

Economia de Energia através da Configuração Inteligente de Parâmetros de Camada Física em Redes LoRa

Mário Nascimento Carvalho Filho¹ e Miguel Elias M. Campista¹

¹Grupo de Teleinformática e Automação
Universidade Federal do Rio de Janeiro (UFRJ)

{carvalho,miguel}@gta.ufrj.br

Abstract. *LoRa (Long Range) technology is characterized by long-distance communications and strong resilience to interference. In LoRa, the modulation is adjusted to allow higher data transmission rates due to the reception sensitivity threshold and communication distance. The spreading factor and transmission power, in turn, are directly related to energy consumption, influencing network performance. This paper proposes the use of supervised learning techniques for simultaneous selection of the spreading factor and transmission power. This approach differs from the literature as it configures two parameters in a supervised way instead of just one, the scattering factor. Through simulations of a LoRa network, different learning techniques are evaluated. Simulations compare the performance of the proposal with the traditional LoRaWAN protocol and the state-of-the-art in the intelligent selection of the spreading factor. The results reveal that the proposal can predict transmission success and adjust the referred parameters to reduce energy consumption without reducing the throughput and packet delivery rate.*

Resumo. *A tecnologia LoRa (Long Range) é caracterizada por comunicações em longa distância e forte resiliência a interferências. No LoRa, a modulação é ajustada para permitir maiores taxas de transmissão de dados em função do limiar de sensibilidade de recepção e distância de comunicação. O fator de espalhamento e a potência de transmissão, por sua vez, estão diretamente relacionados com o consumo de energia, influenciando no desempenho da rede. Este artigo propõe o uso de técnicas de aprendizado supervisionado para seleção simultânea do fator de espalhamento e potência de transmissão. Essa abordagem se diferencia da literatura já que configura de forma supervisionada dois parâmetros ao invés de apenas um, o fator de espalhamento. Através de simulações de uma rede LoRa, diferentes técnicas de aprendizado são avaliadas. Simulações comparam o desempenho da proposta com o protocolo LoRaWAN tradicional e o estado da arte com seleção inteligente do fator de espalhamento. Os resultados mostram que a proposta é capaz de prever o sucesso da transmissão e ajustar os referidos parâmetros de modo a reduzir o consumo de energia, sem prejuízo da vazão e da taxa de entrega de pacotes.*

1. Introdução

Atualmente, as tecnologias por trás do paradigma da Internet das Coisas (*Internet of Things* – IoT), que vão desde microeletrônica até computação em nuvem, têm se tornado a base do desenvolvimento de inúmeras aplicações e serviços modernos. Como resultado, a quantidade de dispositivos IoT têm crescido nos últimos anos, exigindo pesquisas que atendam às demandas da sociedade. Nesse contexto, existem aplicações que, apesar da grande quantidade de dispositivos conectados, geram um montante relativamente pequeno de dados. Esse cenário favorece redes que ofereçam conectividade em larga escala, cobertura de grandes áreas e baixo consumo de energia, como é o caso das redes LPWAN (*Low Power Wide Area Networks*) [Raza et al. 2017, Georgiou and Raza 2017].

As LPWANs conectam grandes quantidades de dispositivos de baixo consumo de energia em grandes áreas, o que não é possível com tecnologias convencionais, como o WiFi, as redes celulares e o *bluetooth*. O compromisso entre a taxa de transmissão de dados e o alcance das comunicações permite a redução do consumo de energia [Georgiou and Raza 2017].

As redes WiFi, por exemplo, oferecem tipicamente baixo consumo de energia, porém alcance limitado. Já as redes celulares permitem a cobertura de grandes áreas ao custo de um alto consumo energético, impossibilitando a sua utilização em aplicações cujo consumo de energia é um fator crítico [Raza et al. 2017]. As LPWANs preenchem a necessidade de cobertura de grandes áreas com baixo consumo de energia ao custo de uma baixa taxa de transmissão. Dentre as LPWANs, a tecnologia *Long Range* (LoRa) se destaca.

A especificação LoRa inclui duas camadas, sendo uma delas a camada física (LoRa RF) e, a segunda, a camada de enlace, chamada de LoRaWAN. O baixo consumo de energia e a comunicação através de longas distâncias são características alcançadas pelo LoRa graças ao esquema de modulação *Chirp Spread Spectrum* (CSS), utilizado na camada física, e da utilização do LoRaWAN, baseada no ALOHA puro. Porém, o aumento de colisões devido ao maior tempo no ar (*Time on Air* – ToA) das transmissões de pacotes tem se tornado uma desvantagem da tecnologia. Isso está relacionado à seleção inadequada de potências de transmissão e de fatores de espalhamento por dispositivos finais. De forma simplificada, enquanto maiores potências de transmissão diminuem as oportunidades de reaproveitamento espacial, maiores fatores de espalhamento tornam o tempo no ar dos sinais transmitidos mais longos. Portanto, para minimizar a probabilidade de colisões e, conseqüentemente, aprimorar o acesso ao meio, deve-se buscar a configuração apropriada de fatores de espalhamento e potências de transmissão.

Este trabalho trata da utilização de técnicas de aprendizado supervisionado para selecionar os valores apropriados de potência de transmissão e o fator de espalhamento dos dispositivos finais em redes densas contendo até 1000 dispositivos finais. Até o momento, a literatura dispõe de trabalhos que ou contam com o mecanismo padrão do LoRa, chamado de *Adaptive Data Rate* (ADR) [Cuomo et al. 2017], ou com abordagens que utilizam técnicas de aprendizado de máquinas diferentes das utilizadas neste trabalho. No caso, essas abordagens são mais limitadas [Yatagan and Oktug 2019], por focarem apenas no fator de espalhamento, ou mais energeticamente custosas para os dispositivos finais, por usarem aprendizado por reforço [Ta et al. 2019, Park et al. 2020]. Além de expandir a avaliação de propostas baseadas em aprendizado de máquinas supervisionado que con-

figuram apenas o fator de espalhamento, este trabalho propõe a configuração em conjunto do fator de espalhamento e potência de transmissão a partir de modelos de aprendizado de máquinas supervisionado. A ideia é combinar ambos os parâmetros de modo que as transmissões se mantenham bem sucedidas, sem que haja desperdício de energia. As técnicas de aprendizado supervisionado permitem a seleção do fator de espalhamento e potência de transmissão, supondo que a rede não é degradada por tecnologias externas (ambiente estático) de forma a obter uma maior taxa de entrega de pacotes e um menor consumo de energia de transmissão em relação ao mecanismo ADR, a um custo computacional menor que as técnicas de aprendizado por reforço. As propostas são avaliadas para cenários em que a largura de banda pode assumir o valor de 125 ou 500 kHz. Dessa forma, é possível avaliar o desempenho em condições de mais ou menos recursos físicos disponíveis, já que o aumento da largura de banda significa o aumento na sensibilidade do *gateway* e o aumento da taxa de transmissão para todos os fatores de espalhamento.

Os resultados mostram que, em relação ao caso da configuração apenas do fator de espalhamento, o uso das técnicas de aprendizado resulta em um aumento da taxa de entrega de pacotes ao custo de um maior consumo de energia em relação ao mecanismo ADR do LoRa. Já ao caso da configuração tanto o fator de espalhamento quanto a potência de transmissão, de forma geral, apresenta menor consumo de energia em relação aos modelos que configuram apenas o fator de espalhamento. Em comparação ao ADR, a proposta de ajuste tanto da potência de transmissão quanto do fator de espalhamento permite um aumento na taxa de entrega de pacotes com redução no consumo de energia. Este último resultado, em particular, é considerado relevante, uma vez que diferencia este trabalho da literatura e confirma que o uso de técnicas de aprendizado supervisionado podem contribuir com as redes LoRa.

Este trabalho está organizado como se segue. A Seção 2 revisa os principais conceitos do LoRa, levando em conta o necessário para a compreensão da proposta, enquanto a Seção 3 introduz o estado da arte em configuração de parâmetros de camada física do LoRa. A Seção 4 introduz a proposta deste trabalho que utiliza técnicas de aprendizado supervisionado para configuração dos parâmetros de rede LoRa. Já a Seção 5 detalha o ambiente de simulação. A Seção 6 define quatro diferentes configurações em termos de largura de banda e parâmetros configuráveis e apresenta os resultados obtidos nas simulações. Por fim, a Seção 7 conclui este trabalho e antecipa os trabalhos futuros.

2. Revisão do LoRa

O LoRa é uma tecnologia projetada para prover enlaces de comunicação sem fio de longo alcance e baixo consumo de energia. Essa tecnologia utiliza modulação proprietária derivada do *Chirp Spread Spectrum* (CSS), na qual o *chirp* representa um sinal senoidal cuja frequência aumenta de forma linear com o tempo, cobrindo toda a largura de banda utilizada [Semtech Corp. 2015].

As redes LoRa seguem topologia estrela. O *gateway* atua como intermediário entre os dispositivos finais e o servidores cabeados. Os dispositivos finais de uma rede LoRa são aqueles que possuem baixo consumo de energia e que se comunicam apenas com o *gateway*. Na camada de enlace, o padrão LoRaWAN é usado. O LoRaWAN define três classes de dispositivos, a Classe A, B e C, que fornecem diferentes serviços para diferentes aplicações. Os dispositivos da Classe A realizam a transmissão (*uplink*) para o

gateway em qualquer instante de tempo e possuem apenas uma janela de recepção (*downlink*) após o término da transmissão. Os dispositivos da Classe B possuem várias janelas de recepção, enquanto os da Classe C podem realizar a recepção a qualquer instante.

A comunicação entre os dispositivos finais e o *gateway* requer o estabelecimento de um fator de espalhamento dentre os seis existentes, da potência de transmissão e de um dos subcanais disponíveis. O fator de espalhamento define o espalhamento espectral, assim como a razão entre a taxa de bits e a taxa de *chirps* [Bor et al. 2016a]. Seis valores diferentes para o parâmetro fator de espalhamento são definidos, variando de 7 a 12 [Semtech Corp. 2015].

Por um lado, o aumento do fator de espalhamento torna o sinal mais resiliente ao ruído, aumentando o alcance da transmissão. Por outro lado, o aumento do SF causa o aumento da duração da transmissão (tempo no ar), aumentando também a energia consumida. Logo, existe um compromisso entre o alcance da transmissão, taxa de transmissão de dados e energia consumida.

Além do impacto na energia consumida, o aumento do fator de espalhamento reduz a taxa de transmissão de dados (R_b) do LoRa. A taxa R_b em bps é calculada como $R_b = SF \times TC \times \frac{2^{SF}}{BW}$, onde SF , BW e TC denotam, respectivamente, o fator de espalhamento, a largura de banda em Hz e a quantidade de bits redundantes das mensagens LoRa. Note que a taxa de dados diminui com o aumento do SF , considerando TC e BW fixos. A largura de banda (BW) define o tamanho da faixa de frequências utilizada, podendo ser configurada em 125, 250 ou 500 kHz. A sensibilidade de recepção do sinal no *gateway* e a taxa de transmissão dependem dos valores configurados para a largura de banda e o fator de espalhamento. Já a quantidade de bits redundantes (TC) nas mensagens LoRa para recuperação de erros é função do código da taxa de correção CR , sendo $TC = \frac{4}{4+CR}$. CR assume um valores inteiros entre 1 e 4 [Semtech Corp. 2015].

As colisões em redes sem fio, e também em redes LoRa, ocorrem quando duas ou mais transmissões se sobrepõem no dispositivo receptor. Nas redes LoRa, as colisões, ou mesmo o baixo reaproveitamento espacial, resultam possivelmente do reuso simultâneo do mesmo fator de espalhamento por diferentes dispositivos finais [Bor et al. 2016b]. Além disso, mesmo com a configuração de diferentes fatores de espalhamento, a colisão pode ainda ocorrer no mesmo canal devido à ortogonalidade imperfeita dos fatores de espalhamento [Yatagan and Oktug 2019]. Caso existam transmissões concorrentes utilizando os mesmos recursos de rede (mesmo fator de espalhamento e mesmo canal), o *gateway* só é capaz de receber uma das transmissões caso a relação sinal-interferência-ruído (SINR) for maior do que o limiar de recepção, para qualquer fator de espalhamento.

No LoRaWAN, os dispositivos finais não sabem a sua distância para o *gateway* mais próximo inicialmente, sendo capazes porém de calcular essa distância através da potência do sinal recebido da transmissão *downlink*. Caso a potência do sinal recebido seja muito alta, o sensor pode diminuir o fator de espalhamento com o intuito de diminuir a energia consumida. Caso o fator de espalhamento esteja no nível mais baixo (nível 7) e a potência do sinal recebido ainda esteja alto, o dispositivo final pode diminuir o nível de potência. Esse mecanismo no LoRaWAN é chamado de *Adaptive Data Rate* (ADR). Nesse contexto, os dispositivos finais próximos ao *gateway* tendem a configurar seus fatores de espalhamento ao valor mínimo na maior parte do tempo, seguindo o

mecanismo ADR, causando colisões entre os mesmos fatores de espalhamento. Com o aumento do número de dispositivos finais, o número de colisões também aumenta. Note então que para proporcionar o reuso espacial, não basta reduzir o fator de espalhamento como forma de redução do alcance e do ToA. A potência de transmissão também deve ser ajustada.

3. Trabalhos Relacionados

Os trabalhos relativos ao aprimoramento da configuração de parâmetros de rede LoRa seguem três linhas principais. A primeira linha utiliza técnicas de otimização diversas das técnicas de aprendizado de máquinas, por exemplo, algoritmos de otimização baseados na quantidade de dispositivos conectados. A segunda linha aborda a utilização de técnicas de aprendizado supervisionado na otimização da configuração de parâmetros. Por fim, a terceira linha ataca o aprimoramento da referida configuração a partir de técnicas de aprendizado por reforço.

Cuomo et al. propuseram dois novos algoritmos para selecionar o fator de espalhamento de redes LoRaWAN [Cuomo et al. 2017]. Um dos algoritmos seleciona fatores de espalhamento baseado no número total de dispositivos conectados, enquanto o segundo realiza a seleção baseado no tempo de transmissão de pacotes para cada fator de espalhamento. Essa proposta ajusta apenas o fator de espalhamento.

Yatagan e Oktug, por outro lado, exploraram técnicas de aprendizado supervisionado para seleção do fator de espalhamento que fosse capaz de otimizar a taxa de entrega de pacotes em redes LoRa [Yatagan and Oktug 2019]. As técnicas utilizadas foram a árvore de decisão e a máquina de vetor de suporte. Os autores avaliaram apenas o efeito da ortogonalidade imperfeita dos fatores de espalhamento, já que ponto havia sido implementado no simulador desenvolvido e utilizado pelos próprios autores. Todos os demais parâmetros da camada física do LoRa são também mantidos fixos.

Ta et al. focaram na linha de aprendizado por reforço ao proporem a abordagem LoRa-MAB [Ta et al. 2019]. O LoRa-MAB ajusta o fator de espalhamento, a potência de transmissão e o canal de transmissão de uma rede LoRaWAN de forma distribuída (técnica implementada nos dispositivos finais) através do uso do algoritmo *Exponential Weights for Exploration and Exploitation* (EXP3). Apesar do aumento da taxa de entrega de pacotes e da redução no consumo de energia, a complexidade computacional da proposta é muito alta, a ponto das simulações considerarem apenas 100 dispositivos finais. Tal problema impediu que o desempenho da proposta fosse avaliado em redes mais densas. Park et al. propuseram a utilização da técnica de aprendizado por reforço profundo para ajustar o fator de espalhamento e a potência de transmissão [Park et al. 2020]. A área na qual os dispositivos finais foram dispostos era de apenas 1,5 quilômetros quadrados e a quantidade de dispositivos foi de apenas 30. Esses parâmetros de simulação não permitem avaliar o desempenho da proposta em redes mais densas, esbarrando novamente no problema da alta complexidade computacional.

A principal contribuição do atual trabalho em relação aos supracitados está na utilização de técnicas de aprendizado supervisionado na configuração dos parâmetros de fator de espalhamento e potência de transmissão de redes LoRa com o intuito de reduzir o consumo de energia na transmissão em relação ao mecanismo ADR, sem prejuízo à taxa de entrega de pacotes. Os experimentos mostram que a abordagem proposta não sofre

igualmente com problemas de escala em redes densas, mesmo com diferentes larguras de banda. Os resultados mostram que diferentes modelos de aprendizado supervisionado podem ser usados a depender da quantidade de dispositivos finais implantados na rede, da quantidade de parâmetros configuráveis e da largura de banda utilizada.

4. Proposta de Configuração Conjunta de Parâmetros LoRa

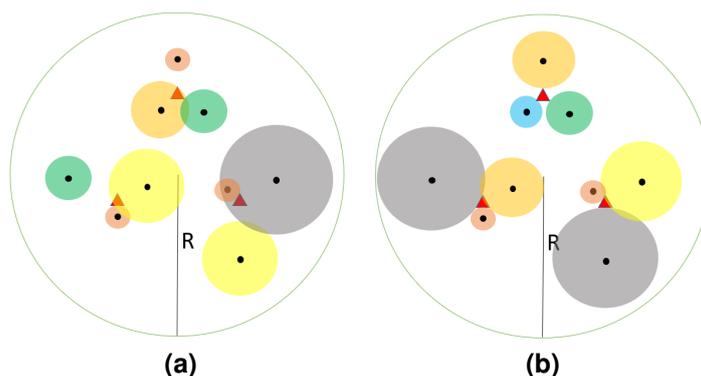


Figura 1. Ilustração do efeito do ajuste dos parâmetros no alcance da comunicação dos dispositivos finais com seus respectivos gateways: (a) sem ajuste de parâmetros e (b) com ajuste de parâmetros.

A utilização de técnicas de aprendizado supervisionado para configurar o fator de espalhamento e a potência de transmissão é a proposta principal para abordar o problema do congestionamento do acesso ao meio em redes LoRa. A ideia por trás da proposta está ilustrada na Figura 1. Nessa figura, os círculos coloridos representam o raio de cobertura dos dispositivos finais enquanto os triângulos representam os gateways da rede LoRa. As cores dos círculos denotam diferentes raios de cobertura. Note que, na Figura 1a, a cobertura dos dispositivos ora está acima do necessário para comunicação com o gateway, ora é insuficiente. Sabe-se que os raios de cobertura são função do fator de espalhamento e da potência de transmissão. Porém, mesmo usando o mecanismo ADR do LoRa, tal configuração pode não ser a mais eficiente, dada a falta de coordenação. A proposta deste trabalho, ilustrada na Figura 1b, ajusta os parâmetros LoRa para que os raios de cobertura possibilitem a comunicação bem sucedida com o gateway ao mesmo tempo que reduzem o número de colisões na rede. O objetivo é reduzir o consumo de energia dos dispositivos finais, sem prejuízo da qualidade das comunicações. Apesar da literatura trazer abordagens que envolvem aprendizado de máquinas, nenhuma delas configura simultaneamente o fator de espalhamento e a potência de transmissão ao mesmo tempo que se preocupa com redes mais densas.

Em termos práticos, o servidor de rede inicialmente configura os parâmetros dos dispositivos finais com valores aleatórios, dentro obviamente dos intervalos de valores possíveis, e inicializa uma rotina de recepção de dados transmitidos pelos dispositivos, durante um tempo definido pelo administrador de rede. A configuração com valores aleatórios é interessante, pois permite avaliar o desempenho da comunicação entre cada um dos dispositivos finais e o gateway sob diferentes condições. Vale ressaltar, porém, que outras abordagens poderiam ser empregadas, como o próprio ADR do LoRa. Durante a referida rotina, é obtido um conjunto de dados que representa o comportamento

da transmissão dos dispositivos configurados com todas as combinações de parâmetros possível. Após o término do referido tempo, o conjunto de dados obtido é utilizado para realizar o treinamento e teste dos classificadores de forma *offline*. Uma vez realizados o treinamento e teste, o servidor de rede configura os dispositivos com os valores mais baixos de cada combinação de parâmetros cujo resultado da transmissão foi bem sucedida. A proposta de utilização das técnicas de aprendizado Árvore de Decisão, *Naïve Bayes*, *k-Nearest Neighbors* (k-NN) e Floresta Aleatória como classificadores no servidor de rede se mostra adequada para a obtenção de taxa de entrega de pacotes maior ou igual a obtida pelo mecanismo ADR. Mais ainda, a utilização das técnicas de aprendizado demonstram redução da energia consumida na transmissão em relação à obtida pelo ADR.

O conjunto de dados é composto por até quatro atributos. Nos casos em que a potência de transmissão não é configurada, o servidor requer amostras que contenham como atributos as coordenadas (x, y) da posição do dispositivo final na topologia da rede e o fator de espalhamento. Para as propostas deste artigo, que também configuram a potência de transmissão, é necessária a adição deste parâmetro às coordenadas topológicas e ao fator de espalhamento. Durante a etapa de aquisição do conjunto de dados para treinamento e teste, deve ser prevista a implementação de uma aplicação do tipo cliente-servidor em que mensagens de controle possam ser enviadas pelo servidor aos dispositivos finais. Essas mensagens devem ser usadas para o ajuste de parâmetros do LoRa e monitoramento do sucesso das transmissões das mensagens.

5. Ambiente de Simulações

O simulador desenvolvido em linguagem Python por Yatagan e Oktug [Yatagan and Oktug 2019] foi utilizado, considerando um ambiente de rede composto por três *gateways*. Tais *gateways* foram dispostos de forma que a distância entre eles seja igual (triangular), conforme representado na Figura 1. Essa topologia circular de raio (R) de 5 km é a mesma utilizada por Yatagan e Oktug [Yatagan and Oktug 2019].

No referido simulador, o efeito da ortogonalidade imperfeita dos fatores de espalhamento e o efeito das colisões devido às transmissões concorrentes estão implementados, tornando o efeito das colisões mais próximo possível da realidade. As alterações realizadas no simulador visaram apenas permitir a variação da potência de transmissão e largura de banda, originalmente fixadas em 14 dBm e 125 kHz, respectivamente [Yatagan and Oktug 2019]. O modelo de propagação utilizado foi o de espaço livre e o canal utilizado foi de 868 MHz. A soma dos ganhos e perdas de sinal considerada nos dispositivos transmissores e receptores foi de 7 dB. O código da taxa de correção CR utilizado tem valor 1.

A quantidade considerada de dispositivos finais varia de 100 a 1000, o que permitiu a avaliação de desempenho das técnicas de aprendizado de máquinas supervisionado em redes mais densas. O tamanho dos pacotes enviados pelos dispositivos é de 200 Bytes. Os dispositivos são de Classe A, já que estes possuem menor consumo de energia. Os intervalos de geração e transmissão de pacotes LoRa seguem uma distribuição de Poisson com média $0,01 \cdot t$ [Tijms 2003, Ross 1996]. A recepção de dados pelos dispositivos (*downlink*) não é considerada.

Uma simulação inicial foi realizada com tempo definido de 4500 segundos. Nesta simulação, os dispositivos foram configurados individualmente com parâmetros

aleatórios, conforme proposta apresentada na Seção 4, e um conjunto de dados foi obtida representando o comportamento das transmissões dos dispositivos. O conjunto de dados gerado, apesar de desbalanceado, foi suficiente para proporcionar bons resultados durante o treinamento das técnicas. O número de classes “transmissão mal sucedida” é muito menor do que o número de classes “transmissão bem sucedida”.

Após a simulação supracitada, o conjunto de dados gerado foi utilizado no treinamento dos classificadores de forma *offline* utilizando a biblioteca *scikit-learn*, desenvolvida em linguagem *python*. As técnicas utilizadas como classificadores foram *Naïve Bayes*, *k-Nearest Neighbors* (k-NN) e Floresta Aleatória. Após o treinamento e teste de cada classificador, os parâmetros com os menores valores e que proporcionaram uma transmissão bem sucedida, para cada dispositivo individualmente, foram utilizados na configuração e uma nova simulação foi realizada para a obtenção da taxa de entrega de pacotes e da energia consumida na transmissão. Também foi realizada uma simulação utilizando o mecanismo ADR com o intuito de comparar o desempenho em termos de taxa de entrega de pacotes e energia consumida com os resultados obtidos pelos classificadores.

O mecanismo de busca em grade (*GridSearch*) da biblioteca *scikit-learn* foi utilizado para realizar a busca exaustiva dos melhores hiper parâmetros das técnicas Árvore de Decisão, Floresta Aleatória e k-NN durante a fase de treinamento. Já para a técnica *Naïve Bayes*, os valores padrão da referida biblioteca foram utilizados.

6. Resultados

Os resultados comparam o desempenho de quatro configurações distintas, além do ADR definido no LoRaWAN. Dentre as quatro configurações, as configurações 3 e 4 se referem à proposta deste trabalho, como visto na Tabela 1. Note que tanto o fator de espalhamento quanto a potência de transmissão podem ser variáveis, sendo que o fator de espalhamento pode variar de 7 a 12 e a potência de transmissão pode variar entre os valores 2, 5, 8, 11 e 14 dbm. Foram definidas quatro configurações com o intuito de avaliar o desempenho do mecanismo ADR e das técnicas de aprendizado supervisionado sob diferentes recursos de rede disponíveis, uma vez que a largura de banda aumenta em virtude do aumento da sensibilidade do *gateway* na recepção do sinal e do aumento da taxa de transmissão para cada fator de espalhamento.

Tabela 1. Configurações utilizadas nas simulações. As Configurações 3 e 4 se referem às propostas deste trabalho em que os valores de fator de espalhamento e potência de transmissão são configuradas por modelos de aprendizado de máquina supervisionado.

Configuração	Fator de espalhamento (SF)	Potência de transmissão (PW)	Largura de banda (BW)
1	Variável	14 dBm	125 kHz
2	Variável	14 dBm	500 kHz
3	Variável	Variável	125 kHz
4	Variável	Variável	500 kHz

Para cada proposta supramencionada, foi utilizado o mecanismo de busca em grade durante a fase de treinamento de cada classificador para a avaliação e seleção dos

hiper parâmetros. Os hiper parâmetros avaliados para cada classificador estão abaixo descritos:

- **Árvore de Decisão:** melhor critério de impureza dentre o '*entropy*' e o '*gini*';
- **Floresta Aleatória:** melhor número de estimadores dentre 3, 10, 60, 100, 200 e 400, e o melhor critério de impureza dentre '*entropy*' e '*gini*';
- **k-NN:** melhor número de vizinhos dentre os valores 3, 5, 7, 10, 20, e o melhor algoritmo dentre '*auto*', '*ball tree*' e '*kd tree*'.

6.1. Precisão das técnicas de aprendizado

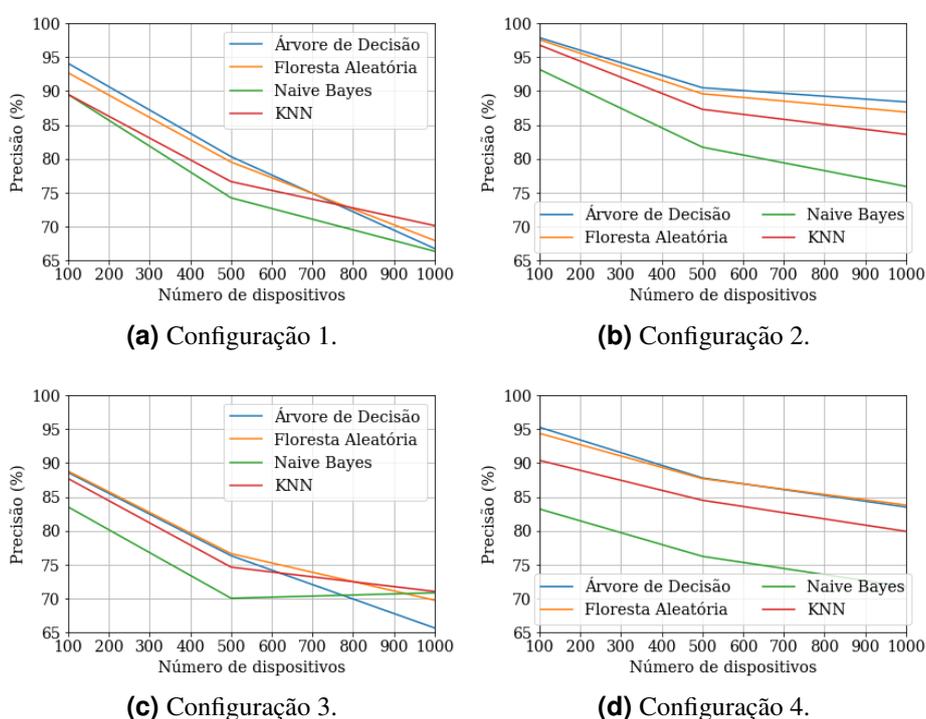


Figura 2. Precisão das técnicas de aprendizado para cada uma das configurações.

A Figura 2 apresenta as precisões obtidas por cada configuração para as diferentes técnicas de aprendizado. A precisão é calculada através da razão entre a quantidade de verdadeiros positivos (verdadeiras transmissões bem sucedidas) e a quantidade de previsões positivas (soma entre o número de verdadeiros positivos e o número de falsos positivos), sendo uma boa medida para ser utilizada quando os custos do falso positivo são altos. No caso das redes LoRa, uma falsa transmissão bem sucedida levará à configuração errônea dos parâmetros.

A Figura 2a mostra que a Árvore de Decisão obteve a maior precisão na Configuração 1, para quantidades de dispositivos de 100 a 750. A Árvore de Decisão foi superada pelo k-NN apenas para quantidades de 750 a 1000 dispositivos. Já na Configuração 2, a Árvore de Decisão obteve a maior precisão para todas as quantidades de dispositivos, como visto na Figura 2b. As Configurações 3 e 4 propostas neste trabalho demonstraram igualmente variação de desempenho entre as técnicas avaliadas

em função do número de dispositivos. Na Configuração 3, a Floresta Aleatória obteve maior precisão entre 100 e 800 dispositivos, sendo superada pelo k-NN até 1000 dispositivos, como visto na Figura 2c. Na Configuração 4, a técnica de Árvore de Decisão obteve a maior precisão entre 100 e 500 dispositivos, enquanto a técnica de Floresta Aleatória obteve a maior precisão entre 500 e 1000 dispositivos, conforme a Figura 2d.

6.2. Taxa de entrega de pacotes

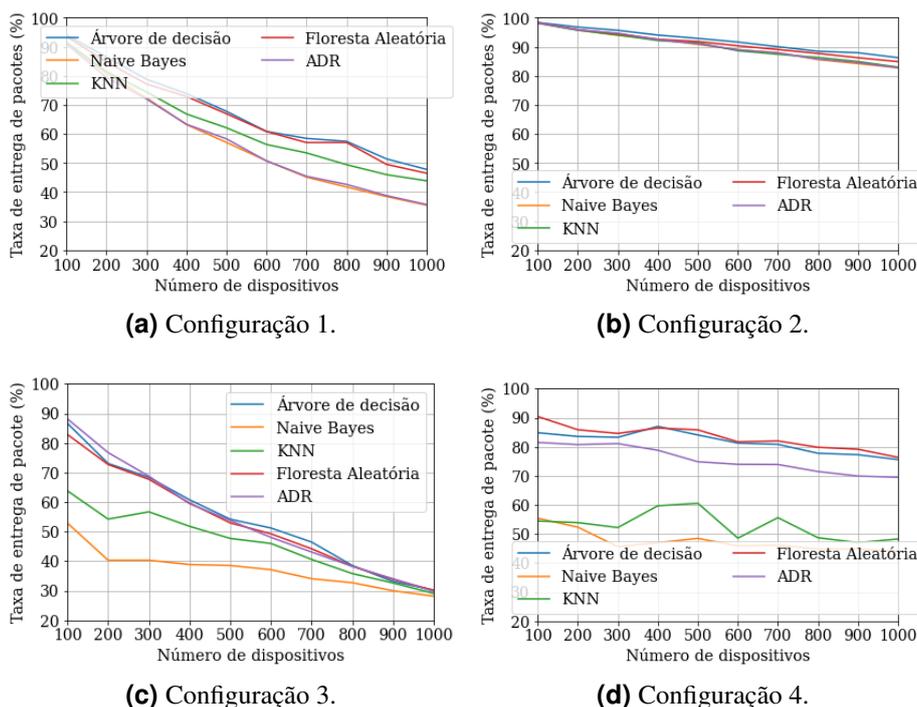


Figura 3. Taxa de entrega de pacotes obtida para cada configuração.

A Figura 3 apresenta os resultados referentes à taxa de entrega de pacotes até o servidor. Na Figura 3a, relativa à Configuração 1, verifica-se que o desempenho da Árvore de Decisão superou o desempenho do ADR e das demais técnicas. De acordo com a Figura 4a, para o caso de 1000 dispositivos, a concentração em fatores de espalhamento com valor 7 selecionados pelo ADR tornou a rede menos resiliente a interferências. Já na Configuração 2, vista na Figura 3b, apesar do aumento na precisão das técnicas em relação às demais configurações, a diferença máxima entre o desempenho das técnicas de aprendizado e o desempenho do ADR é de 2,3% na Configuração 2 para uma quantidade de 1000 dispositivos, enquanto na Configuração 1 esta diferença era de 13%. Isso mostra que o aumento da largura de banda reduz a diferença entre o desempenho das técnicas de aprendizado e o ADR. Verifica-se também na Figura 4b para 1000 dispositivos, que há uma maior seleção de fatores de espalhamento com valores 8, 9 e 10 em relação à Configuração 1. Como consequência, há aumento no tempo de ar, levando a uma maior probabilidade de entrega, e assim, uma maior taxa de entrega de pacotes.

No resultado da Configuração 3, representado na Figura 3c, é possível verificar que as técnicas de aprendizado obtiveram um desempenho semelhante ao do mecanismo ADR. Para a quantidade de 1000 sensores, o resultado da taxa de entrega de pacotes da

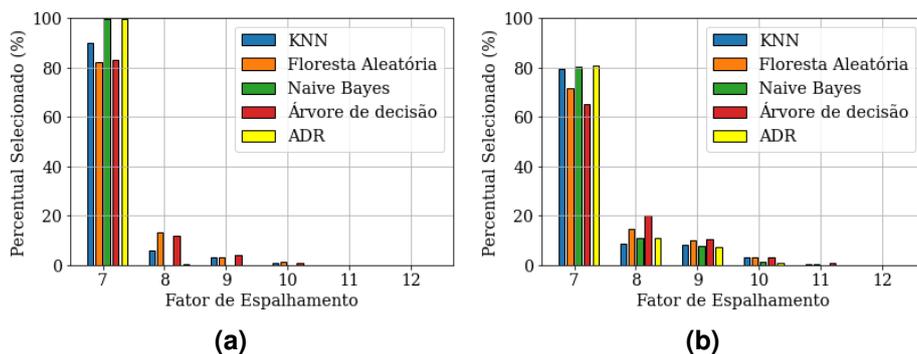


Figura 4. Distribuição dos fatores de espalhamento selecionados nas transmissões bem sucedidas considerando 1000 dispositivos: (a) Configuração 1 e (b) Configuração 2.

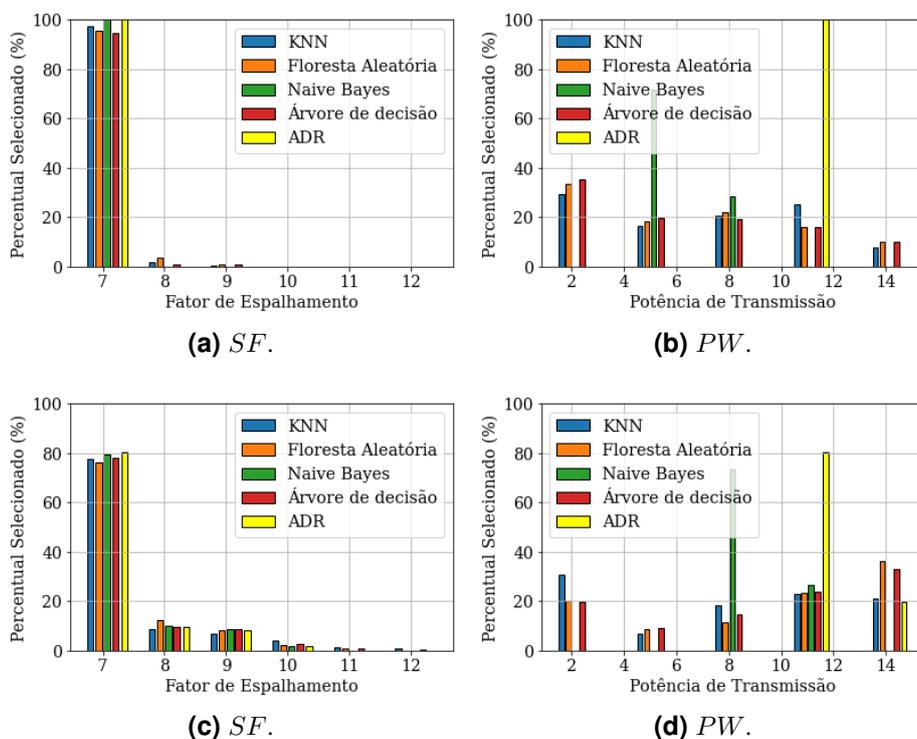


Figura 5. Distribuição dos fatores de espalhamento e potências de transmissão selecionados nas transmissões bem sucedidas considerando 1000 dispositivos: (a,b) Configuração 3 e (c,d) Configuração 4.

técnica Árvore de Decisão foi de 31,4% com margem de erro de 0,44% considerando um intervalo de confiança de 95%. Já o resultado relativo ao mecanismo ADR foi de 30,5% com margem de erro de 0,28% considerando um intervalo de confiança de 95%. Comparando com os resultados da Configuração 1, as técnicas obtiveram uma redução na taxa de entrega de pacotes devido à redução na precisão das referidas técnicas para a largura de banda de 500 kHz, como pode ser visto nas Figuras 3c e 2c, respectivamente.

Os resultados da proposta de Configuração 4 mostram que houve um aumento

global na taxa de entrega de pacotes em relação à proposta de Configuração 3 em virtude do aumento da largura de banda (recursos de rede) representada pelo aumento da sensibilidade no *gateway* e da taxa de transmissão relativa a cada fator de espalhamento. A técnica que obteve a maior taxa de entrega de pacotes nesta Configuração foi a Floresta Aleatória, superando inclusive o mecanismo ADR conforme verifica-se na Figura 3d. De acordo com a Figura 5d, houve um aumento na seleção de fatores de espalhamento com valores 8, 9 e 10 em relação às demais configurações, aumentando a variedade de fatores de espalhamento que, no caso de dispositivos próximos aos *gateways*, pode reduzir o grau de interferência. Em relação aos dispositivos distantes dos *gateways*, fatores de espalhamento com valores maiores aumentam o tempo de transmissão e, conseqüentemente, aumentam a probabilidade de transmissão bem sucedida. Para a quantidade de 1000 sensores, o resultado da taxa de entrega de pacotes da técnica Floresta Aleatória foi de 77,07% com margem de erro de 0,11% considerando um intervalo de confiança de 95%. Já o resultado relativo ao mecanismo ADR foi de 69,64% com margem de erro de 0,40% considerando um intervalo de confiança de 95%.

6.3. Consumo de energia

Os resultados da Configuração 1 mostram que a energia consumida na transmissão relativa a cada técnica de aprendizado é diretamente proporcional à taxa de entrega de pacotes obtida por cada técnica. Verifica-se na Figura 6a, que a *Árvore de Decisão* obteve o maior consumo de energia (assim como obteve a maior taxa de entrega na Configuração 1), enquanto o ADR obteve o menor consumo de energia. O consumo de energia do mecanismo ADR inferior ao da técnica de *Árvore de Decisão* pode ser entendido através da Figura 4a para 1000 dispositivos, na qual observa-se que o mecanismo ADR selecionou apenas o valor 7 enquanto a *Árvore de Decisão* selecionou valores diversos. Valores menores de fator de espalhamento reduzem o tempo de transmissão e, conseqüentemente, economizam energia.

Com o aumento da largura de banda de 125 kHz para 500 kHz (Configuração 2), houve uma redução global significativa no consumo de energia (66,7% no caso da *Árvore de Decisão* para 1000 dispositivos) em relação à Configuração 1, como visto na Figura 6b. Porém, nesta Configuração, o consumo de energia das técnicas de aprendizado foi similar ao consumo do mecanismo ADR.

Em relação à Configuração 3, a Figura 6c mostra que o mecanismo ADR obteve o maior consumo de energia em relação às técnicas de aprendizado supervisionado. Isto pode ser explicado na Figura 5b, na qual pode ser visto que o ADR selecionou valores maiores de potência de transmissão (11 dbm na totalidade) em relação aos valores de potência de transmissão selecionados pela técnica de aprendizado com melhor desempenho (*Árvore de Decisão*), o que explica o maior consumo de energia do mecanismo ADR. Para a quantidade de 1000 sensores, o consumo de energia obtido pela técnica *Árvore de Decisão* foi de 99,16 J com margem de erro de 1,31, considerando um intervalo de confiança de 95%, enquanto o consumo de energia do mecanismo ADR foi de 165,2 J com margem de erro de 0,13 considerando um intervalo de confiança de 95%.

Na Configuração 4, apesar da redução no consumo de energia em relação à Configuração 1 devido ao aumento da largura de banda, o consumo de energia do mecanismo ADR foi similar ao consumo das técnicas de aprendizado, exceto a técnica *Naive*

Bayes. Para a quantidade de 1000 sensores, o consumo de energia na Configuração 4 obtido pela técnica Floresta Aleatória, que obteve melhor desempenho entre as técnicas, foi de 74,34 J com margem de erro de 1,36, considerando um intervalo de confiança de 95%, enquanto o consumo de energia do mecanismo ADR foi de 76,32 J com margem de erro de 0,27 considerando um intervalo de confiança de 95%.

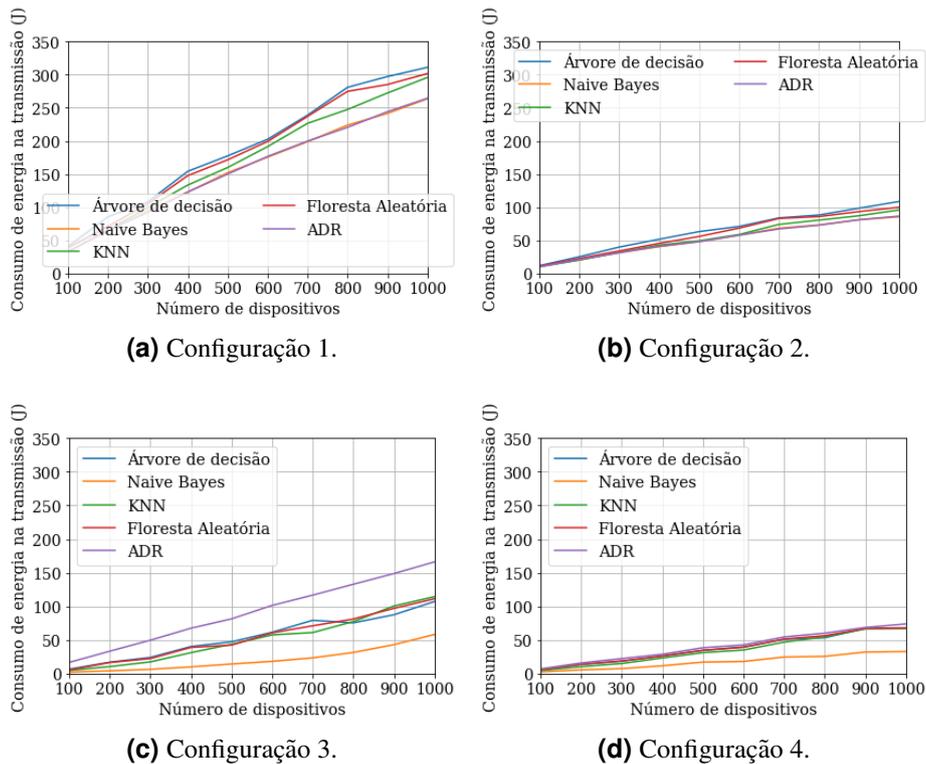


Figura 6. Energia consumida na transmissão.

7. Conclusão e Trabalhos Futuros

Este trabalho avaliou a utilização de técnicas de aprendizado supervisionado na configuração combinada dos parâmetros fator de espalhamento e potência de transmissão de redes LoRa densas. O desempenho das técnicas foi avaliado segundo quatro configurações de parâmetros que combinaram o uso ou não da potência de transmissão fixa e os valores de 125 e 500 kHz de largura de banda.

A técnica de Árvore de Decisão apresentou maior desempenho em termos de taxa de entrega de pacotes na Configuração 1 e 2 que utilizam potência de transmissão fixa, porém ao custo de maior consumo de energia na transmissão em relação ao mecanismo ADR. Comparando as Configurações 1 e 2, o aumento da largura de banda de 125 kHz para 500 kHz permitiu uma redução significativa na energia consumida na transmissão, mas não houve benefício expressivo na utilização de técnicas de aprendizado supervisionado em relação ao mecanismo ADR.

Os resultados relativos à Configuração 3 (configuração de fator de espalhamento e potência de transmissão a 125 kHz) mostram que as técnicas de aprendizado utilizadas

obtiveram o mesmo desempenho do mecanismo ADR em termos de taxa de entrega de pacotes, porém gastaram menos energia na transmissão em relação ao mecanismo ADR.

Na proposta de Configuração 4 (configuração de fator de espalhamento e potência de transmissão a 500 kHz), A técnica Floresta Aleatória superou as demais técnicas e o mecanismo ADR em termos de taxa de entrega de pacotes, para todas as quantidades de dispositivos, consumindo uma quantidade de energia similar ao mecanismo ADR.

Como trabalhos futuros, técnicas de aprendizado diversas das apresentadas neste trabalho podem ser utilizadas, como redes neurais e regressão logística. Além do fator de espalhamento e da potência de transmissão, a frequência é outro parâmetro da camada física que pode ser configurado para avaliar o desempenho das técnicas utilizadas neste trabalho e das acima sugeridas.

Referências

- Bor, M., Vider, J., and Roedig, U. (2016a). Lora for the internet of things. In *EWSN '16: Proceedings of the 2016 International Conference on Embedded Wireless Systems and Networks*, United States. Junction Publishing.
- Bor, M. C., Roedig, U., Voigt, T., and Alonso, J. M. (2016b). Do lora low-power wide-area networks scale? In *MSWiM '16: Proceedings of the 19th ACM International Conference on Modeling, Analysis and Simulation of Wireless and Mobile Systems*, New York, NY, United States. Association for Computing Machinery.
- Cuomo, F., Campo, M., Caponi, A., Bianchi, G., Rossini, G., and Pisani, P. (2017). Explora: Extending the performance of lora by suitable spreading factor allocations. In *IEEE 13th International Conference on Wireless and Mobile Computing, Networking and Communications (WiMob)*, Rome, Italy. IEEE.
- Georgiou, O. and Raza, U. (2017). Low power wide area network analysis: Can lora scale? *IEEE Wireless Communications Letters*, 6(2):162–165.
- Park, G., Lee, W., and Joe, I. (2020). Network resource optimization with reinforcement learning for low power wide area networks. *EURASIP Journal on Wireless Communications and Networking*, 2020(176).
- Raza, U., Kulkarni, P., and Sooriyabandara, M. (2017). Low power wide area networks: an overview. *IEEE Communications Surveys & Tutorials*, 19(2):855–873.
- Ross, S. (1996). *Stochastic processes*. Wiley, New York, NY.
- Semtech Corp. (2015). Lora modulation basics an1200.22. Disponível em: <https://www.frugalprototype.com/wp-content/uploads/2016/08/an1200.22.pdf>. Acessado em janeiro de 2022.
- Ta, D.-T., Khawam, K., Lahoud, S., Adjih, C., and Martin, S. (2019). Lora-mab: A flexible simulator for decentralized learning resource allocation in iot networks. In *12th IFIP Wireless and Mobile Networking Conference (WMNC)*, Paris, France. IEEE.
- Tijms, H. C. (2003). *A first course in stochastic models*. Wiley, New York, NY.
- Yatagan, T. and Oktug, S. (2019). Smart spreading factor assignment for lorawans. In *IEEE Symposium on Computers and Communications (ISCC)*, Barcelona, Spain. IEEE.