

# شبکه‌های عصبی کانولوشن برای کشف اخبار جعلی

# کشف اخبار جعلی

## مسأله

- ▶ با پیشرفت شبکه های اجتماعی اخبار تقلبی برای اهداف مختلف سیاسی و تجاری به وجود آمده اند.
- ▶ اخبار جعلی آثار مخربی دارد و هدف مهم شناسایی این نوع اخبار است .
- ▶ . شناسایی خودکار اخبار جعلی بسیار سخت است
- ▶ طبق نتایج آماری گزارش شده توسط محققان در دانشگاه استنفورد، 3/72 درصد از اخبار جعلی در واقع از رسانه های خبری رسمی و شبکه های اجتماعی آنلاین نشأت می گیرد.

## مثال

- ▶ در طی انتخابات ریاست جمهوری سال ۲۰۱۶، انواع مختلفی از اخبار تقلبی در مورد نامزدها به طور گسترده از طریق رسانه های خبری رسمی و شبکه های اجتماعی آنلاین پخش شد که این اخبار برای حمایت از کاندید مورد نظر یا بر علیه مخالفان منتشر می شود

# مشکلات شناسایی اخبار جعلی

- ▶ شناسایی اخبار جعلی از رسانه های اجتماعی آنلاین به دلایل مختلف بسیار چالش برانگیز است.
- ▶ جمع آوری داده های اخبار جعلی کار سختی است، و برچسب گذاری دستی اخبار جعلی نیز مشکل است
- ▶ اخبار جعلی توسط انسان نوشته شده است.
- ▶ نمایش محدود داده ها از متن، گلوگاهی برای شناسایی اخبار جعلی است

# پیشنهاد یک راه حل برای کشف اخبار جعلی

- ▶ مدلی به نام (TI-CNN، متن و عکس مبتنی بر شبکه عصبی)
- ▶ تا اطلاعات مربوط به متن و تصویر را در تشخیص اخبار جعلی در نظر بگیرد
- ▶ با طرح ویژگی های آشکار و نهان در یک فضای ویژگی واحد، TI CNN به طور همزمان با متن و اطلاعات تصویر آموزش می بیند
- ▶ . فراتر از ویژگی های صریح استخراج شده از داده ها، شبکه های عصبی کانولوشن برای یادگیری ویژگی های پنهان استفاده می شوند که توسط ویژگی های صریح قابل ضبط نیستند.
- ▶ . آزمایشات گسترده ای که بر روی مجموعه داده های اخبار جعلی در دنیای واقعی انجام شده است، اثربخشی TI CNN در حل مسئله جدید کشف جعلی را نشان می دهد.

# پیشنهاد یک راه حل برای کشف اخبار جعلی

- ▶ ما یک مجموعه داده با کیفیت بالا را جمع آوری می کنیم و متن را از چند منظر بررسی می کنیم.
- ▶ ثابت شده است که اطلاعات تصویر از ویژگی های موثر در شناسایی اخبار جعلی است.
- ▶ یک مدل واحد برای تجزیه و تحلیل متن و اطلاعات تصویر با استفاده از شبکه های عصبی کانوشنال پیشنهاد شده است.
- ▶ مدل پیشنهادی در این مقاله راهی موثر برای تشخیص اخبار جعلی از بسیاری از اطلاعات آنلاین است.

# رویکردهای حل مسأله

▶ کشف فریب موضوعی داغ در چند سال گذشته است. اطلاعات فریب شامل تقلب علمی، اخبار جعلی، توییت های دروغین و غیره است. کشف اخبار جعلی یکی از زیرمجموعه های این حوزه است.

▶ محققان مسئله کشف فریب را از دو جنبه حل می کنند:

➤ رویکرد زبانی

➤ رویکرد شبکه

# رویکردهای حل مسأله

## ▶ رویکرد زبانی

- ▶ استفاده از تکنیک های پردازش زبان طبیعی
- ▶ تجزیه و تحلیل بررسی های جعلی در آمازون این سال بر اساس تجزیه و تحلیل احساسات، واژگان، شباهت محتوا، شباهت سبک و ناهماهنگی معنایی برای شناسایی بررسی های جعلی
- ▶ روش یادگیری نیمه نظارت شده را برای تشخیص متن فریبنده در مجموعه داده های دارای منابع گسترده در سال ۲۰۱۶ پیشنهاد شد.
- ▶ روش های مبتنی بر تجزیه و تحلیل کلمات برای شناسایی فریب کافی نیست.

# رویکردهای حل مسأله

## ▶ رویکرد شبکه

▶ روش دیگر برای شناسایی فریب، تجزیه و تحلیل ساختار شبکه است که از ویژگی های تکمیلی مهم

هستند

▶ مفهوم جدیدی به نام "\اثر شبکه\" را برای استخراج احتمالات اخبار ارائه شد

▶ روش های مبتنی بر تجزیه و تحلیل نمودار دانش می توانند به دقت ۶۱ تا ۹۵ درصد برسند.

▶ از رفتار های شبکه های اجتماعی برای شناسایی فریب استفاده کنیم.



# رویکردهای حل مسأله

## ▶ رویکردهای مبتنی بر شبکه عصبی

- ▶ مدل های یادگیری عمیق به طور گسترده ای هم در جامعه دانشگاهی و صنعت استفاده می شوند. در بینایی رایانه ای و تشخیص گفتار و روش های پیشرفته تقریباً همه شبکه های عصبی عمیق هستند.
- ▶ در روش پردازش زبان طبیعی **NLP**، از مدل های یادگیری عمیق برای آموزش مدلی استفاده می شود که می تواند کلمات را به عنوان بردار نشان دهد.
- ▶ محققان بسیاری از مدل های یادگیری عمیق را براساس کلمات بردار برای **QA** و خلاصه سازی و غیره ارائه می دهند.
- ▶ محققان همچنین دریافتند **CNN** در بسیاری از کارهای **NLP** موثر است
- ▶ . به عنوان مثال، تجزیه معنایی، مدل سازی جمله ها و سایر کارهای سنتی **NLP**

# تعریف مساله


- ▶ با توجه به مجموعه ای از  $m$  مقاله خبری که حاوی متن و اطلاعات تصویر هستند ، می توانیم داده ها را به عنوان مجموعه ای از تصاویر متن به صورت  $(A_i^T, A_i^I)^m$  نمایش دهیم .
- ▶ در مسئله کشف اخبار جعلی، ما می خواهیم پیش بینی کنیم که آیا مقالات خبری موجود در  $A$  اخبار جعلی هستند یا خیر.
- ▶ به این صورت می توان برچسب دهی کرد:  $Y = \{[0,1],[1,0]\}$
- ▶ که  $[0,1]$  اخبار جعلی را نشان می دهد و  $[1,0]$  اخبار واقعی را.
- ▶ هدف ما برای کشف اخبار جعلی ساختن مدل  $f = (A_i^T, A_i^I)^m \in X \rightarrow Y$  برای استنباط برچسب های بالقوه مقالات خبری در  $A$ .

# تحلیل داده ها

▶ ما متن و اطلاعات تصویر را از دیدگاه های مختلف مانند زبان محاسباتی، تجزیه و تحلیل احساسات، تجزیه و تحلیل روانشناختی و سایر ویژگی های مربوط به تصویر بررسی می کنیم که اطلاعات کمی از داده ها را در این بخش نشان می دهیم،

## ▶ مجموعه داده :

▶ مجموعه داده های موجود در این مقاله شامل ۲۰،۰۱۵ خبر، یعنی ۱۱۹۴۱ اخبار جعلی و ۸،۰۷۴ خبر واقعی است. بصورت آنلاین در دسترس است برای اخبار جعلی، حاوی متن و فراداده ای است که از بیش از ۲۴۰ وب سایت توسط Megan Risdal در Kaggle2 جمع اوری شده است. اخبار واقعی از وب سایت های خبری معتبر معروف، نیویورک تایمز، واشنگتن پست، و غیره کشف می شود. مجموعه داده ها حاوی اطلاعات متعددی مانند عنوان، متن، تصویر، نویسنده و وب سایت است. برای آشکار کردن تفاوت های ذاتی اخبار واقعی و جعلی، ما فقط از عنوان، متن و اطلاعات تصویر استفاده می کنیم.



## تجزیه و تحلیل متن :

- بیابید فرکانس کلمه در عناوین را به عنوان مثالی
- برای نشان دادن تفاوت های بین اخبار جعلی و واقعی را در شکل روبرو در نظر بگیریم .

اگر خبر عنوان ندارد، عنوان را "\notitle\" قرار می دهیم. کلمات غالباً مشاهده شده در عنوان اخبار جعلی، THE، IN، notitle و بسیاری از اعداد بی معنی هستند که شخصیت های خاصی را نشان می دهند. از این شکل می توان چیزهای جالبی پیدا کنیم: اولاً، بسیاری از اخبار جعلی عنوان ندارند. این اخبار جعلی با چند کلمه کلیدی و پیوند اخبار در شبکه های اجتماعی به طور گسترده پخش می شوند.

در مرحله دوم، شخصیت های سرمایه بیشتری در اخبار جعلی وجود دارد. هدف جلب توجه خوانندگان است، در حالی که اخبار واقعی حاوی حروف بزرگ کمتری هستند که در قالب استاندارد نوشته شده اند. ثالثاً، اخبار واقعی شامل توضیحات مفصل تری هستند. به عنوان مثال، اسامی (جب بوش، میچ مک کانل و غیره) و افعال حرکتی (چپ، ادعا، بحث و نظرسنجی و غیره)

# تحلیل داده ها

## محاسبات آماری زبانی ►

► تعداد کلمات و جملات: اگرچه کسانی که اخبار جعلی را منتشر می کنند تا حدودی بر محتوای داستان های خود کنترل دارند، اما ممکن است حالت ذهنی اصلی آنها از طریق سبک زبان استفاده شده برای روایت داستان آشکار شود. این مورد در رابطه با افرادی که اخبار جعلی را می نویسند نیز صدق می کند

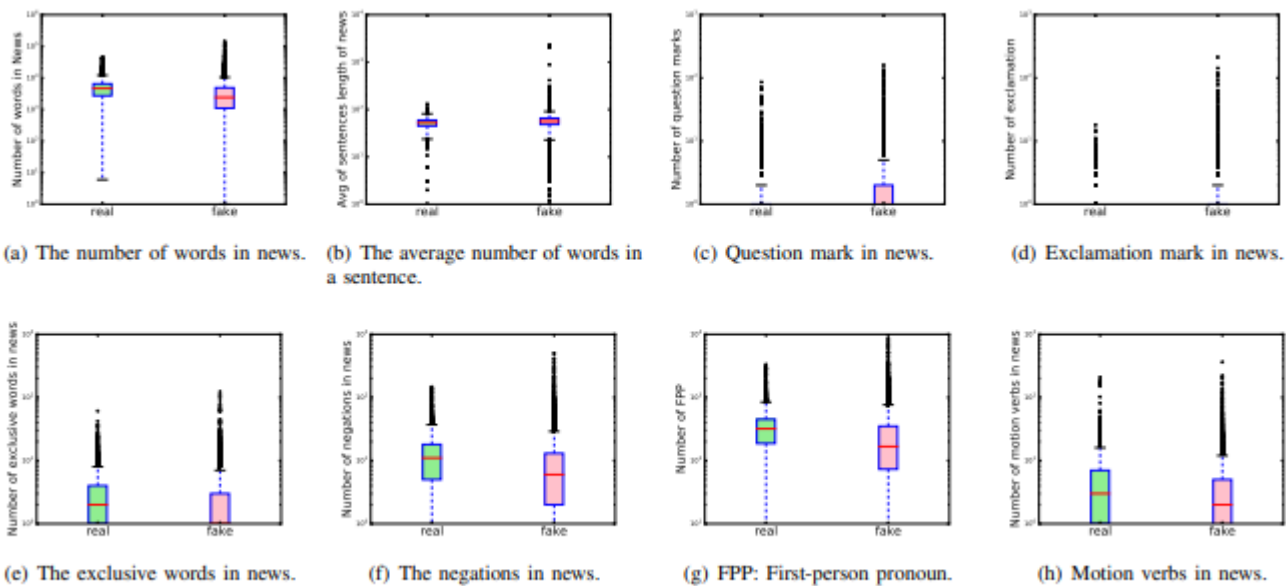


Fig. 3. Analysis on the news text.

همانطور که در شکل بالا نشان داده شده است، اخبار جعلی به طور متوسط کلمات کمتری نسبت به اخبار واقعی دارند. به طور متوسط ۴۳۶۰ کلمه برای اخبار واقعی وجود دارد، در حالی که این تعداد برای اخبار جعلی ۳،۹۴۳ کلمه است. علاوه بر این، تعداد کلمات اخبار جعلی در محدوده وسیعی توزیع می شود که نشان می دهد برخی اخبار جعلی کلمات بسیار کمی دارند و برخی دیگر کلمات زیادی دارند. تعداد کلمات فقط یک نمایش ساده برای تجزیه و تحلیل اخبار جعلی است.

# محاسبات آماری زبانی

▶ اخبار واقعی به طور متوسط جملات بیشتری نسبت به اخبار جعلی دارند. خبر واقعی ۸۴ جمله دارد، در حالی که اخبار جعلی ۶۹ جمله دارد. بر اساس تجزیه و تحلیل فوق، می توانیم به ترتیب میانگین کلمات یک جمله را برای اخبار جعلی و واقعی بدست آوریم.

▶ همانطور که در شکل ۳ (اسلاید قبلی) نشان داده شده است، جمله اخبار واقعی کوتاه تر از اخبار جعلی است. اخبار واقعی به طور متوسط ۵۱.۹ کلمه در یک جمله دارد. با این حال، این تعداد برای اخبار جعلی ۵۷.۱ است. با توجه به شکل جعبه ای، واریانس اخبار واقعی بسیار کمتر از اخبار جعلی است. و این پدیده تقریباً در تمام نمودارهای جعبه ای دیده می شود. دلیل این امر این است که سردبیر اخبار واقعی باید مقاله را تحت قوانین خاص مطبوعات بنویسد. این قوانین شامل طول، انتخاب کلمه، عدم وجود خطاهای دستوری و غیره است. این نشان می دهد که بیشتر اخبار واقعی به روشی استاندارد و سازگارتر نوشته می شوند. با این حال، بیشتر افرادی که اخبار جعلی می نویسند لازم نیست از این قوانین پیروی کنند.

# محاسبات آماری زبانی

▶ علامت سوال، تعجب و حروف بزرگ :

▶ طبق آمار مربوط به متن خبر، اخبار واقعی دارای علامت سوال کمتری نسبت به اخبار جعلی هستند، همانطور که در شکل ۳ (C) نشان داده شده است.

▶ دلیل این امر ممکن است این باشد که سوالات لفظی زیادی در اخبار جعلی وجود دارد. این پرسش های ابلاغی همیشه برای تأکید آگاهانه بر ایده ها و تشدید احساسات مورد استفاده قرار می گیرد. با توجه به تجزیه و تحلیل داده ها، متوجه می شویم که اخبار جعلی و واقعی هر دو اظهارات کمی دارند. با این حال، همانطور که در شکل ۳ (د) نشان داده شده است حصار داخلی نمودار جعبه اخبار جعلی بسیار بزرگتر از حصار اخبار واقعی است، ابراز احساسات می تواند یک جمله توضیحی ساده را به یک دستور قوی تبدیل کند و یا یک ابراز احساسات را منعکس کند.



# محاسبات آماری زبانی

▶ از این رو، اخبار جعلی متمایل به استفاده از کلمات همراه با تعجب برای تحریک احساسات خاص در بین خوانندگان هستند و حروف بزرگ نیز در اخبار جعلی و واقعی تحلیل می شوند. دلیل بزرگ نوشتن خبر، جلب توجه خوانندگان یا تأکید بر ایده بیان شده توسط نویسندگان است. طبق داده های آماری، حروف بزرگ بسیار مهمتر از اخبار جعلی است. این نشان می دهد که فریب دهندگان اخبار جعلی در استفاده از حروف بزرگ برای جلب توجه خوانندگان، در جلب نظر آنها برای خواندن آن و باور آن مهارت دارند

# دیدگاه شناختی

- ▶ از دیدگاه شناختی، ما کلمات انحصاری (به عنوان مثال، "\اما\"، "\بدون\"، "\با این حال\") و منفیات (به عنوان مثال، "\نه\"، "\نه\") را که در اخبار استفاده می شود، بررسی می کنیم.
- ▶ همانطور که در شکل ۳ (e) و ۳ (f) نشان داده شده است، کسانی که اخبار واقعی را منتشر میکنند بیشتر از منفیات استفاده می کنند. کلمات منحصر به فرد در اخبار پدیده مشتبهی با نفی را دارند. میانگین منفیات در اخبار جعلی بسیار کمتر از اخبار واقعی است. فرد دروغگو هنگام استفاده از کلمات و منفیات انحصاری باید دقیق تر باشد دچار تناقض نشود. از این رو، آنها کمتر از کلمات انحصاری و منفی در نوشتن استفاده می کنند. کسی که واقعیت را میگوید از تمام اخبار با جزئیات کامل آگاهی دارد.

# چشم انداز روانشناسی


- ▶ از نظر روانشناسی، ما همچنین استفاده از ضمائر اول شخص (به عنوان مثال، من، ما، من) را در اخبار واقعی و جعلی بررسی می کنیم. افراد فریبنده اغلب از زبانی استفاده می کنند که ارجاعات به خودشان را به حداقل می رساند. شخصی که دروغ می گوید، تمایل دارد که از "\م" و "\من" استفاده نکند و از ضمیر شخص استفاده نمی کند. به طور مشابه، همانطور که در شکل ۳ (g) نشان داده شده است، نتیجه با دیدگاه روانشناسی یکسان است. به طور متوسط، اخبار جعلی ضمائر اول شخص کمتری دارند. ضمائر شخص دوم به عنوان مثال، شما، شما) و ضمائر شخص سوم (به عنوان مثال، او) نیز مورد بحث قرار میگیرند.
- ▶ می بینیم که در اخبار جعلی از ضمیر اول شخص خیلی کم استفاده شده است و بیشتر از ضمیر سوم شخص استفاده میکنند همچنین از بحث در باره ی جزییات خودداری می کنند. و همانطور که در شکل ۳ (h) می بینید از افعال حرکتی کمی استفاده میکنند.

# تنوع واژگانی

▶ تنوع واژگانی معیاری است برای سنجش تعداد کلمات مختلفی که در متن استفاده می شود، در حالی که تراکم واژگانی معیاری از نسبت ایتهم های واژگانی (به عنوان مثال، اسامی، افعال، صفات و برخی از قیدهها) را در متن ارائه می دهد. اخبار غنی از تنوع بیشتری برخوردار است. طبق نتایج تجربی، تنوع لغوی اخبار واقعی  $2.2 \times 10^{-6}$  است، که برای اخبار جعلی بزرگتر از  $1.76 \times 10^{-6}$  است.

# تحلیل احساسات

▶ تحلیل احساسات در اخبار واقعی و جعلی کاملاً متفاوت است. برای اخبار واقعی، نظرات مثبت بیشتری دارند تا نظرات منفی. دلیل آن این است که افراد دروغگو ممکن است احساس گناه کنند یا نسبت به موضوع اطمینان ندارند، برای همین تحت تنش و گناه، ممکن است افراد دروغگو احساسات منفی بیشتری داشته باشند. نتایج تجربی با تحلیل فوق در شکل ۴ موافق است. انحراف معیار اخبار جعلی در مورد احساسات منفی نیز بیشتر از اخبار واقعی است، که نشان می دهد اخبار جعلی دارای احساسات منفی قوی هستند.



(a) The median sentiment values: positive and negative. (b) The standard deviation sentiment values: positive and negative.

Fig. 4. Sentiment analysis on real and fake news.

تحلیل احساسات در اخبار واقعی و جعلی

## ▶ تحلیل تصاویر

▶ طبق برخی مشاهدات بر روی تصاویر موجود در اخبار جعلی، متوجه می شویم که چهره های بیشتری در اخبار واقعی وجود دارد. برخی از اخبار جعلی دارای تصاویر بی ربطی هستند، مانند حیوانات و صحنه ها. نتیجه آزمایش با تحلیل فوق مطابقت دارد. در اخبار واقعی به طور متوسط 0.366 چهره وجود دارد، در حالی که این تعداد در اخبار جعلی 0.299 است. علاوه بر این، اخبار واقعی دارای وضوح تصویر بهتری نسبت به اخبار جعلی هستند. اخبار واقعی به طور متوسط دارای  $277 \times 457$  پیکسل است، در حالی که وضوح اخبار جعلی  $228 \times 355$  است.

# مدل - معماری

معماری مدل TI-CNN ▶

از دو CNN موازی برای استخراج ویژگی های مخفی از اطلاعات متنی و بصری استفاده می کنیم. ▶

و سپس ویژگی های آشکار و پنهان به همان فضای ویژگی تصویر می شود تا بازنمایی های جدیدی از متن ها و تصاویر تشکیل شود. سرانجام، ما پیشنهاد می دهیم نمایش های متنی و تصویری را برای تشخیص اخبار جعلی با هم ادغام کنیم. ▶

# مدل - معماری

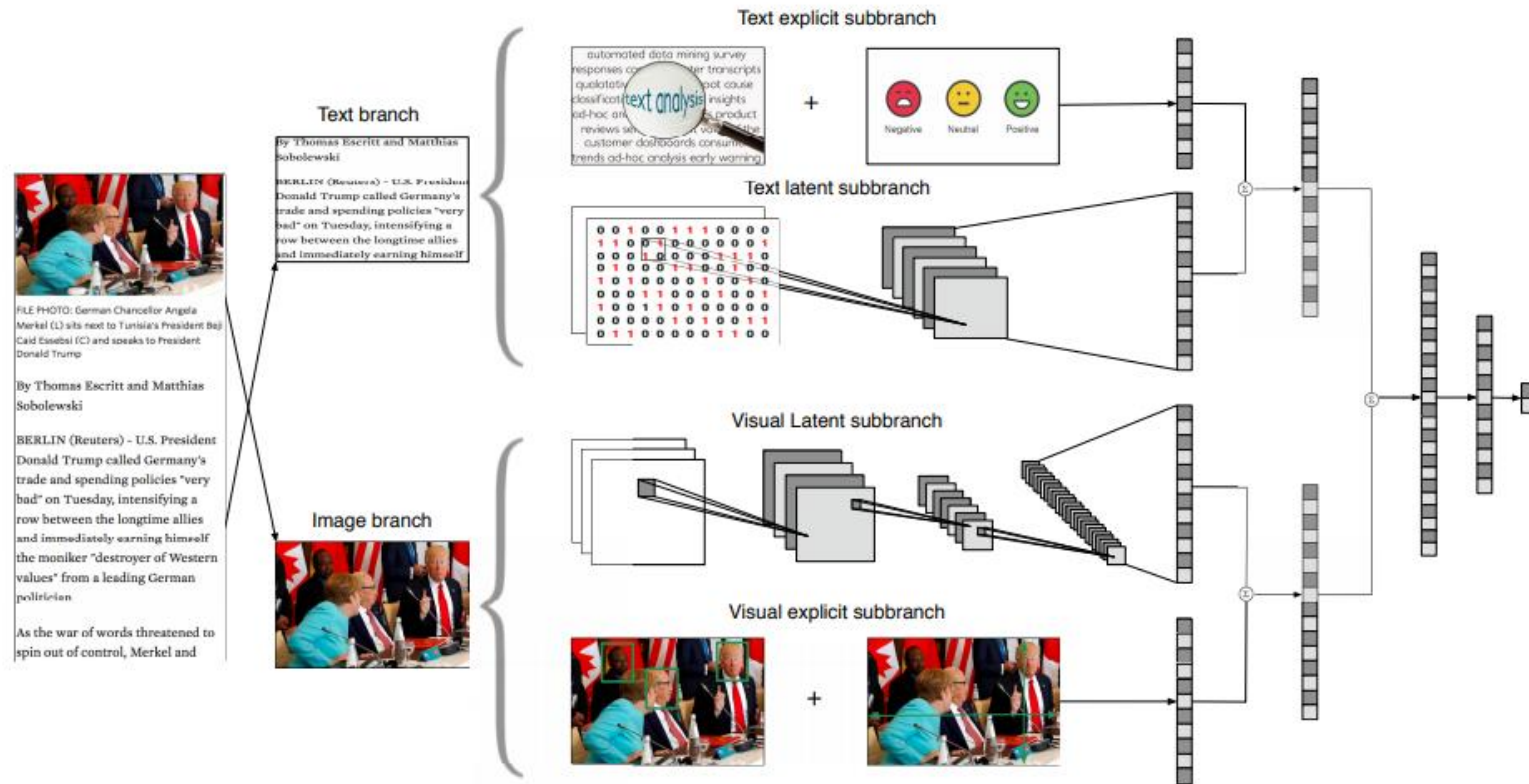


Fig. 5. The architecture of the model. The rectangles in the last 5 layers represent the hidden dense layers. The dropout, batch normalization and flatten layers are not drawn for brevity. The details of the structure are shown in Table III.



# مدل - معماری

- ▶ مدل کلی شامل دو شاخه اصلی است، به عنوان مثال شاخه متن و شاخه تصویر. برای هر شاخه، با در نظر گرفتن داده های متنی یا تصویری به عنوان ورودی، ویژگی اشکار و پنهان برای پیش بینی های نهایی استخراج می شود.
- ▶ دادن نظریه ساخت TI CNN، ما با پاسخ به سوالات زیر مدل را معرفی می کنیم ۱
- ▶ ( چگونه ویژگیهای پنهان را از متن استخراج کنیم؟ ۲ ) چگونه ویژگی های آشکار و پنهان را با هم ترکیب کنیم؟ ۳ ) چگونه با متن و ویژگی های تصویر کنار بیاییم؟ ۴ ) چگونه می توان مدل را با پارامترهای کمتری طراحی کرد؟ ۵ ) چگونه می توان روند آموزش را تسریع کرد؟

# مدل - معماری

## ▶ شاخه متن

▶ برای شاخه متن، ما از دو نوع ویژگی ویژگی های آشکار متنی  $X^{Tl}$  و ویژگی های پنهان متنی  $X^{Te}$  استفاده می کنیم

▶ ویژگی های آشکار متنی از امار متن خبری که در بخش تجزیه و تحلیل داده ها ذکر کردیم،

▶ مانند طول خبر، تعداد جملات، علامت سوال، بیانیه ها و حروف بزرگ و غیره به دست می آیند.

خبرواحد را می توان به صورت برداری با اندازه ثابت سازماندهی کرد.

# مدل - معماری

► ویژگی های پنهان متنی در مدل براساس یک نوع CNN ساخته شده است. اگرچه CNN ها عمدتاً در کارهای بینایی ماشین، مانند طبقه بندی تصویر یا شناسایی اشیاء استفاده می شود، CNN همچنین عملکردهای قابل توجهی را در بسیاری از کارهای پردازش زبان طبیعی (NLP) نشان می دهد با رویکرد کانولوشن، شبکه عصبی می تواند ویژگی های محلی را در اطراف هر کلمه از کلمه مجاور تولید کند و سپس آنها را با استفاده از یک عملیات ماکزیمم برای ترکیب کند تا یک نگاشت سطح کلمه ثابت ایجاد کند

# مدل - معماری

► می توان اخبار کلی را به این صورت نوشت :

$$X_{i,1:n}^{Tl} = x_{i,1} \oplus x_{i,1} \oplus x_{i,2} \oplus \dots \oplus x_{i,n}$$

---

► این بدان معناست که اخبار  $X_{i,l:n}^{Tl}$  هر کلمه پیوند داده می شوند. در این حالت، هر خبر می تواند به عنوان یک

ماتریس نمایش داده شود. سپس ما برای ساخت ویژگی های جدید از فیلترهای کانولوشن ( $w \in R^{h*k}$ )

استفاده می کنیم. به عنوان مثال، یک پنجره کلمه  $X_{i,j:j+h-1}^{Tl}$  می تواند یک ویژگی ( $c_i$ ) به صورت زیر

تولید کند :

$$c_i = f(w \cdot X_{i,j:j+h-1}^{Tl} + b),$$

# مدل - معماری

▶ که در آن  $b \in \mathbb{R}$  یک بایاس است و  $(\cdot)$  یک عملیات کانووشنال است،  $f$  نیز یک انتقال غیر خطی است مثل سیگموئید .  
▶ یک نقشه ویژگی از فیلتر با عبور از تمام پنجره کلمات ممکن در اخبار تولید می شود که به صورت زیر نشان داده می شود:

$$\mathbf{c} = [c_1, c_2, \dots, c_{n-h+1}],$$

▶ که در آن  $\mathbf{c} \in \mathbb{R}^{(n-h+1)}$  است

▶ لایه max-pooling برای گرفتن حداکثر در نقشه ویژگی  $\mathbf{c}$  به کار می رود که به این صورت نشان داده می شود

$$\hat{c} = \max\{c\} .$$

▶ لایه max-pooling می تواند با ذخیره مهم ترین نتایج کانوولوشن برای تشخیص اخبار جعلی مقاومت مدل را

بهبود ببخشد. نتایج جمع آوری به یک لایه کاملاً متصل منتقل می شود تا ویژگیهای نهفته متنی نهایی ما را برای پیش بینی برچسب های خبری بدست آورد.

# مدل - معماری

## ▶ شاخه تصاویر

▶ مشابه شاخه متن، ما از دو نوع ویژگی از ویژگی های آشکار بصری  $X^{le}$  و ویژگی های پنهان بصری  $X^{ll}$  استفاده می کنیم. همانطور که در شکل ۵ نشان داده شده است، برای بدست آوردن ویژگیهای واضح بصری، ابتدا وضوح تصویر و تعداد چهره های تصویر را استخراج می کنیم تا یک بردار ویژگی تشکیل دهیم و سپس، ما بردار را با یک لایه کاملاً متصل به ویژگی واضح بصری تبدیل می کنیم. ویژگی های آشکار بصری می تواند اطلاعات مربوط به تصاویر موجود در اخبار را منتقل کند، این ویژگی دارای ویژگی های دستی است و نه مبتنی بر داده، برای یادگیری مستقیم از تصاویر خام موجود در اخبار برای به دست آوردن ویژگی های قدرتمند تر، ما از CNN دیگری برای یادگیری از تصاویر موجود در اخبار استفاده می کنیم.

# مدل - معماری

## ▶ لایه کانووشنال

- ▶ در لایه convolutional، فیلترها در کل میدان دید تکرار می‌شوند و همان پارامترها را برای ایجاد یک نقشه ویژگی به اشتراک می‌گذارند. در نظر بگیرید لایه کانووشنال دارای نقشه های  $M$  هست با اندازه های  $(M\beta, M\alpha)$ .
- ▶ یک فیلتر  $(K\alpha, K\beta)$  بر روی تمام نقاط تصاویر اعمال شده است. از این رو اندازه نقشه خروجی به شرح زیر است:

$$M_{\alpha}^n = M_{\alpha}^{n-1} - K_{\alpha}^n + 1$$

$$M_{\beta}^n = M_{\beta}^{n-1} - K_{\beta}^n + 1$$

# مدل - معماری

## لایه max pooling ▶

▶ یک لایه max pooling به لایه ی کانوشنال متصل است. سپس بیشترین فعالساز را روی فیلتر مستطیل شکل  $(K\alpha, K\beta)$  را به خروجی لایه max pooling اعمال می کنیم . max pooling می تواند تصویر ورودی را با استفاده از یک ضریب  $K\alpha$  و  $K\beta$  در امتداد هر جهت کاهش دهد که این باعث می شود بتواند ویژگی های ثابت مدل را انتخاب کند، سریعتر همگرا شود و تعمیم را به طور قابل توجهی بهبود بخشد.



# مدل - معماری

عنوان	متن خبر	نوع خبر
اخوان آمیش از دونالد ترامپ برای ریاست جمهوری حمایت کرده اند.	آمیش ها که از نوادگان مستقیم فرقه اصلاح طلب معترض به اناباپتیست ها هستند، در گذشته معمولاً از سیاست دور بوده اند. به عنوان یک قاعده کلی، آنها رأی نمی دهند، در ارتش خدمت نمی کنند، یا در نمایش های دیگر میهن پرستی شرکت نمی کنند. امسال، <b>AAB</b> گفته است که ضروری است که آنها در روند دموکراتیک شرکت کنند	جعلی
ویکی لیکس به هیلاری اجازه اولتیماتوم می دهد، یا اینکه ما چیزی را ویران می کنیم که زندگی را نابود کند	روز یکشنبه، ویکی لیکس به هیلاری کلینتون کمتر از ۲۴ ساعت فرصت داد تا از مسابقه خارج شود، در غیر این صورت چیزی را تخریب می کند که کاملاً او را نابود کند. اخیراً جولیان آسانژ تأیید کرد که ویکی لیکس با دولت روسیه کار نمی کند، بلکه در تعقیب آنها است عدالت، آنها موظفند هرچه در توان دارند را برای روشن کردن یک سیستم فاسد آزاد کنند و چه کسی ممکن است از هیلاری کج فاسد باشد	جعلی

# مدل - معماری

▶ نورون خطی اصلاح شده

▶ توابع فعالساز sigmoid و tan h ممکن است باعث کاهش گرادیان یا محوشدگی گرادیان در شبکه های عصبی کانووشنال شوند از این رو تابع فعالساز RELU را به شاخه تصاویر اضافه می کنیم تا مشکل محوشدگی گرادیان از بین برود.

$$y = \max(0, \sum_{i=1}^k x_i \theta_i + b)$$

▶ تابع فعالساز relu می تواند با تسریع روند آموزش شبکه های عصبی را بهبود ببخشد. محاسبات گرادیان بسیار ساده است (بسته به علامت مقدار آن یا صفر یا ۱ است).

# مدل - معماری

► همچنین، مرحله محاسباتی ReLU آسان است: هر عنصر منفی روی  $0.0$  بدون توان، بدون عملیات ضرب یا تقسیم تنظیم شده است. لجستیک و شبکه های تانژانت هایپربولیک از مشکل محوشدگی گرادیان رنج می برند، که در آن گرادیان اساساً پس از مقداری آموزش (به دلیل دو مجانب افقی) صفر می شود و تمام یادگیری ها را در آن بخش از شبکه متوقف می شود. واحدهای ReLU دارای شیب صفر هستند که از نظر تجربی برتر است.

# مدل - معماری

## ▶ تنظیمات:

▶ ما برای جلوگیری از بیش برآزش (overfitting) از dropout و نرم l2 استفاده میکنیم .

▶ Dropout، تنظیم برخی از عناصر در بردارهای وزن به صورت صفر با احتمال p واحدهای مخفی در طول انتشار رو

به جلو و رو به عقب است. به عنوان مثال ما یک لایه متراکم  $z=[z_1, \dots, z_m]$  داریم و یک بردار  $r$  داریم که

همه ی عناصر آن صفر است هنگامی که شروع به آموزش مدل می کنیم داده های پرت برای تنظیم برخی از عناصر

$r$  به عنوان ۱ با احتمال p است. فرض کنید خروجی لایه متراکم  $y$  باشد داده های پرت میتوانند به صورت رو به رو

فرمول بندی شوند :

$$y = \theta \cdot (z \circ r) + b,$$

# مدل - معماری

► که  $\theta$  بردار وزن است و  $\theta$  عملگر ضرب داخلی است. وقتی ما بر روی مجموعه داده آزمایشی (test) شروع به آزمایش میکنیم

نورون های حذف شده برمیگردند. وزن حذف شده توسط  $p$  مقیاس بندی می شود به طوری که  $\hat{\theta} = p\theta$  که از  $\hat{\theta}$

برای پیش بینی نمونه های آزمایش استفاده می شود. روش فوق بصورت تکراری اجرا می شود، که تا حد زیادی قابلیت

تعمیم مدل را بهبود می بخشد. ما همچنین برای جلوگیری از بیش برآزش آموزش را زودتر متوقف می کنیم (توقف زودرس)

این روش میتواند به عنوان یک روش طبقه بندی در نظر گرفته شده باشد مانند  $L1, L2$  و داده های پرت).

# مدل - معماری

▶ آموزش شبکه :

▶ ما شبکه عصبی خود را با به حداقل رساندن احتمال منفی (likelihood) در مجموعه داده های آموزشی  $D$  آموزش می دهیم. برای تشخیص برجسب خبر  $X$ ، شبکه با پارامتر  $\theta$  مقدار  $S_W(x)_T$  را محاسبه می کند. سپس یک تابع سیگموئید روی تمام امتیازات برجسب ها ( $\tau \in T$ ) استفاده می شود تا مقدار آن را به توزیع احتمال

شرطی برجسب ها تبدیل کند

$$p(\tau|X, \theta) = \frac{e^{s_{\theta}(X)_{\tau}}}{\sum_{\forall i \in T} e^{s_{\theta}(X)_i}}$$

# مدل - معماری

$$E(W) = -\ln p(\tau|\mathbb{X}, \theta) = s_{\theta}(\mathbb{X})_{\tau} - \log \left( \sum_{v_i \in T} e^{s_{\theta}(\mathbb{X})_{\tau}} \right)$$

منفی لگاریتم فرمول قبل به صورت زیر است :

ما از بهینه ساز RMSprop برای کاهش تابع هزینه با توجه به پارامتر  $\theta$  استفاده می کنیم :

$$\theta \rightarrow \sum_{(\mathbf{X}, \mathbf{Y}) \in D} -\log p(\mathbf{Y}|\mathbf{X}, \theta)$$

که در آن  $\mathbf{X}$  داده ورودی و  $\mathbf{Y}$  برچسب خبر است . الگوریتم پس انتشار خطا را برای محاسبه گرادیان شبکه انتخاب می کنیم. با تنظیم پارامترها خطا با تعداد کمی اپوک (تعداد دوره کم) به مینیمم محلی همگرا می شود .

# آزمایشات

موارد مطالعه :

موارد مطالعه اخبار جعلی در این بخش آورده شده است. دو خبر جعلی در جدول **۱** مربوط به شکل **۱** (c) و **۱** (d) است. اولین خبر جعلی مقاله ای است که گزارش می دهد **۱** "اخوان آمیش آمریکایی دونالد ترامپ را برای رئیس جمهور تأیید کرد." با این حال، این وب سایت صفحه جعلی **CNN** است. تصویر موجود در اخبار جعلی را می توان به راحتی از طریق اینترنت جستجو کرد، و با متن خبر مرتبط نیست. برای دومین خبر جعلی -ویکی لیکس به هیلاری کلینتون کمتر از ۲۴ ساعت فرصت داد تا از مسابقات خارج شود **۱**، این در واقع از ویکی لیکس نیست. علاوه بر این، تصویر ترکیبی **۴** در اخبار با کیفیت پایین است.



# مشخصات مدل

TABLE III  
 MODELS SPECIFICATIONS. BN: BATCH NORMALIZATION, ReLU:  
 RECTIFIED LINEAR ACTIVATION FUNCTION, CONV: CONVOLUTIONAL  
 LAYER ON 2D DATA, CONV1D: CONVOLUTIONAL LAYER ON 1D DATA,  
 DENSE: DENSE LAYER, EMB: EMBEDDING LAYER, MAXPO:  
 MAX-POOLING ON 2D DATA, MAXPO1D: MAX-POOLING ON 1D DATA.  
 THERE ARE TWO KINDS OF DROPOUT LAYERS, I.E.,  $D = (D_\alpha, D_\beta)$ ,  
 WHERE  $D_\alpha = 0.5$  AND  $D_\beta = 0.8$ .

جدول 3 ►

Text Branch		Image Branch	
Textual Explicit	Textual Latent	Visual Latent	Visual Explicit
Input $31 \times 1$	Emb $1000 \times 100$	Input $50 \times 50 \times 3$	Input $4 \times 1$
	Dropout $D_\alpha$	$(2 \times 2)$ Conv(32) ReLU	
Dense 128	Emb $1000 \times 100$	Dropout $D_\beta$	Dense 128
	$(3,3)$ Conv1D(10)	$(2 \times 2)$ Maxpo	
	2 MaxPo1D	$(2 \times 2)$ Conv(32)	
BN	Flatten	ReLU	BN
	Dense 128	Dropout $D_\beta$	
	BN	$(2 \times 2)$ Maxpo	
	ReLU	$(2 \times 2)$ Conv(32)	
ReLU	Dropout $D_\beta$	ReLU	ReLU
		Dropout $D_\beta$	
		$(2 \times 2)$ Maxpo	
		Flatten	
Merge		Merge	
ReLU			
Dense 128			
BN			
Sigmoid			

## ▶ راه اندازی آزمایشی

▶ ا از 80٪ داده ها برای آموزش، 10٪ داده ها برای اعتبار سنجی و 10٪ داده ها برای آزمایش استفاده می کنیم. همه آزمایشات حداقل 10 بار به طور جداگانه انجام می شوند. زیرشاخه واضح متنی و زیرشاخه واضح تصویری به یک لایه متراکم متصل می شوند. پارامترهای موجود در این زیرشاخه ها را می توان به راحتی توسط الگوریتم پس انتشار خطا یاد گرفت. بنابراین، بیشتر پارامترها، که باید تنظیم شوند، در زیرشاخه پنهان متنی و زیر شاخه پنهان بصری وجود دارد. پارامترها به شرح زیر تنظیم می شوند:

# مدل - معماری

## ▶ شاخه متن

▶ برای زیر شاخه مخفی متنی، بعد تعبیه شده word2vec روی 100 تنظیم شده است. جزئیات نحوه انتخاب پارامترها در بخش تجزیه و تحلیل احساسات نشان داده شده است.

▶ word2vec روی ۱۰ کلمه تنظیم شده است. اندازه فیلتر در شبکه عصبی کانولوشن (۳، ۳) است، در کل ۱۰ فیلتر وجود دارد. برای بهبود قابلیت تعمیم مدل، دو نقطه پرت در نظر گرفته شده است. برای زیرشاخه صریح متنی، ابتدا یک لایه متراکم با ۱۰۰ نورون اضافه می کنیم و سپس یک لایه نرمال سازی دسته ای اضافه می کنیم تا فعالیت های لایه قبلی در هر دسته نرمال شود. تحولی را اعمال می کند که میانگین فعالیت را نزدیک به ۰ و انحراف معیار فعالیت را نزدیک به ۱ حفظ می کند. خروجی های زیرشاخه آشکار متنی و زیرشاخه ویژگی پنهان متنی با جمع کردن خروجی ها ترکیب می شوند.

# مدل - معماری

▶ شاخه تصاویر :

- ▶ برای زیرشاخه نهان بصری، تمام تصاویر به اندازه  $(50 * 50)$  تغییر شکل می یابند. سه لایه کانولوشن به صورت سلسله مراتبی به شبکه اضافه می شوند. اندازه فیلترها روی  $(3, 3)$  تنظیم شده است و  $32$  فیلتر برای هر لایه کانولوشن و به دنبال آن یک لایه فعال سازی **ReLU** وجود دارد. یک لایه **maxpooling** اندازه  $(2, 2)$  به هر لایه کانولوشن متصل است تا احتمال بیش برآزش را کاهش دهد.
- ▶ سرانجام یک لایه فعالسازی و مسطح سازی و نرمال سازی برای استخراج ویژگی های پنهان تصاویر به مدل اضافه می شود.
- ▶ برای زیرشاخه ویژگی تصاویر واضح، ورودی ویژگیهای آشکار با  $100$  نورون به لایه متراکم متصل می شود. و سپس یک لایه نرمال سازی و فعال سازی اضافه می شود.
- ▶ خروجی های شبکه عصبی کانولوشن تصویر و زیرشاخه ویژگی تصویر صریح با جمع بندی خروجی ها ترکیب می شوند. ما خروجی های متن و شاخه تصویر را بهم پیوند می دهیم. یک لایه فعال سازی و یک لایه متراکم، خروجی را به دو بعد تبدیل می کنند.
- ▶ اخبار توسط آخرین لایه فعال سازی سیگموئید برچسب دهی می شود.
- ▶ تعداد کل پارامترها  $7,509,980$  است و تعداد پارامترهای قابل آموزش  $7,509,176$  است.

# نتایج

▶ جدول ۴. نتایج تجربی در بسیاری از روشهای پایه. شماره بعد از نام مدل، طول ورودی حداکثر برای اطلاعات متنی است. برای آن دسته از خبرهای کمتر از ۱۰۰۰ کلمه، ما دنباله را با ۰ درج می کنیم.

<b>Method</b>	<b>Precision</b>	<b>Recall</b>	<b>F1-measure</b>
<b>CNN-image</b>	0.5387	0.4215	0.4729
<b>LR-text-1000</b>	0.5703	0.4114	0.4780
<b>CNN-text-1000</b>	0.8722	0.9079	0.8897
<b>LSTM-text-400</b>	0.9146	0.8704	0.8920
<b>GRU-text-400</b>	0.8875	0.8643	0.8758
<b>TI-CNN-1000</b>	<b>0.9220</b>	<b>0.9277</b>	<b>0.9210</b>

# مدل - معماری

## نتایج آزمایشات

ما مدل خود را با چندین روش پایه رقابتی در جدول ۴ مقایسه می کنیم. مدل با اطلاعات تصویر به تنهایی نمی تواند اخبار جعلی را به خوبی شناسایی کند. این نشان می دهد که اطلاعات تصویر برای شناسایی اخبار جعلی کافی نیست. با استفاده از اطلاعات متنی، از روش یادگیری ماشین سنتی - رگرسیون لجستیک برای کشف اخبار جعلی استفاده می شود. با این حال، رگرسیون لجستیک در شناسایی اخبار جعلی با استفاده از اطلاعات متنی موفق نیست. دلیل آن این است که ابر صفحه خطی است، در حالی که داده های خام به طور خطی تفکیک نمی شوند. GRU و حافظه کوتاه مدت طولانی (LSTM با اطلاعات متن با توالی های بسیار طولانی ناکارآمد هستند و مدل با طول ورودی ۱۰۰۰ عملکرد بدتری دارد. از این رو، ما طول ورودی ۴۰۰ را به عنوان روش پایه در نظر می گیریم. با اطلاعات متنی و تصویری، TI CNN به طور قابل توجهی از تمام روش های پایه بهتر عمل می کند.

# تجزیه و تحلیل میزان حساسیت

▶ در این بخش، اثربخشی چندین پارامتر در مدل پیشنهادی، ابعاد تعبیه کلمه، اندازه دسته ها، ابعاد لایه های مخفی، احتمال نقاط پرت و اندازه فیلتر را بررسی می کنیم.

▶ بعد تعبیه کلمات :

▶ در شاخه متن، ما از یک شبکه عصبی ۳ لایه برای یادگیری کلمه نگاشت استفاده می کنیم. بردار کلمه آموخته شده را می توان به عنوان برداری با ابعاد مختلف، از ۵۰ تا ۳۵۰ تعریف کرد. در شکل ۶ (a)، رابطه بین ابعاد تعبیه شده کلمه و عملکرد مدل را رسم می کنیم. در شکل ۶ (الف) رابطه بین ابعاد نگاشت کلمه و عملکرد مدل ترسیم شده است. همانطور که در شکل ۶ (الف) نشان داده شده است مشاهده می کنیم که با افزایش ابعاد تعبیه کلمه از ۵۰ به ۱۰۰، دقت و صحت و معیار  $f1$  افزایش می یابد. با این حال، دقت و صحت از ۱۰۰ به ۳۵۰ کاهش می یابد.  $recall$  مدل با افزایش ابعاد تعبیه کلمه در حال رشد است. ما ۱۰۰ را به عنوان ابعاد تعبیه کلمات در نظر می گیریم تا اندازه گیری  $recall$ ،  $precision$  و  $f1$  متعادل باشد. برای شناسایی اخبار جعلی در برنامه های دنیای واقعی، مدل که  $recall$  بالایی داشته باشد انتخاب خوبی است. علت این است که ناشران میتوانند از مدلی که  $recall$  بالایی دارد برای جمع اوری تمام اخبار جعلی مشکوک استفاده کند سپس اخبار جعلی را به صورت دستی شناسایی کند.

# مدل - معماری

## ▶ اندازه دسته ها

▶ اندازه دسته ها تعداد نمونه هایی است که قرار است از طریق شبکه منتشر شود هر چه اندازه دسته ها بزرگ تر باشد فضای حافظه بیشتری برای برنامه نیاز است . هرچه اندازه دسته کمتر باشد، فرایند آموزش زمان کمتری خواهد داشت. رابطه بین اندازه دسته ای و عملکرد مدل در شکل ۶ (ب) نشان داده شده است. بهترین انتخاب برای اندازه دسته ۳۲ و ۶۴ است. معیار F1 ابتدا از اندازه دسته ۸ به ۳۲ بالا می رود و سپس وقتی از اندازه دسته از ۳۲ به ۱۲۸ افزایش می یابد کاهش می یابد. برای اندازه دسته ۸، آموزش داده ها در هر دوره ۳۲ ثانیه طول می کشد. برای اندازه دسته ۱۲۸، آموزش مدل در هر دوره بیش از ۱۰ دقیقه هزینه دارد.




# مدل - معماری

## ▶ ابعاد لایه مخفی :


- ▶ همانطور که در شکل ۵ پیداست در مدل لایه های مخفی زیادی وجود دارد. تصمیم گیری در مورد تعداد نورون ها در لایه مخفی نقش مهمی در تصمیم گیری در باره کل شبکه عصبی دارد. اگرچه این لایه ها به طور مستقیم با محیط خارجی ارتباط برقرار نمی کنند، اما تأثیر زیادی بر خروجی نهایی دارند. استفاده از تعداد بسیار کمی از نورون ها در لایه های پنهان منجر به عدم تناسب می شود. همانطور که در شکل ۶ (C) نشان داده شده است، متوجه می شویم که ۱۲۸ بهترین گزینه برای بعد لایه پنهان است. ابتدا عملکرد با افزایش بعد لایه پنهان از ۸ به ۱۲۸ افزایش می یابد. با این حال، بعد لایه پنهان به ۲۵۶ می رسد، عملکرد مدل به دلیل بیش برآزش کاهش می یابد.
- ▶ شکل ۷. احتمال نقاط پرت (  $Da$ ،  $DB$  )، اندازه فیلتر و عملکرد مدل .

# مدل - معماری

احتمال نقاط پرت ▶



(a) Dropout probabilities ( $D_\alpha, D_\beta$ ) and the performance of the model.



(b) Filter size and the performance of the model.

# نتایج و کارهای آینده :

- ▶ در این مقاله، ما یک مدل واحد، به عنوان مثال، **TI CNN** را پیشنهاد می دهیم، که می تواند اطلاعات متن و تصویر را با ویژگی های آشکار و پنهان مربوطه ترکیب کند. مدل پیشنهادی دارای قابلیت توسعه پذیری بالایی دارد که می تواند سایر ویژگی های اخبار را به راحتی جذب کند. علاوه بر این، شبکه عصبی کانولوشن مدل را قادر می سازد تا کل ورودی را در یک زمان ببیند و می توان آن را بسیار سریعتر از **LSTM** و بسیاری از مدل های **RNN** دیگر آموزش داد.
- ▶ ما آزمایشاتی را روی مجموعه داده های جمع آوری شده قبل از انتخابات ریاست جمهوری انجام می دهیم. نتایج آزمایش نشان می دهد که **TI CNN** می تواند اخبار جعلی را براساس ویژگی های صریح و ویژگی های نهفته ای که از نوروں های کانولوشن آموخته اند، با موفقیت شناسایی کند. مجموعه داده های این مقاله به اخبار مربوط به انتخابات ریاست جمهوری آمریکا می پردازد. برای بررسی بیشتر تفاوت بین اخبار جعلی و واقعی به زبان های دیگر، داده های بیشتری را درباره انتخابات ملی فرانسه بررسی می کنیم. همچنین این یک مسیر امیدوار کننده برای شناسایی اخبار جعلی با اطلاعات شبکه اجتماعی بیشتر مانند ساختارهای شبکه اجتماعی و رفتارهای کاربران است. علاوه بر این، ارتباط بین سرفصل ها و متن های خبری یک موضوع تحقیقاتی بسیار جالب است، که برای شناسایی اخبار جعلی مفید است. به عنوان توسعه شبکه های خصمانه تولیدی **GAN** تصویر می تواند عنوان ایجاد کند. این یک روش جدید برای ارزیابی ارتباط بین تصویر و متن خبر فراهم می کند.