

Modelagem Inteligente de Perda de Percurso Utilizando Transceptores LoRa

Rafael da S. Macêdo, Matheus H. A. Miranda, João Paulo S. H. Lima, Álvaro A. M. de Medeiros

Resumo—Neste artigo é apresentada uma metodologia de modelagem de perda de percurso utilizando transceptores LoRa de baixo custo juntamente com o emprego de uma rede neural artificial para melhorar a caracterização. Tal procedimento permite uma comparação de desempenhos entre a rede neural e os modelos tradicionais de perda de percurso, baseada em medições adquiridas em diversos cenários, considerando abordagens com e sem linha de visada.

Palavras-Chave—LoRa, Perda de percurso, Rede neural, IoT.

Abstract—In this work, a methodology is presented to model path loss utilizing low-cost LoRa transceivers employing an artificial neural network in order to improve the characterization. This procedure allows a performance comparison between the neural network and traditional path loss models, based on measurement acquired for diverse scenarios, considering line-of-sight and non-line-of-sight approaches.

Keywords—LoRa, Path loss, Neural network, IoT.

I. INTRODUÇÃO

Atualmente, com a crescente expansão da Internet das Coisas (IoT), estima-se que, até 2020, o número de dispositivos conectados seja de 50 bilhões [1]. Desse total, encontram-se aplicações para comunicações entre máquinas (*Machine-to-Machine* - M2M), as cidades inteligentes (*Smart cities*), agricultura 4.0 [2], casas inteligentes (*smart house*), comunicação veicular, entre outras. Tais aplicações fazem com que a busca por novas soluções comerciais que possam atender aos requisitos de rede da aplicação sejam desenvolvidas.

Além disso, alguns dispositivos precisam se conectar a longas distâncias e com baixo consumo de potência. Tal necessidade fez com que as LPWANs (*Low-Power Wide Area Networks*) atraíssem uma atenção especial nos últimos anos, principalmente com a criação de tecnologias como SIGFOX [3] e *Long Range* (LoRa) [4], capazes de conciliar ambos os requisitos desse tipo de aplicação.

Em específico, a tecnologia de camada física LoRa garante uma alta resistência a interferências eletromagnéticas do sinal devido a sua técnica de modulação de espalhamento espectral. Essa característica faz dessa uma solução ideal para ambientes urbanos ou suburbanos onde é necessário ter uma rede conectando diversos dispositivos localizados a distâncias relativamente grandes.

Diversos trabalhos utilizam transceptores com a tecnologia LoRa para caracterizar a perda de percurso do ambiente, pois

Rafael S. Macêdo, Matheus H. A. Miranda, João Paulo S. H. Lima, Álvaro A. de Medeiros são do Laboratório de Telecomunicações Aplicadas da Faculdade de Engenharia da Universidade Federal de Juiz de Fora. E-mails: {rafael.macedo2016,matheus.abreu,joao.lima, alvaro}@engenharia.ufjf.br.

seus dispositivos são baratos e de fácil aplicação. Trabalhos como em [5], [6] e [7] validam o uso de dispositivos transceptores LoRa para o estudo de propagação, podendo ainda realizar estudos da rede LoRaWAN com o uso dos mesmos.

Os transceptores podem ser encontrados para as frequências de 433, 868 e 915 MHz, sendo essas as frequências da banda ISM (*Industrial, Scientific & Medical*) segundo a ITU (*International Telecommunications Union*). No Brasil, estão disponíveis para uso as bandas com frequência de portadora de 433 e 915 MHz.

Além disso, ao modelar o canal de forma eficiente, é possível reduzir custos de manutenção com os equipamentos e infraestrutura. Diversos modelos de propagação dedicados à perda de percurso foram criados para previsão dos resultados medidos aos teóricos [8]. Contudo, tais modelos estão suscetíveis a erros de aproximação que, nesse trabalho, serão aprimorados com a implementação de redes neurais artificiais.

Nesse sentido, este artigo trata da caracterização da perda de percurso empregando redes neurais artificiais a partir de dados obtidos através de transceptores da tecnologia LoRa. A Seção II apresenta os equipamentos utilizados na medição. Na Seção III, são abordados os conceitos da rede neural utilizada, bem como as estratégias para o tratamento de dados. Já a Seção IV expõe a forma com que as medidas foram coletadas. Na Seção V, são analisados os resultados obtidos e na Seção VI, por sua vez, são apresentadas as conclusões.

II. SISTEMA DE MEDIÇÃO

Esta Seção apresenta quais são e como foram implementados os equipamentos do sistema de medição.

A. Transmissor

Para o transmissor, foi utilizado um módulo LoRa de 433 MHz SX1278 [9], conectado a um módulo Arduino UNO para fazer os procedimentos de envio de pacotes.

O transceptor foi configurado com uma potência de transmissão de 10 dBm, fator de espalhamento (*Spreading Factor* - SF) igual a 12, largura de banda de 125 kHz e *coding rate* (CR) de 4/8. Tais valores foram escolhidos com base em trabalhos relacionados [5] e [6].

O transmissor foi posicionado na janela do Laboratório de Telecomunicações Aplicadas (LTA), afastado a 1 m do prédio da Faculdade de Engenharia, ligado a uma antena monopolo ressonante em 433 MHz com ganho de 5 dBi, localizada a uma altura de 4 m.

B. Receptor

No receptor, foi utilizado um módulo Arduino UNO ligado a um módulo GPS [10], que registra a latitude e longitude. Ademais, foi empregado um módulo LoRa de 433 MHz também configurado com fator de espalhamento igual a 12, largura de banda de 125 kHz e *coding rate* (CR) de 4/8, além de uma bateria, responsável pela alimentação do circuito. Para armazenar o valor de RSSI (*Received Signal Strength Indicator*) e a posição do receptor, fez-se uso de um módulo cartão SD para salvar as medidas.

Na recepção, foi instalada uma antena monopolo omnidirecional com ganho de 5 dBi sempre a uma distancia de 1,5 m do chão.



Fig. 1. Materiais utilizados para realização da medição.

III. REDE NEURAL

As redes neurais artificiais são modelos computacionais inspirados na forma com a qual o cérebro realiza uma tarefa. Em todos os casos, é necessário passar por um processo de aprendizagem a fim de adquirir certo conhecimento [11].

Na área da inteligência artificial, a rede neural se destaca pela sua capacidade de generalização. Nesse sentido, ela tem a habilidade de produzir saídas adequadas para entradas que não estavam presentes durante a etapa de treinamento [11]. Em geral, as redes neurais são usadas em problemas de classificação de objetos, aproximação de funções contínuas, reconhecimento de padrões, dentre outros [12]. Nesse trabalho, usamos sua aplicabilidade para estimar o valor de RSSI de acordo com a distância entre o emissor e receptor.

A. O modelo do neurônio

O neurônio computacional é a unidade básica de processamento de uma rede neural artificial, sendo fundamental para sua operação [11].

Existem três componentes básicos para seu funcionamento [11]:

- Um conjunto sinapse, em que cada elemento tem seu próprio peso. Com isso, supondo um sinal X_j na entrada da sinapse j , conectada a um neurônio k , tal entrada é multiplicada pelo peso sináptico W_{kj} .
- Um somador, o qual tem a função de agregar os sinais de entradas já ponderados pelas respectivas sinapses do neurônio.
- Uma função de ativação, a qual é utilizada para restringir a amplitude de saída Y_k do neurônio a um valor finito. Os intervalos típicos são $[0, 1]$ ou alternativamente $[-1, 1]$.

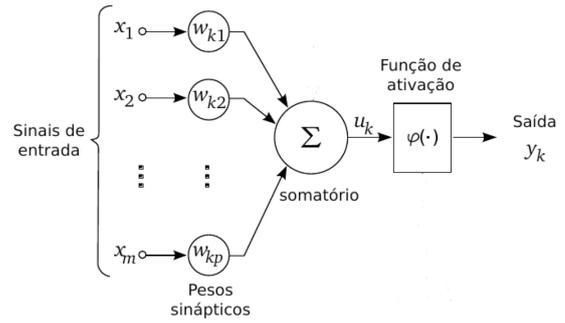


Fig. 2. Modelagem matemática do neurônio. Adaptado de [13].

Entre as diversas funções de ativação, a mais comum é a função sigmoide, a qual apresenta um balanceamento adequado entre o comportamento linear e não-linear [11], e é dada por

$$f(x) = \frac{1}{1 + e^{-x}}. \tag{1}$$

B. Arquitetura de rede feedforward de multicamada

Na arquitetura de uma rede neural *feedforward*, os neurônios estão organizados em camadas, sendo: uma camada de entrada, N camadas ocultas e uma camada de saída. Quanto maior o número de camadas ocultas, mais elevado é a capacidade de extrair valores e resolver problemas não lineares complexos. No entanto, maior será a demanda computacional para a execução da tarefa. Nessa estrutura de rede, um sinal que está na camada de entrada se propaga para a camada oculta, mas o contrário não acontece. Por isso, dizemos que a rede é alimentada adiante (*feedforward*) ou acíclica [11]. Em geral, essas camadas são totalmente conectadas, ou seja, um neurônio em qualquer camada está interligado com todos os outros neurônios da camada anterior [11].

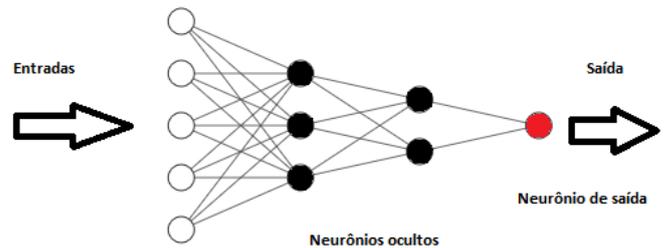


Fig. 3. Arquitetura da rede neural feedforward de multicamadas . Adaptado de [14].

C. Validação cruzada

Um problema comum na etapa de treinamento da rede é o *overfitting*, que acontece quando o modelo se ajusta bem aos dados treinados, mas se mostra ineficaz em fazer previsões de dados não treinados [15]. Entre os diversos métodos para

evitar overfitting, um comumente usado é a validação cruzada k -fold.

O método k -fold consiste em pegar o conjunto total de dados e dividi-lo aleatoriamente em k subconjuntos mutuamente exclusivos de tamanho aproximadamente igual. Sendo assim, um subconjunto é utilizado para teste e os $k - 1$ restantes são utilizados para treino. Esse processo é repetido por k vezes até que todo o conjunto de dados tenha sido usado para treino e teste [16].

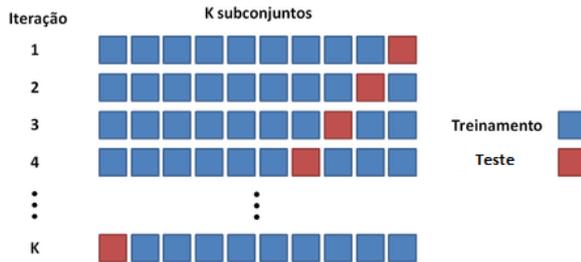


Fig. 4. Separação dos dados para treino e teste pelo método k -fold. Adaptado de [17].

Nesse sentido, podemos usar algumas métricas para estimar o desempenho da rede sobre conjunto teste como, por exemplo, a média dos erros quadráticos médios EQM para as k iterações.

$$EQM = \frac{1}{k} \sum_{i=1}^k (Y_i - \hat{Y}_i)^2, \quad (2)$$

sendo Y_i o valor observado e \hat{Y}_i o valor estimado para melhor aproximação possível.

A validação cruzada também pode ser usada na escolha de certos parâmetros da rede como, por exemplo, o número de neurônios ocultos [11].

D. Modelo proposto

A arquitetura proposta é a rede neural *feedforward* de multicamadas que contém uma camada de entrada, uma camada oculta e uma camada de saída. A única entrada X_i da rede é a distância entre o emissor e o receptor. A única saída \hat{Y}_i da rede é o valor RSSI.

A fim de determinar a quantidade de neurônios na camada oculta, usou-se o método k -fold para $k = 5$. Dessa forma, para cada execução do código, a rede repetia o treino e teste por cinco vezes. No final de cada uma das cinco repetições, era calculado o erro quadrático médio EQM e, ao final de todas as iterações, obteve-se uma média dos erros quadráticos médios. Nesse sentido, esse procedimento foi repetido testando-se diferentes quantidades de neurônios da camada oculta, variando-os de 1 até 10. Por fim, a quantidade que obteve a menor média de erro foi a de 6 neurônios ocultos. Por conta disso, a rede proposta tem a estrutura 1-6-1.

E. Treinamento

Para a rede *feedforward* adquirir algum conhecimento, ela precisa ser treinada. Dessa forma, o algoritmo de treinamento

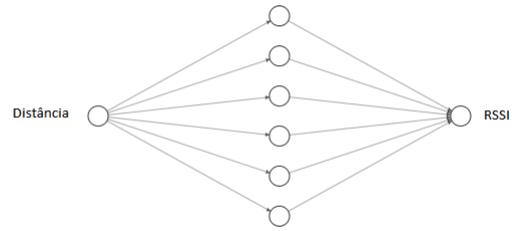


Fig. 5. Arquitetura da rede proposta. Adaptado de [14].

escolhido foi o de retro-propagação. A função sigmoide foi escolhida para ser a função de ativação dos neurônios. Para o melhor desempenho computacional, os dados foram normalizados entre 0 e 1.

A aprendizagem usando o algoritmo de retro-propagação acontece da seguinte forma [12]:

- A rede inicializa seus pesos sinápticos com valores aleatórios;
- Uma entrada X_i é injetada na rede, produzindo uma saída \hat{Y}_i ;
- A saída da rede \hat{Y}_i (valor previsto) é comparada com a saída esperada Y_i (valor observado) e o cálculo do erro é feito pela diferença entre esses dois valores;
- A rede aplica esse erro em uma função gradiente para reajustar os pesos sinápticos entre todas as camadas.

Esse processo é realizado até que o erro seja aceitável ou que seja estabelecido um número de iterações.

Nesse sentido, para avaliar o poder de previsão do modelo e evitar o *overfitting*, usou-se o método k -fold definindo novamente $k = 5$. Deste modo, a rede usa o conjunto de treino para estimar seus parâmetros e faz suas previsões sobre o conjunto teste. Por usar este método de validação cruzada, no final de uma execução do código, todo o conjunto de dados é usado como treino e teste.

IV. METODOLOGIA

As medidas foram realizadas na Faculdade de Engenharia da Universidade Federal de Juiz de Fora para três tipos de cenários:

- (a) Ambiente com visada sem muitos obstáculos;
- (b) Ambiente sem visada com obstrução de prédios;
- (c) Ambiente misto com obstrução devido à topologia do terreno e à vegetação.

A realização da análise em diferentes cenários tem o intuito de verificar a atuação da rede em ambientes com diversos níveis de variabilidade do canal devido aos fatores de obstrução da visada e de multipercursos. Além disso, é possível testar alguns modelos de perda de percurso, encontrando parâmetros que melhor adequam o modelo aos dados medidos.

Para realização das medidas, configura-se o transmissor de forma a enviar um pacote de dados contendo o número do mesmo em intervalos regulares de um segundo.

Já no receptor, tentou-se seguir um caminho uniforme a fim de manter a mesma distância entre os passos, com a antena receptora posicionada sempre a uma mesma distância do solo.

As medidas de distância até a posição do transmissor são coletadas pelo módulo GPS, continuamente com o intuito de manter sempre atualizados os seus valores. Quando o pacote de dados chega, tais medidas são registradas no cartão SD para serem tratados posteriormente.

A Figura 6 mostra as distâncias do ponto final do trajeto até o transmissor para cada medida.



Fig. 6. Ambiente usado para medição.

Após realizar a coleta dos dados, utiliza-se o método dos mínimos quadrados para ajustar os parâmetros do modelo de propagação *Log-distance* [18], que descreve a perda do sinal com a distância de forma logarítmica, isto é,

$$P_L(d) = P_0 + 10 \cdot n \cdot \log_{10}\left(\frac{d}{d_0}\right), \quad (3)$$

em que $P_L(d)$ é o valor de perda do sinal, P_0 é a potência em um ponto de referência, n é o coeficiente de perda, d_0 é a distância do ponto de referência em metros e d é a distância em metros do ponto onde é feita a medição em relação à antena do transmissor.

Além disso, é realizada uma comparação com outros dois modelos e uma análise do erro quadrático médio (*EQM*) com relação aos dados medidos. Assim, são avaliados os modelos *3GPP Spatial Channel Model* e *ITU-Advanced Channel Model* [18] nos cenários já descritos. Tais modelos são descritos com mais detalhes no Apêndice 7.a de [18].

Neste artigo, para efeitos de comparação, é utilizada a Equação 7.47 de [18] do modelo *3GPP* para caracterizar os cenários (a), (b) e (c). Já para no modelo *ITU-Advanced* utilizou-se os modelos descritos na Tabela 7.11 em [18] para ambiente suburbano. No cenário (a) fez-se uso da equação para ambiente suburbano com visada (*Suburban Macro - LoS*), e para os cenários (b) e (c), a equação para ambiente suburbano sem visada (*Suburban Macro - NLoS*).

V. RESULTADOS

Com base nos dados medidos, é possível comparar o desempenho da rede neural em cada um dos três cenários. A Figura 7 mostra os resultados da rede neural para o cenário (a). Nela, pode-se observar que tanto a curva obtida com o modelo *Log-distance* quanto aquela obtida pela rede neural estão

com valores próximos. Nota-se, no entanto, que o método proposto apresentou um melhor ajuste aos dados medidos. Observa-se também que os modelos *3GPP* se aproximam dos valores medidos apenas em distâncias maiores.

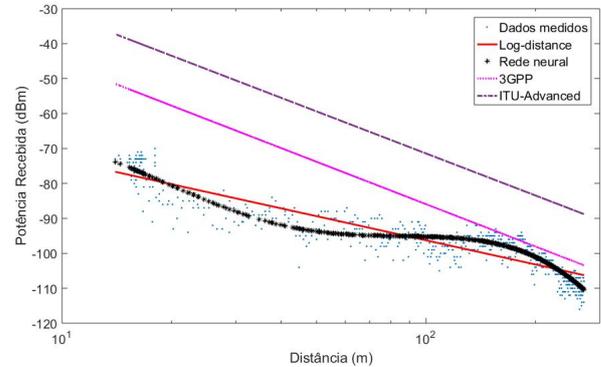


Fig. 7. Medições e resultados da rede e de modelos tradicionais para o cenário (a).

A Figura 8 mostra o resultado para o cenário (b). É possível observar que a curva descrita pela rede neural é capaz de caracterizar melhor o canal. O erro obtido a partir do modelo proposto, nesse caso, é maior quando comparado aos outros cenários. Contudo, a rede neural apresentou um melhor resultado para modelar este cenário em comparação com os modelos de perda de percurso tradicionais.

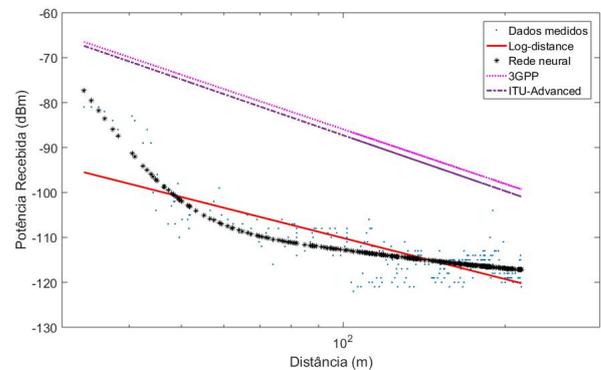


Fig. 8. Medições e resultados da rede e de modelos tradicionais para o cenário (b).

A Figura 9 mostra os resultados para o cenário (c). Nesse cenário, nota-se que os modelos da rede neural e *Log-distance* se aproximam muito, quase se sobrepondo. Já os outros modelos ficaram mais próximos aos dados medidos. Porém, novamente a curva adquirida pela rede neural acompanha melhor as variações de perda de percurso do ambiente.

A Tabela I nos mostra os valores de n , P_0 para os diversos cenários a fim de avaliar seu desempenho. Observa-se ao analisar a Tabela I que, conforme é alterado o cenário os valores de n variam, chegando ao seu maior valor para o cenário (b) e menor valor no cenário (a). Isso já era esperado, já que estes cenários se referem a ambiente sem e com visada respectivamente. Nota-se também que, com o aumento de n , há um aumento do erro *EQM*, em virtude de um aumento da variabilidade nos dados medidos.

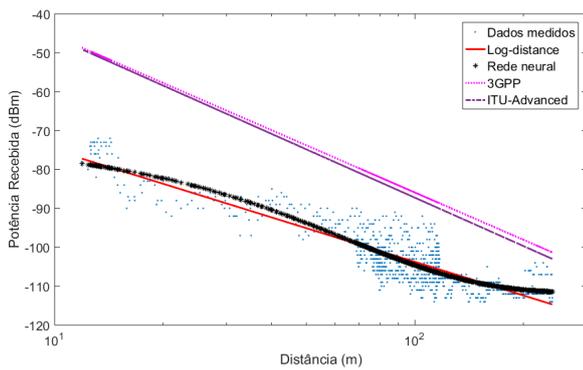


Fig. 9. Medições e resultados da rede e de modelos tradicionais para o cenário (c).

TABELA I

PARÂMETROS ENCONTRADOS PARA O MODELO LOG-DISTANCE.

Cenário	n	P_0
(a)	2.2972	50.3351
(b)	3.0362	49.4207
(c)	2.8705	46.3310

A Tabela II mostra os resultados de erro para cada um dos modelos em relação aos dados medidos. Observa-se que os modelos 3GPP e ITU-Advanced se ajustam ao canal com erros maiores do que aqueles encontrados para os modelos Log-distance e a rede neural. Esta última apresenta um melhor resultado para todos os cenários, o que mostra que, mesmo com a influência da retirada de visada e do aumento da variabilidade, o modelo proposto pela rede neural se ajustou melhor aos cenários avaliados.

VI. CONCLUSÕES

Com o aumento da quantidade de objetos conectados à Internet, aumenta-se o interesse em caracterizar melhor o ambiente de propagação, em específico para as tecnologias LPWAN para as frequências da banda ISM. Cenários típicos de áreas rurais e urbanas que envolvem vegetação, relevos acidentados, obstrução por prédios e ambientes abertos são pontos de interesse para pesquisa e desenvolvimento.

Este trabalho analisou, por meio de dispositivos transceptores LoRa e uma rede neural artificial, os modelos de propagação para perda de percurso na frequência de 433 MHz para diferentes cenários. Foram coletados dados que permitiram realizar comparações entre os modelos de propagação Log-distance, 3GPP, ITU-Advanced e um modelo adquirido pela rede neural para os diferentes cenários.

Os resultados mostraram que o desempenho de uma rede neural simples pode melhorar a modelagem da perda de percurso, fazendo com que o erro diminua drasticamente quando comparado com os modelos convencionais. Além disso, os resultados encontrados contribuem para caracterização do ambiente de propagação usando dispositivos transceptores de baixo custo, para que estes modelos propostos possam ser utilizados em simulações da rede LoRaWAN antes da implementação física da mesma, ou em ajustes na rede durante a sua operação.

TABELA II

VALORES DE EQM ENTRE OS MODELOS.

Cenário	Log-distance	3GPP	ITU-Advanced	Rede neural
(a)	17.8603	190.2911	719.3946	11.6076
(b)	20.8307	575.7243	512.9012	11.0018
(c)	16.3454	321.7144	365.3563	12.8178

Os trabalhos futuros incluem a análise dos resultados da rede para outros cenários de maior distância e também cenários com maior variabilidade de canal.

VII. AGRADECIMENTOS

Os autores gostariam de registrar o agradecimento ao Programa de Pós-Graduação da Engenharia Elétrica da Universidade Federal de Juiz de Fora (PPEE-UFJF).

REFERÊNCIAS

- [1] A. Nordrum. (2016, aug) Popular internet of things forecast of 50 billion devices by 2020 is outdated. [Online]. Available: <https://spectrum.ieee.org>
- [2] Embrapa. (2016, Agosto) Agricultura 4.0: a agricultura conectada. [Online]. Available: <https://www.embrapa.br>
- [3] Sigfox, "The global communications service provider for internet of things (iot)." [Online]. Available: <https://www.sigfox.com> (acessado em Abril de 2019).
- [4] Semtech, "Lora wireless technology." [Online]. Available: <https://www.semtech.com/technology/lora> (acessado em Abril de 2019)
- [5] J. Petajajarvi, K. Mikhaylov, A. Roivainen, T. Hanninen, and M. Pettissalo, "On the coverage of lpwans: range evaluation and channel attenuation model for lora technology," in *2015 14th International Conference on ITS Telecommunications (ITST)*, Dec 2015, pp. 55–59.
- [6] P. Jörke, S. Böcker, F. Liedmann, and C. Wietfeld, "Urban channel models for smart city iot-networks based on empirical measurements of lora-links at 433 and 868 mhz," in *2017 IEEE 28th Annual International Symposium on Personal, Indoor, and Mobile Radio Communications (PIMRC)*, Oct 2017, pp. 1–6.
- [7] S. Benaissa, D. Plets, E. Tanghe, J. Trogh, L. Martens, L. Vandaele, L. Verloock, F. A. M. Tuytens, B. Sonck, and W. Joseph, "Internet of animals: characterisation of lora sub-ghz off-body wireless channel in dairy barns," *Electronics Letters*, vol. 53, no. 18, pp. 1281–1283, 2017.
- [8] C. Phillips, D. Sicker, and D. Grunwald, "A survey of wireless path loss prediction and coverage mapping methods," *IEEE Communications Surveys Tutorials*, vol. 15, no. 1, pp. 255–270, First 2013.
- [9] Semtech, "semtech sx1278." [Online]. Available: <https://www.semtech.com/products/wireless-rf/lora-transceivers/sx1278> (acessado em Abril de 2019)
- [10] Ublox, "Neo-6p module." [Online]. Available: <https://www.u-blox.com/en/product/neo-6p-module> (acessado em Abril de 2019)
- [11] S. Haykin, *Redes neurais: princípios e prática*. Bookman Editora, 2007.
- [12] E. Montgomery and O. Ludwig, *Redes Neurais - Fundamentos e aplicações com programas em C*. Ciência Moderna, 2009.
- [13] S. Silva and F. Schmidt, "Reduction of input variables in artificial neural networks as from principal components analysis data in the modeling of dissolved oxygen," *Química Nova*, vol. 39, 04 2016.
- [14] A. Lenail. Nn-svg. [Online]. Available: <http://alexlenail.me/NN-SVG/index.html> (Acessado em Abril de 2019).
- [15] S. Lawrence, C. Lee Giles, and A. Chung Tsoi, "Lessons in neural network training: Overfitting may be harder than expected." *Proceedings of the National Conference on Artificial Intelligence*, pp. 540–545, 01 1997.
- [16] R. Kohavi, "A study of cross-validation and bootstrap for accuracy estimation and model selection." Morgan Kaufmann, 1995, pp. 1137–1143.
- [17] E. Couto. (2013, julho) Bias vs. variância (parte 2). [Online]. Available: <https://ericcouto.wordpress.com/2013/07/18/bias-vs-variancia-parte-2/> (Acessado em Abril de 2019).
- [18] A. F. Molisch, *Wireless communications*. John Wiley & Sons, 2012, vol. 34.