



Detekce polarity textu s využitím mezijazyčné transformace

Jakub Šmíd¹

1 Úvod

Detekce polarity textu je úloha zpracování přirozeného jazyka, jejímž cílem je klasifikace vstupního textu dle jeho polarity. Pro tuto úlohu jsou potřeba anotovaná data, kterých může být v některých jazycích nedostatek. Proto se hledají metody, které umožňují použití anotovaných dat z jednoho jazyka v jazyce druhém. Jednou z možností jsou mezijazyčné transformace.

Cílem této práce bylo vytvořit program pro detekci polarity českého textu a pomocí experimentů ověřit možnosti využití dat z jiného jazyka (konkrétně angličtiny) s použitím mezijazyčných transformací a zhodnotit jejich vliv na úspěšnost detekce polarity.

2 Lineární mezijazyčné transformace

Lineární mezijazyčné transformace transformují předtrénované jednojazyčné slovní vektory do společného prostoru pomocí lineárního zobrazení a dvojjazyčných slovníků, jak shrnul např. Ruder et al. (2019). Lineární zobrazení umožňuje transformaci mezi dvěma vektorovými prostory prostřednictvím afinních transformací (např. rotace, posun a zrcadlení). Tyto přístupy vychází z pozorování, která ukazují, že rozmístění vektorů slov zdrojového jazyka je po provedení vhodné lineární transformace geometricky velmi podobné rozmístění vektorů slov jejich překladů. Cílem je nalézt transformační matici \mathbf{W} , která umožní transformovat vektorový prostor zdrojového jazyka s do vektorového prostoru cílového jazyka t . Vynásobením vektoru \mathbf{x}^s slova v původním prostoru transformační maticí \mathbf{W} je získán příslušný vektor \mathbf{x}^t v prostoru cílovém (viz rovnice 1). V této práci byla pro získání matice \mathbf{W} použita metoda nejmenších čtverců (MSE), kterou navrhl Mikolov et al. (2013), a ortogonální metoda, kterou popsal Xing et al. (2015). Obě metody ponechávají vždy jeden prostor nezměněný a druhý na něj mapují.

$$\mathbf{x}^t = \mathbf{W}\mathbf{x}^s \quad (1)$$

3 Experimenty a výsledky

Experimenty byly provedeny s použitím tří datových sad obsahujících filmové recenze – jedné české (ČSFD) a dvou anglických (SST a IMDb). Pro detekci polarity textu byly navrženy a implementovány dva modely neuronových sítí – konvoluční neuronová síť (CNN) a rekurentní neuronová síť (konkrétně obousměrná LSTM) – v kombinaci s natrénovanými slovními vektory *fastText*. Modely byly nejprve natrénovány a vyhodnoceny pouze na českých datech. Dále byly s využitím lineárních mezijazyčných transformací natrénovány na anglických datech a vyhodnoceny na češtině. Transformace proběhla z angličtiny do češtiny i naopak. Pro tvorbu transformační matice bylo vybráno 5 000 nebo 20 000 slov. Tabulka 1 ukazuje dosažené výsledky porovnané s jednojazyčnými experimenty.

¹ student bakalářského studijního programu Inženýrská informatika, obor Informatika, e-mail: biba10@students.zcu.cz

BiLSTM							
Počet tříd	CS	Dataset	Metoda	5 000		20 000	
				EN→CS	CS→EN	EN→CS	CS→EN
3	84,92±0,30	SST	MSE	46,06±0,75	48,91 ±2,59	45,86±0,92	47,53 ±3,72
			ortog.	47,25 ±3,10	48,14 ±1,63	49,15 ±2,10	49,71 ±3,03
		SST (fráze)	MSE	46,83±0,60	46,52 ±2,89	46,42±0,98	47,59 ±4,29
			ortog.	49,53 ±2,91	48,09 ±1,39	50,09 ±2,35	49,10 ±2,27
2	94,29±0,29	SST	MSE	82,82±0,71	84,91±0,71	83,37±2,49	82,54±2,49
			ortog.	79,61±2,69	82,41±2,09	81,05±1,88	82,47±2,49
		SST (fráze)	MSE	82,60±2,69	82,57±2,71	83,33±0,93	84,32±0,93
			ortog.	82,42±1,94	83,57±1,25	82,41±2,46	83,14±2,64
		IMDb	MSE	86,20 ±1,84	87,48 ±1,84	85,17±0,89	87,98 ±0,89
			ortog.	86,89 ±0,64	88,25 ±1,14	87,59 ±0,48	88,57 ±0,36

CNN							
Počet tříd	CS	Dataset	Metoda	5 000		20 000	
				EN→CS	CS→EN	EN→CS	CS→EN
3	83,18±0,14	SST	MSE	46,83±0,09	58,87 ±1,10	47,12±0,10	57,60 ±1,61
			ortog.	50,32 ±1,79	50,58±1,10	51,53 ±1,42	50,38±1,08
		SST (fráze)	MSE	46,81±0,10	57,71 ±1,21	47,18±0,09	57,63 ±0,92
			ortog.	50,07 ±1,27	51,50±0,86	51,46 ±0,63	50,42±0,75
2	93,86±0,12	SST	MSE	86,46±0,19	86,66±0,46	86,99±0,12	86,19±0,65
			ortog.	84,25±1,44	85,46±0,80	86,18±0,30	86,82±0,31
		SST (fráze)	MSE	86,31±0,37	86,47±0,22	86,86±0,17	86,83±0,40
			ortog.	84,80±1,17	86,36±0,40	85,93±0,44	86,41±0,40
		IMDb	MSE	88,05±0,20	86,64±1,35	88,36 ±0,10	88,11 ±1,72
			ortog.	87,18±0,34	87,81±0,37	88,16 ±0,17	88,99 ±0,34

Tabulka 1: Makro F-míra v procentech pro modely BiLSTM a CNN se slovními vektory *fast-Text* (natrénované na datech z IMDb a SST datasetů pro angličtinu, z ČSFD datasetu pro češtinu) při použití mezijazyčných transformací s transformační maticí získanou z 5 000 či 20 000 slov metodou nejmenších čtverců nebo ortogonálně a transformací z angličtiny do češtiny (EN→CS) i naopak (CS→EN). Trénováno jen na datech anglických (sloupec **Dataset**) a vyhodnoceno na českých testovacích. Sloupec **CS** slouží k porovnání s jednojazyčnými výsledky. Pro každý model, počet tříd a směr transformace je nejlepší výsledek zvýrazněn **tučně**, při překrývání intervalu spolehlivosti je navíc **podtržený**.

4 Závěr

Porovnání jednojazyčných experimentů s experimenty s využitím mezijazyčné transformace ukázalo, že s dostatečným množstvím výhradně anglických dat lze dosáhnout velmi dobrých výsledků, které jsou jen o 5 až 6 % horší v porovnání s modely trénovanými jen na českých datech.

Literatura

- Mikolov, T., Le, Q. V., a Sutskever, I. (2013) Exploiting Similarities among Languages for Machine Translation. *CoRR*. Dostupné z: <http://arxiv.org/abs/1309.4168>.
- Ruder, S., Vulić, I., a Søgaard, A. (2019) A survey of cross-lingual word embedding models. *Journal of Artificial Intelligence Research*, s. 569–631.
- Xing, C. et al. (2015) Normalized word embedding and orthogonal transform for bilingual word translation. In *Proceedings of the 2015 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*, s. 1006-1011.