

УДК 004.855.5

РАЗРАБОТКА ВОПРОСНО-ОТВЕТНОЙ СИСТЕМЫ ДЛЯ ДИАЛОГОВ НА ИТ ТЕМЫ НА ОСНОВЕ RUDIALOGPT

Самигулин Т. Р. (Федеральное государственное автономное образовательное учреждение высшего образования «Национальный исследовательский университет ИТМО»),
Сафонова А. О. (Федеральное государственное автономное образовательное учреждение высшего образования «Национальный исследовательский университет ИТМО»),
Хлюпина Ю. М. (Федеральное государственное автономное образовательное учреждение высшего образования «Национальный исследовательский университет ИТМО»),
Демин О. Д. (Федеральное государственное автономное образовательное учреждение высшего образования «Национальный исследовательский университет ИТМО»)

Научный руководитель - доктор технических наук, доцент Басов О. О.
(Федеральное государственное автономное образовательное учреждение высшего образования «Национальный исследовательский университет ИТМО»)

Аннотация. В докладе демонстрируется вопросно-ответная система для общения на ИТ-темы на основе русскоязычной DialoGPT - RuDialoGPT. Описываются этапы подготовки данных, а также дообучение модели RuDialoGPT.

Введение. В последнее время в области обработки естественного языка получило распространение GPT-3 - третье поколение алгоритма в данной области и одна из самых крупных и продвинутых языковых моделей на данный момент. Недавно ПАО Сбербанк представили русскоязычную версию данной модели ruGPT-3.

И хотя данные модели показывают высокие результаты в генерации осмысленного текста, было обнаружено, что они плохо подходят для вопросно-ответных систем. С этой целью корпорация Microsoft представил дообученную модель GPT-2 для диалогов - DialoGPT. Позже, вдохновившись модель DialoGPT, компания ICL Services представила русскоязычную модель DialoGPT - RuDialoGPT.

Данная модель показала хорошие результаты в общении с людьми и продемонстрировала умение следить за ходом диалогом на общие темы, но на специализированные темы, например ИТ, модель не всегда выдавала релевантные ответы. Поэтому, в данной работе предлагается способ для повышения качества ответов на диалоги, связанные с ИТ-тематикой.

Основная часть. В данном исследовании мы дообучили модель RuDialoGPT на основе собранных данных из открытых источников, чтобы повысить качество ответов на ИТ-тематике.

В связи с отсутствием готовых наборов данных, первым этапом стал сбор данных из открытых источников: Хабр Q&A, Telegram ИТ чаты. Оба источника содержат вопросы, ответы, а также обсуждения ИТ-тем. Сбор данных начинался с исходного вопроса, например: «Какой язык программирования стоит выучить?», после чего шла цепочка из 5 ответов на данный вопрос.

Далее данные были разделены на 2 части: тренировочная и тестовая. Процесс дообучения был запущен RuDialoGPT на тренировочной части. После этого, дообученная модель была проверена на тестовой выборке, а также проведены небольшие диалоговые сессии с моделью для человеческой оценки способности общения полученной модели на ИТ-темы.

Выводы. Полученная модель показала некоторые знания IT-темы, но она ещё далека от совершенства.

Для получения большего качества ответов нужен большой подготовленный набор данных. Возможным вариантом видится использования транскрипта IT сериалов и фильмов, так как они в явном виде содержат обсуждения на IT-темы.

Также следует добавить ранжировку сгенерированных ответов, чтобы добавить увеличение способности модели общаться с пользователем на связанные с IT темы.

Кроме того, в дальнейшем при обучении можно добавлять новые тематики для специализированных диалогов, например, финансовые технологии, геймдев и др. Это предоставит возможность управления тематикой генерируемых ответов в целях повышения их персонализации.

Самигулин Т. Р. (автор)

Подпись

Сафонова А.О. (автор)

Подпись

Хлюпина Ю.М. (автор)

Подпись

Демин О.Д. (автор)

Подпись

Басов О.О. (научный руководитель)

Подпись