

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ

GUILHERME PAZETTO TELLES

**ALGORITMOS DE LOCALIZAÇÃO EM AMBIENTES EXTERNOS  
APLICANDO REDE LORAWAN**

DISSERTAÇÃO

CURITIBA

2022

GUILHERME PAZETTO TELLES

**ALGORITMOS DE LOCALIZAÇÃO EM AMBIENTES EXTERNOS  
APLICANDO REDE LORAWAN**

**Localization algorithm in outdoor areas applying LoRaWAN Network**

Dissertação apresentada ao da Universidade Tecnológica Federal do Paraná como requisito parcial para obtenção do título de “Mestre em Engenharia Elétrica” – Área de Concentração: Automação e Sistemas de Energia.

Orientador: Guilherme Luiz Moritz

CURITIBA

2022



4.0 Internacional

Esta licença permite download e compartilhamento do trabalho desde que sejam atribuídos créditos ao(s) autor(es), sem a possibilidade de alterá-lo ou utilizá-lo para fins comerciais. Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.



**Ministério da Educação**  
**Universidade Tecnológica Federal do Paraná**  
**Campus Curitiba**



GUILHERME PAZETTO TELLES

## **ALGORITMOS DE LOCALIZAÇÃO EM AMBIENTES EXTERNOS APLICANDO REDE LORAWAN**

Trabalho de pesquisa de mestrado apresentado como requisito para obtenção do título de Mestre Em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná (UTFPR). Área de concentração: Automação E Sistemas De Energia.

Data de aprovação: 21 de Fevereiro de 2022

Prof Guilherme Luiz Moritz, Doutorado - Universidade Tecnológica Federal do Paraná

Prof Marcelo Eduardo Pellenz, Doutorado - Pontifícia Universidade Católica do Paraná (Pucpr)

Prof Ohara Kerusauskas Rayel, Doutorado - Universidade Tecnológica Federal do Paraná

Documento gerado pelo Sistema Acadêmico da UTFPR a partir dos dados da Ata de Defesa em 21/02/2022.

## AGRADECIMENTOS

Agradeço primeiramente a Deus, que me permitiu continuar nesta empreitada e deu forças até nos momentos de maior dificuldade. Gostaria de estender os meus agradecimentos às pessoas que definitivamente contribuíram para entrega deste trabalho:

A minha esposa Juliana, companheira que, sempre ao meu lado, deu conhecimento, amor e carinho para enfrentarmos juntos mais esta etapa.

Aos meus pais e minha irmã Carlyne, que sempre me apoiaram e confiaram em mim com muito amor, paciência e união.

Ao meu orientador, Professor Doutor Guilherme Luiz Moritz, que com muita paciência, conhecimento vasto e motivação, guiou-me com sabedoria para entrega deste trabalho.

Aos professores Doutor Ohara Kerusauskas Rayel e Doutor Marcelo Eduardo Pellenz, pela disponibilidade do precioso tempo e compartilharem parte do seus respeitadas conhecimentos para avaliação deste trabalho.

Aos grandes amigos que deram apoio, paciência e incentivo.

"O conhecimento torna a alma jovem e diminui a amargura da velhice. Colhe, pois, a sabedoria. Armazena suavidade para o amanhã."

Leonardo da Vinci

## RESUMO

TELLES, Guilherme Pazetto. **Algoritmos de localização em ambientes externos aplicando rede LoRaWAN**. 2022. 52 f. Dissertação (Mestrado em Sistemas de Energia) – Universidade Tecnológica Federal do Paraná, Curitiba, 2022.

Neste trabalho são apresentados dois algoritmos para localização de dispositivos com tecnologia LoRaWAN em ambientes externos de larga escala. O primeiro utiliza de *Weighted Centroid* (WC), no qual cada *Gateway* é classificado conforme o valor de Indicador de Força do Sinal Recebido (RSSI, do inglês *Received Signal Strength Indicator*) e a Razão do Sinal Ruído (SNR, do inglês, *Signal Noise Ratio*) emitido pelo *Target Node* (TN). Já o segundo algoritmo também utiliza de RSSI, porém aplica-se a seleção de pontos de intersecção entre circunferências através de algoritmo de detecção de anomalias (do inglês *Outlier Detections*) denominado *Local Outlier of Propability* (LoOP). Ademais, para comparação dos algoritmos propostos com relação a outros empregados na literatura, os algoritmos de Multilateração (MLT) e um de referência de *Time Difference of Arrival* (TDoA) são empregados a fim de se avaliar os resultados. Para uma maior precisão tanto nos algoritmos propostos quanto de comparação, o Filtro de Kalman (FK) aprimora a precisão de acordo com cada sequência de pacotes enviados individualmente por cada TN. Posteriormente, em uma base de dados proveniente da cidade de Antuérpia, Bélgica, análises de comportamento LoRa e dos algoritmos serão comparados, além de comparação com diferentes estudos aplicados na mesma base de dados. Como resultado, o erro médio de WC+FK foi de 566,86 m, enquanto o de LoOP+FK de 569 m, com medianas de 399,04 m e 424,38 m respectivamente. Tal valor apresenta um resultado melhor do que dos métodos MLT e TDoA com erro médio empregando Kalman de 1824,94 e 655,03 m respectivamente, com melhoria de WC+FK e LoOP+FK de mais de 31% e 8.6% e, relação ao MLT+FK e TDoA+FK, além de demonstrar os ganhos dos métodos propostos em comparação aos método mais complexos como *Fingerprinting* (FP), com 340 m de erro médio aplicado na mesma base de estudo.

**Palavras-chave:** LoRaWAN, Weighted Centroid, Outlier Detection

## ABSTRACT

TELLES, Guilherme Pazetto. **Localization algorithm in outdoor areas applying LoRaWAN Network**. 2022. 52 f. Dissertação (Mestrado em Sistemas de Energia) – Universidade Tecnológica Federal do Paraná, Curitiba, 2022.

In this paper, we introduce two different algorithms to localization of LoRaWAN devices on large scale outdoor area. The first one is Weighted Centroid (WC), classifying each gateway accordingly to the Received Signal Strength (RSSI) and Signal Noise Ratio (SNR) from the received package of the Target Node (TN). The second one also applies RSSI technique, however, differently of the previous algorithm, combines with to Outlier Detection method named Local Outlier of Probability (LoOP), selecting intersections points from circumferences. As comparing algorithms, we also will apply a Multilateration (MLT) method, as a Time Difference of Arrival (TDoA) to the same data for results comparison. Looking for better precision estimation, Kalman Filter (KF) was applied to the package series from each TN. To validate the algorithms, they were applied to a database from Antwerp, Belgium, comparing different LoRa behaviors and algorithms characteristics, and also comparing other localization studies developed on the same data. As result, the WC+FK reach a mean error of 566,86 m, while LoOP+FK had 569 m mean. The median from both were 399,04 and 424,38 respectively. These result were better than the compared MLT and TDoA, which had a mean error applying KF of 1824,94 and 655,03 m respectively. This demonstrates that WC+KF and LoOP improved by 31% and 8.6% the MLT+KF and TDoA+KF ones respectively. The proposals algorithms are also closer to a more complex method as Fingerprinting (FP), with 340 m mean error applied to the same database.

**Keywords:** LoRaWAN, Weighted Centroid, Outlier Detection

## LISTA DE FIGURAS

Figura 1	– Exemplo de modelo de sistema apresentado como estudo para algoritmos propostos. ....	22
Figura 2	– Exemplo de Trilateração, onde na área vermelha demonstra-se o índice de incerteza dos cálculos e verde a intersecção pretendida. ....	26
Figura 3	– Posição Relativa entre duas circunferências ....	33
Figura 4	– Exemplo de Local Outlier of Probability, utilizando de um $k = 20$ e $\psi = 3$ , em que quanto mais próximo o valor de 1, maior propabilidade de ser um <i>Outlier</i> ....	35
Figura 5	– Processo de Filtro de Kalman. ....	38
Figura 6	– Exemplo de up-chirp de um sinal LoRa no tempo em função de frequência. ....	39
Figura 7	– Topologia de Rede LoRaWAN. ....	40
Figura 8	– Área de Estudo realizado na cidade de Antuérpia, Bélgica. ....	42
Figura 9	– Dispositivo IM880B-L com comunicação LoRA e GPS para localização. ....	42
Figura 10	– Erro médio em metros relacionado ao Spreading Factor do Pacote ....	45
Figura 11	– Erro médio em metros relacionado à Quantidade de GWs alcançados do Pacote. ....	46
Figura 12	– CDF de erro dos métodos propostos de em comparação com área total de $52,79 \text{ km}^2$ ....	49



## LISTA DE TABELAS

Tabela 1	–	Técnicas de Localização de Nós .....	14
Tabela 2	–	Valores de Coeficientes de Perda no modelo Log-Normal para diferentes ambientes. ....	23
Tabela 3	–	Parâmetros dos métodos de perda de percurso .....	43
Tabela 4	–	Erro médio em metros dos métodos 3.3.3 e 3.3.4 de acordo com o grau de contribuição .....	43
Tabela 5	–	Variação de Coeficiente de Perda .....	44
Tabela 6	–	Variação de erro de medição no Filtro de Kalman .....	47
Tabela 7	–	Comparação de erro médio com estudos propostos (em negrito) comparado com os trabalhos relacionados. O sufixo KF indica a utilização do Filtro de Kalman. ....	48

## LISTA DE SIGLAS

ADR	<i>Adaptive Data Rate</i>
ANN	<i>Artificial Neural Network</i>
AoA	<i>Angle of Arrival</i>
APIT	<i>Approximate Point in Triangle</i>
BW	<i>BandWith</i>
CSS	<i>Chirp Spread Spectrum</i>
ESP	<i>Estimated Signal Power</i>
FK	<i>Filtro de Kalman</i>
FP	<i>Fingerprinting</i>
GPS	<i>Global Position System</i>
GW	<i>Gateway</i>
HW	<i>Hardware</i>
IoT	<i>Internet of Things</i>
KNN	<i>k-Nearest-Neighbor</i>
LoOP	<i>Local Outlier of Probability</i>
LoRa	<i>Long Range</i>
LPWAN	<i>Low Power Wide Area Network</i>
M2M	<i>Machine-to-Machine</i>
PLOF	<i>Probabilistic Local Outlier Factor</i>
RSSI	<i>Received Signal Strength Indicator</i>
SF	<i>Spreading Factor</i>
SNR	<i>Signal Noise Ratio</i>
TDoA	<i>Time Difference of Arrival</i>
TN	<i>Target Node</i>
ToA	<i>Time of Arrival</i>
WC	<i>Weghted Centroid</i>

## LISTA DE SÍMBOLOS

$\mathcal{A}$	Área de Interesse
$\mathcal{R}^2$	Região espacial de duas dimensões
$p_k$	Pacote emitido por TN
$l(p_k)$	Localização de TN ao emitir pacote $p_k$
$x$	Coordenadas de Longitude do pacote $p_k$
$y$	Coordenadas de Latitude do pacote $p_k$
$\mathcal{G}$	Conjunto de Gateways presentes em $\mathcal{A}$
$M$	Quantidade Total de Gateways presente em $\mathcal{G}$
$G_j$	j-ésimo <i>Gateway</i> do conjunto $\mathcal{G}$
$p_{G_j}$	Posição do <i>Gateway</i> $G_j$
$(x_{G_j}, y_{G_j})$	Coordenada da posição $p_{G_j}$
$\mathcal{D}^{p_k}$	Subconjunto de $\mathcal{G}$ com recepção do pacote $p_k$
$\hat{l}(p_k)$	Posição estimada de TN
$(\hat{x}, \hat{y})$	Coordenadas da posição estimada $\hat{l}(p_k)$
$P_{rx}$	Potência do sinal recebido em $G_j$
$P_{tx}$	Potência de transmissão de TN
$G_{tx}$	Ganho da antena de transmissão de TN
$G_{rx}$	Ganho da antena de recepção em $G_j$
$PL$	Perda de percurso do pacote $p_k$ durante transmissão
$\hat{d}$	Distância estimada entre TN e $G_j$
$\eta$	Coefficiente de perda
$\chi$	Sombreamento do Sinal
$f$	Frequência do sinal emitido
$h_B$	Altura da antena de recepção $G_j$
$h_m$	Altura do transmissor TN
$NO_{G_j}(p_k)$	Ruído do sinal no sistema
$N$	Quantidade de <i>Gateways</i> em $\mathcal{D}_{p_k}$
$d_{G_j}$	Distância real entre TN e $G_j$
$c$	Velocidade da luz
$x_e$	Coordenada de Longitude Estimada para função TDoA
$y_e$	Coordenada de Latitude Estimada para função TDoA
$J(x, y)$	Matriz Jacobiana
$\tau$	Parâmetro de Inicialização de Levenberg-Marquardt
$g$	Grau de Contribuição de <i>Weighted Centroid</i>
$D$	Distância entre dois <i>Gateways</i>
$x(G_i, G_j)$	Coordenada de Longitude do Ponto de intersecção de Circunferências
$y(G_i, G_j)$	Coordenada de Longitude do Ponto de intersecção de Circunferências
$p(G_i, G_j)$	Ponto de intersecção entre circunferências de 2 <i>gateways</i>
$\theta$	Coefficiente de proporcionalidade para Circunferências Disjuntas
$\phi$	Conjunto de pontos de intersecção
$d_{Int_j, Int_k}$	Distância entre pontos de intersecção

$S$	Subconjunto de pontos de intersecção
$\varphi$	Fator de desvio padrão de $\sigma$
$pdist$	Distância probabilística de LoOP
NPLOF	Normalização de PLOF
LoOP	Fator de Classificação
$z_k$	Vetor de Variáveis Observáveis
$x_k$	Vetor de Variáveis de Estado
$U$	Matriz de modelo de medição
$R$	Matriz de covariância de medição
$r$	Fator associado a covariância de medição
$I_q$	Matriz Identidade
$\mathcal{P}$	Matriz de Covariância de Erro
$Q$	Matrix de Covariância do modelo de Transição
$q$	Fator associado a covariância de transição
$G_k$	Ganho de Kalman

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>13</b>
1.1	MOTIVAÇÃO	15
1.2	OBJETIVOS	15
1.2.1	Objetivo Geral	15
1.2.2	Objetivos Específicos	16
1.3	ESTRUTURA DO TRABALHO	16
1.4	PUBLICAÇÕES	17
<b>2</b>	<b>TRABALHOS RELACIONADOS</b>	<b>18</b>
<b>3</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>21</b>
3.1	MODELO DE SISTEMA	21
3.2	MODELO DE PERDA DE PERCURSO	21
3.2.1	Log-Normal	22
3.2.2	Okumura-Hata	23
3.2.3	Estimated Signal Power	24
3.3	ALGORITMOS	25
3.3.1	Multilateração	25
3.3.2	TDoA	27
3.3.3	Weighted Centroid	30
3.3.4	Local Outlier of Probability	31
3.3.4.1	Intersecção entre Circunferências	32
3.3.4.2	Método Local Outlier of Probability	33
3.3.4.3	LoOP para Localização	35
3.4	FILTRO DE KALMAN	36
3.4.1	Atualização na Predição	36
3.4.2	Correção na medição	37
3.5	LORA	37
3.5.1	LoRaWAN	39
<b>4</b>	<b>DADOS E RESULTADOS</b>	<b>41</b>
4.1	DADOS	41
4.2	RESULTADOS	41
4.2.1	Grau de Contribuição	43
4.2.2	Coefficiente de Perda	44
4.2.3	Spreading Factor	45
4.2.4	Quantidade de Gateways	46
4.2.5	Variação do Ruído de Medição	47
4.2.6	Resultados comparado com Referências	47
<b>5</b>	<b>CONCLUSÃO E TRABALHOS FUTUROS</b>	<b>50</b>
	REFERÊNCIAS	51

## 1 INTRODUÇÃO

O conceito de Internet das Coisas (do inglês *Internet of Things*, ou IoT) consiste em providenciar facilidades ao cotidiano ao promover comunicação entre objetos e máquinas através de tecnologias de rede em um processo de comunicações denominado *Machine-to-Machine*, ou M2M. A aplicação da IoT pode ser dada as mais diversas áreas - como indústrias, agricultura, transportes, saúde. A extensa diversidade de aplicações, conforme estimativa em (NOKIA, 2017) poderá levar a mais de 30 bilhões de equipamentos aptos a comunicação M2M até 2025.

A fim de prover a conectividade esperada, entretanto, o sistema de dispositivos e rede deverão atender a uma série de requisitos como baixo consumo de energia, facilidade de implementação, baixo custo. Por isso, redes como as denominadas *Low Power Wide Area Networks* (LPWAN) apresentam características que atendem os requisitos necessários. Entre as principais redes, pode-se citar o LoRa, Sigfox e NB-IoT e IEEE.802.15.04 (AERNOUTS et al., 2019).

Dentre as redes apresentadas, as aplicadas com a modulação LoRa (*Long Range*) são umas das com maiores utilizações. Estas redes possuem uma tecnologia aplicada a camada física do modelo OSI e que devido a transmissão através de *Chirp Spread Spectrum* (CSS), são menos suscetíveis a ruídos e interferências (BISSETT, 2018). Além disso, apresentam como característica operarem em faixas de frequência inferior a 1 GHz, regulado legalmente na faixa de 868 MHz e 433 MHz na União Europeia, 915 MHz nos Estados Unidos. No Brasil, além de operar tanto na faixa de 433 e 915, opera em uma faixa em torno de 905 MHz. Além disso, a LoRa Alliance, associação responsável pela difusão do LoRa, apresentam a solução LoRaWAN como uma topologia em formato estrela, equipamentos comunicam-se a *Gateways* para transmissão de pacotes e posterior processamento de dados que serão utilizados pelo usuário, com o objetivo de aprimorar o consumo da bateria e permitir a inclusão com facilidades de múltiplos Nós, além de critérios de segurança na comunicação. (BOR et al., 2016)(LORA ALLIANCE., 2015).

Uma das aplicações difundidas na utilização do IoT é a localização de sensores em ambientes tanto internos, com tecnologias como Wi-Fi, Bluetooth (EYNG et al., 2020), quanto em ambientes externos, como LoRa (AERNOUTS et al., 2019). A localização de equipamentos tem importantes aplicações em rastreamento de veículos, recuperação de cargas roubadas, além de controle em ambientes internos de maquinários, processos de logística. Em ambientes externos, as redes LPWAN são excelentes soluções, como

**Tabela 1 – Técnicas de Localização de Nós.**

	Técnica	Princípio de Operação	HW Complexo	Atenuação	Custo
<i>Range-Based</i>	RSSI	Potência do Sinal Recebido	Não	Alto	Baixo
	ToA	Tempo entre Nó e Gateway	Sim	Baixo	Médio
	TDoA	Tempo entre Gateways	Sim	Baixo	Médio
	AoA	Ângulo de chegada do sinal	Sim	Médio	Alto
<i>Range-Free</i>	Centroid	Média de (x,y) dos Gateways	Não	Alto	Baixo
	DV-HOP	Salto de pacotes	Não	Alto	Baixo
	APIT	Intersecção de Triângulos	Não	Alto	Baixo

Fonte: Adaptado de (AZMI et al., 2018)

no caso do LoRa, com alcance superior em média a 15 km, e com alcance em estudo experimental com mais de 700 km (BISSETT, 2018). Além disso, a rede LoRa permite estender a vida útil de equipamentos comparada a outras metodologias de localização. O GPS (*Global Position System*), tecnologia com alta precisão, para estimar a posição consome significativamente a energia da bateria e reduz o tempo de vida em um dispositivo autônomo. Por exemplo, um equipamento com a bateria com autonomia de 250 mAh teria a capacidade de realizar a coleta de dados de 1000 pacotes quando aplicado o uso de GPS, enquanto na tecnologia LoRa, seria possível transmissão superior a 20.000 pacotes (PODEVIJN et al., 2018).

Para utilização das redes LPWANs para localização, diferentes métodos podem ser aplicados. Existem duas classificações principais quando aos métodos. A primeira seria os métodos centralizados, nos quais é necessário uma central de dados para processamentos e identificação da posição do objeto, o que acarreta uma demora para acesso dos dados e custo de manutenção do banco. A segunda classificação seriam os métodos distribuídos, em que a posição do objeto é estimada sem necessidade deste banco de dados processado, passando a utilizar as informações do dispositivo, *Gateway* (GW) e ambiente para estimar a localização do dispositivo. Dentre os métodos distribuídos, dividem-se entre *Range-Based* e *Range-Free* (AZMI et al., 2018). A primeira consiste na utilização de medições do sinal recebido como a potência do sinal para estimar a posição do Nó. Há dentre estas técnicas as seguintes: *Received Signal Strength Indicator* (RSSI), *Time Difference of Arrival* (TDoA), *Time of Arrival* (ToA) e *Angle of Arrival* (AoA). Já nas técnicas de *Range-Free* (SINGH; SHARMA, 2015), as estimativas de posicionamento considera somente as posições dos *Gateways* receptores, como as técnicas de *Centroid*, APIT e DV-HOP. Os diferentes métodos apresentam características diferentes de custo e atenuação, apresentado na Tabela 1.

Cada uma destas técnicas ainda pode considerar diferentes algoritmos, como de Mínimos Quadráticos (EYNG et al., 2020), *Fingerprinting* (JANSSEN et al., 2020), Levenberg-Marquardt (MENSING; PLASS, 2006), métodos de Detecção de Anomalias, como DBSCAN (LAM et al., 2018), LOF e LoOP (KRIEGEL et al., 2009). Estes métodos utilizarão das distâncias calculadas pelos métodos RSSI ou TDoA para estimar com maior precisão a posição do Nó. Além disso, métodos de filtragem estocástica, como o Filtro de Kalman, os quais, conseguem a partir de características do sistema no tempo reduzir tanto a interferência dos erros quanto ruído deste ambiente no cálculo, e assim gerar maior precisão na estimativa (EYNG et al., 2020).

## 1.1 MOTIVAÇÃO

O crescente número de dispositivos IoT aplicados em diversos ambientes e aplicações, como agricultura, cidade inteligentes, telemetria e rastreamento permite, a partir do sinal emitido e dos parâmetros coletados, fornecer dados para a localização estimada dos dispositivos sem aplicar tecnologias como a do GPS, que reduz a vida útil do equipamento. Com isso, as redes LPWAN que apresentam longo alcance, baixo consumo de energia e podem ser formada por equipamentos de baixo custo, possibilitam uma rápida expansão de soluções a preços módicos (NOKIA, 2017).

Encontrar métodos de localização aplicados a redes como LoRaWAN que possibilitam tais aplicações como rastreamento mostra-se de fundamental importância, além de identificar características e algoritmos, melhorar a precisão da solução e universalizar sua aplicação às mais diversas condições e áreas.

## 1.2 OBJETIVOS

### 1.2.1 Objetivo Geral

Este trabalho tem como objetivo apresentar soluções de posicionamento em ambientes externos em áreas de larga escala através da rede LoRaWAN e técnica de RSSI aplicadas junto a algoritmos como *Weighted-Centroid* e *Local Outlier of Probability*, além de compará-los com outros algoritmos encontrados na literatura como Multilateração e TDoA, e validá-las a uma base de dados real para comparação com outras técnicas como *Fingerprinting*.



### 1.2.2 Objetivos Específicos

- Coletar informações em estudos sobre posicionamento em grandes áreas com utilização de LPWANs.
- Identificar métodos de estimativa de distância, como Okumura-Hata.
- Apresentar método conhecido de comparação, como a Multilateração.
- Apresentar método com a técnica de TDoA, a fim de comparação de técnica com RSSI.
- Propor solução com método denominado *Weighted-centroid*
- Propor solução com algoritmo denominado *Local Outlier of Probability*
- Aprimorar resultados ao aplicar Filtro de Kalman
- Aplicar todos algoritmos à base real de dados
- Identificar diferentes comportamentos quanto a características dos algoritmos, métodos de estimativa de distância e comportamento da rede
- Comparar resultados dos métodos a estudos diversos realizados na mesma base de dados.

### 1.3 ESTRUTURA DO TRABALHO

O trabalho se desenvolverá, além da introdução apresentada, em mais 4 Capítulos. No Capítulo 2 é apresentada uma revisão de estudos aplicados em ambientes externos de áreas extensas com uso da rede LoRa para posicionamento de equipamentos. Já no Capítulo 3 é apresentada a fundamentação teórica para os algoritmos aplicados ao estudo. Na sequência, o Capítulo 4 introduz a base de dados do estudo, além de análises com os algoritmos aplicados e comparação de resultados de estudos diversos. Por fim, no Capítulo 5 é apresentada a conclusão referente a dissertação, além de comentários finais e propostas futuras.

#### 1.4 PUBLICAÇÕES

Este trabalho gerou um artigo aprovado "*Weighted-Centroid Localization using LoRaWAN Network on Large Outdoor Areas*", na revista *Internet Technology Letters* (ITL-22-0033). (TELLES et al., )

## 2 TRABALHOS RELACIONADOS

A localização em ambientes externos de áreas extensas com o uso de redes LoRa foi avaliada em diversos estudos na literatura. Uma seleção dos estudos será apresentada para demonstrar técnicas de posicionamento e posterior comparação com este trabalho. Os estudos apresentados tem como característica áreas de ambiente externo com áreas que variam de  $0,43 \text{ km}^2$  a mais de  $50 \text{ km}^2$ , além de utilização de técnicas RSSI e TDoA, as quais possuem maior abrangência nas aplicações práticas (LORA ALLIANCE, 2018a). Porém, devido a cada estudo possuir uma quantidade de GWs diferentes, distribuições espaciais dos mesmos em áreas de diversos tamanhos, o critério de erro por áreas será utilizado para comparação da qualidade da solução. Este critério consiste na razão entre uma área circular com raio igual ao erro médio do estudo, e a área total do mesmo, representado por Erro de área =  $\frac{\text{Área circular de raio igual ao erro médio}}{\text{Área Total do Estudo}}$  (ALMUZAINI; GULLIVER, 2010).

No estudo apresentado pelo *white paper* (LORA ALLIANCE, 2018a) provido pela LoRa Alliance, características de posicionamento com a técnica TDoA são exploradas, além de demonstrar como efeitos de atraso no tempo ou ruído podem afetar o sinal. Além disso, são apresentadas aplicações como a realizada na cidade de Barcelona, Espanha, onde em uma área de  $0,43 \text{ km}^2$  na região portuária, seis *Gateways* foram instalados distanciados entre si em torno de 400 a 600 metros.

Com equipamentos dotados de comunicação LoRa e GPS, veículos foram avaliados quanto ao tempo em que se encontravam estacionados ou em movimento na área estudada. A partir de um algoritmo aplicado à técnica de TDoA, obteve-se erro de 68 m para veículos parados e 171 m quando em movimento.

No mesmo documento, apresentam-se também outros estudos, como o apresentado em uma localidade próximo a Paris, França, em uma área de  $1,6 \text{ km}^2$ , com 5 *Gateways* dispostos a 900 m a 1300 m entre si. Com um algoritmo também aplicado à técnica de TDoA, o erro médio de distância encontrado nesta aplicação foi de 115 m. A partir do critério de área, o estudo de Barcelona apresenta o valor de  $\frac{68^2\pi}{0,43 \times 10^6} = 3,38\%$ . Já no de Paris, o valor é  $\frac{115^2\pi}{1,6 \times 10^6} = 2,6\%$ . Logo, mesmo com o erro médio superior, o estudo de Paris apresenta uma melhor precisão comparado ao de Barcelona.

No estudo realizado pelos autores em (DANEBJER; HALLDÓRSSON, 2018), o conceito de técnica RSSI combinado com ToA é aplicado a partir tanto de Okumura-

Hata quanto Log-Normal. Com três *Gateways* distribuídos em uma área de  $1\text{km}^2$ , o menor erro médio foi de 272m, na combinação das técnicas RSSI+Trilateração e ToA, e do método Okumura-Hata. Logo, erro de área de  $\frac{271^2\pi}{1000^2\pi} = 7,34\%$ . O valor apresentou um pior resultado comparado aos estudos anteriores, devido a quantidade de *Gateways* e também pelas técnicas utilizadas apresentarem interferência quanto a ruído, no caso de RSSI, e sincronia de tempo entre Nó e *Gateway*, a qual, devido seu cálculo ser baseado na velocidade do sinal próxima a da luz percorrida em um intervalo de tempo, um desvio de milissegundos pode caracterizar quilômetros de distância.

Já no trabalho realizado em (BISSETT, 2018), também revisado por (NGUYEN, 2019), o estudo ocorre em uma área não limitada da Holanda, na rede LoRaWAN local KPN sem limitar a quantidade de GWs. Neste estudo são aplicados diferentes algoritmos com a técnica de TDoA, como mínimos quadráticos não-linear, APIT, um método *Range-Free* Adaptado e principalmente, um algoritmo de dissecação multilateral, que consiste em cruzamento de áreas proveniente de hipérbolas formadas pelo técnica de TDoA ao comparar a chegada do sinal nos *Gateways*. O estudo realizado analisou vinte mil pacotes provenientes de 19 equipamentos transitando no país. O valor ainda foi comparado a técnica TDoA proprietária da operadora holandesa KPN. O estudo teve , em média, o valor de 2 km de erro, enquanto a técnica da KPN apresentou valor médio de 6 km. Apesar do alto valor médio, a mediana do estudo e da operadora foram de 550 metros e 174 metros respectivamente. Portanto, mesmo apresentado grande parte dos valores com resultados inferiores a 600 metros, a técnica de TDoA precisa também de sincronismo entre os *Gateways*, o que gera erros altos que majoram o valor do erro médio da solução.

A base de dados aplicada no seguinte trabalho, em (JANSSEN et al., 2020), foi apresentada inicialmente na publicação (AERNOUTS et al., 2019) realizado na cidade de Antuérpia, Bélgica, o que serviu de base para diversos estudos, e o qual será utilizado para validar os algoritmos propostos nos Capítulos seguintes. No caso de (JANSSEN et al., 2020), dispositivos LoRa foram instalados em veículos do serviço postal da cidade, os quais geraram mais de 130 mil pacotes com metadados para aplicação de técnicas de RSSI e TDoA. Ao trabalhar com uma base de dados comum a diferentes estudos permite-se uma comparação eficaz dos métodos propostos ao se comparar diferentes modos de abordagem, como precisão no caso de *Fingerprinting*, porém com necessidade de validação, ou de algoritmos de RSSI como Min-Max, com menor precisão, mas menor custo de implementação e de fácil implementação.

O estudo já citado em (JANSSEN et al., 2020) trata de duas soluções com uso

da técnica RSSI. A primeira consiste em aplicar algoritmo conhecido como Min-Max, em que intersecções provenientes de retângulos formados pela distância estimada do Nó a cada GW, e assim geram um retângulo final de intersecção. Para isso, utilizou-se várias técnicas de estimativa de distância, como Okumura-Hata, tanto em região urbana quanto rural, e COST-231. Além disso, aplicam-se pesos de classificação aos vértices do retângulo resultante. A técnica de Min-Max gerou um valor de 700 metros de média em uma área total do estudo de  $52,79 \text{ km}^2$ , logo, 2,91% de erro relativo a área de interesse.

No segundo caso do estudo de (JANSSEN et al., 2020), o método apresentado foi de *Fingerprinting* (FP). Este método consiste em, a partir de uma base de dados de recepções de RSSI e da base de dados das antenas, identificar o padrão de comportamento do sistema de estudo e estimar a posição do Nó. O estudo apresenta uma tabela comparativa entre outros que aplicam o método de FP para solução, como no estudo (AERNOOTS et al., 2019), em que se utilizou de um método de FP aplicando *k-Nearest-Neighbor* (KNN), um algoritmo para estimativa de posição a partir de pontos vizinhos. Obteve-se o valor de erro médio de 398,4 m e mediana de 273,03 m. Com a base de dados disponibilizada, o estudo (JANSSEN et al., 2020) e (LI et al., 2021) também aplicaram métodos de FP, com algoritmos como *Random-Forest* e *Artificial Neural Network* (ANN). Dentre os estudos, o com melhor erro médio foi de 158,41 m (LI et al., 2021), e um erro de área de 0,69%. O método de FP, apesar de preciso, apresenta a necessidade de uma fase de preparação em 60% a 70% da base de estudos aplicada apenas para treinamento, além da necessidade de atualização e a restrição do método a ser aplicado apenas na área de interesse.

O trabalho que será desenvolvido, portanto, visa apresentar soluções com melhor precisão a partir da técnica de RSSI. Esta escolha visa evitar os erros apresentados pela falha de sincronia entre GWs da técnica TDoA, o que elevou consideravelmente o erro médio do estudo Bissett (2018), além de poder aplicar um HW mais simples, como apresentado na Tabela 1. Além disso, apresentar um algoritmo com precisão próxima ao de FP, que apesar de um pequeno erro médio, limita a aplicação a área estudada, necessita de atualizações e uma quantidade relativa de dados para fases de preparação.

### 3 FUNDAMENTAÇÃO TEÓRICA

Neste Capítulo serão apresentadas as características do sistema em que ocorrerá o estudo, além dos modelos utilizados para estimar a distância através dos métodos de RSSI e TDoA. Os algoritmos propostos também serão detalhados para demonstrar como os mesmos utilizarão a distância calculada e o sistema para sua aplicação. Além disso, será apresentado o Filtro de Kalman, e como ao longo do tempo aprimora a estimativa do posicionamento do Nó, e assim reduz a imprecisão deste posicionamento. Por final, as redes LoRa e LoRaWAN serão caracterizadas conforme seus comportamentos de transmissão, topologia, faixas de frequência.

#### 3.1 MODELO DE SISTEMA

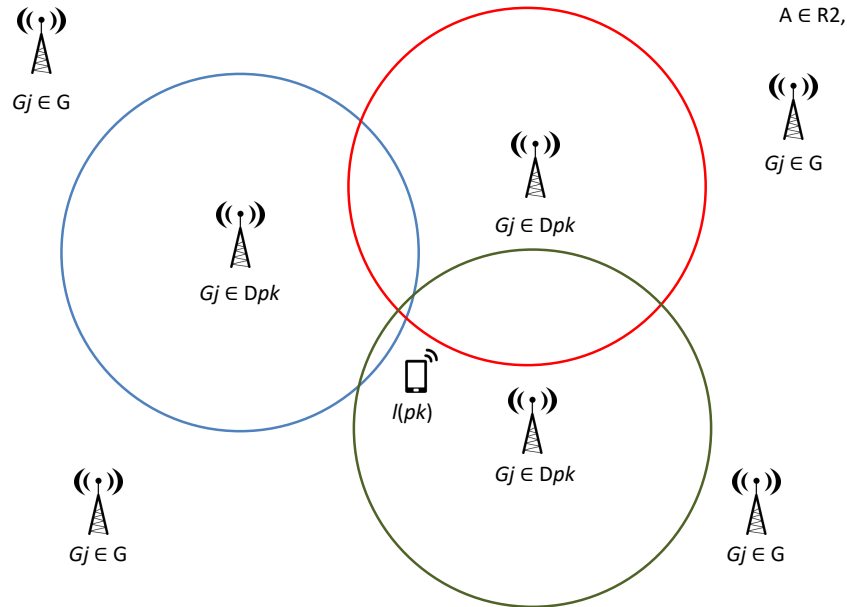
Situado em uma área geográfica  $\mathcal{A} \in \mathcal{R}^2$ , o Nó transmitindo em LoRaWAN denominado *Target Node* (TN) envia um pacote  $p_k$  localizado na posição desconhecida  $l(p_k) = (x, y)$ . Dentro de  $\mathcal{A}$ , existe um conjunto  $\mathcal{G}$  de  $|\mathcal{G}| = M$  Gateways LoRaWAN. O  $j$ -ésimo Gateway de  $\mathcal{G}$ , denominado  $G_j$  está localizado na posição conhecida  $p_{G_j} = (x_{G_j}, y_{G_j}) \in \mathcal{A}$ . O pacote  $k$ -ésimo enviado por TN chega aos gateways de  $\mathcal{G}$ , afetado por ruídos, atenuação e efeitos de propagação. Devido a isso, o pacote  $p_k$  é somente decodificado por parte do conjunto  $\mathcal{G}$ , denominado  $\mathcal{D}^{p_k}$ . Cada gateway  $G_j \in \mathcal{D}^{p_k}$  destina o pacote  $p_k$  recebido a um servidor de rede, contendo individualmente a informação de metadados. Dentre as informações presentes dentro dos metadados recebidos, além de cabeçalho e *payload*, recebe-se também características do sinal, como a intensidade de sinal recebido em  $G_j$   $[\text{RSSI}_{G_j}(p_k)]$ , a razão Sinal-Ruído em  $G_j$   $[\text{SNR}_{G_j}(p_k)]$ , e o tempo de chegada do pacote  $p_k$  em  $G_j$   $[\text{TOA}_{G_j}(p_k)]$ .

Pretende-se definir a função  $\hat{l}(p_k) = (\hat{x}, \hat{y}) := f[p_{G_j}, \text{RSSI}_{G_j}(p_k), \text{SNR}_{G_j}(p_k), \text{TOA}_{G_j}(p_k)]$ ,  $G_j \in \mathcal{D}^{p_k}$ , em que  $\hat{l}(p_k) = (\hat{x}, \hat{y}) \in \mathcal{A}$  é a posição estimada de  $l(p_k)$ . O modelo proposto pode ser visto na Figura 1.

#### 3.2 MODELO DE PERDA DE PERCURSO

A transmissão de sinais eletromagnéticos sofre, no percurso entre Nó e GW, efeitos que atenuam e distorcem o sinal original, como reflexões, sombreamento e interferências (GOLDSMITH, 2005). Assim, a perda de percurso pode ser determinada pelo termo de

**Figura 1 – Exemplo de modelo de sistema apresentado como estudo para algoritmos propostos.**



**Fonte: Autoria Própria**

*Link Budget*, que caracteriza todas as perdas e ganhos do sistema para caracterizar o sinal recebido no receptor. Tal perda pode ser representada por:

$$P_{rx} = P_{tx} + G_{rx} + G_{tx} - PL. \quad (1)$$

no qual  $P_{rx}$  é o valor da potência de recepção em dBm,  $P_{tx}$  a potência de transmissão do emissor,  $G_{tx}$  e  $G_{rx}$  são ganhos das antenas de transmissão e recepção, respectivamente, e  $PL$  o valor que denomina-se de perda de percurso.

Com intuito de aplicar a técnica de RSSI, necessita-se estimar o valor de distância  $\hat{d}$ , e assim aplicar os algoritmos pertinentes. Para estimar de maneira empírica esta distância, a perda de percurso é utilizada por modelos de propagação. Dentre estes, pode-se destacar o de Log-Normal e Okumura-Hata, que serão detalhados nas subseções seguintes.

### 3.2.1 Log-Normal

No modelo de Log-Normal, a perda de percurso permite calcular a distância entre emissor e receptor por:

**Tabela 2 – Valores de Coeficientes de Perda no modelo Log-Normal para diferentes ambientes.**

Ambiente	$\eta$
Área Urbana densa	3,7 - 6,5
Área Urbana menos densa	2,7 - 3,5
Prédio Comercial (mesmo andar)	1,6 - 3,5
Prédio Comercial (diferentes andares)	2 - 6
Estabelecimento Comercial	1,8 - 2,2
Indústria	1,6 - 3,3
Residência	3

Fonte: Adaptado de (RAPPAPORT, 1996)

$$\hat{d} = \hat{d}_0 * 10^{\frac{PL-PL_0-\chi}{10\eta}} \quad (2)$$

em que  $PL$  é a perda de percurso em dBm e  $PL_0$  a perda de percurso em um distancia  $\hat{d}_0$  tida como referência para o cálculo. Esta distância  $\hat{d}_0$  pode ser mensurada, ou calculada pelo modelo de propagação de Friis, sem perda.  $\hat{d}$  é a distância estimada no cálculo, e  $\eta$  que determina o quanto o ambiente interfere na transmissão, e quanto maior o  $\eta$ , maior interferência do sinal no sistema. Já  $\chi$  representa o sombreamento com  $\chi \sim \mathcal{N}(0, \sigma^2)$  como uma distribuição Gaussiana de média zero e desvio padrão  $\sigma$  (GOLDSMITH, 2005).

### 3.2.2 Okumura-Hata

O modelo de Okumura-Hata (DANEBJER; HALLDÓRSSON, 2018) é um modelo empírico aplicado para ambientes em que a frequência opera na faixa de 200 MHz a 1500 MHz e distâncias de até 20 km. A equação consiste em

$$\hat{d} = 10^{\frac{PL_{urbano} - 69.55 - 26.16 \log_{10}(f) + 13.82 \log_{10}(h_B) + a(h_m)}{(44.9 + 6.55 \log_{10}(h_B))}} \quad (3)$$

em que  $\hat{d}$  é distância estimada em km é calculada em função de perda de percurso  $PL_{urbano}$  em dBm,  $f$  é a frequência em MHz,  $h_B$  é a altura da antena de recepção e  $h_m$  a altura do dispositivo móvel com ambas alturas medidas em metros. A função  $a(h_m)$  varia de acordo com o tamanho da cidade, conforme abaixo:



$$a(h_m) = \begin{cases} 3,2 \log_{10}(11,75h_m)^2 - 4,97 & \text{grandes cidades e } f > 300 \text{ MHz} \\ 0,8 + (1,1 \log_{10}(f) - 0,7)h_m - 1,56 \log_{10}(f) & \text{pequenas e m\u00e9dias cidades.} \end{cases} \quad (4)$$

Nos casos de ambiente suburbano, a equa\u00e7\u00e3o \u00e9 modificada com o seguinte fator:

$$PL_{suburbano} = PL_{urbano} - 2(\log_{10} \frac{f}{28})^2 - 5,4 \quad (5)$$

e para ambientes rurais:

$$PL_{rural} = PL_{urbano} - 4,78(\log_{10} f)^2 + 18,33 \log_{10} f - 40,94. \quad (6)$$

### 3.2.3 Estimated Signal Power

No recebimento de um pacote LoRa, o RSSI normalmente \u00e9 associado a pot\u00eancia recebida do sinal. Dessa forma, o RSSI pode ser representado como:

$$RSSI_{G_j}(p_k) = ESP_{G_j}(p_k)_{(W)} + No_{G_j}(p_k)_{(W)} \quad (7)$$

em que  $ESP_{G_j}(p_k)$  \u00e9 o valor representado como a pot\u00eancia do sinal recebido em *Watts* sem a presen\u00e7a do ru\u00eddo  $No_{G_j}(p_k)$  (RAHMADHANI, 2017). Ao mesmo tempo, ao receber um pacote LoRA, h\u00e1 tamb\u00e9m o conceito de SNR, que pode ser calculado pela equa\u00e7\u00e3o:

$$SNR_{G_j}(p_k)_{(W)} = \frac{ESP_{G_j}(p_k)_{(W)}}{No_{G_j}(p_k)_{(W)}} \quad (8)$$

Logo, para estimar com maior precis\u00e3o o valor da pot\u00eancia recebida, sem a adi\u00e7\u00e3o do ru\u00eddo  $No_{G_j}(p_k)$ , calcula-se o valor de  $ESP$  em dBm:

$$ESP_{G_j}(p_k)_{(dBm)} = RSSI_{G_j}(p_k)_{(dBm)} + SNR_{G_j}(p_k)_{(dB)} - 10 \log_{10} \left( 1 + 10^{0.1 SNR_{G_j}(p_k)_{(dB)}} \right) \quad (9)$$

O valor de  $ESP$  passa a substituir o valor de RSSI nos c\u00e1lculos de perda de percurso nas Equa\u00e7\u00f5es (3) e (2) a fim de reduzir a imprecis\u00e3o provocada pelo ru\u00eddo na

medição do sistema.

### 3.3 ALGORITMOS

Nesta seção, serão demonstrados alguns métodos para estimar o posicionamento do Nó de acordo com as informações providas pelos metadados do pacote LoRaWAN. Como modelos de comparação do estudo, serão aplicados o método de Multilateração (MLT) com o conceito de mínimos quadráticos, comumente aplicado em soluções de localização, além de um método de TDoA usado no algoritmo Levenberg-Marquardt. Além disso, dois métodos serão propostos: um método denominado *Weighted Centroid* (WC) e o LoOP, o qual aplica o conceito de detecção de *outliers*.

Após a estimativa gerada por cada um dos algoritmos, será proposto ainda a utilização de um método de filtragem estocástica denominado filtro de Kalman, o que gerará uma maior precisão na posição estimada.

#### 3.3.1 Multilateração

O algoritmo de Multilateração é um conhecido método de localização, aplicado tanto em ambientes internos (EYNG et al., 2020) quanto externos. (LAM et al., 2018), (DANEBJER; HALLDÓRSSON, 2018). Inicialmente, considera-se a distância entre um TN e um GW. Identificada a posição  $(x_j, y_j)$  conhecida de um GW, determina-se que


$$\hat{d}_{G_j} = \sqrt{(\hat{x} - x_{G_j})^2 + (\hat{y} - y_{G_j})^2}. \quad (10)$$

em que  $\hat{d}_{G_j}$  é a distancia entre TN e  $G_j$ ,  $(x_{G_j}, y_{G_j})$  a posição conhecida do *gateway*  $G_j \in \mathcal{D}_{p_k}$  e  $(\hat{x}, \hat{y})$  a localização desconhecida do Nó. Esta equação representa uma circunferência, na qual o centro são as coordenadas de  $G_j$ , o raio da circunferência é a distância, e a posição do TN inscrita no perímetro.

Se a quantidade de GWs for  $N = |\mathcal{D}_{p_k}| = 3$ , passa-se a ser possível estimar a posição não em torno de um perímetro, mas em um ponto único, e através de um sistema de equações (11) (12) (13) localiza-se a posição estimada, como exemplificada em

$$\hat{d}_1 = \sqrt{(\hat{x} - x_{G_1})^2 + (\hat{y} - y_{G_1})^2}. \quad (11)$$

**Figura 2 – Exemplo de Trilateração, onde na área vermelha demonstra-se o índice de incerteza dos cálculos e verde a intersecção pretendida.**



**Fonte: Adaptado de (DANEBJER; HALLDÓRSSON, 2018)**

$$\hat{d}_2 = \sqrt{(\hat{x} - x_{G_2})^2 + (\hat{y} - y_{G_2})^2}. \quad (12)$$

$$\hat{d}_3 = \sqrt{(\hat{x} - x_{G_3})^2 + (\hat{y} - y_{G_3})^2}. \quad (13)$$

Para o caso da Multilateração, em que  $N \geq 3$ , aumenta-se o número de equações. Porém, como é desconhecida a distância exata  $d_{G_j}$  entre TN e  $G_j$ , além da posição correta de TN  $l(p_k)$ , utiliza-se de distâncias estimadas, adquiridas em modelos como (3) e (2), para aproximar o valor de  $d_{G_j}$  e avaliar a possível localização de TN.

A resolução deste sistema consiste na substituição do valor real desconhecido pelos calculados em (3) ou (2) para cada circunferência dentro dos  $N$  GWs. A partir da distância estimada em (10), obtêm-se

$$-\hat{x}_{G_n}^2 - \hat{y}_{G_n}^2 + x_{G_N}^2 + y_{G_N}^2 + (d_{G_n})^2 - (d_{G_N})^2 = \hat{x}(-2x_{G_n} + 2x_{G_N}) + \hat{y}(-2y_{G_n} + 2y_{G_N}). \quad (14)$$

Como a equação do  $G_N$  reduzida e ela mesma é igual a zero, gera-se portanto um

sistema linear de  $N-1$  equações. Este sistema pode ser representado por uma equação de matrizes  $b = A\hat{l}(p_k)$  em que,

$$b = \begin{bmatrix} -\hat{x}_{G_1}^2 - \hat{y}_{G_1}^2 + x_{G_N}^2 + y_{G_N}^2 + (d_{G_1})^2 - (d_{G_N})^2 \\ -\hat{x}_{G_2}^2 - \hat{y}_{G_2}^2 + x_{G_N}^2 + y_{G_N}^2 + (d_{G_2})^2 - (d_{G_N})^2 \\ \vdots \\ -\hat{x}_{G_{N-1}}^2 - \hat{y}_{G_{N-1}}^2 + x_{G_N}^2 + y_{G_N}^2 + (d_{G_{N-1}})^2 - (d_{G_N})^2 \end{bmatrix}, \quad (15)$$

$$A = \begin{bmatrix} -2x_{G_1} + 2x_{G_N} & -2y_{G_1} + 2y_{G_N} \\ -2x_{G_2} + 2x_{G_N} & -2y_{G_2} + 2y_{G_N} \\ \vdots & \vdots \\ -2x_{G_{N-1}} + 2x_{G_N} & -2y_{G_{N-1}} + 2y_{G_N} \end{bmatrix}$$

A fim de minimizar a distância estimada e a distância real entre GWs e o TN, é utilizado o método de mínimos quadrados representado por:

$$\hat{l}(p_k) = (A^T A)^{-1} A^T b \quad (16)$$

em que  $\hat{l}(p_k) = [\hat{x}\hat{y}]^T$  é a localização do Nó calculada a fim de minimizar o valor de  $\sum_{n=1}^N (d_{G_n} - \hat{d}_{G_n})^2$ . A precisão do cálculo é afetada pelos fatores presentes no ambiente, como condições de sombreamento, desvanecimento e multipercursos.

### 3.3.2 TDoA

Ao receber um pacote proveniente do Nó, o  $G_j$  registrará o momento do seu recebimento, adicionada no metadado a ser enviado aos servidores de rede. A técnica de *Time Difference of Arrival* consiste em utilizar a combinação de  $H = \binom{N}{2}$ , ou seja, a cada conjunto de  $N \geq 3$ , fazer a comparação por pares para determinar a diferença de distância do TN a cada  $G_j$ , e por final, após realizado todas as combinações, estimar a posição do TN.

Para iniciar, entende-se que o sinal transmitido pelo TN percorre uma distância de acordo com a velocidade do sinal, denominado:

$$\hat{d} = c * \text{TOA}_{G_j}(p_k) \quad (17)$$

em que a distância estimada  $\hat{d}$  é calculada de forma que  $c$  é a velocidade de propagação do sinal no período do tempo  $\text{TOA}_{G_j}(p_k)$ , que consiste no tempo entre o envio de  $p_k$  até chegar a um  $G_j$ . Portanto, cada interação entre o TN e cada  $G_j \in D_{p_k}$  apresentará esta equação.

Porém, devido ao consumo de bateria do Nó para manter o seu relógio sincronizado com o  $G_j$ . O tempo de envio do pacote será um parâmetro desconhecido para determinação de um método como o ToA. Entretanto, ao realizar-se a combinação mencionada  $H = \binom{N}{2}$ , é comparada a diferença das distâncias do Nó a cada par de  $G_j \in D_{p_k}$ , com a seguinte equação:

$$\begin{aligned} r_{(G_i, G_j)}^{\text{TDOA}} &= d_{G_i}^{\text{TDOA}} - d_{G_j}^{\text{TDOA}} = c \left( \text{TOA}_{G_i}(p_k) - \text{TOA}_{G_j}(p_k) \right), \\ \forall G_i \in \mathcal{D}^{p_k}, \forall G_j \in \mathcal{D}^{p_k}. \end{aligned} \quad (18)$$

Esta equação demonstra que a diferença das distâncias estimadas  $r_{(G_i, G_j)}^{\text{TDOA}}$  do Nó a cada  $G_j$  do par pode ser determinada pela velocidade  $c$  multiplicada pela diferença do tempo de chegada do sinal de  $G_i$  e de  $G_j$ . Como o tempo de envio do pacote é o mesmo, o valor passa a ser anulado, e a equação reduz à diferença entre os tempos de recebimento em cada GW.

A distância real, como demonstrado em (10), apresenta um valor da diferença da posição do Nó a cada GW. Ao avaliar-se o processo de diferença entre GWs, como em (18), assume-se a seguinte equação:

$$\begin{aligned} h_{(G_i, G_j)}^{\text{TDOA}} &= d_i^{\text{TDOA}} - d_j^{\text{TDOA}} = \sqrt{(\hat{x} - x_{G_i})^2 + (\hat{y} - y_{G_i})^2} - \sqrt{(\hat{x} - x_{G_j})^2 + (\hat{y} - y_{G_j})^2}, \\ \forall G_i \in \mathcal{D}^{p_k}, \forall G_j \in \mathcal{D}^{p_k}. \end{aligned} \quad (19)$$

na qual a posição do TN  $(\hat{x}, \hat{y})$  e as posições dos *gateways*  $(x_{G_i}, y_{G_i})$  e  $(x_{G_j}, y_{G_j})$  utilizadas para determinar a diferença de distâncias. A fim de encontrar a função de erro da diferença de resultados das Equações (19) e (18), obtêm-se a seguinte equação

$$\xi(\mathcal{D}^{p_k}) : \sum_{\substack{G_i \in \mathcal{D}^{p_k} \\ G_j \in \mathcal{D}^{p_k}}} \left( r_{(G_i, G_j)}^{\text{TDOA}} - h_{(G_i, G_j)}^{\text{TDOA}} \right)^2, \quad (20)$$

Para determinar o valor de  $\hat{l}(p_k) = (\hat{x}, \hat{y})$ , sendo  $(\hat{x}, \hat{y})$  o valor que minimiza os

termos da Equação (20) , basta determinar o valor que satisfaça a equação proposta a seguir.

$$\underset{\hat{I}_{(p_k)} = (\hat{x}, \hat{y}) \in \mathcal{A}}{\operatorname{argmin}} \quad \xi(\mathcal{D}^{p_k}) \quad (21)$$

Para determinação deste valor, utilizou-se do método de Levenberg-Marquardt. Este processo consiste em fazer seguidas iterações a fim de a partir de uma posição inicial estimada, aproximar o valor de  $(\hat{x}, \hat{y})$  para encontrar o valor mínimo em (21):

$$(\hat{x}, \hat{y}) = (x_e, y_e) - (J^T J + \lambda I_2)^{-1} J^T f(x_e, y_e) \quad (22)$$

em que  $(x_e, y_e)$  a posição inicial estimada, calculada como a posição média entre as coordenadas dos  $G_j \in \mathcal{D}_{p_k}$ .  $J(x, y)$  a matriz Jacobiana da função  $f(x, y)$ , a qual é determinada por  $(r_{(G_i, G_j)}^{\text{TDOA}} - h_{(G_i, G_j)}^{\text{TDOA}})$  em (21). O valor de  $\lambda$  é o fator de amortecimento da equação, que multiplicado pela matriz identidade  $I$ , fará a aproximação da estimativa no valor de  $(\hat{x}, \hat{y})$ . Este valor é determinado através de um algoritmo, que visa a convergência da solução. O algoritmo é apresentado no Quadro 1 (MENSING; PLASS, 2006):

---

**Algoritmo 1: Levenberg-Marquardt**


---

**Entrada:**  $k := 0$ ;  $v^{(k)} := 2$ ;  $S^{(k)} := J(x_k)^T J(x_k)$ ;  $e^{(k)} := J(x_k)^T f(x_k)$ ;

$$\lambda^{(k)} := \tau \max\{[S^{(k)}]_{x_e, y_e}\}$$

**Saída:**  $(\hat{x}, \hat{y})$

**início**

**repita**

$$h^{(k)} = (S^{(k)} + \lambda^{(k)} I_2)^{-1} e^{(k)};$$

$$x^{(k+1)} = x^{(k)} + h^{(k)};$$

$$\rho^{(k)} = \frac{f(x^{(k)}) - f(x^{(k+1)})}{h^{(k)T} (\lambda^{(k)} h^{(k)} + e^{(k)})};$$

**se**  $\rho^{(k)} > 0$  **então**

$$S^{(k+1)} \leftarrow J(x_{k+1})^T J(x_{k+1});$$

$$e^{(k+1)} \leftarrow J(x_{k+1})^T f(x_{k+1});$$

$$\lambda^{(k+1)} \leftarrow \lambda^{(k)} \max\{\frac{1}{3}, 1 - (2\rho^{(k)} - 1)^3\};$$

$$v^{(k+1)} \leftarrow 2;$$

**senão**

$$S^{(k+1)} \leftarrow S^{(k)};$$

$$e^{(k+1)} \leftarrow e^{(k)};$$

$$\lambda^{(k+1)} \leftarrow \lambda^{(k)} v^{(k)};$$

$$v^{(k+1)} \leftarrow 2v^{(k)};$$

**fim**

$$k \leftarrow k + 1;$$

**até**  $\rho^{(k)} \simeq 0$ ;

**fim**

---

O valor de  $\tau$  representa o parâmetro de inicialização que irá determinar inicialmente o passo a ser dado na primeira iteração no algoritmo. O passo, identificado empiricamente, deverá se comportar conforme as características do sistema.

### 3.3.3 Weighted Centroid

O método *Weighted Centroid* (WC) é baseado na técnica de *Centroid*, um modelo de *Range-Free*, que consiste na localização do Nó é determinado pela própria localização dos GWs, em que não é necessário realizar as medições de distância entre cada GW e o Nó. O método do *Centroid* consistiria em realização das médias geométricas das coordenadas de todos os GWs que receberam a transmissão do sinal, representado por  $\hat{x} = \frac{\sum_{i=1}^N x_{G_i}}{N}$ , e o mesmo para  $\hat{y}$  ao substituir  $y_{G_i}$  por  $x_{G_i}$ . Esta solução poderia ser aplicada a LoRa,

porém ao não considerar nenhuma característica do sinal, como RSSI ou TOA, o  $G_j$  não será classificado pela qualidade do sinal recebido, o que torna o algoritmo mais suscetível as interferências e ruídos do sistema. Além disso, a rede LoRa tem longo alcance, e o pacote chega com possibilidade de decodificação a distantes *gateways*, o que afeta o método *Centroid*.

Já no caso do WC, utiliza-se a seguinte equação para o cálculo de  $\hat{x}$  (O cálculo para  $\hat{y}$  é a mesma equação, substituindo  $x_{G_j}$  por  $y_{G_j}$ ):

$$(\hat{x}) = \frac{\sum_{i=1}^N w_{G_i}(x_{G_i})}{\sum_{j=1}^N w_{G_j}} \quad (23)$$

em que a posição estimada  $(\hat{x}, \hat{y})$  é determinada por uma média ponderada da posição de cada GW  $(x_{G_i}, y_{G_i})$  do total de  $N$ , com um fator de peso  $w_i$  determinadas por (ORUJOV, 2016):

$$w_{G_i} = (\hat{d}_{G_i})^{-g}, \quad (24)$$

em que  $\hat{d}$  a distância estimada pelas equações (2) ou (3), e  $g$  um valor determinado empiricamente que determinará o grau de contribuição de cada  $G_j \in \mathcal{D}^{pk}$  para realização da estimativa. Interessante apontar que mesmo baseado numa técnica de *Range-Free*, no caso *Centroid*, o  $G_j$  é criterizado de acordo com a distância estimada por métodos RSSI para qualificar o  $G_j$ , e portanto, comporta-se como uma técnica *Range-Based*.

### 3.3.4 Local Outlier of Probability

O algoritmo de LoOP proposto verifica as intersecções entre circunferências proveniente do cálculo de distância de múltiplos *gateways*, como apresentado na Equação (10), e a partir de uma seleção dos pontos provenientes destas intersecções, estimar  $\hat{l}(p_k)$ . Para isso, um algoritmo de detecção de *Outliers* denominado *Local Outlier of Probability* é aplicado para realizar esta seleção de pontos, classificar e excluir as intersecções divergentes das demais, e torna mais preciso o cálculo do posição  $\hat{l}_{p_k}$ .

Para desenvolvimento do algoritmo, dois tópicos apresentarão as etapas para o cálculo deste algoritmo. Primeiramente, aponta-se como funciona a geração de pontos de intersecção ou posições de referência, e posteriormente, o processo de seleção de pontos de LoOP. Por final, a união dos dois tópicos será aplicada ao processo de localização.



### 3.3.4.1 Intersecção entre Circunferências

A posição relativa entre duas circunferências pode ser determinada como na Figura 3. Em cada caso, há 2 circunferências,  $C_{G_i}$  e  $C_{G_j}$ , e seus respectivos raios  $\hat{d}_{G_i}$  e  $\hat{d}_{G_j}$ , distantes entre si por  $D = \sqrt{(x_{G_i} - x_{G_j})^2 + (y_{G_i} - y_{G_j})^2}$ . No caso das circunferências concêntricas, as intersecções não serão determinadas, o que ocorreria se o mesmo GW apresentar leituras de sinais diversos para o mesmo  $p_k$ .

Já no caso das circunferências secantes, encontram-se dois pontos de intersecção (ALMUZAINI; GULLIVER, 2010). O valor de  $x_{(G_i, G_j)}$  é calculado a partir da seguinte equação. (para o cálculo de  $y_{(G_i, G_j)}$  substitui-se  $x_{G_j}$  e  $x_{G_i}$  por  $y_{G_j}$  e  $y_{G_i}$ , respectivamente, além de alterar a ordem do termo anterior a raiz quadrada de  $\pm$  por  $\mp$ ) :

$$\begin{aligned} x_{(G_i, G_j)} = & \frac{x_{G_i} + x_{G_j}}{2} + \frac{(x_{G_j} - x_{G_i})(\hat{d}_{G_i}^2 - \hat{d}_{G_j}^2)}{2D^2} \\ & \pm \frac{(y_{G_j} - y_{G_i})}{2} \sqrt{(\hat{d}_{G_i} + \hat{d}_{G_j})^2 - D^2}(D^2 - (\hat{d}_{G_i} - \hat{d}_{G_j})^2) \end{aligned} \quad (25)$$

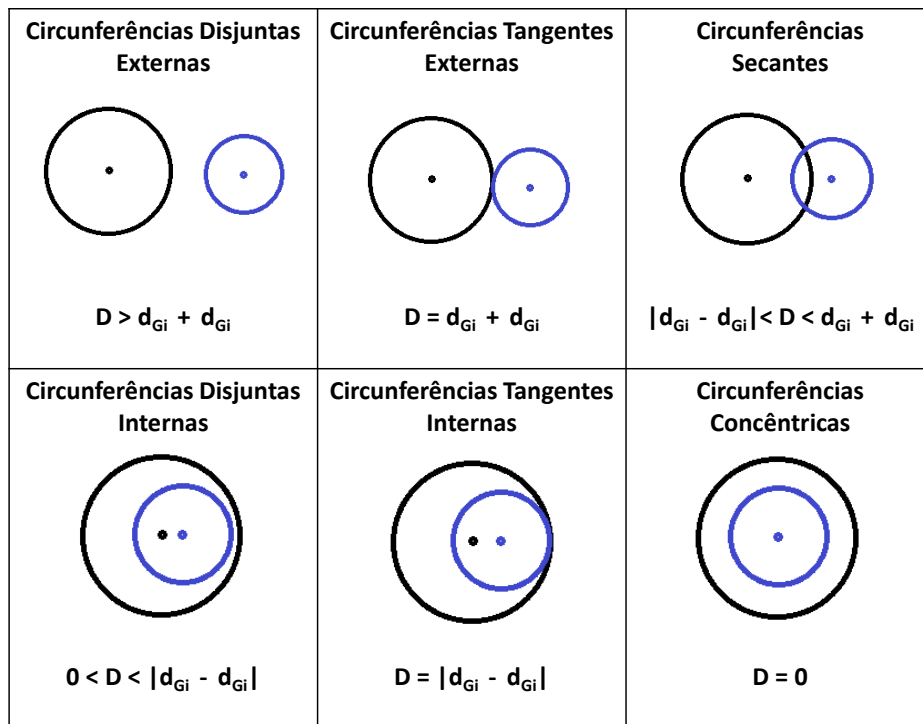
na qual  $p_{(G_i, G_j)} = (x_{(G_i, G_j)}, y_{(G_i, G_j)})$  representa as duas intersecções possíveis, e  $(x_{G_i}, y_{G_i})$  e  $(x_{G_j}, y_{G_j})$  os centros das circunferências  $C_{G_i}$  e  $C_{G_j}$ , respectivamente. Para o caso das circunferências tangentes, o fator dentro das raízes quadradas da equação (25) é anulado, e apenas um único valor possível de intersecção é gerado.

Já no caso das circunferências disjuntas, não ocorre nenhum ponto de intersecção. A fim de selecionar um ponto estipulado para este caso de relação, deduz-se para os seguintes casos:

- Circunferências Disjuntas Externas:  $D = \theta(\hat{d}_{G_i} + \hat{d}_{G_j})$ , em que  $\theta$  é um índice de proporcionalidade da distância  $D$  e  $\hat{d}_{G_i} + \hat{d}_{G_j}$ . Logo, a posição  $p_{(G_i, G_j)}$  avaliada neste caso é  $p_{(G_i, G_j)} = p_{G_i} \frac{\theta d_{G_i} (p_{G_j} - p_{G_i})}{D}$
- Circunferências Disjuntas Internas:  $d_{G_j} = \theta(d_{G_i} + D)$ , onde  $d_{G_j} > d_{G_i}$ . Logo, a posição  $p_{(G_i, G_j)}$  avaliada neste caso é  $p_{(G_i, G_j)} = p_{G_j} \frac{(D + \theta d_{G_i})(p_{G_i} - p_{G_j})}{D}$

Assim, para todos os modelos de posições relativas entre circunferências ocorrerá ao menos uma intersecção ou uma posição estimada.

Figura 3 – Posição Relativa entre duas circunferências.



Fonte: Autoria Própria

### 3.3.4.2 Método Local Outlier of Probability

O *Local Outlier of Probability* é um dos métodos de *Density-Outlier Based*, os quais consistem em, a partir de agrupamento de dados, identificar o grupo de elementos discrepantes dos mesmos, identificados como *Outliers*, e ao mesmo tempo identificar os *Inliers*, não destoantes do agrupamento inicial (KRIEGEL et al., 2009).

O processo de seleção de pontos inicia ao aplicar os critérios da Subseção 3.3.4.1 ao total de combinações  $H = \binom{N}{2}$  sendo  $N = |\mathcal{D}_{p_k}|$ , obtém-se o total de pontos de intersecção denominado  $\phi$ . Para cada ponto de intersecção  $Int_j = p_{(G_i, G_j)}$ , há a distância  $d_{Int_j, Int_k}$  para cada  $Int_k \in \phi$ . Quando a quantidade de  $|\phi|$  apresenta valor elevado, para evitar a necessidade de avaliar de todas as distâncias  $d_{Int_j, Int_k}$  presentes no sistema para classificar o ponto como *outlier* ou *inlier*, aplica-se o conceito de pontos vizinhos, em que os pontos  $s \in S$  dentro de um subconjunto  $S \subseteq \phi$  representam os pontos vizinhos de  $Int_j$ . Com os pontos vizinhos, limita-se a avaliação das distâncias de  $Int_j$  a cada  $s \in S$  para identificar o comportamento do ponto  $Int_j$  no conjunto total  $\phi$ .

Ao aplicar  $Int_j$  como centro de referência do conjunto  $S$ , a distância  $\sigma$ ,

denominada distância padrão entre este ponto e os demais presentes no grupo  $S$  pode ser determinado por:

$$\sigma(Int_j, S) = \sqrt{\frac{\sum(s \in S) d_{Int_j, s}^2}{|S|}} \quad (26)$$

Neste caso,  $\sigma$  representa uma distância padronizada das distância de  $Int_j$  aos demais pontos  $s$ . Porém, ao considerar-se uma circunferência de raio  $\sigma$  do ponto central  $Int_j$ , muitos pontos  $s$  seriam externos a mesma. Utiliza-se, então, de um fator  $\varphi$  que representa um multiplicador do raio  $\sigma$  para abranger os pontos  $s$ . O valor de  $\varphi$  ainda representa a probabilidade de encontrar um ponto  $s$  dentro desta circunferência. Por exemplo,  $\varphi = 1$ , representa que 68% dos pontos de  $S$  devem ser encontrados internos a circunferência. Já  $\varphi = 2$ , há 95% e  $\varphi = 3$ , 98% de probabilidade respectivamente. Observe-se neste caso que  $\varphi$  representa também a quantidade de desvios padrão em quem os pontos  $s$  se encontram distantes de  $Int_j$  em uma distribuição normal. Portanto, assume-se o valor de  $pdist(\varphi, Int_j, S_{(Int_j)}) = \varphi\sigma(Int_j, S)$ , em que quanto menor seu valor, menor possibilidade de ser um *Outlier*. Importante apontar que o valor de  $\varphi$  não altera a relação do ponto  $Int_j$  com todos os pontos de  $\phi$ , mas irá auxiliar na classificação dos pontos ao final do processo.

A partir deste momento, para calcular se um elemento é *outlier*, calcula-se  $pdist(\varphi, Int_j, S_{(Int_j)})$  do elemento  $Int_j$  com o  $pdist(\varphi, s, S_{(s)})$  dos seus pontos vizinhos  $s$ , através da equação:

$$PLOF_{\varphi, Int_j, S_{(Int_j)}} = \frac{pdist(\varphi, Int_j, S_{(Int_j)})}{E_{s \in S}[pdist(\varphi, s, S_{(s)})]} - 1 \quad (27)$$

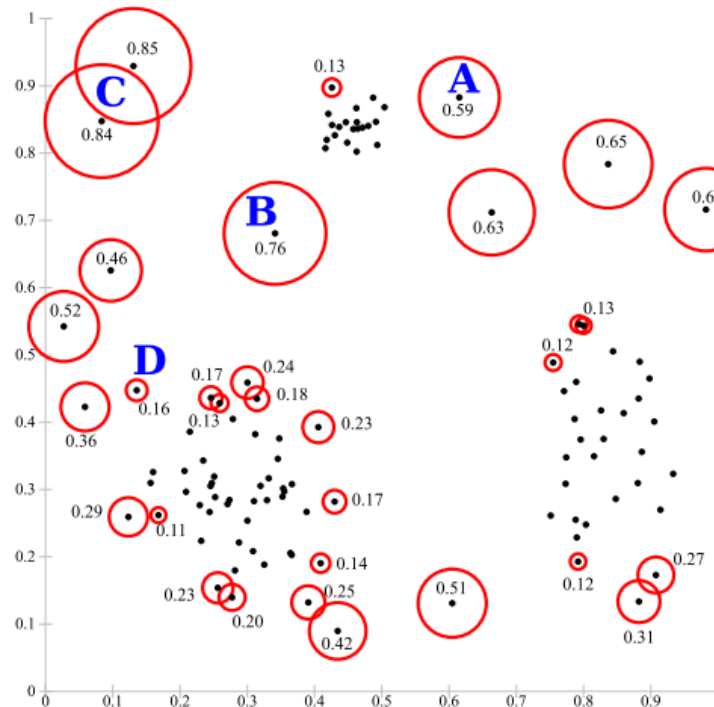
Em que  $E_{s \in S}[pdist(\varphi, s, S_{(s)})]$  representa o valor esperado da  $pdist(\varphi, s, S_{(s)})$  dos pontos  $s$ , calculado com a média dos mesmos. Para normalização de todos os pontos de  $\phi$ , aplica-se o termo NPLOF, determinado por:

$$NPLOF = \varphi \sqrt{E|(PLOF)_{\varphi, Int_j, S_{(Int_j)}}^2|}, \quad \forall Int_j \in \phi \quad (28)$$

Com a normalização, o fator de classificação LoOP é determinado por:

$$LoOP_{\varphi, Int_j, S_{(Int_j)}} = \max \left\{ 0, \operatorname{erf} \left( \frac{PLOF_{\varphi, Int_j, S_{(Int_j)}}}{NPLOF \sqrt{2}} \right) \right\} \quad (29)$$

Figura 4 – Exemplo de Local Outlier of Probability, utilizando de um  $k = 20$  e  $\psi = 3$ , em que quanto mais próximo o valor de 1, maior propabilidade de ser um *Outlier*



Fonte: Adaptado de (KRIEGEL et al., 2009)

O valor de  $LoOP_{\varphi, Int_j, S(Int_j)}$  irá variar de  $[0,1]$ , e quanto mais próximo ao valor de 1, maior probabilidade de ser considerado um *Outlier*. Um exemplo pode ser observado na Figura 4:

### 3.3.4.3 LoOP para Localização

Para a estimativa da posição com o algoritmo LoOP, considera-se novamente posicionamento de Nós em que  $\mathcal{D}_{p_k} \geq 3$ . Ao realizar-se a combinação  $H = \binom{N}{2}$ , haverá a cada iteração a identificação de duas circunferências, calculadas por (3) e (2) e aplicada a fórmula de (10). Ao identificar-se as duas circunferências, verifica-se os pontos de intersecção. O número total de intersecções  $\phi$  será  $N \leq \phi \leq 2|H|$ , o qual permitirão a localização do mesmo item.

Ao identificar os pontos de intersecção, passa-se a aplicar o método LoOP, em que os pontos  $\phi$  serão o grupo de pontos a serem analisados. Para determinar o número de pontos vizinhos, utiliza-se o valor de  $k = N - 1$ . Ao final, identifica-se os valores de pontos *outliers*, os quais serão descartados para o cálculo de posicionamento (ALMUZAINI;

GULLIVER, 2010).

Os pontos não descartados, os quais apresentam convergência em seus posicionamentos, passarão por um processo semelhante ao de 3.3.3, em que cada ponto de intersecção receberá como peso  $w_{Int_j} = (\hat{d}_{G_i} + \hat{d}_{G_j})^{-g}$ , em que  $d_{G_i}$  e  $d_{G_j}$  são os raios das circunferências que geraram a intersecção  $Int_j$ . O valor de contribuição  $g$  será validado empiricamente.

### 3.4 FILTRO DE KALMAN

O Filtro de Kalman (FK) é um modelo de filtragem estocástica muito utilizado para predição de posições, em que a cada iteração do filtro no tempo, o erro através das características do sistema é reduzido (CHEN, 2012).

No modelo de um sistema em que um objeto varia suas características de acordo com o tempo, há a presença de um vetor de estado  $x_k \in \mathbb{R}^{p \times 1}$ . O Filtro de Kalman passa a ser aplicado em duas fases do processo. A primeira consiste em uma predição no tempo da posição do objeto. A seguinte, na atualização das equações de correção conforme as características do sistema.

O sistema pode ser determinado como:

$$z_k = Ux_k + \mathcal{N}(0, R) \quad (30)$$

em que  $z_k \in \mathbb{R}^{j \times 1}$  é um vetor de variáveis observáveis de  $j$  elementos,  $x_k$  o vetor de variáveis de estado, e  $U$  a matriz que correlaciona os mesmos. Devido o sistema apresentar erro nas variáveis observáveis, avalia-se o ruído  $\mathcal{N}(0, R)$ , com média zero e variância  $R = rI_j \in \mathbb{R}^{j \times j}$ . O valor de  $r$  considera o valor do erro no sistema, enquanto  $I_j$  uma matriz identidade  $j \times j$ .

#### 3.4.1 Atualização na Predição

A partir de uma estimativa inicial, passa-se a predizer o valor da posição  $\hat{x}_{k+1}$ , atualizando tanto a estimativa de posição, quanto a matriz de variância  $\mathcal{P}$ , com as seguintes equações:

$$\hat{x}_{k|k-1} = A\hat{x}_{k-1|k-1} \quad (31a)$$

$$P_{k|k-1} = AP_{k-1|k-1}A^T + \mathcal{N}(0, Q) \quad (31b)$$

em que a posição estimada  $\hat{x}_{k|k-1} \in \mathbb{R}$  é a estimativa de posição no momento  $k$  realizada no momento  $k-1$ ,  $A$  é a matriz de transição de estado,  $P_{k|k-1}$  a matriz de covariância de erro estimada ao tempo  $k$  baseado nos dados no momento  $k-1$ . O erro da covariância representado por  $Q = qI_j \in \mathbb{R}^{j \times j}$ , com  $q \in \mathbb{R}$

### 3.4.2 Correção na medição

No processo de atualização, compara-se o valor medido em (30) com os valores estimados em (31):

$$G_k = P_{k|k-1}U^T(UP_{k|k-1}U^T + R)^{-1} \quad (32a)$$

$$\hat{x}_{k|k} = \hat{x}_{k|k-1} + G_k(z_k - U\hat{x}_{k|k-1}) \quad (32b)$$

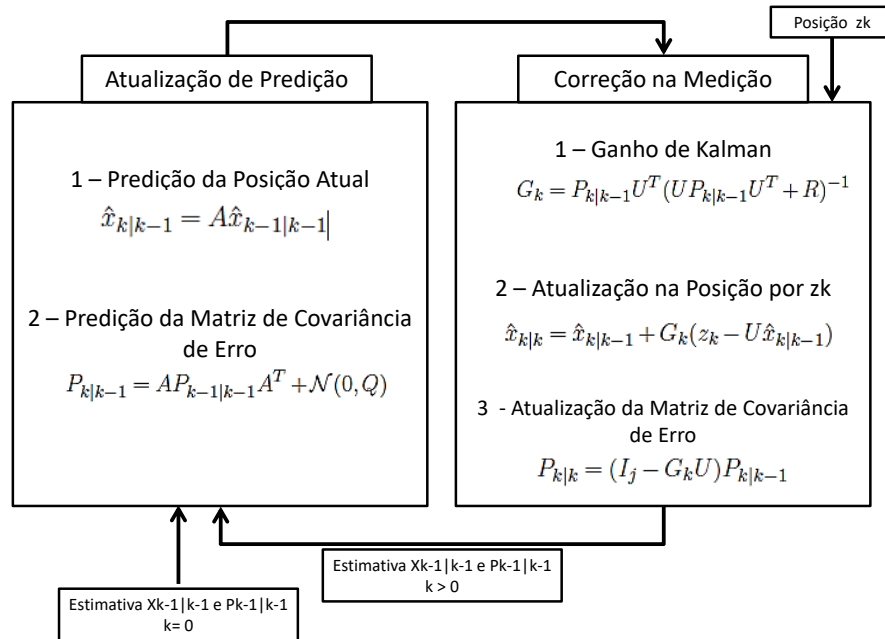
$$P_{k|k} = (I_j - G_kU)P_{k|k-1} \quad (32c)$$

no qual  $G_k$  é o chamado Ganho de Kalman, o qual atualizará o sistema de equações para aprimorar o sistema de predição e medição,  $\hat{x}_{k|k}$  é o valor da posição determinada no momento  $k$  após a verificação das variáveis aleatórias  $z_k$ , e  $P_{k|k}$  a atualização da matriz de covariância de acordo com os dados providos pelo sistema em (30). O processo do Filtro de Kalman pode ser observado na Figura 5.

## 3.5 LORA

LoRa é uma técnica de modulação na camada física desenvolvida pela empresa Semtech Corporation, e nomeada devido as características de longo alcance (*Long Range*), com um alcance usual de até 15 km (BISSETT, 2018). Além disso, apresenta um consumo de energia consideravelmente baixo, com equipamentos alimentados por bateria com duração de mais de 10 anos. (LAM et al., 2018)

Figura 5 – Processo de Filtro de Kalman.



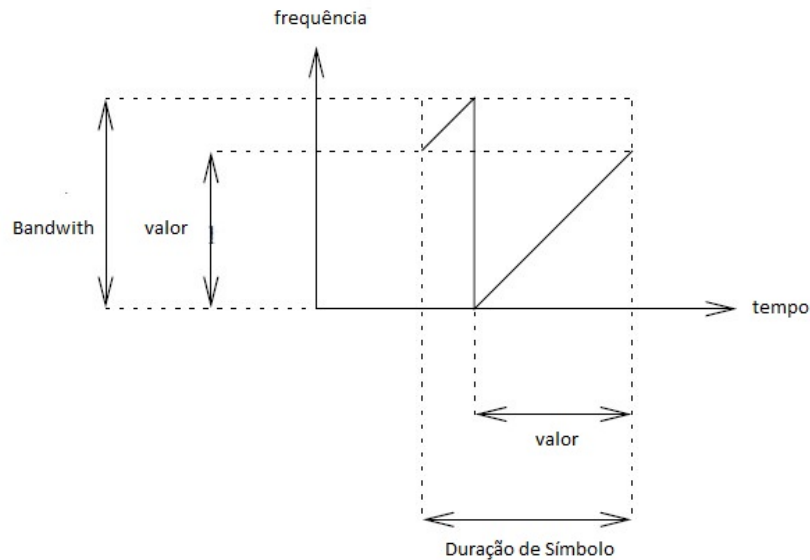
Fonte: Adaptado de (BELMONTE-HERNÁNDEZ et al., 2017)

A modulação LoRa trabalha com um conceito de *Chirp Spread Spectrum* (CSS), o que torna a comunicação menos suscetível a ruídos e interferências. Isso ocorre devido a variação de frequência do sinal de acordo com o tempo, em que o envio de símbolo denominado *chirp* altera entre *up-chirps* e *down-chirps*. Um símbolo de *up-chirp* pode ser observado na Figura 6, em que o sinal varia de acordo com o tempo e frequência limitados pela largura de banda (BW) e a duração do símbolo. Esta variação de tempo e frequência determinadas tornam o sinal emitido em LoRa menos suscetível a efeito Doppler, e interferências multipercurso (RACHKIDY et al., 2019).

Um importante aspecto do sinal LoRa é o chamado SF, que consiste na quantidade de bits presentes a cada transmissão de símbolos. Portanto, a possibilidade de símbolos transmitidos será  $2^{\text{SF}}$  *chirps*/símbolo. O valor do SF varia entre 7 a 12, e deve ser selecionado de acordo com a necessidade do sistema. Quanto maior o SF do sinal, ele apresentará maior robustez, o que facilita sua decodificação e alcance e chegar até 30 km em ambientes abertos com a utilização de SF = 12.

Porém, ao gerar um tempo de transmissão maior, a taxa de dados é menor, o que acarreta em maior interferência em equipamentos operando na mesma faixa de frequência e ocupação no tráfego da rede. Além disso, o transmissor com maior SF há de ter um período mais longo de rádio ligado ao enviar o pacote, o que aumenta o consumo de

**Figura 6 – Exemplo de up-chirp de um sinal LoRa no tempo em função de frequência.**



**Fonte:** Adaptado de (RACHKIDY et al., 2019)

bateria comparado aos de menor SF. Portanto, para otimizar a utilização de bateria, os dispositivos LoRa tem a funcionalidade de ADR, através da qual optará-se em transmitir sempre que possível na menor potência e menor SF, e passa a aumentar inicialmente a potência de transmissão do pacote, e caso ainda sem sucesso de entrega, com a potência máxima de envio, aumentará o SF do sinal. Este comportamento ocorre para que o pacote enviado chegue a ao menos a um GW com a possibilidade de ser decodificado e com menor consumo de energia possível no Nó (BISSETT, 2018).

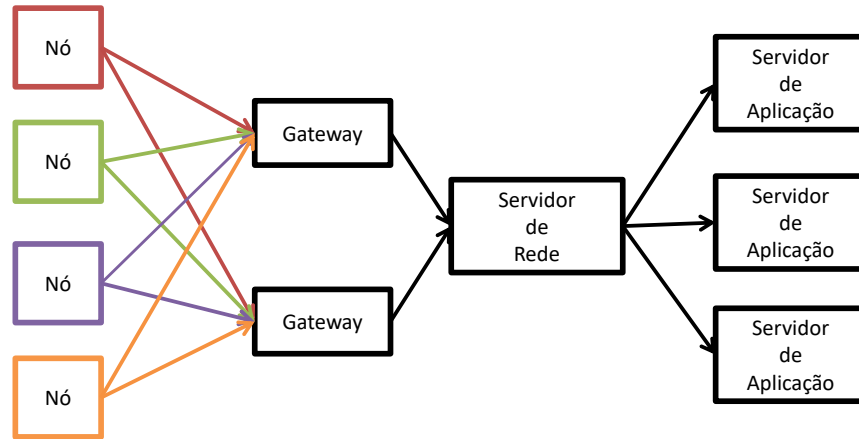
### 3.5.1 LoRaWAN

LoRaWAN é uma especificação de envio implementado pela LoRa Alliance a fim de definir os protocolos de comunicação e arquitetura de rede aplicada com LoRa. Ela utiliza da topologia em formato estrela, conforme observado da Figura 7, em que os Nós transmitem em *broadcast* através do protocolo LoRa para múltiplos Gateways, os quais incluirão informações relevantes para localização, como o tempo de recepção do sinal, RSSI e a SNR. Após a adição destes dados, o Gateway transmitirá via internet aos servidores de rede, que posteriormente transmitirá ao servidores de aplicação para utilização do usuário final. (LORA ALLIANCE., 2015)

Caso haja a necessidade de envio de pacote ao Nó, o Gateway deverá apresentar uma sincronia com o Nó para envio da mensagem. Isso se deve por grande parte dos



**Figura 7 – Topologia de Rede LoRaWAN.**



**Fonte: Autoria Própria**

dispositivos LoRaWAN apresentarem uma característica de envio em que a janela de recepção abre momentaneamente após a transmissão. Este equipamentos são classificados no tipo A da LoRaWAN. Os demais tipo B e C apresentam maiores janelas de recepção, porém a eficiência no consumo de energia se torna menor. A utilização do tipo A torna a bateria mais eficiente, mas dificulta a localização devido a dificuldade de solicitar nova posição pela pequena janela de tempo aberta para recepção, o que corresponde a menos de 1% do tempo do *Duty Cycle*. (BISSETT, 2018)

LoRaWAN ainda atende normais legais de operação em diferentes localidades. Por exemplo, para transmissão, o dispositivo deverá operar na faixa de 867 - 899 MHz, com largura de banda de 125 - 250 KHz na União Europeia, e potência de transmissão de até +14 dBm. Já no caso da América do Norte, a faixa de frequência é de 902 - 928 MHz, com uma largura de banda de 125 - 500 KHz, e potência de transmissão máxima de +20dBm. (LORA ALLIANCE., 2015). No caso do Brasil, o mesmo opera em 3 faixas de frequência, de 433 a 435 MHz, com as mesmas características da Europa, e 902 a 907.5 MHz e 915 a 928 MHz, em conformidade com o padrão Australiano, com potência de transmissão isotrópica de até +30 dBm. (LORA ALLIANCE, 2018b)

## 4 DADOS E RESULTADOS

### 4.1 DADOS

O estudo dos algoritmos apresentados será baseado nos dados providos no estudo (AERNOUTS et al., 2019) , realizado entre Novembro de 2018 e Fevereiro de 2019 na cidade de Antuérpia, Bélgica e apresentado na Figura 8, onde o dispositivo IM880B-L na Figura 9 foi instalado em 23 veículos do serviço postal. Os equipamentos registraram 130.430 pacotes e os dados de recepção suficientes para aplicação dos algoritmos, como RSSI, SNR, tempo de chegada dos pacotes, além de dados provenientes dos GWs, como latitude e longitude.

Para utilização dos dados, entretanto, se faz necessário realizar alguns filtros do total de pacotes de dados apresentados abaixo:

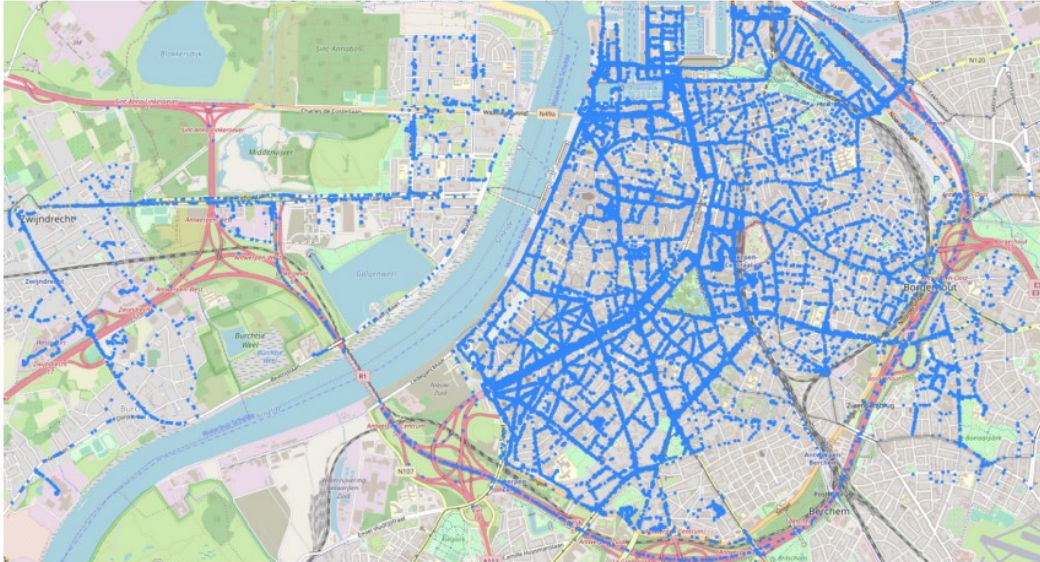
- O pacote deverá ter alcançado  $|D_{p_k}| \geq 3$ .
- Do grupo filtrado no primeiro item,  $|D_{p_k}| \geq 3$  deverão apresentar coordenadas válidas e não nulas.
- A posição estimada do Nó deverá apresentar, independente do método utilizado, um valor inferior a 50 km dos GWs validados pelos 2 primeiros filtros. Caso contrário, o pacote será descartado.

Após a realização do primeiro filtro, o total de 130.430 pacotes é reduzido a 55.376 pacotes. Com os demais filtros, mesmo com a alteração dos parâmetros dos métodos com RSSI, o valor fica em torno de 55 mil pacotes, o que representa 99,3% dos pacotes após o primeiro filtro.

### 4.2 RESULTADOS

Aos aplicar-se os métodos propostos, parâmetros para cálculo dos métodos de perda de percurso (2) (3) são previamente determinados, como por exemplo frequência, altura da antena. Este valores podem ser encontrados na Tabela 3. Os valores usaram como base o estudo (JANSSEN et al., 2020), e a potência de transmissão determinada como o máximo valor de transmissão habilitado no ambiente europeu (LORA ALLIANCE., 2015). Os demais parâmetros empíricos, como o grau de contribuição

Figura 8 – Área de Estudo realizado na cidade de Antuérpia, Bélgica.



Fonte: Adaptado de (JANSSEN et al., 2020)

Figura 9 – Dispositivo IM880B-L com comunicação LoRA e GPS para localização.



Fonte: Adaptado de (WIMOD, 2020)

**Tabela 3 – Parâmetros dos métodos de perda de percurso**

Parâmetro	Variável	Algoritmos	Valor
Frequência	$f$	WC/LoOP/LSE	868 MHz
Potência de Transmissão	$Pt$	WC/LoOP/LSE	+14 dBm
Altura da Torre	$h_B$	WC/LoOP/LSE	30 m
Altura do dispositivo	$h_m$	WC/LoOP/LSE	1,5 m
Velocidade da Luz	$c$	TDoA	$3 * 10^8 m/s$
Parâmetro de Inicialização de Levenberg-Marquasdt	$\tau$	TDoA	$10^6$
Grau de ruído no tempo	$r$	Kalman	40
Grau de ruído na covariância	$q$	Kalman	10

Fonte: Autoria própria.

**Tabela 4 – Erro médio em metros dos métodos 3.3.3 e 3.3.4 de acordo com o grau de contribuição**

Grau de Contribuição	1	2	3	4
WC	651,06	<b>629,81</b>	660,69	700,28
LOOP	705,83	680,85	<b>675,37</b>	684,11
WC_KF	570,54	<b>564,03</b>	586,69	612,37
LOOP_KF	595,84	581,07	<b>578,74</b>	585,82

Fonte: Autoria Própria.

presente nas equações de (24) e o coeficiente de perda presente em (2) serão avaliados nas seguintes subsecções a fim de identificar como o valor de cada um afeta na precisão dos algoritmos propostos.

Nas seguintes subsecções, além de determinar os valores de grau de contribuição e coeficiente de perda, serão avaliados também parâmetros do sistema como quantidades de  $G_j \in \mathcal{D}_{pk}$  e *Spreading Factor* influenciam na precisão dos algoritmos.

#### 4.2.1 Grau de Contribuição

O Grau de Contribuição é um valor empírico que demonstrará como o peso determinado em cada ponto de referência, como a distância estimada no algoritmo WC e a média de distâncias dos  $G_j$  e  $G_i$  no LoOP, influenciam na estimativa da posição. Para determinar o valor do grau de contribuição, utilizou-se o modelo de Okumura-Hata apresentado na Seção 3.2.2, aplicado em uma cidade grande, e valores empíricos para sua determinação, apresentados na Tabela 4.

Conforme Tabela 4, o Grau de contribuição para os diferentes modelos propostos é variado, e o método WC apresentou melhor resultado quando aplicado com o valor de 2, e o método LOP com valor 3. O mesmo se observa caso aplicado o filtro de Kalman.

**Tabela 5 – Erro médio em metros dos métodos 3.3.3, 3.3.1 e 3.3.4 de acordo com o coeficiente de perda aplicado no modelo de cálculo de distância 3.2.1**

Coefficiente de Perda	2,61	2,93	3,26	3,58	3,91	4,24
Pacotes Filtrados	29449	53228	55009	55051	55057	55058
WC	807,99	648,01	633,05	629,62	<b>627,87</b>	627,89
LOOP	2481	941,27	656,41	629	<b>628,4</b>	637,43
MLT	2166,51	8341,07	2357,38	<b>2166,29</b>	2371,45	2444,09
WC_KF	717,16	579,97	566,86	563,74	561,74	<b>560,94</b>
LOOP_KF	1851,88	766,60	569	<b>553,72</b>	555,82	563,68
MLT_KF	13879,15	6107,49	1824,94	<b>1649,05</b>	1800,70	1853,08

**Fonte: Autoria Própria.**

Estes valores de grau de contribuição serão os mesmos aplicados ao validar o coeficiente de perda e a comparação de resultados nas seguintes subseções.

#### 4.2.2 Coeficiente de Perda

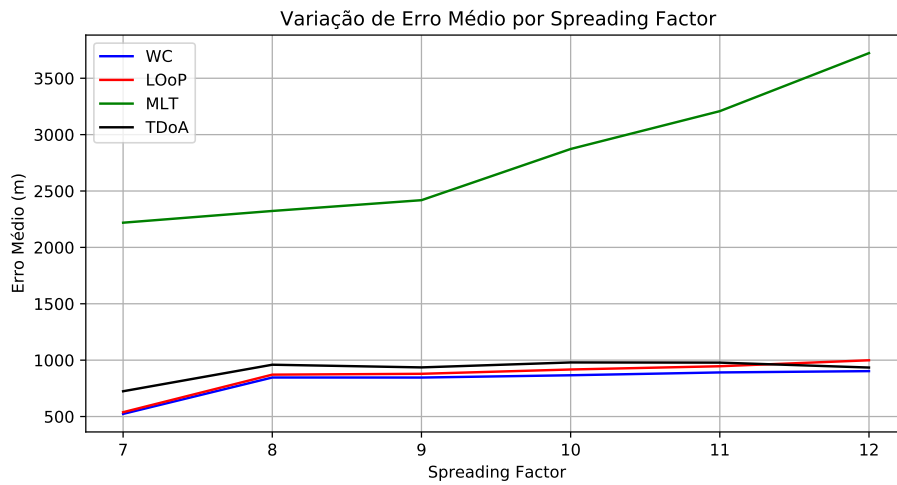
O coeficiente de perda  $\chi$  apresentado na Subseção 3.2.1 para aplicação do método Log-Normal é o valor que identifica o quanto o ambiente em que o pacote  $p_k$  interfere no envio do mesmo, e quanto maior o valor, maior a atenuação do sistema. Este valor pode ser determinado por todas as relações entre um TN e cada  $G_j$ , desde que conhecida a posição de ambos. Por exemplo, dos mais de 130 mil pacotes gerados no estudo, há mais de 300 mil recepções, visto que um mesmo pacote  $p_k$  poderá alcançar mais de um *Gateway* de destino. A partir de cada interação entre o pacote  $p_k$  e cada  $G_j$ , o valor de  $\eta$  que melhor correlaciona os dois é de 3,26. Além disso, o ruído  $\chi$  apresenta um valor de desvio padrão de 10,65 dB.

Entretanto, a fim de verificar como a escolha do coeficiente pode afetar a solução, foram selecionados valores de -20% a +30% do valor estimado, conforme apresentado na Tabela 5.

Nota-se na Tabela 5 que a escolha do coeficiente de perda apresenta uma contribuição mais significativa para os casos de Multilateração e LoOP, com a redução da estimativa de erro em 90% no caso da Multilateração, quando modificado o coeficiente de perda de 2,61 até 3,58. No caso do LoOP, a redução é de 75% entre o coeficiente de 2,61 e 3,91.

Já no caso do WC, mesmo com a redução inicial de 20% entre os coeficientes 2,91 e 2,93, o erro médio estabiliza mesmo com o aumento do coeficiente de perda a partir de 3,26, com reduções de menos de 1% a cada aumento do coeficiente. Logo, o valor

**Figura 10 – Erro médio em metros relacionado ao Spreading Factor do Pacote.**



**Fonte: Autoria Própria**

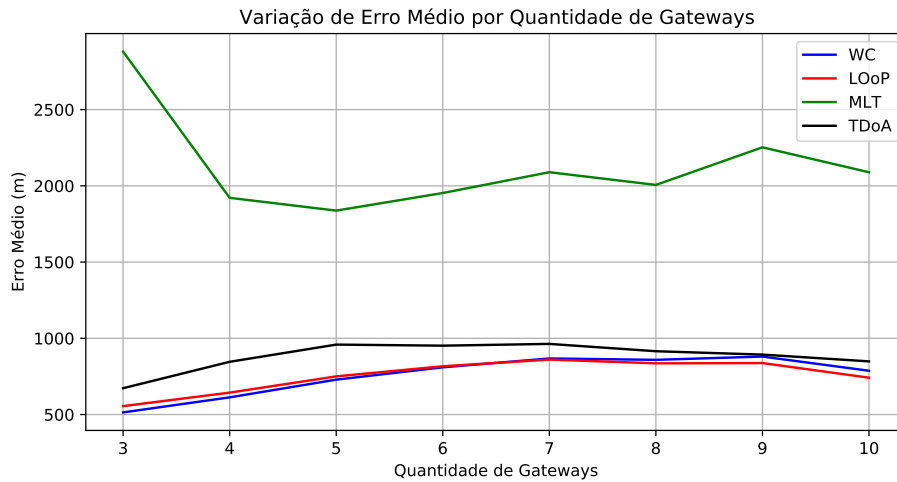
de coeficiente, para este algoritmo, apresenta uma maior robustez em relação a erros no coeficiente de perda. Ainda que o processo de avaliação de coeficiente de perda possa ser considerado o treinamento, a aplicação do algoritmo WC atende as estimativas da literatura, como na Tabela 2, sem necessidade de um treinamento prévio.

#### 4.2.3 Spreading Factor

O valor do *Spreading Factor*, conforme apontado na Seção 3.5, indica como o pacote  $p_k$  será enviado quanto a quantidade de *chirps* por símbolo. Com a utilização do ADR, o envio do mesmo deverá priorizar o envio com menor potência e menor SF. As características apresentadas ao usar o ADR limitam o alcance do sinal, mas permitem maior taxa de envio. O objetivo do ensaio é verificar como a alteração de SF influencia na precisão dos métodos propostos. Como referência, foram utilizados os dados providos pelo coeficiente de perda 3,26, obtido na Subseção 4.2.2, além do valor do método de TDoA nos mesmos pacotes.

Pode-se observar na Figura 10 que o erro médio relacionado ao SF apresenta uma constância na estimativa da distância para todos os métodos menos o MLT, em que o mesmo aumenta conforme o aumento do SF. O fato ocorre pois o ADR, como apresentado na Seção 3.5, ao alcançar a potência máxima, aumentará o SF gradativamente e assim aumentar o alcance do sinal, pois aumenta o ganho do processamento e aumenta a sensibilidade da antena de recepção. Assim, quando o sinal percorre maiores distâncias o MLT, que não possui critério de peso para classificar seus GWs, sofre maior interferência

**Figura 11 – Erro médio em metros relacionado à Quantidade de GWs alcançados do Pacote.**



**Fonte: Autoria Própria**

do sistema e, conseqüentemente, apresenta um maior erro médio. Já no caso do WC e LoOP, ao utilizar-se dos pesos dos GWs e pontos de intersecção baseado nas distâncias, o critério de classificação dos GWs e pontos são mantidos mesmo com o aumento delas, e assim, o aumento de SF não gera maiores impactos. A diferença de erro entre SF7 e SF8 de WC, LoOP e até TDoA, mesmo este não trabalhe com o RSSI, é que a potência inferior aplicada ainda no SF7 torna a área de estudo menor, e logo, erros de distância menores.

#### 4.2.4 Quantidade de Gateways

Para aplicar-se os algoritmos propostos, o pacote enviado pelo Nó deverá alcançar ao mínimo  $|\mathcal{D}_{p_k}| \geq 3$ , e com limite do estudo até 10. A fim de analisar a influência na quantidade de GWs de recepção, utilizar-se a mesma base de dados utilizados em 4.2.3.

Na Figura 11, o método de *Weighted Centroid* apresenta ser o método com melhor desempenho com menor quantidade de GWs utilizados. Entretanto, pode-se notar que a partir do valor de 6 GWs, o métodos de LoOP passa a assumir valores com menor erro comparado aos demais métodos. Isso ocorre devido a maior quantidade de combinações entre GWs permite que o algoritmo LoOP elimine pontos divergentes afetados pelo sombreamento. Já no caso de  $|\mathcal{D}_{p_k}| \leq 6$ , o LoOP apresenta com poucas combinações, de forma que a classificação dos pontos torna-se mais complexa, e a seleção de dados com menor precisão entre *Outliers* e *Inliers*. Importante apontar que 84,47% dos pacotes

**Tabela 6 – Variação de erro de medição no Filtro de Kalman**

$r$	10	20	30	40	50	60	70
WC_KF	577,95	569,7	567,3	<b>566,86</b>	567,26	568,05	569,05
LOOP_KF	587,15	575,14	570,75	569	<b>568,43</b>	568,47	568,87
MLT_KF	1991,21	1903,35	1856,11	1824,94	1802,18	1784,15	<b>1770,21</b>
TDoA_KF	691,53	669,93	660,31	655,03	651,86	649,88	<b>648,62</b>

**Fonte: Autoria Própria.**

(46470) selecionados a partir dos filtros da Seção 4.1 possuem  $|\mathcal{D}_{p_k}| \leq 6$ , o que tornaria ainda sim a solução WC a com melhor resultado médio quanto a quantidade total de pacotes.

#### 4.2.5 Variação do Ruído de Medição

A fim de aplicar o filtro de Kalman, há necessidade de identificar duas condições de variação presentes no ambiente das medições e na atualização de estados. Para simular o valor, aplicará-se processo semelhante ao estudo (EYNG et al., 2020), com  $q = 10$  e variando de  $r$ .

Pode-se observar na Tabela 6 que os métodos que apresentam maior erro médio, como o de MLT e TDoA apresentam maior variância nas suas medições e, com o aumento de  $r$ , passam a ter melhor previsibilidade no cálculo de erro. Já no caso dos algoritmos de MLT e LoOP, a variação é menor, e a estabilidade alcançada quando  $r$  apresenta valores entre 40 e 50 respectivamente. Estes métodos novamente apresentam maior estabilidade de previsões entre as medições e são menos suscetíveis a interferências do sistema.

#### 4.2.6 Resultados comparado com Referências

Conforme apresentado no Capítulo 2 de Trabalhos Relacionados a base de dados aplicados neste estudo foi aplicada em artigos como (JANSSEN et al., 2020), (AERNOUTS et al., 2019), (LI et al., 2021), (NGUYEN, 2019), com métodos diferentes, como *Fingerprinting* principalmente, além de Min-Max com RSSI. Além disso, para contemplar estudos de longo alcance, foi incluído na tabela comparativa o estudo (NGUYEN, 2019) aplicado na rede LoRaWAN presente na Holanda. A comparação está detalhada na Tabela 7.

Na Figura 12, observa-se a distribuição acumulativa de erro da área total de 52,79  $km^2$ . No caso, tanto na Tabela 7 quanto na Figura 12, o método de MLT apresenta um



**Tabela 7 – Comparação de erro médio com estudos propostos (em negrito) comparado com os trabalhos relacionados. O sufixo KF indica a utilização do Filtro de Kalman.**

Algoritmo	Método	Erro Médio (m)	Mediana (m)	90 <sup>th</sup> Percentil (m)	Desvio Padrão (m)	Erro de área
Fingerprinting_Comparação	FP + Random Forest	340	-	-	-	0,69%
Fingerprinting_YanLi	FP + Machine Learning	346,03	158,41	-	-	0,71%
ANN_Antwerp	FP + Redes Neurais	480,2	341,8	1048	-	1,37%
KNN_Antwerp	FP + KNN	507,0	366,0	1118	-	1,53 %
<b>WC_KF Proposto</b>	<b>RSSI WC + FK</b>	<b>566,86</b>	<b>399,04</b>	<b>1216,80</b>	<b>596,60</b>	<b>1,91 %</b>
<b>LoOP_KF Proposto</b>	<b>RSSI LoOP + FK</b>	<b>569</b>	<b>424,38</b>	<b>1200,59</b>	<b>562,44</b>	<b>1,93 %</b>
<b>WC Proposto</b>	<b>RSSI WC</b>	<b>633,05</b>	<b>434,10</b>	<b>1372,52</b>	<b>777,58</b>	<b>2,38 %</b>
<b>TDoA_KF + Proposto</b>	<b>TDoA + FK</b>	<b>655,03</b>	<b>527,46</b>	<b>1242,93</b>	<b>553,68</b>	<b>2,55 %</b>
<b>LoOP Proposto</b>	<b>RSSI LoOP</b>	<b>656,41</b>	<b>477,95</b>	<b>1393,25</b>	<b>726,72</b>	<b>2,56 %</b>
MinMax_Comparação	RSSI	700	-	-	-	2,91 %
<b>TDoA Proposto</b>	<b>TDoA</b>	<b>800,62</b>	<b>625,64</b>	<b>1540,29</b>	<b>759,17</b>	<b>3,81 %</b>
<b>MLT_KF Proposto</b>	<b>RSSI MLT + FK</b>	<b>1824,94</b>	<b>1279,11</b>	<b>3504,38</b>	<b>2112,99</b>	<b>19,82 %</b>
<b>MLT Proposto</b>	<b>RSSI MLT</b>	<b>2357,34</b>	<b>1535,8</b>	<b>4324,92</b>	<b>3372,16</b>	<b>33,07 %</b>
TDoA_Bisset	TDoA	1667,4	500,4	1961	-	-
TDoA_KPN	TDoA	6008,4	174,2	23389	-	-

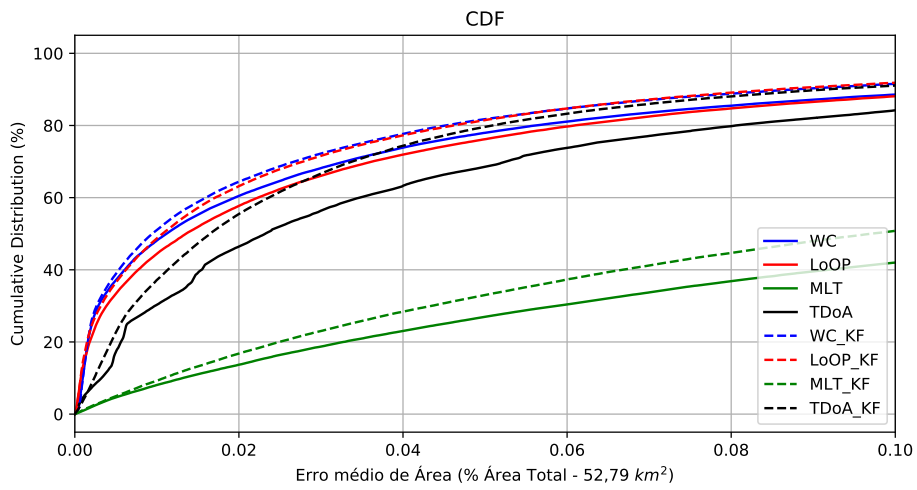
**Fonte: Autoria Própria.**

erro médio de 2,36 km e uma mediana de 1,54 km, muito superior ao demais métodos apresentados, mesmo com aplicação dos filtros de dados. O MLT apresenta esta variação devido ao fato deste algoritmo não classificar os GWs do sistema de acordo com o sinal, como no caso do uso do grau de contribuição nos algoritmos LoOP e WC, além do tempo de chegada em TDoA, e no ambiente aberto, a interferência de sinal pelo sombreamento de um  $G_j \in \mathcal{D}_{p_K}$ . Portanto, apresenta-se como uma solução não recomendada para esta aplicação. Quanto aos demais, o algoritmo de TDoA proposto apresenta uma melhor média se comparado aos estudos apresentados no (NGUYEN, 2019), porém, mesmo com a aplicação de Filtro de Kalman, o método de WC supera este método.

Na Tabela 7, comparado aos métodos de Fingerprinting, os mesmos apresentam melhores resultados médios, porém, como mencionado no estudo (JANSSEN et al., 2020), há a necessidade de uma fase de treinamento de cerca de 60 a 70% da base de dados, além de uma fase de avaliação, o que acarreta na validação com pacotes em torno de 10 a 15%. Além disso, o estudo ainda demonstra que FP, mesmo com pacotes de apenas um GW receptor, é limitado a área de estudo, o que dificulta a movimentação imediata a outro ambiente sem prévio treinamento.

Comparado ao estudo de Min-Max, também apresentado no estudo (JANSSEN et al., 2020) e na Tabela 7, os métodos de LoOP e WC, que também utilizam de RSSI, apresentam melhores resultados mesmo sem filtro de Kalman, com redução de 6,3% com o algoritmo LoOP, e cerca de 9,6% com WC. Mesmo comparado com métodos de TDoA, tanto dos apresentados no trabalho quanto os comparados em (BISSETT, 2018), os algoritmos LoOP e WC apresentam uma solução com melhor média, e grande parte mediana, e resultado pior apenas que o método proprietário da KPN.

Figura 12 – CDF de erro dos métodos propostos de em comparação com área total de  $52,79 \text{ km}^2$



Fonte: Autoria Própria

## 5 CONCLUSÃO E TRABALHOS FUTUROS

A técnica de comunicação LoRa, devido a suas características de baixo consumo e longo alcance, apresenta-se como uma solução viável e em expansão para ser aplicada em uso de soluções de rastreamento, logística, recuperação de cargas compatíveis ao condeito de IoT.

Como apresentado neste trabalhado, e verificado nos demais apresentados como referência, os principais métodos utilizados são o RSSI e TDoA, que se mostraram como soluções práticas, com destaques para utilização de Fingerprinting e TDoA nos trabalhos relacionados. Estas técnicas apresentam um valor proporcional de erro na área estudada até mesmo inferior a 1%, no caso do Fingerprinting. Porém, ambos apresentam limitações que podem prejudicar sua aplicação, como a base de dados extensa, atualização constante e, no caso de FP, limitados a área de estudo, ou para o TDoA sincronia constante entre os *Gateways*.

No trabalho em questão, soluções como LoOP e até mais simples como WC mostraram uma eficácia de erro médio baixo comparado até mesmo de TDoA, referenciado pela LoRa Alliance como uma das principais soluções. Além disso, ambos algoritmos propostos, por utilizar de RSSI, podem ser aplicados a diferentes ambientes, internos e externos. Com a aplicação do filtro de Kalman, o qual não precisa de uma banco de dados para sua atualização, torna o erro ainda menor, de menos de 2% de erro de área. No caso do WC, o erro médio varia em menos de 1% quando aplicado o método de Log-Normal e aumentando em até 40% o valor do coeficiente de perda calculado, o que indica que mesmo ao aplicar coeficientes mais severos, a eficiência do método é mantida. Apesar disso, o modelo é limitado pela quantidade de *Gateways* superior a dois.

Para trabalhos futuros, pretende-se considerar as características de ganho de antena de receptor e emissor para tornar a equação de perda de percurso mais precisa e o erro da equação ainda menor. Além disto, pretende-se aplicar as mesmas soluções para ambientes diversos, e assim validar a manutenção das ordens como grau de contribuição nos algoritmos de WC e LoOP e os fatores de erro apresentados no filtro de Kalman. Em acréscimo propor aplicação de solução em ambientes internos, com tecnologias como LoRa ou até mesmo Bluetooth e Wi-Fi.

## REFERÊNCIAS

- AERNOUTS, M.; BERKVEN, R.; VLAENDEREN, K. V.; WEYN, M. Sigfox and LoRaWAN Datasets for Fingerprint Localization in Large Urban and Rural Areas. Zenodo, jul. 2019. Disponível em: <https://doi.org/10.5281/zenodo.3904158>.
- ALMUZAINI, K.; GULLIVER, T. A. Range-based localization in wireless networks using density-based outlier detection. **Wireless Sensor Network**, v. 2, p. 807–814, 01 2010.
- AZMI, N. A.; SAMSUL, S.; YAMADA, Y.; YAKUB, M. F. M.; ISMAIL, M. I. M.; DZIYAUDDIN, R. A. A survey of localization using rssi and tdoa techniques in wireless sensor network: System architecture. p. 131–136, 2018.
- BELMONTE-HERNÁNDEZ, A.; HERNÁNDEZ-PEÑALOZA, G.; ÁLVAREZ, F.; CONTI, G. Adaptive fingerprinting in multi-sensor fusion for accurate indoor tracking. **IEEE Sensors Journal**, v. 17, n. 15, p. 4983–4998, 2017.
- BISSETT, D. Analysing tdoa localisation in lora networks. In: MSC THESIS, TECHNICAL UNIVERSITY OF DELFT. 2018.
- BOR, M.; ROEDIG, U.; VOIGT, T.; ALONSO, J. Do lora low-power wide-area networks scale? 11 2016.
- CHEN, S. Y. Kalman filter for robot vision: A survey. **IEEE Transactions on Industrial Electronics**, v. 59, n. 11, p. 4409–4420, 2012.
- DANEBJER, J.; HALLDÓRSSON, V. A hybrid approach to gps-free geolocation over lora. 2018. Student Paper.
- EYNG, A. C.; RAYEL, O. K.; OROSKI, E.; REBELATTO, J. L. Kalman filtering-aided hybrid indoor positioning system with fingerprinting and multilateration. p. 1–5, 2020.
- GOLDSMITH, A. **Wireless Communications**. Cambridge University Press, 2005.
- JANSSEN, T.; BERKVEN, R.; WEYN, M. Benchmarking rssi-based localization algorithms with lorawan. **Internet of Things**, v. 11, p. 100235, 2020. ISSN 2542-6605. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2542660520300688>.
- KRIEGEL, H.-P.; KRÖGER, P.; SCHUBERT, E.; ZIMEK, A. Loop: Local outlier probabilities. **International Conference on Information and Knowledge Management, Proceedings**, p. 1649–1652, 01 2009.
- LAM, K.-H.; CHEUNG, C.-C.; LEE, W.-C. New rssi-based lora localization algorithms for very noisy outdoor environment. v. 02, p. 794–799, 2018.
- LI, Y.; BARTHELEMY, J.; SUN, S.; PEREZ, P.; MORAN, B. Urban vehicle localization in public lorawan network. **IEEE Internet of Things Journal**, p. 1–1, 2021.

- LORA ALLIANCE. Lorawan.what is it?. **White Paper.**, 2015. <https://lora-alliance.org/sites/default/files/2018-04/what-is-lorawan.pdf>, Last Accessed: 2021-11-07.
- LORA ALLIANCE. Geolocation whitepaper. **White Paper.**, 2018. [https://lora-alliance.org/wp-content/uploads/2020/11/geolocation\\_whitepaper.pdf](https://lora-alliance.org/wp-content/uploads/2020/11/geolocation_whitepaper.pdf), Last Accessed: 2021-11-21.
- LORA ALLIANCE. Rp002-1.0.0 lorawan® regional parameters. **Especificação Técnica.**, 2018. [https://lora-alliance.org/wp-content/uploads/2019/11/rp\\_2-1.0.0\\_final\\_release.pdf](https://lora-alliance.org/wp-content/uploads/2019/11/rp_2-1.0.0_final_release.pdf), Last Accessed: 2022-01-23.
- MENSING, C.; PLASS, S. Positioning algorithms for cellular networks using tdoa. v. 4, p. IV–IV, 2006.
- NGUYEN, T. Lora localisation in cities with neural networks. In: MSC THESIS, TECHNICAL UNIVERSITY OF DELFT. 2019.
- NOKIA. Lte evolution for iot connectivity. **White Paper.**, 2017. [https://halberdbastion.com/sites/default/files/2017-06/Nokia\\_LTE\\_Evolution\\_for\\_IoT\\_Connectivity\\_White\\_Paper.pdf](https://halberdbastion.com/sites/default/files/2017-06/Nokia_LTE_Evolution_for_IoT_Connectivity_White_Paper.pdf), Last Accessed, 2021-11-07.
- ORUJOV, F. Comparative analysis of the indoor positioning algorithms using bluetooth low energy beacons. 2016.
- PODEVIJN, N.; PLETS, D.; TROGH, J.; MARTENS, L.; SUANET, P.; HENDRIKSE, K.; JOSEPH, W. Tdoa-based outdoor positioning with tracking algorithm in a public lora network. **Wireless Communications and Mobile Computing**, v. 2018, p. 1–9, 05 2018.
- RACHKIDY, N. E.; GUITTON, A.; KANEKO, M. Collision resolution protocol for delay and energy efficient lora networks. **IEEE Transactions on Green Communications and Networking**, v. 3, n. 2, p. 535–551, 2019.
- RAHMADHANI, A. Performance evaluation of lorawan: From small-scale to large-scale networks. In: MSC THESIS, TECHNICAL UNIVERSITY OF DELFT. 2017.
- RAPPAPORT, T. S. **Wireless communications - principles and practice.** Prentice Hall, 1996. I-XVI, 1-641 p. ISBN 978-0-13-375536-7.
- SINGH, S. P.; SHARMA, S. Range free localization techniques in wireless sensor networks: A review. **Procedia Computer Science**, v. 57, p. 7–16, 2015. ISSN 1877-0509. 3rd International Conference on Recent Trends in Computing 2015 (ICRTC-2015). Disponível em: <https://www.sciencedirect.com/science/article/pii/S1877050915018864>.
- TELLES, G. P.; RAYEL, O. K.; MORITZ, G. L. Weighted-centroid localization using lorawan network on large outdoor areas. **Internet Technology Letters**, n/a, n. n/a, p. e367. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1002/itl2.367>.
- WIMOD. im880b-l lora® radio module. **Documento Técnico**, 2020. <https://wireless-solutions.de/products/lora-solutions-by-inst/radio-modules/im880b-l/>, Último Acesso: 2022-01-10.