



دانشکده مهندسی کامپیوتر

توضیح نویسی تصویر با استفاده از ساز و کار توجه در شبکه‌ی عصبی

پروژه برای دریافت درجه کارشناسی در رشته مهندسی کامپیوتر
گرایش هوش مصنوعی و رباتیک

کیارش آقاگیری

استاد راهنما

دکتر ناصر مزینی

تیر ۱۳۹۸



تأییدیه‌ی هیأت داوران جلسه‌ی دفاع از پروژه

نام دانشکده: دانشکده مهندسی کامپیوتر

نام دانشجو: کیارش آقاکثیری

عنوان پروژه: توضیح‌نویسی تصویر با استفاده از ساز و کار توجه در شبکه‌ی عصبی

تاریخ دفاع: تیر ۱۳۹۸

رشته: مهندسی کامپیوتر

گرایش: هوش مصنوعی و رباتیک

ب

ردیف	سمت	نام و نام خانوادگی	مرتبه دانشگاهی	دانشگاه یا مؤسسه	امضا
۱	استاد راهنما	دکتر ناصر مزینی	دانشیار	دانشگاه علم و صنعت ایران	

تأییدیه‌ی صحت و اصالت نتایج

باسمه تعالی

اینجانب کیارش آفاکثیری به شماره دانشجویی ۹۴۵۲۳۰۴۵ دانشجوی رشته مهندسی کامپیوتر مقطع تحصیلی کارشناسی تأیید می‌نمایم که کلیه‌ی نتایج این پروژه حاصل کار اینجانب و بدون هرگونه دخل و تصرف است و موارد نسخه‌برداری‌شده از آثار دیگران را با ذکر کامل مشخصات منبع ذکر کرده‌ام. در صورت اثبات خلاف مندرجات فوق، به تشخیص دانشگاه مطابق با ضوابط و مقررات حاکم (قانون حمایت از حقوق مؤلفان و مصنفان و قانون ترجمه و تکثیر کتب و نشریات و آثار صوتی، ضوابط و مقررات آموزشی، پژوهشی و انضباطی ...) با اینجانب رفتار خواهد شد و حق هرگونه اعتراض درخصوص احقاق حقوق مکتسب و تشخیص و تعیین تخلف و مجازات را از خویش سلب می‌نمایم. در ضمن، مسؤولیت هرگونه پاسخگویی به اشخاص اعم از حقیقی و حقوقی و مراجع ذی‌صلاح (اعم از اداری و قضایی) به عهده‌ی اینجانب خواهد بود و دانشگاه هیچ‌گونه مسؤولیتی در این خصوص نخواهد داشت.

نام و نام خانوادگی: کیارش آفاکثیری

تاریخ و امضا:

مجوز بهره‌برداری از پایان‌نامه

بهره‌برداری از این پایان‌نامه در چهارچوب مقررات کتابخانه و با توجه به محدودیتی که توسط استاد راهنما به شرح زیر تعیین می‌شود، بلامانع است:

- ☐ بهره‌برداری از این پایان‌نامه برای همگان بلامانع است.
- ☐ بهره‌برداری از این پایان‌نامه با اخذ مجوز از استاد راهنما، بلامانع است.
- ☐ بهره‌برداری از این پایان‌نامه تا تاریخ ممنوع است.

استاد راهنما: دکتر ناصر مزینی

تاریخ:

امضا:

چکیده

توصیف و توضیح یک صحنه یا تولید عنوان برای یک تصویر کاری نسبتاً آسان برای ما انسان‌ها است. با این حال، هنگامی که ما در حوزه هوش مصنوعی صحبت می‌کنیم، تولید چنین عناوینی به صورت خودکار مسأله‌ای پیچیده است. در این پایان نامه، یک مدل شبکه عصبی مبنی بر یادگیری عمیق ارائه شده است که می‌تواند یک عنوان (توضیح) برای تصویر داده شده به شبکه تولید کند. این مدل از سه بخش اصلی تشکیل شده است: بخش رمزگذاری، بخش رمزگشایی و قسمت مربوط به استفاده از ساز و کار "توجه" در شبکه‌ی عصبی. به منظور تولید عنوان هم به زبان فارسی و هم به زبان انگلیسی، این مدل به طور جداگانه، یک بار بر روی نسخه‌ی اصلی مجموعه دادگان COCO و یک بار هم بر روی نسخه‌ی فارسی‌شده‌ی این مجموعه‌ی داده آموزش داده شده است.

واژگان کلیدی: توضیح‌نویسی تصویر، عنوان‌نویسی تصویر، شبکه عصبی، توجه، یادگیری عمیق

فهرست مطالب

ح	فهرست تصاویر
د	فهرست جداول
۱	فصل ۱: مقدمه
۱	۱-۱ توضیح نویسی تصویر
۲	۱-۲ توجه در شبکه‌های عصبی
۳	فصل ۲: مجموعه داده‌ی COCO
۳	۲-۱ محتویات مجموعه داده
۴	فصل ۳: شبکه‌ی عصبی
۴	۳-۱ شبکه‌ی رمزگذار
۵	۳-۲ شبکه‌ی رمزگشا
۶	۳-۳ ساز و کار توجه
۸	فصل ۴: کارهای ما
۸	۴-۱ ترجمه به زبان فارسی
۹	۴-۲ پیاده‌سازی مدل
۱۱	فصل ۵: نتایج
۱۲	۵-۱ نتایج فارسی
۱۲	۵-۱-۱ نتایج خوب

۱۵ ۵-۱-۲ نتایج بد

۱۸ ۵-۲ نتایج انگلیسی

۱۸ ۵-۲-۱ نتایج خوب

۲۰ ۵-۲-۲ نتایج بد

۲۴ مراجع

۲۵ واژه‌نامه فارسی به انگلیسی

۲۶ واژه‌نامه انگلیسی به فارسی

فهرست تصاویر

- ۳-۱ معماری شبکه‌ی VGGNet ۵
- ۳-۲ معماری کلی شبکه‌ی عصبی استفاده شده ۶
- ۵-۱ گروهی از مردم در ساحل با بادبادک بازی می‌کنند. ۱۲
- ۵-۲ گروهی از فیل‌ها که در مزرعه ایستاده بودند. ۱۳
- ۵-۳ یه دختر کوچولو که یه تیکه پیتزا می‌خوره. ۱۳
- ۵-۴ یک بازیکن تنیس روی زمین تنیس بازی می‌کند. ۱۳
- ۵-۵ یک اسکی‌باز در حال اسکی روی یک شیب پوشیده از برف است. ۱۴
- ۵-۶ یک چراغ راهنمایی در کنار یک ساختمان بزرگ ۱۴
- ۵-۷ یک هواپیما در آسمان آبی پرواز می‌کند. ۱۵
- ۵-۸ مردی که در آشپزخانه ایستاده بود. ۱۵
- ۵-۹ یک میز پر از غذا و یک لیوان شراب. ۱۶
- ۵-۱۰ یک حمام با یک یخچال سفید و یک ظرف‌شویی ۱۶
- ۵-۱۱ مردی که روی کاناپه نشسته بود. ۱۷
- ۵-۱۲ مردی که سوار بر اسب بود. ۱۷
- ۵-۱۳ a traffic light on the side of a street. ۱۸
- ۵-۱۴ a group of elephants standing next to each other. ۱۸
- ۵-۱۵ a train traveling down the tracks near a train station. ۱۹
- ۵-۱۶ a little girl eating a hot dog. ۱۹
- ۵-۱۷ a man swinging a tennis racket on a tennis court. ۱۹

- ۲۰ a vase filled with flowers on a table. ۵-۱۸
- ۲۰ a group of people seating on a bench. ۵-۱۹
- ۲۱ a cat sitting on top of a wooden floor. ۵-۲۰
- ۲۱ a woman holding a hot dog in front of a table. ۵-۲۱
- ۲۲ a group of elephants walking across a sandy beach. ۵-۲۲
- ۲۲ a group of people flying kites in the sky. ۵-۲۳
- ۲۳ a close up of a bowl of food. ۵-۲۴

فهرست جداول

- ۴-۱ ارزیابی مدل ۱۰
- ۴-۲ مقایسه‌ی نتایج مدل انگلیسی و مدل فارسی ۱۰

فصل ۱

مقدمه

۱-۱ توضیح نویسی تصویر

یکی از اهداف اصلی در حوزه‌ی بینایی ماشین، درک یک صحنه یا تصویر است. منظور از درک صحنه، توانایی تحلیل یک تصویر ورودی و استخراج داده‌های مورد نیاز از آن است، درست همان‌طور که انسان عمل می‌کند. سیستم‌های درک تصویر از ۳ سطح تشکیل می‌شوند: سطح پایین شامل درک لبه‌ها، بافت عناصر و مناطق در تصویر؛ سطح متوسط شامل درک مرزها، سطوح و حجم در تصویر؛ و سطح بالا شامل درک اشیاء، اعمال و اتفاقات تصویر است. [۱]

توانایی تولید توضیح برای یک تصویر به صورت خودکار، یکی از وظیفه‌های بسیار مرتبط با درک صحنه است. در این نوع وظیفه، دو عمل اصلی می‌بایست انجام شود: درک درست و کامل تصویر، و توضیح مناسب آنچه که از تصویر درک شده است.

در گام نخست، می‌بایست سیستم آنقدر قدرتمند باشد تا بتواند با وجود تمام چالش‌های موجود در حوزه‌ی بینایی ماشین، تصویر ورودی را تحلیل کند. این تحلیل باید به گونه‌ای باشد که اشیاء موجود در تصویر، هم درست و هم کامل، تشخیص داده شوند. این گام، همان سطح بالا در درک صحنه است.

در گام بعد، سیستم باید این توانایی را داشته باشد تا هر آنچه را که در گام نخست از تصویر درک کرده به شیوه‌ای صحیح بیان کند. در حوزه‌ی پردازش زبان و گفتار، به این امر، تولید زبان طبیعی گفته می‌شود. بیان

اشیاء موجود در تصویر و روابط میان آن‌ها، همگی با رعایت قوائد دستوری زبان طبیعی، وظیفه‌ی سیستم در این گام است. [۵]

۱-۲ توجه در شبکه‌های عصبی

در سال‌های اخیر، به لطف پیشرفت‌های صورت گرفته در زمینه‌ی یادگیری ماشین و تولید مجموعه داده‌های بسیار وسیع، علاقه به حل مسئله‌ی توضیح نویسی تصویر بیش از پیش شده است. این موج جدید از تحقیقات مسبب تولید روش‌های نو و در نتیجه بهبود چشم‌گیر نتایج بدست آمده در این مسئله نیز شده است. یکی از مهم‌ترین روش‌های ابداع شده در زمینه‌ی یادگیری ماشین، ساز و کار توجه است. این ساز و کار از روی طبیعت و نحوه‌ی پردازش محیط توسط انسان الهام گرفته شده است. در این روش، به جای در نظر گرفتن تمام عکس و فشرده‌سازی آن به یک بردار کوچک برای نمایش ویژگی‌های تصویر، به هر قسمت از تصویر به صورت جداگانه و مناسب با زمان توجه می‌شود. این روش کمک می‌کند تا به جزئیات تصویر بیشتر پرداخته شود؛ که همین امر باعث افزایش دقت و کارایی سیستم می‌شود. [۲]

فصل ۲

مجموعه داده‌ی COCO

در این فصل به معرفی مجموعه داده‌ی مورد استفاده در این مسئله می‌پردازیم. همچنین به دلیل آنکه یکی از اهداف این پروژه تولید توضیح برای تصویر به زبان فارسی بوده است، به بررسی چگونگی ترجمه‌ی این مجموعه داده به زبان فارسی نیز می‌پردازیم.

۲-۱ محتویات مجموعه داده

COCO (Common Objects in Context)^۱ یک مجموعه داده‌ی بزرگ مقیاس است که برای مسائل تشخیص شیء، قطعه‌بندی و توضیح نویسی تصویر استفاده می‌شود. این مجموعه داده از ۳۳۰ هزار تصویر در ۸۰ دسته‌بندی متفاوت تشکیل شده است. همچنین در این مجموعه داده برای هر تصویر ۵ توضیح نوشته شده است.

^۱سایت مجموعه داده‌ی COCO

فصل ۳

شبکه‌ی عصبی


اگر بخواهیم از سطح انتزاع بالا به مدل شبکه عصبی استفاده شده نگاه کنیم، این مدل در واقع از سه بخش کلی تشکیل شده است: شبکه‌ی رمزگذار، شبکه‌ی رمزگشا و ساز و کار توجه؛ که در این قسمت هر شبکه به تفصیل توضیح داده می‌شود و در آخر نیز نحوه‌ی استفاده از ساز و کار توجه مورد بررسی قرار می‌گیرد.

۳-۱ شبکه‌ی رمزگذار

ورودی این قسمت از مدل تصاویر هستند و خروجی آن ویژگی‌هایی هستند که از تصاویر استخراج شده‌اند. در واقع هدف اصلی این بخش، جدا کردن ویژگی‌های مناسب از تصاویر به منظور استفاده از آن‌ها در شبکه‌ی رمزگشا است. [۶] برای پیاده‌سازی این بخش از یک مدل از پیش آموزش داده شده به نام VggNet استفاده می‌کنیم که ساختار آن به این شکل است:

در ابتدا دو لایه‌ی پیچشی وجود دارد که هر لایه از ۶۴ فیلتر ۳ در ۳ تشکیل شده است. خروجی این ۲ لایه وارد یک لایه‌ی Pooling می‌شود که از نوع ماکزیمم‌گیر است. سپس دوباره از دو لایه‌ی پیچشی و یک فیلتر Pooling ماکزیمم‌گیر استفاده می‌شود با این تفاوت که این بار هر لایه‌ی پیچشی از ۶۴ فیلتر ۳ در ۳ تشکیل شده است.

این بار از سه لایه‌ی پیچشی متشکل از ۲۵۶ فیلتر ۳ در ۳ و یک فیلتر تجمع‌گیر دیگر استفاده می‌کنیم. در



شکل ۱-۳: معماری شبکه‌ی VGGNet

انتها از شش لایه‌ی پیچشی استفاده می‌کنیم که سه لایه‌ی اول با یک لایه‌ی تجمع‌گیر از سه لایه‌ی دیگر جدا شده‌اند و هر شش لایه از ۵۱۲ فیلتر ۳ در ۳ تشکیل شده است. تمام فیلترهای Pooling دارای پنجره‌های ۲ در ۲ هستند.


در ضمن به دلیل آنکه از شبکه‌ی VGGNet تنها برای استخراج ویژگی استفاده شده‌است، سه لایه‌ی آخر این مدل در این جا حذف شده‌اند.

۲-۳ شبکه‌ی رمزگشا

در این بخش با استفاده از ویژگی‌های استخراج شده از شبکه‌ی رمزگذار، یک توضیح برای تصویر ورودی تولید می‌شود. در این شبکه، به دلیل متغیر بودن طول توضیح‌ها و همچنین اهمیت ترتیب در کلمات از مدل‌های بازگشتی استفاده می‌کنیم. [۴]

بنابراین، ورودی این بخش از مدل، خروجی قسمت قبل می‌باشد؛ که در واقع همان ویژگی‌های استخراج شده از تصاویر هستند. خروجی بخش رمزگشا، جملات (توضیحات) تولید شده برای هر تصویر هستند. معماری این بخش، یک شبکه‌ی بازگشتی است که در واقع تنها یک سلول LSTM است که طول بردار Em-bedding آن برابر با ۵۱۲ می‌باشد.

با استفاده از همین دو بخش، شبکه‌ی رمزگذار و شبکه‌ی رمزگشا، می‌توان یک مدل کامل برای انجام توضیح نویسی تصویر به کمک شبکه‌ی عصبی ارائه کرد. اما در سال‌های اخیر، پیشرفت‌های چشمگیری در



شکل ۲-۳: معماری کلی شبکه‌ی عصبی استفاده شده

معماری شبکه‌های عصبی برای تولید خروجی دقیق‌تر صورت گرفته است که یکی از تأثیرگذارترین آن‌ها، استفاده از ساز و کار توجه است. [۳]

۳-۳ ساز و کار توجه

در شبکه‌ای که از ساز و کار توجه استفاده نمی‌شود، شبکه‌ی رمزگشا به تمام قسمت‌های تصویر با ضریبی (وزنی) یکسان نگاه می‌کند. اما هنگامی که از ساز و کار توجه استفاده می‌شود، می‌توان برای هر پیکسل از تصویر یک وزن جداگانه در نظر گرفت. با انجام این روش، مدل در هر مرحله برای تولید کلمه‌ی بعد می‌داند که باید به کدام بخش از تصویر توجه بیشتری بکند، که بدین منظور از یک ماتریس وزن استفاده می‌شود.

برای به دست آوردن ماتریس وزن، از دو شبکه‌ی متراکم دو لایه استفاده شده است. ورودی این شبکه‌ها از دو بخش تشکیل شده است: ویژگی‌های استخراج شده توسط شبکه رمزگذار و آخرین کلمه‌ی تولید شده توسط شبکه‌ی رمزگشا. در نهایت، خروجی هر دو شبکه، که دو بردار هستند، با یکدیگر جمع شده و وارد یک

لایه‌ی Softmax می‌شود.

فصل ۴

کارهای ما

۴-۱ ترجمه به زبان فارسی

از آنجایی که COCO یک مجموعه داده‌ی بزرگ مقیاس است، ترجمه‌ی تمام توضیح‌های این مجموعه داده توسط انسان کاری غیرممکن است. به همین دلیل، برای انجام این کار می‌بایست از یک سیستم خودکار استفاده شود.

به دلیل اعمال محدودیت تعداد کاراکترهای ترجمه‌شده‌ی روزانه در تمامی سرویس‌های ترجمه‌ی آنلاین و با توجه به حجم بسیار بالای این مجموعه داده، امکان استفاده‌ی رایگان از هیچ‌کدام از این سرویس‌ها وجود ندارد. همچنین در میان سرویس‌های موجود برای ترجمه از زبان انگلیسی به فارسی، دو سرویس Google Translate و فرازین^۱ به دلیل مبتنی بودن بر شبکه‌ی عصبی بهترین خروجی را تولید می‌کنند. در نهایت، به دلیل هزینه‌ی مالی بسیار بالاتر سرویس Google Translate، برای انجام این پروژه‌ی پایانی مقطع کارشناسی از مترجم هوشمند انگلیسی به فارسی فرازین استفاده شده است.

متأسفانه مترجم هوشمند فرازین از ایرادات متعددی رنج می‌برد؛ که همین امر باعث ایجاد مشکلاتی در خروجی بدست آمده از این سرویس می‌شود. یکی از بزرگترین این مشکلات، ترجمه‌ی ناقص یک جمله از

^۱سایت مترجم هوشمند فرازین

انگلیسی به فارسی است. این مشکل زمانی رخ می‌دهد که تمام کلمات یک جمله‌ی انگلیسی به فارسی ترجمه نمی‌شود و معمولاً یک یا دو کلمه به همان صورت انگلیسی در ترجمه آورده می‌شود.

برای مثال، هنگامی که جمله‌ی "A brown horse is grazing grass near a red house." به عنوان ورودی داده شود، مترجم هوشمند فرازین جمله‌ی "یک اسب قهوه‌ای در حال grazing در نزدیکی یک خانه قرمز است." به عنوان ترجمه‌ی آن برمی‌گرداند. این مشکل زمانی عجیب‌تر می‌شود که می‌بینیم با یک تغییر کوچک و نامربوط نسبت به جمله‌ی اصلی، این ترجمه‌ی ناقص از بین می‌رود! برای نمونه، اگر تنها کلمه‌ی "text:" را به ابتدای همان جمله اضافه کنیم، ترجمه‌ی جمله به "متن: اسب قهوه‌ای در نزدیکی یک خانه قرمز در حال چرا است." تغییر پیدا می‌کند. و البته باید این نکته را در نظر داشت که ممکن است اضافه کردن کلمه‌ای دیگر به جمله‌ی اصلی، تغییر ناخواسته‌ی دیگری در خروجی اعمال کند.

در این پروژه، از نسخه‌ی سال ۲۰۱۴ این مجموعه داده استفاده شده است. این نسخه شامل مجموعه‌ی Train و Validation است که هر کدام به ترتیب شامل ۴۱۴۱۱۳ و ۲۰۲۶۵۴ تصویر هستند. همچنین این نسخه در مجموع ۶۰۶۷۶۷ توضیح متفاوت برای تصویرهای موجود در مجموعه داده دارد که در این میان، حدود ۱۶۰۰۰ جمله‌ی آن بعد از ترجمه به فارسی توسط مترجم هوشمند فرازین دچار مشکل ترجمه‌ی ناقص شده است و ۵۹۰۰۰۰ جمله‌ی دیگر بدون مشکل به فارسی ترجمه شده است.

۴-۲ پیاده‌سازی مدل

تمامی مراحل انجام این پروژه به کمک Google Colab انجام شده است. این فایل با صورت کامل com-ment گذاری شده است. در این [لینک](#) می‌توانید به این فایل دسترسی داشته باشید. برای نصب ماژول‌های مورد نیاز section سوم را باید اجرا کنید. برای بارگذاری داده‌ها از section چهارم استفاده کنید و در نهایت برای استفاده از مدل می‌توانید از section آخر در فایل موجود در Google Colab استفاده کنید.

جدول ۱-۴: ارزیابی مدل

زبان انگلیسی	زبان فارسی	معیار مورد استفاده
1	0.376	Bleu-1
1	0.263	Bleu-2
1	0.179	Bleu-3
1	0.120	Bleu-4
1	0.215	Meteor
1	0.269	Rouge L
1	0.375	CIDER

جدول ۲-۴: مقایسه‌ی نتایج مدل انگلیسی و مدل فارسی

توضیح فارسی	ترجمه‌ی توضیح انگلیسی	توضیح انگلیسی	تصویر
گروهی از فیل‌ها که در یک مزرعه ایستاده بودند.	گروهی از فیل‌ها کنار هم ایستاده بودند.	a group of elephants standing next to each other.	
قطاری که روی ریل قطار نشسته بود.	قطاری که از ریل قطار به ایستگاه قطار حرکت می‌کرد.	a train traveling down the tracks near a train station.	
یه دختر کوچولو که یه تیکه پیتزا می‌خوره.	یک دختر کوچک که یک هات‌داگ می‌خورد.	a little girl eating a hot dog.	
یک بازیکن تنیس روی زمین تنیس بازی می‌کند.	مردی که یک راکت تنیس را روی زمین تنیس تاب می‌داد.	a man swinging a tennis racket on a tennis court.	
یک گلدان پر از گل روی یک میز.	گلدانی پر از گل روی میز.	a vase filled with flowers on a table.	
یک نیمکت چوبی کنار یک نیمکت چوبی نشسته بود.	گروهی از مردم روی نیمکتی نشستند.	a group of people seating on a bench.	
یک پسر جوان در حال خوردن غذا در یک رستوران است.	زنی جلوی یک میز یک سگ داغ را در دست گرفته بود.	a woman holding a hot dog in front of a table.	
گروهی از فیل‌ها در ساحل شنی ایستاده بودند.	گروهی از فیل‌ها در امتداد ساحل شنی قدم می‌زنند.	a group of elephants walking across a sandy beach.	
گروهی از مردم در حال پرواز در حال پرواز هستند.	گروهی از مردم بادبادک را در آسمان پرواز می‌کردند.	a group of people flying kites in the sky.	

فصل ۵

نتایج

در این فصل به بررسی نتایج مدل یادگیری شده با استفاده از داده‌های فارسی و انگلیسی می‌پردازیم. در ابتدا در جدولی دو روش تولید توضیح فارسی به صورت مستقیم و غیر مستقیم مقایسه شده است؛ و در ادامه از هر کدام از زبان‌ها شش مثال خوب و شش مثال بد آورده شده است.

۵-۱ نتایج فارسی


۵-۱-۱ نتایج خوب



شکل ۵-۱: گروهی از مردم در ساحل با بادبادک بازی می‌کنند.



شکل ۵-۲: گروهی از فیل‌ها که در مزرعه ایستاده بودند.



شکل ۵-۳: یه دختر کوچولو که یه تیکه پیتزا می‌خوره.



شکل ۵-۴: یک بازیکن تنیس روی زمین تنیس بازی می‌کند.



شکل ۵-۵: یک اسکی باز در حال اسکی روی یک شیب پوشیده از برف است.



شکل ۵-۶: یک چراغ راهنمایی در کنار یک ساختمان بزرگ

۵-۱-۲ نتایج بد



شکل ۵-۷: یک هواپیما در آسمان آبی پرواز می‌کند.



شکل ۵-۸: مردی که در آشپزخانه ایستاده بود.



شکل ۹-۵: یک میز پر از غذا و یک لیوان شراب.



شکل ۱۰-۵: یک حمام با یک یخچال سفید و یک ظرف شویی



شکل ۱۱-۵: مردی که روی کاناپه نشسته بود.



شکل ۱۲-۵: مردی که سوار بر اسب بود.

۵-۲ نتایج انگلیسی

۵-۲-۱ نتایج خوب



شکل ۱۳-۵: a traffic light on the side of a street.



شکل ۱۴-۵: a group of elephants standing next to each other.



شکل ۱۵-۵: a train traveling down the tracks near a train station.



شکل ۱۶-۵: a little girl eating a hot dog.



شکل ۱۷-۵: a man swinging a tennis racket on a tennis court.



شکل ۱۸-۵: a vase filled with flowers on a table.

۵-۲-۲ نتایج بد



شکل ۱۹-۵: a group of people seating on a bench.



شکل ۵-۲۰: a cat sitting on top of a wooden floor.



شکل ۵-۲۱: a woman holding a hot dog in front of a table.



شکل ۵-۲۲: a group of elephants walking across a sandy beach.



شکل ۵-۲۳: a group of people flying kites in the sky.



شکل ۲۴-۵: a close up of a bowl of food.

مراجع

- [1] Donahue, J., Hendricks, L. A., Rohrbach, M., Venugopalan, S., Guadarrama, S., Saenko, K., and Darrell, T. Long-term recurrent convolutional networks for visual recognition and description.
- [2] Johnson, J., Karpathy, A., and Fei-Fei, L. DenseCap: Fully convolutional localization networks for dense captioning.
- [3] Ng, J. Y.-H., Hausknecht, M., Vijayanarasimhan, S., Vinyals, O., Monga, R., and Toderici, G. Beyond short snippets: Deep networks for video classification.
- [4] Ren, S., He, K., Girshick, R., and Sun, J. Faster r-CNN: Towards real-time object detection with region proposal networks.
- [5] Vinyals, O., Toshev, A., Bengio, S., and Erhan, D. Show and tell: A neural image caption generator.
- [6] Xu, K., Ba, J., Kiros, R., Cho, K., Courville, A., Salakhutdinov, R., Zemel, R., and Bengio, Y. Show, attend and tell: Neural image caption generation with visual attention.

واژه‌نامه فارسی به انگلیسی

Captioning	توضیح نویسی
Captioning	عنوان نویسی
Encoder	رمزگذار
Decoder	رمزگشا
Attention Mechanism	ساز و کار توجه
Abstraction Level	سطح انتزاع
Convolutional	پیچشی
Neural Network	شبکه‌ی عصبی
Deep Learning	یادگیری عمیق
Dataset	مجموعه دادگان

واژه‌نامه انگلیسی به فارسی

Train	آموزش
Validation	اعتبارسنجی
Pooling	تجمع‌گیر
Embedding	نهفته سازی

Abstract:

Describing a scene or generating a caption for an image is a relatively easy task for us. However, when we are speaking in the artificial intelligence domain, generating such a caption automatically is a complex problem. In this thesis, a neural network model is presented which is based on deep learning and can generate a caption for a given image. This model consists of three parts: encoder, decoder, and attention. In order to generate captions both in Farsi and English, the model is separately trained on the original COCO dataset as well as the Persian-translated version of the dataset.

Keywords: Image captioning, Neural Network, Attention, Deep Learning



Iran University of Science and Technology
Computer Engineering Department

Image captioning using Attention mechanism in neural network

**A Thesis Submitted in Partial Fulfillment of the Requirement for the Degree
of Master of Science in Computer Engineering**

By:

Kiarash Aghakasiri

Supervisor:

Dr. Nasser Mozayani

July 2019