

**SAMUEL FLÁVIO DE PAIVA ARAUJO
VINICIUS ROCHA PAIVA**

**PROCESSAMENTO DE DADOS RADAR PARA
ESTIMAÇÃO DA CINEMÁTICA DE ALVOS**

São Paulo
2022

**SAMUEL FLÁVIO DE PAIVA ARAUJO
VINICIUS ROCHA PAIVA**

**PROCESSAMENTO DE DADOS RADAR PARA
ESTIMAÇÃO DA CINEMÁTICA DE ALVOS**

Trabalho apresentado à Escola Politécnica
da Universidade de São Paulo para obtenção
do Título de Engenheiro Mecatrônico.

Área de Concentração:
Engenharia Mecatrônica

Orientador:
Prof. Dr. Thiago de Castro Martins

São Paulo
2022

AGRADECIMENTOS

Primeiramente a Deus que sempre esteve me abençoando, inclusive nas adversidades. Aos meus pais que são a base do cidadão que me formei. À minha esposa, Paula, que sempre me apoiou, esteve ao meu lado e me sustentou nos melhores e piores dias. As minhas irmãs, Raquel e Jael, que mesmo a distância me ajudam diariamente em diversos momentos e me proporcionam alegrias incontáveis. E aos meus amigos, que sem eles a vida seria mais triste e não conseguiríamos completar tal trabalho.

-- SFPA

Aos meus pais, Maria e Alfredo, que são a quem eu devo tudo que sou e que pretendo ser. À minha irmã, Natália, pela amizade e carinho, e pelas reflexões que me instigou a ter. À minha esposa, Clarissa, pelo companheirismo, suporte e paciência ao longo de mais esta empreitada.

-- VRP

Profissionalmente não poderíamos deixar de prestar agradecimentos aos apoios prestados pelo Dr. Cláudio Costa Motta ao disponibilizar o radar Gaivota-X para este trabalho. E ao professor Thiago, nosso orientador, que em nossas conversas nos proporcionou grande aprendizado.

-- SFPA e VRP

"Se apenas com idealismo nada se consegue de prático, sem essa força propulsora é impossível realizar algo de grande."

-Alte. Álvaro Alberto-

"Logo que comunicamos os nossos conhecimentos, deixamos de gostar deles suficientemente."

-Friedrich Nietzsche-

RESUMO

Este trabalho se dedica a desenvolver o acompanhamento de alvos para o Radar Gaivota-X da Marinha do Brasil, através da análise dos dados brutos fornecidos, determinação e eliminação de clutter, e uso de técnicas de filtragem para previsão da posição futura e correta correlação com as observações realizadas pelos sensores. A escolha de modelo dinâmico adequado as características do alvo é de fundamental importância para a correta predição da posição futura. Dessa forma, utilizou-se de dois modelos que são automaticamente selecionados de acordo com os parâmetros de movimento do alvo. O processo de filtragem dos dados radar se baseou na seleção de pontos repetitivos da imagem radar, construção de um mapeamento do terreno nas proximidades com os pontos selecionados, e posterior eliminação do clutter ao longo de toda a amostra de dados recolhida. Dentre as técnicas de filtragem foi realizada uma comparação entre o desempenho dos filtros de Kalman Estendido, Unscented e Filtro de Partículas. Resultados obtidos com dados simulados e dados reais coletados pelo radar demonstram a viabilidade de implementação.

Palavras-Chave – Acompanhamento de Alvos, Radar de Antena Rotativa, Filtro de Kalman Estendido, Filtro de Kalman Unscented, Filtro de Partículas.

ABSTRACT

The purpose of this work is to develop target tracking capability for the Brazilian Navy's Gaivota-X Radar, through analysis of the raw data provided, identification and elimination of clutter, and use of filtering techniques to predict the future position and correct correlation with the observations made by the sensors. The choice of a suitable dynamic model for the target characteristics is of fundamental importance for correctly predicting the future position of the target. Thus, two models were used that are automatically selected according to the movement parameters of the target and according to the type of movement being performed. The process of filtering the radar data was based on selecting repetitive points from the radar image, constructing a terrain mapping in the vicinity of the radar with the selected points, and then eliminating clutter from the entire data sample. Among the filtering techniques, a comparison was made between the performance of the Extended Kalman Filter, Unscented Kalman Filter and Particle Filter. Results obtained with simulated data and real data collected by the radar demonstrate the feasibility of implementation.

Keywords – Target tracking, Rotating Antenna Radar , Extended Kalman Filter, Unscented Kalman Filter, Particle Filter.

LISTA DE FIGURAS

1	Geometria do movimento 2D de um alvo.	26
2	Sequência de movimento de aeronave na aproximação do aeroporto de Congonhas.	34
3	Histogramas da Amplitude para a Primeira Aeronave	35
4	Diagrama Algoritmo de Identificação de Alvo	37
5	Aeronave 1 Identificada	38
6	Aeronave 2 Identificada	39
7	Aeronaves 3 e 4 Identificadas	39
8	Comparativo Medições x Dados Plataforma Flight Radar 24	40
9	Ao invés de passar a Gaussiana pela função não-linear g , é utilizada uma linearização tangente a $g(x)$, sendo x a média. O Resultado é apresentado em tracejado na imagem esquerda superior. Fonte: (1)	43
10	Os pontos sigma são selecionados de forma simétrica ao redor da média x e passados pela função g , o peso atribuído a cada sigma ponto permite que se faça uma regressão linear dos pontos, obtendo-se a aproximação da distribuição gaussiana exposta na imagem esquerda superior em tracejado. Fonte: (1)	46
11	Efeito da variação de α_{Σ} sobre a posição dos pontos sigma.	47
12	Efeito da variação de κ sobre a posição dos pontos sigma.	47
13	Peso atribuído pra cada partícula, a partir da função densidade de probabilidade da medição em azul. A escolha das partículas, com sua posição sinalizada pelas colunas em preto, foi feita a partir da função densidade de probabilidade em vermelho. Fonte: (2)	50
14	Ciclo de correlação de dados	52
15	Trajetória do alvo para teste de parâmetros do UKF.	54
16	Erro Predição x Medição para diferentes valores de α_{Σ} no UKF	55

17	Erro Predição x Medição para diferentes valores de κ no UKF	55
18	Erro Predição x Medição para diferentes valores de β no UKF	55
19	Média do erro entre medição e predição para as três possibilidades de w . . .	56
20	Resultados dos 3 filtros para a primeira trajetória	57
21	Resultados dos 3 filtros para a segunda trajetória	58
22	Resultados dos 3 filtros para a terceira trajetória	59
23	1º exemplo de contato identificado a partir dos dados brutos radar.	60
24	2º exemplo de contato identificado a partir dos dados brutos radar.	61
25	3º exemplo de contato identificado a partir dos dados brutos radar.	61
26	Comparativo entre os dados brutos acompanhados após processamento e dados GPS.	62

LISTA DE TABELAS

1	Pesos para diferentes α_{Σ}	48
2	Pesos para diferentes κ	48
3	Pesos para diferentes β	48

SUMÁRIO

Parte I: INTRODUÇÃO	11
1 Tema	12
2 Contextualização	13
3 Objetivo	15
4 Estado da Arte	17
5 Requisitos de Projeto	21
6 Metodologia e Estrutura do Trabalho	23
Parte II: DESENVOLVIMENTO	25
7 Dinâmica do Alvo	26
8 Identificação do Alvo e Mapeamento do Solo	33
9 Filtros	41
9.1 Filtro de Kalman Estendido	42
9.2 Filtro de Kalman Unscented	45
9.3 Filtro de Partículas	49
10 Correlação e Acompanhamento	52
11 Simulações	54
12 Aplicação do Filtro de Partículas nos Dados Coletados do Radar Gaivota-	
X	60

Parte III: CONCLUSÃO	63
13 Conclusão	64
14 Códigos	66
Referências	67

PARTE I

INTRODUÇÃO

1 TEMA

Desenvolvimento e implementação de otimizador, com o objetivo de reduzir os ruídos advindos de diversas fontes externas para o radar Gaivota-X, incluindo Ground Clutter, da Marinha do Brasil, melhorando seu desempenho e possibilitando o acompanhamento de diversos alvos.

2 CONTEXTUALIZAÇÃO

Apesar de ter uma longa história de desenvolvimento que remonta a Guerra Civil Americana, os veículos aéreos não-tripulados foram usados de forma efetiva pela primeira vez como arma de combate em fevereiro de 2002, quando o drone não tripulado americano Predator MQ-1 foi equipado com um míssil Hellfire e utilizado no Yemen, contra membros da Al-Qaeda (3).

Segundo (4) essa primeira aplicação em campo do veículo aéreo não-tripulado de combate, marca o início da quinta era da guerra, caracterizada por ações sem uso da força como engenharia social, desinformação, cyberataques, junto com tecnologias emergentes como inteligência artificial e sistemas autônomos.

O uso dessa nova arma tem se difundido rapidamente pelas Forças Armadas de diversos países. Muito disso se deve ao baixo custo, um dos drones mais difundidos e de livre comercialização, o Bayraktar TB2, tem custo em torno de US\$ 5 milhões (5), enquanto um avião de ataque leve como o A-29 Super Tucano, um dos mais baratos e economicos do mercado, tem custo médio de US\$ 10 milhões (6). Segundo (7), 16 países já firmaram contratos de compra do drone, entre eles Ucrânia, Azerbaijão, Maroccos, Tunísia, Qatar, Kirguistão e Turcomenistão, demonstrando que o uso de veículos autônomos não se restringe a países desenvolvidos.

Os recentes conflitos de Nagorno-Karabakh, entre Armênia e Azerbaijão, onde especialistas enxergam que o uso do drone foi fator decisivo da vitória do Azerbaijão (7). Os conflitos na Síria, onde o drone ficou conhecido como "Caçador de Pantsyrs", sistema de defesa aéreo russo que se demonstrou incapaz de detectar e abater o alvo (5). E os que mais recente tem ocorrido na Ucrânia, onde, apesar da pequena quantidade disponível, tem se demonstrado útil tanto em ataques pontuais, contra blindados ou artilharia, quanto como apoio, ao ser usado para reconhecimento e como auxílio a apoio de fogo de artilharia. Um exemplo do uso destes drones está no ataque realizado ao Cruzador de Mísseis Moskva, onde dois Bayraktar TB2 foram usados como distração para o sistema de defesa do navio, permitindo que dois mísseis Neptune o atingissem, resultando em seu afundamento (8).

Esses fatos impõem a necessidade de se atualizar os sistemas de defesa, que deverão não só detectar, mas serem capazes de acompanhar os alvos e abatê-los. Muitos países já tem se envolvido no esforço de desenvolver contra-medidas para combater veículos aéreos não-tripulados, com destaque para Israel, que realizou os primeiros testes do Iron Beam, sistema de defesa anti-aéreo com base em energia, que foi capaz de derrubar mísseis com o uso de feixe laser, com o custo de US\$ 3,50 por disparo, podendo ser aplicado em VANTs e até morteiros (9).

Nesse ensejo, a Marinha do Brasil deve desenvolver seus sistemas para ser capaz de defender seus meios contra a ameaça de VANTs, aeronaves convencionais e armamentos aéreos, e assim se adequar às características da guerra moderna.

3 OBJETIVO

A manutenção da segurança e controle dos meios navais pede recursos físicos e técnicas de acompanhamento de alvos aéreos mais sofisticadas, capazes de não só predizer o movimento, mas identificar qual aeronave está sendo acompanhada. Dentre essas técnicas se destaca a aplicação de filtros, segundo Leonard McGee e Stanley Schmidt (1987), desde sua primeira aplicação no início dos anos 60 no controle e navegação da cápsula espacial Apollo, a implementação de otimizadores, como o Filtro de Kalman, na indústria aeroespacial, tem se difundido (10).

A fim de atender essa nova demanda, este trabalho de conclusão de curso tem como objeto de seu estudo o radar Gaivota-X, projeto apoiado pela Financiadora de Estudos e Projetos(FINEP), e o desenvolvimento, implementação e análise de filtros, com o objetivo de reduzir os ruído advindos de diversas fontes externas, melhorando seu desempenho e possibilitando o acompanhamento de alvos.

Para alcançar o objetivo do trabalho de conclusão será implementado o acompanhamento de alvos de grande porte como aviões de uso comercial que se aproximam dos aeroportos de Guarulhos e Congonhas.

Para esse estudo foram analisados, por meio de dados simulados, a aplicação de diversos filtros, sendo eles os filtros de Kalman Unscented, o Estendido e o Filtro de Partículas. Além disso, os dados coletados do radar Gaivota-X foram analisados para que se obtenha a posição medida de aeronaves reais e, para isso, é necessário fazer a eliminação do ground clutter presente nessas amostras. Aos dados processados do radar foi aplicado o otimizador que obteve melhor resultado dentre os filtros acima citados.

O modelo dinâmico apresenta grau de dificuldade elevado por ser relativo ao alvo que está se captando dados, esse podendo apresentar diferentes tipos de movimento, como movimento de rolagem no caso de aeronaves de asa fixa, ou movimentos verticais puros no situação de aeronaves de asa rotativa.

Segundo Nakamura et al (2016), os requisitos que devem ser atendidos por sistemas

desse tipo são: detecção do alvo, cálculo computacional da posição, estimação da posição futura e recuperação do alvo, caso a predição falhe e o alvo seja perdido (11). Podemos ainda acrescentar identificação do alvo, inicialmente trabalhando com modelos de alvos de asa fixa.

Por fim, como forma de validar os resultados encontrados no estudo, foi realizada comparação entre os dados retirados do aplicativo *Flight Radar 24* e os dados do radar Gaivota-X. O *Flight Radar 24* mapeia todo o tráfego aéreo mundial e por meio da conta premium na plataforma é possível realizar a o download da rota da aeronave. Todavia, este método de validação ainda pode incorrer em erros de posição transmitidos pela plataforma.

4 ESTADO DA ARTE

A tecnologia de Filtro de Kalman tem seu início por volta do ano 1960 (12), inicialmente surgindo no âmbito militar para posterior aplicação no meio civil. A técnica de uso de Filtro de Kalman para acompanhamento de alvos está bastante consolidada. Algumas abordagens já foram apresentadas para solucionar a aquisição de alvos de pequeno porte, diferindo entre o tipo de sensor a ser utilizado para obter o alvo: radares de pulso simples, phased array e passivos. Diferem também quanto a técnica de filtragem empregada, onde há trabalhos que utilizam Filtro de Kalman e suas variações, Filtro de Partículas ou comparações entre os resultados de ambos.

Os trabalhos que tratam somente de Filtro de Kalman e suas variações, muitas vezes realizando comparações entre os resultados obtidos, são: (13) que analisa os resultados obtidos para a aquisição de alvo utilizando um Filtro de Kalman de dimensão variável e o Filtro de Kalman Estendido, (14) que desenvolve o Filtro de Kalman de forma própria a fim de obter um filtro que apresente soluções melhores para problemas não lineares, e (15) que se propõe a analisar os resultados da aplicação do Filtro de Kalman Estendido e do Filtro de Kalman Unscented.

Em (13) o autor usa três tipos de trajetória: com curvas de 90° , com curvas de 180° e com curvas de 270° . Além disso são utilizadas três velocidades para o alvo: baixa (7 a 13 nós), média (20 a 30 nós) e alta (70 a 120 nós). Adicionalmente foram criadas uma trajetória sinuosa e um caso com o alvo parado. Quando comparados, o Filtro de Kalman de dimensão variável, que possui estrutura similar ao Unscented, obteve resultados cinco vezes melhores do que o Filtro de Kalman Estendido.

Em (14) os autores desenvolvem o Filtro de Kalman para responder melhor aos sistemas não-lineares. São utilizados três posições iniciais, em 150, 120 e 50 quilômetros, e três velocidades, -600, -700 e -400 metros por segundo, para realizar os testes, que são feitos através de uma simulação de Monte Carlo com 100 repetições. Os resultados obtidos apontam para uma performance superior do algoritmo desenvolvido quando comparado com a performance do Filtro de Kalman Estendido.

Em (15) os autores realizam uma comparação entre o Filtro de Kalman Estendido e o Filtro de Kalman Unscented, com (16) como base de dados para os testes, obtendo resultados melhores com o Unscented, que estima uma trajetória mais suave e próxima da realidade quando comparado ao Filtro de Kalman Estendido, que perde sua qualidade em pontos de menor linearidade.

Os resultados obtidos pelos trabalhos supracitados apresentam uma melhor performance do Filtro de Kalman Unscented e, portanto, uma direção de desenvolvimento para o filtro a ser usado.

Há ainda livros que tratam deste assunto de forma mais ampla, apresentando os diversos filtros de forma isolada e em capítulos introdutórios realizando pequenas comparações quanto à finalidade de aplicação de cada um. Segundo (12) os filtros encontram-se divididos em: quanto ao número de estados; quantidade de eixos de interesse para análise; se o alvo possui manobrabilidade ou não; e se está imerso em *clutter*. Outra divisão apresentada pelo autor está na forma de atualização das equações do filtro, se no tempo contínuo ou discreto.

O capítulo 5 de (17) apresenta algumas técnicas de uso de otimizadores, inicialmente apresentando divisões semelhantes ao livro de Ramachandra, para posteriormente apresentar os filtros de Kalman Unscented, Estendido e Ensemble, e o Filtro de Partículas. O autor investiga situações de implementação de filtros lineares e não lineares para localização e acompanhamento de alvos e apresenta a noção de filtro estimador como um algoritmo que prediz a quantidade de interesse com base em observações indiretas.

Como alternativa ao Filtro de Kalman Unscented, o Filtro de Partículas para aquisição de alvos é apresentada por (18), que realiza uma comparação com o Filtro de Kalman Estendido, e por (19), que o desenvolve com acompanhamento baseado na informação a posteriori do alvo (*tracking before detecting*), onde a detecção, diferentemente do método clássico, que utiliza os dados brutos do radar, é realizada após o processo de filtragem. O filtro desenvolvido é testado em (20), com resultados que demonstram que mesmo para alvos fracos, com razão sinal-ruído menor que zero (ruído maior que o sinal), o filtro foi capaz de detectar e acompanhar os mesmos.

Um outro problema a ser considerado é a presença de mais de um alvo no alcance radar, que gera a necessidade de se associar cada sinal com o alvo correto, mesmo envolvendo trajetórias quase coincidentes em certos momentos do acompanhamento. Nesse ensejo, (20), (18) e (21) desenvolvem algoritmos para o acompanhamento de alvos múltiplos em ambiente com clutter.

Em (20), os autores são capazes de, através do Filtro de Partículas com acompanhamento a posteriori, detectar e correlacionar corretamente múltiplos alvos fracos. Em (18) são consideradas duas trajetória quase coincidentes sendo acompanhadas por três sensores, com resultados melhores para o Filtro de Partículas que, ao acoplar a informação da seção radar do alvo, foi capaz de realizar o acompanhamento de múltiplos alvos corretamente por 94 % do tempo, quando comparado ao Filtro de Kalman Estendido que o fez por 68 % do tempo.

Em (21) a técnica de filtragem utilizada foi a de hipótese de densidade de probabilidade com mistura gaussiana usando Filtro de Kalman por Cubatura. Foi aplicado em seis algoritmos de acompanhamento de alvos múltiplos, resultando em melhora da correlação sinal-alvo, apesar de reduzir a probabilidade de detecção rápida.

Por fim, é importante considerarmos que o sensor a ser utilizado nesse estudo é um radar onde há a possibilidade de implementação de módulo que apresente informações Doppler e, portanto, fornecerá informações que podem ser utilizadas para melhor estimarmos e resolvermos o problema de múltiplos alvos. Em (22) os autores apresentam um algoritmo capaz de determinar em pouco tempo a orientação e velocidade absoluta de um veículo em movimento através da regressão ortogonal da distância em conjunto com algoritmo de consenso e amostragem randômica, a partir das informações fornecidas pelo Doppler.

Em (23) os mesmos autores avaliam processos de integração e derivadas das informações da cinemática do alvo obtidas pelo radar Doppler, obtendo assim a posição por meio da velocidade e maior precisão na aceleração e desaceleração do alvo. A principal diferença da informação obtida com um radar Doppler está na obtenção direta da velocidade radial do alvo. No primeiro estudo os autores mostraram métodos de se chegar a velocidade vetorial por meio da velocidade Doppler e do ângulo de azimute, no segundo além dessa análise inicial utiliza-se do Filtro de Kalman Unscentend para obter dados mais precisos de aceleração e posição.

Todavia nos artigos (22) e (23), sobre o efeito Doppler, há a particularidade dos autores abordarem ambiente urbano, o que como consequência há limitações de velocidades máximas na filtragem que caracterizam o modelo dos alvos em questão. Devido ao ambiente urbano considerar os alvos como corpos extensos estas abordagens também se diferenciam do uso do radar em estudo, pois neste caso o alvo será tratado como corpo rígido.

Em abordagens mais recentes, em (24), e no trabalho seguinte (25), que foi realizado

em complemento ao anterior, os autores realizaram um estudo no qual foi feita uma comparação entre dois tipos de filtro de partículas, Filtro de Partículas de Mínima Variância e o Filtro de Partículas de Máxima Probabilidade, onde encontrou que este obteve melhores resultados em termos de precisão, complexidade e aplicabilidade. No segundo trabalho, os autores propuseram um novo método para obter a localização cartesiana do alvo baseando-se no cascadeamento de dois filtros de partículas de máxima probabilidade. Vale ressaltar que os estudos aqui citados foram realizados com base em um radar passivo, a análise dos dados recebidos não diferencia dos radares ativos, mas algumas equações do modelo da planta podem se diferenciar.

Por fim, em (26) há uma abordagem de múltiplos alvos utilizando radar Doppler, onde os autores apresentam uma nova abordagem por meio de um Filtro de Partículas Híbrido, onde foi possível com redução de custo computacional obter resultados satisfatórios para alvos com baixa energia de reflexão radar.

5 REQUISITOS DE PROJETO

O radar Gaivota-X é um projeto ainda em construção e encontra-se operando normalmente com todos os seus módulos instalados. Sendo assim, não haverá necessidade de gastos financeiros para sua construção. Caso fosse necessário fazer o levantamento dos materiais necessários para construção de projeto desta monta, o presente trabalho fugiria do seu escopo. Desta forma, este trabalho se restringe a análise dos dados, processamento e estimação ótima das informações que serão entregues ao usuário final.

Como não há atualmente módulo implementado no radar que proporcione filtragem de fatores atmosféricos, tais como nuvens e gotículas de água, módulo conhecido como *anti-clutter rain*, haverá a necessidade de se ter condições atmosféricas adequadas para a coleta de dados, com boa visibilidade e não formação de nuvens. Além disso, também será necessário o processamento dos dados com a presença do *ground clutter*, por isso será feito análise dos dados para se avaliar a formação de padrões de retorno do solo.

Além disso, haverá também a necessidade dos alvos estarem dentro do alcance do radar. Sendo que, segundo dados de projeto, o radar Gaivota-X possui alcance máximo de 160 km para o Airbus A320. Quanto a quantidade de alvos, o cenário do espaço aéreo da cidade de São Paulo será suficiente para suprir a demanda, já quanto a distância, o radar é capaz de refletir dados radares de aeronaves que se aproximam tanto do aeroporto de Guarulhos quanto do aeroporto de Congonhas.

Os dados coletados são o contador de azimuth, o delay time e a amplitude, adicionalmente, o tempo pode vir como informação mas este sendo possível ser obtido a partir do contador de azimuth. O contador de azimuth representa a variação angular do radar, pois este possui velocidade de rotação constante de acordo com o valor configurado. De acordo com (27), o dado de amplitude é usado para obter a potência de retorno da onda após o choque com o alvo, e esta é usada para realizar o cálculo de uma grandeza fictícia a seção transversal radar do alvo (RCS). A RCS é uma informação que nos ajuda a entender características do alvo ao tentar capturar sobre a ótica de um único número a capacidade do alvo de absorver energia, pois parte da energia perdida na onda fica absorvida no alvo.

A análise destes dados passará por etapas que possibilitem obter a identificação, acompanhamento e tendência de movimento dos alvos, para uma posterior limpeza da tela a fim de evitar a poluição visual para o leitor. Inicialmente, serão analisados quatro alvos por vez, quantidade factível em consonância com os trabalhos anteriores. Dessa forma, o vetor de dados de entrada (vetor de observações) fica definido por meio das quatro colunas disponibilizadas no radar:

$$\vec{u} = \begin{Bmatrix} A_z \\ R_d \\ A_{mp} \end{Bmatrix}$$

, onde A_z é o Azimute e R_d é a distância radial e A_{mp} é a amplitude. Muito embora a literatura trate o desvio Doppler da frequência em diversos artigos como forma de auxílio na identificação e acompanhamento dos alvos, a análise descrita anteriormente será com os dados reais que não contam com o desvio Doppler da frequência.

O problema da estimação estará fundamentado em disponibilizar informação ótima de posição dos alvos. Para tanto objetiva-se alcançar precisões superiores a 90%. O vetor de estados será definido com base nos dados que serão estimados, sendo composto portanto da posição alvo:

$$\vec{X} = \begin{Bmatrix} X \\ Y \end{Bmatrix}$$

, onde X é a posição ao longo do eixo das abscissas, Y é a posição ao longo do eixo das ordenadas. Após a identificação dos alvos eles serão convertidos de coordenadas polares para cartesianas, a fim de serem analisados pelo filtro preditor.

A plataforma *Flight radar 24* disponibiliza com um pequeno atraso de tempo informações de latitude, longitude e altitude das aeronaves no espaço aéreo mundial. Pode-se, por exemplo, pesquisar pelo aeroporto de Congonhas que se terá estas informações de forma gráfica. Há a possibilidade de se fazer o download da rota da aeronave na plataforma. Os resultados encontrados na estimação do radar poderão então ser comparados com os da plataforma.

6 METODOLOGIA E ESTRUTURA DO TRABALHO

Nos capítulos anteriores foram apresentados tópicos importantes para o entendimento do problema que neste trabalho se propõe. O problema da estimação e acompanhamento de dados radar foi introduzido no capítulo 1 como o tema a ser discutido.

No capítulo 2 foi realizada a contextualização do tema com um breve contexto histórico e sua importância tecnológica. No capítulo seguinte foi apresentado o objetivo, neste foi citado pontos que serão necessários implementar. Já no capítulo 4 foi feita a revisão bibliográfica, levando em consideração artigos mais recentes e livros consolidados na literatura sobre o tema. Neste foi possível analisar quais tipos de filtros poderão ser usados e servirão como forma de comparação para os resultados que posteriormente serão encontrados. No capítulo 5 foram elaborados os requisitos de projeto.

Este trabalho tem como objeto de estudo os dados radar coletados por meio do radar de busca combinada Gaivota-X da Marinha do Brasil, que se encontra instalado dentro do campus da Universidade de São Paulo. A área de estudo é descrita como parte da ciência que realiza o tratamento de dados estatísticos e que lida com sistemas de controle.

A pesquisa que aqui será apresentada possui característica exploratória, uma vez que os dados serão coletados para análise. Será também uma pesquisa experimental e conterá variáveis que influenciam no resultado, uma vez que o projeto do radar em que os dados estão sendo coletados não está completo.

Na parte II será dado início a fase de desenvolvimento do trabalho. Nesta, inicialmente será realizado simulações para avaliar a precisão do uso dos otimizadores implementados e para assim validar as melhores opções para implementar na prática. Posteriormente, o problema da identificação de alvos será abordado e este será o primeiro filtro com os dados reais.

Os algoritmos de acompanhamentos serão implementados em etapas, inicialmente para apenas um alvo e, posteriormente, com quantidade múltipla de alvos, sendo que

a quantidade inicial de alvos que está sendo proposta acompanhar é de 4 alvos. Tal quantidade poderá ser revista ao longo do projeto de acordo com o ganho que isso trouxer para a implementação.

Os materiais que serão usados ao longo deste trabalho serão o radar Gaivota-X e os computadores dos laboratórios da USP, que possuem o *MatLab* e *simulink* instalados para uso dos alunos.

Por fim, serão feitas análises quantitativas dos dados coletados, para tanto foi definida precisão superior a 90% no acompanhamento dos alvos. Na parte III será apresentado os resultados finais do trabalho e conclusões acerca das implementações e propostas de trabalhos futuros.

PARTE II

DESENVOLVIMENTO

7 DINÂMICA DO ALVO

A escolha de um modelo dinâmico adequado, quando se lida com alvos manobráveis, é de grande importância. Como o radar Gaivota-X fornece dados de azimuth ϕ e distância r , conforme a figura 1, a abordagem apresentada aqui será fundamentada em um plano.

De acordo com (28), o movimento de alvos modelados em duas dimensões pode ser reduzido a três casos especiais:

1. Movimento retilíneo com velocidade constante;
2. Movimento retilíneo com variação de velocidade (principalmente com aceleração constante); e
3. Movimento circular com velocidade constante (aceleração normal constante).




Figura 1: Geometria do movimento 2D de um alvo.

Segundo (29), o movimento de uma aeronave pode ser descrito através de dois modelos. Um linear que é coberto de forma razoável por um ruído branco com covariância apropriada, que é capaz de representar as acelerações, possíveis turbulências e mudanças

de vento, associado a um modelo de velocidade constante. O modelo de espaço de estados discreto no tempo resultante é:

$$x_k = \begin{bmatrix} x \\ \dot{x} \\ y \\ \dot{y} \end{bmatrix} = Ax_{k-1} + Bw_v = \begin{bmatrix} 1 & T & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T \\ 0 & 0 & 0 & 1 \end{bmatrix} x_{k-1} + \begin{bmatrix} T^2/2 & 0 \\ T & 0 \\ 0 & T^2/2 \\ 0 & T \end{bmatrix} w_v \quad (7.1)$$

Sendo x_k o vetor de estados x no instante t_k , w_v o ruído branco w para a velocidade, A a matriz de evolução de estados e B a matriz de ruído do processo e T o intervalo de tempo entre medições. O segundo modelo é o de guinada quase constante com velocidade tangencial constante. Passa a ser necessário o acompanhamento da taxa de guinada e, portanto, o acréscimo da velocidade angular w do alvo ao vetor de estados. A taxa de guinada será modelada por um processo Markoviano de primeira ordem, dado pela equação:

$$w_{k+1} = e^{\frac{-T}{\tau}} w_k + w_w \quad (7.2)$$

Onde τ é a variável de tempo de manobra. O resultado é a seguinte equação dinâmica discreta:

$$x_k = \begin{bmatrix} x \\ \dot{x} \\ y \\ \dot{y} \\ w \end{bmatrix} = \begin{bmatrix} 1 & \sin wT/w & 0 & -(1 - \cos wT)/w & 0 \\ 0 & \cos wT & 0 & -\sin wT & 0 \\ 0 & (1 - \cos wT)/w & 1 & \sin wT/w & 0 \\ 0 & \sin wT & 0 & \cos wT & 0 \\ 0 & 0 & 0 & 0 & \beta \end{bmatrix} x_{k-1} + \begin{bmatrix} T^2/2 & 0 \\ T & 0 \\ 0 & T^2/2 \\ 0 & T \\ 0 & 0 \end{bmatrix} w_v + \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 1 \end{bmatrix} w_w \quad (7.3)$$

Sendo $\beta = e^{-\alpha T}$ e $\alpha = \frac{1}{\tau}$. É possível perceber que a equação 7.3, apresentada acima, quando levada a situação limite de $w = 0$, conduz à equação 7.1 e, portanto, é mais

abrangente.

Observa-se, ainda, a importância do parâmetro τ que determina a duração da manobra executada pelo alvo. Segundo (30), é sugerido que para guinadas lentas $\tau = 60s$, para manobras evasivas $10 \leq \tau \leq 20s$ e para condições atmosféricas $\tau = 1s$. Ao realizarmos uma regressão exponencial sobre os valores observados por (30), obtemos a seguinte equação que relaciona w com τ :

$$\tau_k = 492.996e^{-0.138w_{k-1}} + W_\tau \quad (7.4)$$

Entretanto, o τ_k a ser utilizado para calcular α_k e β_k é do momento anterior $k - 1$, e portanto faz-se necessário realizar o acompanhamento de τ entre o estado atual e o posterior. A equação dinâmica resultante do alvo fica:

$$x_k = \begin{bmatrix} x \\ \dot{x} \\ \tau \\ y \\ \dot{y} \\ w \end{bmatrix} = \begin{bmatrix} 1 & \sin wT/w & 0 & 0 & -(1 - \cos wT)/w & 0 \\ 0 & \cos wT & 0 & 0 & -\sin wT & 0 \\ 0 & 0 & \alpha & 0 & 0 & 0 \\ 0 & (1 - \cos wT)/w & 0 & 1 & \sin wT/w & 0 \\ 0 & \sin wT & 0 & 0 & \cos wT & 0 \\ 0 & 0 & 0 & 0 & 0 & \beta \end{bmatrix} x_{k-1} + \begin{bmatrix} 0 \\ 0 \\ 1 \\ 0 \\ 0 \\ 0 \end{bmatrix} 492.996e^{-0.138w} + \begin{bmatrix} T^2/2 & 0 & 0 & 0 \\ T & 0 & 0 & 0 \\ 0 & T & 0 & 0 \\ 0 & 0 & T^2/2 & 0 \\ 0 & 0 & T & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} W_{v_x} \\ W_\tau \\ W_{v_y} \\ W_w \end{bmatrix} \quad (7.5)$$

De acordo com (28) a matriz de covariância de processo da dinâmica do alvo Q é dada por:

$$Q_1 = wT - \sin wT$$

$$Q_2 = 1 - \cos wT$$

$$\begin{aligned}
Q_k = S_w & \begin{bmatrix} 2Q_1/w^3 & Q_2/w^2 & 0 & 0 & Q_1/w^2 & 0 \\ Q_2/w^2 & T & 0 & -Q_1/w^2 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & -Q_1/w^2 & 0 & 2Q_1/w^3 & Q_2/w^2 & 0 \\ Q_1/w^2 & 0 & 0 & Q_2/w^2 & T & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \\
& + \begin{bmatrix} (T^4/4)\sigma_v^2 & (T^3/4)\sigma_v^2 & 0 & 0 & 0 & 0 \\ (T^3/4)\sigma_v^2 & T^2\sigma_v^2 & 0 & 0 & 0 & 0 \\ 0 & 0 & \sigma_\tau^2 & 0 & 0 & 0 \\ 0 & 0 & 0 & (T^4/4)\sigma_v^2 & (T^3/4)\sigma_v^2 & 0 \\ 0 & 0 & 0 & (T^3/4)\sigma_v^2 & T^2\sigma_v^2 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix} \quad (7.6)
\end{aligned}$$

Onde $S_w = 2\alpha\sigma_w$, σ_w o desvio padrão do ruído da velocidade angular w , σ_τ^2 a variância do ruído de τ w_τ e σ_v^2 a variância do ruído da velocidade w_v . Além da dinâmica exposta, (28) ressalta que a escolha de w para o cálculo das matrizes, entre w_k , w_{k-1} e $\bar{w}$, alteram significativamente os resultados do filtro.

Como estamos trabalhando com coordenadas cartesianas e o radar entrega dados nas coordenadas polares é necessária a conversão da medida e das covariâncias da medição R .

Segundo (31), as medições realizadas pelo radar são entregues em marcação θ_m e distância r_m :

$$r_m = r + \tilde{r} \quad \theta_m = \theta + \tilde{\theta} \quad (7.7)$$

Onde as verdadeiras marcação θ e distância r vêm acrescidas de um erro também em marcação $\tilde{\theta}$ e distância $\tilde{r}$, que são independentes com média zero e desvio padrão de σ_θ e σ_r , respectivamente. Em coordenadas cartesianas, que serão utilizadas nos filtros:

$$x_m = r_m \cos \theta_m \quad y_m = r_m \sin \theta_m \quad (7.8)$$

Cada coordenada cartesiana também pode ser representada como a soma do valor real e do erro:

$$x_m = x + \tilde{x} \qquad y_m = y + \tilde{y} \qquad (7.9)$$

Substituindo as equações 9.6 e 9.8 nas 9.7, obtemos:

$$x + \tilde{x} = (r + \tilde{r}) \cos(\theta + \tilde{\theta}) \qquad y + \tilde{y} = (r + \tilde{r}) \sin(\theta + \tilde{\theta}) \qquad (7.10)$$

Desenvolvendo 9.9:

$$\tilde{x} = r(\cos \theta \cos \tilde{\theta} - \sin \theta \sin \tilde{\theta} - \cos \theta) + \tilde{r}(\cos \theta \cos \tilde{\theta} - \sin \theta \sin \tilde{\theta}) \qquad (7.11)$$

$$\tilde{y} = r(\sin \theta \cos \tilde{\theta} - \cos \theta \sin \tilde{\theta} - \sin \theta) + \tilde{r}(\sin \theta \cos \tilde{\theta} - \cos \theta \sin \tilde{\theta}) \qquad (7.12)$$

Como os erros possuem distribuição gaussiana com média zero:

$$E[\cos \tilde{\theta}] = e^{-\sigma_{\tilde{\theta}}^2/2} \qquad (7.13)$$

$$E[\cos^2 \tilde{\theta}] = \frac{1}{2}(1 + e^{-2\sigma_{\tilde{\theta}}^2}) \qquad (7.14)$$

$$E[\sin \tilde{\theta}] = 0 \qquad (7.15)$$

$$E[\sin^2 \tilde{\theta}] = \frac{1}{2}(1 + e^{-2\sigma_{\tilde{\theta}}^2}) \qquad (7.16)$$

$$E[\sin \tilde{\theta} \cos \tilde{\theta}] = 0 \qquad (7.17)$$

A partir das equações 9.10 e 9.11 e dos valores de esperança, variância e covariância expostos acima obtemos a média e variância do erro para as coordenadas cartesianas:

$$\mu_t(r, \theta) = \begin{bmatrix} E[\tilde{x} \mid r, \theta] \\ E[\tilde{y} \mid r, \theta] \end{bmatrix} = \begin{bmatrix} r \cos \theta (e^{-\sigma_{\tilde{\theta}}^2/2} - 1) \\ r \sin \theta (e^{-\sigma_{\tilde{\theta}}^2/2} - 1) \end{bmatrix} \qquad (7.18)$$

$$\begin{aligned} var(\tilde{x} \mid r, \theta) &= r^2 e^{-\sigma_\theta^2} [\cos^2 \theta (\cosh(\sigma_\theta^2) - 1) + \sin^2 \theta \sinh(\sigma_\theta^2)] \\ &\quad + \sigma_r^2 e^{-\sigma_\theta^2} [\cos^2 \theta \cosh(\sigma_\theta^2) + \sin^2 \theta \sinh(\sigma_\theta^2)] \end{aligned} \quad (7.19)$$

$$\begin{aligned} var(\tilde{y} \mid r, \theta) &= r^2 e^{-\sigma_\theta^2} [\sin^2 \theta (\cosh(\sigma_\theta^2) - 1) + \cos^2 \theta \sinh(\sigma_\theta^2)] \\ &\quad + \sigma_r^2 e^{-\sigma_\theta^2} [\sin^2 \theta \cosh(\sigma_\theta^2) + \cos^2 \theta \sinh(\sigma_\theta^2)] \end{aligned} \quad (7.20)$$

$$cov(\tilde{x}, \tilde{y} \mid r, \theta) = \sin \theta e^{-2\sigma_\theta^2} [\sigma_r^2 + r^2(1 - e^{\sigma_\theta^2})] \quad (7.21)$$

Entretanto, essas equações dependem do valor real da marcação e distância do alvo, e o que temos disponíveis são os valores medidos pelo radar. (31) propõe uma aproximação por Séries de Taylor de primeira ordem a fim de obter um resultado que o autor chama de imparcial, ou sem influência, do erro cartesiano.

$$\tilde{x}_L = \tilde{r} \cos \theta - \tilde{\theta} r \sin \theta \quad (7.22)$$

$$\tilde{y}_L = \tilde{r} \sin \theta + \tilde{\theta} r \cos \theta \quad (7.23)$$

Resultando nas equações que convertem a medição e variâncias para o cartesiano a partir dos valores medidos pelo radar e da variância do erro em θ e r :

$$z = \begin{bmatrix} x_m \\ y_m \end{bmatrix} = \begin{bmatrix} r_m \cos \theta_m (1 + e^{-\sigma_\theta^2/2} - e^{-\sigma_\theta^2}) \\ r_m \sin \theta_m (1 + e^{-\sigma_\theta^2/2} - e^{-\sigma_\theta^2}) \end{bmatrix} \quad (7.24)$$

$$\begin{aligned} var(\tilde{x}) &= r_m^2 e^{-2\sigma_\theta^2} [\cos^2 \theta_m (\cosh 2\sigma_\theta^2 - \cosh \sigma_\theta^2) + \sin^2 \theta_m (\sinh 2\sigma_\theta^2 - \sinh \sigma_\theta^2)] \\ &\quad + \sigma_r^2 e^{-2\sigma_\theta^2} [\cos^2 \theta_m (2 \cosh 2\sigma_\theta^2 - \cosh \sigma_\theta^2) + \sin^2 \theta_m (2 \sinh 2\sigma_\theta^2 - \sinh \sigma_\theta^2)] \end{aligned} \quad (7.25)$$

$$\begin{aligned}
var(\tilde{y}) &= r_m^2 e^{-2\sigma_\theta^2} [\sin^2 \theta_m (\cosh 2\sigma_\theta^2 - \cosh \sigma_\theta^2) + \cos^2 \theta_m (\sinh 2\sigma_\theta^2 - \sinh \sigma_\theta^2)] \\
&\quad + \sigma_r^2 e^{-2\sigma_\theta^2} [\sin^2 \theta_m (2 \cosh 2\sigma_\theta^2 - \cosh \sigma_\theta^2) + \cos^2 \theta_m (2 \sinh 2\sigma_\theta^2 - \sinh \sigma_\theta^2)] \quad (7.26)
\end{aligned}$$

$$cov(\tilde{x}, \tilde{y}) = \sin \theta_m \cos \theta_m e^{-4\sigma_\theta^2} [\sigma_r^2 + (r_m^2 + \sigma_r^2)(1 - e^{\sigma_\theta^2})] \quad (7.27)$$

8 IDENTIFICAÇÃO DO ALVO E MAPEAMENTO DO SOLO

Um dos desafios iniciais no projeto de construção de radares é a eliminação de dados que podem gerar confusão na hora de identificação dos alvos. Para isso, é fundamental em radares localizados em terra, como é o caso do Gaivota-X, realizar o mapeamento do solo, técnica que consiste na identificação das estruturas fixas existentes no alcance do radar. Tal módulo não está implementado no radar Gaivota-X e, portanto, será necessário para a identificação dos dados e realizar a separação entre alvos e solo.

Segundo (32), superfícies ao nível do solo, tais como construções feitas pelo homem, o próprio solo ou superfícies naturais(vegetações ou relevos) espalham o sinal de volta ao radar. A intensidade deste sinal depende de alguns fatores, sejam eles a distância destas superfícies, a capacidade absorção de energia do material, o ganho e direção da antena e a área de recepção do sinal de retorno ao radar. Em radares de busca combinada, alvos que possuam a mesma projeção no solo das superfícies refletidas acima podem ser confundidos com estes.

Com base no exposto acima, foi realizada a coleta de dados para análise em software computacional, *MATLAB*. Na figura 2 é apresentado o plot dos dados radar para as primeiras 14 revoluções. Nesta foi possível identificar a existência de uma aeronave em movimento, simbolizada pelos círculos de cor vermelha ao redor de sua posição. A sequência de movimento observada por ela, embora não sinalizada na imagem, foi no sentido horário, onde ao final são as posições em que as aeronaves se aproximam de trecho retilíneo para pouso no aeroporto de Congonhas.




Figura 2: Sequência de movimento de aeronave na aproximação do aeroporto de Congonhas.

Além disso, é possível notar que em um trecho o radar não foi capaz de receber as informações sobre a aeronave. Trecho este localizado entre a 7ª e a 10ª medição. Nota-se que a 8ª medição pode ter se confundido com o clutter do solo existente no radar. Em trabalho de campo, foi possível verificar que há uma construção física que inibe o recebimento de ecos radares nas outras duas perdas de informação. A razão pela qual esta construção física não aparece na tela radar se deve ao fato de que o radar possui um alcance mínimo a partir do qual ele recebe alvos. Segundo (33), isto é uma característica comum em radares bi-estáticos, pois o receptor permanece fechado durante o período de emissão da onda eletromagnética. Radares bi-estáticos são aqueles em que uma única antena compartilha o transmissor e o receptor.

Após esta etapa inicial de avaliar os possíveis pontos de *clutter* e pontos de derrota das aeronaves no espaço aéreo da cidade de São Paulo, em especial em rotas de aproximação do aeroporto de Congonhas, verificou-se que para esta coleta de dados, havia 4 aeronaves cujos dados foram coletados pelo radar Gaivota-X. A imagem final com separação do *clutter*, será mostrada posteriormente com as derrotas estabelecidas por estas aeronaves.

Antes de iniciar a construção do algoritmo, passou-se por período de entendimento das características dos retornos radares, tanto para as aeronaves quanto para com o *ground clutter* em si, para avaliar quais características seriam possíveis de ser usadas na identificação das aeronaves. Na figura 2, os ecos de retorno radar foram divididos em 4 grupos distintos, a saber: inicial com medições mais limpas, segunda divisão com a presença de *clutter* próximo ao alvo, divisão onde não há informações da aeronave e divisão final com presença de *clutter* - porém em menor escala do que na segunda divisão.

A análise dos dados mostrou que a quantidade de retornos radar por revolução para uma mesma aeronave não permaneceu constante, variando para o caso mostrado de cerca de 30 a mais de 200 ecos por revolução. Duas possíveis razões levantadas para este fenômeno foram: existência de outras estruturas próximas a posição do alvo no instante da medição da posição, desviando assim parte do retorno para as outras estruturas; e posição relativa da aeronave em relação a antena, o que proporcionaria maior ou menor área para choque da onda eletromagnética com o alvo.

Na figura 3 é apresentado o histograma referente a aeronave apresentada em 2 em 3 pontos diferentes da trajetória. A figura mostra uma variação não uniforme da quantidade de ecos da aeronave. Além disso, é possível notar que não há um padrão de retorno para as amplitudes nem em relação aos retornos dentro da revolução radar, nem no decorrer de várias revoluções. Uma possível causa para a quantidade de ecos ser maior em um trecho do que no outro já foi elencada anteriormente. Essa primeira aeronave foi identificada como sendo um *Boing* e devido ao seu tamanho e posição relativa ao radar que proporcione maior área de choque tem quantidade de ecos radares de retorno elevada.




Figura 3: Histogramas da Amplitude para a Primeira Aeronave

Com relação às segunda e terceira aeronaves, há pouca quantidade de retorno radar por revolução. Esta característica pode estar relacionada com diversos fatores de uma aeronave, tais como distância e posição relativa da aeronave em relação ao radar, tama-

nho, material e cor em que é construída e o meio em que a medição esta ocorrendo. Ao analisar a derrota apresentada e os dados da plataforma *Flight Radar 24*, observou-se que essas aeronaves são correspondentes a dois vôos da companhia aérea Latam, aeronaves de tamanho comercial e que quando comparadas com a primeira, relaciona-se que a quantidade de retorno radar por revolução deva ser elevada. Todavia, o que acontece é o oposto e uma possível explicação para elas possuírem pouco retorno radar, principalmente no início de suas trajetórias, pode estar relacionado à posição relativa da aeronave em relação ao radar. E para a última aeronave, a trajetória se mantém linear e a posição relativa ao radar se mantém relativamente a mesma ao longo de todo o período em que foi observada, impossibilitando assim uma comparação.

Durante a década de 1950 foram introduzidos os modelos de alvos flutuantes por (34), estes modelos separavam os possíveis alvos em quatro categorias, duas em que haveriam variações na potência de retorno de uma revolução do radar à outra, chamados de modelos *scan-to-scan*, e os outros dois em que a variação ocorre a cada pulso do radar, chamados de *pulse-to-pulse*. Estes modelos tratavam das variações das amplitudes e em muitas situações reais os alvos estariam situados entre um modelo e outro. No caso do radar Gaivota-X o modelo que melhor se encaixaria dadas as características observadas nos dados coletados seria um do tipo *pulse-to-pulse*, pois há grande variação da amplitude ao longo da mesma volta em um mesmo alvo. Para utilizá-los na identificação de alvos seriam necessários de dados mais aprofundados de características de funcionamento do radar no tocante à propagação das ondas eletromagnéticas.

O contador de azimuth apresentou pequenas flutuações entre uma revolução e outra do radar, esta flutuação do valor do azimuth é comum de acontecer e está relacionada com a precisão do equipamento, determinada pela largura do feixe de ondas. O delay time teve uma pequena variação dentro da mesma volta, algo que segundo (27) é normal e esperado. Além disso, entre um ciclo e outro apresentou pouca variação no delay time. Há outros fatores que determinam a precisão de observação dos alvos radares, mas no tocante à flutuação do valor do azimuth o mais importante atributo é o valor da largura do feixe de ondas.

Após elencadas algumas características acerca dos dados entregues pelo radar, passa-se para o segundo passo, a execução do algoritmo de identificação de alvos. Na abordagem apresentada, concentrou-se em averiguar a existência de regiões com repetibilidade de dados, levando em consideração pequenas variações no contador de azimuth e no delay time. Essas regiões foram selecionadas para compor arquivo de *ground clutter*, que é obtido para cada velocidade de rotação do radar e que deve ser iniciado junto com o

radar. Para radares localizados em terra, onde há certa constância entre as estruturas físicas ao seu redor é aceitável utilizar de tal artifício para reduzir o custo computacional. Em radares que se movimentam, por exemplo em embarcações ou aeronaves, isso não seria possível devido à própria variação do clutter ao longo do tempo e nestes o desvio doppler é muito importante.

Após a determinação do algoritmo de mapeamento do solo citado anteriormente, segue-se para a lógica de construção do algoritmo de identificação de alvos que é apresentada no diagrama da figura 4.




Figura 4: Diagrama Algoritmo de Identificação de Alvo

As entradas para o algoritmo são o novo dado que foi capturado pelo radar e a matriz correspondente ao *ground clutter*. A correlação acontece por meio de comparação da posição do novo dado com as posições existentes na tabela dentro de um range bem estabelecido por 3 vezes o desvio padrão dos dados incluídos na matriz de *Clutter*. Após a correlação o dado é classificado ou como ruído ou como um possível novo contato, os dados classificados como ruído são descartados e os dados classificados como possível novo contato são adicionados à matriz de novos pontos e aguarda para processamento. O processamento ocorre ao final da revolução do radar. Nesta etapa os diversos ecos que correspondem ao mesmo ponto são aglutinados e por fim ainda é feita uma última análise ao classificar os alvos como pontos espúrios ou não. Esta última análise é feita levando em consideração dois parâmetros, a amplitude e a taxa de repetição do contato. A taxa de repetição aqui indica a quantidade de ecos de retorno que um mesmo objeto espalha de volta.

Experimentalmente, verificou-se que havia muitos alvos com baixíssima taxa de repetição (uma ou duas vezes) e com baixa amplitude. Este fator se explica devido à regulagem do radar no dia da coleta, o threshold de potência mínima de recepção foi reduzido para que se pudesse captar a maior quantidade possível de alvos, com isso, oca-

sionou de obter-se diversos falsos contatos, que puderam em sua maioria ser eliminados por este filtro citado. Nas figuras 5, 6 e 7 são apresentadas 3 imagens com as derrotas das aeronaves identificadas.




Figura 5: Aeronave 1 Identificada

Na figura 5 são visto os pontos relativo à primeira aeronave discutida anteriormente na cor azul e pontos relativos ao clutter na cor cinza. A derrota apresentada é um caminho padrão para aeronaves de grande porte que se deslocam do norte do país pela costa em direção ao aeroporto de Congonhas, por exemplo num vôo do aeroporto de Vitória para São Paulo. É possível notar que há, além dos pontos correspondentes a medição da aeronave, alguns pontos espúrios que mesmo com os filtros não foram completamente eliminados. E por fim, é possível notar, assim como na figura 2, que há a perda do sinal em um setor específico por razões já explicadas anteriormente.

Na figura 6 é mostrada uma nova aeronave que se aproxima para pouso no aeroporto de Congonhas pelo azimuth 240°. Esta aeronave apresenta movimento vindo do sul do Brasil ou do centro-oeste brasileiro.




Figura 6: Aeronave 2 Identificada




Figura 7: Aeronaves 3 e 4 Identificadas

Na figura 7 são mostradas outras duas aeronaves, a primeira com derrota semelhante àquela apresentada na figura 6, mas desta vez o filtro utilizado para eliminar o ruído também eliminou as informações acerca dela em alguns pontos. Provavelmente, esta é uma aeronave menor que apresenta menor retorno radar. Seria necessário outras técnicas para realizar a identificação deste tipo de aeronave, tais como as modelos de alvos flutuantes de Swerling ou outros que utilizem o desvio Doppler que atualmente não está instalado no radar Gaivota-X, já que se eliminarmos o uso do filtro de repetição e de mínima amplitude haveria grande quantidade de retorno, o que impossibilitaria o uso das medições pelo algoritmo de acompanhamento.

Estas simulações apresentadas foram para a velocidade de rotação da antena de 8 rotações por minuto. O radar é capaz de operar a velocidades de 2 a 64 rpm's. Em velocidades maiores ele apresenta maior variação dos parâmetros, produzindo assim maior

ruído para ser interpretado, porém em menor quantidade.

Por fim, na figura 8 é apresentada comparação entre a derrota coletada pelo radar e a derrota da aeronave disponibilizada pela plataforma *Flight Radar 24*. Nesta comparação são apresentados em verde os dados relativos à posição verdadeira do voo GLO1225 da companhia aérea Gol, realizado no dia 10/11/2022, com saída do aeroporto Santos Dumont, na cidade do Rio de Janeiro, e chegada no aeroporto de Congonhas, na cidade de São Paulo.




Figura 8: Comparativo Medições x Dados Plataforma Flight Radar 24

Os intervalos de amostragem relativos aos dados verdadeiros e os dados medidos pelo radar são diferentes, sendo que os dados reais apresentam intervalo de amostragem não regular, chegando em alguns trechos a 3 segundos e em alguns a mais de 30 segundos. Isso no tocante à proximidade da cidade de São Paulo, quando voando em regime de cruzeiro esses intervalos eram muito superiores.

9 FILTROS

De acordo com o exposto no capítulo 4, entre os trabalhos estudados se sobressaem a utilização de 3 filtros: o Filtro de Kalman Estendido, o Filtro de Kalman Unscented e o Filtro de Partícula que foram analisados quanto a sua capacidade de prever a posição futura do alvo. O objetivo é, portanto, inferir, dada uma sequência de medidas z , o estado x_k no momento discreto futuro k do alvo.

Seja $P(A)$ a probabilidade do evento A acontecer, e $P(A \cup B)$ a probabilidade conjunta de que A e B aconteçam. A probabilidade condicional de que A aconteça dado que B tenha acontecido é definida por:

$$P(A | B) = \frac{P(A \cup B)}{P(B)} \quad (9.1)$$

De acordo com (35) o Teorema da Probabilidade Total afirma que, dado eventos B_i com $i = 1, \dots, n$, com probabilidade condicional $P(B_i \cup B_j) = 0$ para $\forall i \neq j$, e exaustivo:

$$\sum_{i=1}^n P(B_i) = 1 \quad (9.2)$$

Então a probabilidade total de qualquer evento A acontecer pode ser decomposto em termos da probabilidade condicional:

$$P(A) = \sum_{i=1}^n P(A \cup B_i) = \sum_{i=1}^n P(A | B_i) P(B_i) \quad (9.3)$$

O Teorema da Probabilidade Total em termos da função densidade de probabilidade $p(x)$ para variáveis aleatórias x e z pode ser desenvolvido de maneira análoga para se obter:

$$p(x) = \int_{-\infty}^{\infty} p(x, z) dz = \int_{-\infty}^{\infty} p(x | z) p(z) dz \quad (9.4)$$

Onde $p(x, z)$ é a função densidade de probabilidade conjunta de x e z . Segundo (35), o Teorema de Probabilidade Total é a principal ferramenta para se obter o estado estimado na presença de incertezas do modelo e da medição. Em (36), a suposição Markoviana fundamentada no Teorema de Probabilidade Total:

$$p(x_k) = \int_{-\infty}^{\infty} p(x_k | x_{k-1})p(x_{k-1})dx_{k-1} \quad (9.5)$$

afirma que a distribuição do estado x no momento discreto k pode ser predita a partir do estado anterior de x no momento discreto $k-1$. Como $p(x_{k-1})$ é corrigido por uma série de medições z_i com i indo de 1 até $k-1$, chega-se na equação de Chapman-Kolmogorov, que descreve o processo de predição nos filtros:

$$p(x_k | z_{1:k-1}) = \int_{-\infty}^{\infty} p(x_k | x_{k-1})p(x_{k-1} | z_{1:k-1})dx_{k-1} \quad (9.6)$$

A etapa de atualização utiliza a nova medição $z_k = h(x_k, w_k)$ e gera um estado predito a posteriore, ou estado corrigido, através do Teorema de Bayes:

$$P(A | B) = \frac{P(B | A)P(A)}{P(B)} \quad (9.7)$$

Substituindo pelas variáveis usadas no filtro fica:

$$p(x_k | z_{1:k}) = \frac{p(z_k | x_k)p(x_k | z_{1:k-1})}{p(z_k)} \quad (9.8)$$

As equações 9.6 e 9.8 fundamentam as equações dos filtros, guardadas as particularidades de abordagem de cada um deles.

9.1 Filtro de Kalman Estendido

Segundo (1), a suposição de que, dentro da evolução de um vetor de estados, o próximo estado é uma função linear do anterior, é essencial para que o Filtro de Kalman funcione corretamente. Da mesma forma, a observação de que a transformação linear de uma distribuição gaussiana resultaria em outra distribuição gaussiana possui papel importante no Filtro de Kalman. Entretanto, na análise de sistemas reais, verifica-se a existência de diversas não-linearidades que reduzem a eficiência do filtro.

De forma a mitigar o efeito dessas não-linearidades, o Filtro de Kalman Estendido

(EKF) calcula uma aproximação da gaussiana através da transformação linear da média por Séries de Taylor de primeira ordem, conforme apresentado na figura 9.




Figura 9: Ao invés de passar a Gaussiana pela função não-linear g , é utilizada uma linearização tangente a $g(x)$, sendo x a média. O Resultado é apresentado em tracejado na imagem esquerda superior.

Fonte: (1)

Dessa forma, o Filtro de Kalman Estendido utiliza a função não-linear para realizar a predição do estado futuro e uma linearização dessa função não-linear para realizar a predição da matriz de covariância do estado.

As equações de predição do Filtro de Kalman Estendido são:

$$\hat{x}_{k|k-1} = f(\hat{x}_{k-1|k-1}, w) \quad (9.9)$$

$$P_{k|k-1} = F_k P_{k-1|k-1} F_k^T + Q_k \quad (9.10)$$

Onde $\hat{x}_{k|k-1}$ é o estado predito para o instante k , $\hat{x}_{k-1|k-1}$ é o estado corrigido para o instante $k-1$, $P_{k|k-1}$ é a matriz de covariância do estado predito para o instante k , $P_{k-1|k-1}$ é a matriz de covariância do estado corrigida para o instante $k-1$ e F_k é o jacobiano resultante da linearização por Série de Taylor da matriz de evolução de estados. Já as equações de atualização são as mesmas do Filtro de Kalman simples:

$$K_k = P_{k|k-1} H^T (H P_{k|k-1} H^T + R_k) \quad (9.11)$$

$$\hat{x}_{k|k} = \hat{x}_{k|k-1} + K_k (z_k - H \hat{x}_{k|k-1}) \quad (9.12)$$

$$P_{k|k} = (I - K_k H) P_{k|k-1} \quad (9.13)$$

Sendo H a matriz de observação, R_k a matriz de covariância da medição e K_k o ganho do filtro. A matriz de observação H é dada por:

$$H = \begin{bmatrix} 1 & 0 \\ 0 & 0 \\ 0 & 0 \\ 0 & 1 \\ 0 & 0 \\ 0 & 0 \end{bmatrix} \quad (9.14)$$

Se o estado predito possuir alta variância comparada a observação, $P_{k|k-1}$ grande, o ganho do filtro K tende a 1, fazendo com que o estado corrigido tenha os estados observáveis preditos descartados e substituindo pela observação realizada. Já se o estado predito possuir pouca variância em comparação à observação, $P_{k|k-1}$ é pequeno, o ganho do filtro tende a 0, fazendo com que a observação seja desconsiderada no cálculo do estado corrigido. O ganho, portanto, determina quanto da observação e da predição será levada em conta na composição do estado corrigido.

A inicialização do Filtro de Kalman Estendido é feita após a correlação entre duas medições.

$$z(1) = \begin{bmatrix} x(1) \\ y(1) \end{bmatrix} \quad z(2) = \begin{bmatrix} x(2) \\ y(2) \end{bmatrix}$$

De acordo com (30) o vetor de estado de inicialização é calculado como:

$$x_0 = \begin{bmatrix} x(2) \\ (x(2) - x(1))/T \\ 500 \\ y(2) \\ (y(2) - y(1))/T \\ 0 \end{bmatrix} \quad (9.15)$$

E a matriz de covariância do estado inicial:

$$P_{2,2} = (2\text{var}(x)/T^2) + \text{var}(v) \quad P_{5,5} = (2\text{var}(y)/T^2) + \text{var}(v)$$

$$P_0 = \begin{bmatrix} \text{var}(x) & \text{var}(x)/T & 0 & \text{covar}(x, y) & 0 & 0 \\ \text{var}(x)/T & P_{2,2} & 0 & 0 & -\sin wT & 0 \\ 0 & 0 & \text{var}(\tau) & 0 & 0 & 0 \\ \text{covar}(x, y) & 0 & 0 & \text{var}(y) & \text{var}(y)/T & 0 \\ 0 & -\sin wT & 0 & \text{var}(y)/T & P_{5,5} & 0 \\ 0 & 0 & 0 & 0 & 0 & 2\alpha\text{var}(w) \end{bmatrix} \quad (9.16)$$

Onde $\text{var}(x)$ é a variância da posição em x , $\text{covar}(x, y)$ a covariância entre x e y , τ a constante de tempo e w a velocidade angular.

9.2 Filtro de Kalman Unscented

Outro método de linearização é executado pelo Filtro de Kalman Unscented. Segundo (1), o UKF realiza uma linearização estocástica através de um processo de regressão linear estatística com o uso de pontos, que auxiliam a realizar o equacionamento ponderado da distribuição, chamada de transformada Unscented. A esses pontos de auxílio são dados o nome sigma e são selecionados de forma simétrica ao longo dos eixos principais da covariância em torno da média.

Diferente do EKF, não existe a linearização da função de evolução de estados, cada ponto é evoluído individualmente pela função não-linear e através dos resultados e do peso dado a cada um deles é realizada a regressão, conforme apresentado na figura 10.




Figura 10: Os pontos sigma são selecionados de forma simétrica ao redor da média x e passados pela função g , o peso atribuído a cada sigma ponto permite que se faça uma regressão linear dos pontos, obtendo-se a aproximação da distribuição gaussiana exposta na imagem esquerda superior em tracejado.

Fonte: (1)

Para um vetor de estados de n dimensões, com média μ e covariância Σ são utilizados $2n + 1$ pontos sigma X escolhidos de acordo com a seguinte regra:

$$X^{[0]} = \mu \quad (9.17)$$

$$X^{[i]} = \mu + (\sqrt{(n + \lambda)\Sigma}) \quad \text{para } i = 1, \dots, n \quad (9.18)$$

$$X^{[i]} = \mu - (\sqrt{(n + \lambda)\Sigma}) \quad \text{para } i = n + 1, \dots, 2n \quad (9.19)$$

Onde $\lambda = \alpha_{\Sigma}^2(n + \kappa) - n$. α_{Σ} e κ são parâmetros de escalabilidade que determinam a distância a partir da média que os pontos sigma serão selecionados. Em (37) é sugerido que $\alpha_{\Sigma} \in (0, 1]$ e $\kappa \geq 0$. Na figura 11 podemos perceber o efeito que a variação de α_{Σ} causa na posição dos pontos sigma, e na figura 12 o efeito da variação de κ . O aumento desses parâmetros aumenta o espaçamento entre os pontos sigma e, portanto, cria uma distribuição com maior variância, sendo que α_{Σ} faz um ajuste mais fino dessa posição.




Figura 11: Efeito da variação de α_Σ sobre a posição dos pontos sigma.




Figura 12: Efeito da variação de κ sobre a posição dos pontos sigma.

Cada ponto sigma tem dois pesos associados, w_m e w_c , que são usados para recompor a média e a distribuição, respectivamente. Os pesos são definidos pela seguinte regra:

$$w_m^{[0]} = \frac{\lambda}{n + \lambda} \quad (9.20)$$

$$w_c^{[0]} = \frac{\lambda}{n + \lambda} + (1 - \alpha_\Sigma^2 + \beta) \quad (9.21)$$

$$w_m^{[i]} = w_c^{[i]} = \frac{1}{2(n + \lambda)} \quad (9.22)$$

Segundo (37), o parâmetro β define o formato da distribuição, e para distribuições gaussianas o valor ótimo a ser assumido é 2. O efeito da variação de cada parâmetro para o peso, após serem normalizados, é exposto nas tabelas 1,2 e 3. Foram utilizados como

α_Σ	$w_m^{[0]}$	$w_m^{[i]}$	$w_c^{[0]}$	$w_c^{[i]}$	κ	$w_m^{[0]}$	$w_m^{[i]}$	$w_c^{[0]}$	$w_c^{[i]}$
0.1	-74.000	6.2500	-17.797	1.5664	1	-0.3393	0.1116	0.6014	0.0332
0.2	-17.750	1.5625	-3.7348	0.3946	2	-0.1719	0.0977	0.6512	0.0291
0.3	-7.3333	0.6944	-1.1313	0.1776	3	-0.0417	0.0868	0.6900	0.0258
0.4	-3.6875	0.3906	-0.2207	0.1017	4	0.0625	0.0781	0.7210	0.0233
0.5	-2.0000	0.2500	0.2000	0.0667	5	0.1477	0.0710	0.7463	0.0211
0.6	-1.0833	0.1736	0.4277	0.0477	6	0.2188	0.0651	0.7675	0.0194
0.7	-0.5306	0.1276	0.5639	0.0363	7	0.2788	0.0601	0.7854	0.0179
0.8	-0.1719	0.0977	0.6512	0.0291	8	0.3304	0.0558	0.8007	0.0166
0.9	0.0741	0.0772	0.7097	0.0242	9	0.3750	0.0521	0.8140	0.0155
1.0	0.2500	0.0625	0.7500	0.0208	10	0.4141	0.0488	0.8256	0.0145

Tabela 1: Pesos para diferentes α_Σ .Tabela 2: Pesos para diferentes κ .

valores padrão para as comparações $\alpha_\Sigma = 0.8$, $\kappa = 2$ e $\beta = 2$.

α_Σ	$w_m^{[0]}$	$w_m^{[i]}$	$w_c^{[0]}$	$w_c^{[i]}$
1	-0.1719	0.0977	0.5034	0.0414
2	-0.1719	0.0977	0.6512	0.0291
3	-0.1719	0.0977	0.7312	0.0224
4	-0.1719	0.0977	0.7814	0.0182
5	-0.1719	0.0977	0.8157	0.0154
6	-0.1719	0.0977	0.8408	0.0133
7	-0.1719	0.0977	0.8598	0.0117
8	-0.1719	0.0977	0.8748	0.0104
9	-0.1719	0.0977	0.8869	0.0094
10	-0.1719	0.0625	0.8968	0.0086

Tabela 3: Pesos para diferentes β .

As equações de predição do Filtro de Kalman Unscented são:

$$X_{k-1|k-1} = [\mu_{k-1|k-1} \quad \mu_{k-1|k-1} + \gamma\sqrt{\Sigma_{k-1|k-1}} \quad \mu_{k-1|k-1} - \gamma\sqrt{\Sigma_{k-1|k-1}}] \quad (9.23)$$

$$\hat{X}_{k|k-1} = f(X_{k-1|k-1}, w) \quad (9.24)$$

$$\hat{\mu}_{k|k-1} = \sum_{i=0}^{2n} w_m^{[i]} \hat{X}_{k|k-1}^{[i]} \quad (9.25)$$

$$\hat{\Sigma}_{k|k-1} = \sum_{i=0}^{2n} w_c^{[i]} (\hat{X}_{k|k-1}^{[i]} - \mu_{k|k-1})(\hat{X}_{k|k-1}^{[i]} - \mu_{k|k-1})^T + Q_k \quad (9.26)$$

Onde $\gamma = \sqrt{n + \lambda}$. A equação 9.33 computa os pontos sigma, que são evoluídos pela

matriz de evolução de estados na equação 9.34. Cada uma dessas predições é multiplicada por seus respectivos w_m a fim de se recompor o estado predito, conforme apresentado na equação 9.35. Na 9.36 acontece a recomposição da distribuição gaussiana. As equações de atualização do Filtro de Kalman Unscented são:

$$X_{k|k-1} = [\hat{\mu}_{k|k-1} \quad \hat{\mu}_{k|k-1} + \gamma\sqrt{\Sigma_{k|k-1}} \quad \hat{\mu}_{k|k-1} - \gamma\sqrt{\Sigma_{k|k-1}}] \quad (9.27)$$

$$\hat{z}_k = \sum_{i=0}^{2n} w_m^{[i]} H X_{k|k-1} \quad (9.28)$$

$$S_k = \sum_{i=0}^{2n} w_c^{[i]} (H X_{k|k-1}^{[i]} - \hat{z}_k)(H X_{k|k-1}^{[i]} - \hat{z}_k)^T + R_k \quad (9.29)$$

$$\Sigma_k^z = \sum_{i=0}^{2n} w_c^{[i]} (X_{k|k-1}^{[i]} - \hat{\mu}_k)(H X_{k|k-1}^{[i]} - \hat{z}_k)^T \quad (9.30)$$

$$\hat{K}_k = \Sigma_k^z S_k^{-1} \quad (9.31)$$

$$\mu_{k|k} = \hat{\mu}_k + K_k(z_k - \hat{z}_k) \quad (9.32)$$

$$\Sigma_{k|k} = \hat{\Sigma}_{k|k-1} - K_k S_k K_k^T \quad (9.33)$$

A inicialização do Filtro de Kalman Unscented se dá da mesma forma que o Estendido e, portanto, através das equações 9.15 e 9.16.

9.3 Filtro de Partículas

Segundo (1), diferente dos filtros anteriores, o Filtro de Partículas não depende de distribuições gaussianas para calcular a correção de suas predições, mas computa amostras a serem evoluídas para um estado predito através da matriz de evolução de estados, que reconstroem de forma ponderada a média. Esse processo é parecido com o realizado pelo Filtro de Kalman Unscented na Transformada Unscented, contudo a diferença reside na forma como as amostras são selecionadas. Na Transformada Unscented os sigma pontos são selecionados de forma paramétrica, enquanto no Filtro de Partículas essa amostragem é feita de forma aleatória.

A essas amostras é atribuído um peso a partir da função densidade de probabilidade

da observação do sensor. Cada amostra é uma hipótese do verdadeiro vetor de estados. É feita nova amostragem, dentro do universo de partículas hipótese, só que ponderada, para só então computar-se o estado corrigido, conforme apresentado na figura 13.




Figura 13: Peso atribuído pra cada partícula, a partir da função densidade de probabilidade da medição em azul. A escolha das partículas, com sua posição sinalizada pelas colunas em preto, foi feita a partir da função densidade de probabilidade em vermelho. Fonte: (2)

Segundo (35), pela Lei das Grandes Quantidades, a soma de grandes quantidades de variáveis aleatórias independentes tende ao valor esperado da variável. Dado uma sequência de variáveis aleatórias x_i , com $i = 1, \dots, n$. Sendo a média e variância dada por:

$$E[x_i] = \bar{x} \quad Var(x_i) = \sigma^2$$

A média amostral é dada por:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$$

A variância amostral pode, então, ser calculada:

$$Var(\bar{x}) = Var\left(\frac{1}{n} \sum_{i=1}^n x_i\right) = \frac{1}{n^2} Var\left(\sum_{i=1}^n x_i\right) = \frac{n\sigma^2}{n^2} = \frac{\sigma^2}{n}$$

É possível perceber que o aumento no número de partículas faz com que a variância tenda para 0, fazendo com que o Filtro de Partículas seja capaz de se aproximar de forma consistente do valor esperado do estado corrigido. Contudo o custo computacional acaba limitando o número de amostras a serem utilizadas.

As equações de predição do Filtro de Partículas são:

$$X_{k-1|k-1} = [x_{k-1}^{[m]}] \quad \text{com } m = 1, \dots, M \quad (9.34)$$

Onde cada amostra $x_{k-1}^{[m]}$ possui mesma probabilidade de ser selecionada.

$$X_{k|k-1} = f(X_{k-1|k-1}, w) \quad (9.35)$$

$$\hat{x}_k = \sum_{m=0}^M X_{k|k-1} \quad (9.36)$$

As equações de atualização do Filtro de Partículas são:

$$w_k^{[m]} = p(z_k | x_k^{[m]}) \quad \text{com } m = 1, \dots, M \quad (9.37)$$

$w_k^{[m]}$ são tomados de forma que $\sum_{m=0}^M w_k^{[m]} = 1$,

$$X_{k|k} = [x_k^{[m]}] \quad \text{com } m = 1, \dots, M \quad (9.38)$$

Onde cada amostra $x_k^{[m]}$ possui probabilidade $w_k^{[m]}$ de ser selecionada.

$$x_k = \sum_{m=0}^M X_{k|k} \quad (9.39)$$

A inicialização do Filtro de Partículas é realizada considerando-se um estado inicial obtido após a correlação de duas medidas, de forma análoga ao utilizado pelos filtros anteriores, conforme a equação 9.15. Esse estado inicial é evoluído pela matriz de evolução de estados M vezes, sendo M o número de amostras determinado para o filtro.

A existência de um ruído branco faz com que cada um dos M estados gerados seja único dentro do universo das M amostras.

10 CORRELAÇÃO E ACOMPANHAMENTO

A correlação entre as medidas z no instante k com as predições $\hat{x}$ do instante $k - 1$ é composta de dois passos, *gating* e associação. *Gating* é o processo pelo qual são eliminadas da possibilidade de correlação as medidas que não são possíveis de correlacionar com a trajetória do alvo, que estão fora do *gate*. A associação é um método pelo qual é selecionada a melhor medição para realizar a etapa de atualização ou correção do filtro.




Figura 14: Ciclo de correlação de dados

Para resolução do *gating* será utilizado a norma d^2 do vetor de residual $\tilde{z}_k$. De acordo com (38), o vetor residual é obtido pela equação:

$$\tilde{z}_k = z_k - H\hat{x}_{k|k-1} \quad (10.1)$$

E possui matriz de covariância:

$$S = HP_{k|k-1}H^T + R \quad (10.2)$$

Com as equações 10.1 e 10.2 obtemos a norma do vetor residual:

$$d^2 = \tilde{z}_k^T S^{-1} \tilde{z}_k \quad (10.3)$$

Deve-se definir um valor limite G para a norma, abaixo do qual a medição é considerada no passo de associação:

$$d^2 = \tilde{z}_k^T S^{-1} \tilde{z}_k < G \quad (10.4)$$

Segundo (39), G pode ser definido a partir da tabela de chi quadrado. Considerando dois graus de liberdade e 10% de probabilidade permitida que uma medição válida não caia dentro do gate, foi obtido o valor de $G = 4.605$.

As medições que caem dentro do gate passam para a etapa seguinte de associação. O método selecionado para realizar a associação foi o Global Nearest Neighbour. Segundo (38) a lógica por trás do método é a atribuição de um peso pra cada medida, de acordo com a norma do vetor residual de forma que o somatório dos pesos seja 1. Para o algoritmo desenvolvido foi utilizado a equação:

$$w_k^{[m_i]} = \frac{d_{ij}^2}{\sum_{i=0}^n w_k^{[m_i]}} \quad (10.5)$$

Onde m_i com $i = 1, \dots, n$ são as medições que estavam presentes na etapa de associação e d_{ij}^2 a norma de m_i até a predição $\hat{z}_j$.

É selecionado a medição com menor peso, de acordo com a regra do Global Nearest Neighbour, como medição associada e, a partir daí, realizada a atualização da posição do alvo através do filtro.

11 SIMULAÇÕES

As primeiras simulações realizadas tiveram como objetivo a determinação dos melhores parâmetros do Filtro de Kalman Unscented. Para tal, foi utilizado a trajetória exposta na figura 15, a partir da qual o filtro foi inicializado e medido o erro entre a posição predita no instante $k - 1$ e a posição medida no instante k , para diferentes valores de α_Σ (Figura 16), κ (Figura 17) e β (Figura 18), utilizando como padrão sobre o qual as variações eram realizadas os valores $\alpha_\Sigma = 0.8$, $\kappa = 6$ e $\beta = 2$. Foram realizadas 1.000 simulações para cada valor a fim de se obter uma média.




Figura 15: Trajetória do alvo para teste de parâmetros do UKF.




Figura 16: Erro Predição x Medição para diferentes valores de α_Σ no UKF




Figura 17: Erro Predição x Medição para diferentes valores de κ no UKF




Figura 18: Erro Predição x Medição para diferentes valores de β no UKF

Com os parâmetros do Filtro de Kalman Unscented determinados a partir da análise das figuras, $\alpha_\Sigma = 0.8$, $\kappa = 6$ e $\beta = 2$, e 200 partículas para o Filtro de Partículas, dá-se prosseguimento com a análise de performance quanto à sugestão de w a ser usado do equação de transição de estados dada em (28). Para tal foram comparadas três possibilidades de w , do momento anterior w_{k-1} , do momento atual w_k e uma média entre ambos $\bar{w}$, para a mesma trajetória apresentada na figura 15.





Figura 19: Média do erro entre medição e predição para as três possibilidades de w .


Podemos concluir pela figura 19, que a melhor abordagem para w é a média entre w_{k-1} e w_k , sendo assim será adotado $\bar{w}$.

Prosseguindo para a análise entre as performances dos 3 filtros selecionados quanto ao tempo de execução do algoritmo e do erro entre posição predita e posição medida. Foram utilizadas 3 trajetórias e cada filtro foi simulado para cada trajetória 1.000 vezes, a fim de eliminar possíveis predições excepcionais e obtermos um resultado possível de se comparar.


A primeira trajetória testada representa o comportamento de um alvo inimigo com intenção de atacar o meio sobre o qual o radar está montado, com forte curva e aproximação. São apresentados na figura 20 os resultados dos pontos preditos e medidos para cada filtro e uma comparação entre os erros ao longo do tempo.




(a) Predição realizada pelo EKF



(b) Predição realizada pelo UKF



(c) Predição realizada pelo PF



(d) Média de Erro Predição x Medição

Figura 20: Resultados dos 3 filtros para a primeira trajetória

A segunda trajetória testada representa o comportamento de um alvo com função de localizar o meio no qual está localizado o radar. São apresentados na figura 21 os resultado dos pontos preditos e medidos para cada filtro e uma comparação entre os erros ao longo do tempo.




Figura 21: Resultados dos 3 filtros para a segunda trajetória

A terceira trajetória testada representa o comportamento de um alvo se aproximando de um aeroporto e realizando guinadas para alinhar com a pista. São apresentados na figura 22 os resultados dos pontos preditos e medidos para cada filtro e uma comparação entre os erros ao longo do tempo.




Figura 22: Resultados dos 3 filtros para a terceira trajetória

Os tempos de execução para cada algoritmo foi de $3.4119 \cdot 10^{-5}s$ para o Filtro de Kalman Estendido, $3.62 \cdot 10^{-4}s$ para o Filtro de Kalman Unscented e $5.9 \cdot 10^{-3}s$ para o Filtro de Partículas. Resultados obtidos com processador de 3.8 GHz e 8 núcleos.

12 APLICAÇÃO DO FILTRO DE PARTÍCULAS NOS DADOS COLETADOS DO RADAR GAIVOTA-X

A partir dos resultados das simulações, observando uma demanda computacional que permite a implementação do Filtro de Partículas e seus resultados perante os outros dois filtros, o mesmo foi selecionado para a aplicação nos dados coletados do Radar Gaivota-X.

Os dados coletados usados para análise foram obtidos com o radar funcionando a 8 rotações por minuto. Os dados brutos obtidos possuem a aparência da figura 2. Passaram pelas etapas de mapeamento do solo e identificação de potenciais alvos, correlacionamento, previsão e associação, resultando no acompanhamento exposto nas figuras 23 a 25.




Figura 23: 1º exemplo de contato identificado a partir dos dados brutos radar.




Figura 24: 2º exemplo de contato identificado a partir dos dados brutos radar.




Figura 25: 3º exemplo de contato identificado a partir dos dados brutos radar.

Para validarmos o processamento dos dados realizado foi feita uma comparação com a trajetória GPS do avião, plotada a partir da figura 8 e apresentada na figura 26.




Figura 26: Comparativo entre os dados brutos acompanhados após processamento e dados GPS.

PARTE III

CONCLUSÃO

13 CONCLUSÃO

Este trabalho objetivou o desenvolvimento do acompanhamento de alvos para o Radar Gaivota-X, fundamentado na análise de diferentes abordagens quanto a forma de prever a posição futura do alvo. Inicialmente foram realizadas análises com dados simulados utilizando o software *MATLAB*, posteriormente, avaliou-se a implementação de algoritmo para a identificação de aeronaves com dados reais do radar Gaivota-X e, por fim, foram feitas análises de acompanhamento para os dados reais.

O Filtro de Kalman Estendido obteve performance pior dentro das simulações com trajetórias não-lineares, conforme esperado, alcançando erros de 600 metros. Possui demanda computacional baixa, com tempo de execução de $3.4119 \cdot 10^{-5}s$. Entretanto o erro alcançado impossibilitaria seu uso em cenários militares, onde trajetórias com grandes não-linearidades são comuns. Em situações com mais de um alvo e pontos espúrios existe grande chance de haver a correlação com o ponto errado, fazendo com que a capacidade principal, que é acompanhar o alvo, fosse perdida.

O Filtro de Kalman Unscented, por causa de sua transformada Unscented, sem tentar aproximar o comportamento de alvo como linear, é capaz de performar consideravelmente melhor que o Filtro de Kalman Estendido. No cenário da trajetória 3, apresentado na figura 22, o erro máximo ficou abaixo dos 200 metros, em outros cenários o erro não ultrapassou 100 metros. O tempo de execução do algoritmo foi de $3.4119 \cdot 10^{-4}s$, 5.000 vezes menor tempo de uma rotação alcançado pelo radar, que é de 1.75s, para a situação da figura em questão. O Filtro de Kalman Unscented é um forte candidato a implementação em sistemas com menor capacidade computacional.

O Filtro de Partículas atendeu às expectativas performando melhor quando comparado aos outros, com erro máximo de 100 metros no cenário da trajetória 3, sendo seu pior cenário, assim como o Unscented. Nos outros cenários o erro ficou em torno de 50 metros, com tempo de execução de $5.9 \cdot 10^{-3}s$.

Considerando os avanços na área de computação e a evolução dos processadores, o

tempo de execução dos filtros tendem a ser menores quando implementados em placas embarcadas dedicadas, tornando viável a adoção e implementação do Filtro de Partículas.

Ao ser analisado nos dados reais, o desempenho do algoritmo alcançou os requisitos, sendo capaz de correlacionar as medidas e previsões e executar o acompanhamento. O tempo completo de execução, passando pelas etapas seguintes a de mapeamento do solo e identificação de potenciais contatos, foi de $6.1 \cdot 10^{-3} s$. Mesmo se considerarmos a existência de 10 contatos, ficaríamos na ordem de $10^{-2} s$.

Entretanto a etapa de mapeamento do solo e identificação de potenciais contatos só é viável no estado atual para radares fixos, onde esse mapeamento pode ser executado uma vez e salvo na memória. Para radares móveis, como os embarcados em meios navais, sua execução se torna um empecilho. A grande quantidade de retornos, combinada a uma ausência de dados, como Doppler do alvo e Identificação Amigo-Inimigo (IFF), tornam a separação entre *clutter* e potenciais alvos um obstáculo à implementação local em tempo real.

Um dos pontos a serem ressaltados é a influência de uma correta escolha de equação dinâmica para modelo cinemático do alvo. A diversidade de alvos nos cenários militares demanda a correta identificação do alvo, entre avião comercial, avião militar, míssil e helicóptero, para uso do modelo que melhor se encaixa para aquele alvo específico. As figuras de 16 até 19 apresentam a diferença de desempenho para escolhas de parâmetros diferentes para o mesmo modelo, demonstrando a importância da correta seleção de modelo.

Diante desses resultados promissores é possível avaliar como viável a implementação no radar, que atualmente utiliza de módulos instalados em placas FPGA, que permitem o paralelismo de diversas funções e ganhos computacionais elevados. Para isto, é fundamental realizar a incorporação de funcionalidades importantes para a identificação de alvos, entre elas, módulo com Desvio Doppler, módulos com eliminação de ruídos atmosféricos e módulo com eliminação do *Ground Clutter*. Assim, é possível ter ganho de melhoria e performance na previsão e com a informação fornecida pelo equipamento IFF, corroboraria os resultados obtidos pelo algoritmo, aumentando sua confiabilidade. Para a implementação destes módulos de separação entre ruídos e alvos será necessário técnicas computacionais bem mais sofisticadas, tais como os modelos de flutuação de alvos de Swerling já anteriormente citados.

14 CÓDIGOS

Os códigos utilizados estão disponíveis no repositório do GitHub e podem ser acessados clicando [aqui](#).

REFERÊNCIAS

- 1 THRUN, S. *Probabilistic robotics*. [S.l.: s.n.], 2002. v. 45. ISSN 00010782.
- 2 STACHNISS, C. *Robot Mapping: Particle Filter*. 2013. Universidade de Freiburg, Alemanha. Disponível em: <http://ais.informatik.uni-freiburg.de/teaching/ws13/mapping/>.
- 3 SCHEVE, T. *A Brief History of UAVs*. Disponível em: <https://science.howstuffworks.com/reaper1.htm>.
- 4 ABBOT, D. *The Handbook of Fifth-Generation Warfare*. [S.l.]: Nimble Books, 2010.
- 5 CONFALONIERI lisabetta. *The Turkish Bayraktar TB2: Ankara's Renewed Prominence in the Drone Market*. Disponível em: http://www.planalto.gov.br/ccivil_03/leis/l7565compilado.html.
- 6 SACONI, A. *Conheça o A-29, avião de ataque da Embraer cobiçado pelo Taliban*. Disponível em: <https://economia.uol.com.br/todos-a-bordo/2021/08/18/a-29-super-tucano-caca-afeganistao-saconi.htm>.
- 7 TOPCU, E. *How useful are Turkish-made drones fighting in Ukraine?* Disponível em: <https://www.dw.com/en/how-useful-are-turkish-made-drones-fighting-in-ukraine/a-61035894>.
- 8 MEIER, R. *Drone Bayraktar reportedly used in attack on Russian cruiser Moskva*. Disponível em: <https://www.airdatanews.com/drone-bayraktar-tb2-reportedly-sank-russian-cruiser-moskva/>.
- 9 FABIAN, E. *In 'game changer,' Israeli laser-based air defense shoots down drones*. Disponível em: <https://www.timesofisrael.com/laser-based-air-defense-shoots-down-drones-rockets-in-first-series-of-trials/>.
- 10 SCHMIDT, L. A. M. e S. F. Discovery of the kalman filter as a practical tool for aerospace and industry. *NASA TM-86847*, n. 85424, 1987.
- 11 PAZZI Éfren Lopes e Eduardo Nakamura e R. Target tracking for sensor networks: A survey. *ACM Computing Surveys*, v. 49, p. 1–31, 2016.
- 12 RAMACHANDRA, K. V. *Kalman Filtering Techniques for Radar Tracking*. Primeira edição. [S.l.]: Marcel Dekker, 2000. 256 p. ISBN 9781315214887.
- 13 OLIVEIRA, J. R. P. de. Acompanhamento de alvos-radar utilizando filtragem de kalman e vetor de estados com dimensão variável. *COPPE/UFRJ, M.Sc. Engenharia Elétrica*, 2005.
- 14 LEE, S. P. e J. G. Improved kalman filter design for three-dimensional radar tracking. *IEEE Transactions on Aerospace and Electronic Systems*, v. 37, n. 2, p. 727–739, 2001.

- 15 SUN, J. S. e Yanan Liu e Sese Wang e Z. Evaluation of unscented kalman filter and extended kalman filter for radar tracking data filtering. p. 190–194, 2014.
- 16 LIN, Z. Research on information fusion system engineering guidelines. 2005.
- 17 BUEHRER, S. A. Z. e R. M. *Handbook of Position and Location*. Segunda edição. [S.l.]: Wiley-IEEE Press, 2019. ISBN 978-1-119-43458-0.
- 18 MOULIN, S. H. e P. A particle filtering approach to fm-band passive radar tracking and automatic target recognition. v. 4, p. 4–4, 2002.
- 19 DRIESSEN, Y. B. e J. Particle filter based detection for tracking. v. 6, p. 4393–4397 vol.6, 2001.
- 20 JULOSKI, Y. B. e Johannes Driessen e F. Verschure e Maurice Heemels e A. A multi target track before detect application. v. 9, p. 104–104, 2003.
- 21 MITRA, A. R. e D. Multi-target trackers using cubature kalman filter for doppler radar tracking in clutter. *IET Signal Processing*, v. 10, p. 888–901, 2016.
- 22 KELLNER, D. et al. Instantaneous lateral velocity estimation of a vehicle using doppler radar. In: . [S.l.: s.n.], 2013.
- 23 KELLNER, D. et al. Tracking of extended objects with high-resolution doppler radar. *IEEE Transactions on Intelligent Transportation Systems*, v. 17, 2016. ISSN 15249050.
- 24 ALMANOFI, A. M.; MALKI, A.; KAZEM, A. Doppler frequency estimation for a maneuvering target being tracked by passive radar using particle filter. *Journal of Communications Software and Systems*, Croatian Communications and Information Society, v. 16, p. 279–284, 2020. ISSN 18466079.
- 25 ALMANOFI, A. M.; MALKI, A.; KAZEM, A. 3d target localization by using particle filter with passive radar having one non-cooperative transmitter and one receiver. *Journal of Communications Software and Systems*, Croatian Communications and Information Society, v. 17, p. 36–43, 3 2021. ISSN 18466079.
- 26 LIU, J. et al. Hybrid particle filter based dynamic compressed sensing for signal-level multitarget tracking. *IEEE Access*, Institute of Electrical and Electronics Engineers Inc., v. 8, p. 17134–17148, 2020. ISSN 21693536.
- 27 RAUP, R. C. et al. *The Best Approximation of Radar Signal Amplitude and Delay The High-Earth-Orbit Satellite Tracking Problem*. 1990.
- 28 LI, X.; JILKOV, V. P. Survey of maneuvering target tracking. part i. dynamic models. Institute of Electrical and Electronics Engineers Inc., v. 39, n. 4, p. 1333–1364, 2003.
- 29 LI, X.; BAR-SHALOM, Y. Design of an interacting multiple model algorithm for air traffic control tracking. *IEEE Transactions on Control Systems Technology*, v. 1, n. 3, p. 186–194, 1993.

- 30 SINGER, R. A. Estimation optimal tracking filter performance for manned maneuvering targets. Institute of Electrical and Electronics Engineers Inc., AES-6, n. 6, p. 474–483, 1970.
- 31 LERRO, D.; BAR-SHALOM, Y. Tracking with debiased consistent converted measurements versus ekf. *IEEE Transactions on Aerospace and Electronic Systems*, v. 29, n. 3, p. 1015–1022, 1993.
- 32 LACOMME, P. et al. *Air and Spaceborne Radar Systems: An Introduction*. [S.l.: s.n.], 2007.
- 33 O'DONNELL, R. M. *Introduction to Radar Systems Online*. 2018. MIT Lincoln Laboratory. Disponível em: <https://www.youtube.com/playlist?list=PLUJAYadtuzA8RC2Qk8LfmiWA56HZsk9y>.
- 34 SWERLING, P. Probability of detection for fluctuating targets. *IRE Transactions on Information Theory*, v. 6, 1960. ISSN 21682712.
- 35 BAR-SHALOM, Y.; LI, X. R.; KIRUBARAJAN, T. *Estimation with applications to tracking and navigation*. [S.l.]: John Wiley Sons, Inc., 2001.
- 36 KALMAN, R. E. A new approach to linear filtering and prediction problems. *Journal of Basic Engineering*, v. 82, n. 1, p. 35, 1960.
- 37 STACHNISS, C. *Robot Mapping: Unscented Kalman Filter*. 2012. Universidade de Freiburg, Alemanha. Disponível em: <http://ais.informatik.uni-freiburg.de/teaching/ws13/mapping/>.
- 38 KONSTANTINOVA, P.; UDVAREV, A.; SEMERDJIEV, T. A study of a target tracking algorithm using global nearest neighbor approach. 01 2003.
- 39 BAR-SHALOM, Y.; FORTMANN, T. E. *Tracking and Data Association*. [S.l.]: Academic Press, 1988.