

A Syndrome Based Decoding of Linear Codes Using Deep Learning Method

Ali Moradi¹, Mohammad Tahghighi Sharabyan^{2*}

1. MSc Student, Faculty of Electrical and Computer Engineering, Zanjan Branch, Islamic Azad University, Zanjan, Iran. moradi.ali2@gmail.com
2. Assistant Professor, Faculty of Electrical and Computer Engineering, Zanjan Branch, Islamic Azad University, Zanjan, Iran. (*Corresponding Author*) mntahghighi@gmail.com

Abstract

Introduction: The development of digital communication with high reliability has been made possible in the first place by designing codes that allow the receiver to recover the received message efficiently and correctly in noisy channel conditions. Coding theory has progressed tremendously over the past seven decades, and we now see near-optimal codes for relatively long codes. The private codes have reached the Shannon capacity limit using the belief propagation algorithm. Although this shows acceptable performance for relatively long codes, for medium and short codes, the belief propagation algorithm performs poorly. Hence, we are still facing challenges with short codes, which are of paramount importance currently in digital communication thanks to the spread of the Internet of Things. With the emergence of deep learning models that have obtained good results in various fields such as object recognition and speech recognition, the use of neural networks in the field of coding has been revived. Among these, convolutional networks, which play an essential role in the success of deep learning models, have been favored by researchers in the field of coding.

Method: To increase the coding accuracy of short-length LDPC (Density-Low Parity Check Codes) based on the sign equation and reduce its computational complexity, the combined architecture of a one-dimensional convolutional network, and recurrent neural network was used. To determine the solution of the sign equation, the error pattern detection method was utilized. For this purpose, first, a one-dimensional convolutional network with three main layers was used, each layer containing sublayers of convolution and integration. Then, the output of the convolutional network was applied to the return network of the GRU. The GRU return network with three times the length of the codeword was used with the ReLU activation function.

Findings: We consider Maximizer Posterior Probability or MAP as the comparison metric. The comparison between the combined model of the one-dimensional convolutional network and the return network with the pure return network model shows that for the 64-length LDPC code in reducing the bit error rate, the combined model of the convolutional network and the GRU network performs better. The bit error rate in different noise conditions is 0.5 to 0.8 dB less than the rate of maximum likelihood coder.

Discussion and Conclusion:

In the last few years, in the encoding method of linear codes based on the syndrome equation, methods based on deep learning are used to solve the equation of the symbol and also to detect the error pattern. We showed that convolutional networks have the potential to improve the performance of such networks.

Keywords: Text Attacks, Adversarial Examples, Loss function gradient, Sentiment Analysis, Natural Language Processing.

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

علی مرادی^۱، محمد تحقیقی شریبان^{۲*}

۱. دانشکده مهندسی برق و کامپیوتر، دانشگاه آزاد اسلامی واحد نجان، زنجان، ایران: moradi.ali2@gmail.com

۲. استادیار، گروه کامپیوتر، دانشکده مهندسی کامپیوتر، واحد زنجان، دانشگاه آزاد اسلامی، زنجان، ایران. mntahghighi@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 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 تانسورفلو نسخه ۲ مقداردهی 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 بیشینه‌گر 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 بخشند.

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

۱. مقدمه

گسترش سریع اینترنت بسیاری از مسائل امنیت شبکه همچون نشت اطلاعات شخصی، حملات هکرها و ویروس‌های تهدیدآمیز (بدون امضا) را به همراه داشته‌است و موضوع امنیت سایبری مسئله مهم قرن بیست و یکم شده‌است. مسائلی همچون طغیان جنگ سایبری، نیازهای امنیت شبکه را بیش از پیش تهییج کرده‌است 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 کرده‌است. هدف نهایی اتحادیه بین‌المللی مخابرات از تهیه این شاخص تقویت فرهنگ جهانی امنیت سایبری است. این شاخص شامل پنج مؤلفه قوانین و مقررات، اقدامات فنی، ساختارهای اجرایی و سازمانی، ظرفیت‌سازی، 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 اعمال‌شده 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 دست‌یافته‌اند و ولی کدهای با طول زیاد در کاربردهایی که نیاز به تأخیر کم دارند قابل قبول عمل نمی‌کنند. شیوع استفاده از ابزارهای ارتباطی در قالب اینترنت اشیا نیازمند طراحی کدهایی با تأخیر کم می‌باشد و این به معنی نیاز به طراحی کدهایی با طول کوتاه می‌باشد که همچنان به‌عنوان یک مسئله حل‌نشده در این حوزه باقی مانده‌است.

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 گرفته‌است. در حقیقت کدینگ زیربنای ارتباط سالم و با کیفیت را فراهم می‌کند. از طرفی، موفقیت‌هایی که مدل‌های یادگیری عمیق در حوزه‌های پردازش تصویر و گفتار به دست 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 کدواژه‌ها حین عبور از کانال بر آن‌ها اعمال می‌شود، اهمیت کاربرد این الگوریتم‌ها را برای بهبود کیفیت کدینگ افزایش داده‌است. توسعه ارتباط دیجیتال با قابلیت اطمینان بالا، در وهله اول به وسیله طراحی کدهایی میسر شده‌است که به گیرنده این امکان را می‌دهد تا بتواند پیام ارسالی را به‌صورت کارا و صحیح در شرایط کانال نویزی بازیابی کند. با وجود نویز به‌عنوان 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

جدول ۱: خلاصه پیشینه پژوهش

در طیف گسترده‌ای از سیستم‌های ارتباطی فراهم کند. رشته نظریه کدینگ در طول هفت دهه گذشته پیشرفت شایانی را تجربه کرده‌است 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 پی‌ریزی کرد که اکنون با عنوان نظریه کدینگ یا کدهای تصحیح‌کننده 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 هرچند 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 شانون، علاوه بر اثبات وجود کدهایی با نرخ انتقال نزدیک به ظرفیت کانال، این است که این کدها را می‌توان ساخت ولی هزینه عملیات کدگذاری و کدبرداری از این کدها (پیچیدگی محاسباتی) بسیار بالاست. با این وجود مقاله ایشان سرآغاز تلاش‌های محققان برای ساخت کدهایی با پیچیدگی محاسباتی کم شده‌است. تلاش برای طراحی این نوع کدها و روش‌های کدبرداری کارا توسط همینگ و سایر دانشمندان در دهه ۱۹۴۰ میلادی آغاز شد و تاکنون توجه بسیاری از پژوهشگران را معطوف خود ساخته‌است. از جمله کدهای خطی معروف که توانسته به حد شانون نزدیک شود کدهای خلوت ($LDPC^2$) 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^۳ تفسیر گرافیکی از کدهای خلوت ارائه داد ولی بازم این کدها مورد اقبال قرار نگرفتند. در دهه ۱۹۹۰ گروهی از پژوهشگران، کدهای خلوت را با تعمیم گسترده‌تری دوباره کشف کردند؛ به طوری که 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 داشته‌است. 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 اشیا بسیار مورد تقاضا و مهم می‌باشند؛ بنابراین یکی از چالش‌های پیش روی کدینگ، کاهش نرخ خطای بیت برای کدهای با طول کم است.

۲. روش تحقیق

دو مقاله [۴] و [۵] با استفاده از خاصیت مستقل بودن کارایی الگوریتم انتشار باور از کدواژه و نیز استفاده از ساختار گراف تنر

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

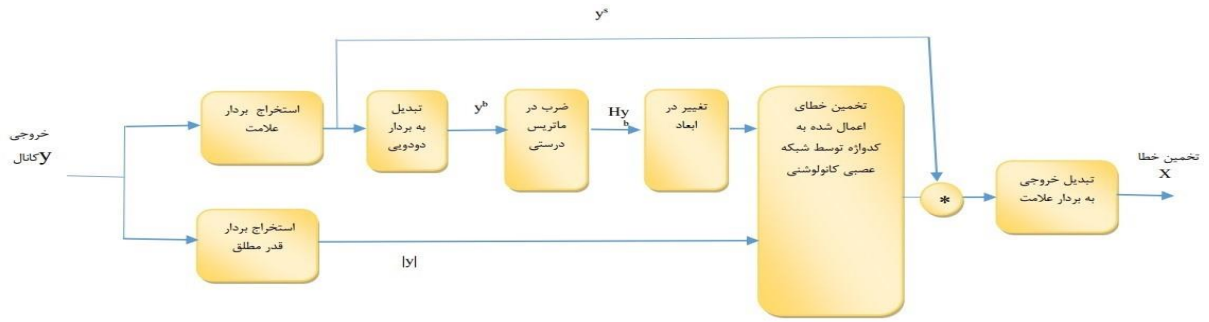
مورد استفاده در الگوریتم انتشار باور به عنوان ساختار معماری شبکه عصبی، الگوریتمی پیشنهاد داده اند که مشکل بیش برآزش را ندارد. مشکل کار ایشان این است که معماری شبکه عصبی استفاده شده محدود به چهار چوب ساختار گراف تر شده است و نمی توان از مزایای معماری های مختلف شبکه های عمیق بهره برد.

رویکرد دیگر برای مواجهه با مشکل بیش برآزش استفاده از روش کد برداری بر مبنای معادله علامت^۴ است. در این روش با جدا کردن نویز از کدواژه، نیاز به استفاده از کدواژه های مختلف برای آموزش شبکه مرتفع می شود؛ و به این صورت می توان شبکه عصبی را با تنها یک کدواژه آموزش داد تا مسئله بیش برآزش حل شود. مکانیسم کد برداری با استفاده از معادله علامت ایجاب می کند که بخشی از سیستم کدینگ وظیفه تشخیص نویز اعمال شده را داشته باشد. استفاده از شبکه های عصبی برای انجام وظیفه تشخیص الگوی خطا زمینه را برای استفاده از پتانسیل قوی شبکه های عصبی در زمینه کد برداری فراهم می کند. 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 چالش های مهم برای استفاده از شبکه های عصبی کاملاً متصل و برگشتی تعداد زیادی پارامتر شبکه عصبی است. شبکه های کانولوشنی به دلیل داشتن مزیت اشتراک پارامترها و اتصال خلوت، راهکار بسیار مناسبی برای این مشکل است که در زمینه های تشخیص اشیاء، طبقه بندی تصاویر و تشخیص گفتار و ترجمه ماشینی موفقیت هایی در حد لبه علمی به دست آورده است. در جدول شماره ۱ پیشینه پژوهش به صورت خلاصه و طبقه بندی شده آورده شده است.

ما در این پژوهش بر آنیم که با استفاده از شبکه های عصبی کانولوشنی نرخ خطای بیت در کد برداری کدهای خطی را کاهش دهیم. مسئله پژوهش حاضر کاهش هزینه محاسباتی و افزایش دقت کد برداری بر


مبنای معادله سندرم است که ما این کار را با استفاده از شبکه های کانولوشنی انجام می دهیم. مطابق شکل ۱ پس از دریافت خروجی کانال نویزی مراحل زیر بر روی آن انجام می شود. جهت کد برداری از کدواژه عبور داده شده از کانال نویزی با نویز گوسی، یعنی λ ، به این صورت عمل می شود که با اعمال عملگر علامت که برای هر سیگنال دریافت شده علامت آن را استخراج می کند، برداری به طول n شامل ۱ و -۱ خواهیم داشت. سپس عملگر باینری بر روی بردار اعمال می شود که در آن ۱ به ۰ و -۱ به ۱ تبدیل می شود. سپس حاصل در ماتریس درستی ضرب شده که همان معادله علامت خوانده می شود و با ایجاد تغییر در ابعاد آن به همراه قدر مطلق خروجی کانال به ورودی شبکه عصبی کانولوشنی اعمال می شود. 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 شبکه های عصبی عمیق می شوند. رویکرد نخست با استفاده از ساختار گراف تر و شبکه عصبی منطبق با آن توانسته به مقدار $9/0$ دسی بل دقت کد برداری از کدهای خطی را بهبود بخشد 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.



شکل ۱: دیاگرام منطقی ارتباط بین متغیرها

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 کد واژه‌ها 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 تانسورفلو 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 کد واژه‌های را کشف کنیم. مقادیر ابر پارامترها ابتدا به صورت پیش فرض تانسورفلو 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 مقداردهی 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.

رویکرد دوم مبتنی بر استفاده از معادله سندرم. معادله سندرم در حقیقت برای تشخیص این که در دریافت کدواژه خطایی رخ داده است یا نه به کار می‌رود. این معادله در رابطه $(1/1)$ آورده شده است که در آن 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 طول کدواژه و k نیز تعداد بیت‌های اضافه شده به عنوان بیت‌های توازن به پیام است، انجام می‌دهد. به تعداد K^2 جواب برای معادله‌های سندرم 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 سندرم صدق می‌کند را به عنوان الگوی خطا انتخاب کنیم. به یاد داریم که کدگشای درست‌نمایی بیشینه نیز کد واژه‌ای 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 سندرم 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 تابع هزینه مشتق می‌گیریم.



شکل ۳: نتایج نرخ خطای بیت بر اساس مقادیر ابرپارامترها

شکل ۴ نتایج عملکرد مدل در زمینه کاهش loss نرخ خطای بیت را 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 داشته‌باشد در همان تعداد ایپاک آموزش را متوقف می‌کنیم. برای مدل ما تعداد صد ایپاک (دور) بهترین نتیجه را داشته‌است. پس از اینکه مدل به خوبی آموزش دید و توانست نتیجه قاب 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 ندیده‌است کمترین نرخ خطا را داشته‌باشد. 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 از 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 بناتن [۹] ساخته و آموزش دیده‌است. برای مقایسه با سایر

تعداد 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 مقداردهی آن‌ها را طوری انجام دادیم که بهترین نتیجه حاصل گردد. داده‌های آموزش با اعمال طیف ۰ تا ۵ دسی‌بل نویز سفید گوسی^۵ به کدواژه‌ها 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 تخفیف که ما آن را برای همه گام‌های زمانی برابر با ۰.۵ قرار دادیم، H_{CE} تابع 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 به عنوان معیار برای مقایسه استفاده کرده‌ایم. این داده‌ها از سایت گیت‌هاب^۶ تهیه شده‌است. معیار مقایسه عملکرد روش ما بیشینه‌گر احتمال پسین^۷ یا همان MAP است. دلیل اینکه نتایج 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 ابرپارامترهای مدل به دست آمده و در یکی از نتایج عملکرد کدبرداری بهتر از کدبرداری MAP داشته‌است. 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.

روش‌های جدول ۱، در شکل ۶ نتایج مشابه برای روش‌های مقالات [۱۹] آورده شد است.



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

مسئله، روش‌های فرا اکتشافی بهترین ابزار برای این کار شناخته شده است.

۴. نتیجه‌گیری

ما با ترکیب شبکه کانولوشنی یک‌بعدی و شبکه برگشتی توانستیم کدبرداری از کدهای خطی بر مبنای معادله علامت را بهبود بخشیم. 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



شکل ۶: مقایسه با سایر روش‌ها

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 LDPC", *11th 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. Bengio, A. Courville, *Deep Learning*, Cambridge: MIT press, ۲۰۱۷
- [۵] E. Nachmani, Y. Be'ery, 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*, Vol. 8, No. 1, 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*

پی‌نوشت

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