

Распознавание интенгов с помощью нейросетей

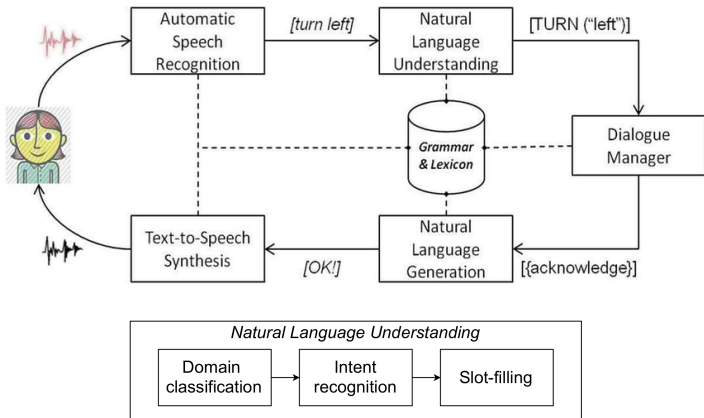
Баймурзина Диляра

Московский физико-технический институт
Факультет управления и прикладной математики

dilyara.rimovna@gmail.com

Апрель 2018

Введение



Примеры распознавания интенгов:



Постановка задачи

Данные

Набор данных SNIPS¹ содержит:

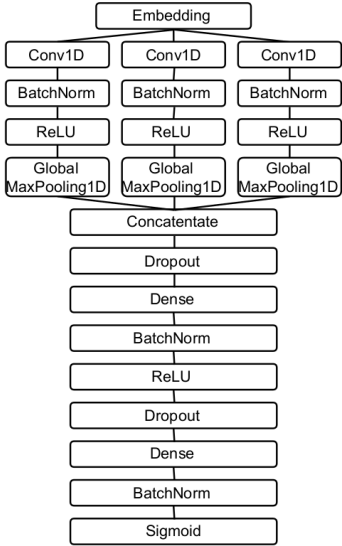
- семь интенгов: AddToPlaylist, BookRestaurant, GetWeather, PlayMusic, RateBook, SearchCreativeWork, SearchScreeningEvent,
- 2.4 тысячи примеров каждого класса,
- разметку именованных сущностей (слотов).

Задача


Классификация запросов по заданным классам (интенгам).

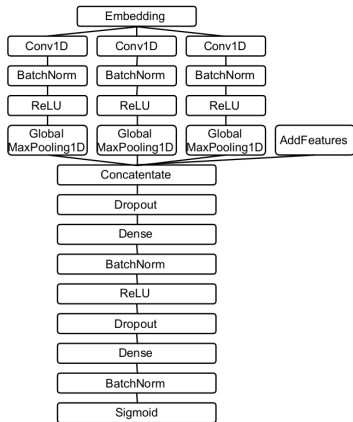
¹<https://github.com/snipsco/nlu-benchmark/tree/master/>

Базовые модели



Embedding – векторное представление каждого слова запроса.





Дополнительные признаки AddFeatures:

- векторные представления запроса InferSent размерностью 4096,
- именованные сущности (ground-truth и полученные моделью BiLSTM-CRF [F1=0.95]) – one-hot разметка наличия именованной сущности в запросе размерностью 39.

Эксперимент

- Метрика – F-мера.
- 3 итерации разбиения на тренировочный и тестовый наборы в соотношении 4 к 1 с одинаковым процентом вхождения каждого класса.
- Максимальная длина запроса – 25 слов.
- Векторные представления размерности 100 получены с помощью fastText², обученной на комментариях с сайта Reddit³.
- Подбор параметров с помощью случайного поиска.
- Усреднение полученных значений метрики по результатам 16 запусков.

²<https://github.com/facebookresearch/fastText>

³<http://files.pushshift.io/reddit/comments/>

Результаты

Модель	Среднее значение F-меры для каждого интента						
	AddTo Playlist	Book Restaurant	Get Weather	Play Music	Rate Book	Search Creative Work	Search Screening Event
api.ai	0.9931	0.9949	0.9935	0.9811	0.9992	0.9659	0.9801
ibm.watson	0.9931	0.9950	0.9950	0.9822	0.9996	0.9643	0.9750
microsoft.luis	0.9943	0.9935	0.9925	0.9815	0.9988	0.9620	0.9749
wit.ai	0.9877	0.9913	0.9921	0.9766	0.9977	0.9458	0.9673
snips.ai	0.9873	0.9921	0.9939	0.9729	0.9985	0.9455	0.9613
recast.ai	0.9894	0.9943	0.9910	0.9660	0.9981	0.9424	0.9539
amazon.lex	0.9930	0.9862	0.9825	0.9709	0.9981	0.9427	0.9581
CNN	0.9956	0.9973	0.9968	0.9871	0.9998	0.9752	0.9854
CNN & NER	0.9964	0.9958	0.9920	0.9865	0.9970	0.9652	0.9768
CNN & InferSent	0.9956	0.9971	0.9969	0.9879	0.9994	0.9753	0.9845
BiLSTM	0.9612	0.9488	0.9514	0.9351	0.9688	0.8769	0.8979
CNN& NER-truth	0.9996	0.9987	0.9986	0.9997	1.0000	1.0000	1.0000

Выводы

- Свёрточные модели превосходят рекуррентные по точности для набора данных SNIPS.
- Добавление векторного представления запроса в целом (InferSent) не добавляет значимых улучшений.
- Добавление ground-truth именованных сущностей значительно повышает точность классификации.
- Добавление предсказаний именованных сущностей будет значительно улучшать качество распознавания интенгов при достижении более высокой точности распознавания именованных сущностей.

Список литературы

- 1 Anh L. T., Arkhipov M. Y., Burtsev M. S. Application of a Hybrid Bi-LSTM-CRF model to the task of Russian Named Entity Recognition // arXiv preprint arXiv:1709.09686. 2017.
- 2 Bojanowski P. et al. Enriching word vectors with subword information // arXiv preprint arXiv:1607.04606. 2016.
- 3 Conneau A. et al. Supervised learning of universal sentence representations from natural language inference data // arXiv preprint arXiv:1705.02364. 2017.
- 4 Le H. T., Cerisara C., Denis A. Do Convolutional Networks need to be Deep for Text Classification? // arXiv preprint arXiv:1707.04108. 2017.