

# Predição de Bloqueio em Redes de Telefonia Móvel

Gabriel da Silva Melo  
Departamento de Computação  
CEFET-MG  
Belo Horizonte, Brasil  
gabrielsilvameo96@gmail.com

Bruno André Santos  
Departamento de Computação  
CEFET-MG  
Belo Horizonte, Brasil  
bsantos@cefetmg.br

Rogério Martins Gomes  
Departamento de Computação  
CEFET-MG  
Belo Horizonte, Brasil  
rogerio@cefetmg.br

**Resumo**—Bloqueios em redes de telefonia é um problema que consiste na recusa da conexão entre um aparelho telefônico e uma célula responsável pela emissão do sinal. A ocorrência de bloqueios pode ser um indicador de que a célula está próxima de sofrer um congestionamento, o que pode gerar perdas financeiras para as empresas de telefonia. Neste trabalho, foram desenvolvidos dois sistemas de previsão usando redes neurais MLPs (Multi Layer Perceptron) e seguindo as estratégias conhecidas como Direta e DirRec [1]. Para realizar o treinamento e teste das redes MLPs, foram utilizados dados reais contendo históricos de taxa de bloqueios em células de tecnologia 3G. As etapas do desenvolvimento consistiram na análise do desempenho das redes variando o número de neurônios nas camadas ocultas e o número de passos previstos. Os dois sistemas, Direto e DirRec, apresentaram desempenhos semelhantes, fazendo previsões de curto (15 minutos) e longo (5 horas) prazos com RMSE (*Root Mean Squared Error*) de aproximadamente 12% e 31%, respectivamente. Porém, o sistema que utilizou a estratégia DirRec se mostrou mais viável por demandar uma quantidade menor de redes MLPs e, desta maneira, ter um treinamento mais simples.

**Palavras-chave:** Redes de Telefonia, Previsão de Taxa de Bloqueio de Célula, Multi-Layer Perceptron, Séries Temporais.

## I. INTRODUÇÃO

Ao administrar as redes de telefonia, as empresas devem se preocupar com vários fatores para garantirem a qualidade do sinal. Um dos fatores é o congestionamento das unidades emissoras de sinal (células telefônicas). Quando uma célula está congestionada, a comunicação de todos os dispositivos conectados a ela fica prejudicada, impossibilitando que seus serviços sejam oferecidos de forma satisfatória.

Diversos motivos podem levar ao congestionamento, tais como: sobrecargas de potência, excesso de conexões de usuários, excesso de tráfego de dados nas células e a sobrecarga do processador da célula telefônica [2]. Quando uma célula identifica que está próxima de sofrer um congestionamento, ela pode realizar algumas ações para amenizar a situação, tais como: redução da qualidade das chamadas de voz, transferência de uma conexão de uma célula para outra ou bloqueio de novas conexões [3]. O problema é que essas ações podem ser desvantajosas para as empresas pois reduzem o lucro que seria obtido com clientes que deveriam estar usando a rede. Além disso, a má qualidade do serviço oferecido prejudica a imagem da empresa. Sendo assim, é do interesse das empresas de telecomunicação conhecerem, com antecedência, a intensidade e duração dos congestionamentos para poderem realizar medidas reativas com o objetivo de evitar ou minimizar os efeitos negativos.

Para tratar do problema do congestionamento, alguns trabalhos têm sido desenvolvidos. Neto [4], por exemplo, comparou o desempenho de diferentes modelos de previsão de séries temporais para o problema de previsão do tráfego de dados IP de uma rede de telefonia. Foram desenvolvidos modelos usando Holt-Winters, Holt-Winters com dupla sazonalidade, TBATS, ARIMA (*Autoregressive Integrated Moving Average*), métodos de suavização exponencial, rede neural auto-regressiva, RNN (*Recurrent Neural Network*), MLP e LSTM (*Long Short-Term Memory*). Os métodos foram treinados com a própria informação do tráfego e foram avaliadas as previsões para um passo e múltiplos passos. Para a previsão de um passo no futuro, a rede MLP obteve o melhor resultado e para múltiplos passos a rede LSTM foi a que teve o melhor desempenho.

Dong, Fan e Gu [5], realizaram uma comparação entre o ARIMA e o modelo de Suavização de Exponencial para previsão de tráfego de dados de uma rede 4G. Eles criaram quatro cenários de previsão, diferenciando entre previsões feitas usando uma única célula ou uma região geográfica de células, e modelos treinados com dados de dias da semana ou de finais de semana. Nos resultados encontrados, o modelo ARIMA foi melhor que o modelo de suavização exponencial para prever o tráfego em dias úteis. Por outro lado, o modelo de suavização exponencial conseguiu melhores resultados que o modelo ARIMA para prever o tráfego de dados em uma única célula.

No estudo feito por Torres et al. [6], foi desenvolvida uma metodologia para previsão da taxa de transferência média de download para uma célula 4G e, através disso, detectar sobrecargas na rede. Os dados do trabalho foram coletados por sondas acopladas em automóveis. Para realizar a previsão, foi utilizado o modelo ARIMAX (*Autoregressive Integrated Moving Average with Explanatory Variable*). Os resultados encontrados mostraram que a previsão do comportamento da rede era viável e com alta precisão.

Chen et al. [7] propuseram um sistema baseado em redes LSTM com GA (*Genetic Algorithm*). Inicialmente, as redes LSTM foram usadas para extrair recursos de histórico de tráfego, em seguida o GA foi usado para identificar hiperparâmetros adequados para a rede LSTM. O modelo desenvolvido teve uma precisão maior quando comparado com a previsão utilizando técnicas como ARIMA e LSTM puros.

Em Wang [8] foi proposto um método que combina redes

LSTM com GPR (*Gaussian process regression*) para realizar a previsão do tráfego de células de telefonia. Os testes realizados mostraram que o sistema criado supera os testes de *benchmark* definidos, especialmente para a previsão em períodos em que o tráfego estava sobrecarregado.

Ozovehe [9] realizou uma comparação de diferentes métodos de previsão para determinar o congestionamento em redes GSM/GPRS(2G). Foram criados modelos usando redes MLP, RBF (*Radial Basis Function*) e GMDH-PNN (*Group Method of Data Handling- Probabilistic Neural Network*) e ANFIS (*Adaptive Neuro-Fuzzy Inference System*) para cada célula do conjunto de pesquisa. Foram usados dois anos de relatórios de tráfego de dados e de taxa de sucesso de configuração de chamadas. Os testes que usaram redes GMDH-PNN foram os que obtiveram o melhor resultado.

No trabalho de Lima [10], foi avaliado o desempenho de diferentes modelos de redes neurais para a previsão de um passo da série de bloqueio. O estudo foi desenvolvido com os dados de três células de rede 3G. Para realizar a previsão, foram usados cinco parâmetros reportados pelas células: a taxa de bloqueio, a taxa de disponibilidade da célula telefônica, o tráfego de dados, a taxa de troca de antenas de usuários e o tráfego de voz. Os métodos de previsão utilizados foram as redes MLP, RBF e LSTM. Os testes que alcançaram melhores resultados foram os que usaram redes LSTM.

No presente trabalho, foram desenvolvidos e comparados o desempenho de dois sistemas que realizam a previsão de longo prazo da taxa de bloqueio. A diferença entre os sistemas está na estratégia utilizada para se realizar as previsões de longo prazo. Enquanto um sistema utiliza uma estratégia direta, na qual existe um modelo (uma rede neural, por exemplo) para realizar a previsão de cada estado futuro, o outro sistema utiliza uma estratégia recursiva, na qual as próprias previsões são utilizadas como entradas para fazer as previsões futuras. A previsão foi realizada usando uma base de dados contendo informações de bloqueio de células de rede 3G de diversas regiões do Brasil. A metodologia utilizada para desenvolvimento do trabalho, os resultados e as conclusões são apresentados nas seções II, III e IV, respectivamente.

## II. METODOLOGIA

Inicialmente será apresentado como os dados foram obtidos e tratados (Sec. II-A). Em seguida, dois modelos desenvolvidos para realizar a previsão de múltiplos passos serão apresentados (Sec. II-B). Por fim, serão apresentados os métodos de treinamento (Sec. III-C) e avaliação dos modelos (Sec. II-D).

### A. Obtenção e pré-processamento da base de dados

A base de dados foi obtida a partir de uma rede contendo 21 mil células, com tecnologia 3G, em período de 6 meses, e contendo os seguintes campos 1) identificação da célula, 2) *timestamp* (dia/horário) e 3) taxa de bloqueio dentro de um período de 15 minutos. De toda a base de dados, 1,26% possuía dados de taxas de bloqueio maiores do que zero. Esses dados foram extraídos da base, gerando séries temporais de durações distintas que foram utilizadas para treinar os modelos




Fig. 1: Variação da taxa de bloqueio (eixo y) no tempo (eixo x). Como no intervalo de 00:00 até 1:00 o bloqueio tem um valor maior que 0, criou-se uma série a partir desse intervalo de tempo. Como de 1:45 até 03:30 o valor de bloqueio também apresenta valores maiores que 0, criou-se uma segunda série usando esse intervalo. A primeira série tem duração de 1 hora e a segunda de 1 hora e 45 minutos.

TABELA I: Quantidade de séries na base de dados agrupadas pela quantidade de elementos.

| Duração total do bloqueio | Quantidade de Séries | Porcentagem |
|---------------------------|----------------------|-------------|
| 15min                     | 1.624.138            | 74.40%      |
| 30min                     | 273.920              | 12.54%      |
| 45min                     | 94.280               | 4.30%       |
| 1h-6h                     | 168.996              | 7.75%       |
| 6h-12h                    | 11.988               | 0.54%       |
| 12h-24h                   | 8.207                | 0.37%       |
| Total                     | 2.180.154            | 100%        |

de predição. O método de extração utilizado é ilustrado na Figura 1. Destaca-se que a taxa de bloqueio permanece em 0 (zero) na maior parte do tempo pois esse é o comportamento normal de uma célula, sendo o bloqueio uma anomalia.

Uma das características observada no conjunto de dados é que as séries tendem a ter curta duração, conforme apresentado na Tabela I. Pode ser visto que em 74.40% das vezes em que bloqueios foram reportados, eles não duraram mais do que 15 minutos. Outra característica observada é que a taxa de bloqueio dos primeiros elementos de uma série encontra-se concentrada em valores pequenos, enquanto elementos mais distantes estão mais dispersos, conforme apresentado na Figura 2.

### B. Arquitetura dos Sistemas de Previsão

Foram projetados dois tipos de sistemas de previsão de múltiplos passos utilizando as estratégias Direta e DirRec (Direta Recursiva), respectivamente. [1].

A estratégia Direta utiliza um modelo de previsão para prever cada passo no futuro, tendo como entrada dados reais da série. Por exemplo, considerando que se deseja prever 5 passos no futuro a partir de uma série histórica contendo 10 valores, deve-se construir 5 modelos distintos, cada qual com 10 entradas, sendo que o 1º modelo irá prever o passo 11, o 2º modelo o passo 12, e assim por diante até o 5º modelo.




Fig. 2: Distribuição dos valores de bloqueio agrupados pelos intervalos de tempo.

Note que os modelos fazem a previsão da série  $N$  passos no futuro utilizando as mesmas 10 entradas. O 5º modelo, por exemplo, recebe 10 entradas e faz a previsão do passo 15 sem conhecer os valores da série nos passos 11, 12, 13 e 14.

Seguindo esta estratégia, foi desenvolvido um sistema, denominado *Sistema Direto*, contendo várias redes MLPs (*Multi Layer Perceptron*). Este sistema é formado por 20 subsistemas, sendo que cada um deles recebe uma quantidade diferente de entradas (de 1 a 20), conforme ilustrado na Figura 3. O primeiro subsistema recebe uma entrada ( $y_1$ ) e faz a previsão dos próximos 20 passos, sendo que para cada passo foi desenvolvida uma rede MLP. A rede  $MLP_{1,1}$ , por exemplo, recebe uma entrada ( $y_1$ ) e gera como saída o valor da taxa de bloqueio de 1 passo no futuro ( $\hat{y}_2$ ). Já a rede  $MLP_{1,20}$ , que também recebe a entrada  $y_1$ , gera como saída o valor da taxa de bloqueio de 20 passos no futuro ( $\hat{y}_{21}$ ). O segundo subsistema recebe duas entradas ( $y_1, y_2$ ) e faz a previsão dos próximos 19 passos (de  $\hat{y}_3$  até  $\hat{y}_{21}$ ). O número de entradas em cada subsistema varia até o último subsistema que recebe 20 entradas e faz a previsão do próximo passo ( $\hat{y}_{21}$ ). No total, foram desenvolvidas 210 redes MLPs, sendo 20 redes do primeiro sistema, 19 do segundo, 18 do terceiro, e assim por diante até uma rede do último sistema.

Na segunda estratégia de modelagem, DirRec, os modelos fazem a previsão de apenas um passo no futuro. Para realizar a previsão de múltiplos passos, os modelos são interligados de tal maneira que o modelo que faz a previsão do passo  $t+N$  receba, como entrada, a saída do modelo que faz a previsão do passo  $t+(N-1)$ . Por exemplo, considerando que se deseja prever 5 passos no futuro a partir de uma série histórica contendo 10 valores, deve-se construir 5 modelos distintos, sendo que o 1º modelo receberá como entrada os 10 valores da série histórica e fará a previsão do passo 11. O 2º modelo receberá como entrada os mesmos 10 valores da série histórica mais o valor previsto pelo 1º modelo e fará a previsão do passo 12. Este processo se repete até o passo 15.

A estrutura do sistema que utiliza a estratégia DirRec é ilustrada na Figura 4. Cada subsistema possui uma quantidade diferente de entradas contendo valores da série histórica (ex.  $[y_1]$  para o subsistema 1,  $[y_1 y_2]$  para o subsistema 2]). O subsistema 1 possui 20 redes MLPs, o subsistema 2 possui

## Sistema Direto

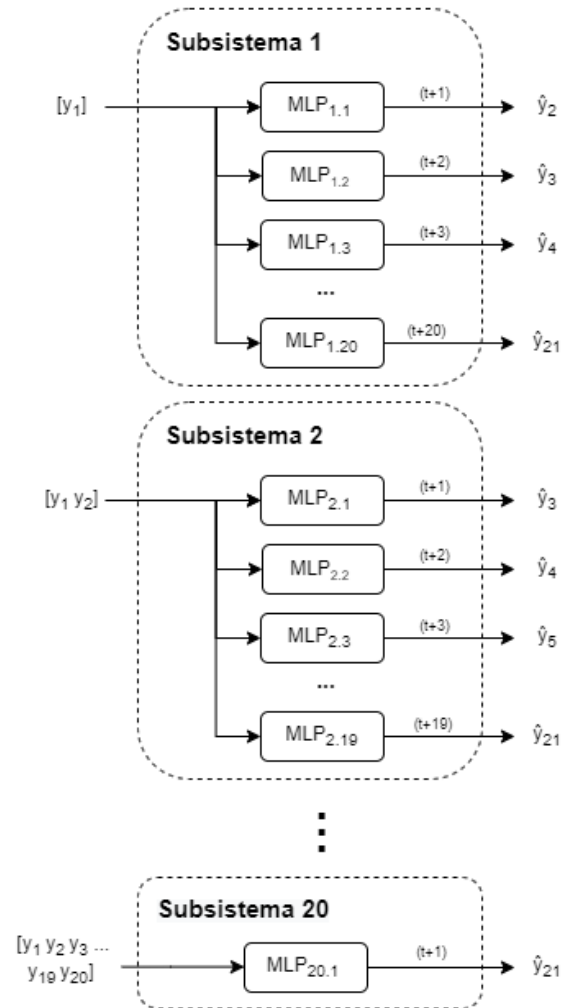


Fig. 3: Arquitetura do Sistema Direto de previsão. Cada retângulo de linha pontilhada representa um subsistema. Note que o número de entradas (ex.  $[y_1 y_2]$ ) varia em cada subsistema. Cada retângulo de linha contínua representa uma rede MLP diferente. No subíndice  $m.n$  (de cada rede MLP), o valor de  $m$  representa o número de entradas da rede e o valor de  $n$  representa o passo no futuro que se deseja prever.

19 redes e, assim por diante, até o subsistema 20 que possui apenas 1 rede. Os subsistemas compartilham as mesmas redes. Por exemplo, a rede  $MLP_{2,1}$  está nos subsistemas 1 e 2. A diferença é que enquanto no subsistema 1 a rede  $MLP_{2,1}$  recebe como entrada 1 valor da série histórica ( $y_1$ ) e 1 valor previsto ( $\hat{y}_2$ ), no subsistema 2 a mesma rede recebe como entrada dois valores da série histórica ( $[y_1 y_2]$ ).

O Sistema DirRec funciona da seguinte maneira: quando a série histórica possui um único valor, utiliza-se o subsistema 1 para fazer a previsão dos próximos 20 passos. A entrada  $y_1$  é aplicada à rede  $MLP_{1,1}$  para gerar a previsão do passo 2 ( $\hat{y}_2$ ). O valores  $y_1$  e  $\hat{y}_2$  são utilizados como entrada da

## Sistema DirRec

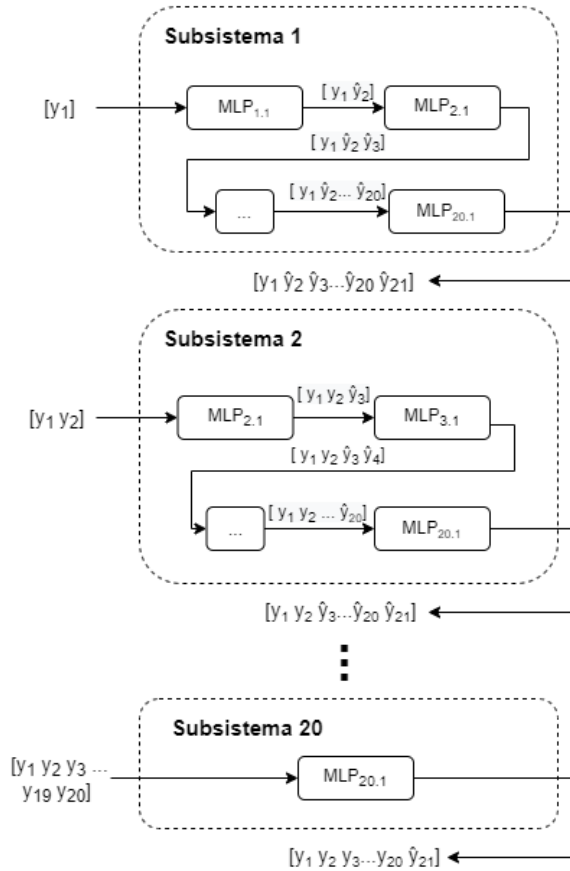


Fig. 4: Arquitetura do Sistema DirRec de previsão. Cada retângulo de linha pontilhada representa um subsistema. Note que o número de entradas (ex.  $[y_1 y_2]$ ) varia em cada subsistema. Cada retângulo de linha contínua representa uma rede MLP diferente. No subíndice  $m.n$  (de cada rede MLP), o valor de  $m$  representa o número de entradas da rede e o valor de  $n$  representa o passo no futuro que se deseja prever.

rede  $MLP_{2,1}$ . A rede  $MLP_{2,1}$ , por sua vez, gera a previsão do segundo passo ( $\hat{y}_3$ ) a partir  $y_1$ . A saída  $\hat{y}_3$  é concatenada com os valores anteriores ( $[y_1 \hat{y}_2]$ ) gerando a entrada da de  $MLP_{3,1}$ . Esse procedimento se repete até a rede  $MLP_{20,1}$  que faz a previsão do 21º elemento da série. Quando a série histórica possui dois valores, o subsistema 2 é utilizado. Neste caso, os dois valores reais são aplicados diretamente na rede  $MLP_{2,1}$ . A rede  $MLP_{2,1}$  gera a saída  $\hat{y}_3$  que é concatenada a  $[y_1 y_2]$  gerando a entrada de  $MLP_{3,1}$ . Novamente, o procedimento se repete até a rede  $MLP_{20,1}$ . Quando a série histórica possui 20 valores, o subsistema 20 será utilizado para realizar a previsão do próximo passo  $\hat{y}_{21}$ .

É importante notar que, os sistemas de previsão propostos neste trabalho têm como objetivo fazer a previsão de como irá evoluir a taxa de bloqueio de uma célula a partir do momento que algum bloqueio ocorreu. Por este motivo, os sistemas Direto e DirRec possuem diferentes subsistemas com

quantidades diferentes de entradas.

### C. Treinamento das redes MLPs

A modelagem das redes MLPs, juntamente com as funções de perda, otimização e ativação foram implementadas usando o pacote disponibilizado pelo Tensor Flow [11]. Os modelos foram implementados utilizando a função ‘RMSE’ para função de perda, ‘Adam’ para função de otimização e ‘ReLU’ para função de ativação. O treino de todas as redes foi feito em 100 épocas. No treinamento das redes também foi empregado o método de validação cruzada K-Fold [12], usando um valor de  $K$  igual a 4.

Para auxiliar na definição do número de neurônios que seriam usados nas camadas ocultas das redes MLPs, foram feitos testes usando 5, 10, 20, 30 neurônios na primeira camada e 0, 5, 10, 20 e 30 na segunda camada. Foram calculados os erros de previsão do passo  $t+1$  para modelos com tamanho de entrada de 1 a 20. A configuração com menor erro foi escolhida para a implementação dos sistemas Direto e DirRec.

Para realizar o treinamento das redes MLP, foi criada uma base de dados balanceada contendo as séries de bloqueio. O balanceamento foi necessário pois a maior parte dos valores de bloqueio eram menores que 40%, o que poderia gerar *overfitting* dos modelos. O balanceamento foi feito criando quatro conjuntos de séries, em cada conjunto o elemento que deveria ser previsto pela rede estava dentro de uma faixa de valor. A 1ª parte do conjunto balanceado foi formada por séries cujo valor previsto estava entre 0 e 25. A 2ª por valores a serem previstos entre 25 e 50, a 3ª por valores entre 50 e 75 e a 4ª por valores entre 75 e 100. Cada uma dessas bases de dados balanceadas foi composta por 2 mil séries que usaram uma distribuição de 25% (500 séries) para cada conjunto. Dentro do 1º conjunto, foi separado que 50 séries (do total de 500) teriam o valor previsto igual à 0. Na Figura 5 é ilustrado como foi feito o balanceamento.

O treino e o teste das redes MLP foram realizados usando a base balanceada, seguindo estratégia de K-folds, com  $K$  igual a 4. O treinamento foi realizado em 100 épocas e foi usada a estratégia de correção de valores mini-batch igual a 100.

### D. Avaliação dos Sistemas de previsão Multi-Passo

Após as redes MLPs serem treinadas individualmente e as arquiteturas dos sistemas de previsão terem sido implementadas (conforme descrito na Seção II-B), deu-se início a etapa de avaliação dos Sistemas Direto e DirRec.

O conjunto de dados para avaliação dos sistemas foi formado por 2 mil séries usando como referência o 21º elemento (que é o último valor previsto nos sistemas). Dentre o conjunto das séries selecionadas, 25% delas possuíam um valor entre 0 e 25 no 21º elemento, 25% entre 25 e 50, 25% entre 50 e 75, e por último, 25% entre 75 e 100.

O processo de avaliação de cada sistema foi feito em 20 etapas. Na primeira etapa foi fornecido aos sistemas Direto e DirRec apenas o 1º elemento das séries do conjunto de avaliação. A partir do 1º elemento, foram feitas as previsões até o 21º elemento e o RMSE de cada passo foi calculado.

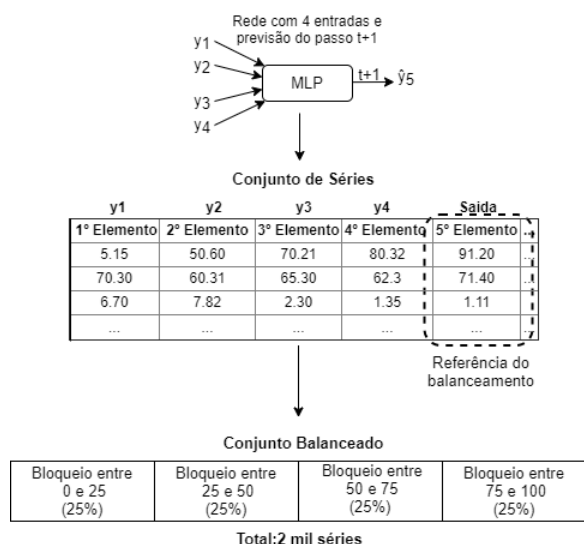


Fig. 5: Exemplo de como foi feito o balanceamento dos dados para treinamento da rede que possui 4 entradas e faz a previsão do passo  $t+1$ . O esquema da rede MLP é ilustrado no topo da figura. As séries que compõem a base de dados de treinamento possuem 5 elementos, sendo que o 5º elemento corresponde à saída que deve ser prevista pela rede. Vinte e cinco por cento dos valores do 5º elemento estão entre 0 e 25. Outros 25% estão entre 25 e 50, e assim por diante, conforme ilustrado na parte inferior da figura.

Na segunda etapa de avaliação, forneceu-se os dois primeiros elementos da série e foram previstos os 19 elementos seguintes e calculados os respectivos erros. Este processo se repetiu até a última etapa na qual foram usados 20 elementos das séries para previsão do 21º passo.

Para se ter um parâmetro de comparação de desempenho dos sistemas Direto e Direc, foi criado um terceiro sistema, chamado Naive, que realiza as previsões de forma ingênua. Foram testadas quatro métodos de previsão para o sistema ingênuo. Os três primeiros métodos usaram regressão polinomial de 2º, 3º e 4º graus e o quarto método utilizou a média dos valores da entrada para prever todos os passos seguintes. Dos quatro métodos testados, o sistema que utilizou a média obteve melhor resultado (menor RMSE). Sendo assim, ele foi escolhido para ser usado na comparação com os sistemas Direto e DirRec.

### III. RESULTADOS

#### A. Treinamento das redes

Para determinar o número de neurônios nas camadas ocultas das redes, foram treinadas 1.600 redes. Esse número de treinos se deve aos 20 tamanhos de entrada possíveis, multiplicadas por 20 combinações de neurônios nas camadas ocultas, multiplicadas por 4 combinações de treinos (devido ao uso do K-Folds).

Nas Tabelas II e III são apresentados os resultados dos experimentos variando o número de camadas das redes com

TABELA II: Experimentos variando o número de neurônios nas redes com 5 entradas. As linhas representam o número de neurônios na primeira camada oculta (L1) e as colunas o número de neurônios na segunda camada (L2). A média do RMSE é 15,535 com desvio padrão de 0,201.

| L1xL2 | 0      | 5      | 10     | 20     | 30     |
|-------|--------|--------|--------|--------|--------|
| 5     | 15,982 | 15,795 | 15,733 | 15,733 | 15,526 |
| 10    | 15,890 | 15,643 | 15,533 | 15,472 | 15,324 |
| 20    | 15,635 | 15,445 | 15,404 | 15,333 | 15,411 |
| 30    | 15,398 | 15,445 | 15,312 | 15,334 | 15,355 |

TABELA III: Experimentos variando o número de neurônios nas redes com 10 entradas. A média do RMSE é 13,392 com desvio padrão de 0,104.

| L1xL2 | 0      | 5      | 10     | 20     | 30     |
|-------|--------|--------|--------|--------|--------|
| 5     | 13,587 | 13,540 | 13,487 | 13,333 | 13,441 |
| 10    | 13,524 | 13,352 | 13,404 | 13,308 | 13,312 |
| 20    | 13,443 | 13,513 | 13,403 | 13,347 | 13,392 |
| 30    | 13,221 | 13,232 | 13,415 | 13,276 | 13,300 |

5 e 10 entradas, respectivamente. Nota-se que diferentes combinações de neurônios nas camadas geram pouca variação no RMSE. Essa pequena variação no RMSE se repetiu para todos os tamanhos de entradas testados, conforme pode ser visto pelos valores de desvio padrão apresentados na Tabela IV. Observa-se que o erro decai com o aumento do número das entradas se estabilizando aproximadamente em 13 para entradas maiores ou iguais a 8 elementos.

Na Tabela V é apresentada a média dos testes realizados agrupados pelas combinações de neurônios usadas. A configuração da rede com menor média de RMSE (30 neurônios em L1 e 5 em L2) foi escolhida para implementar os sistemas Direto e DirRec; ou seja, 210 redes com 30 neurônios em L1 e 5 em L2 foram treinadas para comporem os dois sistemas.

TABELA IV: Média e Desvio Padrão dos testes com diferentes número de neurônios agrupados pelo tamanho de entrada.

| Tamanho da Entradas | RMSE Médio | Std(RMSE) |
|---------------------|------------|-----------|
| 1                   | 22,826     | 0,625     |
| 2                   | 18,296     | 0,436     |
| 3                   | 16,668     | 0,339     |
| 4                   | 15,790     | 0,280     |
| 5                   | 15,535     | 0,201     |
| 6                   | 14,739     | 0,184     |
| 7                   | 14,698     | 0,138     |
| 8                   | 13,887     | 0,126     |
| 9                   | 13,683     | 0,147     |
| 10                  | 13,392     | 0,104     |
| 11                  | 13,556     | 0,070     |
| 12                  | 13,217     | 0,053     |
| 13                  | 12,926     | 0,078     |
| 14                  | 13,196     | 0,087     |
| 15                  | 13,008     | 0,117     |
| 16                  | 13,088     | 0,108     |
| 17                  | 12,964     | 0,084     |
| 18                  | 13,390     | 0,069     |
| 19                  | 13,369     | 0,075     |
| 20                  | 13,623     | 0,048     |

TABELA V: Média dos testes com diferentes tamanhos de entradas agrupados pela combinação de neurônios. Cada célula contém a média dos testes para os 20 tamanhos de entrada possíveis.

| L1xL2 | 0      | 5      | 10     | 20     | 30     |
|-------|--------|--------|--------|--------|--------|
| 5     | 14,955 | 14,780 | 14,658 | 14,541 | 14,534 |
| 10    | 14,753 | 14,672 | 14,551 | 14,505 | 14,495 |
| 20    | 14,631 | 14,577 | 14,505 | 14,513 | 14,504 |
| 30    | 14,549 | 14,494 | 14,508 | 14,552 | 14,573 |

Na Tabela VI é apresentado o resultado dos treinos das 210 redes. O sistema DirRec foi implementado utilizando as 20 redes que fazem a previsão do passo  $t+1$ . Já o sistema Direto foi implementado utilizando todas as 210 redes treinadas. A análise destes dois sistemas é apresentada na próxima seção.

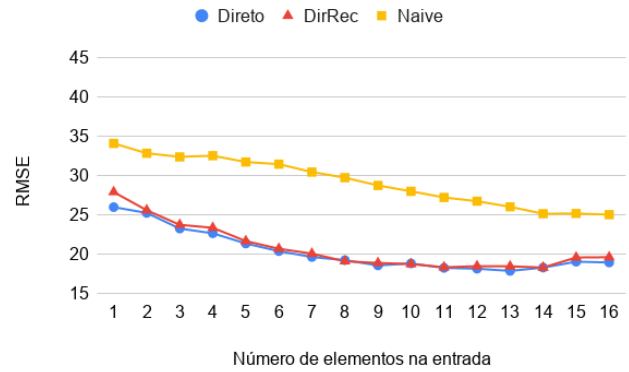
### B. Avaliações dos sistemas de previsão

O desempenho dos sistemas para a previsão dos passos  $t+5$  e  $t+10$  é apresentado na Figura 6. Na Figura 6a, pode ser visto que o erro da previsão do sistema Direto usando apenas 1 elemento na entrada é de aproximadamente 26. Note que, neste caso, está sendo feita a previsão do 6º elemento ( $t+5$ ) utilizando o 1º elemento da série. Na Figura 6b são mostradas as previsões do passo  $t+10$ . O erro de previsão do sistema Direto usando apenas 1 elemento como entrada é de aproximadamente 29. Neste caso, foi usado apenas o 1º elemento da série para prever o 11º elemento. Observa-se que depois de um determinado tamanho de entrada, os erros dos sistemas Direto e DirRec se estabilizam dentro de uma faixa de valor. Também pode ser visto que o erro do sistema Naive é sempre maior do que o erro dos outros dois sistemas.


Na Figura 8 é apresentado o RMSE das previsões de todos os elementos (até o 21º) para todos tamanhos de entrada (de 1 a 20). Na Figura 8a, a curva referenciada como “2 Entradas” (ver legenda) significa que o sistema Direto está fazendo as previsões utilizando 2 valores reais de taxa de bloqueio. A primeira previsão feita pelo sistema se inicia no 3º elemento. Os valores seguintes da curva são os erros das previsões dos elementos seguintes (até o 21º elemento). Nota-se que os erros, para todas as entradas, se aproximam de um valor constante para previsões de passos mais distantes. Por exemplo, os erros das previsões com 5 entradas, do 15º elemento em diante, do sistema DirRec, se mantêm em torno de 27.

### C. Comparação entre os modelos

Para comparar os sistemas de previsão, foi feita uma análise da distribuição dos RMSEs considerando todas as possibilidades de entradas (de 1 a 20) e todas as previsões até o 21º elemento, ou seja, foram utilizados todos os valores de RMSEs de cada um dos gráficos da Figura 8. Conforme apresentado na Figura 7, os sistemas Direto e DirRec obtiveram desempenhos semelhantes. O intervalo de confiança para os sistemas Direto e DirRec foi de 21,13 a 22,86 e de 21,02 a 22,97, respectivamente, com mesma mediana de 22. Já para o sistema Naive, o intervalo de confiança foi de 29,09 a 31,90 com mediana de 30,50, o que indica uma vantagem



(a) RMSE da previsão do passo  $t+5$  utilizando os 3 sistemas: Direto, DirRec e Naive (conforme legenda).



(b) RMSE da previsão do passo  $t+10$  utilizando os 3 sistemas: Direto, DirRec e Naive (conforme legenda).

Fig. 6: RMSE da previsão dos passos  $t+5$  e  $t+10$

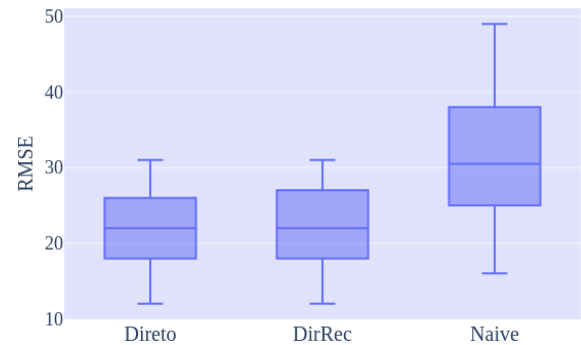


Fig. 7: Comparação entre as distribuições de RMSEs (eixo y) dos sistemas Direto, DirRec e Naive (eixo x).

na utilização dos sistemas na previsão do comportamento da taxa de bloqueio.

### D. Exemplo de previsões feitas pelos sistemas

Na Figura 9 é apresentado a aplicação dos modelos para a previsão de uma série. Os modelos Direto e DirRec geraram estimativas semelhantes. Na Figura 9a, a previsão do 6º elemento ( $t+1$ ) feita pelos sistemas Direto e DirRec foram

TABELA VI: RMSE do teste das redes MLP com 30 neurônios na primeira camada oculta e 5 neurônios na segunda camada oculta. Cada elemento da tabela mostra a média do RMSE dos 4 testes gerados pelo K-Folds. As linhas da tabela indicam quantas entradas o modelo recebe e as colunas indicam o passo no futuro previsto pelo modelo.

| Entradas | t+1  | t+2  | t+3  | t+4  | t+5  | t+6  | t+7  | t+8  | t+9  | t+10 | t+11 | t+12 | t+13 | t+14 | t+15 | t+16 | t+17 | t+18 | t+19 | t+20 |
|----------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|
| 1        | 22,7 | 27,2 | 26,4 | 28,3 | 30,0 | 27,5 | 29,8 | 29,0 | 29,7 | 28,7 | 28,5 | 29,0 | 30,2 | 29,3 | 29,2 | 29,1 | 29,0 | 29,0 | 29,1 | 29,2 |
| 2        | 18,4 | 22,7 | 24,5 | 24,2 | 25,1 | 27,1 | 26,7 | 27,3 | 27,2 | 28,1 | 27,7 | 27,8 | 28,1 | 28,2 | 28,1 | 28,0 | 28,0 | 28,0 | 28,0 | 28,0 |
| 3        | 16,5 | 20,8 | 22,9 | 23,1 | 24,3 | 25,5 | 25,5 | 26,5 | 26,1 | 26,2 | 27,4 | 26,9 | 26,9 | 27,1 | 27,4 | 28,1 | 27,4 | 28,1 |      |      |
| 4        | 15,6 | 19,4 | 21,3 | 22,1 | 23,1 | 23,9 | 24,2 | 25,5 | 24,6 | 25,8 | 27,4 | 26,6 | 26,8 | 27,1 | 27,4 | 26,9 | 26,9 |      |      |      |
| 5        | 15,4 | 18,8 | 19,8 | 22,0 | 21,6 | 23,6 | 24,2 | 24,9 | 24,7 | 24,7 | 26,4 | 26,3 | 26,3 | 25,5 | 26,5 | 26,9 |      |      |      |      |
| 6        | 14,5 | 17,4 | 19,3 | 20,2 | 20,7 | 22,4 | 23,0 | 23,7 | 23,9 | 25,1 | 25,4 | 25,2 | 25,7 | 25,9 | 26,3 |      |      |      |      |      |
| 7        | 14,6 | 17,1 | 18,5 | 19,4 | 19,7 | 21,9 | 22,4 | 23,7 | 24,6 | 23,8 | 24,8 | 26,1 | 24,5 | 25,3 |      |      |      |      |      |      |
| 8        | 13,7 | 16,3 | 17,8 | 19,2 | 19,6 | 21,0 | 21,6 | 22,4 | 22,9 | 24,2 | 23,7 | 24,4 | 24,2 |      |      |      |      |      |      |      |
| 9        | 13,5 | 16,3 | 17,6 | 18,4 | 19,7 | 20,7 | 21,0 | 22,2 | 23,4 | 23,8 | 22,6 | 23,6 |      |      |      |      |      |      |      |      |
| 10       | 13,2 | 15,6 | 17,0 | 17,9 | 19,1 | 20,3 | 21,3 | 22,3 | 22,7 | 23,1 | 22,9 |      |      |      |      |      |      |      |      |      |
| 11       | 13,4 | 15,5 | 17,3 | 17,8 | 19,6 | 20,8 | 20,8 | 21,0 | 21,5 | 23,0 |      |      |      |      |      |      |      |      |      |      |
| 12       | 13,2 | 16,0 | 17,2 | 17,7 | 19,6 | 19,4 | 20,7 | 20,7 | 21,9 |      |      |      |      |      |      |      |      |      |      |      |
| 13       | 13,0 | 16,3 | 17,5 | 18,6 | 18,7 | 19,5 | 19,7 | 20,6 |      |      |      |      |      |      |      |      |      |      |      |      |
| 14       | 13,2 | 15,5 | 16,9 | 18,0 | 18,8 | 19,9 | 19,8 |      |      |      |      |      |      |      |      |      |      |      |      |      |
| 15       | 13,0 | 16,2 | 17,1 | 18,3 | 19,6 | 19,9 |      |      |      |      |      |      |      |      |      |      |      |      |      |      |
| 16       | 13,0 | 15,5 | 16,7 | 18,3 | 19,4 |      |      |      |      |      |      |      |      |      |      |      |      |      |      |      |
| 17       | 12,9 | 15,6 | 16,8 | 18,4 |      |      |      |      |      |      |      |      |      |      |      |      |      |      |      |      |
| 18       | 13,4 | 15,4 | 17,0 |      |      |      |      |      |      |      |      |      |      |      |      |      |      |      |      |      |
| 19       | 13,4 | 15,3 |      |      |      |      |      |      |      |      |      |      |      |      |      |      |      |      |      |      |
| 20       | 13,6 |      |      |      |      |      |      |      |      |      |      |      |      |      |      |      |      |      |      |      |

próximas do valor da série real: o valor real era 16,54 e o valor previsto tanto pelo Direto quanto DirRec foi 18,85. Um ponto que deve ser destacado é que a previsão do DirRec e Direto sempre são iguais para a previsão do passo t+1. Isso ocorre pois a rede que faz a previsão deste passo é a mesma para os dois sistemas. Na previsão do 7º elemento (t+2), os sistemas Direto e DirRec também previam resultados próximos do valor da série real: o valor real era 18,19, o sistema Direto previu 19,64 e o sistema DirRec previu 18,19. Nas previsões seguintes ao passo t+2, apesar das previsões não acompanharem as oscilações na taxa de bloqueio, elas seguem a tendência de comportamento da série. Para ambos os tamanhos de entrada, o modelo Naive subestimou a porcentagem de bloqueio ao longo de toda a janela de previsão.

#### IV. DISCUSSÕES E CONCLUSÕES

O desenvolvimento do presente trabalho possibilitou o estudo do desempenho de diferentes arquiteturas de redes MLPs para o problema de previsão de taxas de bloqueio em redes de telefonia celular. No seu desenvolvimento, foi avaliado o desempenho das redes considerando diferentes combinações de neurônios nas camadas ocultas. Foi avaliado também o desempenho na previsão de múltiplos passos por meio da utilização de duas estratégias: Direta e DirRec (Direta Recursiva).

Avaliando os resultados encontrados e observando as previsões feitas pelos dois sistemas (Direto e DirRec), foi visto que ambos fazem previsões semelhantes e os erros medidos têm valores bem próximos. Os dois sistemas fizeram previsões de curto prazo (15 minutos) com RMSE de 12% e longo prazo (5 horas) com RMSE de 31%. Além disso, a distribuição do RMSEs dos dois sistemas também foi semelhante (mesma mediana e intervalos de confiança próximos). Por esses motivos, em termos da qualidade das previsões, não há vantagem de


um sistema sobre o outro. Porém, a utilização do Sistema DirRec é mais viável por demandar um número menor de redes (20 redes para o sistema DirRec e 210 para o Direto) e, desta maneira, ter um treinamento mais simples e um custo computacional de operação menor.

Como trabalhos futuros, a previsão poderia ser feita utilizando uma base de dados com outras informações (*features*) relacionadas à taxa de bloqueio, tais como: o volume de tráfego de pacotes e o volume de tráfego de voz. A utilização de mais *features* poderia diminuir o erro das previsões e também permitir a previsão do início de um bloqueio (e não apenas prever como ele se comportará após o seu início). Os sistemas Direct and Dirrec também poderiam ser implementados com outros modelos de previsão, tais como: ARIMA, LSTM e Holt-Winters. Além de procurar meios para melhorar o desempenho do modelo, uma outra linha de pesquisa seria o estudo da previsão de bloqueio para outras tecnologias de redes, tais como a 4G.


Por fim, espera-se que esse trabalho possa ser usado como referência para o desenvolvimento de outros modelos para a previsão da taxa de bloqueio, permitindo a criação de uma ferramenta funcional para sistemas de monitoramento de redes telefônicas.

#### AGRADECIMENTOS


Os autores gostariam de agradecer ao CEFET-MG pelo suporte financeiro, sem o qual esse trabalho não teria sido possível.



(a) RMSE do Sistema Direto.



(b) RMSE do Sistema DirRec.



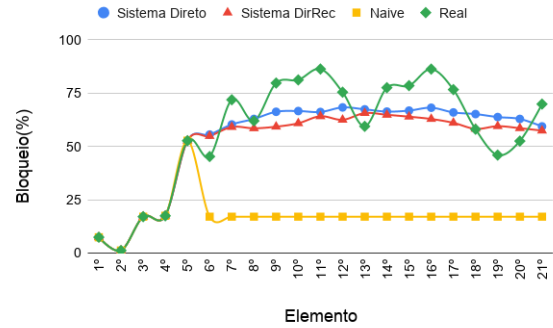
(c) RMSE do Sistema Naive.




Fig. 8: RMSE da avaliação dos sistemas. O eixo horizontal mostra o elemento que está sendo previsto e o eixo vertical mostra o erro RMSE da previsão. As curvas (ver legenda) mostram os valores de RMSE das previsões realizadas a partir de um determinado tamanho de entrada.

## REFERÊNCIAS

- [1] A. Sorjamaa and A. Lendasse, "Time series prediction using dirrec strategy,," in *Esann*, vol. 6, pp. 143–148, 2006.
- [2] S. Kyriazakos, N. Papaoulakis, D. Nikitopoulos, E. Gkroustiotis, C. Kechagias, C. Karambalis, and G. Karetsos, "A comprehensive study and performance evaluation of operational gsm and gprs systems under varying traffic conditions,," in *11th IST Mobile Summit*, Citeseer, 2002.
- [3] E. B. Rodrigues, F. R. Cavalcanti, and S. Wänstedt, "Congestion control for wireless cellular systems with applications to umts,," in *Optimizing Wireless Communication Systems*, pp. 141–185, Springer, 2009.
- [4] C. L. NETO, "Previsão de Tráfego em Redes IP,," 2018. Monografia (Bacharel em Engenharia Elétrica), UFMG (Universidade Federal de Minas Gerais), Belo Horizonte, Brasil.
- [5] X. Dong, W. Fan, and J. Gu, "Predicting lte throughput using traffic time series,," *ZTE Communications*, vol. 13, no. 4, pp. 61–64, 2015.
- [6] P. Torres, P. Marques, H. Marques, R. Dionísio, T. Alves, L. Pereira, and J. Ribeiro, "Data analytics for forecasting cell congestion on lte networks,," in *2017 Network Traffic Measurement and Analysis Conference (TMA)*, pp. 1–6, IEEE, 2017.



(a) Previsão da taxa de bloqueio do 6° ao 21° da série utilizando 5 valores de entrada.



(b) Previsão da taxa de bloqueio do 11° ao 21° da série utilizando 10 valores de entrada.

Fig. 9: Casos de previsão da taxa de bloqueio. A curva verde representa a série real. A série real é a mesma nos gráficos (a) e (b). Enquanto em (a) a previsão é feita utilizando, como entrada, os 5 primeiros elementos da série, em (b) a previsão é feita usando dos 10 primeiros elementos.

- [7] J. Chen, H. Xing, H. Yang, and L. Xu, "Network traffic prediction based on lstm networks with genetic algorithm,," in *International Conference on Signal and Information Processing, Networking and Computers*, pp. 411–419, Springer, 2018.
- [8] W. Wang, C. Zhou, H. He, W. Wu, W. Zhuang, and X. S. Shen, "Cellular traffic load prediction with lstm and gaussian process regression,," in *ICC 2020-2020 IEEE International Conference on Communications (ICC)*, pp. 1–6, IEEE, 2020.
- [9] A. Ozovehe, O. U. Okereke, A. E. Chibuzo, and A. U. Usman, "Comparative analysis of traffic congestion prediction models for cellular mobile macrocells,," *European Journal of Engineering Research and Science*, vol. 3, no. 6, pp. 32–38, 2018.
- [10] G. P. LIMA, "Previsão de bloqueio em células 3G - Um estudo de caso,," 2018. Monografia (Bacharel em Engenharia Elétrica), UFMG (Universidade Federal de Minas Gerais), Belo Horizonte, Brasil.
- [11] M. Abadi, A. Agarwal, P. Barham, E. Brevdo, Z. Chen, C. Citro, G. S. Corrado, A. Davis, J. Dean, M. Devin, S. Ghemawat, I. Goodfellow, A. Harp, G. Irving, M. Isard, Y. Jia, R. Jozefowicz, L. Kaiser, M. Kudlur, J. Levenberg, D. Mané, R. Monga, S. Moore, D. Murray, C. Olah, M. Schuster, J. Shlens, B. Steiner, I. Sutskever, K. Talwar, P. Tucker, V. Vanhoucke, V. Vasudevan, F. Viégas, O. Vinyals, P. Warden, M. Wattenberg, M. Wicke, Y. Yu, and X. Zheng, "TensorFlow: Large-scale machine learning on heterogeneous systems,," 2015. Software available from tensorflow.org.
- [12] P. Refaeilzadeh, L. Tang, and H. Liu, *Cross-Validation*, pp. 532–538. Boston, MA: Springer US, 2009.