

Predição de Enlaces em Redes Oportunistas utilizando Redes Neurais Profundas

Vinícius S. Thiago¹, Ronaldo M. Salles^{1,2}, Julio Cesar Duarte¹, Gabriela M. S. Dias¹

Instituto Militar de Engenharia (IME)

Praça General Tibúrcio, 80 – 22.290-270 – Urca, Rio de Janeiro – RJ – Brasil

CIICESI, ESTG, Instituto Politécnico do Porto, Portugal

{vinicius.thiago, salles, duarte, gabriela}@ime.eb.br

Abstract. *Opportunistic Networks are mobile wireless networks without a fixed infrastructure that present unique challenges in the context of link prediction, a traditional problem in computer networks. Although several approaches have been proposed to solve this problem, the application of such techniques in opportunistic networks appears as a promising strategy to improve packet delivery. This paper carries out an in-depth analysis, comparing Machine Learning methods used in the task of link prediction in opportunistic networks. Solutions containing Artificial Neural Networks, Convolutional Neural Networks, Recurrent Neural Networks, and Attention Mechanisms are analyzed. The experiments use two datasets from real opportunistic networks, ITC and Infocom06. From the performance analysis, it was possible to observe that Convolutional Neural Networks using two-dimensional convolutions are promising options for link prediction, having obtained values of 0.9831 for AUC and 0.7590 for PRAUC in Infocom06 data.*

Resumo. *As Redes oportunistas, caracterizadas pela sua natureza móvel e ausência de infraestrutura fixa, apresentam desafios singulares no contexto da predição de enlaces, um problema tradicional em redes de computadores. Embora diversas abordagens tenham sido propostas para solucionar esse problema, a aplicação de tais técnicas em redes oportunistas surge como uma estratégia promissora para otimizar a entrega de pacotes. Dessa forma, este trabalho realiza uma análise aprofundada, comparando métodos de Aprendizado de Máquina empregados na tarefa de predição de enlaces em redes oportunistas. Dentre as abordagens investigadas, incluem-se Redes Neurais Artificiais, Redes Neurais Convolucionais, Redes Neurais Recorrentes e Mecanismos de Atenção. Os experimentos conduzidos utilizam dois conjuntos de dados provenientes de redes oportunistas reais, o ITC e o Infocom06. Pela análise de desempenho dos resultados, foi possível observar que as Redes Neurais Convolucionais utilizando convoluções de duas dimensões são promissoras opções para a predição de enlaces, tendo obtido os valores de 0,9831 para AUC e de 0,7590 para PRAUC nos dados do Infocom06.*

1. Introdução

Redes Oportunistas são caracterizadas como um tipo de Rede Tolerante a Atrasos, ou *Delay Tolerant Networks* (DTN), do Inglês, ou seja, são redes em que é admitido que

os pacotes sejam entregues com atraso. Tais redes não possuem infraestruturas fixas e são formadas por nós móveis que se comunicam por meio de enlaces sem fio, como, por exemplo, *bluetooth*. Em uma Rede Oportunista é comum a ausência de uma rota direta entre dois nós, tornando necessário aguardar encontros fortuitos com outros nós para ativar mais enlaces e realizar o encaminhamento dos pacotes. Dessa forma, tais nós aproveitam a oportunidade de enviar pacotes quando ocorrem encontros entre eles, o que justifica o nome de Redes Oportunistas. Os nós que formam uma rede oportunista utilizam como estratégia para transmissão de pacotes a chamada *store-carry-forward*, de modo que os mesmos armazenam os pacotes até encontrarem uma oportunidade apropriada para encaminhá-los para os próximos nós, fazendo com que as redes sejam adequadas para situações de conexão intermitente ou inexistente [Garg et al. 2022].

É comum, entretanto, que os dispositivos membros de uma rede oportunista tenham recursos limitados, como bateria e armazenamento. Assim, é importante que estes recursos sejam utilizados de forma otimizada de modo a não causar o desligamento precoce dos nós e conseqüente descarte prematuro dos pacotes [Fu et al. 2019]. A decisão crítica no protocolo de encaminhamento envolve a escolha do próximo nó destinatário, denominado *next-hop*. Dessa forma, encontrar um protocolo de encaminhamento de pacotes apropriado e que proporcione uma taxa de entrega adequada sem exaurir os recursos da rede é um problema amplamente estudado em Redes Oportunistas.

Devido às características apresentadas, tais redes podem ser aplicadas em diversas situações, principalmente naquelas em que a infraestrutura de comunicação pode estar avariada ou indisponível, como em áreas afetadas por desastres e campos de batalha, entre outras [Garg et al. 2022].

A partir de características espaciais e temporais observadas na rede, prever as conexões entre nós da rede no futuro é uma tarefa difícil em razão da constante mobilidade dos nós e da possibilidade de desligamento abrupto devido à falta de bateria. No entanto, a previsão de enlaces futuros pode auxiliar o algoritmo de roteamento a escolher o próximo nó de encaminhamento, de modo que, quanto melhor for a previsão, maior será a eficiência do algoritmo de encaminhamento, possibilitando alcançar boas taxas de entrega de pacotes ao destino final, além de utilizar uma menor quantidade de recursos da rede.

Redes Neurais Artificiais (RNA) foram desenvolvidas inspirando-se no funcionamento do sistema nervoso humano e são formadas por diversas unidades de processamento (chamadas de neurônios artificiais) densamente interconectadas que computam funções matemáticas. Os neurônios ficam dispostos em camadas interligadas, cujas conexões possuem pesos associados que ponderam a entrada recebida por cada neurônio. A informação em uma RNA geralmente segue da camada de entrada da rede em direção à camada de saída, no entanto, as redes podem apresentar conexões de retroalimentação, permitindo que um neurônio receba como entrada a saída de um neurônio da mesma camada ou de camadas posteriores [Faceli et al. 2021]. Esse tipo particular de RNA é chamado de Rede Neural Recorrente (RNR).

Redes Neurais Convolucionais, ou *Convolutional Neural Networks* (CNN), são um tipo de rede neural especializada em processar dados que tenham uma topologia em forma de grade (matrizes). Como exemplo deste tipo de dados existem as séries temporais (que podem ser interpretadas como matrizes de uma dimensão nas quais estão

presentes amostras retiradas em intervalos de tempo regulares) e as imagens (que podem ser interpretadas como matrizes de duas dimensões formadas por píxeis). O nome deste tipo de rede neural é um indicativo da operação matemática utilizada e chamada de convolução. Desta forma, CNN podem ser descritas simplesmente como RNA que usam convoluções em vez da multiplicação de matrizes em geral em pelo menos uma de suas camadas [Goodfellow et al. 2016].

Este trabalho tem por objetivo prever enlaces futuros em Redes Oportunistas por meio de técnicas de aprendizado profundo, e, assim, obter resultados superiores a trabalhos de referência que utilizam técnicas mais clássicas. Para isso, serão utilizadas Redes Neurais Densas, Redes Neurais Convolucionais, a arquitetura SimVP com o tradutor ViT e a arquitetura ConvLSTM para previsão de enlaces e serão comparados os resultados obtidos.

O presente artigo está organizado da forma a seguir descrita. Trabalhos relacionados são descritos na Seção 2. A modelagem do problema de previsão de enlaces em redes oportunistas é descrita na Seção 3. A Seção 4 apresenta as soluções propostas para tratar o problema definido, a Seção 5 descreve como foram implementados os testes realizados e os resultados obtidos são mostrados e analisados na Seção 6. Finalmente, a Seção 7 apresenta a conclusão do trabalho e discute trabalhos futuros.

2. Trabalhos Relacionados

Para o levantamento dos trabalhos relacionados, foram realizadas buscas com os termos “*opportunistic network*” e “*link prediction*” nos títulos, resumos e palavras-chave de trabalhos utilizando o banco de dados Scopus, tendo sido selecionados aqueles com as seguintes características:

- Estudos publicados a partir de 2018;
- Estudos nos idiomas português e inglês;
- Estudos disponíveis para acesso (livre *download*);
- Estudos que fizeram uso de técnicas de Aprendizado de Máquina;
- Estudos que utilizaram matrizes de adjacência para representar os enlaces da rede.

A busca por estudos publicados a partir de 2018 obteve 14 resultados em língua inglesa, dos quais apenas 10 estavam disponíveis para acesso. Destes, dois não utilizaram técnicas de aprendizado de máquina e dois não utilizaram matrizes de adjacências na representação dos enlaces, de modo que foram selecionados seis trabalhos.

[Cai et al. 2018] propuseram um método de predição de enlaces baseado em RNR. No modelo proposto, a informação do histórico de conexão dos pares de nós é dividida em *snapshots* da rede e transformada em uma sequência de vetores. Esses vetores são utilizadas como entrada para um modelo chamado de RNN-LP. A RNR captura as características escondidas da sequência de vetores, permitindo que se aprenda a correlação entre os nós e extraindo a regra de formação de conexão entre os nós, que muda frequentemente em redes oportunistas. Como RNN tradicionais apresentam o problema do esvanecimento do gradiente e da dependência de longo prazo, podendo descartar informações antigas, perdendo, assim, características e prejudicando a previsão, o trabalho utiliza *Long Short-Term Memory Network* (LSTM) para resolver esses problemas. É utilizada a base ITC nos experimentos com o modelo proposto e avaliada a métrica *area under the receiver operating characteristic curve* (AUC), obtendo-se 0,9780 como resultado.

Já [Ma and Shu 2019] propuseram um modelo, chamado de BRRN-LP, que transforma as informações de conexões em um vetor de correlação, no qual a correlação é proporcional à frequência e à duração das conexões. O modelo proposto utiliza uma *Bayesian Recurrent Neural Network* (BRNN), mais especificamente uma *Bayesian LSTM* para tratar a incerteza dos parâmetros na rede, usando o mecanismo de portão (*gate*) para memorizar informações úteis. O objetivo da LSTM Bayesiana é obter a distribuição posterior de pesos na rede e, assim, reduzir os parâmetros e agilizar o treinamento. É utilizado o conjunto de dados *MIT Reality* nos experimentos e são avaliadas as métricas AUC e Precisão.

[Yemeni et al. 2019] propuseram uma abordagem para a previsão de enlaces que utiliza *Deep Belief Networks* (DBN). Katz Index, Resource Allocation, Adamic Adar, e Common Neighbor são utilizados separadamente como métricas para formar vetores de entrada para o algoritmo DBN (que contém somente enlaces não repetidos). As DBN são formadas pelo empilhamento de diversas *Restricted Boltzmann Machines* (RBM), que são treinadas de forma gulosa, e são modelos gráficos de aprendizagem que extraem uma representação da hierarquia dos dados de treinamento. O trabalho também divide a rede em *snapshots* com intervalos de 10 min e 30 min e cria matrizes de adjacências. É utilizado o *dataset* ITC nos experimentos, obtendo o resultado de 0,98 para AUC.

[Liao et al. 2020] propuseram um método que utiliza uma matriz de probabilidade de transição de Markov e define uma matriz de índice de similaridade chamada IRWR (*Improved Random Walk with Restart*). Em seguida, a rede oportunista é dividida em *snapshots* e a matriz de similaridade de cada *snapshot* é calculada. O modelo proposto é chamado de IRWR-DBN, pois utiliza uma DBN que extrai as características temporais da rede. O modelo é composto por diversas RBM. Os experimentos foram realizados nas bases ITC e *MIT Reality* e mediram a AUC e a precisão dos resultados. Para a base ITC, o trabalho obteve o resultado 0,9591 para AUC e 0,9540 para a precisão.

Por outro lado, [Shu et al. 2022a] utilizaram um fator de correlação, baseado na quantidade e tempo de conexões entre os nós, para designar pesos para os enlaces da matriz de adjacências da rede oportunista e, em seguida, juntar as matrizes de diferentes intervalos de tempo, formando uma estrutura 3D. A estrutura da solução apresentada utiliza cinco camadas convolucionais e duas camadas totalmente conectadas, além da camada de saída. Para testar a arquitetura proposta foi utilizado o *dataset* ITC e foram medidas as métricas acurácia e precisão, tendo obtido como resultados 0,9188 para precisão e 0,9507 para acurácia.

[Shu et al. 2022b] propuseram um modelo para predição de enlaces baseado no *framework Transformers* formado por quatro componentes: um extrator de características da topologia, um extrator de características temporais, um método de fusão de características e um modelo de mapeamento para vetores. Um mecanismo de atenção é utilizado para extrair as características da topologia, agregando informações dos nós vizinhos, que aprende dependências temporais de longo prazo, além de capturar a regra de evolução global das redes. As características da topologia são fundidas com as características temporais de modo que os vetores de características fundidas sejam transformados por um modelo de mapeamento na topologia futura da rede. O trabalho utilizou as bases ITC, MIT e Infocom06 e verificou as métricas AUC e *area under the precision-recall curve* (PRAUC). Foram obtidos como resultados na base ITC os valores de 0,9708 para AUC e

0,8915 para PRAUC; e para a base Infocom06 os valores de 0,9580 para AUC e 0,7240 para PRAUC.

A Tabela 1 mostra a comparação entre os trabalhos relacionados.

Tabela 1. Trabalhos relacionados

Trabalho	Método	Métrica medida	Dataset
[Cai et al. 2018]	LSTM	AUC	ITC
[Ma and Shu 2019]	BRNN	AUC e Precisão	<i>MIT Reality</i>
[Yemeni et al. 2019]	DBN	AUC	ITC
[Liao et al. 2020]	DBN	AUC e Precisão	ITC e <i>MIT Reality</i>
[Shu et al. 2022a]	Conv3D	Acurácia e Precisão	ITC
[Shu et al. 2022b]	<i>Transformers</i>	AUC e PRAUC	Infocom06

O presente trabalho utiliza diversas técnicas de aprendizado de máquina de forma crescente em complexidade para realizar a predição de enlaces utilizando as bases ITC e Infocom06. Em seguida, os resultados alcançados são comparados com os trabalhos relacionados com o intuito de descobrir uma arquitetura que alcance resultados superiores. Os resultados obtidos no presente trabalho foram superiores aos obtidos por [Shu et al. 2022b] para a base Infocom06.

3. Modelagem do Problema de Predição de Enlaces

Para melhor tratar o problema de previsão de enlaces como um problema de Aprendizado de Máquina, a rede oportunista pode ser transformada em uma sequência de matrizes de adjacências $A = \{A^1, A^2, \dots, A^i, \dots, A^T\}$, onde A^i representa uma matriz com os índices formados pelos nós da rede no intervalo de tempo i ($i \in \{1, 2, \dots, T\}$). Dessa forma, quando existe uma conexão entre dois nós a e b , então $A^i(a, b)$ é igual a 1 e, quando não há conexão entre os nós, $A^i(a, b)$ é igual a 0. De acordo com [Shu et al. 2022b], o problema de previsão de enlaces fica definido então como, a partir de uma sequência de matrizes de adjacências $A^{t:t+\tau-1} = A^t, A^{t+1}, \dots, A^{t+\tau-1}$, prever a próxima matriz $A^{t+\tau}$, onde τ representa o tamanho da sequência de entrada. A estrutura pode ser melhor visualizada na Figura 1.

Dessa forma, o problema de predição de enlaces se transforma em um problema de classificação binária dos elementos da matriz com o valor 1 representando a existência de um enlace e o valor 0 representando a ausência.

4. Solução Proposta

Visando alcançar melhores métricas para a previsão de enlaces nas redes oportunistas, este trabalho avaliou o desempenho da previsão em redes neurais artificiais, em redes convolucionais 2d, em redes convolucionais 3d, utilizando a arquitetura SimVP com o ViT como tradutor, e utilizando a arquitetura ConvLSTM.

O *Simple Video Predictor* (SimVP) é um modelo preditivo proposto por [Tan et al. 2022] que é construído inteiramente sobre redes convolucionais, sem utilizar arquiteturas recorrentes, dividindo-se em três blocos: um codificador espacial, um tradutor e um decodificador espacial, conforme pode ser observado na Figura 2. O codificador e o decodificador espacial contam com camadas de convolução 2D.




Figura 1. Previsão da matriz de adjacências. Adaptado de [Shu et al. 2022b]

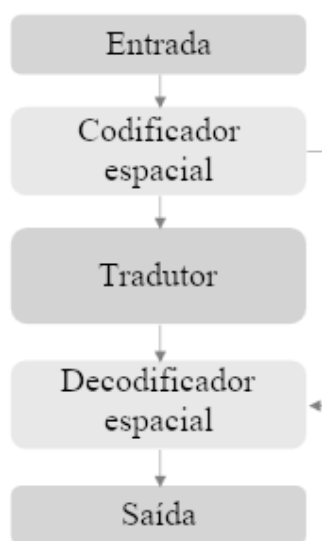


Figura 2. A estrutura do SimVP. Adaptado de [Tan et al. 2022]

A biblioteca OpenSTL [Tan et al. 2023] permite utilizar várias configurações para o tradutor (parte temporal) do SimVP, como o *Vision Transformer* (ViT) [Dosovitskiy et al. 2020], que utiliza blocos da arquitetura *Transformers*. Ela permite que sejam definidos valores para os hiperparâmetros como número de camadas ou blocos (N_S) e de dimensões ocultas (hid_S) do codificador espacial, e número de camadas (N_T) e de dimensões ocultas (hid_T) do tradutor.

A *Convolutional LSTM* (ConvLSTM) é um modelo proposto por [Shi et al. 2015] que estende uma LSTM totalmente conectada com estruturas convolucionais para tratar sequências de dados espaço-temporais.

5. Experimentos Realizados

Para implementar as redes neurais e convolucionais foi utilizada a biblioteca PyTorch [The PyTorch Foundation 2023] e para realizar os testes com as arquiteturas SimVP e ConvLSTM, a biblioteca OpenSTL, que compreende uma implementação em código aberto de diversas arquiteturas para previsões espaço-temporais permitindo que se tenha acesso a vários métodos de estado da arte.

Para os testes das soluções propostas são utilizados os conjuntos de dados *Imote Traces Cambridge* (ITC) e *Infocom06* [Scott et al. 2022]. Ambos os *datasets* contém os encontros (conexões) entre pequenos dispositivos que se comunicam por *Bluetooth* chamados iMotes e foram formatados para apresentar linhas com as seguintes informações dos encontros: número identificador do primeiro nó, número identificador do segundo nó, momento em que o contato se iniciou, momento em que o contato terminou.

A base ITC registrou, durante doze dias, os encontros entre cinquenta iMotes no campus da Universidade de Cambridge. Foram utilizados tanto dispositivos móveis, entregues aos alunos, quanto fixos que foram posicionados em bares, mercados, shopping centers e na recepção do laboratório de computação. O arquivo no formato descrito anteriormente possui informação sobre 10776 contatos.

A base *Infocom06* registrou, durante 4 dias, o movimento de 98 equipamentos portáteis presentes na Conferência IEEE *Infocom 2006* em Barcelona. Setenta e oito iMotes móveis foram utilizados, com um alcance de cerca de trinta metros, além de vinte iMotes estacionários, que apresentavam um alcance de cerca de cem metros. O arquivo no formato descrito anteriormente possui informação sobre 227657 contatos.

Para os testes realizados foram seguidos os parâmetros utilizados em [Shu et al. 2022b], isto é, o ITC foi dividido em intervalos de 300s para gerar as matrizes de adjacências, e o *Infocom06* foi dividido em intervalos de 270s, onde todas as previsões contaram com uma sequência de entrada de 10 matrizes.

5.1. Descrição dos experimentos

Foram realizados testes com diversas arquiteturas de redes neurais densas (RND), variando de duas a quatro camadas intermediárias e, em cada camada, variando-se também a quantidade de neurônios (com valores que variaram entre 25 a 2000). Ao final dos testes foram selecionadas as duas arquiteturas que obtiveram os melhores resultados. A primeira RND utilizada apresenta duas camadas intermediárias, uma formada por 80 neurônios e a segunda formada por 50 neurônios. A segunda RND utilizada também possui duas camadas intermediárias, porém uma apresenta 150 neurônios e a outra conta com 80 neurônios.

A função de ativação utilizada nas camadas intermediárias foi a ReLU (*Rectified Linear Unit*), que é amplamente utilizada ao projetar redes neurais atualmente. Na camada de saída, foi utilizada a função de ativação Sigmoid, apropriada para problemas de classificação binária por converter quaisquer valores de entrada em uma saída no intervalo entre 0 e 1, sendo usada para prever a probabilidade de uma variável binária. Para calcular o erro foi utilizada a função de entropia cruzada binária *BCEWithLogitsLoss*, apropriada para problemas de classificação binária, e como otimizador foi utilizado o método adam com taxa de aprendizado de 0,001. O modelo foi treinado durante 1000 épocas.

Foram implementadas duas redes convolucionais. A primeira CNN é composta por três camadas intermediárias do tipo *Conv2d*, seguidas, cada uma, por um *dropout*, que permite prevenir o sobre-ajuste, anulando aleatoriamente uma fração dos neurônios da camada. A segunda CNN é composta por três camadas intermediárias do tipo *Conv3d*, seguidas também por um *dropout*. As descrições das redes convolucionais 2d e 3d utilizadas podem ser observadas na Figura 3.

Ao utilizar as camadas *conv2d* e *conv3d*, foi escolhida a opção de *padding* circu-




Figura 3. Representação das redes convolucionais utilizadas.

lar, que é um método desenvolvido originalmente para imagens omnidirecionais e cujo objetivo é eliminar a perda de informação que ocorre ao se adotar métodos de *padding* como o “zero” ou “same”. Ao utilizar o *padding* circular no eixo horizontal, por exemplo, a parte esquerda da imagem é preenchida com a parte mais à direita da imagem, e vice-versa [Wang et al. 2018]. Dessa forma, esta técnica utiliza informações das bordas opostas e garante que os *kernels* de *padding* tenham o mesmo comportamento no interior e nas bordas das imagens [Schubert et al. 2019].

Para calcular o erro foi utilizado a função de entropia cruzada binária *BCEWithLogitsLoss* e como otimizador foi utilizado o método adam com taxa de aprendizado de 0,001. O modelo foi treinado durante 1000 épocas.

Foram realizados experimentos com o SimVP com ViT contando com 100 épocas, taxa de aprendizagem de 0,001, $N_S = 4$, $N_T = 8$, $hid_S = 64$ e $hid_T = 256$ (parâmetros apresentados na Seção 4).

Foram realizados experimentos com a ConvLSTM contando com 100 épocas e taxa de aprendizagem de 0,001.

5.2. Métricas Utilizadas

Os resultados obtidos foram avaliados pelas métricas: acurácia, AUC, PRAUC, precisão para a classe 1 (existência de um enlace), abrangência para a classe 1 e Medida F1 para a classe 1.

De acordo com [Faceli et al. 2021] a acurácia pode ser calculada como a divisão da soma do número de verdadeiros positivos e verdadeiros negativos pela soma dos valores dos elementos da matriz.

Já de acordo com [Shu et al. 2022b] a métrica de avaliação AUC é largamente

adotada na avaliação de modelos de classificação. A fórmula para o cálculo da métrica é

$$AUC = \frac{n' + 0.5n''}{n}$$

onde n é o número de comparações em uma amostra, n' é o número de comparações em que o valor previsto para um enlace existente é maior do que para enlaces ausentes e n'' é o número de comparações em que os valores são iguais. As principais vantagens desse tipo de análise estão na possibilidade de se obter medidas de desempenho independentes do limiar de classificação e de custos associados a classificações incorretas e distribuições de classes [Faceli et al. 2021].

A métrica PRAUC é utilizada para tratar exemplos escassos (ou muito desbalanceados). De acordo com [Shu et al. 2022b], o cálculo da métrica é

$$PRAUC = \frac{1}{N} \sum_{u=1}^N \sum_{v=1}^N \frac{|A(u, v) = 1 \cap P(u, v) = 1|}{|A(u, v) = 1|}$$

no qual $A(u, v) = 1$ representa a existência de um enlace entre os nós u e v e $P(u, v) = 1$ representa que é previsto que exista um enlace entre os nós u e v .

Ainda de acordo com [Faceli et al. 2021], a precisão é definida como a razão entre o número de verdadeiros positivos e a soma deste com o número de falsos positivos. A abrangência pode ser definida como a divisão do número de verdadeiros positivos pela soma deste com o número de falsos negativos. Já a Medida F1 é calculada multiplicando-se por dois o produto da precisão e da abrangência e dividindo pela soma da precisão com a abrangência. Todas as métricas descritas apresentam valores entre 0 e 1, sendo 1 o melhor resultado possível.

6. Resultados Obtidos

Os resultados provenientes dos testes realizados com as RND no conjunto de dados ITC estão apresentados na Tabela 2. Notavelmente, constata-se que, embora as RND se destaquem por sua simplicidade estrutural, conseguiram superar os valores de acurácia obtidos por [Shu et al. 2022a]. Entretanto, é pertinente observar que essas redes não demonstraram desempenho satisfatório em métricas importantes, como a precisão, a AUC e a PRAUC.

Tabela 2. Resultados obtidos com RND e *dataset* ITC

Métrica	RN 80-50	RN 150-80
Acurácia	0,9918	0,9927
AUC	0,8882	0,8856
PRAUC	0,3276	0,3350
Precisão	0,4648	0,5613
Abrangência	0,4051	0,2689
Medida F1	0,4329	0,3636

Já os resultados obtidos nos testes utilizando as redes densas e o *dataset* Info-com06 podem ser observados na Tabela 3. Percebe-se que as RND apresentaram valores

Tabela 3. Resultados obtidos com RND e *dataset* Infocom06

Métrica	RN 80-50	RN 150-80
Acurácia	0,9979	0,9982
AUC	0,9697	0,9719
PRAUC	0,5532	0,5711
Precisão	0,4457	0,5019
Abrangência	0,6968	0,6981
Medida F1	0,5437	0,5839

para AUC melhores do que [Shu et al. 2022b], no entanto, não mostraram bons resultados para PRAUC.

Na sequência, podemos observar os resultados obtidos nos testes utilizando as CNN e o *dataset* ITC, conforme a Tabela 4. Verifica-se, nesse caso, que as CNN apresentaram valores para acurácia melhores do que [Shu et al. 2022b], valores para AUC melhores do que [Cai et al. 2018, Yemeni et al. 2019, Liao et al. 2020, Shu et al. 2022b], no entanto, não mostraram bons resultados para precisão e PRAUC.

Tabela 4. Resultados obtidos com CNN e *dataset* ITC

Métrica	Conv2D	Conv3D
Acurácia	0,9936	0,9851
AUC	0,9840	0,9944
PRAUC	0,7893	0,7123
Precisão	0,7417	0,3336
Abrangência	0,8108	0,9363
Medida F1	0,7747	0,4919

Na Tabela 5 podemos observar os resultados obtidos nos testes utilizando as CNN e o *dataset* Infocom. Percebe-se que a CNN Conv3D apresentou um valor para AUC semelhante a [Shu et al. 2022b], no entanto, não apresentou um bom resultado para PRAUC. Já a CNN Conv2D apresentou bons valores para AUC e PRAUC, obtendo um resultado superior ao trabalho relacionado.

Tabela 5. Resultados obtidos com CNN e *dataset* Infocom06

Métrica	Conv2D	Conv3D
Acurácia	0,9991	0,9904
AUC	0,9831	0,9533
PRAUC	0,7590	0,4509
Precisão	0,7425	0,4439
Abrangência	0,7308	0,5811
Medida F1	0,7366	0,5033

Dando sequência aos experimentos realizados, a Tabela 6 mostra os resultados obtidos utilizando as arquiteturas SimVP e ConvLSTM no *dataset* ITC. Percebe-se que ambas as arquiteturas obtiveram resultados com acurácia superior à publicação

de [Shu et al. 2022a] e AUC com valores semelhantes aos obtidos por [Cai et al. 2018, Yemeni et al. 2019, Liao et al. 2020, Shu et al. 2022b]. No entanto, os valores obtidos de precisão e de PRAUC são inferiores aos dos trabalhos relacionados.

Tabela 6. Resultados obtidos com SimVP+ViT e ConvLSTM e *dataset* ITC

Métrica	SimVP+ViT	ConvLSTM
Acurácia	0,9941	0,9956
AUC	0,9706	0,9556
PRAUC	0,7110	0,7291
Precisão	0,8538	0,7773
Abrangência	0,3567	0,6743
Medida F1	0,5032	0,7221

Finalmente, os resultados obtidos utilizando as arquiteturas SimVP e ConvLSTM no *dataset* Infocom06 podem ser observados na Tabela 7. Percebe-se que ambas as arquiteturas obtiveram resultados com AUC e PRAUC inferiores aos obtidos por [Shu et al. 2022b].

Tabela 7. Resultados obtidos com SimVP+ViT e ConvLSTM e *dataset* Infocom06

Métrica	SimVP+ViT	ConvLSTM
Acurácia	0,9924	0,9927
AUC	0,8871	0,8868
PRAUC	0,3868	0,4016
Precisão	0,6997	0,6848
Abrangência	0,1211	0,1966
Medida F1	0,2065	0,3055

Os resultados encontrados nos trabalhos relacionados utilizando as bases ITC e Infocom06, descritos anteriormente, podem ser observados nas Tabelas 8 e 9 em paralelo com os melhores resultados obtidos neste trabalho.

Tabela 8. Resultados obtidos para o *dataset* ITC

Trabalho	AUC	Precisão	Acurácia	PRAUC
[Cai et al. 2018]	0,9780	-	-	-
[Yemeni et al. 2019]	0,9800	-	-	-
[Liao et al. 2020]	0,9591	0,9540	-	-
[Shu et al. 2022a]	-	0,9188	0,9507	-
[Shu et al. 2022b]	0,9708	-	-	0,8915
Conv2D	0,9840	0,7417	0,9936	0,7893
SimVP+ViT	0,9706	0,8538	0,9941	0,7110
ConvLSTM	0,9556	0,7773	0,9956	0,7291

7. Considerações Finais

Este trabalho aborda o problema das Redes Oportunistas que consiste em melhorar o encaminhamento de pacotes preservando os recursos da rede. Para isso, utilizou-se uma

Tabela 9. Resultados obtidos para o *dataset* Infocom06.

Trabalho	AUC	PRAUC
[Shu et al. 2022b]	0,9580	0,7240
Conv2D	0,9831	0,7590

abordagem que leva em conta a predição de enlaces futuros. Visando prever estes enlaces, a rede foi dividida em intervalos com os quais foram geradas matrizes de adjacências, mostrando os enlaces existentes em cada intervalo de tempo.

O objetivo do trabalho foi, então, prever a constituição da próxima matriz (matriz futura) a partir de uma sequência de matrizes de adjacências. Foram realizados experimentos com redes densas, redes convolucionais 2D e 3D, arquitetura SimVP utilizando o ViT como tradutor e com a arquitetura ConvLSTM. Os resultados foram comparados com os dos trabalhos relacionados e foi possível verificar que a rede convolucional 2D alcançou resultados superiores com o conjunto de dados Infocom06, mais especificamente, obteve os valores de AUC de 0,9831 e PRAUC de 0,7590, superiores aos valores de AUC de 0,9580 e PRAUC de 0,7240 obtidos por [Shu et al. 2022b].

Como proposta de trabalhos futuros verifica-se a possibilidade da utilização de modelos de fundação (*foundation models*) para a previsão de enlaces. De acordo com [Galkin et al. 2023], os modelos de fundação são modelos frequentemente pré-treinados em grandes conjuntos de dados de forma autossupervisionada, e podem, após esse pré-treinamento, serem ajustados para outras tarefas.

Uma abordagem promissora para outros trabalhos seria, no lugar de realizar a previsão da próxima matriz de adjacências, empregar métodos de aprendizado de máquina para tentar antecipar as diferenças entre a matriz futura e a última matriz disponível. Esta estratégia se baseia na premissa de que as variações entre duas matrizes consecutivas são geralmente sutis. Considerando que são poucas as diferenças entre duas matrizes seguidas, as técnicas poderiam focar em realizar menos previsões, o que pode levar a resultados ainda melhores.

Agradecimentos

Este material é baseado no trabalho apoiado pelo Escritório de Pesquisa Científica da Força Aérea (AFOSR) sob o número FA9550-22-1-0475 e foi parcialmente financiado por fundos nacionais através da FINEP, Financiadora de Estudos e Projetos, e FAPEB, Fundação de Apoio à Pesquisa, Desenvolvimento e Inovação do Exército Brasileiro, no âmbito do projeto “Sistema de Sistemas de Comando e Controle” com referência nº 2904/20 sob o contrato nº 01.20.0272.00.

Referências

- Cai, X., Shu, J., and Al-Kali, M. (2018). Link prediction approach for opportunistic networks based on recurrent neural network. *IEEE Access*, 7:2017–2025.
- Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., Dehghani, M., Minderer, M., Heigold, G., Gelly, S., et al. (2020). An image is worth 16x16 words: Transformers for image recognition at scale. *arXiv preprint arXiv:2010.11929*.

- Faceli, K., Lorena, A. C., Gama, J., Almeida, T. A. d., and Carvalho, A. C. P. d. L. F. d. (2021). *Inteligência artificial: uma abordagem de aprendizado de máquina*. LTC.
- Fu, X., Yao, H., Postolache, O., and Yang, Y. (2019). Message forwarding for wsn-assisted opportunistic network in disaster scenarios. *Journal of Network and Computer Applications*, 137:11–24.
- Galkin, M., Yuan, X., Mostafa, H., Tang, J., and Zhu, Z. (2023). Towards foundation models for knowledge graph reasoning. *arXiv preprint arXiv:2310.04562*.
- Garg, P., Dixit, A., and Sethi, P. (2022). MI-fresh: novel routing protocol in opportunistic networks using machine learning. *Computer Systems Science & Engineering, Forthcoming*.
- Goodfellow, I., Bengio, Y., and Courville, A. (2016). *Deep learning*. MIT press.
- Liao, Z., Liu, L., and Chen, Y. (2020). A novel link prediction method for opportunistic networks based on random walk and a deep belief network. *Ieee Access*, 8:16236–16247.
- Ma, Y. and Shu, J. (2019). Opportunistic networks link prediction method based on bayesian recurrent neural network. *IEEE access*, 7:185786–185795.
- Schubert, S., Neubert, P., Pöschmann, J., and Protzel, P. (2019). Circular convolutional neural networks for panoramic images and laser data. In *2019 IEEE intelligent vehicles symposium (IV)*, pages 653–660. IEEE.
- Scott, J., Gass, R., Crowcroft, J., Hui, P., Diot, C., and Chaintreau, A. (2022). *Crawdad cambridge/haggle (v. 2009-05-29)*. Disponível em <https://dx.doi.org/10.15783/C70011>. [Online, acesso em 24-agosto-2023].
- Shi, X., Chen, Z., Wang, H., Yeung, D.-Y., Wong, W.-K., and Woo, W.-c. (2015). Convolutional lstm network: A machine learning approach for precipitation nowcasting. *Advances in neural information processing systems*, 28.
- Shu, J., Li, J., and Zhang, X. (2022a). Link prediction based on 3d convolutional neural network. In *2022 IEEE/CIC International Conference on Communications in China (ICCC)*, pages 156–161. IEEE.
- Shu, J., Shi, J., and Liao, L. (2022b). Link prediction model for opportunistic networks based on feature fusion. *IEEE Access*, 10:80900–80909.
- Tan, C., Gao, Z., Li, S., and Li, S. Z. (2022). Simvp: Towards simple yet powerful spatiotemporal predictive learning. *arXiv preprint arXiv:2211.12509*.
- Tan, C., Li, S., Gao, Z., Guan, W., Wang, Z., Liu, Z., Wu, L., and Li, S. Z. (2023). Openstl: A comprehensive benchmark of spatio-temporal predictive learning. In *Conference on Neural Information Processing Systems Datasets and Benchmarks Track*.
- The PyTorch Foundation (2023). Pytorch. Disponível em <https://pytorch.org/>. [Online, acesso em 30-novembro-2023].
- Wang, T.-H., Huang, H.-J., Lin, J.-T., Hu, C.-W., Zeng, K.-H., and Sun, M. (2018). Omni-directional cnn for visual place recognition and navigation. In *2018 IEEE International Conference on Robotics and Automation (ICRA)*, pages 2341–2348. IEEE.

Yemeni, Z., Shu, J., Zhang, X., and Liu, L. (2019). A dbn approach to predict the link in opportunistic networks. In *Recent Developments in Intelligent Computing, Communication and Devices: Proceedings of ICCD 2017*, pages 575–587. Springer.