



Universidade de Brasília

Instituto de Ciências Exatas
Departamento de Ciência da Computação

Uso de Modelos de Redes LSTM para Redução de Ruído em Sensores de Unidade de Medição Inercial para Simuladores

Noélio H. Ferreira

Dissertação apresentada como requisito parcial para conclusão do
Mestrado Profissional em Computação Aplicada

Orientadora

Prof.a Dr.a Aletéia Patrícia Favacho de Araújo von Paumgarten

Coorientador

Prof. Dr. Flávio de Barros Vidal

Brasília
2025

Ficha catalográfica elaborada automaticamente,
com os dados fornecidos pelo(a) autor(a)

FFN769u
u Ferreira, Noelio Heluy
Uso de Modelos de Redes LSTM para Redução de Ruído em
Sensores de Unidade de Medição Inercial para Simuladores /
Noelio Heluy Ferreira; orientador Patrícia Favacho de Araújo
von Paumgartten; co-orientador Flávio de Barros Fidal.
Brasília, 2025.
116 p.

Dissertação(Mestrado Profissional em Computação Aplicada)
Universidade de Brasília, 2025.

1. Simulação. 2. Sensores Inerciais. 3. Aprendizado de
Máquina. 4. Filtro de Kalman. 5. LSTM. I. Favacho de Araújo
von Paumgartten, Patrícia, orient. II. de Barros Fidal,
Flávio, co-orient. III. Título.

Dedicatória

Dedico este trabalho à minha esposa, Lerticia Maria Senhorin, e à minha filha, Helena Ferreira, que são fontes constantes de amor, apoio e motivação em minha vida. Dedico também à minha falecida mãe, Clelda Maria Heluy Ferreira, à minha irmã Sumaya e ao meu querido e falecido pai, Mário Ferreira Sobrinho, integrante do Quadro de Engenheiros Militares e formado no Instituto Militar de Engenharia (IME), que foi o maior incentivo da minha trajetória acadêmica e profissional, sempre inspirando-me a explorar meus limites e a superar cada barreira encontrada.

Agradecimentos

Agradeço ao Gen. Eduardo Wolski, então Chefe do Centro de Desenvolvimento de Sistemas (CDS), por ter aberto as portas para a realização deste mestrado na última oportunidade de minha carreira, e ao Gen. Marcelo Corrêa Horewicz, atual Chefe do CDS, pelo apoio constante e fundamental ao longo desta jornada. Registro meu reconhecimento ao Prof. Dr. Marcelo Ladeira, que acreditou em minha capacidade e assumiu protagonismo na superação de desafios administrativos entre as instituições, tornando possível a continuidade no mestrado profissional em momento decisivo. Estendo meus agradecimentos à minha orientadora, Profa. Dra. Aletéia Araújo, e ao meu coorientador, Prof. Dr. Flávio Vidal, pelas orientações criteriosas e pela condução segura desde o início desta trajetória até sua conclusão.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES), por meio do Acesso ao Portal de Periódicos.

Resumo

Este trabalho consiste em uma abordagem para a estabilização dos dados coletados de sensores *Inertial Measurement Unit (IMU)* de baixo custo. Atualmente, os avanços alcançados no uso do Aprendizado de Máquina são relevantes para o refinamento da estabilização de curto e longo prazo, utilizando o modelo *Long Short-Term Memory (LSTM)* para corrigir os ruídos adicionados aos valores causados por interferências parasitárias de campos eletromagnéticos, que causam instabilidade e derivação constante na orientação dos sensores. Essa abordagem foi combinada com os métodos convencionais de filtro de remoção de ruídos e filtros passa-baixa, pois o uso desses métodos é um ponto de partida fundamental para a solução proposta de refinamento dos dados coletados dos sensores inerciais para a simulação. A proposta de treinar o modelo e aplicá-lo nos dados dinâmicos provenientes do sensor pode ser de grande relevância em projetos de baixo custo, ao aumentar o ganho de precisão com a tecnologia embarcada no software, em detrimento da necessidade de investimento em hardware de alta precisão, resultando em altos custos de projeto. Os resultados deste trabalho são consideráveis para a aplicação em simuladores que utilizam plataformas de movimento ou armas de tiro simuladas, ou para a aplicação em estruturas ou hardwares reais, como Veículos Aéreos Não Tripulados(VANT), plataformas estruturais de grande porte, robótica, dentre outros no campo da indústria e da engenharia.

Palavras-chave: Simulação, Sensores Inerciais, IMU, Filtro de Kalman, Aprendizado de Máquina, LSTM, RNN

Abstract

This work consists of an approach for the stabilization of data collected from low-cost Inertial Measurement Unit (IMU) sensors. Currently, advances achieved in the use of Machine Learning are relevant for the refinement of short- and long-term stabilization, using the Long Short-Term Memory (LSTM) model to correct noise added to the measured values caused by parasitic electromagnetic field interferences, which lead to instability and continuous drift in sensor orientation. This approach was combined with conventional noise-removal filtering methods and low-pass filters, since the use of such methods represents a fundamental starting point for the proposed solution aimed at refining data collected from inertial sensors for simulation purposes. The proposal of training the model and applying it to dynamic data acquired from the sensor can be highly relevant in low-cost projects, as it increases precision gains through software-embedded technology, instead of requiring investments in high-precision hardware, which would result in high project costs. The results of this work are relevant for applications in simulators that use motion platforms or simulated firing systems, as well as for applications in real structures or hardware, such as Unmanned Aerial Vehicles (UAVs), large-scale structural platforms, robotics, among others within the fields of industry and engineering.

Keywords: *Simulation, Inertial Sensors, IMU, Kalman Filter, Machine Learning, LSTM, RNN.*

Sumário

1	Introdução	1
1.1	Justificativa	3
1.2	Objetivos	5
1.3	Organização do Documento	5
2	Simulador SIMAF	6
2.1	Definição de Simulação	6
2.2	Classificação das Técnicas de Simulação	8
2.3	Simulador Militar	9
2.4	Simulador de Apoio de Fogo	12
2.4.1	Características	14
2.4.2	Localização e Infraestrutura	15
2.5	Caso de Uso - Simulador SIMAF	16
2.6	Limitações do SIMAF	20
3	Sensores e Aprendizado de Máquina	22
3.1	Tempo Necessário	22
3.2	Sensores Inerciais	23
3.3	Ruídos Indesejáveis	25
3.4	Filtro de Fusão e Remoção de Ruídos	28
3.5	Filtro de Kalman (KF)	30
3.5.1	Análise da Complexidade do Filtro de Kalman	34
3.6	Algoritmos de Aprendizado de Máquina e Redes Neurais Recorrentes	35
3.6.1	Arquitetura <i>LSTM</i> Aplicada à Estabilização de Sensores Inerciais	37
3.7	Sumarização dos Trabalhos Relacionados	38
4	Metodologia	40
4.1	Modelo <i>LSTM</i> e Dados do Filtro de Fusão e Remoção de Ruídos	40
4.1.1	Filtro de Fusão e Remoção de Ruído	42
4.1.2	Coleta de Dados	42

4.2	Treinamento do Modelo com o Algoritmo <i>LSTM</i>	46
4.2.1	Carregamento e Preparação dos Dados	46
4.2.2	Treinamento e Teste da Rede Neural	48
4.2.3	Validação dos Resultados Obtidos	49
4.2.4	Definição da Arquitetura da Rede Neural LSTM e o Otimizador	49
4.3	Planejamento dos Cenários	51
4.3.1	Cenário 1: Análise Isolada das Tecnologias Empregadas	51
4.3.2	Cenário 2: Generalização Sem Movimento Do Sensor	52
4.3.3	Cenário 3: Generalização Com Movimento Do Sensor	53
5	Resultados	55
5.1	Métricas de Generalização	55
5.2	Estrutura dos Dados Coletados	57
5.3	Utilização do LSTM em Tempo de Execução	58
5.3.1	Ponto de Partida	58
5.3.2	Processamento Concorrente	59
5.3.3	Filtro de Média Móvel	61
5.3.4	Algoritmo <i>LSTM</i> em Tempo Necessário	62
5.3.5	Inferência de <i>LSTM</i>	63
5.3.6	Filtro de Kalman	64
5.4	Cenário 1: Análise Isolada das Tecnologias Empregadas	65
5.4.1	O Filtro de Fusão de Dados e Redução de Ruídos	65
5.4.2	O Filtro de Kalman e o Filtro de Média Móvel	67
5.4.3	Análise ente o Filtro de Kalman e o Filtro de Média Móvel	67
5.4.4	Análise do Algoritmo LSTM	68
5.5	Cenário 2: Generalização sem Movimento do Sensor	71
5.5.1	Análise dos Resultados do Modelo no Conjunto de Teste do Sensor 1	71
5.5.2	Análise da Validação do Modelo em Novos Dados do Sensor 1	72
5.5.3	Análise da Aplicação do Modelo na Estabilização dos Dados do Sensor 1	73
5.6	Cenário 3: Generalização com Movimento do Sensor	76
5.6.1	Análise dos Resultados do Modelo no Conjunto de Teste do Sensor 1	76
5.6.2	Análise da Validação do Modelo em Novos Dados do Sensor 1	79
5.6.3	Análise da Aplicação do Modelo do Sensor 1 em Dados do Sensor 2	79
5.6.4	Análise da Aplicação do Modelo na Estabilização dos Dados do Sensor 1	82
5.6.5	Eficiência dos Resultados	85
5.7	Implantação da Solução no Simulador SIMAF	87

6	Conclusões e Trabalhos Futuros	90
6.1	Conclusões	90
6.2	Trabalhos Futuros	91
	Referências	94

Lista de Figuras

2.1	Conceito dos tipos [1] de simulação no Exército Brasileiro (Adaptado do CA-Sul [2]).	11
2.2	Compartimentação da Maquete do SIMAF (Adaptado de Duarte [3]).	15
2.3	Organizações militares de abrangência do SIMAF-AMAN (Adaptado de Duarte [3]).	16
2.4	Registro no Sistema de Acompanhamento de Defeitos [4].	17
2.5	Registro da resposta no Sistema de Acompanhamento de Defeitos [4].	17
2.6	O erro de paralaxe ilude o observador, informando necessidade de recarga (Fonte: Elaborado pelo autor).	18
2.7	Transporte pela Fórmula do Milésimo (Fonte: Caderno de Instrução "O Levantamento Topográfico Eletrônico"[5]).	19
2.8	Transporte pelo Fator Seno (Fonte: Caderno de Instrução "O Levantamento Topográfico Eletrônico"[5]).	19
2.9	Registro do teste da empresa no Sistema de Acompanhamento de Defeitos [4].	19
2.10	Exemplo de Obuseiro sensorizado (Adaptado do CA-Sul [2]).	20
4.1	Fluxo metodológico do treinamento e avaliação do modelo LSTM	41
4.2	Esquema de varredura angular do obuseiro (Fonte: Elaborado pelo autor).	43
5.1	Eficiência entre os Filtros de Kalman e Média Móvel.	67
5.2	Comparação entre os resultados do filtro de Kalman e do modelo LSTM para os eixos X, Y e Z.	70
5.3	Predição nos dados de teste do Sensor 1.	72
5.4	Gráfico de predição nos novos dados do Sensor 1 (validação).	73
5.5	Correção 20% com os dados estáticos.	74
5.6	Correção 40% com os dados estáticos.	74
5.7	Gráfico de predição nos dados de teste (escala deslormalizada).	77
5.8	Gráfico de predição nos dados de teste (escala normal).	78
5.9	Gráfico de predição nos dados de Validação (escala normalizada).	80

5.10	Gráfico de predição nos dados de validação (escala desnormalizada).	81
5.11	Predição nos dados do Sensor 2 (escala ampliada).	82
5.12	Predição nos dados do Sensor 2 (escala normal).	83
5.13	Correção do arrasto em dados do Sensor 1 com aplicação do Fator de Correção.	83
5.14	Campo de provas: comparação simultânea entre saída da fusão (IMU), LSTM e Filtro de Kalman. Cada estágio estabiliza adicionalmente o sinal recebido do estágio anterior.	86
5.15	Fixação do sensor ao obuseiro.	88
5.16	Janelas com a exposição dos dados por etapa.	88
5.17	Ponto de impacto.	89

Lista de Tabelas

3.1	Comparação de técnicas em trabalhos relacionados.	39
4.1	Distribuição espacial dos pontos de coleta no campo de pontaria	44
4.2	Detalhamento do treinamento e predição dos sensores GY-87.	46
5.1	Faixas interpretativas do coeficiente de determinação (R^2) adotadas neste trabalho.	56
5.2	Formato dos dados coletados: vetor tridimensional por linha.	57
5.3	Ordem das tecnologias empregadas.	68
5.4	Comparação quantitativa entre o modelo LSTM e o Filtro de Kalman.	69
5.5	Métricas de desempenho no Split 4.	71
5.6	Métricas de desempenho do Sensor 1 em novos dados (validação).	72
5.7	Comparação global entre os resultados de Teste e Validação no Cenário 2.	75
5.8	Métricas de desempenho no Split 3 (melhor resultado).	76
5.9	Métricas nos dados de validação.	79
5.10	Métricas nos dados do Sensor 2 (aleatório).	80
5.11	Resumo por fator de correção: variações percentuais médias (entre eixos) de STD e RMS do sinal corrigido em relação ao original. Valores negativos indicam redução (estabilização).	84
5.12	Refino do Kalman sobre a saída do LSTM: reduções de $ \Delta $ por eixo (valores em graus).	87
6.1	Refino do <i>Filtro de Kalman</i> sobre a saída da <i>LSTM</i> : reduções de $ \Delta $ por eixo (valores em graus).	91

Lista de Abreviaturas e Siglas

Adam Adaptive Moment Estimation.

AKF Adaptive Kalman Filter.

AMAN Academia Militar das Agulhas Negras.

CA-Sul Centro de Adestramento-Sul.

CAI Computer-Assisted Instruction.

CDS Centro de Desenvolvimento de Sistemas.

CNN Convolutional Neural Network.

Com Comunicações.

ConvLSTM Convolutional Long Short-Term Memory.

CPU Central Processing Unit.

CTir Central de Tiro.

DCT Departamento de Ciência e Tecnologia.

EKF Extended Kalman Filter.

ES Embedded Systems.

FOROP Força Oponente.

FWKF Frequency-weighted Kalman Filter.

GNSS Global Navigation Satellite System.

GPS Global Position System.

IMU Inertial Measurement Unit.

INS Inertial Navigation System.

KF Kalman Filter.

LF Linha de Fogo.

Log Logística.

LSTM Long Short-Term Memory.

LSTM-RNN Long Short-Term Memory-Recurrent Neural Network.

MAE Mean Absolute Error.

MAF Moving Average Filter.

MAPE Mean Absolute Percentage Error.

MEMS Micro-Electro-Mechanical Systems.

ML Machine Learning.

MSE Mean Squared Error.

Nadam Accelerated Adaptive Moment Estimation.

OA Observador Avançado.

PO Posto de Observação.

RMS Root Mean Square.

RMSE Root Mean Squared Error.

RNN Recurrent Neural Network.

SIMAF Simulador de Apoio de Fogo.

SSEB Sistema de Simulação do Exército Brasileiro.

STD Standard Deviation.

VANT Veículo Aéreo Não Tripulado.

VR Virtual Reality.

Capítulo 1

Introdução

O uso da simulação no treinamento de tropas, cada vez mais consolidado nas Forças Armadas, possibilita a criação de ambientes virtuais realistas. Nesses ambientes, sensores e dispositivos ópticos permitem que os militares pratiquem cenários táticos variados sem os riscos e custos de exercícios reais. O treinamento militar das Forças Armadas do Brasil tem passado por transformações significativas nas últimas décadas. Esse processo foi impulsionado pelos avanços tecnológicos, que permitem uma preparação mais eficaz e segura dos soldados [6]. Ao mesmo tempo, essa evolução tecnológica, que transcende o campo militar, reforça a necessidade de aprimoramentos contínuos, a fim de garantir a capacitação para um desempenho superior, mesmo em condições desafiadoras.

Segundo Savchenko *et al.* [7] e Slim [8], a simulação exerce um papel crucial na formação de tropas, oferecendo um ambiente seguro e controlado para o desenvolvimento de habilidades. Esses dispositivos são essenciais no treinamento, pois permitem enfrentar cenários complexos sem os riscos inerentes a situações reais. Conforme Girardi *et al.* [9], os simuladores também apresentam vantagens econômicas, já que reduzem a necessidade de recursos físicos e logísticos. Além disso, possibilitam treinamento intensivo e repetitivo sem desgaste de equipamentos reais. Outro aspecto relevante é a avaliação de desempenho em tempo real, que facilita a correção imediata de erros e melhora a eficácia do treinamento.

No campo civil, os sensores ocupam uma posição central em diversas áreas, como robótica, plataformas petrolíferas e dispositivos móveis de comunicação [10, 11]. Em robótica, sensores avançados possibilitam a interação segura e precisa entre máquinas e ambientes dinâmicos, como destaca Ryumin [12], viabilizando tarefas complexas de manipulação e navegação autônoma. Já em plataformas de petróleo, sensores permitem a previsão de inclinações prejudiciais ao processo de perfuração e à segurança da tripulação, reduzindo o risco de acidentes, conforme Hu *et al.* [13]. Em dispositivos móveis, de acordo com Chebanyuk e Anton [10] e Monteiro e Arturo [11], sensores integrados, como

acelerômetros, giroscópios e sensores de proximidade, aprimoram a funcionalidade e a experiência do usuário, viabilizando recursos como realidade aumentada e detecção de gestos.

Para as Forças Armadas, a integração de sensores em equipamentos e sistemas de treinamento é essencial para simular operações reais e coletar dados críticos durante os exercícios de treinamento, como ocorre com as torres de tiro simuladas de blindados no Centro de Instrução de Blindados General Walter Pires (Santa Maria-RS) [14], e como é feito com armas coletivas e/ou portáteis, além dos coletes de detecção de impacto utilizados pelos militares no Centro de Adestramento-Sul (Santa Maria-RS). Segundo dos Santos *et al.* [15] e Figueira *et al.* [16], sensores instalados em veículos militares podem monitorar o terreno, identificar obstáculos e fornecer informações em tempo real para apoiar a tomada de decisão dos comandantes de frações sobre eixos de progressão e vias de acesso impeditivas ou restritivas.

Segundo Bultmann *et al.* [17], essa tecnologia é fundamental para o desenvolvimento de sistemas de armas inteligentes e para a manutenção preditiva, aumentando a eficiência e a segurança das operações. O emprego de sensores e simuladores não apenas aprimora a preparação das tropas, mas também contribui para o Departamento de Ciência e Tecnologia (DCT), gerando inovações que se estendem à sociedade civil, como o que foi utilizado para a detecção de aeronaves de asas rotativas mais próximas de um pedido de socorro em enchentes, otimizando o tempo de resgate e o consumo de horas de voo.

No Exército, os simuladores incluem: (i) sistemas de Comando e Controle com rastreamento de viaturas e tropas desembarcadas; (ii) sistemas de busca de alvos por *drones* e veículos terrestres não tripulados; e (iii) simulações com realidade virtual e aumentada. Esses sistemas oferecem uma experiência imersiva nos níveis tático e estratégico, a exemplo do que é feito com militares que são colocados virtualmente em montanhas, por meio de Óculos de Realidade Virtual, para realizar a observação e condução do tiro balístico, cuja pontaria é indireta, ou seja, não se enxerga o alvo diretamente. Na Artilharia, onde esses armamentos são empregados, o Exército Brasileiro utiliza o Simulador de Apoio de Fogo (SIMAF) [2] voltado para o treinamento de tropas com armamentos pesados de tiro balístico de longa distância. O SIMAF [3] contempla o treino dos três subsistemas básicos para o engajamento, além dos subsistemas de apoio Observador Avançado (OA), Central de Tiro (CTir) e Linha de Fogo (LF).

Apesar de sua relevância, o SIMAF, adquirido pelo Exército Brasileiro para o adestramento de tropas de Artilharia, Cavalaria e Infantaria no emprego do tiro balístico de apoio ao combate, ainda apresenta limitações e requer ajustes em algumas áreas [3]. Nesse cenário, a instabilidade dos sensores inerciais torna-se um desafio central. São necessárias recalibrações frequentes e em intervalos curtos, restringindo a execução de missões

entre os períodos de calibração. Como os sensores são cruciais para a automação da pontaria, surgiu a necessidade de investigar Sistemas Computacionais Embarcados, ou simplesmente Sistemas Embarcados (do inglês *Embedded Systems-ES*), em conjunto com sensores inerciais.

Diante disso, este trabalho tem como objetivo explorar o uso de Aprendizado de Máquina (do inglês *Machine Learning-ML*), em conjunto com processos de filtragem tradicionais e estocástica, para estabilizar os dados de sensores dentro de uma margem de erro de até 2 milésimos, conforme o Caderno de Instrução CI 6-199/1 [18] e [19, 20]. Outro ponto abordado é a derivação, que consiste em erros sistemáticos acumulados ao longo do tempo e que alteram as leituras angulares, mesmo na ausência de movimento do sensor. Esses problemas foram documentados em um relatório oficial do Exército [21], produzido em 2021 e encaminhado ao Centro de Desenvolvimento de Sistemas (CDS) em 2024. A derivação pode comprometer o funcionamento do sistema, gerando desalinhamentos e oscilações [22, 23] nas medições de atitude.

1.1 Justificativa

Segundo Duarte [3], a simulação de técnicas, táticas ou procedimentos constitui um mecanismo complementar ao treino real, acelerando a aprendizagem ao conferir maior realismo às atividades de instrução. Embora a instrução militar permaneça fundamentada nos Programas-Padrão (PP), que buscam imitar o combate real, nenhum simulador substitui integralmente o exercício em terreno. Ainda assim, seu emprego é essencial para a redução de custos e para a ampliação da segurança do treinamento, conforme estabelecido na Portaria nº 902-EME [24], que institui o Sistema de Simulação do Exército Brasileiro (SSEB). Entre as premissas dessa portaria, destaca-se que a aquisição e o uso de meios de simulação devem ser justificados por sua necessidade efetiva, pela economia proporcionada e pelos benefícios ao adestramento. Indicadores dessa economia foram demonstrados por Duarte [3], ao apontar que, em 2019, os tiros simulados evitaram gastos significativos com munição real.

Além dos benefícios financeiros e da mitigação de riscos à tropa em instrução, o emprego de simuladores reduz o impacto ambiental de exercícios reais, evitando danos associados à detonação de munições, como ondas de choque, calor, estilhaços metálicos e a liberação de resíduos decorrentes da combustão. Esse aspecto reforça a crescente relevância da simulação militar frente às demandas contemporâneas de eficiência, segurança e sustentabilidade.

Nesse contexto, o Simulador de Apoio de Fogo (SIMAF) ocupa um papel central no treinamento da Artilharia de Campanha, uma vez que, quanto maior for a quantidade de

exercícios conduzidos no ambiente simulado, menor será a probabilidade de desperdício de munição real durante o coroamento da instrução no terreno. No entanto, apesar da robustez do sistema, sua automação plena é limitada pelas restrições impostas pelos sensores inerciais responsáveis pela medição dos movimentos da peça. Em razão dessas limitações, a automação do processo é frequentemente interrompida, comprometendo a fluidez das atividades simuladas e exigindo que a equipe de instrutores realize recalibrações recorrentes para restabelecer a confiabilidade das medições.

O problema central reside na instabilidade da precisão desses sensores, cuja deriva temporal e sensibilidade a interferências exigem calibrações frequentes ao longo do dia de instrução. Movimentos angulares superiores a 100 milésimos ou o simples transcurso das horas após a calibração podem fazer com que o sensor deixe de refletir fielmente as condições de pontaria adotadas nos armamentos reais. Tais limitações constam em documento interno do Exército [21], que apresenta relatório de testes realizados em 2021 e remetido ao CDS em 2024, evidenciando a necessidade urgente de soluções técnicas para estabilizar os dados inerciais.

Ressalta-se que esses sensores são restritos ao simulador, não sendo utilizados em tiros reais, mas desempenham um papel fundamental no treinamento dos militares que executam a pontaria e o disparo com armamentos reais.

Diante desse cenário, torna-se tecnicamente justificável a busca por métodos capazes de mitigar as limitações intrínsecas dos sensores empregados. Este trabalho propõe uma abordagem inovadora que combina técnicas de Aprendizado de Máquina (do inglês *Machine Learning-ML*) com métodos de filtragem estocástica, com o objetivo de estabilizar e corrigir os dados oriundos dos sensores inerciais. A integração dessas tecnologias visa aumentar a precisão e a confiabilidade do simulador, reduzindo a dependência de calibrações manuais e aproximando o comportamento do sistema simulado das condições reais de operação.

Assim, a justificativa desta pesquisa fundamenta-se na convergência entre a necessidade operacional, evidências técnicas da instabilidade dos sensores atuais, o impacto direto na qualidade do treinamento e o potencial de inovação proporcionado pelos métodos de aprendizado profundo e filtragem. Essa evolução tecnológica representa uma adequação às exigências modernas do campo de batalha e reforça a necessidade de dotar as Forças Armadas de ferramentas de instrução mais precisas, confiáveis e aderentes às realidades da guerra contemporânea.

1.2 Objetivos

O objetivo geral deste trabalho é propor uma implementação para a melhoria de sensores do tipo Unidade de Medição Inercial (do inglês *Inertial Measurement Unit-IMU*). A proposta é avaliada quanto à capacidade de reduzir o ruído e melhorar a precisão dos dados em um ambiente de simulação, usando Aprendizado de Máquina. Para alcançar esse objetivo geral, foram definidos e atingidos os seguintes objetivos específicos:

- Reduzir o erro de derivação, ampliando o intervalo entre recalibrações do sensor;
- Permitir a execução de exercícios de simulação sem interrupções;
- Diminuir as oscilações de curto prazo nos dados fornecidos pelos sensores, de modo que permaneçam dentro do limite de 2 milésimos, conforme as normas de precisão militar.

1.3 Organização do Documento

Este documento foi estruturado para guiar o leitor por uma sequência lógica e detalhada dos tópicos abordados. O objetivo é facilitar a compreensão das etapas, conceitos e metodologias utilizadas. Além deste capítulo introdutório, a dissertação está organizada em mais cinco capítulos:

- **Capítulo 2** — descreve a estrutura e a finalidade do Simulador de Apoio de Fogo (SIMAF), bem como o problema a ser solucionado;
- **Capítulo 3** — apresenta a fundamentação teórica e a revisão bibliográfica associada ao objetivo deste trabalho;
- **Capítulo 4** — detalha as técnicas e as ferramentas utilizadas, incluindo coleta de dados, processamento paralelo simulado, filtros e algoritmos;
- **Capítulo 5** — analisa os resultados obtidos, destacando o desempenho do modelo em diferentes cenários e conjuntos de dados;
- **Capítulo 6** — apresenta a conclusão sobre os resultados e a contribuição desta pesquisa para o simulador estudado.

Capítulo 2

Simulador SIMAF

Este capítulo aborda o Simulador de Apoio de Fogo (SIMAF), enfatizando sua estrutura, seus objetivos e os desafios atuais de desempenho. A Seção 2.1 introduz o conceito de simulação, destacando sua importância como método para representar sistemas reais em ambientes controlados, permitindo estudo, experimentação e análise segura de operações complexas. Em continuidade, a Seção 2.2 apresenta as principais categorias de técnicas de simulação, classificadas em construtiva, virtual e viva, e explica suas aplicações no contexto militar.

A Seção 2.3 caracteriza o simulador militar como ferramenta fundamental para o adestramento, ressaltando seu papel na racionalização de recursos, no aumento da segurança e na padronização doutrinária. Em seguida, a Seção 2.4 descreve o simulador empregado na artilharia, abordando sua estrutura, seus subsistemas, as características técnicas necessárias ao realismo operacional e a infraestrutura destinada ao seu funcionamento. Nesse ponto, a apresentação evidencia como o sistema integra sensores e módulos específicos para reproduzir fielmente os procedimentos de tiro e observação.

Por fim, a Seção 2.6 apresenta as limitações identificadas no desempenho atual do simulador, discutindo os principais entraves técnicos e metodológicos que comprometem a precisão dos dados e a confiabilidade operacional. Nessa parte, são introduzidas propostas de otimização que fundamentam as soluções desenvolvidas ao longo deste trabalho, com foco no aprimoramento dos sensores e na aplicação de técnicas avançadas de tratamento de sinais.

2.1 Definição de Simulação

A simulação é uma técnica amplamente utilizada em diversas áreas do conhecimento para modelar e analisar o comportamento de sistemas complexos. Na engenharia, por exemplo, ela é aplicada em diferentes especializações: na engenharia mecânica para análise de siste-

mas dinâmicos e robótica; na engenharia elétrica e eletrônica para simulação de circuitos e controle de sistemas; e na engenharia aeroespacial, onde é essencial para o desenvolvimento de sistemas de navegação, controle de voo e sensores inerciais [23, 25, 26]. Na Ciência da Computação, a simulação é empregada em áreas como redes de computadores, sistemas distribuídos, inteligência artificial e realidade virtual [13, 27]. As ciências econômicas e financeiras também fazem uso extensivo dessa técnica, especialmente em modelos de previsão de mercado, análise de risco e simulação de comportamentos econômicos baseados em agentes [28]. Na área da saúde e biociências, a simulação permite estudar sistemas fisiológicos, modelar epidemias e realizar treinamentos médicos com simuladores [29]. Além disso, em transporte e logística, ela é usada para modelar tráfego urbano e otimizar sistemas de transporte [30]. No setor de defesa e aeroespacial, a simulação é crítica para o desenvolvimento e teste de sistemas complexos, como veículos autônomos, simuladores de voo e sistemas de armamento [1, 24]. Dessa forma, a simulação se consolidou como uma ferramenta fundamental para a análise, validação e otimização de sistemas em diversas disciplinas científicas e tecnológicas.

Dessa forma, ela permite a reprodução de processos ou sistemas reais em ambiente controlado, com o objetivo de prever comportamentos sob diferentes condições, testar hipóteses e apoiar decisões em cenários alternativos. De acordo com Law e Kelton [31], simulação pode ser definida como o processo de criação de um modelo de um sistema real e a condução de experimentos com esse modelo, a fim de compreender melhor seu comportamento ou avaliar diferentes estratégias de operação.

Segundo Fletcher [32], a simulação é uma técnica instrucional voltada à replicação de experiências sensoriais de ambientes operacionais reais. O método envolve representar sensações visuais, auditivas, táteis e, em alguns casos, olfativas, para criar experiências autênticas de aprendizagem. Diferencia-se da Instrução Assistida por Computador (do inglês *Computer-Assisted Instruction-CAI*), pois prioriza a aprendizagem por meio da interação com essas experiências realistas.

De acordo com Sokolowski e Banks [33], a simulação é uma disciplina que utiliza modelos como aproximações do mundo real para facilitar a observação e análise de sistemas ou eventos. Esse processo permite realizar experimentos em ambiente controlado, testando variáveis e cenários sem os riscos ou custos de experimentos diretos. A simulação, assim, constitui uma ferramenta essencial para integrar conhecimentos de diferentes disciplinas, assumindo papel de infraestrutura em aplicações complexas.

A técnica de simulação é particularmente valiosa em contextos em que experimentos diretos seriam caros, perigosos ou impraticáveis. Segundo Mahdi *et al.* [25], a simulação é amplamente utilizada na indústria aeronáutica por meio de simuladores de voo que treinam pilotos em diferentes cenários climáticos e falhas de sistema sem colocar vidas

em risco. Segundo Hadeel *et al.* [29], na medicina, simuladores de cirurgia capacitam profissionais de saúde e reduzem erros em procedimentos críticos. Segundo Zahara *et al.* [28], na economia, redes neurais recorrentes são empregadas na previsão de indicadores como o índice de preços ao consumidor. Segundo Han *et al.* [23] e Hosseinyalamdary [26], na engenharia, a simulação é usada no desenvolvimento e teste de algoritmos de navegação aplicados a sensores inerciais e sistemas embarcados. Segundo o Centro de Instrução de Blindados [1] e a Portaria nº 902-EME [24], no treinamento de militares, simulações de apoio de fogo e operações táticas são realizadas em ambientes virtuais imersivos. Segundo Shannon [34] e Martins [33], a simulação também permite a análise de sistemas em tempo acelerado ou retardado, possibilitando a observação de processos que, na realidade, ocorreriam em escalas de tempo muito diferentes.

2.2 Classificação das Técnicas de Simulação

A simulação, de acordo com Sokolowski e Banks [33], e Law [31], constitui uma ferramenta fundamental para modelar, analisar e prever o comportamento de sistemas complexos. Dependendo do sistema em estudo e dos objetivos do trabalho, diferentes tipos de simulação podem ser empregados. Segundo esses autores, cada abordagem apresenta características específicas, adequadas a contextos distintos. Segundo Law [31], as principais categorias incluem: simulação determinística e estocástica, conforme o grau de incerteza envolvido; simulação estática e dinâmica, dependendo da evolução temporal do sistema; e simulação contínua e discreta, conforme a natureza das variáveis de estado. A simulação baseada em eventos e agentes é destacada por Banks *et al.* [35], especialmente em contextos computacionais complexos. Por fim, Cellier e Kofman [36] detalham aplicações específicas da simulação contínua em sistemas modelados por equações diferenciais. Dessa forma, os principais tipos de simulação, conforme os autores [31, 33, 35, 36], podem ser sintetizados conforme apresentado a seguir:

- **Simulação Determinística:** o comportamento do sistema é totalmente previsível a partir de um conjunto de condições iniciais. A mesma entrada sempre gera a mesma saída, sem aleatoriedade. É empregada em processos com variáveis bem definidas, como engenharia e sistemas de produção controlados [31];
- **Simulação Estocástica:** incorpora incertezas e variáveis aleatórias, o que faz com que diferentes execuções possam gerar resultados distintos, mesmo com as mesmas condições iniciais. É útil em áreas como economia, saúde e logística, onde há influência de fatores imprevisíveis [31];

- **Simulação Estática:** avalia o sistema em um único instante ou condição fixa, sem considerar a passagem do tempo. Foca na relação entre variáveis de entrada e saída, sendo comum em análises de risco e finanças, como na simulação de Monte Carlo [31];
- **Simulação Dinâmica:** modela sistemas que evoluem ao longo do tempo, permitindo observar mudanças de estado e interações entre variáveis em diferentes momentos. É amplamente aplicada em cadeias de suprimento, processos industriais e políticas públicas [31, 33].
- **Simulação Contínua:** as variáveis de estado mudam continuamente no tempo, normalmente representadas por equações diferenciais. É usada em sistemas físicos, como dinâmica de fluidos, processos térmicos e mecânica clássica [36];
- **Simulação Discreta:** ocorre por meio de eventos que causam mudanças no estado do sistema em pontos específicos no tempo. É utilizada em contextos como filas, produção e redes de computadores, onde o tempo entre eventos é relevante [35];
- **Simulação Baseada em Eventos e Agentes:** a abordagem baseada em eventos discretos enfatiza a sequência e o momento em que as mudanças ocorrem, sendo útil em sistemas produtivos e logísticos [35]. Já a simulação baseada em agentes representa entidades autônomas que interagem entre si e com o ambiente, sendo eficaz na modelagem de sistemas sociais, econômicos e ecológicos [33].

2.3 Simulador Militar

No livro de Tolk [37], a simulação é apontada como uma metodologia fundamental para o treinamento militar e para a tomada de decisão estratégica. O autor evidencia a capacidade da simulação em criar cenários realistas para preparação e análise de operações militares. Por meio dela, é possível explorar o impacto de diferentes estratégias em ambientes seguros, minimizando riscos para as forças armadas e aumentando a eficácia operacional.

A simulação, de acordo com o Exército Brasileiro [1], possibilita a criação de ambientes virtuais que representam cenários de combate e operações militares. Utilizando modelos computacionais, são reproduzidos aspectos críticos de ambientes reais. Assim, os militares podem treinar, planejar e executar operações sem os riscos associados à prática real. Conforme Duarte [3], essa abordagem fornece uma plataforma controlada para experimentação e análise de estratégias, táticas e procedimentos. Conforme Tolk [37], os benefícios para o treinamento militar são amplos:

- **Redução de riscos e custos:** permite o treinamento em ambientes controlados sem expor pessoal a riscos físicos. Além disso, reduz custos com danos a equipamentos e uso de munição;
- **Repetição e variação de cenários:** possibilita repetir exercícios específicos várias vezes e ajustar variáveis para testar capacidades em diferentes contextos operacionais, incluindo situações impraticáveis no mundo real;
- **Análise detalhada:** permite gravar e revisar treinamentos, facilitando a identificação de falhas e oportunidades de melhoria por meio de *feedback* construtivo;
- **Treinamento integrado:** favorece a coordenação entre unidades distintas, promovendo interoperabilidade mesmo quando estão geograficamente dispersas;
- **Adaptação a tecnologias emergentes:** incorpora avanços tecnológicos em tempo oportuno, mantendo as forças atualizadas em relação a inovações de táticas e equipamentos;
- **Preparação para cenários complexos:** permite o treinamento em ambientes urbanos densos e contextos com ameaças assimétricas, nos quais segurança e precisão são críticas;
- **Desenvolvimento de liderança:** cria situações para que líderes militares testem suas capacidades de comando e controle em cenários dinâmicos e de alta pressão.

Além disso, a simulação possibilita testar teorias em ambientes controlados, reduzir riscos, otimizar custos de experimentação e aprimorar a compreensão de sistemas complexos. Ela também se consolida como um meio eficaz de treinamento e educação em diversas áreas [32, 33, 37, 38]. Dessa forma, configura-se como uma ferramenta indispensável para pesquisa, desenvolvimento e planejamento em disciplinas que vão da engenharia e defesa até saúde e gestão. No âmbito militar, permite elevar a eficácia operacional e a prontidão das forças, além de garantir resposta adequada a ameaças emergentes.

No Exército Brasileiro, conforme Caderno de Instrução Emprego da Simulação EB70-CI-11.441 [1], existem três classificações de simulação definidas em documentação interna. Cada uma delas corresponde a uma convenção organizacional, de caráter mais abstrato, que abrange um ou mais tipos de simulação, conforme descrito na Seção 2.2. As classificações podem ser observadas na Figura 2.1:

1. **Simulação Construtiva** [39]: envolve tropas e elementos simulados, controlados por agentes reais, geralmente em situações de comandos constituídos. Também é conhecida como “jogos de guerra”. O foco é a interação entre forças oponentes sob a

TIPO	FATORES	PESSOAS	EQUIPAMENTO	EFEITOS
 Simulação Construtiva		Simulado	Simulado	Simulado
 Simulação Virtual		Real	Simulado	Simulado
 Simulação Viva		Real	Real	Simulado

Figura 2.1: Conceito dos tipos [1] de simulação no Exército Brasileiro (Adaptado do CA-Sul [2]).

direção de um exercício. Seu emprego principal ocorre no adestramento de comandantes e estados-maiores, no processo de tomada de decisão e no funcionamento de postos de comando. A Simulação Construtiva pode ser:

(a) *Quanto aos objetivos:*

- i. Didática: utilizada para apoiar exercícios de Postos de Comando nos diversos escalões, com fins de aprendizado doutrinário e aprimoramento do trabalho em estado-maior. Também é aplicada na formação de oficiais, tanto em sala de aula quanto em atividades de autotreinamento. O foco é o adestramento de recursos humanos;
- ii. Analítica: visa representar a realidade do combate com maior precisão. É usada como ferramenta no desenvolvimento de sistemas de emprego militar e como suporte à validação de doutrinas. Também se aplica ao adestramento de comandantes e ao estudo de casos reais, funcionando como recurso de apoio à decisão.

(b) *Quanto à constituição:*

- i. Livre: dois ou mais partidos enfrentam-se utilizando seus quadros de organização vigentes em um ambiente comum. A Direção do Exercício pode interferir, mas ambos os comandos permanecem em adestramento;
- ii. Dirigida: um dos partidos é composto por uma Força Oponente (FOROP). Essa tropa pode adotar doutrina distinta da brasileira. A Direção do

Exercício pode optar por controlar diretamente a FOROP ou permitir sua atuação autônoma.

2. **Simulação Virtual** [40]: envolve agentes reais operando sistemas simulados ou gerados em computador. Essa modalidade substitui sistemas de armas, veículos e aeronaves que exigem elevado grau de adestramento ou cujo uso envolve riscos e custos altos. Seu objetivo é desenvolver técnicas e habilidades individuais, explorando os limites do operador e do equipamento. Pode ser integrada em ambientes virtuais comuns, permitindo o adestramento tático de frações e interoperabilidade de sistemas de simulação;
3. **Simulação Viva** [41]: envolve agentes reais operando sistemas reais, como armamentos, equipamentos, viaturas e aeronaves, no ambiente real. Utiliza sensores, apontadores *laser* e outros dispositivos que permitem acompanhar elementos e simular engajamentos. Pode ser integrada a outros sistemas de simulação mediante equipamentos adequados.

Segundo Sokolowski e Banks [33], a diversidade dessas classificações reflete a complexidade dos sistemas militares e a variedade de aplicações possíveis. A escolha da modalidade depende do sistema analisado, dos objetivos do estudo e das restrições de tempo e recursos. Independentemente da classificação, a simulação se mantém como uma ferramenta poderosa para compreender sistemas, validar hipóteses e apoiar decisões. A próxima seção apresenta o simulador SIMAF, adotado pelo Exército Brasileiro para o treinamento das tropas.

2.4 Simulador de Apoio de Fogo

O Simulador de Apoio de Fogo (SIMAF) do Exército Brasileiro, segundo Duarte [3], é uma ferramenta avançada de treinamento desenvolvida para aprimorar a capacitação das tropas em operações de apoio de fogo. O simulador oferece um ambiente virtual realista, no qual os militares podem praticar o planejamento e a execução de missões de artilharia e outras formas de apoio de fogo sem os riscos e custos associados a exercícios ao vivo. Com cenários que replicam situações de combate em diferentes terrenos e condições, o SIMAF permite que os operadores de artilharia desenvolvam suas habilidades em coordenação e precisão, essenciais para o sucesso das operações militares.

O SIMAF [2] é um simulador de Apoio de Fogo completo, que treina o militar na condução de tiro de armas pesadas e tem por missão adestrar Grupos de Artilharia de Campanha (GAC) e Pelotões de Morteiro Pesado (Pel Mrt P) 120mm orgânicos das Unidades de Infantaria e Cavalaria. Além disso, possibilita a execução de Exercícios de

Planejamento e Coordenação de Fogos no âmbito da Artilharia Divisionária e do Comando de Artilharia de Exército. O foco é a função de combate de fogos, empregando uma mescla de simulação viva, virtual e construtiva.

De acordo com Duarte [3], o simulador possui uma infraestrutura capaz de reproduzir em ambiente virtual os fogos indiretos, com suas respectivas trajetórias balísticas, pontos de impacto e efeitos sobre os alvos. Dessa forma, é possível treinar com os materiais da artilharia de campanha e dos pelotões de morteiro pesado do Exército Brasileiro. Assim, os tipos de exercícios de adestramento no SIMAF são:

- Pelotão de Morteiro Pesado;
- Grupo de Artilharia de Campanha;
- Observadores Avançados dos Grupos de Artilharia de Campanha;
- Observadores Avançados dos Pelotões de Morteiro Pesado;
- Planejamento e Coordenação de Fogos em nível Brigada ou superior.

Segundo Duarte [3], além de proporcionar treinamento técnico, o SIMAF desempenha papel relevante na preparação estratégica das tropas. Ao simular situações complexas e imprevisíveis, contribui para a melhoria da tomada de decisões sob pressão e da capacidade de adaptação a diferentes cenários operacionais. Também colabora com a sustentabilidade das operações militares, reduzindo a necessidade de munições reais e minimizando o impacto ambiental das atividades de treinamento. Como ferramenta alinhada à doutrina atual, o SIMAF reforça o compromisso do Exército Brasileiro com a modernização e a eficiência operacional.

A utilização do SIMAF nos cursos de Artilharia, Infantaria e Cavalaria da AMAN¹ fortalece a formação integral do militar. O simulador, segundo Bridi [6], desenvolve habilidades, estimula o conhecimento e consolida competências essenciais para comandantes de pequenas frações de tropa, como grupos de quatro a dez militares que compõem a guarnição de um armamento de tiro.

O estudo de Bridi [6] apresenta análise quantitativa do impacto do SIMAF, comparando o desempenho dos cadetes antes e após sua utilização. Os dados evidenciam melhorias significativas nas notas, com redução expressiva no número de cadetes em recuperação, especialmente na disciplina Técnicas Militares V, que abrangem conteúdos relacionados à técnica de tiro e à condução do tiro por meio de métodos de observação, os quais empregam equipamentos específicos que auxiliam na coleta de dados e na conversão

¹A Academia Militar das Agulhas Negras (AMAN) é o estabelecimento de ensino superior responsável pela formação dos oficiais combatentes do Exército Brasileiro. Os cursos de Artilharia, Infantaria e Cavalaria integram o currículo da AMAN e preparam os cadetes para o exercício do comando de pequenas frações de tropa em suas respectivas áreas.

dessas informações em cálculos operacionais, essenciais para a execução precisa do tiro. O uso do simulador [6] não apenas aprimorou os resultados acadêmicos, mas também favoreceu o aprendizado em áreas correlatas.

Bridi [6], conclui que o emprego do SIMAF, aliado a metodologias pedagógicas inovadoras, contribuiu para a formação mais eficiente e abrangente dos futuros oficiais da AMAN. O estudo demonstra o valor da simulação como ferramenta de ensino, tanto para consolidar o conhecimento técnico quanto para desenvolver competências necessárias aos oficiais do Exército.

2.4.1 Características

Segundo Fontana [42], destacam-se entre as principais características do SIMAF:

- **Utilização dos três tipos de simulação militar:** Viva (trabalhos de Linha de Fogo em obuseiros sensorizados), Virtual (condução de missões de tiro no Posto de Observação (PO), utilizando optrônicos) e Construtiva (montagem e manipulação de calungas de tropas em carta 2D);
- **Integração dos oito subsistemas de Artilharia:** Observação, Linha de Fogo, Topografia, Direção/Coordenação de Tiro, Busca de Alvos, Logística, Comunicações e Meteorologia; abrangendo desde o nível Batalhão/Regimento até Divisão de Exército;
- **Otimização do uso de munição real:** no qual o militar repete os procedimentos no ambiente virtual diversas vezes antes de finalizar seu aprendizado com o tiro real. Também permite a realização de missões inviáveis no terreno por motivos de segurança, como tiro próximo de tropa amiga ou em área urbana;
- **Montagem da rede lógica e instalação de diversos equipamentos, tais como:** projetores, telões, rádios simulados, interfones, bússolas simuladas, *GPS* simulados, sensores de peças e optrônicos do observador.

No simulador, em cenários variados de terreno, condições meteorológicas e presença de inimigos, é possível realizar:

- Tiro simulado com obuseiros e morteiros pesados, sem restrições de campos de tiro;
- Condução de missões com munições convencionais e especiais, utilizando imagens virtuais, optrônicos com visão noturna e telemetria laser;
- Missões de inteligência e busca de alvos com Sistema Aéreo Remotamente Pilotado (SARP) e radar de contrabateria;

- Exercícios de comunicações;
- Atividades de logística;
- Trabalhos de Estado-Maior, integrando funções de combate;
- Solicitação de apoio de fogo aéreo ou naval.

Ao final de cada exercício, o comandante da fração realiza a Análise Pós-Ação (APA), com relatórios objetivos (sistema) e subjetivos (equipe de instrução), utilizados para corrigir ou ajustar os procedimentos da tropa.

2.4.2 Localização e Infraestrutura



Figura 2.2: Compartimentação da Maquete do SIMAF (Adaptado de Duarte [3]).

O SIMAF [8, 3, 6], ilustrado na Figura 2.2, está instalado e em operação em dois quartéis do Exército no Brasil: na Academia Militar das Agulhas Negras (AMAN), em Resende-RJ; e no Centro de Adestramento-Sul (CA-Sul), em Santa Maria-RS. O sistema integra os seguintes subsistemas:

- *Observador Avançado (OA)*: subsistema localizado em ponto avançado no terreno, a mais de 10 km à frente dos armamentos, responsável pela condução do tiro ao alvo por meio de métodos empíricos, julgamento e técnicas quantitativas, incluindo instrumentos ópticos e medições;
- *Central de Tiro (CTir)*: transforma a mensagem do OA em dados de direção, orientação e controle do tiro;
- *Linha de Fogo (LF)*: recebe as orientações e dados calculados pela CTir, prepara a munição e insere no armamento junto aos dados de tiro;

- *Comunicações (Com)*: realiza a troca de mensagens, interligando os subsistemas de apoio de fogo;
- *Logística (Log)*: responsável pelo pessoal e material de apoio.

A Figura 2.2 mostra o SIMAF 1.0, sistema integrado que combina simulação virtual [40], construtiva [39] e viva [41]. Esses três tipos de simulação estão previstos no Caderno de Instrução Emprego da Simulação EB70-CI-11.441 [1].

Na AMAN, o SIMAF realiza exercícios de adestramento em 27 Organizações Militares espalhadas pelo Brasil, conforme pode ser observado na Figura 2.3, além dos três Cursos de Cadetes: Infantaria, Cavalaria e Artilharia, sediados no próprio estabelecimento de ensino. Para cada exercício, são emitidos relatórios de desempenho e certificações pelos Comandos Militares de Área.

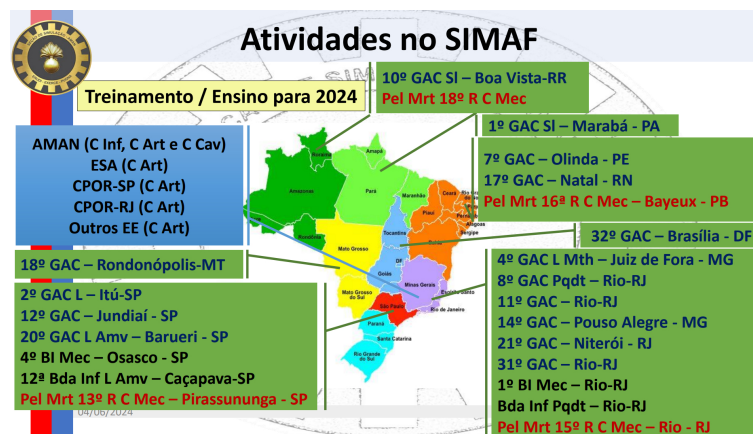


Figura 2.3: Organizações militares de abrangência do SIMAF-AMAN (Adaptado de Duarte [3]).

2.5 Caso de Uso - Simulador SIMAF

Em um trabalho de verificação realizado com a coleta de dados de sensores *IMU* no SIMAF, foi registrado, no Sistema de Acompanhamento de Defeitos [4] da empresa desenvolvedora, um relato de falha que compromete o trabalho da equipe de instrutores em situações de mudança de alvo. A imprecisão dos dados provenientes do sensor *IMU*, conforme discutido anteriormente, afeta de forma aleatória a equipe sempre que a leitura apresenta erro superior a três milésimos, sem possibilidade de identificação prévia desse desvio. Ressalta-se que a limitação descrita, apresentada na Figura 2.4, não inviabiliza totalmente o uso do sensor, desde que seja aceita uma maior tolerância no erro dos resultados dos cálculos.

Descrição do Defeito:

Tanto para a deriva, quanto para a elevação que aparecem no painel da peça, o valor medido deve ser arredondado para a unidade (casas decimais e centesimais não são necessárias. Além de não serem usadas pelo usuário, dão falsa impressão de imprecisão, porque o usuário não consegue a precisão suficiente para zerar as casas decimais e centesimais). Obs: os testes dos sensores de deriva e elevação precisam ser feitos nas peças. Os testes em fábrica não foram conclusivos.

Linha de Fogo_sensor de deriva (avaliação realizada no [REDACTED]); o sensor de deriva NÃO atingiu a precisão adequada para os trabalhos da linha de fogo na avaliação realizada no [REDACTED].

Figura 2.4: Registro no Sistema de Acompanhamento de Defeitos [4].

A descrição do defeito inclui a observação: "Linha de Fogo_sensor de deriva (avaliação realizada no ...): o sensor de deriva não atingiu a precisão adequada para os trabalhos da linha de fogo na avaliação realizada no ...". Essa constatação justifica o desafio central abordado neste trabalho. Em resposta, a Empresa apresentou a comunicação registrada na Figura 2.5. A resposta, baseada em um valor de aceitação não especificado no documento, indica que a precisão é mantida até um giro angular horizontal de cem milésimos, a partir da direção inicial de calibração.

15/12/2015 Linha de Fogo_sensor de deriva (avaliação realizada no [REDACTED]); o sensor de deriva NÃO atingiu a precisão adequada para os trabalhos da linha de fogo na avaliação realizada no [REDACTED]. PERMANECE
Obs: A calibração do giroscópio no Obus M101 garantiu uma precisão em deriva aceitável até uma variação de 100 milésimos a partir da direção inicial de calibração. A calibração em elevação no Obus M101 atingiu precisão aceitável.
Demais materiais não foram testados com giroscópio.

Figura 2.5: Registro da resposta no Sistema de Acompanhamento de Defeitos [4].

Ainda segundo a descrição do defeito, os valores registrados para o sensor em elevação foram considerados satisfatórios, sem detalhamento sobre o erro de aceitação que fundamentou essa decisão. Já em relação ao valor de deriva (direção), a precisão não foi atingida e tampouco foi especificado o parâmetro de referência desejado.

Antes de prosseguir com a exemplificação, torna-se necessário esclarecer o conceito de paralaxe, a fim de contextualizar os erros de leitura. Catelli *et al.* [43] apresentam a paralaxe de forma didática, com ênfase em sua aplicação para medir distâncias astronômicas por meio da paralaxe trigonométrica. O artigo descreve como a variação aparente da posição de uma estrela próxima, em relação às estrelas de fundo, pode ser utilizada para calcular distâncias. Esse processo baseia-se na formação de um triângulo retângulo imaginário entre a Terra, em dois pontos de sua órbita, e a estrela próxima. A paralaxe é o ângulo subtendido pelo raio da órbita terrestre visto da estrela. Os autores propõem duas abordagens para o ensino do conceito: uma atividade geométrica em sala de aula e uma atividade prática de campo, envolvendo fotografia, para medições terrestres por paralaxe.

De modo complementar, Bemm *et al.* [44] descrevem a construção e uso do "Visor de Paralaxe", um instrumento que permite medir ângulos e distâncias entre dois pontos sem a necessidade de acesso direto a ambos. Esse dispositivo é utilizado, por exemplo, para estimar a área de polígonos convexos e constitui uma ferramenta prática tanto para o ensino quanto para aplicações reais. O estudo inclui um experimento de validação da eficiência do visor e destaca o emprego da História da Matemática e investigações geométricas como métodos didáticos. Dessa forma, o visor de paralaxe apresenta a aplicabilidade

do conceito em diferentes contextos, extrapolando a astronomia e alcançando medições terrestres e geométricas.

Assim, pode-se caracterizar o erro de paralaxe, conforme Jeison [45], como a observação equivocada em uma escala graduada, ocasionada por um desvio óptico devido ao ângulo de visão do observador. Dependendo da posição de observação, o instrumento pode apresentar diferentes leituras, o que leva a interpretações distintas. No caso dos instrumentos de medição, esse efeito pode comprometer a exatidão da leitura. Como exemplo ilustrativo, a Figura 2.6 apresenta o medidor de pressão de um extintor de incêndio.



Figura 2.6: O erro de paralaxe ilude o observador, informando necessidade de recarga (Fonte: Elaborado pelo autor).

Após a explanação sobre o erro de paralaxe, ao analisar a limitação existente, observa-se que qualquer exercício de simulação com a restrição de cem milésimos impõe severa limitação operacional. Nessas condições, a equipe de tiro fica restrita a um transporte de pontaria equivalente a quinhentos e noventa metros ($F = 100 * 5,9$), já com tolerância superior à estabelecida em manual, considerando o alvo situado a 5,9 km da linha de fogo. Essa restrição inviabiliza exercícios simulados em ângulos superiores a seiscentos milésimos, ocasião em que o observador deve adotar outra metodologia de cálculo para o transporte de tiro. Nesse ponto, a Fórmula do Milésimo, ilustrada na Figura 2.7, deve ser substituída pelo método do Fator Seno, representado na Figura 2.8.

O método da Fórmula do Milésimo [5] é empregado preferencialmente por simplificar os cálculos em ângulos pequenos. Nesses casos, o erro de paralaxe não exerce influência relevante na prática. A aplicação desse método proporciona rapidez na pronta resposta do Observador e reduz a exposição do militar, o que diminui o risco de detecção e preserva o fator surpresa diante do inimigo.

Por outro lado, o método do Fator Seno apresenta desvantagens em comparação à Fórmula do Milésimo. Além da maior complexidade, exige que o militar memorize valores em condições de fadiga ou utilize a tabela do Fator Seno durante a execução da missão, aumentando o tempo necessário para a resposta. Essa característica pode comprometer a eficiência da operação, conforme ilustrado na Figura 2.8.

Outro dado de imprecisão refere-se ao giro horizontal. A justificativa da empresa registra: "Após realizar várias mudanças na orientação, alternando giros curtos (50 ou 100

2) Cálculo da frente quando o desvio angular entre dois pontos é inferior a 600'':

EXEMPLO – Suponhamos que o ponto de referência está a 2400 metros do observador e que um alvo surgiu 300'' à direita. Por meio da fórmula do milésimo chega-se ao valor da distância da frente (F):




Figura 2.7: Transporte pela Fórmula do Milésimo (Fonte: Caderno de Instrução "O Levantamento Topográfico Eletrônico"[5]).

3) Cálculo da frente quando o desvio angular entre dois pontos é maior que 600'':

Ângulo em milésimos (n)	Fator seno (f)
600	0,6
700	0,6
800	0,7
900	0,8
1.000	0,8
1.100	0,9
1.200	0,9
1.300 ou superior	1,0

EXEMPLO – Suponhamos que o ponto de referência está a 2500 metros do observador e que um alvo surgiu 900'' à direita. Utilizando-se o fator seno chega-se ao valor da distância da frente (F).




Figura 2.8: Transporte pelo Fator Seno (Fonte: Caderno de Instrução "O Levantamento Topográfico Eletrônico"[5]).

milésimos) com giros longos (200 ou 300 milésimos), o maior erro detectado foi de três milésimos". Deduz-se, a partir desses testes, que o sensor de orientação da peça, após a calibração, mostrou-se suficientemente sensível para mensurar corretamente a orientação no simulador. No entanto, os erros detectados são resultantes da soma do erro do giroscópio, do erro do goniômetro da peça e do erro humano ao apontar o goniômetro. Esse resultado supera o erro máximo permitido no manual, que é de 2 milésimos, em contraste com os 3 milésimos obtidos no teste, conforme a Figura 2.9.

Después se realizaron varios cambios en la orientación, alternando giros cortos (50 ó 100º) con giros largos (200 ó 300º), en los cuales el máximo error detectado fueron 3º. Se deduce de estas pruebas que, después de calibrar, el comportamiento del sensor de orientación de la pieza es suficientemente sensible como para medir correctamente la orientación de la pieza del simulador, teniendo en cuenta que los errores obtenidos en las pruebas son una suma del error de giroscopio del sensor, más el error del goniómetro de pieza, más el error humano al apuntar el goniómetro.

Figura 2.9: Registro do teste da empresa no Sistema de Acompanhamento de Defeitos [4].

Como agravante, observa-se a derivação constante apresentada por sensores inerciais

de baixo custo. Esse fenômeno decorre do acúmulo de resíduos gerados pela influência eletromagnética de massas metálicas próximas. Tal característica inviabiliza o grau de confiabilidade que o instrutor pode atribuir aos dados dos sensores, especialmente em contextos de prova, nos quais o valor medido pelo sensor é confrontado com o resultado obtido pelo instruendo.

Adicionalmente, não foram realizados testes de persistência dos valores dos sensores ao longo do tempo, aspecto que necessita de avaliação. Para suprir essa lacuna, será elaborado e encaminhado aos militares instrutores que utilizam o simulador para a certificação da tropa um documento formalizando as necessidades de informações quanto à inconstância dos valores registrados, em especial na variável de deriva (direção). Essa medida tem por objetivo oficializar a calibração periódica, atualmente conduzida de forma extraoficial, a fim de mitigar o erro de derivação acumulado ao longo do tempo, além de solicitar esclarecimentos sobre o grau de aceitação mencionado anteriormente.

2.6 Limitações do SIMAF

Na Linha de Fogo, ilustrada na Figura 2.10, observa-se um armamento equipado com sensores do tipo Unidade de Medição Inercial (do inglês *Inertial Measurement Unit-IMU*) e Sistemas Embarcados (do inglês *Embedded Systems-ES*). O fio ligado ao quebra-chamas, ou à boca do tubo, conecta-se ao sensor *IMU*, responsável pela coleta dos valores de direção e elevação do armamento de dotação de uma determinada Organização Militar.



Figura 2.10: Exemplo de Obuseiro sensorizado (Adaptado do CA-Sul [2]).

De acordo com o manual Técnica de tiro de Artilharia de Campanha [19], nos armamentos utilizados na Linha de Fogo (LF) da Artilharia de Campanha, a pontaria é realizada por meio de instrumentos ópticos e ajustes manuais, caracterizando uma operação de natureza analógica. Segundo Bridi, [6], no treinamento da equipe da Linha de Fogo, o adestramento com o SIMAF deve respeitar os procedimentos adotados no ar-

mamento real, de modo que a pontaria, mesmo em ambiente virtual, seja realizada da forma tradicional, como ocorre na linha de fogo real. Assim, o tiro virtual, com balística simulada, mantém a coerência com a representação real. Para tanto, utilizam-se sensores inerciais com giroscópio, acelerômetro e magnetômetro, responsáveis por coletar informações e enviá-las ao simulador. É necessário, portanto, aprimorar a estabilização desses sensores, a fim de viabilizar avaliações mais longas de erros humanos em exercícios.

Devido à necessidade de conduzir exercícios com múltiplos problemas militares simulados de forma contínua, como se fosse no emprego de armamento real em exercícios com munição real, por dedução óbvia, exige-se maior confiabilidade nos dados do sensor, sem que haja derivações que atrapalhem a continuidade do treinamento. Por exemplo: um pelotão inimigo aproxima-se de uma estação de tratamento de água essencial para as cidades em linhas amigas. Após cumprir a missão de neutralizá-lo, o instrutor pode emitir uma nova missão imediatamente, gerando diversas operações subsequentes. Esse tipo de continuidade, comum em situações reais, exige a evolução do sistema para que a simulação acompanhe a complexidade operacional.

Para exercícios de maior duração, a falta de confiabilidade nos dados coletados pelos sensores obriga a equipe de instrutores a designar um militar por armamento apenas para realizar a leitura analógica e inseri-la manualmente no simulador. Esse procedimento aumenta a possibilidade de erro humano externo ao militar avaliado.

O Capítulo 3 apresenta a base teórica que fundamenta a pesquisa, explorando conceitos essenciais e revisando a literatura. A função crucial dos sensores inerciais é detalhada, com ênfase em suas características, aplicações e desafios, como a presença de ruídos. São discutidas técnicas de filtragem e algoritmos de aprendizado de máquina, demonstrando como essas abordagens podem melhorar a precisão e a estabilidade dos dados sensoriais.

Capítulo 3

Sensores e Aprendizado de Máquina

Este capítulo apresenta a base teórica que fundamenta a pesquisa e os trabalhos relacionados, com foco nos desafios referentes aos ruídos indesejáveis em sensores inerciais, técnicas de filtragem e remoção de ruídos, e a aplicação de algoritmos de aprendizado de máquina para estabilização dos dados. A revisão bibliográfica explora a natureza dos ruídos nos sensores *IMUs*, as técnicas tradicionais de filtragem, como o Filtro de Kalman, e aborda a finalidade das redes neurais recorrentes, especificamente *LSTM*, na melhoria da precisão e estabilidade dos dados sensoriais.

3.1 Tempo Necessário

Segundo Martins [46], o termo é definido como a realização de tarefas cuja duração seja adequada, mas não necessariamente instantânea. Neste contexto, o termo "tempo necessário" foi muito utilizado neste trabalho com o mesmo significado de tempo adequado para uma finalidade específica.

Após verificar a documentação do SIMAF, no tocante ao sensor de pontaria, não foi encontrada nenhuma exigência quantitativa sobre mensuração de tempo, o que resta apenas a análise qualitativa. Nesta abordagem, a passagem dos dados pelos filtros e pelo modelo LSTM gera um pequeno atraso perceptível quando o sensor é agitado rapidamente com as mãos, gerando uma ligeira defasagem na reação gráfica do armamento virtual. No entanto, como o sensor é para ser usado acoplado ao tubo do armamento real, uma estrutura metálica pesada, cujo movimento é naturalmente lento durante a mudança de pontaria, não foi observado atraso visual perceptível entre o movimento do armamento real e o correspondente movimento virtual. Ainda que não haja percepção de atraso, não é correto usar o termo "tempo real" para a solução, mas sim, "tempo necessário".

3.2 Sensores Inerciais

Segundo Groves [47], o modelo matemático de uma Unidade de Medição Inercial (do inglês *Inertial Measurement Unit-IMU*), composta por acelerômetro, giroscópio e magnetômetro, pode ser representado pelas seguintes equações no espaço tridimensional R^3 . Os sensores não medem diretamente o estado verdadeiro, mas sim uma versão afetada por ruído e bias.

Acelerômetro

$$\mathbf{f}_m(t) = \mathbf{a}(t) - \mathbf{g}(t) + \mathbf{b}_f + \mathbf{n}_f$$

onde:

- $\mathbf{f}_m(t)$ é a aceleração específica medida pelo acelerômetro;
- $\mathbf{a}(t)$ é a aceleração linear total do corpo (incluindo a gravidade);
- $\mathbf{g}(t)$ é o vetor da aceleração gravitacional;
- \mathbf{b}_f é o bias (desvio) do acelerômetro;
- \mathbf{n}_f é o ruído branco gaussiano.

Giroscópio

$$\boldsymbol{\omega}_m(t) = \boldsymbol{\omega}(t) + \mathbf{b}_\omega + \mathbf{n}_\omega$$

onde:

- $\boldsymbol{\omega}_m(t)$ é a velocidade angular medida;
- $\boldsymbol{\omega}(t)$ é a velocidade angular verdadeira do corpo;
- \mathbf{b}_ω é o bias do giroscópio;
- \mathbf{n}_ω é o ruído branco do giroscópio.

Para estimar a orientação ao longo do tempo, a variação angular pode ser integrada:

$$\boldsymbol{\theta}(t) = \boldsymbol{\theta}(t_0) + \int_{t_0}^t \boldsymbol{\omega}_m(\tau) d\tau$$

ou, em forma discreta (incremental):

$$\theta_{gyro} = \theta_{est} + \Delta\theta_{gyro}$$

Magnetômetro

$$\mathbf{m}_m(t) = \mathbf{m}(t) + \mathbf{b}_m + \mathbf{n}_m$$

onde:

- $\mathbf{m}_m(t)$ é o vetor do campo magnético medido;
- $\mathbf{m}(t)$ é o campo magnético terrestre verdadeiro no local;
- \mathbf{b}_m é o bias do magnetômetro;
- \mathbf{n}_m é o ruído do sensor.

A Unidade de Medição Inercial (do inglês *Inertial Measurement Unit-IMU*) é um dispositivo eletrônico que mede velocidade angular, aceleração e, em alguns casos, campo magnético de um corpo. Os sensores *IMUs* são utilizados em diversas aplicações que requerem informação precisa sobre o movimento e a orientação do corpo [48], como em sistemas de navegação para veículos, aeronaves e drones, assim como em dispositivos de rastreamento de movimento para Realidade Virtual (do inglês *Virtual Reality-VR*) e em dispositivos vestíveis para monitoramento de atividades físicas.

A definição de um sensor *IMU* é apresentada por Ahmed E. Mahdi [25] como um Sistema de Navegação Inercial que fornece tanto acelerações quanto taxas angulares. As *IMUs* são componentes cruciais para obter uma solução de navegação contínua em várias aplicações e dependem, principalmente, da qualidade e do grau da própria *IMU*.

Segundo Groves [47], o grau de uma *IMU* é determinado pela precisão, estabilidade e nível de ruído dos sensores de aceleração e rotação que a compõem. Essa classificação é tradicionalmente dividida em três categorias principais:

- **Grau industrial (*industrial grade*)** – *IMUs* dessa categoria são utilizadas em aplicações comerciais que demandam precisão moderada e boa robustez ambiental, como máquinas industriais, robótica civil e automação. Possuem deriva relativamente controlada (entre 1 e 10°/h) e boa estabilidade de *bias*, permitindo medições estáveis por períodos intermediários sem necessidade de recalibração constante;
- **Grau tático (*tactical grade*)** – com maior precisão e estabilidade, essas *IMUs* são empregadas em sistemas militares, navais e de navegação aérea. Apresentam baixos níveis de ruído, deriva reduzida (tipicamente abaixo de 1°/h) e excelente compensação térmica, sendo capazes de operar por longos períodos sem referência externa. São amplamente utilizadas em mísseis, aeronaves e plataformas estabilizadas;
- **Grau de navegação (*navigation grade*)** – representam o nível mais alto de desempenho entre as *IMUs* descritas por Groves. Possuem deriva extremamente

reduzida (abaixo de $0,01^\circ/\text{h}^1$), estabilidade excepcional e erros de *bias* mínimos. São encontradas em sistemas de navegação inercial de alta precisão, como submarinos, foguetes e satélites, nos quais a confiabilidade absoluta é requisito essencial.

Segundo Ahmed E. Mahdi [25], a *IMU* é formada por três acelerômetros, que medem forças específicas, e três giroscópios, que medem taxas angulares. Estes componentes são essenciais para o funcionamento do *INS*, permitindo a atualização do estado atual do alvo (posição, velocidade e atitude) com base no conhecimento dos estados iniciais.

De acordo com Han *et al.* [23], a precisão e a confiabilidade dos dados fornecidos por sensores IMU são fundamentais para uma ampla gama de aplicações, incluindo simuladores que requerem alta precisão, como é o foco deste trabalho. Também segundo Mundt *et al.* [30], a utilidade desses dados é frequentemente comprometida pela presença de ruído e imprecisões inerentes aos dispositivos de sensoriamento. Há necessidade de calibração precisa e de procedimentos confiáveis para alcançar níveis aceitáveis de repetibilidade e precisão na estimativa dos dados provenientes de sensores inerciais.

Os ruídos indesejáveis em *IMUs* representam um desafio complexo e relevante para diversas aplicações práticas. Segundo Groves [47], a estabilização eficaz desses sensores constitui uma área de pesquisa contínua, necessária para mitigar ruídos e compensar imprecisões inerentes a esses dispositivos. Segundo o autor [47], esforços devem ser direcionados ao aprimoramento dos métodos de calibração e filtragem, assegurando que as *IMUs* ofereçam leituras consistentes e precisas, fundamentais para o sucesso das operações em que são empregadas, incluindo navegação de aeronaves e espaçonaves, armas guiadas, submarinos, veículos terrestres e sistemas de levantamento geodésico e topográfico, quando integrados com o Sistema Global de Navegação por Satélite (do inglês *Global Navigation Satellite System-GNSS*). À medida que as demandas por precisão aumentam, o avanço nas técnicas de estabilização desses sensores torna-se não apenas desejável, mas essencial. Essa busca por refinamento aprimora o desempenho das *IMUs* e amplia sua aplicabilidade em contextos cada vez mais complexos e exigentes.

3.3 Ruídos Indesejáveis

Para efeito de estudos aplicados neste trabalho, foram utilizados sensores de baixo custo baseados em Sistemas Microeletromecânicos (do inglês *Micro-Electro-Mechanical Systems-MEMS*). Dispositivos dessa classe, como o módulo GY-87, são voltados a aplicações experimentais, educacionais ou de prototipagem, que segundo Han [23], *MEMS*, são muito

¹A unidade $^\circ/\text{h}$ representa graus por hora e indica a taxa de deriva angular ao longo do tempo, sendo amplamente utilizada na caracterização do desempenho de giroscópios e sensores inerciais.

suscetíveis a erros aleatórios provocados por fatores como as variações de pressão atmosférica, que afetam diretamente o sensor barométrico do módulo, alterando as medições de altitude e ocasionando pequenas flutuações nas leituras de aceleração devido à deformação dos elementos sensoriais de silício. As vibrações mecânicas [23], por sua vez, introduzem ruídos dinâmicos no acelerômetro e no giroscópio, pois provocam microoscilações estruturais no *chip* sensorial, confundindo o movimento real do corpo com perturbações externas. Já as interferências eletromagnéticas [23], provenientes de motores, cabos de energia ou massas metálicas próximas, afetam o magnetômetro (HMC5883L), distorcendo o campo magnético medido e comprometendo a determinação da direção.

Adicionalmente, segundo Gao [49], os giroscópios podem sofrer erros aleatórios devido a variações de temperatura, ruído eletrônico e imprecisões de fabricação. Esses erros podem causar desvios nos dados medidos e levar a representações imprecisas do movimento ou da orientação, causados por *bias* e ruídos gaussianos, matematicamente explicados na Seção 3.2.

Esses efeitos combinados distorcem as leituras, afetando diretamente a qualidade dos dados, introduzindo erros que reduzem o desempenho de sistemas de navegação e controle. Em sistemas autônomos e aplicações de realidade aumentada, a precisão na percepção do ambiente e na determinação da orientação é fundamental. Mesmo pequenos desvios na estimativa de orientação podem acumular-se ao longo do tempo, resultando em erros significativos na trajetória estimada e comprometendo a eficácia e a segurança dos sistemas.

De acordo com Shaghaghian [50], a interferência em determinadas faixas de frequência, proveniente de fontes externas, como sinais eletromagnéticos, ou do próprio sensor, como o ruído inerente ao processo de medição, pode ser atenuada por meio de um Filtro de Kalman Adaptativo (*Adaptive Kalman Filter-AKF*), que ajusta dinamicamente os pesos (ou as matrizes de covariância) de acordo com as características do ruído, atribuindo menor influência às frequências mais ruidosas e, assim, melhorando a precisão das estimativas.

Ainda segundo Shaghaghian [51], a interferência em faixas específicas de frequência, tanto de origem externa (p. ex., interferência eletromagnética) quanto interna (ruído do sensor), pode ser mitigada por meio de um Filtro de Kalman Ponderado por Frequência (*Frequency-weighted Kalman Filter-FWKF*), que introduz ponderações no domínio da frequência para reduzir a contribuição das bandas mais ruidosas, aumentando a acurácia das estimativas.

Por fim, segundo Hosseinyalamdary [26], ao integrar dados de múltiplos sensores, diferentes tipos de interferência podem afetar cada dispositivo de forma distinta. Em [26], um sensor pode ser mais suscetível a interferência eletromagnética, enquanto outro pode ser influenciado por ruído térmico. A integração de sensores busca mitigar esses efeitos, combinando dados de várias fontes para gerar estimativas mais robustas e precisas.

De acordo com Hosseinyalamdary [26], as causas da derivação constantes entre a orientação real do objeto e a estimada podem levar a erros persistentes que se acumulam com o tempo. Oscilações nas medições, em [26], também podem surgir quando o sistema tenta corrigir continuamente erros acumulados, ocasionando flutuações indesejadas nas estimativas de atitude. Segundo Valenti *et al.* [22], esse comportamento instável é especialmente problemático em aplicações que exigem alta precisão e estabilidade, como veículos autônomos e sistemas de controle de voo. Entre as causas identificadas, destacam-se:

1. **Interferências eletromagnéticas [22]:** campos externos que perturbam os sinais dos sensores. Podem ser provocados por outros dispositivos eletrônicos ou por massas metálicas próximas, resultando em medições inconsistentes e imprecisas;
2. **Desvios de *offset* [23]:** erros constantes que geram desvios nas leituras angulares. Esses erros sistemáticos acumulam-se ao longo do tempo, ampliando a diferença entre a orientação real e a estimada;
3. **Ruído de quantização [23]:** erros introduzidos durante a digitalização dos sinais analógicos, causados pela limitação da resolução do conversor analógico-digital (ADC), que não capta variações muito pequenas nos sinais;
4. **Erros de calibração [23]:** imprecisões que surgem durante o processo de calibração. A calibração inadequada gera leituras distorcidas e prejudica a precisão das estimativas de atitude.

A mitigação desses ruídos exige compreensão aprofundada dos mecanismos que os produzem, bem como o desenvolvimento de métodos adequados de identificação e compensação. Técnicas de processamento de sinal, como filtragem passa-baixa para redução de ruído de alta frequência [47], filtragem passa-alta para compensação de deriva [47], suavização por média móvel [47], e transformadas no domínio da frequência [47], aliadas a algoritmos de filtragem e correção, como o Filtro de Kalman [52, 47], desempenham papel crucial na melhoria da qualidade dos dados dos sensores IMU, permitindo aplicações mais precisas e confiáveis.

Portanto, os ruídos nos sensores *IMU* evidenciam a necessidade de abordagens inovadoras para tratamento dessas interferências externas, visando à otimização do desempenho de dispositivos e sistemas que dependem criticamente da acurácia e da confiabilidade das medições de movimento.

3.4 Filtro de Fusão e Remoção de Ruídos

Segundo Valenti *et al.* [22], a principal vantagem do Filtro de Fusão e Remoção de Ruídos está na simplicidade e eficácia em comparação com outras técnicas, como o Filtro de Kalman Estendido (do inglês *Extended Kalman Filter-EKF*). O *EKF* é uma adaptação do Filtro de Kalman clássico projetada para lidar com sistemas não lineares, ajustando as estimativas de estado de forma aproximada, porém com maior custo computacional. O autor demonstra que o Filtro de Fusão e Remoção de Ruídos é adequado para aplicações em tempo de execução, pois fornece estimativas confiáveis de atitude com baixo custo computacional. Mostra também que combina dados de diferentes sensores, como acelerômetros e giroscópios, de forma eficiente, resultando em estimativas mais precisas da orientação do objeto. Segundo Han *et al.* [23], assim, é especialmente útil em sistemas que requerem respostas rápidas e confiáveis, como em Veículo Aéreo Não Tripulado (VANT), aeronaves sem piloto, ou outros sistemas de navegação inercial, como robôs ou carros autônomos, nos quais é essencial manter a estabilidade e a precisão das leituras sensoriais sem sobrecarregar o processamento.

Essa eficiência, conforme Valenti *et al.* [22], decorre da arquitetura do filtro, que aplica filtragem passa-alta aos dados do giroscópio e filtragem passa-baixa aos dados do acelerômetro e do magnetômetro. No contexto deste projeto, em que a estabilização dos dados de sensores *IMUs* de baixo custo é indispensável, o Filtro de Fusão e Remoção de Ruídos garante confiabilidade e precisão. O processo de cálculo da Estimativa de Ângulo é composto por:

a. Inicialização: Definir uma estimativa inicial do ângulo θ_{est} , que no início do processo é igual a zero:

$$\theta_{est} \Leftrightarrow 0: \text{Estimativa inicial do ângulo.}$$

Independentemente do alinhamento físico do sistema, o filtro assume que a orientação inicial é desconhecida ou de repouso, podendo ser considerada zero. Esse procedimento simplifica a medição inicial e a calibração de outros filtros, permitindo maior rapidez na execução do processo de estimativa.

b. Para cada nova medição (iterações): O filtro processa os dados do giroscópio e do acelerômetro para atualizar continuamente a estimativa do ângulo, conforme a Equação 3.1, a Equação 3.2 e a Equação 3.3 a seguir.

1. Integração da taxa de rotação do giroscópio para obter a variação do ângulo:

$$\Delta\theta_{gyro} = \omega_{gyro} \cdot \Delta t \quad (3.1)$$

onde:

- $\Delta\theta_{gyro}$ é a variação do ângulo estimada a partir da leitura do giroscópio, medida em radianos ou graus;
- ω_{gyro} é a taxa de rotação angular medida pelo giroscópio, em rad/s ou °/s;
- Δt é o intervalo de tempo de cálculo da variação, medido em segundos.

A integração da taxa de rotação permite calcular a variação angular do sistema desde a última medição. Esse valor é fundamental para ajustar a estimativa do ângulo em cada movimento, com base na leitura inercial fornecida pelo giroscópio.

2. Atualização da estimativa do ângulo com base na leitura do giroscópio:

$$\theta_{gyro} = \theta_{est} + \Delta\theta_{gyro} \quad (3.2)$$

onde:

- θ_{gyro} é o ângulo estimado atual baseado na leitura do giroscópio, após a atualização;
- θ_{est} é a estimativa anterior antes da atualização;
- $\Delta\theta_{gyro}$ é a variação do ângulo calculada com base na leitura do giroscópio.

Assim, a estimativa do ângulo é ajustada com a variação calculada, refletindo a nova posição angular do sistema. O valor anterior recebe o incremento proporcional ao movimento detectado.

3. Cálculo da estimativa final do ângulo:

$$\theta_{est} = \alpha \cdot \theta_{gyro} + (1 - \alpha) \cdot \theta_{acc} \quad (3.3)$$

onde:

θ_{est} : Estimativa final do ângulo combinando as leituras do giroscópio e do acelerômetro.

α : Coeficiente que define o peso atribuído à leitura do giroscópio.

θ_{gyro} : Ângulo estimado com base no giroscópio.

$(1 - \alpha)$: Coeficiente que define o peso atribuído à leitura do acelerômetro.

θ_{acc} : Ângulo estimado com base no acelerômetro.

Nesta fase, é realizado o cálculo da estimativa final do ângulo utilizando uma combinação ponderada das leituras do giroscópio e do acelerômetro. O parâmetro α ajusta a

influência de cada sensor na estimativa final. Em particular, α define o peso dado à leitura do giroscópio em relação ao acelerômetro. Valores típicos de α variam de acordo com as características dos sensores e as exigências da aplicação [22]. Em geral, α é ajustado entre 0,01 e 0,99. Valores próximos de 1 atribuem maior peso ao giroscópio, enquanto valores próximos de 0 aumentam a influência do acelerômetro.

Segundo David Titterton e Weston [53], o Filtro de Fusão e Remoção de Ruídos é descrito como um método que combina as leituras do giroscópio e do acelerômetro por meio de operações aritméticas básicas, como a soma ponderada das leituras. Essas operações envolvem apenas multiplicações e adições simples, sem necessidade de cálculos matriciais complexos. Os autores destacam que a complexidade do filtro é $O(1)$, pois cada nova amostra exige apenas operações constantes e diretas.

Higgins [54] aborda explicitamente a comparação entre a complexidade do Filtro de Fusão e Remoção de Ruído e a do Filtro de Kalman. O trabalho aponta que o primeiro é mais simples porque requer menos cálculos em relação ao KF , que depende da solução da equação de Riccati e do cálculo dos ganhos de Kalman. Em [54], a equação de Riccati é uma relação diferencial que descreve a evolução da matriz de covariância do erro no tempo, sendo responsável por ajustar o ganho do filtro para minimizar a incerteza da estimativa. Essa diferença de complexidade confere ao filtro a vantagem de maior simplicidade e rapidez de execução, especialmente em sistemas que necessitam de altas taxas de atualização, como pouso automático ou navegação inercial.

Por fim, devido à simplicidade estrutural, é possível implementar o filtro como parte do código em um Sistema Embarcado - ES de baixo poder computacional. Essa implementação possibilita a execução eficiente das operações de fusão de dados e remoção de ruídos diretamente no módulo embarcado, otimizando o desempenho e a precisão na estimativa dos estados do sistema. Além disso, contribui para reduzir a carga de processamento em outros componentes, permitindo que o ES opere de forma contínua e em tempo necessário, mesmo em cenários complexos e dinâmicos.

3.5 Filtro de Kalman (KF)

Segundo Montella [55], o KF encontra aplicação em diversos campos, como análise de sinal, controle de voo espacial e robótica, sendo amplamente reconhecido como um algoritmo subótimo para a estimação de estados de sistemas dinâmicos sob incerteza. De acordo com Groves [47], esse filtro é fundamentado no princípio da estimativa de estado Bayesiana, no qual as probabilidades a priori e a posteriori são combinadas de forma recursiva para produzir a estimativa mais provável do estado do sistema, utilizando um

modelo de transição linear e assumindo que os ruídos do processo e das medições seguem uma distribuição gaussiana.

O trabalho [55] detalha o funcionamento do KF , apresentando suas duas fases principais. A primeira é a fase de predição (ou atualização de tempo), na qual o estado do sistema é projetado para o instante de tempo seguinte. A segunda é a fase de correção (ou atualização de medição), em que as observações coletadas são incorporadas para ajustar a estimativa do estado. O artigo enfatiza a relevância da matriz de ganho de Kalman, peça central para minimizar o erro quadrático médio na estimativa do estado.

Montella [55] também discute a complexidade computacional do KF , bem como sua correção e precisão. O autor destaca que, sob as premissas do modelo, o filtro oferece a estimativa mais precisa possível do estado do sistema. Além disso, a pesquisa aborda variantes do KF , como o Filtro de Kalman Estendido (*Extended Kalman Filter-EKF*), capaz de lidar com sistemas dinâmicos não lineares, e o Filtro de Partículas, uma abordagem não paramétrica adequada para sistemas não lineares e não gaussianos. O artigo inclui uma comparação entre os diferentes filtros, acompanhada de um exemplo prático em navegação robótica, ilustrando diferenças de complexidade, precisão e aplicabilidade.

De acordo com David A. Forsyth e Jean Ponce em [56], o KF é descrito como um método recursivo voltado para sistemas lineares variantes no tempo. Trata-se de uma teoria e algoritmo de estimação ótima, aplicável a sistemas dinâmicos sujeitos a interferências aleatórias. Em cada iteração do filtro, ocorrem atualizações de tempo e estado, organizadas em dois *loops*: um responsável pelo cálculo do filtro e outro pelo cálculo do ganho. Essa estrutura permite atualizar a estimativa do estado *a posteriori* a partir do estado *a priori*, considerando o vetor de controle e as medições disponíveis.

No escopo deste estudo, o KF foi implementado para aprimorar a precisão da estimativa de estado do sistema simulado, com foco no rastreamento do movimento e da orientação do tubo de um obuseiro durante disparos e ajustes de mira. O modelo segue a estrutura padrão descrita no KF , aplicando as equações de atualização para prever e corrigir o estado a partir das medições recebidas. O filtro foi concebido para lidar com ruídos presentes tanto nas medições quanto nas dinâmicas do sistema, oferecendo robustez no rastreamento preciso de estados em ambientes incertos e variáveis.

Para melhor compreensão, apresenta-se uma formulação matemática detalhada do funcionamento do filtro, acompanhada de explicação passo a passo para estimar o estado de um sistema dinâmico linear no tempo, sujeito à interferência aleatória.

Modelo Dinâmico: Esse modelo é representado por duas equações fundamentais: a equação de transição de estado e a equação de medição. Ambas estão baseadas em distribuições normais, que modelam as incertezas no processo e nas medições. As variáveis de estado \mathbf{x}_i seguem uma distribuição normal, conforme a Equação 3.4:

$$\mathbf{x}_i \sim \mathcal{N}(\mathbf{D}_i \mathbf{x}_{i-1}, \Sigma_{di}) \quad (3.4)$$

onde:

- \mathbf{x}_i representa o estado atual, normalmente distribuído, com média $\mathbf{D}_i \mathbf{x}_{i-1}$ e covariância Σ_{di} . No contexto deste estudo, esse estado pode indicar a orientação e a posição do tubo do obuseiro em determinado instante;
- \mathbf{D}_i é a matriz de transição de estado, responsável por propagar o estado anterior \mathbf{x}_{i-1} para o estado atual \mathbf{x}_i , de acordo com a dinâmica do sistema modelado. Essa matriz descreve como as variáveis de estado evoluem ao longo do tempo, podendo incluir dependências entre posição, velocidade e orientação, conforme o modelo físico adotado;
- Σ_{di} é a covariância associada ao processo, refletindo a incerteza do modelo de transição, a qual pode ser influenciada por vibrações e variações de calibração dos sensores.

As variáveis de medição \mathbf{y}_i também seguem uma distribuição normal, de acordo com a Equação 3.5:

$$\mathbf{y}_i \sim \mathcal{N}(\mathbf{M}_i \mathbf{x}_i, \Sigma_{mi}) \quad (3.5)$$

onde:

- \mathbf{y}_i é a medição observada, relacionada ao estado atual \mathbf{x}_i . Um exemplo é a leitura do ângulo de elevação do tubo do obuseiro fornecida pelos sensores;
- \mathbf{M}_i é a matriz de medição, que conecta o estado do sistema às observações realizadas, convertendo a orientação do tubo em dados observáveis;
- Σ_{mi} é a covariância das medições, representando a incerteza das leituras dos sensores, causada por interferências externas ou limitações dos instrumentos.

Pressupostos Iniciais: Para dar início ao processo, assume-se que os valores iniciais estimados do estado e da covariância são representados por \mathbf{x}_0^- e Σ_0^- , respectivamente. Esses valores são definidos com base nas condições iniciais do sistema, como a posição e a orientação do tubo antes de qualquer movimento. Nesse cenário, considera-se o tubo do obuseiro no estado neutro, com a bolha de nível centralizada em elevação e a direção alinhada ao chassi.

Equações de Atualização: O processo de atualização é estruturado em duas etapas principais: a etapa de previsão e a etapa de correção. Ambas são aplicadas de forma iterativa, de modo a ajustar continuamente as estimativas do estado ao longo do tempo.

Na etapa de **previsão**, são calculadas as estimativas *a priori* do estado e da covariância. Essas estimativas representam o valor previsto antes da incorporação de novas medições e são expressas pelas Equações 3.6 e 3.7:

$$\mathbf{x}_i^- = \mathbf{D}_i \mathbf{x}_{i-1}^+ \quad (3.6)$$

$$\Sigma_i^- = \mathbf{D}_i \Sigma_{i-1}^+ \mathbf{D}_i^T + \Sigma_{di} \quad (3.7)$$

onde:

- \mathbf{x}_i^- : estimativa *a priori* do estado atual, obtida pela propagação do estado anterior;
- \mathbf{x}_{i-1}^+ : estimativa corrigida do estado no instante anterior, já atualizada com base nas medições anteriores;
- \mathbf{D}_i : matriz de transição de estado, responsável por projetar o estado anterior para o instante atual;
- Σ_i^- : covariância *a priori*, que representa a incerteza associada à previsão do estado;
- Σ_{i-1}^+ : covariância corrigida no instante anterior, incorporando as medições anteriores;
- Σ_{di} : covariância do processo, associada às incertezas inerentes ao modelo de transição.

Na etapa de **correção**, as estimativas obtidas na previsão são ajustadas a partir das medições atuais. O ganho de Kalman, responsável pela ponderação entre o valor previsto e o valor observado, é calculado conforme a Equação 3.8. Em seguida, as Equações 3.9 e 3.10 realizam a atualização do estado e da covariância corrigidos, respectivamente:

$$\mathbf{K}_i = \Sigma_i^- \mathbf{M}_i^T (\mathbf{M}_i \Sigma_i^- \mathbf{M}_i^T + \Sigma_{mi})^{-1} \quad (3.8)$$

$$\mathbf{x}_i^+ = \mathbf{x}_i^- + \mathbf{K}_i (\mathbf{y}_i - \mathbf{M}_i \mathbf{x}_i^-) \quad (3.9)$$

$$\Sigma_i^+ = (\mathbf{I} - \mathbf{K}_i \mathbf{M}_i) \Sigma_i^- \quad (3.10)$$

- \mathbf{K}_i : ganho de Kalman, que determina o peso dado às medições em relação à previsão;
- \mathbf{M}_i : matriz de medição, que relaciona o vetor de estado com o espaço das observações;

- \mathbf{M}_i^T : transposição da matriz de medição;
- \mathbf{y}_i : vetor de medições fornecido pelos sensores no instante i ;
- \mathbf{x}_i^- : estimativa *a priori* do estado, obtida na etapa de previsão;
- \mathbf{x}_i^+ : estimativa corrigida do estado, ajustada com base nas medições atuais;
- Σ_i^- : covariância *a priori*, herdada da etapa de previsão;
- Σ_i^+ : covariância corrigida, que reflete a nova incerteza após a atualização;
- Σ_{mi} : covariância das medições, associada à incerteza dos sensores;
- \mathbf{I} : matriz identidade, que preserva a dimensionalidade do sistema.

Essas etapas são aplicadas de forma iterativa, ajustando continuamente as estimativas do estado e da covariância com base nas medições disponíveis. Esse processo garante que o sistema se adapte dinamicamente a diferentes cenários e incertezas operacionais, mantendo a coerência da estimativa em cada ciclo de atualização.

3.5.1 Análise da Complexidade do Filtro de Kalman

Para que não haja prejuízos ou retrabalho durante a implementação, é necessária a realização de um estudo prévio de esforço computacional, que serve como subsídio para a escolha do *hardware* mais adequado à execução do algoritmo *KF*. A complexidade computacional do filtro pode ser analisada em duas fases principais: a fase de previsão e a fase de correção. Essa abordagem é discutida por Montella [55] e corroborada por Higgins [54], bem como por Titterton e Weston [53]. A seguir, detalha-se a complexidade das operações em cada fase.

Fase de Previsão ^{3.5}:

Na fase de previsão, o filtro de Kalman projeta o estado e a covariância para o próximo instante de tempo com base no modelo do sistema. As principais operações incluem:

1. **Previsão do Estado** (Equação 3.6): Consiste em calcular o estado projetado por meio da multiplicação entre a matriz de transição \mathbf{D}_i e o estado corrigido anterior \mathbf{x}_{i-1}^+ . A complexidade computacional desta operação é $O(n^2)$, onde n corresponde à dimensão do vetor de estado.

2. **Previsão da Covariância** (Equação 3.7): Envolve a atualização da covariância *a priori* do erro associada ao estado previsto. Esta operação requer a multiplicação de matrizes de dimensão $n \times n$, resultando em uma complexidade $O(n^3)$.

Assim, a complexidade total da fase de previsão é dominada pela atualização da covariância, sendo estimada em $O(n^3)$.

Fase de Correção ^{3.5}:

Na fase de correção, as medições obtidas são integradas ao modelo para refinar as estimativas do estado e da covariância, mediante a utilização do ganho de Kalman. As operações fundamentais são:

1. **Cálculo do Ganho de Kalman** (Equação 3.8): Determina-se a matriz de ganho \mathbf{K}_i , que minimiza a incerteza da estimativa posterior. O cálculo exige a inversão de uma matriz $n \times n$, com complexidade de $O(n^3)$.

2. **Atualização do Estado** (Equação 3.9): Ajusta o estado projetado considerando as medições disponíveis e o ganho de Kalman. Essa operação requer multiplicações matriciais, com complexidade $O(n^2)$.

3. **Atualização da Covariância** (Equação 3.10): Atualiza a covariância do erro de estado com base no ganho de Kalman, refletindo a nova incerteza após a correção. Essa operação também apresenta complexidade $O(n^3)$.

Portanto, a fase de correção é dominada pelo cálculo do ganho de Kalman e pela atualização da covariância, o que resulta em complexidade global de $O(n^3)$.

Conforme Montella [55], a análise completa da complexidade computacional do *KF* demonstra que tanto a fase de previsão quanto a fase de correção possuem complexidade $O(n^3)$. Isso torna o filtro particularmente adequado a sistemas com estados de pequena a média dimensão. Para sistemas de alta dimensão, estratégias de otimização, como a adoção de filtros de Kalman estendidos ou de filtros de ordem reduzida, podem ser aplicadas a fim de atenuar o custo computacional.

Embora seja aplicável em *ES* simples, em razão dessa complexidade, simplicidade e do custo financeiro, infere-se que a implementação do Filtro de Kalman conjugado com o Filtro de Fusão e Remoção de Ruídos (chamado em algumas bibliografias de Filtro Complementar) possa vir a comprometer o desempenho. Logo, é prudente implementá-lo em um *ES* externo, ou até em sistemas com elevado poder de processamento. O emprego de máquinas com maior capacidade computacional garante que o filtro opere com a precisão e a velocidade necessárias, especialmente em aplicações que envolvem múltiplos estados e grandes volumes de dados sensoriais.

3.6 Algoritmos de Aprendizado de Máquina e Redes Neurais Recorrentes

Os avanços recentes em algoritmos de *ML*, especialmente as Redes Neurais Recorrentes (do inglês *Recurrent Neural Network-RNN*), que são projetadas para processar dados sequenciais e capturar dependências temporais, incluindo variações mais sofisticadas como as redes *LSTM* (do inglês *Long Short-Term Memory-LSTM*), e as Redes Neurais Convo-

lucionais (do inglês *Convolutional Neural Network-CNN*), que se destacam pela extração automática de padrões espaciais e pela redução de ruído em sinais multicanais, combinados com métodos de filtragem clássicos, como o *KF*, abriram novas possibilidades para a melhoria da qualidade dos dados obtidos por sensores *IMU* [26]. Tais tecnologias contribuem de forma significativa para a redução de ruído e para o aumento da precisão e da estabilidade dos dados sensoriais.

Em Goodfellow *et al.* [57] apresentam como as *RNN* podem ser aplicadas na modelagem de sequências de dados, destacando que as *LSTM* superam limitações das *RNN* tradicionais, em especial problemas de desvanecimento e explosão de gradientes. Para Junqi Zhao *et al.* [48] descrevem uma aplicação de Redes Neurais Convolucionais LSTM (do inglês ConvLSTM) no campo da segurança ocupacional, voltada à identificação de posturas de trabalhadores da construção civil. Utilizando unidades de medição inerciais (IMU) vestíveis, o estudo demonstra como a tecnologia *ConvLSTM* pode processar e analisar dados temporais complexos capturados pelos sensores, reconhecendo de forma eficaz diferentes posturas de trabalho. A *ConvLSTM* combina as propriedades das redes *CNN*, responsáveis pela extração de características espaciais dos sinais, com a capacidade das redes *LSTM* de modelar dependências temporais de longo prazo, resultando em uma arquitetura capaz de compreender simultaneamente padrões espaciais e temporais nos dados sensoriais.

A pesquisa de Saidi e Trabelsi [27] propõe um modelo híbrido baseado em *Deep Learning*, que combina *CNN* e *LSTM* para prever atividades futuras em contextos complexos, como terrorismo. Os autores demonstram que a integração desses modelos permite capturar simultaneamente características espaciais e temporais dos dados, ampliando a precisão das previsões em ambientes caracterizados por grande volume e variabilidade de informações.

Por sua vez, o estudo de Hu *et al.* [13] propõe um método de aprendizado de máquina em duas etapas, destinado à previsão do número de vítimas em situações de emergência. O modelo combina classificação e regressão, apresentando eficácia na análise de dados imprevisíveis e complexos, com desempenho adaptativo que melhora a precisão das previsões em cenários de alta incerteza. No que se refere à aplicação prática dessas tecnologias em sensores inerciais, destaca-se o uso da arquitetura *LSTM-RNN* para estabilizar dados obtidos por sensores.

3.6.1 Arquitetura *LSTM* Aplicada à Estabilização de Sensores Inerciais

As *RNN*, em particular a *LSTM*, têm demonstrado elevado desempenho na modelagem de sistemas não lineares e na fusão de dados provenientes de sensores inerciais, como as *IMU*, com informações de *GPS* [58, 59]. A *LSTM-RNN* é especialmente eficiente para lidar com divergências não lineares dos dados sensoriais ao longo do tempo, resultando em ganhos expressivos de confiabilidade para sistemas de navegação autônoma.

Pesquisas recentes, como as de Hosseinyalamdary [26] e Zhao e Obonyo [48], analisam a integração de *LSTM* com filtros estocásticos, como o *KF*, com o objetivo de aumentar a precisão e a estabilidade de sistemas de navegação baseados em *IMU*, em ambientes desafiadores descritos a seguir.

Hosseinyalamdary [26] evidencia que a utilização do *Deep Kalman Filter* (DKF), em conjunto com sensores GNSS e *IMU*, eleva a precisão de navegação mesmo em condições adversas, como ambientes urbanos densos ou locais fechados com sinal GNSS intermitente ou distorcido. Essa abordagem fornece uma fusão de dados robusta, valendo-se de modelos de *ML* para compensar perdas ou distorções nas informações, aspecto essencial para cenários caracterizados por elevada incerteza.

Em Zhao e Obonyo [48] destacam o uso de um modelo de *Convolutional LSTM* (ConvLSTM) para identificar e rastrear posturas de trabalhadores em locais de construção, onde os dados das *IMU* estão sujeitos a interferências constantes e o movimento contínuo gera ruído nas medições. O ConvLSTM, quando combinado ao filtro de Kalman, aprimora a detecção de padrões de movimento mesmo em condições de elevada vibração e interferência, assegurando maior precisão na identificação de posturas inadequadas.

Segundo Hochreiter e Schmidhuber [60], o *LSTM* constitui uma forma modificada de Rede Neural Recorrente (*RNN*) projetada para modelar dependências de longo prazo em dados sequenciais. Com arquitetura composta por portas (*gates*) de entrada, saída e esquecimento, o *LSTM* regula o fluxo de informações de modo eficiente, mantendo dados relevantes por períodos prolongados e descartando informações desnecessárias. Conforme os autores, tais mecanismos superam os problemas de desvanecimento ou explosão do gradiente característicos de redes recorrentes tradicionais, assegurando a preservação do contexto relevante ao longo do tempo. Diante disso, e conforme evidenciado por Han *et al.* [23], Jiang *et al.* [58] e Zhang [61], o *LSTM* mostra-se apropriado para identificar desvios em dados de sensores inerciais em longos intervalos, aprendendo padrões e dependências temporais, aspecto relevante para o simulador considerado neste trabalho.

Esse potencial do *LSTM* na modelagem de séries temporais torna-o também um recurso valioso em aplicações práticas. Han [23] destaca que o modelo é essencial para aprimorar a precisão de dados provenientes de sensores inerciais, sobretudo em relação ao

ruído do sinal bruto de giroscópios de Sistemas Microeletromecânicos (do inglês *Micro-Electro-Mechanical Systems-MEMS*). A capacidade do *LSTM* de capturar e modelar dependências temporais permite reduzir o ruído e melhorar de forma significativa a qualidade dos dados, resultando em medições mais precisas e confiáveis.

Jiang *et al.* [58] demonstram que o *LSTM* tem sido aplicado com sucesso à redução de ruído em sinais de sensores inerciais, como giroscópios *MEMS*, produzindo medições mais precisas e confiáveis. Zhang [61] evidencia que o *LSTM* é eficaz na estabilização de dados de sensores, especialmente em sistemas de navegação integrados, nos quais a qualidade do sinal é determinante para o desempenho global. Para esse autor, o *LSTM* é particularmente útil na redução de ruído (do inglês *denoising*) do sinal bruto de giroscópios *MEMS*, uma vez que sua estrutura permite filtrar e aprimorar os sinais, mesmo diante das complexidades de dados temporais e ruídos inerentes. Guang *et al.* [59] ressaltam que a aplicação do *LSTM* em giroscópios *MEMS* contribui para reduzir erros do sinal bruto, ampliando a precisão dos sensores inerciais. Essa abordagem é fundamental para aplicações que dependem fortemente da confiabilidade dos dados, como navegação, robótica e monitoramento de movimento.

A capacidade do *LSTM* de lidar com dependências de longo prazo e filtrar ruído de forma eficiente confirma-se como recurso valioso para aprimorar a precisão de sensores inerciais, em especial de giroscópios *MEMS* [23]. Essa abordagem representa avanço relevante na tecnologia de sensores, possibilitando dados mais confiáveis e precisos em diferentes contextos [26].

Com base na literatura sobre estabilização de sensores inerciais, torna-se crucial selecionar um modelo apto a lidar com dependências temporais de longo alcance em sequências de dados. Estudos recentes [48, 62] indicam que o *LSTM* [63] é alternativa adequada para tarefas de previsão em séries temporais, como as tratadas neste trabalho. Embora o *LSTM* seja também empregado em processamento de linguagem natural e reconhecimento de fala, o enfoque aqui recai sobre a análise de dados sequenciais oriundos de sensores inerciais [48].

3.7 Sumarização dos Trabalhos Relacionados

A Tabela 3.1 apresenta uma análise comparativa entre os métodos empregados em trabalhos correlatos e as inovações propostas nesta pesquisa. Em particular, observa-se o foco na integração de tecnologias como *IMU*, redes neurais *LSTM* e processamento pseudo-paralelo, evidenciando as contribuições desta pesquisa no campo de aplicação prática. Essa comparação demonstra como as técnicas adotadas neste estudo comple-

mentam abordagens tradicionais no tratamento de dados de sensores *IMU*, oferecendo novas perspectivas e ganhos de eficiência.

A revisão explorou o potencial das redes neurais recorrentes, em especial as *LSTM*, na modelagem de séries temporais e na mitigação de ruídos em sensores inerciais. A combinação dessas técnicas com métodos clássicos de filtragem apresenta alternativas para a elevação da precisão e da confiabilidade dos dados sensoriais.

De forma conclusiva, a análise comparativa dos trabalhos relacionados demonstra que a integração entre técnicas de *Machine Learning*, processamento concorrente [64] e métodos tradicionais de filtragem pode resultar em melhorias significativas na qualidade das medições de sensores *IMU*. Tal integração reflete a evolução contínua das tecnologias de sensoriamento inercial e a necessidade de soluções cada vez mais precisas e eficientes, particularmente em aplicações críticas, como a simulação militar.

Tabela 3.1: Comparação de técnicas em trabalhos relacionados.

Referência	IMU	Média Móvel	Kalman	<i>LSTM</i>	Otimização
[55]	X		X		
[23]	X		X		
[26]	X		X	X	
[48]	X			X	
[52]	X		X		
[65](*)					X
[64](*)					X
[66]		X			
[58](*)	X			X	
[67](*)	X			X	
[59](*)	X		X	X	
[68](*)	X			X	
[69](*)	X			X	
[61](*)	X		X	X	
Este trabalho(*)	X	X	X	X	X

* Uso do algoritmo ou processo implementado em tempo necessário ^{3.1}.

O capítulo seguinte apresenta a solução proposta nesta pesquisa. Nele, são descritas as estratégias de coleta de dados, a seleção e aplicação dos filtros, bem como a implementação dos algoritmos de *Machine Learning*. O objetivo central é melhorar a precisão dos dados provenientes dos sensores e, adicionalmente, garantir que tais melhorias sejam sustentáveis e aplicáveis em ambientes operacionais reais. Essa contribuição visa ao avanço do estado da arte em simulações militares e em outras aplicações críticas de sensores inerciais.

Capítulo 4

Metodologia

Este capítulo apresenta a solução proposta, detalhando a construção do modelo, os experimentos e a validação dos resultados. O objetivo principal é abordar os desafios associados à estabilização dos dados sensoriais, notadamente aqueles provenientes dos sensores *IMU*, com vistas a obter resultados mais confiáveis e precisos durante os exercícios de simulação. Para tal finalidade, a Seção 4.1 foca nas etapas de processamento dos dados por meio do Filtro de Fusão e Remoção de Ruído, englobando a coleta de dados, o treinamento, a validação e o teste dos modelos, culminando na gravação do modelo *LSTM* para utilização no simulador. A Seção 5.3 explora a execução prática dos modelos no tempo necessário, aplicando o Filtro de Fusão e Remoção de Ruído, a predição e a remoção de ruído com o modelo *LSTM* gravado, e, por fim, o pós-processamento com o Filtro de Kalman, todos operando em um ambiente de processamento concorrente. Para aprimorar a compreensão da sequência metodológica aplicada neste estudo, foi elaborado um fluxo síntese da abordagem 4.1. O primeiro bloco representa o treinamento do modelo, que precede o segundo bloco responsável pela aplicação no tempo de execução necessário. A seguir, está detalhado passo a passo o procedimento adotado para permitir sua reprodução.

4.1 Modelo *LSTM* e Dados do Filtro de Fusão e Remoção de Ruídos

Esta seção delinea as etapas de treinamento, validação e teste dos modelos, começando com a implantação do Filtro de Fusão e Remoção de Ruído (Seção 4.1.1), que é responsável pelo processamento dos dados dos componentes giroscópio, acelerômetro e magnetômetro do sensor *IMU*, seguida pela execução da coleta de dados (Seção 4.1.2). Posteriormente, a Seção 4.2 aborda o treinamento e a gravação dos modelos *LSTM*.

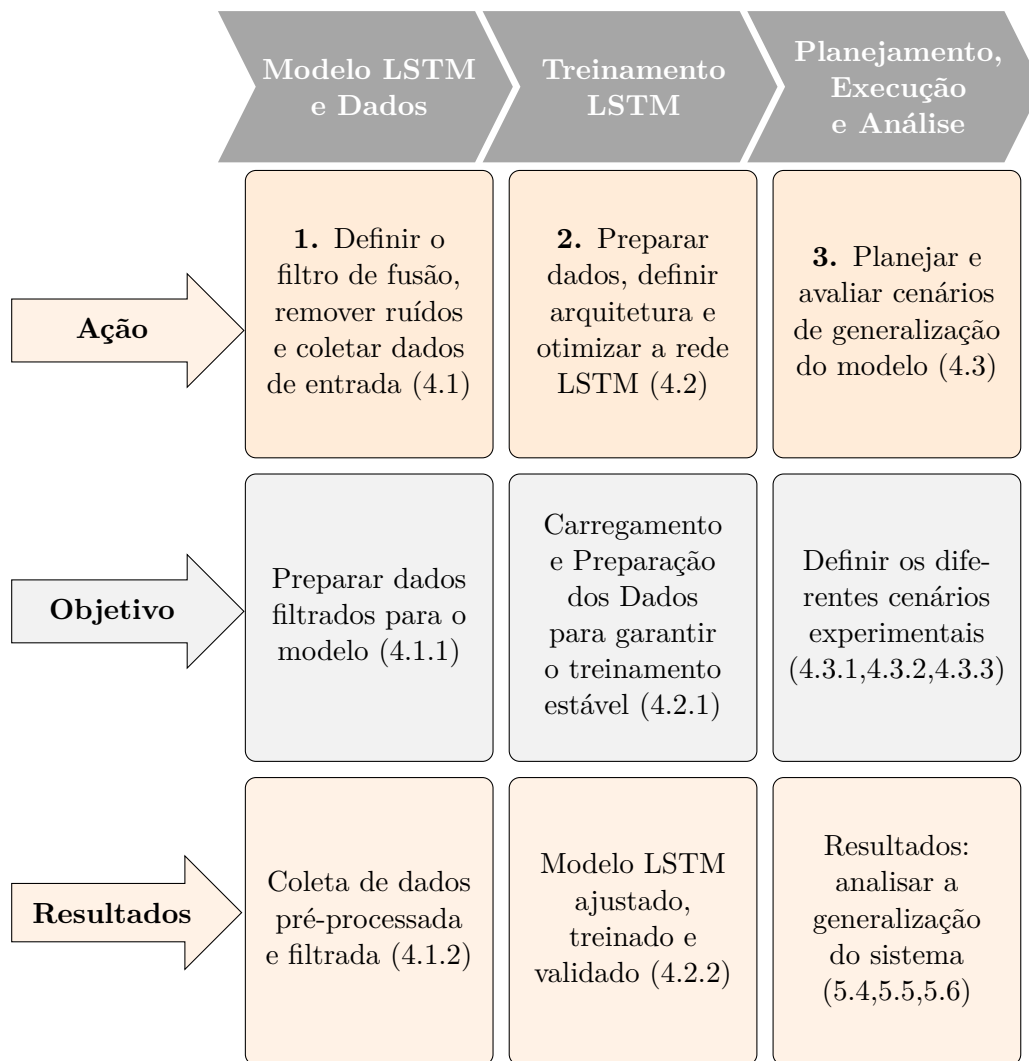


Figura 4.1: Fluxo metodológico do treinamento e avaliação do modelo LSTM

4.1.1 Filtro de Fusão e Remoção de Ruído

No Sistema Computacional Embarcado (do inglês *Embedded Systems-ES*) onde o sensor *IMU* está acoplado, foi utilizado o Filtro de Fusão e Remoção de Ruídos [22], que fornece estimativas de atitude mais confiáveis com um custo computacional relativamente baixo, permitindo sua aplicação eficiente no código do *ES*. Neste trabalho, esse filtro combina as vantagens do giroscópio e do acelerômetro, isto é, a alta precisão do giroscópio para detectar mudanças rápidas e a confiabilidade do acelerômetro para corrigir a deriva ao longo do tempo.

O resultado dessa fusão é um conjunto de dados de atitude (inclinação, guinada e rotação) mais estáveis e confiáveis, essencial tanto para o treinamento quanto para a execução do modelo *LSTM*. O uso desse filtro, além de melhorar a qualidade dos dados, contribui para a eliminação de ruído e oferece respostas mais rápidas, o que é fundamental em aplicações de tempo necessário. Dessa forma, garante-se que o modelo *LSTM* seja alimentado com dados consistentes e de alta qualidade, otimizando seu desempenho tanto na fase de aprendizado quanto na execução prática em campo.

Nesse contexto, a abordagem mais apropriada deve implementar técnicas que permitam uma análise rápida e eficiente sem descartar dados. Métodos como a suavização de dados, exemplificados pela Média Móvel [66], ou a aplicação de filtros adaptativos, como o Filtro de Kalman Adaptativo (*Adaptive Kalman Filter-AKF*) [50], são amplamente empregados para atenuar ruídos e aprimorar a estabilidade das medições provenientes de sensores inerciais. Esses filtros devem ser projetados para lidar com a incerteza e o ruído de forma eficaz, ajustando-se dinamicamente às mudanças nos dados de entrada, o que os torna ideais para cenários em que os sensores operam sob condições variáveis e imprevisíveis.

Após a aplicação do Filtro de Fusão e Remoção de Ruído, etapa fundamental para assegurar a consistência e qualidade dos sinais inerciais utilizados, inicia-se o processo de coleta dos dados. Essa fase foi conduzida de forma padronizada, seguindo uma metodologia de *benchmarking* inspirada diretamente nos procedimentos reais de operação do Material de Tiro, em Bridi [6]. O objetivo foi garantir que os dados refletissem com fidelidade as condições dinâmicas enfrentadas em campo, tanto nos momentos de estabilização quanto durante a transição angular da peça.

4.1.2 Coleta de Dados

A coleta de dados foi realizada com o Sensor GY-87, acoplado ao material de tiro (obuseiro), com o objetivo de capturar informações cinemáticas, ou seja, de movimento acoplado rotacional tridimensional sob diferentes orientações de pontaria. O procedimento

foi cuidadosamente estruturado para cobrir toda a amplitude operacional do obuseiro, conforme pode-se observar na Figura 4.2 — desde a elevação mínima até a máxima, e da deriva esquerda à direita — de modo a simular cenários realistas de operação. Essa abordagem busca ampliar a diversidade do conjunto de dados empregado nas etapas de treinamento, teste e validação de modelos baseados em redes neurais recorrentes, como a *LSTM*.




Figura 4.2: Esquema de varredura angular do obuseiro (Fonte: Elaborado pelo autor).

A Figura 4.2 ilustra a trajetória angular percorrida durante a coleta, enquanto a Tabela 4.1 apresenta a organização lógica da malha de coleta, juntamente com a descrição detalhada de cada orientação testada.

Legenda:

1. Centro-Centro: posição inicial com deriva e elevação iguais a zero.
2. Centro-Esquerda: deriva central e elevação no limite esquerdo.

Tabela 4.1: Distribuição espacial dos pontos de coleta no campo de pontaria

(9) Superior-Esquerda	(8) Superior-Centro	(7) Superior-Direita
(2,10) Centro-Esquerda	(1,11) Centro-Centro	(6) Centro-Direita
(3) Inferior-Esquerda	(4) Inferior-Centro	(5) Inferior-Direita

3. Inferior-Esquerda: deriva inferior e elevação no limite esquerdo.
4. Inferior-Centro: deriva inferior e elevação central.
5. Inferior-Direita: deriva inferior e elevação no limite direito.
6. Centro-Direita: deriva central e elevação no limite direito.
7. Superior-Direita: deriva superior e elevação no limite direito.
8. Superior-Centro: deriva superior e elevação central.
9. Superior-Esquerda: deriva superior e elevação no limite esquerdo.
10. Centro-Esquerda (Retorno): deriva central e elevação no limite esquerdo, para reforço da posição simétrica.
11. Centro-Centro (Retorno Final): reposicionamento à configuração inicial.

Esse mapeamento segue a lógica real de manipulação do armamento em situações de treinamento e operação militar, respeitando os movimentos executados por operadores humanos durante a pontaria em combate. Assim sendo, embora os pontos de coleta estejam definidos, o alcance exato de cada orientação não é atingido com precisão absoluta, dada a natureza do controle mecânico humano, sujeito a variações tanto no espaço quanto na velocidade de movimentação. O movimento da ponta do tubo do obuseiro descreve, no espaço, uma trajetória angular tridimensional que se assemelha a uma superfície de cunha esférica aberta.

Consequentemente, os dados coletados refletem a complexidade dos movimentos angulares, exigindo abordagens robustas para sua análise e modelagem. Essas características tornam os dados particularmente adequados para validação de modelos com capacidade de generalização, como é o caso das redes *LSTM*, e garantem que o experimento represente adequadamente as variações reais enfrentadas em campo.

Esse conjunto de posições e transições foi planejado como um *benchmark* experimental, com caráter padronizado, repetível, comparável e auditável. Dessa forma, não apenas as

medições em pontos fixos, mas também as respostas cinemáticas — posição, velocidade e aceleração angulares — durante o reposicionamento fazem parte da base de análise.

O experimento foi conduzido em um ambiente igual ao da simulação de tiro - um pavilhão destinado à garagem dos obuseiros, do 31º Grupo de Artilharia de Campanha, em Brasília-DF, com telha de zinco, paredes de alvenaria e rede elétrica - com início na posição neutra do obuseiro, definida por deriva e elevação iguais a zero. A cada intervalo de aproximadamente 35 minutos — tempo representativo de uma mudança operacional típica — a peça era movimentada de forma sistemática até um novo ponto no campo de pontaria, seguindo uma sequência contínua e ordenada de orientações, conforme mostrado na Figura 4.2. Ao todo, foram definidos 11 pontos distintos de coleta, abrangendo posições centrais, extremas e intermediárias, com o objetivo de representar toda a faixa de movimento do armamento.

Durante o movimento e a cada uma das posições de parada, foi realizada uma coleta contínua de dados inerciais (aceleração, velocidade angular e campo magnético), o que totalizou aproximadamente 1,3 milhão de vetores coletados. Essa quantidade foi consequência natural do tempo de exercício e da frequência de amostragem, e não uma meta definida previamente. Essa abordagem permitiu capturar diferentes dinâmicas associadas à mudança de orientação do material de tiro, servindo tanto para o treinamento quanto para a validação cruzada do modelo.

Além do Sensor 1, dois sensores adicionais (GY-87, com o mesmo projeto e características técnicas) foram utilizados seguindo a mesma metodologia de coleta. O objetivo foi verificar a capacidade de generalização do modelo proposto frente a variações físicas entre unidades do mesmo tipo de sensor.

Todos os conjuntos de dados foram submetidos previamente a um Filtro de Fusão e Remoção de Ruído, etapa fundamental para garantir a integridade dos sinais e mitigar o impacto de ruídos aleatórios e *offsets* de fábrica. Esse pré-processamento também contribuiu para a otimização do treinamento, reduzindo a complexidade no ajuste de hiperparâmetros da rede *LSTM*.

Os dados coletados estão disponíveis para reprodução e análise externa, assegurando a reprodutibilidade do experimento. A Tabela 4.2 resume a estratégia geral de separação dos dados em conjuntos de treinamento, teste e validação entre os diferentes sensores empregados.

Com os dados devidamente preparados e organizados, o próximo passo é o treinamento do modelo utilizando o algoritmo *LSTM*, uma etapa crucial para garantir que o modelo aprenda a identificar padrões e realizar previsões precisas com base nos dados de entrada.

Tabela 4.2: Detalhamento do treinamento e predição dos sensores GY-87.

Etapa	Arquivo de Dados	Descrição
Treinamento	sensor_data GY-87_1.txt	Treinamento (validação cruzada)
Teste	sensor_data GY-87_1.txt	Teste (validação cruzada)
Validação	sensor_data GY-87_1.1.txt	Predição realizada em 1 milhão de vetores do mesmo sensor
Generalização	sensor_data GY-87_2.txt	Aplicação do modelo treinado nos dados de um segundo sensor

4.2 Treinamento do Modelo com o Algoritmo *LSTM*

Para o uso de Aprendizado de Máquina, em tempo necessário, deve-se, antes de tudo, entender o tipo de dado, as características que o definem e o processo de uso do modelo na filtragem dos dados, para que se tenha confiança no que está sendo implementado, partindo da revisão bibliográfica feita neste trabalho.

Para atingir esse objetivo devem ser abordados processos e métodos que permitem aos usuários entender e confiar nos resultados e saídas criadas por algoritmos de *ML*. Dito isso, está explicada cada etapa do processo a seguir, a partir do carregamento dos dados.

4.2.1 Carregamento e Preparação dos Dados

Os dados provenientes dos sensores inerciais foram carregados e processados para análise, assegurando uma base de dados consistente e adequada para o treinamento do modelo. Após a aplicação do filtro de fusão e remoção de ruídos, os sinais brutos oriundos do goniômetro, acelerômetro e magnetômetro resultam em vetores tridimensionais, ou seja, $\mathbf{s} = [s_x, s_y, s_z]^T$, $\mathbf{v} = [v_x, v_y, v_z]^T$ e $\mathbf{a} = [a_x, a_y, a_z]^T$.

Deve-se observar que os dados provenientes do sensor variam em um intervalo angular que pode atingir até 360 graus, refletindo a natureza cíclica da variável medida. Durante períodos de inatividade ou estabilização, podem ocorrer oscilações superiores a 1 grau que, embora sutis, são significativas no contexto do SIMAF, pois influenciam diretamente a precisão da inferência do modelo.

Para garantir que essa natureza cíclica seja respeitada, todas as operações de diferença, média e normalização angular são realizadas no domínio circular, conforme descrito por Titterton e Weston [53]. A normalização circular, apresentada na Equação 4.3, é a etapa fundamental que assegura o respeito à periodicidade da variável, pois restringe os ângulos ao intervalo $(-\pi, \pi]$ (ou alternativamente $[0, 2\pi)$), evitando descontinuidades artificiais na vizinhança de $0^\circ/360^\circ$.

A diferença circular mínima, expressa na Equação 4.1, garante que a variação angular entre duas medições consecutivas seja corretamente interpretada dentro do intervalo

cíclico, prevenindo saltos de $\pm 360^\circ$. Já a média circular, descrita na Equação 4.2, calcula a média vetorial dos ângulos sobre o círculo unitário, assegurando que a suavização das amostras preserve a coerência angular mesmo quando os valores se aproximam dos limites do intervalo [56].

Assim, a função *wrap*, aplicada na Equação 4.3, é a operação que efetivamente preserva a natureza cíclica do sinal angular, enquanto as Equações 4.1 e 4.2 complementam esse tratamento ao garantir a consistência das diferenças e médias no espaço circular, evitando distorções nos resultados do modelo [51], conforme apresentado:

$$\Delta\theta = \text{wrap}_{(-\pi, \pi]}(\theta_2 - \theta_1). \quad (4.1)$$

$$\bar{\theta} = \text{atan2}\left(\frac{1}{N} \sum_{i=1}^N \sin \theta_i, \frac{1}{N} \sum_{i=1}^N \cos \theta_i\right). \quad (4.2)$$

$$\theta_{\text{norm}} = \text{wrap}_{(-\pi, \pi]}(\theta). \quad (4.3)$$

Após a correção e estabilização angular, os sinais filtrados são então organizados temporalmente para o treinamento do modelo. Nessa etapa, busca-se preservar a coerência cronológica das amostras, garantindo que as relações entre medições sucessivas — agora consistentes no domínio circular — sejam corretamente interpretadas pelo modelo sequencial. A presença de ruídos residuais e derivações nos dados reforçou a necessidade do uso de técnicas de *ML* capazes de capturar padrões complexos e dinâmicos em séries temporais.

Para preservar a sequência temporal das amostras e evitar o vazamento de informações entre os conjuntos de treino e validação, os dados foram particionados de forma sequencial utilizando o método de partição sequencial [70], que respeita a série temporal tratada pelo modelo *LSTM*. Esse método realiza uma validação cruzada específica para séries temporais, em que os subconjuntos de validação contêm amostras que ocorrem posteriormente às amostras de treino, sem qualquer embaralhamento aleatório.

Conforme discutido por Greff *et al.* [71], redes do tipo *LSTM* capturam dependências temporais em séries, mas não inferem causalidade, operando sobre correlações observadas nos dados sequenciais. De forma análoga, a aplicação de um particionamento temporal que respeita a ordem cronológica, conforme descrito anteriormente, também não implica causalidade temporal. No contexto dos sensores inerciais, as amostras consecutivas apresentam correlação física — pois resultam de um mesmo movimento contínuo —, mas o modelo não estabelece uma relação causal no sentido estatístico entre os instantes sucessivos. Dessa forma, a divisão temporal preserva a coerência sequencial dos dados e impede

o uso de informações futuras durante o treinamento, sem, contudo, definir que a predição em um instante t dependa estritamente das causas ocorridas em $(t - 1, t - 2, \dots)$.

Por fim, após a partição sequencial, as séries foram reestruturadas em janelas deslizantes de tamanho fixo, de modo que cada bloco de dados passou a conter diversas sequências temporais *batch*, cada uma composta por um conjunto ordenado de instantes no tempo *timesteps* e por múltiplas variáveis medidas em cada instante *features*. Essa organização em três dimensões — amostras, sequência temporal e características — corresponde ao formato de entrada utilizado pelas redes *LSTM*, conforme detalhado na próxima Seção.

4.2.2 Treinamento e Teste da Rede Neural

Para garantir que o modelo de rede neural seja robusto e capaz de generalizar para novos dados, o treinamento foi realizado com foco na minimização da função de perda. Esse processo emprega técnicas como validação cruzada, em vez de utilizar uma divisão fixa entre dados de treinamento e teste (como a estratégia clássica de 70% para treino e 30% para teste), e otimização de hiperparâmetros, fundamentais para ajustar o modelo de forma a aprender padrões relevantes nos dados e, ao mesmo tempo, manter sua capacidade de generalização.

Adicionalmente, foi usado o critério de Parada Antecipada (do inglês *Early Stopping*) como mecanismo de controle de sobreajuste. Essa técnica, conforme descrita por Chollet [62], consiste em monitorar o desempenho do modelo sobre o conjunto de validação ao longo das épocas de treinamento, encerrando o processo tão logo se identifique deterioração nessa métrica, mesmo que a perda no conjunto de treinamento continue a decrescer. Tal abordagem evita que o modelo aprenda padrões espúrios ou ruídos específicos aos dados de treinamento, protegendo sua capacidade de generalização.

Durante esse processo, foram ajustados hiperparâmetros como o número de épocas, a taxa de amostragem e a taxa de regularização por meio de *dropout*, que desativa temporariamente algumas conexões durante o treinamento de forma aleatória e probabilística, para reduzir o sobreajuste (*overfitting*), sempre priorizando a estabilidade do modelo frente à variabilidade dos dados. A taxa de amostragem foi mantida no menor valor possível que ainda garantisse a captura das dinâmicas relevantes, buscando equilíbrio entre custo computacional e fidelidade temporal. O número de épocas foi calibrado de forma adaptativa, sendo interrompido automaticamente pelo *Early Stopping*, conforme o comportamento da validação ao longo do treinamento.

O modelo treinado foi avaliado em um conjunto de dados composto por aproximadamente 1,3 milhão de vetores coletados, quantidade resultante do processo de coleta, na garagem dos Obuseiros do 31º Grupo de Artilharia de Campanha, em Brasília-DF, que possui as mesmas características da garagem do SIMAF, o que permitiu testar sua

capacidade de generalização para dados não vistos, ou seja, amostras que não foram utilizadas durante o treinamento do modelo, como destacado por François Chollet [62], como sendo o verdadeiro teste de seu desempenho, superando a simples adequação aos dados de treinamento.

4.2.3 Validação dos Resultados Obtidos

A validação do modelo foi realizada por meio de métricas quantitativas amplamente utilizadas em problemas de regressão, incluindo o Erro Quadrático Médio (MSE), o Erro Absoluto Médio (MAE) e a Raiz do Erro Quadrático Médio (RMSE) [62]. Essas métricas foram aplicadas de forma sistemática durante cada etapa de treinamento e validação, permitindo uma análise rigorosa da capacidade de generalização do modelo *LSTM* em diferentes cenários.

A validação dos resultados não se restringe ao âmbito quantitativo, mas estende-se à comprovação qualitativa por meio da implementação prática da solução desenvolvida neste trabalho. O modelo proposto foi efetivamente integrado ao *software* BOMBARDA, substituto do sistema gráfico anterior empregado no SIMAF, o que confere caráter aplicado e relevância operacional à pesquisa. Essa integração demonstra que os resultados obtidos transcendem o ambiente experimental e contribuem diretamente para a modernização de sistemas reais de simulação e controle.

A seção seguinte detalha a execução do modelo em tempo necessário de execução, abordando as metodologias aplicadas para garantir que os ganhos obtidos na modelagem se mantenham no momento da inferência sob restrições operacionais do SIMAF.

4.2.4 Definição da Arquitetura da Rede Neural LSTM e o Otimizador

Após o pré-processamento dos dados inerciais, a arquitetura da rede neural foi definida considerando as propriedades dinâmicas e não lineares das séries temporais geradas pelos sensores. Tais propriedades decorrem da natureza física do movimento do tubo e da torre do obuseiro, cujos sinais apresentam forte dependência temporal e variações contínuas de aceleração e velocidade angular. Além disso, as relações entre os eixos medidos, representados pelo vetor tridimensional $\mathbf{x} = [x, y, z]^T$, são não lineares em virtude do acoplamento entre sensores, da fusão trigonométrica dos ângulos e da presença de ruídos e derivações cumulativas. Diante desse comportamento complexo, adotou-se a arquitetura baseada em redes do tipo *LSTM* [26, 58, 62, 71], reconhecida por sua capacidade de modelar dependências temporais de curto e longo prazo em sistemas multivariados não lineares, mantendo coerência e estabilidade na predição dos estados ao longo do tempo.

A estrutura final do modelo foi composta por uma camada *LSTM* com 324 unidades ocultas, configurada com função de ativação tangente hiperbólica (*tanh*), seguida de uma camada totalmente conectada (*Dense*) com 608 neurônios e ativação *ReLU*, e de uma camada de saída com três neurônios, correspondentes às componentes do vetor tridimensional de predição $\hat{\mathbf{y}} = [\hat{y}_x, \hat{y}_y, \hat{y}_z]^T$. O modelo foi configurado no modo sequência-para-passo (*sequence-to-one*), recebendo janelas de 64 amostras consecutivas por vez, com entradas tridimensionais correspondentes aos eixos X, Y e Z, representando os estados do sistema em tempo discreto.

A regularização *Dropout* (com taxa de 0,145) foi testada, porém não mantida na versão final, uma vez que apresentou degradação no desempenho de validação, indicando perda de capacidade de retenção de dependências temporais relevantes. Para o processo de otimização, utilizou-se o algoritmo *Nadam*, selecionado por apresentar melhor estabilidade e convergência durante os experimentos preliminares. A função de perda adotada foi o erro quadrático médio (*MSE*), e as métricas de avaliação incluíram o erro médio absoluto (*MAE*), a raiz do erro quadrático médio (*RMSE*) e variações específicas por eixo (*mse_x*, *mse_y*, *mse_z*).

Durante o treinamento, o modelo foi ajustado em 50 épocas, com tamanho de lote de 608 amostras, utilizando a estratégia de parada antecipada (*EarlyStopping*) com paciência de 10 iterações, monitorando a função de perda de validação. A divisão temporal dos dados seguiu a abordagem de validação cruzada sequencial [70] com quatro partições, garantindo a preservação da ordem cronológica das amostras e evitando o vazamento de informações temporais entre os conjuntos de treino e validação.

O otimizador escolhido foi o *Nadam*, que, segundo Zahara *et al.* [28], combina o *Adam* ao momentum de Nesterov aplicado ao Estimador de Momento Adaptativo (do inglês *Adaptive Moment Estimation-Adam*). Essa combinação permite lidar com taxas de aprendizado variáveis, evitando reduções abruptas ou aumentos excessivos durante o processo de otimização. O *Nadam* introduz uma correção antecipada do gradiente, incorporando o termo de momentum de Nesterov antes da atualização dos pesos. Essa abordagem ajusta o passo de descida com base na tendência observada nos gradientes anteriores, promovendo maior estabilidade e eficiência na atualização dos parâmetros da rede. Como resultado, o otimizador acelera o processo de descida do gradiente, superando mínimos locais e convergindo mais rapidamente para o mínimo global da função de perda, quando comparado ao *Adam*.

É importante destacar que o *Nadam* não realiza regressão nem previsão explícita de gradientes futuros. Seu comportamento de “antecipação” decorre exclusivamente da aplicação do momentum de Nesterov sobre a média móvel dos gradientes já observados, herdada da formulação do *Adam*. Assim, o termo de antecipação não tem natureza

preditiva, mas representa uma correção numérica no cálculo do gradiente atual, o que resulta em uma trajetória de convergência mais suave e estável ao longo do treinamento.

A seguir está detalhado o processo proposto para o treinamento e teste da rede neural, que é um passo fundamental para garantir que o modelo aprenda padrões relevantes e seja capaz de generalizar para novos dados. Este processo é importante não apenas para otimizar o desempenho do modelo, mas também para assegurar que ele possa ser aplicado com confiança no contexto do SIMAF.

4.3 Planejamento dos Cenários

Após a pesquisa descrita na Seção 3.7, em confronto com os requisitos de precisão deste estudo, concluiu-se que a melhor forma de atingir o estado final desejado seria por meio da integração de duas ou mais tecnologias. Esse raciocínio levou à definição de diferentes Cenários experimentais, concebidos com abordagens distintas, porém correlacionadas, para enfrentar o desafio proposto.

No primeiro Cenário, o objetivo é compreender o funcionamento das tecnologias de forma independente, condição fundamental para estabelecer a confiança no que é reportado pela literatura e, adicionalmente, verificar a suficiência de cada técnica isoladamente na resolução do problema. Caso uma única abordagem não seja capaz de atender aos requisitos, procede-se então à definição da forma de integração entre elas.

O segundo e o terceiro Cenários concentram-se no uso de modelos de aprendizado de máquina, que constituem a principal contribuição deste trabalho no campo da Ciência de Dados. Tais cenários diferenciam-se pelas estratégias de captura de dados: o primeiro foca na estabilização de curto e longo prazo com o sensor mantido em repouso, de modo a verificar se o modelo consegue aprender os padrões de ruído estático e realizar dedução a posteriori; o segundo envolve a captura de ruído com o sensor em movimento, cobrindo toda a amplitude operacional de pontaria do material de tiro.

Em ambas as estratégias, o sensor é rigidamente acoplado à massa metálica do material de tiro real, cuja estrutura interfere eletromagneticamente nas leituras da IMU. Esse procedimento garante que os dados utilizados no treinamento reflitam as condições reais de operação.

4.3.1 Cenário 1: Análise Isolada das Tecnologias Empregadas

Neste contexto, cada filtro (Fusão e remoção de Ruídos, Kalman, Média Móvel e *LSTM*) foi analisado de forma independente. O objetivo foi avaliar a eficácia individual dos filtros na estabilização e na resposta a variações angulares. Este cenário foi essencial para compreender o desempenho e o comportamento de cada componente. Essa abordagem

permitiu adquirir conhecimento sobre a utilização e combinação adequadas dos filtros e algoritmos.

As etapas do experimento incluíram:

1. Aplicação dos filtros nos dados dos sensores para os períodos especificados;
2. Comparação dos dados filtrados com os dados brutos para observar a suavização e o tempo de estabilização;
3. Análise para tomadas de decisão sobre cada filtro.

As métricas de avaliação utilizadas foram:

- **Precisão:** medida por Erro Médio Absoluto (MAE), Erro Quadrático Médio (MSE) e Erro Percentual Absoluto Médio ($MAPE$);
- **Tempo de Resposta:** definido pelo tempo necessário para estabilizar os dados após uma variação;
- **Desvio Acumulado:** representando a comparação entre o movimento dos dados brutos e os dados filtrados.

A análise foi realizada por meio de gráficos comparativos, mostrando a resposta de cada filtro e do modelo em relação aos dados brutos, os quais serviram de subsídios para a conjugação das tecnologias.

4.3.2 Cenário 2: Generalização Sem Movimento Do Sensor

No segundo cenário, realizou-se a aplicação de uma combinação do filtro Kalman e do modelo $LSTM$, em sequência, utilizando dados de sensores coletados dentro de um obuseiro, sob um telhado de zinco, e sujeitos a interferências eletromagnéticas, mas coletados sem movimento do material de tiro. O objetivo foi avaliar a capacidade de generalização para a estabilização com o modelo treinado em dados com o sensor parado, ou seja, sem movimento da pontaria.

As etapas do experimento foram:

1. Aplicação inicial do Filtro de Fusão e Redução de Ruído, seguido do modelo $LSTM$ para suavização e refinamento posterior;
2. Análise da generalização do modelo em novos dados do sensor;
3. Análise da suavização dos dados e da redução do desvio acumulado.

As métricas de avaliação incluíram:

- **Precisão e Estabilização:** com comparação das métricas de erro (MAE , MSE , $MAPE$) em relação aos filtros isolados;
- **Redução de Variância Residual:** análise da variância dos dados após a fusão das tecnologias;
- **Desvio Acumulado:** representando a diferença entre os dados brutos e os dados filtrados.

4.3.3 Cenário 3: Generalização Com Movimento Do Sensor

O terceiro cenário consistiu na repetição dos mesmos testes do cenário 2, mas com a coleta de dados seguindo um *benchmarking* com mudanças de pontaria padronizada. O objetivo foi avaliar a capacidade de generalização para a estabilização na mesma situação do exercício simulado.

As etapas do experimento foram:

1. Aplicação inicial do Filtro de Fusão e Redução de Ruído, seguido do modelo *LSTM* para suavização e refinamento posterior;
2. Análise da generalização do modelo em novos dados do sensor;
3. Análise da suavização dos dados e da redução do desvio acumulado.

As métricas de avaliação incluíram:

- **Precisão e Estabilização:** com comparação das métricas de erro (MAE , MSE , $MAPE$) em relação aos filtros isolados;
- **Redução de Variância Residual:** análise da variância dos dados após a fusão das tecnologias;
- **Desvio Acumulado:** representando a diferença entre os dados brutos e os dados filtrados.

Com a metodologia estabelecida — abrangendo a caracterização dos sensores inerciais, o processamento preliminar dos sinais, a aplicação dos filtros determinísticos e estocásticos, bem como a definição dos procedimentos de treinamento, teste e validação dos modelos baseados em *LSTM*, e a definição de Cenários com abordagens diferentes para atingir o objetivo proposto — cria-se o arcabouço necessário para a análise comparativa entre as técnicas implementadas. As etapas experimentais descritas fornecem um fluxo reprodutível que permite avaliar, de forma objetiva, a capacidade de cada linha de ação em mitigar ruídos de curto prazo, lidar com deriva acumulada e responder às exigências

dinâmicas impostas pelo SIMAF. Dessa forma, o capítulo seguinte apresenta os resultados quantitativos e qualitativos decorrentes da aplicação rigorosa desses procedimentos, permitindo examinar o comportamento dos filtros e dos modelos neurais sob diferentes condições operacionais e níveis de variabilidade residual, bem como interpretar seu desempenho à luz das métricas previamente definidas.

Capítulo 5

Resultados

Neste capítulo são apresentados os resultados obtidos a partir da aplicação da metodologia proposta. Esses resultados têm como objetivo avaliar a eficácia das abordagens adotadas, especialmente no que diz respeito à coleta de dados, à capacidade de generalização do modelo *LSTM*, à estabilização dos dados dos sensores do SIMAF em tempo necessário e ao comparativo dos dados da nova solução com os dados do sistema legado.

A análise destes dados foi fundamental para validar as hipóteses formuladas durante a fase metodológica, bem como para identificar possíveis áreas de melhoria. São abordados os desempenhos dos filtros aplicados, a eficiência do modelo *LSTM* em tempo necessário, e a adequação das soluções implementadas ao longo dos testes iniciais.

Estes resultados não apenas fornecem uma visão sobre a viabilidade da metodologia proposta, mas também orientam os próximos passos no processo de refinamento e otimização das técnicas empregadas, com vistas a alcançar uma maior precisão e confiabilidade nos exercícios de simulação.

5.1 Métricas de Generalização

Antes da apresentação dos resultados, faz-se necessário estabelecer métricas que permitam quantificar, de forma objetiva, o grau de desempenho e a satisfatoriedade alcançados pelos modelos treinados. No contexto deste trabalho, o conceito de *generalização* é entendido conforme descrito por François Chollet [62], como a capacidade de um modelo de manter bom desempenho em dados que não foram apresentados durante o treinamento. Essa característica distingue um modelo que efetivamente aprende os padrões subjacentes dos dados de outro que apenas memoriza as amostras de treino, sem capacidade de extrapolação.

Para avaliar quantitativamente esse comportamento, adotou-se o coeficiente de determinação (R^2), métrica amplamente utilizada para medir a proporção da variância dos

dados explicada pelo modelo. Segundo Montgomery *et al.* [72], o R^2 expressa a adequação global de um modelo de regressão, sendo que valores próximos de 1 indicam que a maior parte da variabilidade observada é explicada pela regressão. Entretanto, os autores [62, 72] ressaltam que não há limiares universais para definir quando um modelo é “bom” ou “excelente”, pois a interpretação depende do contexto experimental e da natureza dos dados analisados.

O coeficiente de determinação é calculado conforme a Equação 5.1, que representa a razão entre a soma dos quadrados dos erros e a soma total dos quadrados. Essa relação expressa a fração da variabilidade dos dados que é explicada pelo modelo:

$$R^2 = 1 - \frac{\text{Soma dos Quadrados dos Erros}}{\text{Soma Total dos Quadrados}} \quad (5.1)$$

Como tanto o numerador quanto o denominador são expressos em unidades ao quadrado da variável observada (por exemplo, graus² ou m/s²), as unidades se cancelam, tornando o R^2 uma **grandeza adimensional**. Seus valores variam entre 0 e 1, podendo ser expressos em termos percentuais apenas para fins interpretativos.

Embora não existam limiares universais para classificar a qualidade da generalização, é comum empregar faixas interpretativas como referência prática, ajustadas ao domínio de aplicação. Neste trabalho, adota-se a convenção apresentada na Tabela 5.1, que reflete critérios de adequação utilizados em estudos aplicados de regressão [72] e aprendizado supervisionado. Essa classificação é empregada como referência metodológica para interpretação dos resultados, e não como padrão universal, conforme discutido por Montgomery *et al.* [72].

Tabela 5.1: Faixas interpretativas do coeficiente de determinação (R^2) adotadas neste trabalho.

Faixa de R^2	Classificação da Generalização
$R > 0,95$	Excelente (forte capacidade explicativa)
$0,70 < R^2 \leq 0,95$	Boa (nível satisfatório de generalização)
$0,50 < R^2 \leq 0,70$	Limitada (baixa capacidade explicativa)
$R^2 \leq 0,50$	Aleatória (capacidade explicativa nula)

Em relação às métricas de erro — Erro Quadrático Médio (do inglês *Mean Squared Error-MSE*), Raiz do Erro Quadrático Médio (do inglês *Root Mean Squared Error-RMSE*) e Erro Médio Absoluto (do inglês *Mean Absolute Error-MAE*) —, estas são expressas na mesma unidade da variável de interesse, pois derivam diretamente das diferenças entre os valores observados e previstos [57, 72]. Em particular, o *MSE* acumula o erro ao quadrado (unidade em grau, por se tratar de ângulos), enquanto o *RMSE* reverte à unidade original ao aplicar a raiz quadrada [72]. O *MAE* mede a média das diferenças absolutas e também

permanece na unidade da variável resposta [57]. Em todas essas métricas, valores mais próximos de zero indicam melhor ajuste do modelo aos dados.

5.2 Estrutura dos Dados Coletados

A coleta dos dados foi realizada utilizando sensores inerciais do tipo GY-87, acoplados ao Material de Tiro (obuseiro), com o objetivo de capturar informações cinemáticas tridimensionais durante exercícios simulados de movimentação angular. O experimento foi conduzido em um ambiente real, no qual o obuseiro foi orientado a percorrer uma sequência de posições previamente definidas, conforme descrito na Seção 4.1.2, abrangendo diferentes combinações de elevação e deriva.

Cada ponto da trajetória foi mantido por um intervalo de tempo suficiente para a estabilização do sensor, sendo a coleta contínua ao longo de todo o processo de movimentação e posicionamento. O sensor registra medidas em três eixos (X, Y, Z), correspondentes aos ângulos de orientação *pitch*, *yaw* e *roll*, respectivamente, resultando em um vetor tridimensional por amostra. Após o pré-processamento com o Filtro de Fusão e Remoção de Ruído, os dados foram estruturados em tuplas temporais, no seguinte formato:

$$(x_t, y_t, z_t), \quad \text{para } t = 1, 2, \dots, N$$

A estrutura do arquivo é composta por tuplas que representam os valores de orientação angular em X, Y e Z no instante t . Os dados foram armazenados em arquivos de texto com três colunas por linha, representando as componentes X, Y e Z, conforme ilustrado na Tabela 5.2.

Tabela 5.2: Formato dos dados coletados: vetor tridimensional por linha.

Índice	X (pitch)	Y (yaw)	Z (roll)
0	-0,000950	0,000237	0,010570
1	-0,001587	0,000567	0,020933
2	-0,002018	0,001377	0,031095
⋮	⋮	⋮	⋮

O percurso completo, composto por 11 pontos de coleta com paradas de aproximadamente 35 minutos cada — tempo compatível com a duração típica de um exercício simulado — resultou, de forma natural, em aproximadamente 1.300.000 (um milhão e trezentos mil) vetores tridimensionais. Essa quantidade de amostras não foi predefinida, mas sim consequência direta do comportamento contínuo dos sensores durante os períodos de movimentação e estabilização angular do obuseiro em cada ponto da trajetória.

Ao todo, foram utilizados três sensores distintos, todos com o mesmo projeto físico (modelo GY-87), aplicados em momentos distintos do experimento. O objetivo dessa abordagem foi avaliar a robustez e a capacidade de generalização do modelo preditivo frente a variações de hardware, mantendo-se constante a metodologia de coleta e o ambiente operacional.

Todos os dados foram normalizados e organizados em uma estrutura de séries temporais multivariadas, com formato compatível com a entrada da rede *LSTM*, que exige como entrada sequências temporais de janelas com múltiplas variáveis.

Por fim, a divisão dos dados em conjuntos de treinamento e validação foi realizada com a técnica da validação cruzada, a qual preserva a ordem temporal das amostras, evitando vazamento de dados e garantindo a integridade da validação.

5.3 Utilização do LSTM em Tempo de Execução

Após a execução de todo o processo de treinamento, testes e validações, chega-se à finalidade primordial deste trabalho, que é a execução do modelo treinado conjugado com o Filtro de Kalman para estabilizar os dados provenientes do Filtro de Fusão de Dados do sensor *IMU*, obtido do Sistema Computacional Embarcado (do inglês *Embedded Systems-ES*). Os dados estabilizados têm a finalidade de apontar os obuseiros virtuais do simulador, na mesma direção e elevação do obuseiro real.

O processo é composto pela integração do sistema embarcado, responsável pelo filtro passa-alta e passa-baixa que funde os dados do acelerômetro, giroscópio e magnetômetro, a uma unidade computacional externa, com alto poder de processamento, que faz o trabalho de estabilização por meio do modelo *LSTM* treinado e do Filtro de Kalman, conjugados. Esta unidade computacional externa, por sua vez, passa os dados estabilizados para outra unidade responsável por rodar o *software* de simulação.

A seguir está apresentado o detalhamento de todo esse processo, da metodologia de otimização utilizada, dos filtros e do modelo treinado em tempo de execução necessária para o bom uso do Simulador. Também faz parte da apresentação os cenários executados para a prova de conceito, abordando na prática a utilização da proposta apresentada em ambiente real.

5.3.1 Ponto de Partida

O ponto de partida desta etapa baseou-se na identificação de limitações de precisão observadas no Simulador de Apoio de Fogo (SIMAF), especialmente em cenários que exigem resposta rápida e confiável. Para mitigar tais limitações, foram empregadas diferentes

abordagens tecnológicas, de forma empírica, em uma arquitetura híbrida, distribuída entre o ES de baixo custo e um ES externo de alto desempenho, a exemplo da tentativa de colocar o Filtro de Média Móvel (do inglês, *Moving Average Filter-MAF*) ou o Filtro de Kalman (do inglês, *Kalman Filter-KF*) com o Filtro de Fusão e Redução de Ruído diretamente no ES de baixo custo.

Após os testes o que foi possível ter um resultado satisfatório, mantendo o menor custo financeiro possível foi estimativa de atitude implementada diretamente no Sistema Embarcado (*ES*) por meio da aplicação de um Filtro de Fusão e Remoção de Ruídos, que combina leituras dos sensores do módulo *IMU* (acelerômetro, giroscópio e magnetômetro), utilizando componentes de filtragem passa-baixa e passa-alta. Essa etapa permitiu uma estimativa mais robusta e responsiva das variáveis cinemáticas de orientação (*pitch*, *yaw*, *roll*) com custo computacional compatível com os recursos restritos do *hardware* embarcado de baixo custo.

Em seguida, os dados processados pelo *ES* foram transmitidos a um ambiente computacional externo, onde foram submetidos a um modelo de rede neural recorrente do tipo *LSTM*, previamente treinado. Esse modelo teve por objetivo deduzir ruídos residuais presentes nos dados — tanto de curto quanto de longo prazo — com base no reconhecimento de padrões temporais não lineares. A aplicação do *LSTM* foi essencial para interpretar os desvios não modelados pelo filtro embarcado, contribuindo significativamente para a precisão dos dados antes da etapa de controle.

Posteriormente, os dados refinados pelo *LSTM* foram estabilizados por meio de um Filtro de Kalman (*KF*), também executado no ambiente externo. O *KF* foi responsável por suavizar as variações remanescentes e garantir coerência temporal nas estimativas, fornecendo uma saída filtrada com estabilidade suficiente para acionar com precisão o obuseiro virtualizado. Esse controle final permitiu reproduzir a pontaria em tempo real com maior confiabilidade.

Essa sequência — processamento embarcado com filtro de fusão, refinamento com rede *LSTM* e estabilização final com Filtro de Kalman — constituiu a base do *pipeline* experimental desenvolvido neste trabalho. A viabilidade técnica e o desempenho dessa solução foram avaliados por meio de uma prova de conceito, permitindo verificar sua aplicabilidade ao contexto do SIMAF. Cabe destacar que quaisquer ganhos obtidos, seja em precisão na pontaria, seja na ampliação do intervalo entre recalibrações, já representam uma contribuição relevante e aplicável ao sistema.

5.3.2 Processamento Concorrente

Durante a realização das provas de conceito, diversas tentativas de implementação de um fluxo direto de dados dentro de um único bloco de código foram testadas. Inicialmente,

o sistema operava normalmente, com todas as janelas de visualização e processamento (Sensor, rede *LSTM* e Filtro de Kalman) respondendo de forma sincronizada. No entanto, à medida que o tempo de execução aumentava, observou-se um comportamento assimétrico: a janela responsável pelo recebimento direto dos dados da *IMU* apresentava resposta imediata aos movimentos do sensor, enquanto as janelas associadas ao Filtro de Kalman e ao modelo *LSTM* começavam a apresentar atrasos perceptíveis e incrementais.

Esse fenômeno caracteriza um tipo específico de latência denominado *processing-time latency*, ou latência de tempo de processamento, que resulta do acúmulo de dados em *buffers* intermediários ao longo da cadeia de processamento. Conforme demonstrado por Karimov et al. [73], esse tipo de latência é recorrente em arquiteturas que processam dados em fluxo contínuo e em tempo de execução, especialmente sob carga computacional crescente e sem adequada redistribuição das tarefas. Popularmente, esse tipo de atraso acumulado é conhecido como *lag*, e compromete a sincronização entre módulos de análise em tempo necessário, ou tempo de execução necessário. Em casos como o deste trabalho, a existência de *lag* inviabiliza a aplicação prática do sistema quando operando de forma sequencial em um único bloco.

O processamento concorrente desempenhou um papel central na reorganização do fluxo de execução do sistema desenvolvido, pois foi a única solução que conseguiu tratar a MAF, o KF e o LSTM em tarefas separadas, mitigando o atraso acumulativo na saída dos dados que ocorria na solução única. É fundamental ressaltar que a alocação de tarefas em núcleos distintos de processamento não pode ser controlada diretamente, uma vez que depende exclusivamente das políticas internas do sistema operacional, conforme discutido por Palach [74].

Ainda assim, a arquitetura operacional adotada neste trabalho foi definida para se beneficiar das vantagens do paralelismo. Essa estrutura integra diversas tecnologias e práticas de processamento de dados — como argumentado por Ben-Nun e Hoefler [64], bem como por Gressler [65] — permitindo que tarefas computacionais fossem divididas em unidades menores, idealmente alocadas em múltiplos núcleos, gerenciados pelo Sistema Operacional, para otimização de desempenho. A implementação do pseudo-paralelismo, portanto, não só atenua os efeitos do *lag*, mas também amplia a capacidade de resposta do sistema sob condições de operação prolongada e de alta carga.

O conceito de processo adotado neste contexto refere-se a um conjunto de práticas, métodos e ferramentas organizadas com o objetivo de facilitar a execução simultânea de tarefas específicas, como a manipulação e análise de grandes volumes de dados. Tais dados foram gerados a partir da leitura contínua do *ES*, munido do sensor *IMU*, e posteriormente submetidos a rede neural *LSTM*, e a algoritmos como o Filtro de Kalman (*KF*). Essa estrutura conceitual e operacional foi especialmente desenvolvida para atender aos

requisitos deste projeto.

Independentemente do controle sobre a distribuição de tarefas pelos núcleos do processador, usando a biblioteca *Multiprocessing* da linguagem Python, o procedimento concorrente foi fundamental para acelerar o tempo total de execução. A expectativa, confirmada na prática, foi a de que essa divisão permitisse a manipulação eficiente de grandes volumes de dados e a execução de algoritmos complexos, como redes neurais, de maneira eficaz e responsiva.

Neste trabalho, o processamento concorrente foi aplicado na visualização e análise paralela de múltiplas camadas de dados, incluindo:

- Dados puros tratados pelo Filtro de Fusão e Remoção de Ruído;
- Dados suavizados com o Filtro de Média Móvel (exclusivamente para fins comparativos e de análise);
- Dados tratados pelo algoritmo *LSTM*;
- Dados tratados pelo Filtro de Kalman, na etapa de estabilização final.

Durante a execução em tempo necessário mais eficiente possível nessa abordagem, cada processo concorrente foi configurado com uma janela gráfica específica, contendo uma interface de controle para ajustes dinâmicos de parâmetros. Essa funcionalidade foi projetada para experimentações em bancada, permitindo que o usuário alterasse, em tempo real, fatores de correção do modelo de *ML* ou a janela de tempo empregada no cálculo de variações angulares. Essa capacidade de ajuste dinâmico foi essencial para otimizar o tempo de experimentação e aumentar a precisão da análise.

Com a adoção dessa técnica, observou-se que o uso de processamento concorrente permitiu não apenas a execução simultânea dos filtros e modelos, mas também a flexibilidade na calibração de parâmetros. Isso foi particularmente relevante na comparação entre o desempenho do Filtro de Média Móvel (empregado como referência), do Filtro de Kalman (aplicado à saída do *LSTM*) e do próprio modelo *LSTM*, cuja complexidade impõe naturalmente maior demanda computacional.

Nas próximas seções são descritos os três processos principais executados em paralelo. Cabe ainda destacar a existência de um quarto processo: a visualização dos dados provenientes da *IMU*, já processados no *ES* pelo Filtro de Fusão e Remoção de Ruído.

5.3.3 Filtro de Média Móvel

O Filtro de Média Móvel (do inglês, *Moving Average Filter-MAF*) foi implementado neste trabalho com o objetivo específico de comparação com os resultados obtidos pelo Filtro de Kalman, especialmente no que se refere à capacidade de estabilização dos dados. Embora o

MAF tenha se mostrado eficaz na suavização de variações rápidas e ruídos de curto prazo, a sua performance durante movimentos bruscos do sensor indicou um atraso na resposta, o que comprometeu sua aplicação prática em tempo necessário. Por essa razão, o filtro não foi adotado no *pipeline* final de processamento, tendo sido utilizado exclusivamente como referência comparativa.

Conforme descrito por Yalcinkaya et al. [66], o *MAF* é uma técnica clássica de suavização que calcula a média de um subconjunto de dados em uma janela deslizante ao longo da série temporal. Essa média móvel produz uma sequência suavizada, reduzindo variações aleatórias e permitindo uma visualização mais clara das tendências nos dados. A otimização do algoritmo, por meio da subtração do elemento que sai da janela e adição do novo elemento que entra, mantém a complexidade computacional em $O(n)$, sendo n o número total de elementos processados.

Na prática, ao aplicar o *MAF* aos dados previamente tratados pelo Filtro de Fusão e Remoção de Ruído, foi possível observar que, embora o filtro tenha promovido uma boa estabilização do sinal, ele apresentava um *delay* considerável nos momentos de transições rápidas, prejudicando sua aplicabilidade no cenário de simulação com resposta mais imediata. Dessa forma, a técnica foi descartada como opção principal de pré-processamento para o modelo *LSTM*, mas mantida para fins de comparação com os demais filtros.

A comparação permitiu avaliar com maior clareza os benefícios do *LSTM* e do Filtro de Kalman na estabilização dos sinais oriundos dos sensores inerciais, reforçando a escolha por soluções mais robustas e adaptativas ao comportamento dinâmico do sistema simulado.

5.3.4 Algoritmo *LSTM* em Tempo Necessário

Neste trabalho, foi implementado um modelo baseado em redes neurais recorrentes do tipo *LSTM* com o objetivo de atuar como mecanismo de correção de ruído nos dados inerciais, tanto de curto quanto de longo prazo. A aplicação ocorreu em tempo necessário, com foco na dedução de perturbações nos sinais gerados por sensores GY-87 durante o movimento do armamento. Essa etapa foi executada externamente ao *ES*, em um ambiente com maior capacidade de processamento, e seu resultado alimentava, em tempo real, a próxima fase do fluxo de dados.

O modelo *LSTM* foi treinado previamente com dados processados por Filtro de Fusão e Remoção de Ruído, mantendo a mesma estrutura de *timesteps* na fase de execução. Dessa forma, a rede neural foi capaz de reconhecer padrões temporais nas variações de atitude (*pitch*, *roll* e *yaw*), realizando previsões e suavizações contínuas dos dados. O objetivo central foi a remoção de flutuações inconsistentes que poderiam comprometer a precisão da pontaria do obuseiro no simulador.

A visualização dos resultados foi conduzida por uma interface gráfica desenvolvida para exibir, em tempo real, os dados processados pela rede neural, incluindo informações sobre as coordenadas corrigidas nos eixos x , y e z , e as taxas de variação angular. Essa implementação possibilitou ajustes dinâmicos dos hiperparâmetros e permitiu a análise imediata dos efeitos da correção neural, proporcionando um mecanismo flexível para testes e validações em bancada.

A utilização de *LSTM* demonstrou-se adequada à demanda de correção adaptativa e contextualizada dos dados de sensores inerciais, fornecendo um sinal estabilizado que foi então repassado ao módulo subsequente, o Filtro de Kalman.

5.3.5 Inferência de *LSTM*

A implementação do filtro baseado em uma rede neural *LSTM-RNN*, aplicada a dados dinâmicos em tempo necessário, provenientes de um sensor inercial (como o sensor GY-87), foi conduzida conforme as etapas a seguir:

1. *Long Short-Term Memory (LSTM)*: foi implementado por se tratar de um tipo de *Recurrent Neural Network (RNN)* projetada para lidar com dependências de longo prazo, pois segundo Han *et al.* [23] e Hochreiter *et al.*, diferentemente das *RNN* tradicionais, que apresentavam dificuldades em aprender e manter informações por períodos extensos, as *LSTM* possuem mecanismos internos que lhes permitem reter sequências de dados por intervalos maiores, sendo particularmente relevantes para análise de séries temporais;
2. Filtro *LSTM*: No presente contexto, o filtro *LSTM* foi utilizado para prever valores futuros de uma série temporal com base em observações anteriores. O modelo foi previamente treinado com dados históricos e, em seguida, empregado para a predição de valores subsequentes da série, funcionando de acordo com Jiang *et al.* [58] e Guang *et al.* [59];
3. Suavização e Correção: Após a previsão dos valores da série, foi aplicado um fator de correção sobre os resultados previstos. Esse fator suavizou as predições e as ajustou aos valores observados, podendo ser recalibrado dinamicamente durante a execução, o que permitiu maior adaptação a mudanças na dinâmica dos dados, conforme descrito por e Guang *et al.* [59] e Li *et al.* [69];
4. Visualização em Tempo Necessário: A implementação contemplou uma interface gráfica destinada à exibição simultânea dos dados temporais, das predições realizadas e da aplicação do fator de correção. Essa visualização possibilitou acompanhar o desempenho do filtro *LSTM* e verificar, em tempo necessário, o ajuste dos dados;

5. Avaliação Contínua: Após a aplicação do modelo aos dados dinâmicos, foi realizada uma avaliação contínua do desempenho alcançado. Essa etapa assegurou a adaptação do modelo às variações observadas nos dados em tempo necessário, garantindo respostas consistentes e adequadas, mesma metodologia aplicada no trabalho de Guang *et al.* [59] e Nagaraj *et al.* [67].

Em síntese, o filtro *LSTM* configurou-se como um componente de inferência capaz de antecipar o comportamento do sistema e aplicar correções em tempo necessário com base em padrões temporais complexos. Essa característica o tornou adequado para sistemas que exigem elevada precisão e estabilidade em cenários marcados por ruídos e deriva, como o SIMAF.

Complementarmente, o uso de processamento concorrente mostrou-se essencial para mitigar os efeitos da latência durante a execução contínua de sistemas operando em tempo necessário, otimizando o fluxo de dados e viabilizando sua aplicação em ambientes simulados. Em contextos de alta demanda computacional, como na execução de modelos *LSTM* e filtros em tempo real, verificou-se que a execução sequencial conduzia ao acúmulo de *buffer* e ao atraso progressivo, caracterizando o que Karimov *et al.* [73] denominaram *processing-time latency*.

O processamento concorrente distribuiu as tarefas entre múltiplos núcleos de execução, reduzindo gargalos e elevando a responsividade do sistema. Essa abordagem esteve em conformidade com as diretrizes de escalabilidade e desempenho descritas por Ben-Nun e Hoeffler [64], que ressaltaram a relevância da decomposição de tarefas em arquiteturas paralelas e distribuídas. Palach [74] e Gressler [65] reforçaram, adicionalmente, a importância de estruturas organizadas para a manipulação eficiente de fluxos contínuos de dados, especialmente em sistemas de execução em tempo necessário para o exercício do simulador.

Por fim, embora técnicas de aprendizado profundo *LSTM* tenham demonstrado elevado potencial para correção e estabilização de dados de sensores *IMU*, sua aplicação prática exigiu recursos computacionais significativos. Por essa razão, a execução desses modelos foi realizada em sistemas externos com maior capacidade de processamento, cujos resultados foram posteriormente integrados a outros módulos, como o Filtro de Kalman e, por fim, repassados ao simulador responsável pela representação virtual do armamento.

5.3.6 Filtro de Kalman

Após o processamento pelos algoritmos *LSTM*, os dados corrigidos foram submetidos ao Filtro de Kalman, que teve como papel principal estabilizar as flutuações residuais e preparar o sinal final de atitude para ser transmitido ao módulo de simulação do armamento.

O Filtro de Kalman foi implementado conforme descrito em [56], por tratar-se de uma técnica consagrada para a estimação de estados em sistemas dinâmicos lineares ruidosos.

O modelo utilizou a estimativa do estado corrente para prever o próximo estado do sistema, com posterior correção baseada na nova observação. Essa característica preditiva mostrou-se especialmente vantajosa durante movimentos bruscos, onde o Filtro de Kalman respondeu com mais agilidade em comparação ao Filtro de Média Móvel (do inglês *Moving Average Filter-MAF*), garantindo maior estabilidade visual e consistência do sinal ao longo do tempo.

Durante as análises, a comparação com o Filtro de Média Móvel indicou que, apesar de ambos apresentarem desempenho semelhante em condições estáticas ou de movimento lento, o Filtro de Kalman se destacou em situações de transições rápidas, justificando sua escolha como filtro final de estabilização. O *MAF*, portanto, foi mantido apenas como referencial analítico para fins de comparação, conforme detalhado na Subseção 5.3.3.

Dessa forma, o fluxo de dados foi consolidado na seguinte sequência: Filtro de Fusão e Remoção de Ruído → Algoritmo *LSTM* → Filtro de Kalman → Obuseiro Virtualizado no Simulador. Essa estrutura permitiu uma correção hierárquica e adaptativa, combinando predição por aprendizado de máquina com rastreamento estatístico, otimizando a precisão dos dados de entrada no SIMAF.

5.4 Cenário 1: Análise Isolada das Tecnologias Empregadas

O intuito deste Cenário é verificar se cada uma das tecnologias empregadas, como sensor bem calibrado, é capaz de entregar o estado final desejado. Após estudos da revisão bibliográfica, foi necessário entender como os filtros trabalham isoladamente, expondo seus resultados para melhor atender e adaptar às peculiaridades do problema apresentado neste trabalho. As soluções dos trabalhos relacionados estão intrinsecamente relacionadas ao comportamento dos dados específicos destes trabalhos, quer seja na conjugação dos filtros, quer seja na forma de treinar o modelo. Assim sendo, a seguir são apresentadas as análises de cada componente utilizado nesta solução.

5.4.1 O Filtro de Fusão de Dados e Redução de Ruídos

O Filtro de Fusão e Redução de Ruídos, foi implementado diretamente no sistema computacional embarcado que contém o sensor IMU. A estratégia adotada combina um filtro passa-baixa aplicado aos dados do acelerômetro, para retenção das componentes de baixa frequência associadas à orientação estática, com um filtro passa-alta aplicado aos dados

do giroscópio, para preservação das variações rápidas e mitigação do acúmulo de erro de integração (deriva). Essa ponderação visa compensar as limitações intrínsecas de cada sensor, proporcionando um sinal de orientação mais estável.

Segundo Roberto G. Valenti [22], o ganho α deve ser ajustado dinamicamente conforme as condições de movimento, de modo que, durante acelerações intensas, a contribuição do acelerômetro seja reduzida, evitando que acelerações lineares indevidas comprometam a estimativa de orientação. Em situações estáticas, o ganho é elevado para privilegiar a leitura do acelerômetro, garantindo a correção gradual das derivações do giroscópio. Essa estratégia adaptativa, denominada *adaptive gain*, permite que o filtro mantenha precisão mesmo sob diferentes regimes dinâmicos, assegurando estabilidade e resposta rápida do sistema. No contexto do simulador SIMAF, que modela o giro do tubo de um obuseiro, esse ajuste de α é decisivo para assegurar que a orientação estimada do tubo seja precisa e responda às mudanças rápidas de ângulo. Durante o disparo ou ajuste de elevação, o giroscópio forneceu resposta imediata ao movimento angular, registrando as variações rápidas de direção. Nessas situações, um α próximo de 1 foi adotado para privilegiar as medições do giroscópio, garantindo que o simulador reaja de forma ágil às mudanças de orientação. Em contrapartida, quando o obuseiro permanece estacionário ou executa movimentos lentos e constantes, o acelerômetro fornece uma estimativa mais estável e confiável, corrigindo os desvios acumulados pelo giroscópio devido à deriva induzida por ruídos. Nesses casos, foi ajustado α para valores próximos de 0, assegurando que o simulador utilize mais a leitura do acelerômetro, mantendo o tubo alinhado corretamente ao longo do tempo, mesmo após múltiplos disparos ou ajustes de mira.

O resultado obtido consistiu em uma boa estabilização, ainda distante do ideal para o simulador, apresentando ruído nos eixos X (*pitch*), Y (*roll*) e Z (*yaw*), e derivação considerável no eixo Z (*yaw*). Este último apresentou instabilidade mais acentuada devido à sua maior dependência da leitura do magnetômetro no cálculo do *yaw*, cuja determinação é obtida pela relação trigonométrica apresentada na Equação 5.2, que utiliza as componentes do campo magnético medidas pelo magnetômetro:

$$\theta_Z = \arctan\left(\frac{m_y}{m_z}\right). \quad (5.2)$$

onde m_y e m_z representam as componentes do campo magnético medidas pelo magnetômetro. Apesar de necessária para fornecer referência absoluta de direção, essa leitura é altamente suscetível a ruídos e interferências magnéticas externas, o que contribuiu para o aumento da deriva observada e para a instabilidade no plano horizontal.

5.4.2 O Filtro de Kalman e o Filtro de Média Móvel

Os exercícios realizados no Simulador de Apoio de Fogo (SIMAF) são dinâmicos no que se refere à mudança de pontaria, sendo necessária uma pronta resposta da leitura dos ângulos da pontaria em direção e em elevação do tubo de tiro. Na Figura 5.1 há dois quadros apresentando os Filtros de Média Móvel e Filtro de Kalman, respectivamente, que foram implementados no sistema, coletando dados do sensor acoplado ao material de tiro. Ambos os Filtros se aplicam bem à estabilização desejada ao suavizar o ruído, apresentando resultado com oscilações abaixo de dois milésimos de erro, com picos maiores em raras exceções observadas, mas ainda abaixo de três milésimos. Para o instrutor, esses picos são facilmente desprezados em seu julgamento, ao se ater e anotar o dado claramente estável, desprezando os dados que se comportam como *outliers*, mas de forma intuitiva, desconsiderando variações esporádicas.

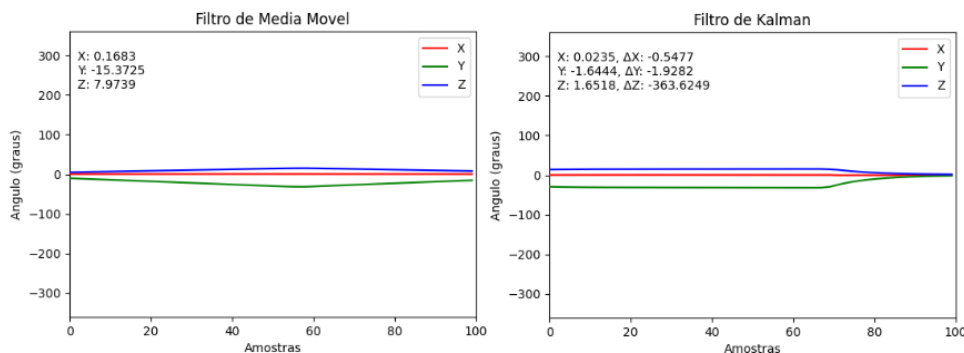


Figura 5.1: Eficiência entre os Filtros de Kalman e Média Móvel.

Em comparação ao Filtro de Média Móvel, o Filtro de Kalman mostrou-se superior em termos de resposta às mudanças de estado do sensor, além da estabilização observada, como pode ser constatado na Figura 5.1. Observe o Filtro de Média Móvel, à esquerda do gráfico, que, enquanto os ângulos observados apresentam estado de convergência para o valor real, no Filtro de Kalman os ângulos já apresentam valores convergidos e estabilizados. A velocidade de convergência pode ser melhor comprovada e analisada à direita dos dois gráficos. Assim sendo, é possível inferir que a proposta sobre o uso do *KF* foi assertiva sobre o *MAF* quando se deseja resposta mais rápida, mas com a mesma confiança nos resultados dos dados estabilizados.

5.4.3 Análise entre o Filtro de Kalman e o Filtro de Média Móvel

Os modelos foram treinados com a abordagem por *Cross Validation*, possibilitando o treinamento robusto e assertivo, permitindo inferir melhor confiança sobre a generalização nos novos dados do sensor IMU.

Após analisar o resultado de cada abordagem empregada, confrontando com o tipo de dado e a necessidade de emprego, é possível inferir que existe lógica em implementar cada tecnologia de forma conjugada e em ordem conforme a eficiência e eficácia de cada uma delas. Na Tabela 5.3, segue a ordem de cada componente, a forma e a justificativa de seu emprego.

Ordem	Abordagem	Local	Justificativa
1	Filtro de Fusão	ES de baixo custo com IMU	Conjugar os Componentes do sensor de forma ponderada para obtenção de precisão
2	Modelo LSTM	ES Externo de alto desempenho	Estabilizar o ruído de longo prazo
3	Filtro de Kalman	ES Externo de alto desempenho	Estabilizar o ruído de curto prazo

Tabela 5.3: Ordem das tecnologias empregadas.

Conforme a ordenação proposta, na primeira posição tem-se o Filtro de Fusão e Remoção de Ruídos, que, conforme descrito por Valenti *et al.* [22], é essencial na etapa inicial do processo. Esse filtro foi implementado no sistema computacional embarcado (do inglês *Embedded Systems-ES*) e baseia-se no princípio de ganho adaptativo, no qual um parâmetro de ponderação ajusta dinamicamente a contribuição dos sensores conforme o regime de movimento. Assim, combina-se, de forma ponderada, os dados provenientes do acelerômetro, giroscópio e magnetômetro — sensores integrantes da *IMU* — por meio da aplicação conjunta de filtros passa-baixa e passa-alta. Essa abordagem adaptativa permite reter as componentes de baixa frequência associadas à orientação estática e, simultaneamente, preservar as variações rápidas e mitigar a deriva do giroscópio, resultando em estimativas mais precisas e estáveis dos ângulos de atitude (*pitch*, *roll* e *yaw*), assegurando maior confiabilidade no processamento subsequente.

5.4.4 Análise do Algoritmo LSTM

A aplicação do Modelo *LSTM* em um *ES* externo, de alto poder de desempenho, gerou resultados na redução de ruído causado pelo sensor. Essa etapa foi definida pelo estudo em relação aos trabalhos relacionados, ao mostrar sua aplicação eficaz em sensores inerciais suscetíveis a interferências externas, causadoras de derivações. Os testes realizados mostraram que a derivação que ocorre no dado bruto deve ser confrontada com o *LSTM*, por sua complexidade e origem, que carrega consigo a variação comportamental a ser aprendida, ou seja, antes de qualquer processo de suavização, quer seja pelo Filtro de Média Móvel, quer seja pelo Filtro de Kalman. Quando foram utilizados os dados do

filtro de Kalman para o treinamento do modelo, não havia aprendido e isso está melhor explicado nos dois cenários a seguir. A grosso modo, sem variação residual, não há aprendizado.

Um exemplo dessa constatação é corroborado pelos resultados obtidos na Seção 2 5.5, que introduziu variações mais realistas; o comportamento do modelo confirmou essa relação. Observou-se que os eixos **X** e **Y**, de menor instabilidade, apresentaram menor aprendizado, enquanto o **eixo Z**, mais sujeito a variações angulares e ruídos residuais, produziu resultados substancialmente melhores. Conforme apresentado na Tabela 5.5, os valores de erro médio quadrático (MSE) e coeficiente de determinação (R^2) foram:

- **Eixo X:** $MSE = 0,027122^\circ / R^2 = 0,235479$;
- **Eixo Y:** $MSE = 0,023438^\circ / R^2 = 0,232666$;
- **Eixo Z:** $MSE = 0,011026^\circ / R^2 = 0,843352$.

Esses resultados demonstram numericamente que, quanto menor a variação residual nos dados (caso dos eixos X e Y), menor é a capacidade de aprendizado do modelo, enquanto a presença de variações residuais moderadas (como no eixo Z) fornece o estímulo necessário para que a rede *LSTM* estabeleça padrões temporais significativos e aprenda a estabilizá-los.

Ao analisar as previsões entre o modelo *LSTM* e o *KF*, observa-se que o modelo *LSTM*, **no curto prazo**, não foi mais efetivo ao atenuar os dados quanto o Filtro de Kalman. Conforme pode ser visto na Figura 5.2, graduada em ($^\circ$), o *KF* foi mais eficiente ao tratar o dado bruto e entregar valores mais suavizados (com menos dispersão) dentro dos limites operacionais exigidos pela simulação — aproximadamente dois milésimos de radiano ($0,1125^\circ$) para mais ou para menos do valor aferido na luneta de pontaria ou erro de cálculo, conforme o Caderno de Instrução CI 6-199/1 [18, 19, 20].

Em relação à capacidade preditiva nos dados brutos, o modelo de aprendizado supervisionado *LSTM* apresenta oscilações residuais quase nulas em relação ao estimador estocástico *KF*. A Tabela 5.4 apresenta a comparação quantitativa entre ambos os métodos com base nas métricas de Erro Médio Absoluto (MAE) e coeficiente de determinação (R^2) para os três eixos analisados.

Tabela 5.4: Comparação quantitativa entre o modelo LSTM e o Filtro de Kalman.

Eixo	MAE (LSTM)	MAE (Kalman)	R^2 (LSTM)	R^2 (Kalman)
X	0,0255 $^\circ$	0,0217 $^\circ$	0,9965	0,9965
Y	0,0327 $^\circ$	0,0192 $^\circ$	0,9972	0,9990
Z	0,0948 $^\circ$	0,0777 $^\circ$	0,9973	0,9982




Figura 5.2: Comparação entre os resultados do filtro de Kalman e do modelo LSTM para os eixos X, Y e Z.

Observa-se que o Filtro de Kalman apresentou desempenho superior em todos os eixos analisados, com destaque para o eixo Y, em que a redução do MAE foi de aproximadamente 41% e o aumento do coeficiente de determinação (R^2) atingiu 0,9990, indicando um ajuste de 99,9% perfeito ao sinal real. O eixo Z, que corresponde à orientação de guinada (yaw), apresentou os maiores valores absolutos de erro, coerentes com o fato de ser o mais suscetível às interferências magnéticas do magnetômetro. Ainda assim, a filtragem de Kalman manteve os erros dentro dos limites de tolerância do simulador, demonstrando sua eficácia na estabilização angular e na atenuação do ruído residual após o aprendizado do modelo $LSTM$.

Desta forma, conclui-se parcialmente que os filtros e o modelo usados de forma isolada não entregam o estado final desejado, pois o Filtro de Fusão e Redução de Ruídos, bem como o Filtro de Kalman, não eliminam a derivação causada pela acumulação residual de longo prazo, assim como o modelo $LSTM$ não é capaz de eliminar suficientemente o ruído de curto prazo com a eficácia dos filtros citados. Importante ressaltar que o planejamento dos três Cenários certifica o que era previsto nos trabalhos relacionados sobre a conjugação de tecnologias, apenas com o diferencial da forma de coleta de dados para a peculiaridade deste trabalho. Os dois Cenários a seguir abordam o treinamento do modelo para a utilização dos algoritmos de forma conjugada, vista como a única maneira de obter sucesso na estabilização geral, de curto e médio prazo, e com a precisão desejada.

5.5 Cenário 2: Generalização sem Movimento do Sensor

O objetivo deste Cenário foi avaliar se o aprendizado do modelo, utilizando apenas os ruídos naturais do sensor, estando parado — sem inserção de movimento induzido (mudança de pontaria durante a coleta de dados) — poderia contribuir para a dedução da deriva de longo prazo. A intenção foi verificar se a rede seria capaz de aprender as flutuações residuais provenientes do próprio sistema sensorial, deduzindo os componentes de ruído e estabilizando os dados ao longo do tempo. De forma complementar, buscou-se compreender se, na ausência de variações significativas nos dados, haveria limitação no processo de aprendizado supervisionado. Essa análise foi fundamental para identificar o papel da variabilidade residual no desempenho do modelo e compreender sua capacidade de generalização em condições estáticas, conforme demonstrado nas análises a seguir.

5.5.1 Análise dos Resultados do Modelo no Conjunto de Teste do Sensor 1

A aplicação do modelo treinado aos dados de teste do Sensor 1 revelou resultados consistentes com a hipótese de que a ausência de variação residual limita o aprendizado. O Erro Quadrático Médio (do inglês, *Mean Squared Error-MSE*) apresentou valores insatisfatórios, conforme explicado em 5.1, com aleatoriedade de generalização nos eixos X e Y , e com boa generalização apenas no eixo Z , que, por ser mais instável, fez com que houvesse maior atenção do modelo no aprendizado desse eixo. Os valores são apresentados na Tabela 5.5.

Tabela 5.5: Métricas de desempenho no Split 4.

Eixo	MSE	R^2
Total	0,020595°	0,437166
X	0,027122°	0,235479
Y	0,023438°	0,232666
Z	0,011026°	0,843352

Os resultados mostram que o eixo Z apresentou um coeficiente de determinação (R^2) de aproximadamente 0,84, o que significa boa capacidade de generalização ao abranger os dados brutos em 84%, conforme explicado na Seção 5.1, enquanto os eixos X e Y , mais estáveis, alcançaram valores de generalização aleatória dos dados brutos, próximos a 23%. Essa diferença numérica evidencia que o aprendizado foi fortemente associado à presença de pequenas flutuações, ou seja, à variabilidade residual do eixo Z .




Figura 5.3: Predição nos dados de teste do Sensor 1.

O gráfico da Figura 5.3 ilustra a comparação entre os valores reais e previstos pelo modelo para os três eixos. Observa-se que, embora as curvas de predição estejam alinhadas às dos dados reais, a rede não conseguiu ajustar adequadamente a amplitude dos sinais, apresentando aprendizado limitado nos eixos mais estáveis. Esse comportamento confirma que, na ausência de variação residual, a rede tende à convergência prematura, com baixo ganho de generalização.

5.5.2 Análise da Validação do Modelo em Novos Dados do Sensor 1

A validação do modelo em um novo conjunto de dados, coletado em ambiente distinto, permitiu avaliar sua robustez frente a condições não vistas durante o treinamento. Os resultados estão apresentados na Tabela 5.6, que mostra um MSE de 0,215127 e coeficiente de determinação (R^2) de 0,784817.

Tabela 5.6: Métricas de desempenho do Sensor 1 em novos dados (validação).

Métrica	Valor
MSE	0,21512793401718522°
R^2	0,7848173638286863

Embora o erro médio tenha aumentado em relação ao conjunto de teste, o valor de R^2 indica que o modelo foi capaz de explicar aproximadamente 78,5% dos novos dados do mesmo sensor. Essa consistência demonstra que o aprendizado obtido no eixo de maior variação (Z) foi mantido, ainda que o desempenho global permaneça limitado pelos eixos X e Y . A Figura 5.4 ilustra a aderência entre as curvas previstas e observadas.




Figura 5.4: Gráfico de predição nos novos dados do Sensor 1 (validação).

5.5.3 Análise da Aplicação do Modelo na Estabilização dos Dados do Sensor 1

Ainda que o desempenho geral do modelo não tenha atingido o nível esperado para o propósito deste estudo, sua aplicação prática demonstrou potencial para reduzir derivações de longo prazo. Ao aplicar as previsões do modelo diretamente sobre os dados brutos do sensor, observou-se estabilização de aproximadamente 20% e 40% nos testes, conforme mostrado nas Figuras 5.5 e 5.6. Essa redução de deriva evidencia que, mesmo com aprendizado restrito, a rede *LSTM* foi capaz de inferir parcialmente o ruído de baixa frequência, melhorando a estabilidade dos dados inerciais.

Em síntese, após o treinamento, teste e validação nos dados capturados estaticamente pelo sensor *IMU*, constatou-se que o modelo apresentou baixo desempenho em termos de generalização. O comportamento dos eixos X e Y , mais estáveis, limitou o aprendizado, enquanto o eixo Z , mais sujeito a pequenas flutuações, foi o que mais contribuiu para o processo de ajuste dos pesos da rede. Essa diferença de comportamento entre os eixos

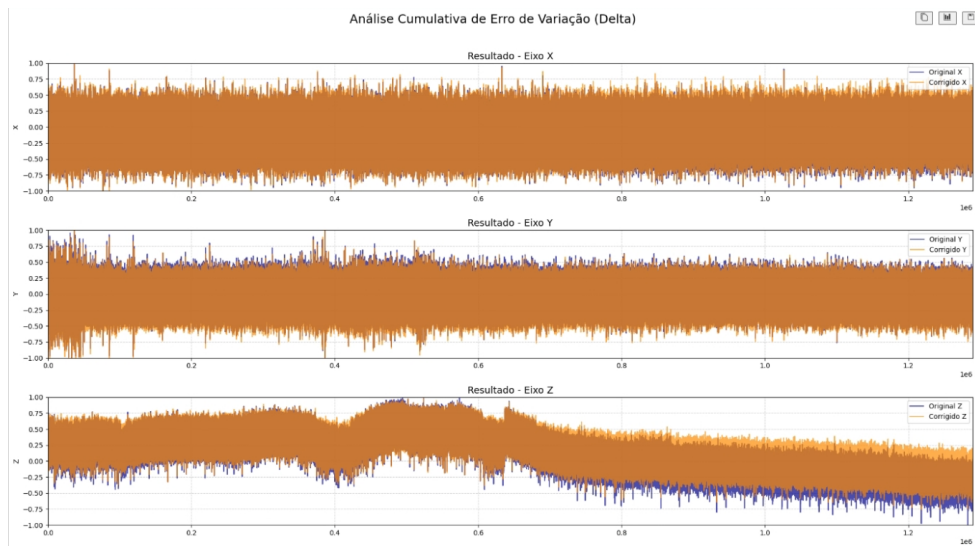


Figura 5.5: Correção 20% com os dados estáticos.

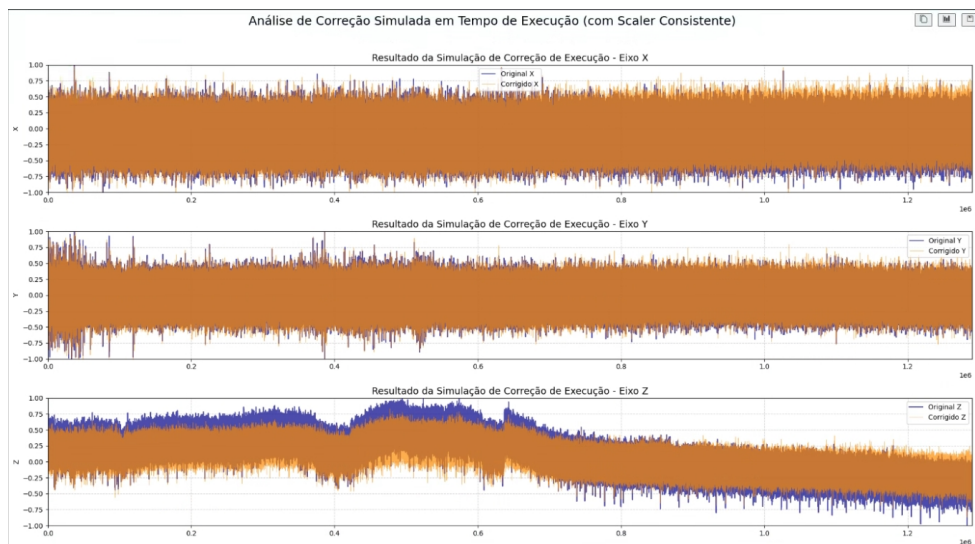


Figura 5.6: Correção 40% com os dados estáticos.

forneceu evidências diretas sobre a influência da variação residual no aprendizado da rede *LSTM*.

Os resultados confirmam que a ausência de variação residual nos dados de entrada restringe o aprendizado e reduz a capacidade de generalização do modelo. O desempenho superior observado no eixo Z , tanto no teste quanto na validação, demonstra numericamente que a variação residual é um fator determinante para o processo de aprendizado supervisionado.

A Tabela 5.7 apresenta a comparação direta entre as métricas globais de desempenho obtidas nos conjuntos de teste e validação do Cenário 2. Observa-se que, apesar do baixo valor absoluto de MSE no conjunto de teste, o coeficiente de determinação (R^2) inferior a 50% indica baixa capacidade de explicação da variabilidade dos dados reais, caracterizando um comportamento essencialmente aleatório, conforme discutido na Seção Métricas de Desempenho 5.1. Em contrapartida, o conjunto de validação apresenta um valor de R^2 significativamente superior, ainda que acompanhado por aumento do erro médio, evidenciando uma discrepância de desempenho entre os conjuntos analisados.

Tabela 5.7: Comparação global entre os resultados de Teste e Validação no Cenário 2.

Conjunto	MSE Total	R^2 Total
Teste	0,020595°	0,437166
Validação	0,2151279340°	0,784817

Essas evidências revelam uma inconsistência no comportamento do modelo no Cenário 2. Observa-se que, mesmo sendo o conjunto de teste temporalmente sequencial aos dados de treinamento, o coeficiente de determinação (R^2) obtido permanece limitado a aproximadamente 43,7%, caracterizando baixa capacidade de explicação da variabilidade dos dados reais e indicando um comportamento próximo ao aleatório.

Em contraste, o conjunto de validação — coletado em condições distintas, com variações ambientais adicionais, como temperatura e interferências externas — apresentou um valor de R^2 significativamente superior (78,5%). Essa discrepância entre os resultados de teste e validação evidencia a incoerência do aprendizado obtido, sugerindo que o modelo não desenvolveu uma representação estável e consistente do comportamento do sensor, mas respondeu de forma sensível às condições específicas de cada conjunto de dados. Com aproximadamente 100 modelos testados e validados neste Cenário, as informações comparativas, quantitativa e qualitativamente no tocante à generalização e à correção ajudaram a compor a tabela de métricas de desempenho, da Seção 5.1.

Dessa forma, os resultados indicam elevada incerteza na generalização do modelo quando treinado exclusivamente com dados estáticos, reforçando a limitação do aprendizado supervisionado na ausência de excitação dinâmica suficiente. Tal constatação

conduz diretamente à necessidade do **Cenário 3**, no qual movimentos controlados são introduzidos de forma deliberada, com o objetivo de ampliar a variabilidade temporal do sinal e permitir um aprendizado mais coerente e representativo entre os três eixos.

5.6 Cenário 3: Generalização com Movimento do Sensor

Este Cenário se baseou na mudança de estratégia quanto à captura dos dados dos sensores inerciais. Enquanto no segundo Cenário os dados foram capturados sem a mudança geoespacial do sensor, ou seja, o sensor permaneceu imóvel do início ao fim do processo de coleta, neste Cenário foram feitas 11 mudanças de posição de pontaria, conforme descrito na Seção 4.1.2. Esse *benchmarking* serviu como padronização para a reprodução do experimento e foi capaz de fazer com que o modelo realizasse o aprendizado dos três eixos. A metodologia de aprendizado seguiu o mesmo padrão do Cenário 5.5, os resultados também ofereceram uma prévia da capacidade de generalização, com validação cruzada, para posterior aplicação combinada das tecnologias na estabilização dos dados do sensor *IMU*.

5.6.1 Análise dos Resultados do Modelo no Conjunto de Teste do Sensor 1

A aplicação do modelo nos dados de teste com validação cruzada revelou um desempenho satisfatório, conforme pode ser observado na Tabela 5.8. O *MSE* ficou em torno de $0,00302^\circ$, o que é suficientemente baixo para indicar que o modelo possui uma boa capacidade de aproximação dos dados reais em contextos de teste mais desafiadores.

Tabela 5.8: Métricas de desempenho no Split 3 (melhor resultado).

Eixo	MSE	R^2
Total	$0,000302^\circ$	0,992284
X	$0,000030^\circ$	0,996957
Y	$0,000435^\circ$	0,990582
Z	$0,000440^\circ$	0,989312

Além disso, o coeficiente de determinação R^2 , que mede a proporção da variância explicada pelo modelo em relação à variância total dos dados, foi de aproximadamente 0,992284. Esse resultado indica que o modelo consegue explicar cerca de 99,2% da variabilidade presente nos dados de teste, confirmando sua robustez mesmo em condições de maior complexidade.

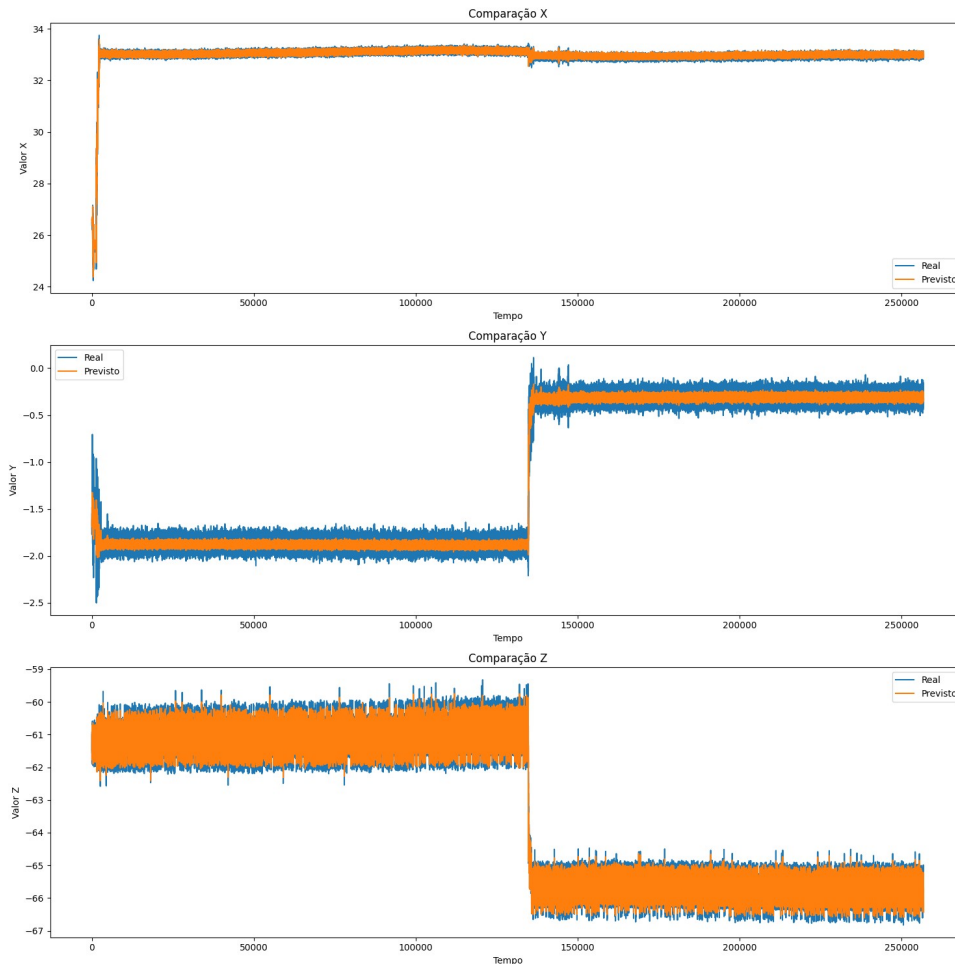


Figura 5.7: Gr fico de predic o nos dados de teste (escala deslormalizada).

Com um coeficiente de determina o $R^2 = 99.2\%$, o modelo explica a maior parte da variabilidade dos dados observados, restando cerca de 0.8% da variabilidade n o explicada.   importante notar que esse 0.8% n o corresponde diretamente a um “afastamento” fixo ou a uma margem de erro ponto a ponto, mas sim   parcela da vari ncia total dos dados que n o   capturada pelo modelo. Em termos pr ticos, isso significa que podem existir desvios locais vis veis entre as s ries predita e real, especialmente em determinadas janelas de medi o ou sob mudan as abruptas, sem que isso contradiga um R^2 elevado. Esses desvios tornam-se particularmente percept veis quando a escala   normalizada e/ou ampliada, ainda que, em magnitude absoluta, permane am pequenos e coerentes com m tricas como o MSE .

As Figuras 5.7 e 5.8 ilustram a compara o entre as s ries reais e previstas para os tr s eixos, na escala aumentada e na escala normal da amplitude espacial total do sensor, respectivamente. Visualmente, observa-se uma aparente diferen a entre os pontos das curvas, com a aproxima o exagerada, que poderia sugerir desempenho inferior. No

entanto, tal percepção decorre principalmente do processo de normalização e ampliação da escala visual, entre o máximo e o mínimo de um dado momento de medição. Erros absolutos da ordem de centésimos, embora estatisticamente desprezíveis no cálculo do MSE e coerentes com um R^2 elevado, tornam-se perceptíveis quando os dados estão em escala comprimida. Além disso, o R^2 é uma métrica que captura a capacidade do modelo em explicar a tendência e a variabilidade global dos dados, não exigindo coincidência ponto a ponto entre as séries. Assim, o alinhamento observado em transições abruptas e a preservação das tendências gerais explicam os valores elevados de desempenho, mesmo diante de desvios visíveis em determinadas regiões do gráfico.




Figura 5.8: Gráfico de predição nos dados de teste (escala normal).

Em síntese, um $R^2 = 99.2\%$ — valor próximo de 1, conforme discutido por Montgomery [72] — indica que o modelo apresenta desempenho consistente e boa capacidade de generalização, mostrando-se adequado para aplicações práticas em cenários de monitoramento inercial. Ainda assim, é imprescindível validar a generalização em dados verdadeiramente novos (não vistos), conforme recomendado por Collet e detalhado na Seção 5.1; essa avaliação está conduzida na próxima subseção. Por fim, o contraste entre as métricas numéricas e a inspeção visual reforça a necessidade de interpretar gráficos em conjunto com medidas estatísticas, a fim de evitar conclusões equivocadas.

5.6.2 Análise da Validação do Modelo em Novos Dados do Sensor 1

A aplicação do modelo ao novo conjunto de dados de validação demonstrou uma capacidade significativa de generalização. Conforme indicado na Tabela 5.9, o *MSE* registrado foi de aproximadamente 0,0114577°. Embora esse valor seja mais elevado do que nos testes anteriores, ele ainda representa um nível de erro compatível com aplicações práticas que toleram pequenas imprecisões nas previsões inerciais.

Tabela 5.9: Métricas nos dados de validação.

Métrica	Valor
MSE	0,011457725888450227°
R ²	0,9676836611330525

Em relação ao coeficiente de determinação R^2 foi de 0,96768, indicando que o modelo é capaz de explicar cerca de (96.8%) da variabilidade nos dados. Este valor de validação, que é mais importante que os valores de teste, é o percentual que pode ser deduzido do ruído responsável pela derivação de longo prazo.

As Figuras 5.9 e 5.10 ilustram a comparação entre as séries reais e previstas para os três eixos, na escala aumentada e na escala normal da amplitude espacial total do sensor, respetivamente. Nota-se que o modelo segue de forma relativamente próxima os padrões apresentados nos dados reais, mesmo em trechos com variações abruptas. Entretanto, desvios menores que 0,03232 (3.2%) podem ser observados principalmente nas transições de patamar e picos de oscilação, os quais são naturalmente mais difíceis de prever com precisão. Adicionalmente, o comportamento geral das séries previstas acompanha bem a tendência dos dados reais, reforçando a robustez do modelo diante de novas entradas.

5.6.3 Análise da Aplicação do Modelo do Sensor 1 em Dados do Sensor 2

Com o objetivo de avaliar a capacidade de generalização do modelo proposto, aplicou-se o modelo a conjuntos de dados provenientes de k sensores inerciais distintos, selecionados por amostragem aleatória simples dentre os dispositivos adquiridos “de prateleira” no mercado, sem considerar lote, série sequencial ou fabricante como critérios de elegibilidade, e incluindo unidades obtidas de diferentes fornecedores ao longo de períodos distintos do ano.

O modelo foi aplicado nos dados desse novo sensor e como evidenciado na Tabela 5.10, o modelo apresentou um Erro Quadrático Médio de aproximadamente 0,0206°, valor suficientemente baixo para indicar boa capacidade de aproximação aos dados reais.

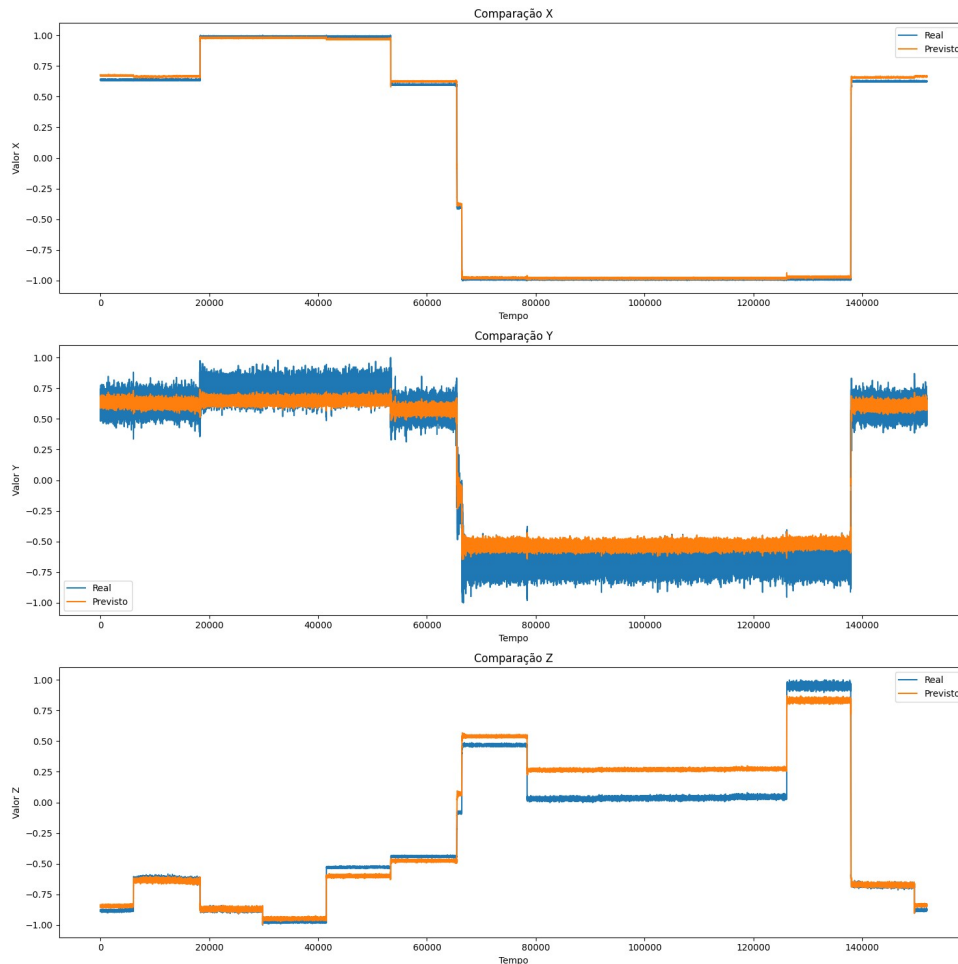


Figura 5.9: Gráfico de predição nos dados de Validação (escala normalizada).

Tabela 5.10: Métricas nos dados do Sensor 2 (aleatório).

Métrica	Valor
MSE	0,02060896863335962°
R ²	0,9531063938462528

O coeficiente de determinação $R^2 = 0,9531$ demonstra que o modelo explica cerca de 95,3% da variância observada, resultado consistente com o esperado para um processo de generalização adequado.

As Figuras 5.11 e 5.12 ilustram a comparação entre as séries reais e previstas para os três eixos, na escala aumentada e na escala normal da amplitude espacial total do sensor, respetivamente. Nota-se que, embora existam pequenas discrepâncias ponto a ponto, o modelo acompanha de forma fiel a tendência global dos sinais, inclusive nas regiões de transições abruptas. Tal comportamento confirma que o *LSTM* é capaz de captar as dinâmicas temporais e reproduzi-las de forma consistente, mesmo diante de variações decorrentes de sensores distintos.




Figura 5.10: Gráfico de predição nos dados de validação (escala desnormalizada).

Em síntese, os resultados confirmam a robustez do modelo frente a dados reais, comprovando sua capacidade de generalização de $R^2 = 0,9531$, próximos a 1 conforme Montgomery [72], e explicada em novos dados (não vistos), segundo Collet, descrito na Seção 5.1. Essa característica é particularmente relevante para cenários de aplicação prática no SIMAF, nos quais múltiplos sensores podem ser utilizados sem necessidade de calibração individualizada, ampliando a escalabilidade e confiabilidade do sistema.

Ressalta-se, contudo, que este resultado é apresentado exclusivamente como evidência de robustez metodológica, não constituindo a abordagem adotada na implementação final do simulador. Permanecem duas etapas complementares e com efeitos em horizontes distintos:

(i) **Efeito de longo prazo:** a aplicação da predição do modelo diretamente sobre o dado bruto para expurgar o ruído, incluindo o *bias* responsável pela derivação (acúmulo residual que provoca *drift*) ao longo do tempo,

(ii) **Efeito de curto prazo:** a conjugação com o KF (Filtro de Kalman), de modo a promover estabilização adicional da série temporal, suavizando flutuações instantâneas e melhorando a resposta operacional no imediato.

Sob essa perspectiva, infere-se que:

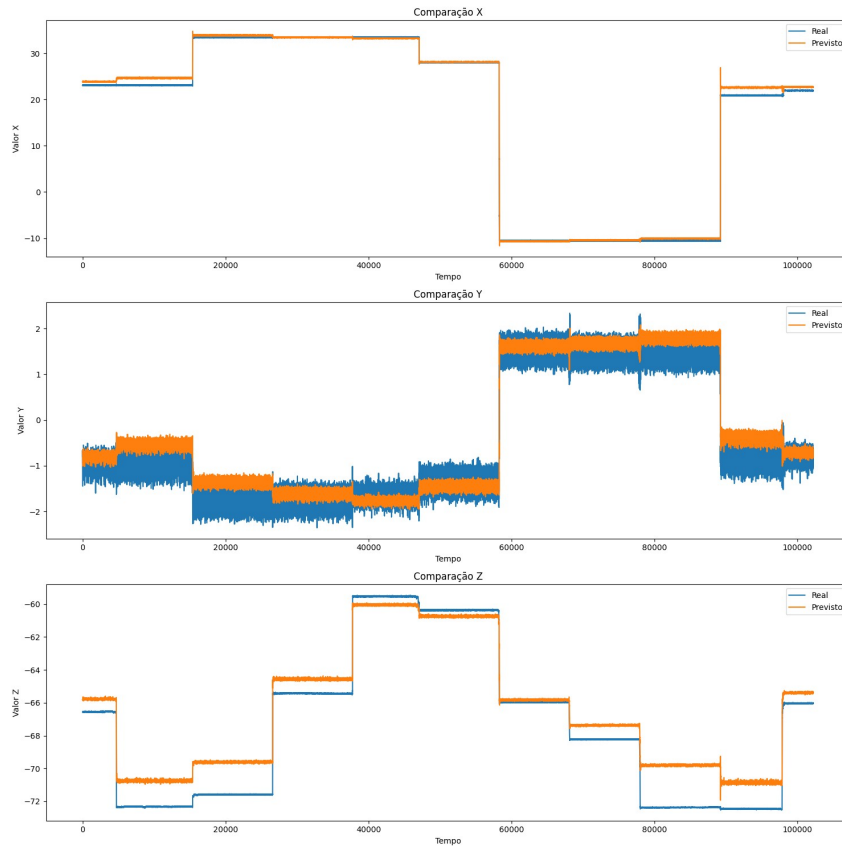


Figura 5.11: Predição nos dados do Sensor 2 (escala ampliada).

1. A aplicação da predição do modelo no sinal bruto tenderá a remover o componente ruidoso — em especial o *bias* — reduzindo a derivação de longo prazo.
2. Ao deduzir o ruído do dado bruto, espera-se uma estabilização mais linear do sinal. Somada ao KF, essa linearidade deverá ser ainda mais pronunciada, favorecendo a aderência ao limite de aproximadamente dois milésimos de radiano ($0,1125^\circ$) para mais ou para menos do valor aferido na luneta de pontaria ou erro de cálculo, conforme o Caderno de Instrução CI 6-199/1 [18, 19, 20].

5.6.4 Análise da Aplicação do Modelo na Estabilização dos Dados do Sensor 1

Em uma prova de conceito, o modelo foi aplicado com o objetivo de estabilizar os dados do sensor, com ênfase na mitigação do arrasto (derivação) de longo prazo. Para isso, utilizou-se um parâmetro escalar, denominado *Fator de Correção* $\alpha \in (0, 1]$, que pondera a influência da predição do modelo no ajuste incremental dos valores observados.




Figura 5.12: Predição nos dados do Sensor 2 (escala normal).

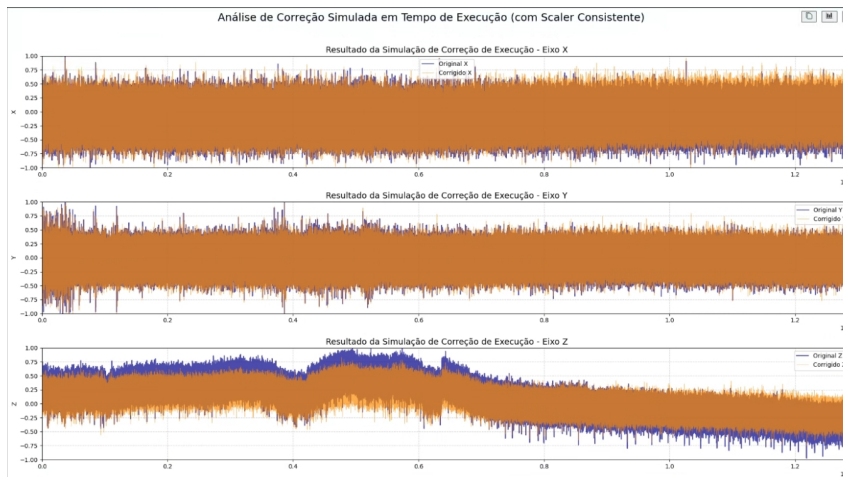


Figura 5.13: Correção do arrasto em dados do Sensor 1 com aplicação do Fator de Correção.

Formulação da correção incremental e validade. A estratégia de correção proposta fundamenta-se no controle incremental do sinal, tomando como referência a dinâmica (primeiras diferenças) do sinal observado e da predição. Em cada instante t , computam-

se:

$$\Delta y_t = y_t - y_{t-1} \quad \text{e} \quad \Delta \hat{y}_t = \hat{y}_t - \hat{y}_{t-1}.$$

Define-se o erro incremental de variação como $(\Delta y_t - \alpha \Delta \hat{y}_t)$ e atualiza-se o sinal corrigido por integração recursiva:

$$y_t^{\text{corrigido}} = y_{t-1}^{\text{corrigido}} + (\Delta y_t - \alpha \Delta \hat{y}_t). \quad (5.3)$$

A Equação 5.3 é consistente quando a predição \hat{y}_t modela a componente indesejada do sinal (ruído/bias e sua dinâmica). Nessa formulação, a correção atua na derivada discreta do processo (*primeira diferença*), o que confere duas propriedades: (i) preservação da estrutura temporal do sinal observado, pois a atualização é recursiva na dinâmica; e (ii) supressão progressiva de componentes de tendência indesejada (deriva), quando a predição captura, ainda que parcialmente, o termo responsável pelo *drift*. Em termos de controle, a Equação 5.3 se comporta como um compensador de ganho α aplicado ao incremento previsto, reduzindo a contribuição desta componente no estado acumulado. Portanto, a formulação faz sentido e é adequada ao objetivo de atenuação da deriva de longo prazo quando \hat{y}_t representa a dinâmica do ruído/bias a ser removido.

Efeito quantitativo por fator de correção. Para quantificar a estabilização, avaliou-se a variação percentual do desvio-padrão (do inglês, *Standard Deviation-STD*) e do valor quadrático médio (do inglês, *Root Mean Square-RMS*) entre o sinal original e o sinal corrigido, nos três eixos (X, Y e Z), sob cinco fatores de correção $\alpha \in \{0.2, 0.4, 0.6, 0.8, 1.0\}$. O *STD* expressa a dispersão das amostras em torno da média, enquanto o *RMS*, conforme definido por Oppenheim e Schaffer [75], representa a amplitude ou energia efetiva do sinal, refletindo sua potência média. Reduções negativas nas variações percentuais de *STD* e *RMS* indicam maior estabilização, caracterizada por menor dispersão e menor energia residual no sinal. A Tabela 5.11 resume, por fator, a média das variações percentuais entre os três eixos, evidenciando atenuação substancial e monotônica com o aumento de α .

Tabela 5.11: Resumo por fator de correção: variações percentuais médias (entre eixos) de STD e RMS do sinal corrigido em relação ao original. Valores negativos indicam redução (estabilização).

Fator α	Δ <i>STD</i> (%)	Δ <i>RMS</i> (%)
0.2	-18.92	-18.98
0.4	-37.61	-37.11
0.6	-55.83	-55.08
0.8	-72.87	-71.96
1.0	-84.80	-83.98

Observa-se que a estabilização é consistente em todos os fatores, com reduções médias em *STD* e *RMS* que evoluem aproximadamente de $\sim 19\%$ (para $\alpha = 0.2$) até $\sim 85\%$ (para $\alpha = 1.0$). Em particular, $\alpha \in [0.8, 1.0]$ produz as maiores reduções, o que é compatível com a interpretação de que a predição captura um componente dominante do ruído/deriva que, ao ser deduzido, diminui substancialmente a variabilidade de longo prazo.

Conclusão e encadeamento com o estágio de curto prazo. Os resultados indicam atenuação significativa da deriva de longo prazo, coerente com a expectativa de mitigação de componentes de *bias* e ruído correlacionado. Concluída esta etapa, o sinal corrigido pode ser encaminhado ao estágio subsequente de estabilização de curto prazo (por exemplo, o estimador estocástico recursivo KF), cuja função é reduzir oscilações residuais de alta frequência e melhorar a suavidade operacional do traçado, em complemento à correção de tendência promovida pela Equação 5.3.

5.6.5 Eficiência dos Resultados

Arquitetura de processamento em cascata. A solução adota uma **cadeia de estabilização em três estágios**, na qual cada módulo opera sobre a saída já tratada do estágio anterior, realizando uma *estabilização da estabilização*:

1. **Fusão no *ES* (IMU):** combinação sensorial (acelerômetro, giroscópio, magnetômetro) com filtragem embarcada, produzindo um vetor de atitude com supressão de ruído bruto e coerência entre canais.
2. **LSTM (horizonte de longo prazo):** aplicado sobre a saída da fusão para **redução de deriva (drift) de longo prazo**, isto é, mitigação de tendências cumulativas associadas a *bias* e componentes correlacionadas no tempo.
3. **Filtro de Kalman (horizonte de curto prazo):** aplicado sobre a saída do LSTM para **atenuação de oscilações residuais de alta frequência**, refinando a resposta instantânea sem reintroduzir deriva.

Dessa forma, o Kalman não opera sobre o dado bruto, mas sim sobre um sinal já corrigido de deriva pelo LSTM; por sua vez, o LSTM opera sobre um sinal previamente fundido/filtrado no *ES*. Essa organização em cascata reduz latência e viabiliza operação em tempo necessário.

Critério principal: precisão. O requisito de precisão adotado estabelece erro máximo admissível de ± 2 milésimos, equivalente a $2 \times 0.05625^\circ = 0.1125^\circ$. Na Figura 5.14, as variações angulares instantâneas (Δ) reportadas nos estágios LSTM e Kalman permanecem abaixo desse limite, satisfazendo o critério.




Figura 5.14: Campo de provas: comparação simultânea entre saída da fusão (IMU), LSTM e Filtro de Kalman. Cada estágio estabiliza adicionalmente o sinal recebido do estágio anterior.

Evidência quantitativa de estabilização incremental. Os valores de Δ observados na Figura 5.14 são:

- **LSTM:** $\Delta X = 0.0800^\circ$, $\Delta Y = -0.0579^\circ$, $\Delta Z = 0.1451^\circ$.
- **Kalman:** $\Delta X = 0.0268^\circ$, $\Delta Y = 0.0071^\circ$, $\Delta Z = 0.0291^\circ$.

Definições de métricas utilizadas. Para quantificar o efeito de estabilização entre estágios, utiliza-se o módulo das variações instantâneas reportadas na figura, denotado por $|\Delta|$ (em graus). A partir desses valores, definem-se:

- **Redução absoluta** (Δ_{abs}): diferença direta entre os módulos das variações do estágio anterior (LSTM) e do estágio posterior (Kalman),

$$\Delta_{\text{abs}} = |\Delta|_{\text{LSTM}} - |\Delta|_{\text{Kalman}}.$$

Mede o quanto, em graus, a variação instantânea foi reduzida pelo filtro de Kalman em relação à saída do LSTM.

- **Redução percentual relativa** (Δ_{rel}): redução absoluta normalizada pelo valor do estágio anterior (LSTM),

$$\Delta_{\text{rel}} = \frac{|\Delta|_{\text{LSTM}} - |\Delta|_{\text{Kalman}}}{|\Delta|_{\text{LSTM}}} \times 100\%,$$

isto é, a fração (em %) de $|\Delta|_{\text{LSTM}}$ que foi suprimida pelo filtro de Kalman. Quando o contexto já deixa claro que é uma redução relativa, também referimos como *delta relativo*.

Com essas definições, a Tabela 5.12 apresenta $|\Delta|$ por eixo para o modelo LSTM e para o filtro de Kalman, bem como as reduções absoluta (Δ_{abs}) e percentual relativa (Δ_{rel}).

Leitura técnica:

Tabela 5.12: Refino do Kalman sobre a saída do LSTM: reduções de $|\Delta|$ por eixo (valores em graus).

Eixo	$ \Delta _{\text{LSTM}}$	$ \Delta _{\text{Kalman}}$	Δ_{abs}	Δ_{rel}
X	0.0800	0.0268	0.0532	66.5%
Y	0.0579	0.0071	0.0508	87.7%
Z	0.1451	0.0291	0.1160	79.9%

- O LSTM atua como compensador de **longo prazo**, reduzindo a *derivação* associada a *bias* e a componentes autocorrelacionadas, o que limita o acúmulo de erro (*drift*) ao longo do tempo.
- O filtro de Kalman, operando sobre esse sinal já livre de deriva de longo prazo, realiza **filtragem recursiva de curto prazo**, suprimindo flutuações de alta frequência e reduzindo a amplitude efetiva das variações instantâneas ($|\Delta|$), conforme quantificado na Tabela 5.12.

Todos os $|\Delta|$ finais do filtro de Kalman permanecem bem abaixo de 0.1125° , aumentando a folga em relação ao limite de precisão.

Conclusão. A cadeia Fusão \rightarrow modelo LSTM \rightarrow filtro de Kalman implementa **estabilização em cascata**: cada estágio acrescenta uma camada de correção apropriada à sua escala temporal (deriva de longo prazo no LSTM; oscilações de curto prazo no filtro de Kalman). Essa *estabilização da estabilização* cumpre o requisito de precisão (± 2 milésimos; 0.1125°) sem hardware adicional e viabiliza a integração no SIMAF.

5.7 Implantação da Solução no Simulador SIMAF

A implementação desta nova solução ao *software* de simulação já foi feita no laboratório de desenvolvimento do Simulador, localizado no Centro de Desenvolvimento de Sistemas (CDS), no Quartel General do Exército (QGEX), sediado em Brasília-DF. Porém, este trabalho só termina com a implementação da solução ao ambiente de produção, que está devidamente validado e homologado pelas equipes dos dois SIMAF implantados no Brasil, conforme já abordado na Subseção 2.4.2. A seguir está explicado o processo para melhor elucidação, o que se deu da seguinte forma: fixação do Sistema Computacional Embarcado (do inglês *Embedded Systems-ES*), com o sensor *IMU*, no tubo do Obuseiro, como observado na Figura 5.15, que é responsável pela captura do dado em tempo de execução necessária ao simulador. Importante ressaltar que o suporte de fixação existente no SIMAF tem que ser redesenhado para o novo *ES* deste Trabalho.



Figura 5.15: Fixação do sensor ao obuseiro.

O processamento dos dados em um *ES* externo de maior poder de processamento, esse tratamento dos dados ocorre em etapas com a apresentação de cada filtro, e do modelo aplicado aos dados, em janelas como *dashboard*, conforme pode ser observado na Figura 5.16. O *dashboard* dos filtros garantiu a devida depuração para análises necessárias.

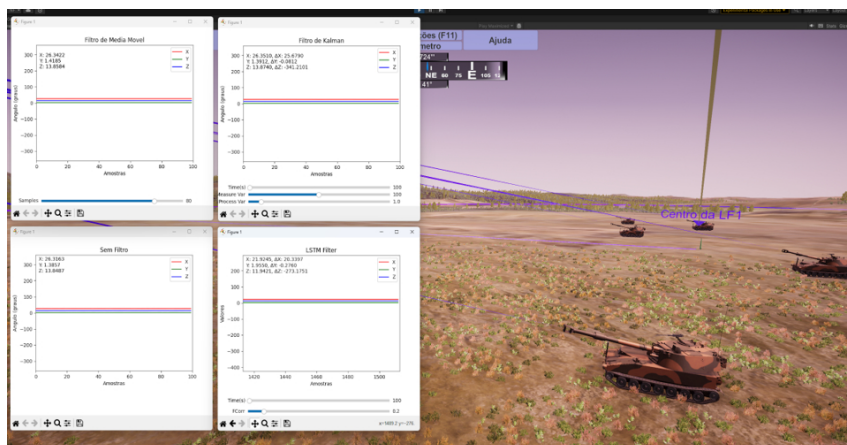


Figura 5.16: Janelas com a exposição dos dados por etapa.

Após os dados serem processados, estes são direcionados a um outro Sistema Computacional Embarcado, responsável pela execução do *software* de simulação, denominado SIMAF. Importante ressaltar que a Figura 5.16 mostra um mesmo *ES* processando tanto a solução com seus *dashboard*, quanto o *software* do SIMAF, mostrando que a solução entrega um excelente desempenho, mas ressalta-se que não é a arquitetura desejada a ser implementada, que conta com *ES* distintos, ambos com alto poder de processamento.

Por fim, a solução deste Trabalho entrega a direção e a elevação do material real de tiro para material simulado, ou seja, ao mudar a pontaria do material de tiro real, que é um processo mecânico, os dados processados movem o material de tiro simulado. Esse processo garantiu o resultado qualitativo pela observação do ponto de impacto por meio da linha de trajetória, cujo início pode ser observado na Figura 5.16 e seu fim na Figura



Figura 5.17: Ponto de impacto.

5.17, por meio do qual não se observou alteração do ponto de impacto como ocorria anteriormente, com grandes oscilações e derivação constante.

O Capítulo 6 aborda a Conclusão, destacando as principais contribuições deste trabalho para validar a aplicação das técnicas de ML e otimização no SIMAF, estabelecendo novas diretrizes para futuras implementações em simuladores militares.

Capítulo 6

Conclusões e Trabalhos Futuros

6.1 Conclusões

Este trabalho apresentou uma arquitetura de estabilização inercial em *tempo necessário* para o SIMAF, orientada ao uso de sensores de baixo custo e sujeita a ruídos eletromagnéticos, *bias* e interferências parasitárias. O problema abordado compreendeu: (i) derivações de longo prazo associadas a componentes autocorrelacionadas e deslocamentos de *bias*; e (ii) oscilações de curto prazo (alta frequência) que degradam a repetibilidade angular e a precisão operacional do simulador.

A solução foi organizada em cascata: Fusão Embarcada no $ES \rightarrow LSTM$ (correção de longo prazo) \rightarrow *Filtro de Kalman* (estabilização de curto prazo). Cada estágio opera sobre a saída já tratada do anterior, caracterizando uma estabilização incremental. A fusão embarcada reduz ruído bruto e assegura coerência física entre acelerômetro, giroscópio e magnetômetro. A *LSTM* mitiga derivações de longo prazo (tendências cumulativas ligadas a *bias*). E o *Filtro de Kalman* suprime oscilações residuais de alta frequência, refinando a resposta instantânea sem reintroduzir derivações.

Do ponto de vista experimental, a cadeia atendeu ao requisito de precisão do SIMAF, com o erro máximo admissível de ± 2 milésimos, equivalente a 0.1125° . No *campo de provas*, foram observadas variações instantâneas ($|\Delta|$) nos estágios *LSTM* e *Filtro de Kalman*, a partir das quais se calcularam reduções absolutas e relativas.

A Tabela 6.1 consolida os valores de $|\Delta|$ e as reduções obtidas por eixo, evidenciando reduções de 66.5% (X), 87.7% (Y) e 79.9% (Z) após a aplicação do *Filtro de Kalman* sobre a saída da *LSTM*. Todos os $|\Delta|$ finais permaneceram confortavelmente abaixo de 0.1125° .

Do ponto de vista metodológico, destacam-se: (i) a correção incremental baseada em primeiras diferenças e ganho de compensação na saída da *LSTM*, adequada para mitigar derivações sem distorcer a estrutura temporal; (ii) a decomposição funcional por escala temporal (longo prazo na *LSTM*, curto prazo no *Filtro de Kalman*), que favorece *tuning*

Tabela 6.1: Refino do *Filtro de Kalman* sobre a saída da *LSTM*: reduções de $|\Delta|$ por eixo (valores em graus).

Eixo	$ \Delta _{LSTM}$	$ \Delta _{Kalman}$	Δ_{abs}	Δ_{rel}
X	0.0800	0.0268	0.0532	66.5%
Y	0.0579	0.0071	0.0508	87.7%
Z	0.1451	0.0291	0.1160	79.9%

independente por eixo; e (iii) a viabilidade operacional em *tempo necessário* em CPU de baixo desempenho, com ajuste dinâmico de parâmetros e ausência de acúmulo de *buffer*.

Em síntese, a arquitetura em cascata estabiliza sinais inerciais de sensores com conformidade ao requisito de precisão, sem necessidade de hardware adicional. A principal contribuição é a engenharia de um *pipeline* determinístico, mensurável e adaptável, que combina *LSTM* para mitigação de derivações de longo prazo com *Filtro de Kalman* para estabilização de curto prazo, fornecendo ganhos objetivos de desempenho angular.

6.2 Trabalhos Futuros

O próximo passo consiste na homologação operacional na Academia Militar das Agulhas Negras (AMAN), como entrega sucessiva do Centro de Desenvolvimento de Sistemas (CDS). Esse processo objetiva validar desempenho, calibrar parâmetros com o usuário final e consolidar perfis de operação para o Simulador de Apoio de Fogo. O plano contempla:

- Ensaios com o cliente final no contexto do Simulador de Apoio de Fogo, cobrindo roteiros representativos, condições controladas e cenários não estacionários. Esses ensaios devem incluir sequências com acelerações suaves e abruptas, pausas prolongadas, perturbações eletromagnéticas e vibroacústicas, bem como variações ambientais (temperatura e umidade);
- Ponderação conjunta de parâmetros da *LSTM* (janela temporal, arquitetura, regularização e fator de correção por eixo) e do *Filtro de Kalman* (covariâncias de processo e de medida por eixo, discretização do modelo de estado), buscando compromisso ótimo entre precisão, responsividade e robustez. A ponderação deverá ser documentada por cenário, com rastreabilidade de versões e critérios objetivos de aceitação;
- Coleta de *feedback* técnico para ajustes finos e identificação de requisitos adicionais do usuário operacional: latência máxima tolerável, limites de saturação, comportamento sob interferências, requisitos de visualização e diagnóstico. O *feedback* servirá de base para revisões do manual de emprego e de manutenção.

- Planos de melhoria, incluindo:
 - Calibração adaptativa *on-line* do fator de correção por eixo na *LSTM*: ajuste automático do ganho de correção por eixo (X, Y, Z) em função de métricas de qualidade do sinal e do regime dinâmico, preservando a mitigação de derivações de longo prazo sem supercorreções;
 - Estimadores híbridos (e.g., *LSTM-CNN*) para detecção de padrões transientes e melhoria da previsão de tendência sob excitações rápidas;
 - Filtro de Kalman Adaptativo (*Adaptive Kalman Filter-AKF*): adaptação *on-line* de Q e R em função do estado e/ou das inovações, tornando o filtro mais rígido em regimes estáveis e mais responsivo durante manobras ou perturbações;
 - Filtro de Kalman Ponderado por Frequência (*Frequency-weighted Kalman Filter-FWKF*): ponderação seletiva por banda (ou banco de filtros) para suprimir faixas de ruído específicas e preservar conteúdo informativo, com *tuning* de Q/R dependente da frequência;
 - Diagnóstico de estabilidade por *Allan deviation* e análise espectral *on-line* (do inglês, *Power Spectral Density — PSD*), com alertas para mudanças de regime que motivem o reajuste de parâmetros;
 - Mecanismos de *fallback* e autodiagnóstico para operação prolongada: detecção de saturação, perda de atualização e divergência das inovações, com comutação controlada para modos seguros (por exemplo, operação apenas com fusão no *ES*) e posterior retorno ao regime nominal.

A homologação na AMAN deverá consolidar a validação externa do desempenho, a rastreabilidade de parâmetros e a definição de perfis de *tuning* por cenário de emprego, estabelecendo protocolos de verificação periódica que mantenham a precisão dentro de ± 2 milésimos. Espera-se, com isso, ampliar a confiabilidade, a sustentabilidade (redução de consumo de recursos em campo) e a versatilidade de aplicação militar e civil do sistema.

Por fim, os resultados deste trabalho foram publicados no artigo “*Noise Reduction on Inertial Measurement Unit Sensors in Ballistic Simulators using Deep Models*” (ID 144), apresentado em 26 de novembro de 2025, durante a sessão *Computational Intelligence Techniques and its Applications* do 46º Congresso Ibero Latino-Americano de Métodos Computacionais em Engenharia (CILAMCE 2025), realizado em Vitória-ES. O artigo apresentou uma abordagem comparativa entre métodos tradicionais de filtragem e modelos de aprendizado profundo aplicados à redução de ruído em sensores inerciais (IMU) de baixo custo empregados em simuladores balísticos, demonstrando que a aplicação de

modelos recorrentes do tipo LSTM permite estabilizar medições sujeitas a interferências eletromagnéticas e variações ambientais, reduzindo a deriva e ampliando a confiabilidade das medições em sistemas de simulação militar.

Referências

- [1] Brasileiro, Exército: *Caderno de Instrução Emprego da Simulação. Edição Experimental. Itens 3.2.3*. Exército Brasileiro, 2020.
[https://www.sgex.eb.mil.br/sg8/004_documentos_instrucao/01_cadernos_de_instrucao\(ci\)/port_n_133_coter_02out2020.html](https://www.sgex.eb.mil.br/sg8/004_documentos_instrucao/01_cadernos_de_instrucao(ci)/port_n_133_coter_02out2020.html). xi, 7, 8, 9, 10, 11, 16
- [2] CA-Sul: *SIMAF*. <https://casul.eb.mil.br/index.php/simaf>, acesso em 2024-04-11. xi, 2, 11, 12, 20
- [3] Duarte, Dartanhan do Nascimento: *Proposta de metodologia de emprego do sistema de simulação de apoio de fogo no adestramento dos pelotões de morteiro pesado*. Biblioteca do Exército, 2020.
<http://bdex.eb.mil.br/jspui/handle/123456789/7172>, acesso em 2024-06-11. xi, 2, 3, 9, 12, 13, 15, 16
- [4] Projeto SAFO: *Relatório Histórico de Tickets do Sistema SAFO – Fase III*. Relatório Técnico, Sistema TRAC – Ticket Report and Analysis for Code, novembro 2019. Relatório técnico interno. Consulta personalizada (Custom Query) contendo o histórico de defeitos, melhorias e análises do desenvolvimento do sistema SAFO. xi, 16, 17, 19
- [5] Brasileiro, Exército: *Portaria Nº 011-COTER, de 21 de novembro de 2005*. Brasília, DF, 2005. [http://www.sgex.eb.mil.br/sg8/004_documentos_instrucao/01_cadernos_de_instrucao\(ci\)/port_n_011_coter_21nov2005.html](http://www.sgex.eb.mil.br/sg8/004_documentos_instrucao/01_cadernos_de_instrucao(ci)/port_n_011_coter_21nov2005.html), Acesso em: 24 ago. 2024. xi, 18, 19
- [6] Bridi, André Luis Simião: *O rendimento escolar dos cadetes do Curso de Artilharia da AMAN e o emprego do Simulador de Apoio de Fogo na instrução*. Sangue Novo, 18(29):52–57, 2019.
<https://www.ebrevistas.eb.mil.br/SN/article/view/4387>, acesso em 2024-04-11. 1, 13, 14, 15, 20, 42
- [7] Savchenko, Vitalii, A. Y. Derevjanchuk, Taras Dzyuba e D. Moskalenko: *Intensive Training Model for Artillery Cadets Using 3D Simulators*. Advances in Military Technology, 2023. <https://api.semanticscholar.org/CorpusID:257268122>. 1
- [8] Wilin, Leonel Francisco Slim: *O simulador de apoio de fogo e a influência no adestramento de tropas*. Revista Doutrina Militar Terrestre, 9(28):56–61, 2021, ISSN 2317-6350. <https://www.ebrevistas.eb.mil.br/DMT/article/view/8931>, acesso em 2024-06-11. 1, 15

- [9] Girardi, Romullo, Adinê Alves Pereira Filho, Gabriel Pinheiro Teodoro e Jauvane C. de Oliveira: *TAT VR: a Virtual Reality Simulator for Military Shooting Training*. Proceedings of the 24th Symposium on Virtual and Augmented Reality, 2022. <https://api.semanticscholar.org/CorpusID:269010396>. 1
- [10] Chebanyuk, Olena e Anton Yukhymenko: *Approach to Prevent of Spoken Information Leakage through Gyroscope and Accelerometer Sensors in Mobile Devices with Android Operation System*. Information Theories and Applications, 2021. <https://api.semanticscholar.org/CorpusID:266356156>. 1
- [11] Monteiro, Martín e Arturo Carlos Marti: *Resource Letter MDS-1: Mobile devices and sensors for physics teaching*. American Journal of Physics, 2022. <https://api.semanticscholar.org/CorpusID:248339168>. 1
- [12] Ryumin, Dmitry, Denis Ivanko e Elena V. Ryumina: *Audio-Visual Speech and Gesture Recognition by Sensors of Mobile Devices*. Sensors (Basel, Switzerland), 23, 2023. <https://api.semanticscholar.org/CorpusID:257072011>. 1
- [13] Hu, Xiaofeng, Jinming Hu e Miaomiao Hou: *A two-step machine learning method for casualty prediction under emergencies*. Journal of Safety Science and Resilience, 3(3):243–251, 2022, ISSN 2666-4496. <https://www.sciencedirect.com/science/article/pii/S2666449622000160>. 1, 7, 36
- [14] Centro de Instrução de Blindados - CIBld: *Centro de instrução de blindados - cibld*, 2025. <https://www.cibld.eb.mil.br/>, Acesso em: 16 out. 2025. 2
- [15] Santos, Rômulo Ferreira dos, Claudio Gottschalg Duque, Tomás Roberto Cotta Orlandi e Simão Domingos Sebastião: *Viaturas militares autônomas elétricas: Avanços, desafios e impactos na mobilidade futura*. Revista de Geopolítica, 16(4):e643, ago. 2025. <https://revistageo.com.br/revista/article/view/643>. 2
- [16] Figueira, Nina Machado: *Sistemas e materiais de emprego militar sensorizados e sua importância para a consciência situacional no ambiente operacional terrestre*. Tese de Mestrado, Escola de Aperfeiçoamento de Oficiais (EsAO), Rio de Janeiro, 2020. <http://bdex.eb.mil.br/jspui/handle/123456789/13964>. 2
- [17] Bultmann, Simon, Raphael Memmesheimer e Sven Behnke: *External Camera-Based Mobile Robot Pose Estimation for Collaborative Perception with Smart Edge Sensors*. 2023 IEEE International Conference on Robotics and Automation (ICRA), páginas 8194–8200, 2023. <https://api.semanticscholar.org/CorpusID:257378529>. 2
- [18] Estado-Maior, Brasil Exército: *PORTARIA Nº 013-COTER, DE 21 DE NOVEMBRO DE 2005*. [http://www.sgex.eb.mil.br/sg8/004_documentos_instrucao/01_cadernos_de_instrucao\(ci\)/port_n_013_coter_21nov2005.html](http://www.sgex.eb.mil.br/sg8/004_documentos_instrucao/01_cadernos_de_instrucao(ci)/port_n_013_coter_21nov2005.html), acesso em 2024-08-08. 3, 69, 82

- [19] Estado-Maior, Brasil Exército: *Técnica de tiro de Artilharia de Campanha*. BDEx, 2001. <http://bdex.eb.mil.br/jspui/handle/123456789/393>, acesso em 2024-08-08. 3, 20, 69, 82
- [20] Estado-Maior, Brasil Exército: *Topografia do artilheiro*. BDEx, 1986. <http://bdex.eb.mil.br/jspui/handle/123456789/412>, acesso em 2024-08-08. 3, 69, 82
- [21] Oliveira Gressler, Henrique de: *DIEx Simplificado No 29-DACDS-SMA/DACDS/CDS*. Relatório Técnico EB: 64202.004463/2024-32, Exército Brasileiro, Destacamento Avançado do DCT em Santa Maria, Brasília, DF, 2024. Documento assinado eletronicamente. 3, 4
- [22] Valenti, Roberto G., Ivan Dryanovski e Jizhong Xiao: *Keeping a good attitude: A quaternion-based orientation filter for imu and margs*. *Sensors*, 15(8):19302–19330, 2015, ISSN 1424-8220. <https://www.mdpi.com/1424-8220/15/8/19302>. 3, 27, 28, 30, 42, 66, 68
- [23] Han, Shipeng, Zhen Meng, Olatunji Omisore, Toluwanimi Akinyemi e Yuepeng Yan: *Random error reduction algorithms for mems inertial sensor accuracy improvement—a review*. *Micromachines*, 11(11):1021, 2020. <https://www.mdpi.com/897892>. 3, 7, 8, 25, 26, 27, 28, 37, 38, 39, 63
- [24] Brasileiro, Exército: *Portaria EME/C Ex nº 902, de 28 de outubro de 2022: Diretriz para o Sistema de Simulação do Exército Brasileiro (SSEB) – EB20-D-04.010*. Ministério da Defesa, Estado-Maior do Exército, 2022. https://www.sgex.eb.mil.br/sg8/006_outras_publicacoes/01_diretrizes/04_estado-maior_do_exercito/port_n_902_eme_28out2022.html. 3, 7, 8
- [25] Mahdi, Ahmed E, Ahmed Azouz, Ahmed E Abdalla e Ashraf Abosekeen: *A machine learning approach for an improved inertial navigation system solution*. *Sensors*, 22(4):1687, 2022. <https://www.mdpi.com/1509658>. 7, 24, 25
- [26] Hosseinyalamdary, Siavash: *Deep kalman filter: Simultaneous multi-sensor integration and modelling; a gnss/imu case study*. *Sensors (Basel, Switzerland)*, 18(5):1316, 2018, ISSN 1424-8220. <https://www.mdpi.com/285958>. 7, 8, 26, 27, 36, 37, 38, 39, 49
- [27] Saidi, Firas e Zouheir Trabelsi: *A hybrid deep learning-based framework for future terrorist activities modeling and prediction*. *Egyptian Informatics Journal*, 23(3):437–446, 2022, ISSN 1110-8665. <https://www.sciencedirect.com/science/article/pii/S1110866522000263>. 7, 36
- [28] Zahara, S, Sugianto e M B Ilmiddaviq: *Consumer price index prediction using Long Short Term Memory (LSTM) based cloud computing*. *Journal of Physics: Conference Series*, 1456(1):012022, 2020. <https://dx.doi.org/10.1088/1742-6596/1456/1/012022>. 7, 8, 50

- [29] Aal, Hadeel, Shereen Taie e Nashwa El-Bendary: *An optimized RNN-LSTM approach for parkinson's disease early detection using speech features*. Bulletin of Electrical Engineering and Informatics, 10(5):2503–2512, 2021, ISSN 2302-9285. <https://beei.org/index.php/EEI/article/view/3128>. 7, 8
- [30] Mundt, Marion, William R Johnson, Wolfgang Potthast, Bernd Markert, Ajmal Mian e Jacqueline Alderson: *A comparison of three neural network approaches for estimating joint angles and moments from inertial measurement units*. Sensors, 21(13):4535, 2021. 7, 25
- [31] Law, Averill M.: *Simulation Modeling and Analysis*. McGraw-Hill series in industrial engineering and management science. McGraw-Hill Education, New York, NY, 5th edição, 2013, ISBN 978-0-07-340132-4. <http://www.averill-law.com>, <https://staff.universitaspahlawan.ac.id/web/upload/materials/958-materials.pdf>, Includes bibliographical references and index. 7, 8, 9
- [32] Fletcher, J. D.: *Education and training technology in the military*. Science, 323(5910):72–75, 2009. <https://www.science.org/doi/abs/10.1126/science.1167778>. 7, 10
- [33] Sokolowski, J.A. e C.M. Banks: *Modeling and Simulation Fundamentals: Theoretical Underpinnings and Practical Domains*. Wiley, 2010, ISBN 9780470590614. <https://books.google.com.br/books?id=oza7FSuIIDgC>. 7, 8, 9, 10, 12
- [34] Shannon, R.E.: *Systems Simulation: The Art and Science*. Prentice-Hall, 1975, ISBN 9780138818395. <https://books.google.com.br/books?id=cWpRAAAAMAAJ>. 8
- [35] Banks, Jerry, John S. Carson, Barry L. Nelson e David Malcolm Nicol: *Discrete-Event System Simulation*. Prentice-Hall, 5ª edição, 2010, ISBN 9780136062127. 8, 9
- [36] Cellier, F.E. e E. Kofman: *Continuous System Simulation*. Springer US, 2006, ISBN 9780387302607. https://books.google.com.br/books?id=-_ENNypwV0kC. 8, 9
- [37] Tolk, Andreas: *Engineering principles of combat modeling and distributed simulation*. John Wiley & Sons, 2012. <https://onlinelibrary.wiley.com/doi/book/10.1002/9781118180310>. 9, 10
- [38] Ören, TI: *Body of knowledge of modeling and simulation (m&sbok): pragmatic aspects*. Proc. EMSS, páginas 4–6, 2006. <https://www.site.uottawa.ca/~oren/pubs-pres/2006/pres-0612-Barcelona-MSBOK.pdf>. 10
- [39] Brasileiro, Exército: *Caderno de Instrução Exercícios de Simulação Construtiva. Itens 1.3.1 e 1.3.2*. Exército Brasileiro, 2017. [http://www.sgex.eb.mil.br/sg8/004_documentos_instrucao/01_cadernos_d_e_instrucao\(ci\)/port_n_018_coter_08maio2017.html](http://www.sgex.eb.mil.br/sg8/004_documentos_instrucao/01_cadernos_d_e_instrucao(ci)/port_n_018_coter_08maio2017.html). 10, 16

- [40] Brasileiro, Exército: *Caderno de Instrução Exercícios de Simulação Virtual. Itens 1.2.8 e 1.2.9*. Exército Brasileiro, 2020.
[http://www.sgex.eb.mil.br/sg8/004_documentos_instrucao/01_cadernos_d_e_instrucao\(ci\)/port_n_134_coter_02out2020.html](http://www.sgex.eb.mil.br/sg8/004_documentos_instrucao/01_cadernos_d_e_instrucao(ci)/port_n_134_coter_02out2020.html). 12, 16
- [41] Brasileiro, Exército: *Caderno de Instrução Exercícios com Emprego da Simulação Viva. Edição Experimental. Itens 1.3.17*. Exército Brasileiro, 2021.
[http://www.sgex.eb.mil.br/sg8/004_documentos_instrucao/01_cadernos_d_e_instrucao\(ci\)/port_n_100_coter_23ago2021.html](http://www.sgex.eb.mil.br/sg8/004_documentos_instrucao/01_cadernos_d_e_instrucao(ci)/port_n_100_coter_23ago2021.html). 12, 16
- [42] Fontana, Mariana: *Projeto SIMAF - Simulador de Apoio de Fogo - DefesaNet*.
<https://www.defesanet.com.br/terrestre/projeto-simaf-simulador-de-apoio-de-fogo/>, acesso em 2024-04-11. 14
- [43] Catelli, Francisco, Odilon Giovannini e Paula Hoffmann: *Um problema didático: como determinar ângulos de paralaxe trigonométrica*. Revista Brasileira de Ensino de Física, 40(1), 2018, ISSN 1806-1117.
<https://doi.org/10.1590/1806-9126-RBEF-2017-0135>. 17
- [44] Bemm, Laerte, Alexandra de Oliveira Abdala Cousin e Wagner Szpak: *Visor de paralaxe*. REMAT: Revista Eletrônica da Matemática, 5(2):123–142, 2019.
<https://periodicos.ifrs.edu.br/index.php/REMAT/article/view/3393>. 17
- [45] Jeison: *O erro de paralaxe: Você sabe o que É?*
<https://blogdaqualidade.com.br/o-erro-de-paralaxe-parte-1/>, acesso em 2024-05-09. 18
- [46] Martins, André Ferrer Pinto: *Concepções de estudantes acerca do conceito de tempo: uma análise à luz da epistemologia de Gaston Bachelard*. Tese de doutorado, Faculdade de Educação, Universidade de São Paulo, São Paulo, 2004.
<https://www.teses.usp.br/teses/disponiveis/48/48134/tde-30112004-183841/pt-br.php>, Acesso em: 2024-10-25. 22
- [47] Groves, Paul: *Principles of GNSS, Inertial, and Multisensor Integrated Navigation Systems, Second Edition*. Artech House, março 2013, ISBN 9781580538947. 23, 24, 25, 27, 30
- [48] Zhao, Junqi e Esther Obonyo: *Convolutional long short-term memory model for recognizing construction workers' postures from wearable inertial measurement units*. Advanced Engineering Informatics, 46:101177, 2020, ISSN 1474-0346.
<https://www.sciencedirect.com/science/article/pii/S1474034620301488>. 24, 36, 37, 38, 39
- [49] Gao, Yunqi, Dianxi Shi, Ruihao Li, Zhe Liu e Wen Sun: *Gyro-net: Imu gyroscopes random errors compensation method based on deep learning*. IEEE Robotics and Automation Letters, 8(3), 2022.
<https://ieeexplore.ieee.org/document/9992043>. 26

- [50] Shaghaghian, Alireza e Paknoosh Karimaghaee: *Accuracy improvement in motion-measurement using frequency-weighted kalman filter*. IET Radar, Sonar & Navigation, 14(1):89–96, 2020. <https://ietresearch.onlinelibrary.wiley.com/doi/abs/10.1049/iet-rsn.2019.0249>. 26, 42
- [51] Shaghaghian, Alireza e Paknoosh Karimaghaee: *Accuracy improvement in motion-measurement using frequency-weighted kalman filter*. IET Radar, Sonar & Navigation, 14(1):89–96, 2020. <https://ietresearch.onlinelibrary.wiley.com/doi/full/10.1049/iet-rsn.2019.0249#>. 26, 47
- [52] Won, S. H.P., F. Golnaraghi e W.W. Melek: *A fastening tool tracking system using an imu and a position sensor with kalman filters and a fuzzy expert system*. IEEE transactions on industrial electronics (1982), 56(5):1782–1792, 2009, ISSN 0278-0046. <https://ieeexplore.ieee.org/document/4689397>. 27, 39
- [53] Titterton, David e John Weston: *Strapdown Inertial Navigation Technology*. Radar, Sonar and Navigation. Institution of Engineering and Technology, 2004. <https://digital-library.theiet.org/content/books/ra/pbra017e>. 30, 34, 46
- [54] Higgins, Walter T.: *A comparison of complementary and kalman filtering*. IEEE Transactions on Aerospace and Electronic Systems, AES-11(3):321–325, 1975. 30, 34
- [55] Montella, Corey: *The kalman filter and related algorithms: A literature review*. Journal of Algorithmic Finance, 2011. https://www.researchgate.net/publication/236897001_The_Kalman_Filter_and_Related_Algorithms_A_Literature_Review. 30, 31, 34, 35, 39
- [56] Forsyth, David Alexander e Jean Ponce: *Computer Vision: A Modern Approach*. Prentice Hall, 2002. <https://api.semanticscholar.org/CorpusID:53924538>. 31, 47, 65
- [57] Goodfellow, Ian, Yoshua Bengio e Aaron Courville: *Deep Learning Book*. MIT Press, 2017. <https://www.deeplearningbook.com.br/arquitetura-de-redes-neurais-long-short-term-memory/>. 36, 56, 57
- [58] Jiang, Changhui, Shuai Chen, Yuwei Chen, Boya Zhang, Ziyi Feng, Hui Zhou e Yuming Bo: *A mems imu de-noising method using long short term memory recurrent neural networks (lstm-rnn)*. Sensors, 18(10):3470, 2018. <https://www.mdpi.com/1424-8220/18/10/3470>. 37, 38, 39, 49, 63
- [59] Guang, Xingxing, Yanbin Gao, Pan Liu e Guangchun Li: *Imu data and gps position information direct fusion based on lstm*. Sensors, 21(7):2500, 2021. 37, 38, 39, 63, 64
- [60] Hochreiter, Sepp e Jürgen Schmidhuber: *Long Short-Term Memory*. Neural Computation, 9(8):1735–1780, 1997, ISSN 0899-7667. <https://doi.org/10.1162/neco.1997.9.8.1735>. 37
- [61] Zhang, Yuexin: *A fusion methodology to bridge gps outages for ins/gps integrated navigation system*. IEEE Access, 7:61296–61306, 2019. 37, 38, 39

- [62] Chollet, Francois: *Deep Learning with Python*. Manning Publications Co., USA, 1st edição, 2017, ISBN 1617294438. 38, 48, 49, 55, 56
- [63] Hochreiter, Sepp e Jürgen Schmidhuber: *Long Short-Term Memory*. *Neural Computation*, 9(8):1735–1780, 1997, ISSN 0899-7667. <https://doi.org/10.1162/neco.1997.9.8.1735>. 38
- [64] Ben-Nun, Tal e Torsten Hoefler: *Demystifying parallel and distributed deep learning: An in-depth concurrency analysis*. *ACM Comput. Surv.*, 52(4), agosto 2019, ISSN 0360-0300. <https://doi.org/10.1145/3320060>. 39, 60, 64
- [65] Gressler, Henrique de Oliveira e Márcia Cristina Cera: *O impacto da paralelização com openmp no desempenho e na qualidade das soluções de um algoritmo genético*. *Revista Brasileira de Computação Aplicada*, 6:35–47, 2014. <https://seer.upf.br/index.php/rbca/article/view/3660>. 39, 60, 64
- [66] Xue, Hui, Mengjie Ruan e Yifan Cheng: *A fixed length adaptive moving average filter-based synchrophasor measurement algorithm for p class pmus*. *Energies*, 12(21), 2019, ISSN 1996-1073. <https://www.mdpi.com/1996-1073/12/21/4168>. 39, 42, 62
- [67] Nagaraj, Deepak, Erik Schake, Patrick Leiner e Dirk Werth: *An rnn-ensemble approach for real time human pose estimation from sparse imus*. Em *Proceedings of the 3rd International Conference on Applications of Intelligent Systems*, páginas 1–6, 2020. 39, 64
- [68] Meißl, Florian, Florian Eibensteiner, Phillip Petz e Josef Langer: *Online handwriting recognition using lstm on microcontroller and imu sensors*. Em *2022 21st IEEE International Conference on Machine Learning and Applications (ICMLA)*, páginas 999–1004. IEEE, 2022. 39
- [69] Li, Tzuu Hseng S, Ping Huan Kuo, Chuan Han Cheng, Chia Ching Hung, Po Chien Luan e Chien Hsin Chang: *Sequential sensor fusion-based real-time lstm gait pattern controller for biped robot*. *IEEE Sensors Journal*, 21(2):2241–2255, 2020. 39, 63
- [70] Pedregosa, Fabian, Gaël Varoquaux, Alexandre Gramfort, Vincent Michel, Bertrand Thirion, Olivier Grisel, Mathieu Blondel, Peter Prettenhofer, Ron Weiss, Vincent Dubourg, Jake Vanderplas, Alexandre Passos, David Cournapeau, Matthieu Brucher, Matthieu Perrot e Édouard Duchesnay: *Scikit-learn: Machine learning in Python*. *Journal of Machine Learning Research*, 12:2825–2830, 2011. 47, 50
- [71] Greff, Klaus, Rupesh K. Srivastava, Jan Koutník, Bas R. Steunebrink e Jürgen Schmidhuber: *Lstm: A search space odyssey*. *IEEE Transactions on Neural Networks and Learning Systems*, 28(10):2222–2232, 2017, ISSN 2162-2388. <http://dx.doi.org/10.1109/TNNLS.2016.2582924>. 47, 49
- [72] Montgomery, D.C., E.A. Peck e G.G. Vining: *Introduction to Linear Regression Analysis*. *Wiley Series in Probability and Statistics*. Wiley, 2021, ISBN 9781119578727. <https://books.google.com.br/books?id=20tMvgEACAAJ>. 56, 78, 81

- [73] Karimov, Jeyhun, Tilmann Rabl, Asterios Katsifodimos, Roman Samarev, Henri Heiskanen e Volker Markl: *Benchmarking distributed stream data processing systems*. Em *2018 IEEE 34th International Conference on Data Engineering (ICDE)*, páginas 1507–1518, 2018. 60, 64
- [74] Palach, Jan: *Parallel Programming with Python*. Packt Publishing Ltd., Birmingham, UK, 2014, ISBN 9781783288397. <https://www.packtpub.com/en-us/product/parallel-programming-with-python-9781783288397>. 60, 64
- [75] Oppenheim, Alan V., Ronald W. Schafer e John R. Buck: *Discrete-time signal processing (2nd ed.)*. Prentice-Hall, Inc., USA, 1999, ISBN 0137549202. <https://dl.acm.org/doi/10.5555/294797>. 84