

## کدبرداری از کدهای خطی بر مبنای معادله سندرم با استفاده از یادگیری عمیق

DOR: 20.1001.1.27832570.1400.2.1.2.3

علی مرادی

دانشگاه شهید باهنر - دانشکده مهندسی کامپیوتر - کرمان - ایران - moradi.ali2@gmail.com

**چکیده:** استفاده از کدهای طول کوتاه در ارتباطات دیجیتال به خاطر فراگیر شدن پدیده اینترنت اشیا از اهمیت ویژه‌ای برخوردار است. از طرفی مدل‌های یادگیری عمیق در زمینه‌های مختلفی مانند تشخیص اشیاء و تشخیص گفتار نتایج لبه علمی را بدست آورده‌اند. از این میان شبکه‌های کانولوشنی نقش اساسی در موفقیت مدل‌های یادگیری عمیق دارند. برای افزایش دقت کدبرداری کدهای طول کوتاه LDPC (Low Density Parity Check Codes) بر مبنای معادله علامت از شبکه کانولوشنی استفاده گردید. برای تعیین جواب معادله علامت از روش تشخیص الگوی خطا بهره‌گرفته شد. به این منظور، نخست شبکه کانولوشنی یک بعدی با سه لایه اصلی که هر لایه شامل زیرلایه‌های کانولوشن و ادغام می‌باشند، استفاده شد؛ و سپس خروجی شبکه کانولوشنی بر شبکه برگشتی GRU اعمال گردید. شبکه برگشتی GRU با تعداد سه برابر طول کدواژه با تابع فعالسازی ReLU مورد استفاده واقع گردید. تعیین مقدار ابرپارامترهای شبکه عصبی مورد استفاده ابتدا به صورت مقادیر پیش فرض کتابخانه تنسورفلو نسخه ۲ مقدار دهی شد و در برخی موارد برای افزایش دقت تغییر داده شدند. مقایسه بین مدل ترکیبی حاصل از شبکه کانولوشنی یک بعدی و شبکه برگشتی با مدل شبکه برگشتی نشان می‌دهد که برای کد LDPC با طول ۶۴ در کاهش نرخ خطای بیت، مدل ترکیبی حاصل از شبکه کانولوشنی و شبکه GRU بهتر عمل می‌کند. نرخ خطای بیت در شرایط نویزی مختلف به میزان ۰.۵ تا ۰.۸ دسیبل کمتر از میزان کدبردار پیشینه‌گر احتمال می‌باشد. همچنین ما نشان دادیم که شبکه‌های کانولوشنی در کنار شبکه‌های برگشتی پتانسیل این امر را دارند که بتوانند عملکرد چنین شبکه‌هایی را بهبود ببخشند.

واژه‌های کلیدی: کدینگ، یادگیری عمیق، شبکه‌های کانولوشنی، کدهای LDPC

## A Syndrome Based Decoding of Linear Codes Using Deep Learning Method

Ali Moradi

Shahid Bahonar University of Kerman- Faculty of Computer Engineering- Kerman- Iran- moradi.ali2@gmail.com

**Abstract:** Using short-length codes has height degree of importance because of the Internet-of-Things ubiquitous applications. On the other hand, Deep Learning Methods have acquired state-of-the-art in object detection, speech processing, and other fields. Meanwhile, Convolutional Neural Network (CNN) models play a fundamental role in Deep Learning methods success. We used the CNN model for boosting the accuracy of syndrome-based decoding of Low-Density Parity-Check Codes (LDPC). And for determining the solution of syndrome equations, we used an error pattern recognition method. To do so, we used a three-layered CNN in which any layer contains a pooling and convolution sub-layer. Then the output of CNN was applied to Gated Recurrent Unit (GRU). We used GRU recurrent network with rectified linear unit (ReLU) activation function, and node counts as three times as codeword-length. We used the Tensorflow library's default value for hyperparameters. For some hyper-parameters, we altered manually for accuracy improvement reasons. Comparing the mixed model and bare recurrent model showed that for LDPC code, with a length of 64, the bit error rate drops when we used the combinatory model. In different signal-to-noise conditions, the bit error rate drops 0.5 to 0.8 Db toward the Maximum Likelihood decoder. Also, we showed that CNNs have the potential to improve the recurrent network accuracy.

**Keywords:** Coding, Deep Learning, Convolutional Neural Networks, LDPC Codes

تاریخ ارسال مقاله: ۱۴۰۰/۰۲/۲۸

تاریخ پذیرش مقاله: ۱۴۰۰/۰۴/۲۷

## ۱. مقدمه

گسترش سریع اینترنت بسیاری از مسائل امنیت شبکه همچون نشت اطلاعات شخصی، حملات هکرها و ویروس‌های تهدیدآمیز (بدون امضا) را به همراه داشته است و موضوع امنیت سایبری مسئله‌ی مهم قرن بیست و یکم شده است. مسائلی همچون طغیان جنگ سایبری، نیازهای امنیت شبکه را بیش از پیش تهییج کرده است و ارزیابی وضعیت امنیت سایبری به منظور رفع کارآمد این قبیل مشکلات امنیتی بسیار ضروری است.

اتحادیه بین‌المللی مخابرات، اولین نسخه از راهنمای راهبرد امنیت سایبر را در سال ۲۰۰۸ و نسخه اصلاحی این شاخص را برای اندازه‌گیری کمی سطح پیشرفت امنیت سایبری در کشورها طراحی کرده است. هدف نهایی اتحادیه بین‌المللی مخابرات از تهیه این شاخص تقویت فرهنگ جهانی امنیت سایبری است. این شاخص شامل پنج مؤلفه‌های قوانین و مقررات، اقدامات فنی، ساختارهای اجرایی و سازمانی، ظرفیت سازی، همکاری ملی و بین‌المللی می‌باشد.

کدینگ ارتباط قابل اطمینانی را بر روی کانالهای نویزی و نامطمئن میسر می‌سازد. به این صورت که با کدگذاری پیام به وسیله بیت‌هایی که به آن می‌افزاید، خطاهای اعمال شده توسط نویز کانال را می‌توان تصحیح کرد و یا نرخ خطا را به حد قابل قبولی رساند. کدهای مدرن به نرخ خطای بسیار پایین برای کدهای با طول زیاد دست یافته‌اند ولی کدهای با طول زیاد در کاربردهایی که نیاز به تاخیر کم دارند قابل قبول عمل نمی‌کنند. شیوع استفاده از ابزارهای ارتباطی در قالب اینترنت اشیاء نیازمند طراحی کدهایی با تأخیر کم می‌باشد و این به معنی نیاز به طراحی کدهایی با طول کوتاه می‌باشد که همچنان به‌عنوان یک مسئله حل نشده در این حوزه باقی مانده است.

استفاده از کدینگ در سیستم‌های ارتباطی و انتقال اطلاعات به قدری حائز اهمیت می‌باشد که در هر گوشی تلفن همراه نسل ۲ تا نسل ۵ یکی از الگوریتم‌های کدینگ مورد استفاده قرار گرفته است. در حقیقت کدینگ زیربنای ارتباط سالم و با کیفیت را فراهم می‌کند. از طرفی، موفقیت‌هایی که مدهای یادگیری عمیق در حوزه‌های پردازش تصویر و گفتار بدست آورده‌اند حاکی از قدرت این گونه الگوریتم‌ها در تشخیص الگوها می‌باشد و از این روی در کدینگ نیز برای کشف الگوهای خطایی که بر روی کد واژه‌ها حین عبور از کانال بر آنها اعمال می‌شود، اهمیت کاربرد این الگوریتم‌ها را برای بهبود کیفیت کدینگ افزایش داده است. توسعه ارتباط دیجیتال با قابلیت اطمینان بالا، در وهله اول به وسیله طراحی کدهایی میسر شده است که به گیرنده این امکان را می‌دهد تا بتواند پیام ارسال شده را به‌صورت کارا و صحیح در شرایط کانال نویزی بازیابی کند. با وجود نویز بعنوان ویژگی و مشخصه ذاتی کانال‌های ارتباطی، این علم کدینگ است که از بدو ظهور سیستم‌های ارتباطی دیجیتال توانسته است انتقال صحیح و بدون

خطای اطلاعات را در طیف گسترده‌ای از سیستم‌های ارتباطی فراهم کند. رشته نظریه کدینگ در طول هفت دهه گذشته پیشرفت شایانی را تجربه کرده است و ما اکنون شاهد کدهای نزدیک به کد بهینه برای کدهای با طول نسبتاً زیاد هستیم [۹].

در سال ۱۹۴۸ شانون در مقاله معروف خود [۱] چارچوب ریاضی و نظری سلسله پژوهش‌هایی را پی ریزی کرد که اکنون با عنوان نظریه کدینگ یا کدهای تصحیح کننده خطا شناخته می‌شود. جان کلام نظریه شانون این بود که اگر نرخ انتقال سیگنال در یک سیستم از ظرفیت کانال کمتر باشد، ارتباط بدون خطا با انتخاب روش کدگذاری و کدبرداری مناسب قابل دستیابی خواهد بود؛ و مهمتر اینکه شانون اثبات می‌کند هر کدی هر چند بسیار بزرگ می‌تواند به این ظرفیت برسد و البته از جزئیات و نحوه ساخت این کدها و همچنین از نحوه کدگذاری و کدبرداری آن‌ها سخنی به میان نیاورده است. نکته جالب در کار آقای شانون، علاوه بر اثبات وجود کدهایی با نرخ انتقال نزدیک به ظرفیت کانال، اینست که این کدها را می‌توان ساخت ولی هزینه عملیات کدگذاری و کدبرداری از این کدها (پیچیدگی محاسباتی) بسیار بالا خواهد بود. با این وجود مقاله ایشان سرآغاز تلاشهای محققان برای ساخت کدهایی با پیچیدگی محاسباتی کم شده است. تلاش برای طراحی این نوع کدها و روش‌های کدبرداری کارا توسط همینگ و سایر دانشمندان در دهه ۱۹۴۰ میلادی آغاز شد و تا کنون توجه بسیاری از پژوهشگران را معطوف خود ساخته است. از جمله کدهای خطی معروف که توانسته است به حد شانون نزدیک شود کدهای خلوت (LDPC<sup>2</sup>) هستند که اولین بار توسط گلگر در اوایل دهه ۱۹۶۰ میلادی ارائه شدند [۲] و به مدت ۲۰ سال نادیده گرفته شدند.

در سال ۱۹۸۱ دانشمندی به نام تنر<sup>۳</sup> تفسیر گرافیکی از کدهای خلوت ارائه داد ولی بازهم این کدها مورد اقبال قرار نگرفتند. در دهه ۱۹۹۰ گروهی از پژوهشگران، کدهای خلوت را با تعمیم گسترده‌تری دوباره کشف کردند؛ به‌طوری‌که کدهای خلوت با طول زیاد با الگوریتم کدگذاری انتشار باور تکراری تا رسیدن به حد شانون فقط کسری از دسی‌بل فاصله دارند [۳]. تمایل برای به‌کارگیری شبکه‌های عصبی در کد برداری از دوران دهه ۸۰ میلادی وجود داشته است. این کارهای اولیه به دلیل محدودیت‌های شبکه‌های عصبی موفقیت چندانی نداشتند. از طرفی روش‌های کدبرداری مبتنی بر تکرار مانند الگوریتم انتشار باور بر روی کدهای با طول بیش از ۱۲۸ نرخ خطای بیت پایینی را کسب کرده و به حد شانون رسیده‌اند و برای کدهای با طول کم کارایی مناسبی ندارند [۴]. کدهای با طول کم به دلیل کاربردشان در زمینه اینترنت اشیاء بسیار مورد تقاضا و مهم می‌باشند؛ بنابراین یکی از چالش‌های پیش روی کدینگ، کاهش نرخ خطای بیت برای کدهای با طول کم است.

## جدول ۱ - خلاصه پیشینه پژوهش

نام مرجع	کارهای قبل از یادگیری عمیق	Nachmani 2017	Lugosch 2017	Gruber 2017	Bennaten 2018
نقطه قوت	استفاده از شبکه عصبی	حل مشکل بیش برآزش - استفاده از تنها یک کدواژه	استفاده از جمع کمینه	برای گذرواژه نسبتاً کوتاه	معادله علامت
نقطه ضعف	محدودیت قدرت پردازش و دقت پایین	محدودیت معماری مدل	محدودیت معماری مدل	تعداد پارامتر زیاد	تعداد پارامتر زیاد
محدودیت معماری شبکه عصبی	دارد	دارد	دارد	ندارد	ندارد
غلبه بر بیش برآزش	ندارد	دارد	دارد	دارد	دارد
شبکه برگشتی	استفاده نشده	استفاده شده	استفاده شده	استفاده نشده	استفاده شده
شبکه کانولوشنی	استفاده نشده	استفاده نشده	استفاده نشده	استفاده نشده	استفاده نشده
پیش پردازش کدواژه	دارد	دارد	دارد	ندارد	دارد

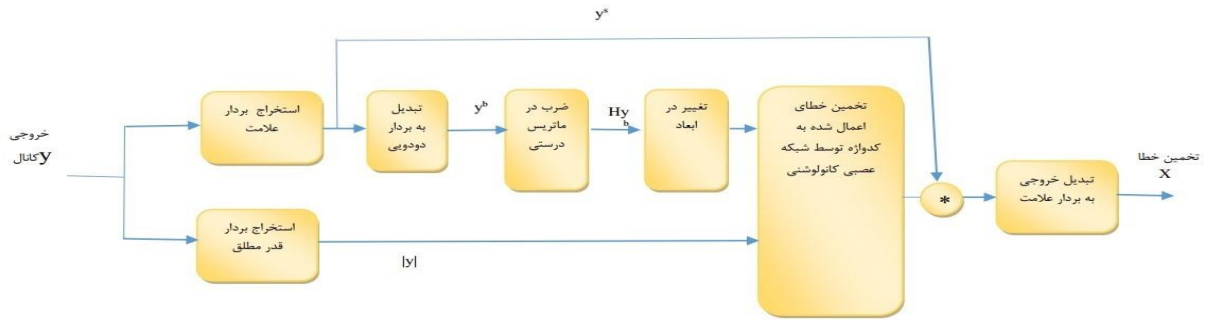
## ۲. روش تحقیق

ما در این پژوهش بر آنیم که با استفاده از شبکه‌های عصبی کانولوشنی نرخ خطای بیت در کدبرداری کدهای خطی را کاهش دهیم. مسئله پژوهش حاضر کاهش هزینه محاسباتی و افزایش دقت کدبرداری بر مبنای معادله سندرم است که ما این کار را با استفاده از شبکه‌های کانولوشنی انجام می‌دهیم. مطابق شکل ۱- پس از دریافت خروجی کانال نویزی مراحل زیر بر روی آن انجام می‌شود. جهت کدبرداری از کدواژه عبور داده شده از کانال نویزی با نویز گوسی، یعنی  $y$ ، به این صورت عمل می‌شود که با اعمال عملگر علامت که برای هر سیگنال دریافت شده علامت آن را استخراج می‌کند، برداری به طول  $n$  شامل ۱ و -۱ خواهیم داشت. سپس عملگر باینری بر روی بردار اعمال می‌شود که در آن ۱ به ۰ و -۱ به ۱ تبدیل می‌شود. سپس حاصل در ماتریس درستی ضرب شده که همان معادله علامت خوانده می‌شود و با ایجاد تغییر در ابعاد آن به همراه قدر مطلق خروجی کانال به ورودی شبکه عصبی کانولوشنی اعمال می‌شود. برای بهترین تخمین از الگوی خطا، همین دو آیتم قدر مطلق خروجی کانال و معادله علامت کافی است. خروجی شبکه نیز پس از ضرب شدن در بردار علامت، برآورد الگوی خطا را در خود دارد؛ که با جمع این الگوی خطا با کدواژه دریافت شده، بردار حاوی پیام اصلی و بدون خطا را خواهیم داشت.

همان گونه که در بخش قبل بیان گردید، مسئله اصلی در این پژوهش ساخت کدهایی با طول کوتاه و نزدیک به ظرفیت کانال با پیچیدگی محاسباتی کم است. کارهای قبلی صورت گرفته برای حل این مسئله شامل دو رویکرد کلی با استفاده از شبکه‌های عصبی عمیق می‌شوند. رویکرد نخست با استفاده از ساختار گراف تر و شبکه عصبی منطبق با آن توانسته است به مقدار  $9/0$  دسی‌بل دقت کدبرداری از کدهای خطی را بهبود ببخشد و در کاری دیگر با همین رویکرد با پیوند پارامترهای شبکه عصبی به یکدیگر، از مزیت شبکه عصبی برگشتی استفاده شده و تعداد پارامترها کاهش داده شده و در نتیجه از هزینه محاسباتی کاسته شده است.

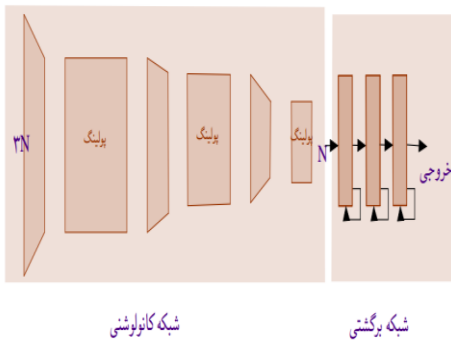
دو مقاله [۴] و [۵] با استفاده از خاصیت مستقل بودن کارایی الگوریتم انتشار باور از کدواژه و نیز استفاده از ساختار گراف تر مورد استفاده در الگوریتم انتشار باور به عنوان ساختار معماری شبکه عصبی، الگوریتمی پیشنهاد داده‌اند که مشکل بیش برآزش را ندارد. مشکل کار ایشان این است که معماری شبکه عصبی استفاده شده محدود به چهار چوب ساختار گراف تر شده است و نمی‌توان از مزایای معماری‌های مختلف شبکه‌های عمیق بهره برد.

رویکرد دیگر برای مواجهه با مشکل بیش برآزش استفاده از روش کدبرداری بر مبنای معادله علامت<sup>۴</sup> است. در این روش با جدا کردن نویز از کدواژه، نیاز به استفاده از کدواژه‌های مختلف برای آموزش شبکه مرتفع می‌شود؛ و به این صورت می‌توان شبکه عصبی را با تنها یک کدواژه آموزش داد تا مسئله بیش برآزش حل شود. مکانیسم کدبرداری با استفاده از معادله علامت ایجاب می‌کند که بخشی از سیستم کدینگ وظیفه تشخیص نویز اعمال شده را داشته باشد. استفاده از شبکه‌های عصبی برای انجام وظیفه تشخیص الگوی خطا زمینه را برای استفاده از پتانسیل قوی شبکه‌های عصبی در زمینه کدبرداری فراهم می‌کند. انتخاب معماری شبکه عصبی که بتواند به صورت کارا و مؤثری این وظیفه را انجام دهد مسئله مورد نظر در این پژوهش است. یکی از چالش‌های مهم برای استفاده از شبکه‌های عصبی کاملاً متصل و برگشتی تعداد زیادی پارامتر شبکه عصبی است. شبکه‌های کانولوشنی به دلیل داشتن مزیت اشتراک پارامترها و اتصال خلوت، راهکار بسیار مناسبی برای این مشکل است که در زمینه‌های تشخیص اشیاء، طبقه‌بندی تصاویر و تشخیص گفتار و ترجمه ماشینی موفقیت‌هایی در حد لبه علمی به دست آورده است. در جدول شماره ۱ پیشینه پژوهش به صورت خلاصه و طبقه‌بندی شده آورده شده است.



شکل ۱- دیاگرام منطقی ارتباط بین متغیرها

تابع هزینه مشتق می‌گیریم. این مشتق‌گیری توسط الگوریتم مشتق‌گیری پس انتشار صورت می‌گیرد.



شکل ۲ - ترکیب شبکه کانولوشنی و برگشتی


این امر در شبکه‌های برگشتی و کانولوشنی نیز صادق است. ما برای بهبود کارایی شبکه برگشتی، ابتدا کدواژه‌ها را توسط شبکه کانولوشنی پردازش و سپس به شبکه برگشتی وارد می‌کنیم. این کار دقت کدبرداری را افزایش می‌دهد. در شکل ۲ این امر مشاهده می‌شود.

ترکیب دو نوع شبکه برگشتی و کانولوشنی برای افزایش دقت کدبرداری است که پیاده‌سازی آن در محیط کتابخانه تنسورفلو ۲,۰ انجام گرفت. مزیت ترکیب این دو شبکه پرکاربرد و قدرتمند پتانسیل زیادی برای کشف الگوهای پنهان در درون داده‌ها دارد و ما با استفاده از این پتانسیل الگوی خطای نهفته در کدواژه‌های را کشف کنیم. مقادیر ابر پارامترها ابتدا به صورت پیش فرض تنسورفلو قرار داده شد و سپس برای افزایش دقت با انجام آزمایش‌های مختلف برخی از آن‌ها تغییر داده شد. شبکه کانولوشنی سه لایه برای بخش ابتدایی مدل استفاده گردید. هر لایه شامل دو زیر لایه ادغام و کانولوشن می‌باشند. تابع فعالیت ReLU هم در شبکه برگشتی و هم در کانولوشنی مورد استفاده قرار گرفت. در ابتدای امر به دلیل اینکه مقادیر پارامترها تأثیر مستقیمی بر روی نتایج کار دارد. این پارامترها عبارت‌اند از نرخ یادگیری در الگوریتم ADAM که ما برای این الگوریتم آن را برابر با ۰,۰۰۱ قرار دادیم. برای کامپایل مدل نیز از هر دو تابع MSE و Binary-Cross-Entropy استفاده کرده‌ایم که با تابع MSE نتیجه بهتری حاصل شده است. تعداد

رویکرد دوم مبتنی بر استفاده از معادله سندم است. معادله سندم در حقیقت برای تشخیص این که در دریافت کدواژه خطایی رخ داده است یا نه به کار می‌رود. این معادله در رابطه (۱/۱) آورده شده است که در آن  $r$  بردار کدواژه و  $H$  ماتریس توازن هستند و وقتی  $r$  معتبر است که این معادله برابر با صفر قرار داده شود. که منجر به یک دستگاه با  $n-k$  معادله با  $n$  مجهول می‌شود. اینکه بتوان الگوی خطایی که رخ داده است را نیز تشخیص داد کاری است که با حل تعداد  $n-k$  معادله با  $n$  مجهول که در آن  $n$  طول کدواژه و  $k$  نیز تعداد بیت‌های اضافه‌شده به عنوان بیت‌های توازن به پیام است، انجام می‌دهد. به تعداد  $K^2$  جواب برای معادله‌های سندم وجود دارد که تنها یکی صحیح است؛ بنابراین این یک مسئله از مرتبه نامایی است. برای کمینه کردن احتمال خطای کدگشایی باید محتمل‌ترین الگوی خطایی که در معادلات سندم صدق می‌کند را به عنوان الگوی خطا انتخاب کنیم. به یاد داریم که کدگشایی درست‌نمایی بیشینه نیز کدواژه‌ای را انتخاب می‌کند که فاصله همینگ الگوی خطا را کمینه کند.

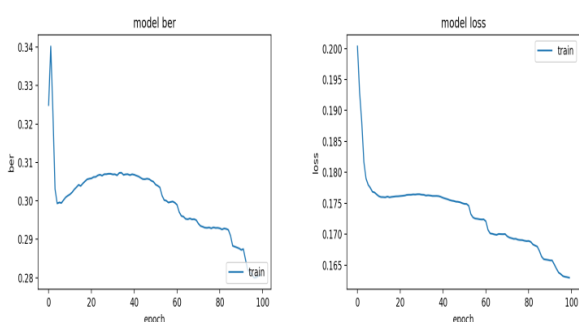
$$S = (S_0, S_1, \dots, S_{n-k-1}) = rH^T = 0 \quad (1.0)$$

با استفاده از شبکه عصبی عمیق می‌توان این کدگشایی را انجام داد. آنچه انجام شده است این است که شبکه عمیق استفاده شده یک شبکه کاملاً متصل است و این منجر به افزایش تعداد پارامترهای شبکه و نیز به تبع آن هزینه محاسباتی می‌شود. با وجود اینکه روش مبتنی بر سندم مشکل محدودیت معماری شبکه عصبی را ندارد ولی تعداد بسیار زیاد پارامترهای شبکه، خود مانع بزرگی برای کارا بودن الگوریتم است. بنابراین مسئله اساسی در پژوهش حاضر کاستن از هزینه محاسباتی الگوریتم کدبرداری بر مبنای معادله علامت است؛ که برای این منظور می‌توان با کاستن تعداد پارامترهای شبکه عصبی مورد استفاده برای کدبرداری، از بار محاسباتی عمل کدبرداری کاست. در شبکه‌های عصبی هدف یافتن مقدار بهینه پارامترها است که این امر به واسطه محاسبه خروجی شبکه برای ورودی‌های آموزشی و مقایسه خروجی شبکه با مقدار واقعی خروجی و کاهش دادن این فاصله تا حد امکان صورت می‌گیرد. برای یافتن مقدار کمینه خطا ما از



شکل ۳ - نتایج نرخ خطای بیت بر اساس مقادیر ابر پارامترها

نشان می‌دهد. هر چه تعداد دوره‌های آموزشی بیشتر می‌شود به دلیل عملکرد صحیح مدل، مقدار تابع هزینه کاهش می‌یابد.



شکل ۴ - نتایج عملکرد مدل برای کاهش نرخ خطای بیت

تعیین تعداد بهینه ایپاک‌ها با تکیه بر مقایسه مقدار هزینه در حین آموزش و حین آزمایش مدل صورت می‌گیرد. ما مقدار تابع هزینه را برای تعداد ایپاک‌های مختلف اندازه‌گیری می‌کنیم و سپس در حین آزمایش مدل نیز چنانچه مقدار تابع هزینه افزایش بدون دلیل داشته باشد در همان تعداد ایپاک آموزش را متوقف می‌کنیم. برای مدل ما تعداد صد ایپاک (دور) بهترین نتیجه را داشته است. پس از اینکه مدل به خوبی آموزش دید و توانست نتیجه قابل قبولی در کاهش مقدار تابع هزینه و نرخ خطای بیت برای داده‌های آموزشی به دست آورد باید قادر باشد تا با داده‌های آزمون که قبلاً با آن‌ها آموزش ندیده است کمترین نرخ خطا را داشته باشد. داده‌های آموزشی در شرایط نویزی با بازه نسبت سیگنال به نویز ۱ تا ۵ آموزش دیده‌اند و شرایط داده‌های آزمون نیز به همین منوال است. شکل-۵- آ نتیجه کدبرداری در شرایط نویزی ذکر شده برای کد خطی LDPC با طول ۶۴ را نشان می‌دهد. همان‌طور که در شکل نمایش داده شده است کدبردار طراحی شده در اکثر مواقع در شرایط نویزی مختلفی بهتر از کدبردار پایه بیشینه‌گر احتمال پسین عمل می‌کند. و در پایان برای مقایسه، نتیجه کدبرداری با مدلی که در آن شبکه کانولوشنی استفاده نشده و فقط با شبکه برگشتی آموزش دیده است را در شکل-۵-ب نشان داده‌ایم. این نوع معماری شبکه برگشتی بر اساس کار بنناتن [۹] ساخته و آموزش دیده شده است. برای مقایسه با سایر روش‌های جدول شماره ۱، در شکل شماره ۶ نتایج مشابه برای روشهای مقالات [۱ و ۹] آورده شده است.


لایه‌ها در شبکه برگشتی و شبکه کانولوشنی، اندازه فیلتر مورد استفاده در شبکه کانولوشنی، تابع فعال‌سازی در لایه‌های مختلف، اندازه لایه‌های پولینگ در شبکه کانولوشنی و همچنین پدینگ از جمله پارامترهای مهم در مدل ما هستند که مقادیر آن‌ها را طوری انجام دادیم که بهترین نتیجه حاصل گردد. داده‌های آموزش با اعمال طیف ۰ تا ۵ دسی‌بل نویز سفید گوسی<sup>۵</sup> به کد واژه‌ها با طول ۶۴ ساخته شده‌اند. در همه آزمایش‌های انجام شده مقدار نسبت سیگنال به نویز (SNR) را برای داده‌های آموزشی و هم برای داده‌های آزمایش، یکسان در نظر گرفته‌ایم. تابع ضرر مورد استفاده ما به شکل زیر است:

$$L = \frac{1}{N} \sum_{t=1}^T \sum_{i=1}^N Y^{T-t} H_{CE}(\tilde{z}_i^s, \hat{z}_i^s(t)) \quad (2.0)$$


که در آن  $N$  طول کد،  $T$  تعداد کل گامهای زمانی،  $Y$  ضریب تخفیفکه ما آنرا برای همه گامهای زمانی برابر با ۰٫۵ قرار دادیم، تابع  $H_{CE}$  Cross-entropy،  $\tilde{z}_i^s$  علامت کدواژه  $i$ -ام و  $\hat{z}_i^s(t)$  نیز خروجی شبکه برگشتی در گام زمانی  $t$ -ام برای کدواژه  $i$ -ام است. ما در نمودارهایمان از کدبرداری پایه MAP به‌عنوان معیار برای مقایسه استفاده کرده‌ایم. این داده‌ها از سایت گیت‌هاب<sup>۶</sup> تهیه شده است. معیار مقایسه عملکرد روش ما بیشینه‌گر احتمال پسین<sup>۷</sup> یا همان MAP است. دلیل اینکه ما نتایجمان را با بیشینه‌گر احتمال پسین مقایسه کرده‌ایم این است که این معیار پایه برای کدبرداری است و مقایسه با این معیار امری رایج است [۶].

### ۳. یافته‌ها

همان‌طور که در شکل-۳ دیده می‌شود نتایج مختلفی با تغییر دستی ابر پارامترهای مدل به دست آمده و در یکی از نتایج عملکرد کدبرداری بهتر از کدبرداری MAP داشته است. ما از پیکره‌بندی‌های موفق مدل‌های یادگیری عمیق که در [۷] و [۸] پیشنهاد شده‌اند استفاده کرده‌ایم. پس از یافتن پیکره‌بندی مناسب پارامترها نوبت به نمایش نحوه عملکرد مدل در زمینه کاهش مقدار تابع هزینه (Loss) و نرخ خطای بیت (BER) می‌رسد. مدل در حین آموزش یاد می‌گیرد که مقدار تابع هزینه را کاهش دهد که این منجر به کاهش نرخ خطای بیت می‌شود. شکل ۴ نتایج عملکرد مدل در زمینه کاهش Loss نرخ خطای بیت را



شکل ۵- (ب) بدون استفاده از شبکه کانولوشنی



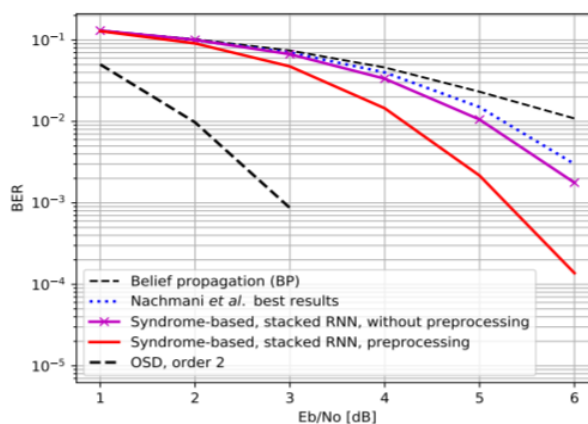
شکل ۵- (آ) با استفاده از ترکیب شبکه کانولوشنی و برگشتی

شکل ۵- نتایج حاصل از کدبرداری با مدل پیشنهادی

#### ۴. نتیجه گیری

ما با ترکیب شبکه کانولوشنی یک‌بعدی و شبکه برگشتی توانستیم کدبرداری از کدهای خطی بر مبنای معادله علامت را بهبود ببخشیم. در حقیقت ما با استفاده از پتانسیل ترکیب این دو نوع شبکه عصبی توانستیم الگوی خطای اعمال شده بر کدواژه‌ها که در حین عبور از کانال با نویز گوسی بر آن‌ها اعمال می‌شود را کشف کنیم و کدواژه اصلی ارسال شده از طرف فرستنده را با کمترین خطا در طرف گیرنده بازیابی کنیم.

از آنجا که تعیین پارامترهای مدل‌های یادگیری عمیق کاری طاقت‌فرسا و پرهزینه در حین ساخت مدل است روش‌های کدبرداری با استفاده از یادگیری عمیق با تکیه بر الگوریتم‌های فرا اکتشافی جهت تعیین پارامترها به‌عنوان پیشنهاد برای پژوهش‌های آینده مطرح می‌شود. این پژوهش‌ها می‌تواند در حوزه بهینه‌سازی مدل‌ها و یا بهینه‌سازی مقادیر پارامترها انجام شود؛ که به دلیل فراخ و بی‌نهایت بودن فضای مسئله، روش‌های فرا اکتشافی بهترین ابزار برای این کار شناخته شده است.



شکل ۶- مقایسه با سایر روش‌ها

#### ۵. مراجع

- [۱] E. Nachmani, E. Marciano, L. Lugosch, W. Gross, D. Burshtein و Y. Be'ery, "Deep learning methods for improved decoding of linear codes", *IEEE Journal of Selected Topics in Signal Processing*, ۲۰۱۸,
- [۲] Gruber, T et al, "On Deep Learning based decoding", *Annual Conference on Information Sciences and Systems (CISS)*, (۲۰۱۷).
- [۳] F. Chollette, *Deep Learning with Python in Keras*, MIT Press, ۲۰۱۷
- [۴] I. Goodfellow, Y. Benjio و A. couville, *Deep Learning*, Cambridge: MIT press, ۲۰۱۷
- [۵] E. Nachmani, Y. Be'ery و D. Burshtein, "Learning to decode linear codes using deep learning", *communication, control and computing*, Alerton, ۲۰۱۶
- [۶] D. J. C. A. S. Lin, *Error control coding: Fundamentals and applications*, ۱۹۸۲
- [۷] R. Gallager, "Low-density parity-check codes", *IRE Transactions on information theory*, شماره ۸, جلد ۱, pp. ۲۱-۲۸, ۱۹۶۲
- [۸] C. E. Shannon, "A mathematical theory of communication", *Bell system technical journal*, pp. ۳۷۹-۴۲۳, ۱۹۴۸
- [۹] e. a. A. Bennaten, "Deep learning for decoding of linear codes-a syndrome-based approach", *arXiv preprint arXiv:۲۰۱۸.۱۸۰۲.۰۴۷۴۱*

#### زیر نویس

1. Error Correcting Codes
2. Low Density Parity Check Code
3. Tanner
4. Syndrome Equation
5. Added White Gaussian Noise
6. <https://github.com/gruberto/DL/ChannelDecoding>
7. Maximum A-posteriori