



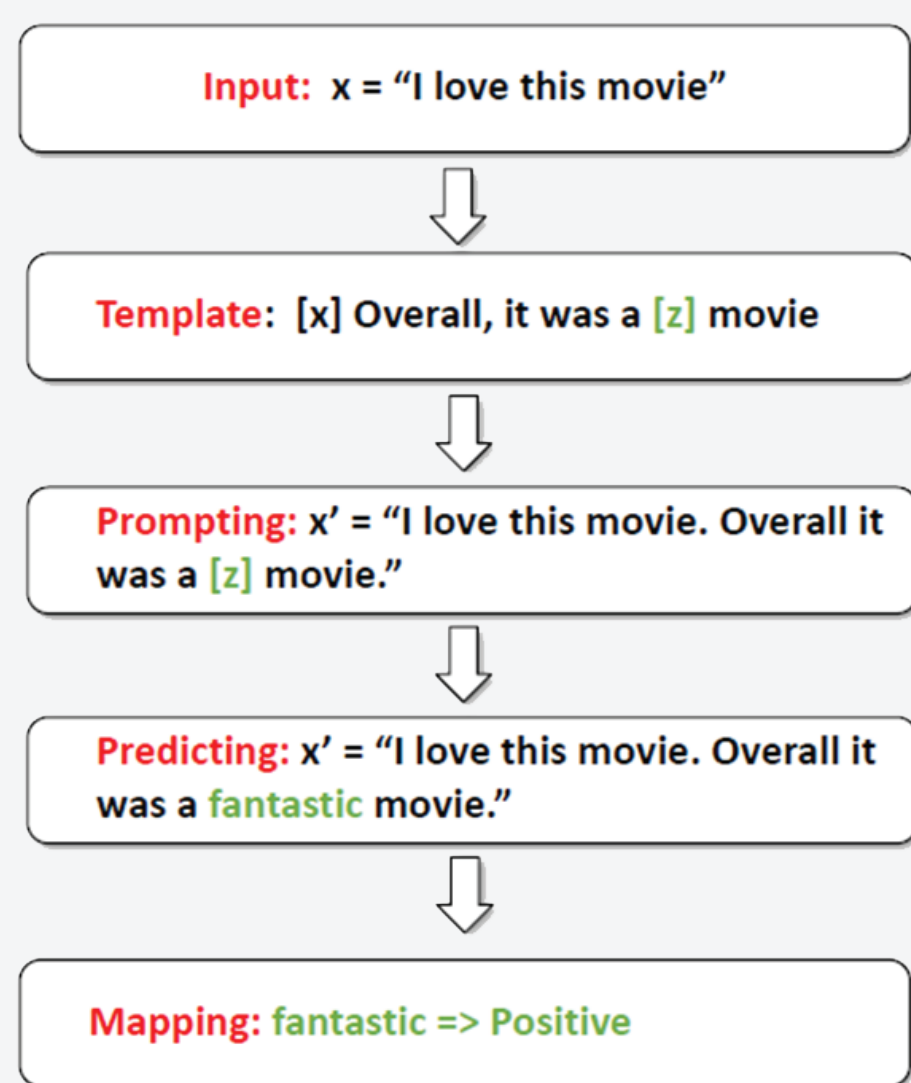

در پردازش زبان طبیعی، امروزه داده های برجسب دار اهمیت بالایی دارند و گاهی تعداد در دسترس کم است و گاهی نیز نایاب هستند. بسیاری از کارها وجود دارند که به سختی میتوان داده های مورد نیاز برچسب دار را برای آن تهیه کرد. برای مثال در ترجمه ماشینی، باید داده های زیادی در زبان مقصد تهیه کنیم تا عملکرد کار در حد قابل قبولی باشد. ممکن است در زبان مقصد نتوانیم داده های مفیدی را جمع آوری کنیم. از این رو نیاز است که از یادگیری با داده های کم یا بدون داده استفاده کنیم. اخیراً متدی با عنوان پیام‌واره نویسی (Prompting) معرفی شده که در این کار، ورودی های متن با استفاده از یک قالب معین، به متن با ساختار جدید تبدیل میشوند که یک جای خالی دارد. در نهایت مدل آموزش دیده، بهترین کلمه را جایگزین جای خالی می کند. این کار، می تواند به ما در زمینه یادگیری با نمونه های کم و حتی بدون نمونه کمک کند. پیش تر با استفاده از مدل های زبانی بزرگی مثل GPT-2 و GPT-3، بدون داده برچسب دار و با استفاده از متد پیام‌واره، وظایفی مانند ترجمه را انجام می دادند. اما استفاده از این نوع مدل ها، به علت اینکه تعداد زیادی پارامتر دارند، نیازمند سخت افزارهای بزرگی هستند. در ادامه، PET و IPET معرفی شدند که با استفاده از پیام‌واره نویسی و مدل های کوچکتری مثل Bert و Roberta یادگیری با داده های کم و یا بدون استفاده از داده ها را انجام داده اند. به طور مثال در دیتاست Yahoo که یک دیتاست طبقه بندی متن است، با استفاده از IPET و Roberta و ده دیتای برچسب دار، به دقت ۷۰ درصدی رسیده است. در این پژوهش میخواهیم با استفاده از پیام‌واره نویسی، به ساختاری دست پیدا کنیم تا بتوان با دیتای کم، بسیاری از وظایف NLP را با دقت بالا و قابل قبولی انجام دهیم.

واژه های کلیدی: پردازش زبان طبیعی، یادگیری با نمونه های محدود، پیام‌واره، مدل زبانی، Prompting

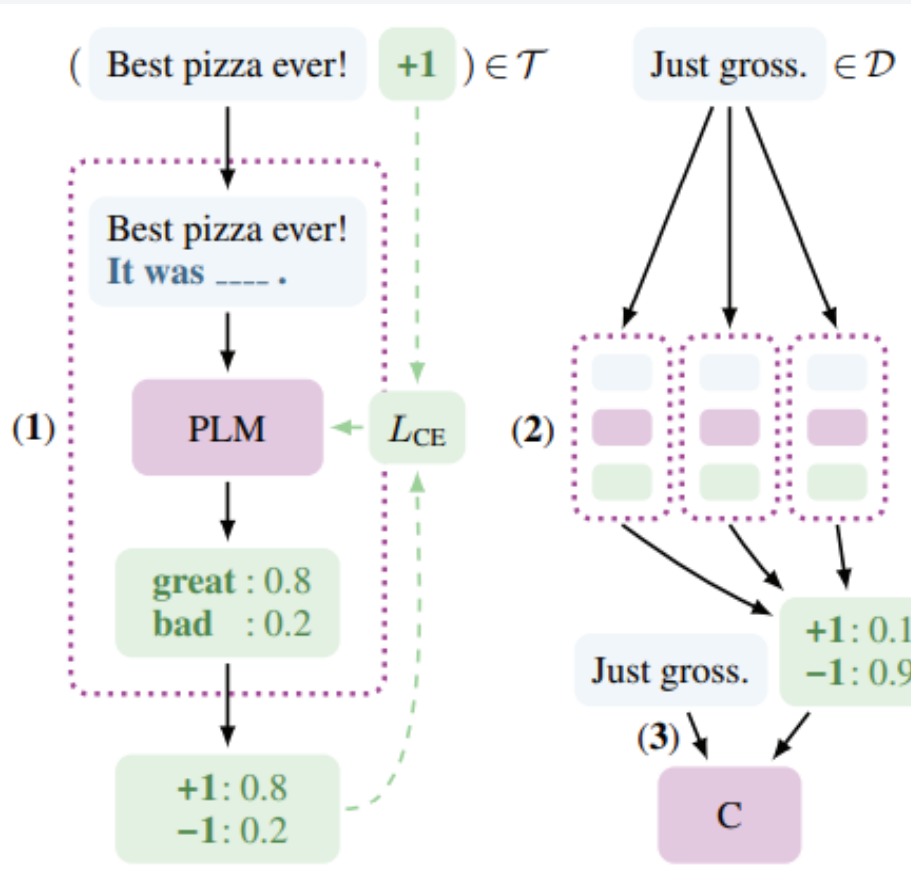
مواد و روش ها



مقدمه



نمودار ۱: نحوه کار Prompting




تصویر ۲: نحوه کار PET

همانطور که گفته شد، هسته پژوهش، متد Prompting است. مطابق تصویر مقابل، یک قالب طراحی می شود و بر اساس آن، ساختار ورودی متن به یک ساختار مشخص تبدیل میشود که جای خالی در آن وجود دارد. با استفاده از مدل های از پیش آموزش دیده، پیش بینی و برچسب گذاری انجام می شود. نکته مهم کار این است که به داده های زیاد احتیاج نداریم و یا ممکن است نیازی به داده نباشد. از لحاظ انتخاب مدل زبانی پیش آموزش دیده، مهندسی ساخت قالب و مهندسی ساخت نگاشت ها میتوان تاثیر زیادی در خروجی نهایی داشت. این متد، کاربرد های متنوعی در وظایف مختلف NLP دارد و بر اساس هر وظیفه ای که میخواهیم انجام دهیم باید قالب و تابع نگاشت مختص آن را بسازیم. یکی از ایده ها این است که PET را گسترش دهیم. مطابق تصویر مقابل، در PET، با استفاده از داده های برچسب دار و تغییر آنها بر اساس قالب ساخته شده، تعدادی مدل پیش آموزش دیده به صورت مجموعه ای، تنظیم دقیق می شوند و در نهایت مدل ها می توانند داده های بدون برچسب را با دقت مناسبی به داده برچسب دار تبدیل کنند. داده های تولیدی به مدل یادگیری ماشین تحویل داده می شوند.

در سال های اخیر مدل های پیش آموزش دیده زیادی برای انجام وظیفه های مختلفی مانند ترجمه و تحلیل احساسات ساخته شده اند. هر کدام از مدل ها ویژگی های مختص خود را دارد. کارایی مدل ها به مرور بهتر شده و بزرگتر شده اند. اخیراً Transformer ها معرفی شدند که از مفهوم Attention استفاده می کنند.

مدل منجر به پیشرفت قابل توجهی در بسیاری از وظایف چالش برانگیز NLP شده است. مدل های پیش آموزش دیده با تعداد پارامتر های زیاد و بسیار قوی مانند Bert و GPT معرفی شدند. اما هنوز محدودیت هایی وجود دارد، و آن هم این است که هنوز نیاز به مجموعه داده های خاص وظیفه و تنظیم دقیق آن وجود دارد. برای آن که به عملکرد مطلوبی در وظیفه برسیم نیاز است که داده های برچسب دار زیادی در همان وظیفه را آماده سازی کنیم و مدل را تنظیم دقیق کنیم. در واقع سیستم های کنونی بیشتر به عنوان متخصصان محدود شناخته می شوند تا کلی گرایان شایسته. ما میخواهیم بدون نیاز به داده های زیاد و همچنین مدل های بزرگی مانند GPT-3، مدلی واحد طراحی کنیم که بتواند با دیتای کم و برای چند وظیفه مختلف از NLP به دقت مطلوبی برسد.



تصویر ۱: تحول در پردازش زبان طبیعی با معرفی Prompting

امروزه برای حذف محدودیت ها، پژوهش های فراوانی انجام شده است. یکی از رویکردهای جدید که به این کار کمک میکند، پیام‌واره است. این متد به سه مرحله (۱) پیش آموزش (۲) پیام‌واره (۳) پیش بینی تقسیم میشود. در این کار ساختار ورودی متن با استفاده از تابع پیام‌واره به یک ساختار مشخص تبدیل شده و با استفاده از مدل های از پیش آموزش دیده، پیش بینی و برچسب گذاری انجام می شود.

نتایج



Num	Method	Yelp	AG's
T = 10	supervised	21.1 ± 1.6	25.0 ± 0.1
	PET	52.9 ± 0.1	87.5 ± 0.0
	IPET	57.6 ± 0.0	89.3 ± 0.1
T = 50	supervised	44.8 ± 2.7	82.1 ± 2.5
	PET	60.0 ± 0.1	86.3 ± 0.0
	IPET	60.7 ± 0.1	88.4 ± 0.1

جدول ۲: مروری بر نتایج PET

مقاله PET به تنهایی به روی بسیاری از دیتاست ها آزمایشات مختلفی انجام داده است. به طور نمونه، دقت دو دیتاست Yelp و AG news در جدول مقابل مقایسه شده است. |T| تعداد دیتای مورد استفاده است. دقت مدل PET و IPET با رویکرد قدیمی (supervised learning) مقایسه شده است.

منابع



1. Alec Radford et al. Language Models are Unsupervised Multitask Learners. *OpenAI blog*
2. Brown et al. Language Models are Few-Shot Learners. *NeurIPS 2020*, arXiv:2005.14165v4
3. Timo Schick and Hinrich Schütze. Exploiting Cloze Questions for Few Shot Text Classification and Natural Language Inference. *EACL2021*, arXiv:2001.07676v3
4. Gao et al. Making Pre-trained Language Models Better Few-shot Learners. *ACL 2021*, arXiv:2012.15723
5. Timo schick et al. Automatically Identifying Words That Can Serve as Labels for Few-Shot Text Classification. *COLING 2020*, arXiv:2010.13641v1
6. Pengfei Liu et al. Pre-train, Prompt, and Predict: A Systematic Survey of Prompting Methods in Natural Language Processing. arXiv:2107.13586v1

#	سال	عنوان مقاله	خلاصه کار	خلاصه نتایج
۱	۲۰۱۹	Language models are unsupervised multitask learners	معرفی GPT-2 با ۱/۵ میلیارد پارامتر و انجام یادگیری بدون نمونه	کسب نتایج نسبتاً خوب مثلاً ۶۰ درصد دقت در دیتاست LAMBADA
۲	۲۰۲۰	Exploiting Cloze Questions for Few Shot Text Classification and NLI	معرفی PET و IPET با استفاده از Roberta و انجام یادگیری با نمونه های محدود	کسب نتایج خوب مثلاً ۷۰ درصد دقت در دیتاست Yahoo با ۱۰ دیتا اولیه
۳	۲۰۲۰	Language Models are Few-Shot Learners	معرفی GPT-3 با ۱۷۵ میلیارد پارامتر و انجام یادگیری بدون نمونه با استفاده از Prompting	در بسیاری از وظایف و دیتاست ها به دقت های خوبی رسیده است.
۴	۲۰۲۰	Automatically Identifying Words That Can Serve as Labels for Few-Shot Text Classification	افزافه کردن تعریف اتوماتیک نگاشت ها در PET و معرفی آن با عنوان PETAL	در وظایف مختلف دقت های خوبی کسب کرده است. اما نیاز به بهبود دارد.
۵	۲۰۲۱	Making Pre-trained Language Models Better Few-shot Learners	تنظیم دقیق مدل های زبانی کوچک تر با نمونه های محدود و ساخت خودکار قالب ها	به طور متوسط ۱۱ درصد بهبود دقت نسبت به GPT-3

جدول ۱: مروری بر کارهای انجام شده به صورت خلاصه

برخی از کارهای انجام شده ضعیف هایی دارند. بزرگ بودن مدل زبانی استفاده شده، نیاز به ساخت دستی قالب ها و نگاشت ها و پایین بودن دقت ها از ضعف های عمده کارهای پیشین بوده است. در این پژوهش، هدف بهبود و حل مشکلات این حوزه است.