

Применение глубокого обучения к моделированию диалога на естественном языке*

Е.В. Чистова^{I,II}, А.О. Шелманов^I, И.В. Смирнов^{I,II}

^I Институт системного анализа Федерального исследовательского центра «Информатика и управление» РАН, Москва, Россия

^{II} Российский университет дружбы народов, Москва, Россия

Аннотация. В работе представлен обзор общетематических (неспециализированных) порождающих диалоговых моделей, основанных на глубоком обучении. Рассмотрены основные проблемы построения диалоговых моделей, основанных на машинном обучении, и методы их решения. На русскоязычном корпусе проведено экспериментальное сравнение классической нейросетевой диалоговой модели «кодировщик-декодировщик» с ее модификацией, использующей механизм внимания.

Ключевые слова: диалоговые системы, обработка естественного языка, генерация текста, нейронные сети, искусственный интеллект, глубокое обучение, модель «кодировщик-декодировщик».

DOI: 10.14357/20790279190110

Введение

Диалоговые системы начинают активно применяться для оказания информационно-аналитических услуг во многих сферах. В последнее время становится популярной парадигма messaging-as-an-interface, в которой доступ к различным информационным сервисам предоставляется посредством чат-ботов. Среди подобных систем можно назвать: Duolingo¹ – чат-бот для обучения иностранным языкам; Babylon Health² и HealthTap³ – диалоговые системы для оказания медицинских услуг; система DoNotPay⁴ предоставляет услуги юридического характера и позволяет на основе информации о дорожном штрафе составить рекомендацию к последующим действиям, необходимым чтобы его оспорить.

По методам, использующимся для порождения ответов, диалоговые системы можно разделить на следующие типы.

- Системы, основанные на правилах (rule-based). На запрос (команду) пользователя ответ формируется на основе заранее заданного шаблона или правила.
- Системы, выбирающие для заданного пользователем сообщения ответы из заранее заданного списка (retrieval-based).

- Системы, основанные на порождающих (generative) моделях без заранее заданного списка ответов.

Наибольший интерес среди исследователей вызывает последний тип диалоговых систем. Важным преимуществом порождающих моделей перед системами, основанными на правилах, является возможность их создания с минимальным привлечением ручного труда с помощью обучения на неразмеченных вопросно-ответных символических последовательностях. Такими ресурсами могут быть, например, диалоги пользователей социальных сетей, а также диалоги, извлеченные из субтитров кинофильмов. За последнее время было создано также много открытых специализированных ресурсов, пригодных для обучения диалоговых моделей.

Одни из первых подходов к построению порождающих диалоговых моделей были основаны на принципах статистических методов машинного перевода [1]. Более современные подходы основаны на дистрибутивной семантике: векторных представлениях символов или слов (embeddings) [2]. По сравнению со статистическими моделями они требуют меньше памяти, позволяют генерировать более адекватные ответы и учитывать больше различных факторов [3]. Например, после небольшой модификации на вход такой модели можно подавать в виде векторов не только текст, но и дополнительные данные о собеседнике (возраст, пол, профессия и др.)

* Публикация подготовлена при поддержке Программы РУДН «5-100» и финансовой поддержке РФФИ, проект №18-29-22027 «МК».

¹ <http://bots.duolingo.com/>

² <https://www.babylonhealth.com/>

³ <https://www.healthtap.com/>

⁴ <http://www.donotpay.co.uk/signup.php>

На текущий момент одним из наиболее быстро развивающихся научных направлений в области диалоговых систем является применение порождающих моделей на основе глубокого обучения. Поскольку подобные модели, с одной стороны, хорошо зарекомендовали себя для схожей задачи – машинного перевода, а с другой стороны, легко адаптируются для ведения диалога. Они получили большое внимание со стороны исследователей, которые добились с помощью них ряда значимых успехов. В настоящей работе представлен аналитический обзор методов построения порождающих моделей на основе глубокого обучения. Кроме того, в работе на русскоязычном корпусе проведено экспериментальное исследование влияния добавления к традиционной архитектуре seq2seq [4] механизма «внимания». Продемонстрирована возможность с помощью нейросетевых моделей формировать грамматически согласованные ответы на русском языке, существенная часть из которых может считаться уместной. Также показана состоятельность обучения диалоговой модели на размеченных данных, извлеченных из комментариев пользователей развлекательного ресурса.

В первом разделе настоящей работы приведен обзор методов и моделей естественно-языковой коммуникации, основанных на глубоком обучении. Во втором разделе рассмотрены основные подходы к оценке диалоговых систем. В третьем – данные для обучения диалоговых моделей. В четвертом разделе представлены исследуемые в настоящей работе нейросетевые модели для диалоговых систем. В пятом разделе описаны экспериментальные исследования моделей на материале русскоязычных ресурсов. В заключении приводятся результаты работы и предлагаются направления дальнейших исследований.

1. Обзор диалоговых моделей, основанных на глубоком обучении

Наиболее часто используемой архитектурой для создания диалоговых систем является модель sequence-to-sequence (seq2seq или «кодировщик»-«декодировщик») [4], которая была разработана для машинного перевода. Она максимизирует оценку вероятности генерируемой целевой последовательности T (target) при заданной исходной последовательности S (source):

$$\hat{T} = \operatorname{argmax}_T \{\log p(T|S)\}.$$

Для этого модель использует две рекуррентные сети: кодировщик и декодировщик. Кодировщик «сворачивает» входную последовательность в

вектор фиксированной размерности – контекстный вектор. Декодировщик генерирует новую последовательность, используя контекстный вектор и выходы кодировщика на каждой итерации. Слова преобразуются во входные вектора при помощи матрицы представлений размерности $N \times M$, где N – размер словаря, M – размер ячейки рекуррентной сети.

В оригинальной seq2seq – модели, представленной в работе [4], используются две рекуррентные сети с архитектурой long-short turn memory (LSTM) [5], состоящие из четырех слоев. Допустимо использование любого класса рекуррентных нейронных сетей [6], однако именно архитектура LSTM хорошо зарекомендовала себя в области обработки последовательностей [7] благодаря тому, что в ней частично решается проблема затухающего градиента. В качестве объектов обрабатываемой последовательности могут быть как слова, так и символы. Посимвольная генерация решает проблему нехватки памяти для словарей языков с богатой морфологией (например, русского).

В случае, когда модель seq2seq обучается машинному переводу, используют параллельные корпуса. В случае, когда необходимо обучить модель генерировать ответы в рамках диалога, было предложено использовать диалоговые пары. Для создания систем, способных поддерживать общую беседу используют, например, кинесубтитры из открытых сетевых ресурсов [8]. Для разработки специализированных систем могут использоваться, например, вопросно-ответные базы служб технической поддержки [9].

Одна из главных проблем диалоговых моделей, основанных на оригинальной архитектуре seq2seq, – невозможность сохранения контекста отдельной беседы. В работе [2] предлагаются способы сохранения контекста диалога в скрытых слоях декодировщика. Для этого в диалоге выделяются три лингвистические сущности: контекст c , сообщение m и ответ r . Под контекстом понимается вектор, кодирующий предыдущий диалоговый опыт любой длины. Скрытые слои декодировщика на каждой итерации принимают композицию контекст-сообщение (c, m) . Исследуется три подхода к композиции этих векторов: конкатенация векторов (ведет к увеличению длины вектора), конкатенация с последующим линейным преобразованием для уменьшения размерности (теряется возможная зависимость между векторами c и m), а также конкатенация их линейных отображений. В работе [10] предлагается модель hierarchical recurrent encoder-decoder (HRED), в которой для разрешения проблемы долгосрочных контекстных зависимостей в кодировщике используется иерархия из

двух рекуррентных сетей: кодировщика высказывания и кодировщика контекста. Первая сеть преобразует входную последовательность слов одной реплики в вектор фиксированной длины. Вектора реплик диалога используются как входы второй сети-кодировщика. Она аккумулирует информацию из всего предыдущего диалога и порождает его контекстный вектор, который уже используется декодировщиком для генерации ответа.

Другой часто встречающейся проблемой, порождающих диалоговых моделей, является генерация сетью общих реплик вида «*I don't know*». Этот эффект возникает из-за того, что подобные общие реплики склонны иметь наибольшее значение вероятности $p(T|S)$. Для решения этой проблемы в работе [11] предлагается максимизировать взаимную информацию (mutual information, сокр. *MI*):

$$\begin{aligned} \hat{T} &= \operatorname{argmax}_T MI(T, S, \lambda) = \\ &= \operatorname{argmax}_T (\log p(T|S) - \lambda \log p(T)). \end{aligned}$$

Здесь λ – гиперпараметр, штрафующий ответы, наиболее вероятные в данном языке. Стоит отметить, что такой подход имеет ряд проблем. Во-первых, как наиболее вероятные зачастую штрафуются грамматически верные ответы. Во-вторых, первые слова генерируемой последовательности в значительной степени определяют оставшуюся часть предложения, и к большему разнообразию ответа ведут штрафы слов, предсказанных моделью в первую очередь. Для решения этой проблемы в функцию вероятности ответа $p(T)$ вносится штрафующий множитель, монотонно убывающий при увеличении длины ответа. В [11] в качестве такого множителя предлагается ступенчатая функция:

$$g(k) = \begin{cases} 1, & \text{если } k \leq w_0; \\ 0, & \text{иначе} \end{cases}$$

с порогом штрафования w_0 для слов на позиции k . В-третьих, после преобразований по теореме Байеса взаимная информация приобретает вид:

$$MI(T, S, \lambda) = (1 - \lambda) \log p(T|S) + \lambda \log p(S|T),$$

следовательно, необходимо обучить две модели, одна из которых генерирует ответ по вопросу, а другая – вопрос по ответу.

Еще одной проблемой оригинальной архитектуры seq2seq является то, что простая рекуррентная сеть склонна быстро забывать начало длинной последовательности. Так как ключевой способностью модели является сжатие входной информации в вектор представления фиксированного размера, входные последовательности обрабатываются хуже с увеличением их длин. Для решения этой проблемы в [12] предлагается добавить

в архитектуру сети механизм внимания (attention mechanism). В качестве объекта внимания в диалоговой модели используются выходы последнего слоя кодировщика, в качестве ключа – выход последнего слоя декодировщика. Механизм внимания реализуется следующим образом: каждому вектору из выхода декодировщика при помощи ключа k сопоставляется вес внимания a_i . Веса внимания для выходов декодировщика преобразуются при помощи софтмакс-нормализации и могут быть интерпретированы как вероятности выбора декодировщиком контекстного представления I . Таким образом, внимание модели фокусируется на объектах, наиболее схожих с ключами. Ввиду традиционного обучения seq2seq-моделей с использованием метода обратного распространения ошибки, исследователи используют механизм мягкого внимания (soft attention), при котором вектор представления объектов внимания с учетом ключа вычисляется как линейная комбинация объектов и весов внимания. Механизм жесткого внимания (hard attention), напротив, исследует каждый вес a_i дискретно, для обучения модели с таким механизмом необходимо прибегать к вариационным приближениям, и в данной задаче он используется редко [13]. Возможно использование механизмов внимания в комбинации с эвристиками, генерируемыми независимые переранжируемые подпоследовательности [14]. В [12] показано, что механизм внимания улучшает качество генерируемых последовательностей для длинных запросов.

Многие исследователи также указывают на проблему, связанную с невозможностью ведения диалога с обезличенной моделью. В работе [15] предлагаются две диалоговые модели с различным подходом к моделированию личности. Первая модель «Speaker» оперирует вектором в некотором пространстве спикеров, формируемом при помощи доступной информации об авторах реплик в обучающем наборе данных (пол, возраст, уровень образования, место жительства). На каждой итерации предсказания ответа состояние скрытых слоев изменяется исходя из комбинации состояния в предыдущей итерации, представления слова на данной итерации и вектора спикера. Положительной стороной такой модели является ее склонность к кластеризации спикеров, дающая возможность оперировать информацией из диалогов ближайших по векторному пространству спикеров. Вторая модель «Speaker-Addressee» позволяет решать задачу предсказания ответа адресата i на реплику спикера j . В этом случае не только модели, но и пользователю также присваивается векторное представление, и комбинация двух векторов используется для

вычисления состояний ячеек сети. Обученная сеть будет отвечать пользователю k иначе, чем пользователю j . Данная модель обладает тем же положительным качеством, что и первая, но требует много обучающих данных о диалогах одних и тех же людей с разными оппонентами. Векторы представлений пользователей можно также использовать при персонализированном диалоговом моделировании с ранжированием [16].

Стоит отметить, что для совершенствования диалоговых систем применяют также методы активного обучения (active learning), подразумевающие взаимодействие системы с реальными пользователями. В этом случае модель дообучается при получении реакции пользователя на каждый ответ системы (one-shot learning) [17]. Возможно также обучение с подкреплением (reinforcement learning). Так, цель системы, разработанной в [18] – поддерживать продолжительную беседу; разнообразие ответов системы поощрялось по результатам подсчета среди них уникальных N -грамм.

2. Подходы к оценке диалоговых систем

Специфика диалоговых моделей такова, что использовать классические для машинного обучения критерии оценки (точность, полнота, F_1 -мера) не представляется возможным, поскольку генерируемые моделями последовательности обладают высокой вариативностью. Для автоматической оценки генеративных диалоговых моделей чаще всего прибегают к методам, разработанным для задач машинного перевода. Среди них наиболее популярна метрика BLEU, определяющая процент n -грамм, совпадающих в машинном и эталонном переводе [19], применяются также ее модификации [20,21], Avg, перплексия. Однако многие исследователи критично относятся к использованию метрик качества машинного перевода при оценке диалоговых систем. В исследовании [22] показано, что метрики для машинного перевода и экспертные оценки имеют либо слабую корреляцию между собой, либо не имеют ее вовсе. В [16] также указывают на неэффективность применения метрик BLEU и перплексии ввиду того, что они оценивают лишь лексическую гибкость и игнорируют отступление от контекста беседы.

В работе [23] предложена реализация метода обучения с противником (adversarial learning), основанного на обучении с подкреплением. В качестве вознаграждения для порождающей модели используется заключение бинарного классификатора, играющего роль эксперта в тесте Тьюринга [24] – он классифицирует поступающее выска-

зывание как человеческое или машинное. Стоит заметить, что не все исследователи считают тест Тьюринга приемлемым для оценки диалоговой системы: целью оценки должно быть определение качества диалогового опыта, а не разоблачение машины [25].

Ввиду несовершенства существующих автоматизированных методик разработаны специальные способы экспертной оценки диалогов. Некоторые исследователи применяют экспертные оценки напрямую: используют процент предпочтительных экспертами ответов одной из тестовых моделей или оценку по некоторой шкале [6, 11]. Другие находят способы составления специальных функций на основе слабо сопоставимых экспертных оценок (адекватность контексту, лексическая грамотность, достижение результата) [17]. Так, в одной из первых работ, касающихся оценки диалоговых агентов, оценка вычисляется как каппа Коэна на основе матрицы диалог-сценарий, на главной диагонали которой – число совпадений с ожидаемым поведением системы, вне – ее ошибки [26].

3. Данные для обучения диалоговых моделей

Как было сказано выше, для обучения нейросетевых моделей не требуется ручная разметка корпусов, их можно обучать на любых коллекциях диалоговых реплик. Диалоговые агенты, нацеленные на свободный диалог, часто обучают на открытых данных из многопользовательских сетевых ресурсов. Среди них для английского языка особенно популярны комментарии ресурсов Reddit и Twitter. Для свободного скачивания доступны корпус комментариев Reddit⁵ (1,7 млрд комментариев), Microsoft Research Social Media Conversation Corpus⁶ (12696 id твитов, представляющих 4232 диалога по три реплики) [2]. Диалоговые агенты возможно также обучать на киносценариях. В работе [17] корпус Cornell Movie Dialog⁷, содержащий беседы (220579 диалоговых обменов между 10292 персонажами) и метаданные (рейтинг фильма в IMDB, жанр, пол высказывающегося персонажа и т.д.) использовался для предварительного обучения модели, чтобы ознакомить ее с синтаксисом и семантикой языка. Дальнейшее обучение происходило на корпусе JabberWacky⁸ (история диалогов в онлайн-чате) для приближения порождаемых ответов к стилю коротких сообщений.

⁵ https://www.reddit.com/r/datasets/comments/3bxlg7/i_have_every_publicly_available_reddit_comment/

⁶ <https://www.microsoft.com/en-us/download/details.aspx?id=52375>

⁷ http://www.cs.cornell.edu/~cristian//Cornell_Movie-Dialogs_Corpus.html

⁸ <http://www.jabberwacky.com/j2conversations>

Для тестового обучения ассистентов технической поддержки можно использовать Ubuntu Dialogue Corpus, содержащий вопросы, касающиеся проблем с операционной системой Ubuntu, возникшие у пользователей одноименного чата в сети IRC [27]. Еще одним ресурсом, используемым для обучения диалоговых систем, является корпус ChangeMyViewDataset – собрание всех доступных на 11.11.2016 дискуссий ветки «измени мое мнение» ресурса Reddit⁹. Стоит также отметить, что в работе [28] предложено использовать помимо диалоговых данных внешнюю информацию из экспертной области (Foursquare, TripAdvisor, Goodreads, IMDB и т.д.).

4. Диалоговые модели, используемые для экспериментальных исследований на материале русскоязычных ресурсов

Для экспериментов с русскоязычными данными в настоящей работе были использованы две архитектуры seq2seq: стандартная и с механизмом внимания; генерация ответов производится пословно. Рассмотрим эти архитектуры более подробно.

Пусть на вход кодировщика поступает фраза «*добрый день!*» (рис. 1). Каждое слово на позиции i входной последовательности ассоциируется с числовым вектором $w_i \in \mathbb{R}^d$ из обучаемой матрицы нейронной сети или из предобученной модели векторных представлений слов языка.

Последовательность векторов w_0, \dots, w_3 пошагово поступает в LSTM-сеть. Последнее скрытое состояние сети (в данном случае это e_2) является выходом кодировщика – векторным представлением всей входной последовательности e .

Контекстный вектор используется для инициализации скрытого состояния сети-декодировщика. В экспериментах в качестве кодировщика и декодировщика использовались идентичные рекуррентные сети LSTM с 256 нейронами и оптимизационным алгоритмом Adam [29] с коэффициентом скорости обучения 0,02.

После обновления скрытое состояние декодировщика (рис. 2) при помощи некоторой функции $g(h_0)$ получает представление s_0 с размерностью v , равной мощности словаря; s_0 нормализуется функцией softmax:

$$\begin{aligned} h_0 &= LSTM(e, w_{\langle sos \rangle}) \\ s_0 &= g(h_0) \\ p_0 &= softmax(s_0). \end{aligned}$$

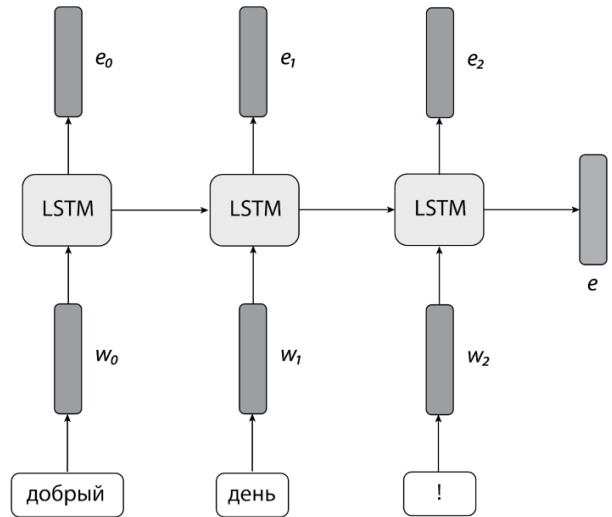


Рис. 1. Принцип работы сети-кодировщика в seq2seq

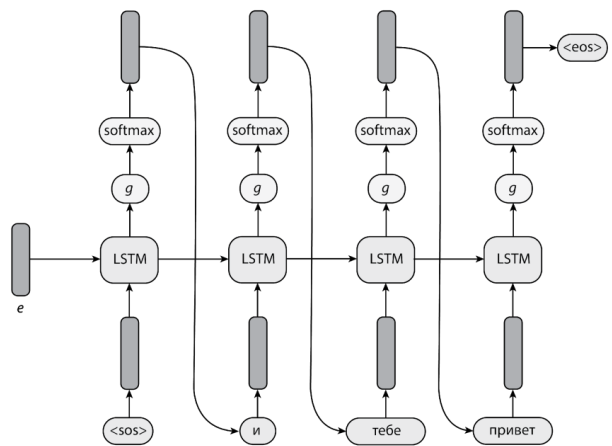


Рис. 2. Схематичное изображение сети-декодировщика в seq2seq

Полученное значение $p_0 \in \mathbb{R}^v$ можно трактовать как вектор, показывающий вероятность появления в текущем контексте каждого слова из словаря. Допустим, применение $i_0 = argmax(p_0)$ указывает на индекс в словаре слова «и», как обладающего наибольшей вероятностью. Соответствующий этому слову вектор $w_{i_0} = w_{и}$ вместе с текущим скрытым состоянием h_0 подается на вход декодировщика на следующем шаге:

$$\begin{aligned} h_1 &= LSTM(h_0, w_{i_0}) \\ s_1 &= g(h_1) \\ p_1 &= softmax(s_1) \\ i_1 &= argmax(p_1). \end{aligned}$$

Последний шаг повторяется, пока $i_T \neq \langle eos \rangle$.

Исследования в других работах показывают, что корректировка выходов кодировщика при по-

⁹ <https://chenhaot.com/pages/changemyview.html>

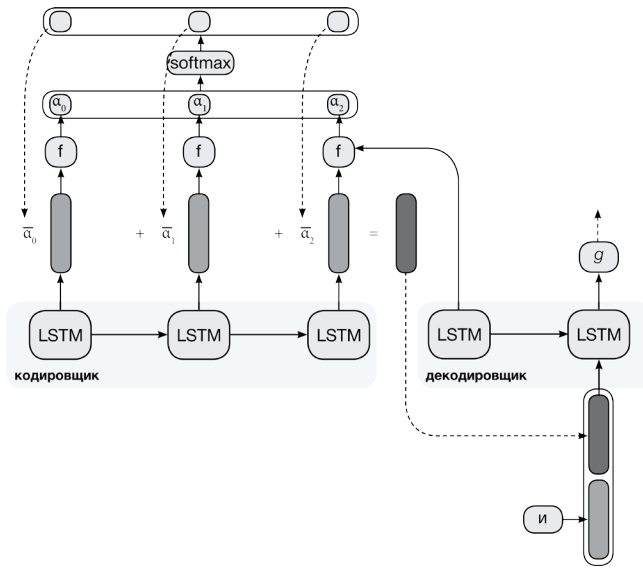


Рис. 3. Принцип работы seq2seq с механизмом внимания

мощи выходов декодировщика повышает эффективность сети при обработке длинных последовательностей. Такая регулировка осуществима с помощью механизма внимания (рис. 3).

При реализации этого механизма на вход декодировщика на каждом шаге t дополнительно поступает контекстный вектор c_t : $h_t = LSTM(h_{t-1}, [w_{i_{t-1}}, c_t])$. Вектор c_t является взвешенным средним всех внутренних состояний $e_{t'}$ кодировщика: $c_t = \sum_{t'=0}^n \alpha_{t'} e_{t'}$. Веса внимания $\alpha_{t'} \in \mathbb{R}$ зависят от предыдущего состояния декодировщика h_{t-1} и от внутреннего состояния кодировщика: $\alpha_{t'} = f(h_{t-1}, e_{t'})$, где f – некоторое нелинейное преобразование. Обычно используют нормализованные веса $\bar{\alpha}_{t'} \in [0, 1]$, которые можно понимать как вероятность внимания для каждого из выходов кодировщика:

$$\alpha_{t'} = f(h_{t-1}, e_{t'}), t' = \{0, \dots, T\}$$

$$\bar{\alpha}_{t'} = softmax(\alpha_{t'})$$

$$c_t = \sum_{t'=0}^n \bar{\alpha}_{t'} e_{t'}$$

В процессе обучения seq2seq – модели минимизируется кросс-энтропия между целевым распределением (на векторах заданных ответов y_1, \dots, y_m) и распределением, предсказываемым моделью p_1, \dots, p_m :

$$Loss = - \sum_{i=1}^m y_i \log p_i$$

5. Экспериментальные исследования диалоговых моделей на материале русскоязычных ресурсов

5.1 Данные для экспериментальных исследований, метод оценки

Для экспериментов с русским языком были использованы данные из открытой базы субтитров (50 000 реплик) и комментарии русскоязычного информационного сообщества Пикабу¹⁰ (3 611 347 диалоговых пар). Для экспериментов использовалась готовая реализация модели seq2seq, представленная в [2]. Были обучены пять моделей при разном размере словаря и с разными предобученными моделями векторных представлений слов. В частности, использовались две модели ресурса RusVectors¹¹, обученные на двух разных корпусах: RuWikirusCorpora, состоящий из русскоязычных статей Wikipedia, корпус Araneum Russicum, содержащий тексты, извлеченные из сайтов в доменах «.ru» и «.рф».

Как уже было отмечено, в настоящее время не существует специальных метрик для оценки качества диалоговых систем. Примененный в настоящей работе экспертный метод оценки заключался в создании списка из двухсот общих вопросов, взятых из обычного диалога в мессенджере, и в ручном подсчете доли уместных ответов модели. Доля уместных ответов – доля ответов, которые можно считать приемлемыми, среди ответов модели на 200 заранее заготовленных вопросов (реплик) общей тематики, которые можно встретить в обычной переписке.

5.2 Результаты

В табл. 1 представлены основные результаты экспериментального сравнения диалоговых моделей seq2seq. По результатам видно, что модели, архитектура которых содержит механизм внимания, показывают более высокий результат относительно моделей с классической архитектурой seq2seq. Модели, не использовавшие предобученные векторы слов русского языка, показали существенно более худшие результаты ввиду ограниченного времени обучения. Однако, стоит отметить, что при возможности длительного обучения использование векторных представлений, обученных на данных, используемых для обучения диалоговой модели, может улучшить результат ввиду специфики данных сетевых дискурсов, не придерживающихся литературно-публицистических норм и тематик, свойственных данным, использовавшимся при обучении векторов проектом RusVectors.

¹⁰ https://github.com/tchewik/datasets/tree/master/pikabu_comments

¹¹ <http://rusvectors.org/ru/models/>

Табл. 1

Доля уместных ответов исследуемых диалоговых моделей

Размер словаря	Архитектура	Уместность
25000	vanilla	18%
25000	attention	30%
50000	vanilla	32%
50000	attention	43%
100000	vanilla	36%
100000	attention	56%

Полученные значения качества показывают, что данные модели не пригодны для практического применения: поддержание разговора представляется невозможным, поскольку более, чем в 50% случаев их ответ неуместен. Однако обучение на неразмеченных данных без каких-либо правил продемонстрировало некоторые результаты для русского языка. В будущем возможна комбинация такого подхода к генерации ответов и использование баз знаний для того, чтобы модель оперировала более конкретными представлениями в каждой области, что невозможно при обучении на репликах большого количества людей.

Табл. 2 демонстрирует, как меняются ответы одной из моделей на разных шагах обучения. Данная модель обучена на корпусе комментариев Пикабу, что придает ее ответам некоторые характерные для дискурса в этом сообществе особенности.

На рис. 4 представлены графики обучения моделей с классической архитектурой seq2seq при словарях разного объема на корпусе Пикабу. На данном графике у моделей с большей словарной мощностью можно наблюдать более скорую сходимость к минимуму функции ошибки.

Табл. 3 демонстрирует долю уместных ответов и примеры ответов каждой из данных моделей.

Табл. 2

Примеры работы стандартной seq2seq-модели на разных шагах обучения

Реплика пользователя	Шаг 94280	Шаг 167294	Шаг 229022
Добрый день!	Привет, земляк!	И тебе привет!	+1.
Что такое надежда ?	Асинхронный двигатель?.	Асинхронный двигатель?.	Асинхронный двигатель?.
Что такое сон?	Я не знаю, что это.	Это не яблоко..	Что?.
Ненавижу тебя	А я веган..	А я томат.	А я веган.
Что случится, если машины начнут думать ?	В смысле?	В том то и дело, что нет.	В смысле?

Табл. 3

Сопоставление результатов обучения моделей с разным размером словаря

Мощность словаря	Min Loss	Max Loss	Доля уместных ответов	Примеры ответов
25000	2,644	5,743	25%	- Свобода - это иллюзия? - Незнание- сила. - Кто такой Билл Гейтс? - Это водила.
50000	2,467	6,165	23%	- Ты в порядке ? - А ты?. - Кто все эти люди? - А что с ними не так?.
100000	2,396	6,754	35%	- Это сделала Анна. - Спасибо, кэп. - Сколько ног у паука? - А что за порода?.




Рис. 4. Значения функции потерь при обучении стандартной seq2seq с разным размером словаря

Заключение

В работе рассмотрены подходы к построению диалоговой модели на основе рекуррентных нейронных сетей. Результаты эксперимента на русскоязычных данных показывают, что добавление к модели seq2seq механизма внимания повышает качество генерируемых ей реплик. В работе показано, что модели генерируют грамматически согласованные ответы на русском языке. В будущем возможна комбинация данного подхода к генерации ответов и использования баз знаний для того, чтобы модель оперировала более конкретными представлениями в каждой области.

Порождающие диалоговые модели, основанные на глубоком обучении, пока не демонстрируют результатов, достаточных для применения их в реальных приложениях диалогового моделирования. Однако их исследование необходимо для решения задачи моделирования общетематического диалога с обучением на размеченных данных. Среди перспективных подходов к повышению качества диалоговых агентов можно назвать гибридные подходы на основе моделей различных типов. К таким можно отнести: генерацию нормированного текста с последующим применением модели-согласователя, что позволяет производить вычисления над языками с большим количеством словоформ, экономя память; комбинацию моделей глубокого обучения и онтологических ресурсов. Помимо исследований в области архитектуры диалоговых моделей необходима также разработка универсальной метрики диалогов.

В будущих работах планируется дальнейший поиск пригодной для задачи диалогового моделирования качественной метрики, а также эксперименты с комбинированием различных подходов к моделированию диалога в рамках одного диалогового агента.

Литература

1. Ritter A., Cherry C., Dolan W.B. Data-driven response generation in social media //Proceedings of the conference on empirical methods in natural language processing. – Association for Computational Linguistics, 2011. – P. 583-593.
2. Sordoni A. et al. A Neural Network Approach to Context-Sensitive Generation of Conversational Responses //Proceedings of the 2015 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. – 2015. – P. 196-205.
3. Cho K., van Merriënboer B., Bahdanau D., Bengio Y. On the properties of neural machine translation: Encoder-decoder approaches. //Proceedings of SSST-8, Eighth Workshop on Syntax, Semantics and Structure in Statistical Translation, 2014. – P. 103-111.
4. Sutskever I., Vinyals O., Le Q.V. Sequence to sequence learning with neural networks //Advances in neural information processing systems. – 2014. – P. 3104-3112.
5. Schmidhuber Jürgen, Sepp Hochreiter. “Long short-term memory.” Neural Comput 9.8 (1997): 1735-1780.
6. Serban I.V. et al. Multiresolution Recurrent Neural Networks: An Application to Dialogue Response Generation //AAAI. – 2017. – P. 3288-3294.
7. Graves A. Generating sequences with recurrent neural networks //arXiv preprint arXiv:1308.0850. – 2013.
8. Tiedemann J. News from OPUS-A collection of multilingual parallel corpora with tools and interfaces //Recent advances in natural language processing. – 2009. – P. 237-248.
9. Vinyals O., Le Q. A neural conversational model // ICML Deep Learning Workshop - 2015.
10. Serban I.V. et al. Building End-To-End Dialogue Systems Using Generative Hierarchical Neural Network Models //AAAI. – 2016. – P. 3776-3784.
11. Li J. et al. A Diversity-Promoting Objective Function for Neural Conversation Models // Proceedings of NAACL-HLT. – 2016. – P. 110-119.
12. Bahdanau D., Cho K., Bengio Y. Neural machine translation by jointly learning to align and translate // ICLR. – 2015.
13. Luong M.T., Pham H., Manning C.D. Effective approaches to attention-based neural machine translation //arXiv preprint arXiv:1508.04025. – 2015.
14. Shao L. et al. Generating High-Quality and Informative Conversation Responses with Sequence-to-Sequence Models //Proceedings of EMNLP. – 2017.

15. *Li J. et al.* A persona-based neural conversation model. //Proceedings of ACL. – 2016. – P. 994-1003
16. *Al-Rfou R. et al.* Conversational contextual cues: The case of personalization and history for response ranking //arXiv preprint arXiv:1606.00372. – 2016.
17. *Asghar N. et al.* Deep active learning for dialogue generation //Proceedings of the 6th Joint Conference on Lexical and Computational Semantics (* SEM 2017). – 2017. – P. 78-83.
18. *Li J. et al.* Deep Reinforcement Learning for Dialogue Generation //Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing. – 2016. – P. 1192-1202.
19. *Papineni K. et al.* BLEU: a method for automatic evaluation of machine translation //Proceedings of the 40th annual meeting on association for computational linguistics. – Association for Computational Linguistics, 2002. – P. 311-318.
20. *Galley M. et al.* deltaBLEU: A Discriminative Metric for Generation Tasks with Intrinsically Diverse Targets //Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing (Volume 2: Short Papers). – 2015. – Vol. 2. – P. 445-450.
21. *Banerjee S., Lavie A.* METEOR: An automatic metric for MT evaluation with improved correlation with human judgments //Proceedings of the ACL workshop on intrinsic and extrinsic evaluation measures for machine translation and/or summarization. – 2005. – P. 65-72.
22. *Liu C.W. et al.* How NOT To Evaluate Your Dialogue System: An Empirical Study of Unsupervised Evaluation Metrics for Dialogue Response Generation //Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing. – 2016. – P. 2122-2132.
23. *Li J. et al.* Adversarial Learning for Neural Dialogue Generation //Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing. – 2017. – P. 2157-2169.
24. *Turing A.* Computing intelligence and machinery //Mind. – 1950. – Vol. 59. – N. 2236.
25. *Venkatesh A. et al.* On Evaluating and Comparing Conversational Agents //arXiv preprint arXiv:1801.03625. – 2018.
26. *Walker M.A. et al.* PARADISE: A framework for evaluating spoken dialogue agents //Proceedings of the eighth conference on European chapter of the Association for Computational Linguistics. – Association for Computational Linguistics, 1997. – P. 271-280.
27. *Lowe R. et al.* The Ubuntu Dialogue Corpus: A Large Dataset for Research in Unstructured Multi-Turn Dialogue Systems //Proceedings of the 16th Annual Meeting of the Special Interest Group on Discourse and Dialogue. – 2015. – P. 285-294.
28. *Ghazvininejad M. et al.* A Knowledge-Grounded Neural Conversation Model //arXiv preprint arXiv:1702.01932. – 2017.
29. *Kingma D.P., Ba J. Adam.* A method for stochastic optimization //arXiv preprint arXiv:1412.6980. – 2014.

Чистова Елена Викторовна. Институт системного анализа Федерального исследовательского центра «Информатика и управление» РАН. Москва. Программист. E-mail: chistova@isa.ru

Шелманов Артем Олегович. Институт системного анализа Федерального исследовательского центра «Информатика и управление» РАН. Москва. Научный сотрудник, кандидат технических наук. Количество печатных работ: 31. Область научных интересов: искусственный интеллект, компьютерная лингвистика, машинное обучение, информационно-аналитические системы. E-mail: shelmanov@isa.ru

Смирнов Иван Валентинович. Институт системного анализа Федерального исследовательского центра «Информатика и управление» РАН. Москва. Заведующий отделом, кандидат физико-математических наук, доцент. Количество печатных работ: 70. Область научных интересов: обработка естественного языка, интеллектуальный анализ информации. E-mail: ivs@isa.ru

Natural language dialogue modelling with deep learning

E.V. Chistova^{1,II}, A.O. Shelmanov^I, I.V. Smirnov^{1,II}

^I Federal Research Center “Computer Science and Control” of Russian Academy of Sciences, Moscow, Russia

^{II} Peoples’ Friendship University of Russia (RUDN University), Moscow, Russia

Abstract. Building natural language dialogue systems that can converse coherently with user is an actual problem of artificial intelligence. This paper presents an overview of the open-domain generative neural network dialogue models. The main problems of constructing dialogue models based on machine learning and methods for their solution are considered. An experimental comparison of the vanilla neural network encoder-decoder model with its attention mechanism modification was carried out on the Russian-language data.

Keywords: *dialogue systems, natural language processing, natural language generation, neural networks, artificial intelligence, deep learning, encoder-decoder model.*

DOI: 10.14357/20790279190110

References

1. Ritter A., Cherry C., Dolan W.B. Data-driven response generation in social media //Proceedings of the conference on empirical methods in natural language processing. – Association for Computational Linguistics, 2011. – P. 583-593.
2. Sordoni A. et al. A Neural Network Approach to Context-Sensitive Generation of Conversational Responses //Proceedings of the 2015 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. – 2015. – P. 196-205.
3. Cho K., van Merriënboer B., Bahdanau D., Bengio Y. On the properties of neural machine translation: Encoder-decoder approaches. //Proceedings of SSST-8, Eighth Workshop on Syntax, Semantics and Structure in Statistical Translation, 2014. – P. 103-111.
4. Sutskever I., Vinyals O., Le Q.V. Sequence to sequence learning with neural networks //Advances in neural information processing systems. – 2014. – P. 3104-3112.
5. Schmidhuber Jürgen, and Sepp Hochreiter. “Long short-term memory.” *Neural Comput* 9.8 (1997): 1735-1780.
6. Serban I.V. et al. Multiresolution Recurrent Neural Networks: An Application to Dialogue Response Generation //AAAI. – 2017. – P. 3288-3294.
7. Graves A. Generating sequences with recurrent neural networks //arXiv preprint arXiv:1308.0850. – 2013.
8. Tiedemann J. News from OPUS-A collection of multilingual parallel corpora with tools and interfaces //Recent advances in natural language processing. – 2009. – P. 237-248.
9. Vinyals O., Le Q. A neural conversational model // ICML Deep Learning Workshop - 2015.
10. Serban I.V. et al. Building End-To-End Dialogue Systems Using Generative Hierarchical Neural Network Models //AAAI. – 2016. – P. 3776-3784.
11. Li J. et al. A Diversity-Promoting Objective Function for Neural Conversation Models // Proceedings of NAACL-HLT. – 2016. – P. 110-119.
12. Bahdanau D., Cho K., Bengio Y. Neural machine translation by jointly learning to align and translate // ICLR. – 2015.
13. Luong M.T., Pham H., Manning C.D. Effective approaches to attention-based neural machine translation //arXiv preprint arXiv:1508.04025. – 2015.
14. Shao L. et al. Generating High-Quality and Informative Conversation Responses with Sequence-to-Sequence Models //Proceedings of EMNLP. – 2017.
15. Li J. et al. A persona-based neural conversation model. //Proceedings of ACL. – 2016. – P. 994-1003
16. Al-Rfou R. et al. Conversational contextual cues: The case of personalization and history for response ranking //arXiv preprint arXiv:1606.00372. – 2016.
17. Asghar N. et al. Deep active learning for dialogue generation //Proceedings of the 6th Joint Conference on Lexical and Computational Semantics (*SEM 2017). – 2017. – P. 78-83.
18. Li J. et al. Deep Reinforcement Learning for Dialogue Generation //Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing. – 2016. – P. 1192-1202.
19. Papineni K. et al. BLEU: a method for automatic evaluation of machine translation //Proceedings of the 40th annual meeting on association for computational linguistics. – Association for Computational Linguistics, 2002. – P. 311-318.

20. *Galley M. et al.* deltaBLEU: A Discriminative Metric for Generation Tasks with Intrinsically Diverse Targets //Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing (Volume 2: Short Papers). – 2015. – Vol. 2. – P. 445-450.
21. *Banerjee S., Lavie A.* METEOR: An automatic metric for MT evaluation with improved correlation with human judgments //Proceedings of the ACL workshop on intrinsic and extrinsic evaluation measures for machine translation and/or summarization. – 2005. – P. 65-72.
22. *Liu C.W. et al.* How NOT To Evaluate Your Dialogue System: An Empirical Study of Unsupervised Evaluation Metrics for Dialogue Response Generation //Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing. – 2016. – P. 2122-2132.
23. *Li J. et al.* Adversarial Learning for Neural Dialogue Generation //Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing. – 2017. – P. 2157-2169.
24. *Turing A.* Computing intelligence and machinery //Mind. – 1950. – Vol. 59. – N. 2236.
25. *Venkatesh A. et al.* On Evaluating and Comparing Conversational Agents //arXiv preprint arXiv:1801.03625. – 2018.
26. *Walker M.A. et al.* PARADISE: A framework for evaluating spoken dialogue agents //Proceedings of the eighth conference on European chapter of the Association for Computational Linguistics. – Association for Computational Linguistics, 1997. – P. 271-280.
27. *Lowe R. et al.* The Ubuntu Dialogue Corpus: A Large Dataset for Research in Unstructured Multi-Turn Dialogue Systems //Proceedings of the 16th Annual Meeting of the Special Interest Group on Discourse and Dialogue. – 2015. – P. 285-294.
28. *Ghazvininejad M. et al.* A Knowledge-Grounded Neural Conversation Model //arXiv preprint arXiv:1702.01932. – 2017.
29. *Kingma D.P., Ba J. Adam.* A method for stochastic optimization //arXiv preprint arXiv:1412.6980. – 2014.

Chistova Elena Viktorovna. Institute for Systems Analysis Federal Research Center “Computer Science and Control” of Russian Academy of Sciences, 44/2 Vavilova str., Moscow, 119333, Russia. E-mail: chistova@isa.ru

Shelmanov Artem Olegovich. PhD, Institute for Systems Analysis Federal Research Center “Computer Science and Control” of Russian Academy of Sciences, 44/2 Vavilova str., Moscow, 119333, Russia. The number of publications: 31. Research interests: artificial intelligence, natural language processing, machine learning, search and analytical systems. E-mail: shelmanov@isa.ru

Smirnov Ivan Valentinovich. PhD, Associate Professor, head of the department for Intelligent Data Analysis, Institute for Systems Analysis Federal Research Center “Computer Science and Control” of Russian Academy of Sciences, 44/2 Vavilova str., Moscow, 119333, Russia. The number of publications: 70. Research interests: natural language processing, data mining. E-mail: ivs@isa.ru