы бизнеса возникают именно у того, кто не может обеспечить своих 15 % процентов акций в компании.

Развитие темы, сгенерированное векторной моделью языка, выделено курсивом после фразы *потому, что*. Здесь трудно комментировать «творчество» векторной модели языка, однако, для активизации мыслительной деятельности в поисках решений сгенерированный текст может служить строителем нового ментального пространства. Отметим, что векторная модель позволяет сгенерировать несколько вариантов развития заданной темы.

Рассмотрим еще одну векторную модель для генерации текста **rugpt3large_based_on_gpt2**.

С помощью этой модели мы пытались получить пояснение для полученных в статической векторной модели языка двух классов решений «Вредные бизнесмены» и «Недоверчивые бизнесмены».

Вот так выглядит продолжение темы (выделено курсивом) для этих двух классов решений:

- Вредные бизнесмены это те, кто не может или не хочет работать.
- Недоверчивые бизнесмены это те, кто не верит в успех.

И наконец, развитие традиционной темы, сгенерированное этой векторной моделью языка следующее: Ну да, а наши нынешние бизнесмены не доверяют никому и ничему - ни своим партнерам, ни чьим-либо обещаниям *потому, что* не знают, что с ними будет завтра.

Как видим в некоторых продолжениях, предложенной темы можно увидеть некоторый здравый смысл.

5. Заключение

На примерах исследована возможность интерпретации формальных решений обратной задачи, полученных в семиотической модели ситуации с помощью статических и динамических векторных моделей языка. Статические векторные модели языка позволяют получить с помощью лексико-синтаксических шаблонов имена классов решений и контекст их употребления. Динамические векторные модели языка решают большое количество языковых задач, однако, многие из этих решений трудно верифицировать. Некоторые решения выглядят некорректными. Однако, в задачах поиска интуитивно-опытных решений контр фактические и абсурдные идеи не отвергаются. Такие решения принимаются к рассмотрению, например в методах мозгового штурма, синектики поскольку стимулируют мышление и могут привести к появлению нетривиальных решений.

Литература

1. Fauconnier G. Mental Spaces: Aspects of meaning construction in natural language. — Cambridge: Cambridge University Press, 1994.
2. Fauconnier G., Turner M. The Way We Think: Conceptual Blending and the Mind's Hidden Complexities. — NY: Basic Books. - 2002.
3. Бондарко А.В. Проблемы функциональной грамматики. Полевые структуры. – С-Пб.: Наука, 2005. – 478 с.
4. Хомский Н. Язык и мышление. Изд-во Моск. Гос. Университета. – 1972. - 121 с.

5. *Glaser R.* Education and Thinking: The role of knowledge/ *Amer. Psychologist*. V.39 (2). (1984). - P. 93-104.
6. *Кулинич А.А.* Семиотическая модель ментального пространства / Труды 20-й Национальной конференции по искусственному интеллекту с международным участием (КИИ-2022, Москва). М.: Изд-во МЭИ. - 2022. - Т. 2. - С. 362-380 (1-20).
7. *Кулинич А.А.* Концептуальные каркасы онтологий слабо структурированных предметных областей // Искусственный интеллект и принятие решений. - 2014. - № 4. - С. 31-41.
8. *Pedrycz W.* Algorithms for solving fuzzy relational equations in a probabilistic setting// *Fuzzy Sets and Systems*. - 1990. - № 38. - p. 313-327.
9. *Величковский Б.М.* Когнитивная наука: Основы психологии познания. В 2-х томах. — М.: Смысл / Академия. - 2006. - 448 с.
10. *Marecek D., Rosa R.* Extracting syntactic trees from transformer encoder selfattentions. Proceedings of the 2018 EMNLP Workshop BlackboxNLP: Analyzing and Interpreting Neural Networks for NLP, Brussels, Belgium, Nov. 1, - 2018 - p. 347–349. <https://aclanthology.org/W18-5444/>
11. *Mikolov, et al.* Distributed representations of words and phrases and their compositionality. In *Advances in Neural Information Processing Systems: 27th Annual Conference on Neural Information Processing Systems*. Proc. Dec. 5-8, 2013, Lake Tahoe, Nevada, United States. - 2013. - p. 3111–3119.
12. *Bolshakova E., Efremova N., Noskov A.* LSPL-Patterns as a Tool for Information Extraction from Natural Language Texts // *New Trends in Classification and Data Mining*. K.Markov et al. (Eds.). Sofia, ITHEA, 2010, - p. 110-118.
13. Юрий Бузиашвили: В нашем обществе не хватает доверия. Тема с академиком РАН Юрием Бузиашвили// *Российская газета - столичный выпуск*. 13 апреля 2020 г. №8133. URL: <https://rg.ru/2020/04/12/iurij-buziashvili-v-nashem-obshchestve-ne-hvataet-doveriia.html>. Дата обращения 05.09.2023.
14. <https://huggingface.co/models/> Дата обращения 27.06.2023.