



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA DE TELEINFORMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE TELEINFORMÁTICA

ANTONIO REGILANE LIMA PAIVA

**AVALIAÇÃO DE UM MÉTODO DE RASTREAMENTO DE CANAL BASEADO EM
FILTROS DE KALMAN PARA BEAMTRACKING**

FORTALEZA

2018

ANTONIO REGILANE LIMA PAIVA

AVALIAÇÃO DE UM MÉTODO DE RASTREAMENTO DE CANAL BASEADO EM
FILTROS DE KALMAN PARA BEAMTRACKING

Dissertação de Mestrado submetida à Coordenação do Programa de Pós-graduação em Engenharia de Teleinformática (PPGETI) da Universidade Federal do Ceará (UFC) como requisito parcial para obtenção do grau de Mestre em Engenharia de Teleinformática. Área de Concentração: Sinais e Sistemas.

Orientador: Prof. Walter da Cruz Freitas Junior.

FORTALEZA

2018

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca Universitária
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

P166a Paiva, Antonio Regilane Lima.
Avaliação de um método de rastreamento de canal baseado em filtros de Kalman para beamtracking /
Antonio Regilane Lima Paiva. – 2018.
72 f. : il. color.

Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-
Graduação em Engenharia de Teleinformática, Fortaleza, 2018.
Orientação: Prof. Dr. Walter da Cruz Freitas Junior.

1. beamtracking. 2. EnKF. 3. MIMO. 4. mmWave. 5. UPA. I. Título.

CDD 621.38

ANTONIO REGILANE LIMA PAIVA

AVALIAÇÃO DE UM MÉTODO DE RASTREAMENTO DE CANAL BASEADO EM
FILTROS DE KALMAN PARA BEAMTRACKING

Dissertação de Mestrado submetida à Coordenação do Programa de Pós-graduação em Engenharia de Teleinformática (PPGETI) da Universidade Federal do Ceará (UFC) como requisito parcial para obtenção do grau de Mestre em Engenharia de Teleinformática. Área de Concentração: Sinais e Sistemas.

Aprovada em 29/07/2018:

BANCA EXAMINADORA

Prof. Walter da Cruz Freitas Junior. (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Yuri Carvalho Barbosa Silva.
Universidade Federal do Ceará (UFC)

Prof. Vicente Angelo de Sousa Junior .
Universidade Federal do Rio Grande do Norte (UFRN)

Dr. Igor Moáco Guerreiro.
Grupo de Pesquisa em Telecomunicações Sem Fio (GTEL)

Dedico este trabalho aos meus pais, meu irmão
e a todos os meus colegas da UFC.

AGRADECIMENTOS

Primeiramente a Deus por todas as bênçãos ao longo da minha vida.

A todos que direta ou indiretamente fizeram parte da minha formação, o meu muito obrigado.

"Vivemos indo, vivemos voltando, do caos à simplicidade e da simplicidade ao caos."

(Antonio Regilane)

RESUMO

Visando a projeção futura de uma grande demanda por transmissão de dados, provenientes das atuais aplicações de sistemas de teleinformática, estudos recentes apontam para os sistemas MIMO massivo, as tecnologias de formatação de feixes (do inglês *beamforming*) e a exploração do espectro não licenciado na faixa de ondas milimétricas (mmWaves, do inglês *millimeter wave*), como alicerces dos sistemas de comunicação móvel de 5ª geração (5G). A comunicação móvel de características 5G é desafiadora devido ao curto comprimento das mmWaves, que sofrem muito com perdas de percurso, absorções atmosféricas e atenuações por bloqueios, e aos feixes estreitos gerados por grandes arranjos, que sofre com a iminência de desalinhamento devido à mobilidade do terminal móvel. O *beamtracking* é um conjunto processos periódicos fundamentais para garantir o alinhamento do feixes ao longo do tempo. Porém, é de grande importância que os algoritmos de *beamtracking* tenham baixa complexidade de treinamento, para não afetarem a taxa de transmissão efetiva do sistema, e de processamento, para que possam ser executados nas interfaces sem fios dos equipamentos dos usuários a fim de reduzir o número de *feedbacks*. Os filtros de Kalman (KFs, do inglês *Kalman filter*) podem proporcionar um poderoso *framework* de rastreamento de canais de baixa complexidade para aplicações em *beamtracking*. Neste trabalho, é realizado um estudo do uso de filtros de Kalman como algoritmo base de *beamtracking* para canais massivo-MIMO mmWave utilizando arranjos uniformes lineares e planares de antenas. São implementados três tipos de KFs: o EKF (do inglês, *extended Kalman filter*), o UKF (do inglês *unscented Kalman filter*) e o EnKF (do inglês *ensemble Kalman filter*), bem como sua versão determinística, o DEnKF (do inglês *deterministic ensemble Kalman filter*). Os algoritmos KFs são avaliados em seis casos de estudo: em regimes de alta e baixa SNR, cenários com alta mobilidade do terminal móvel, canais com número variado de *clusters* e espalhadores, sistemas de alta dimensão que resultam de grandes arranjos, arquitetura *beamforming* limitada em níveis de quantização de fase, e erros heurísticos de predeterminação de parâmetros dos filtros. Uma análise qualitativa é realizada tomando como base algoritmos de mínimos quadrados. O procedimento de avaliação é realizado usando simulações computacionais.

Palavras-chave: beamtracking, EnKF, UKF, EKF, ULA, UPA, MIMO, ondas milimétricas.

ABSTRACT

Recent studies on Fifth-Generation Mobile communications systems (5G) point to massive MIMO systems, beamforming technologies and the millimeter waves as a way to deal with the large demand for data transmission from the current applications of teleinformatics systems. The 5G mobile communication is challenging due to the short length of mmWaves, which suffer greatly from path losses, atmospheric absorption and block attenuations, and narrow radiation beams from large arrays, which suffers from the imminence of misalignment due to the terminal mobility. The beamtracking is a set fundamental periodic processes to ensure beam alignment over time. However, it is of great importance that the beamtracking algorithms have low training complexity, so as not to affect the system throughput, and low processing complexity, so that it can be executed in mobile device's wireless interfaces in order to reduce the feedbacks. Kalman (KF) filters can provide a powerful framework for estimation of channels with low complexities for beamtracking applications. This master thesis aims to study of the use of Kalman filters as the base beamtracking algorithm for millimeter wave massive MIMO channel using linear and planar antenna arrays. Three types of KFs are implemented: the EKF, the UKF and the EnKF, as well as its deterministic version, the DEnKF. The KFs algorithms are evaluated in six case studies: in high and low SNR regimes, terminal mobility with high-level mobility, channels with varied number of clusters and scatterers, high-dimensional systems from large arrays, beamforming architecture limited in levels of phase quantization, and heuristics errors of predetermination of filter parameters. A qualitative analysis is performed based on least squares algorithms. Computational simulations were performed to evaluate the algorithms.

Keywords: beamtracking, EnKF, UKF, EKF, ULA, UPA, MIMO, mmWave.

LISTA DE ILUSTRAÇÕES

Figura 1 – Ilustração do alinhamento de feixes. Entre todos os pares possíveis de feixes, o par BS _x –MT _y é o que fornece a maior SNR.	2
Figura 2 – Ilustração do padrão de radiação de um feixe.	7
Figura 3 – Padrões de feixes para elevações de 0°, 45° e 65°. O <i>beamforming</i> convencional produz lóbulos secundários e diretividades que variam com a direção.	7
Figura 4 – Coordenada y ao longo de m -ésima ULA horizontal do arranjo UPA.	10
Figura 5 – Sistema MIMO com <i>beamforming</i> analógico para ondas milimétricas.	12
Figura 6 – Sistema MIMO com <i>beamforming</i> digital para ondas milimétricas.	13
Figura 7 – Sistema MIMO com <i>beamforming</i> híbrido para ondas milimétricas.	13
Figura 8 – Diferentes resoluções de padrões de feixes.	14
Figura 9 – Exemplo de um método de busca iterativa.	17
Figura 10 – Exemplo de aplicação de um <i>beamtracking</i> . Fenômenos repentinos, como obstáculos e rotação, que podem ocorrer com MT em velocidade consideravelmente alta, causam desalinhamento na ausência do <i>beamtraining</i> . O <i>beamtracking</i> garante o alinhamento do feixe durante os fenômenos repentinos.	18
Figura 11 – Exemplo de <i>beamtraining</i> e <i>beamtracking</i> no tempo com TDD.	18
Figura 12 – Modelo de canal espacial com <i>clusters</i>	22
Figura 13 – Influência da largura de feixe no coeficiente de correlação temporal. A curva tracejada representa modelo Gaussiano da Equação (3.19), enquanto que as curvas de linha cheia representam a Equação (3.21) para diferentes tamanhos de arranjo ULA (tamanho expresso em potência de base 2).	28
Figura 14 – Análise de desempenho do OMP com $G = 181$ para diferentes números de iterações com arranjo ULA 16.	33
Figura 15 – Análise de desempenho do OMP para diferentes números de iterações com arranjo ULA 16.	34
Figura 16 – Desempenho do sistema por número de antenas e iterações para SNR de 25 dB e $G = 180$	34
Figura 17 – Análise de desempenho do OMP para diferentes números de iterações com arranjo UPA 4×4 e $G = 400$	35
Figura 18 – Esquema de estimação de canal com EKF.	38
Figura 19 – Esquema de estimação de canal com EnKF.	38

Figura 20 – Comparação entre os paradigmas do EKF e do EnKF.	46
Figura 21 – Análise de desempenho do EnKF para diferentes números de iterações com arranjo ULA.	52
Figura 22 – Análise de desempenho do EnKF para diferentes números de iterações com arranjo UPA.	53
Figura 23 – Análise de SNR para arranjo ULA–16.	54
Figura 24 – Análise de SNR para arranjo UPA–(4 × 4).	55
Figura 25 – Desempenho em função do número de espalhadores para o arranjo ULA–16.	57
Figura 26 – Desempenho em função do AS e da velocidade do MT para um arranjo ULA–16 e SNR de 20 dB.	59
Figura 27 – Desempenho em função do AS e da velocidade do MT para um arranjo UPA–(4 × 4) e SNR de 20 dB.	60
Figura 28 – Desempenho dos algoritmos em relação ao tamanho de um arranjo ULA, num regime de SNR de 20 dB, para diferentes valores de σ_u	61
Figura 29 – Desempenho dos algoritmos em relação ao número de feixes de treinamento para diferentes tamanhos de arranjos ULA.	62
Figura 30 – Análise de robustez para um erro de σ_u	64
Figura 31 – Análise de robustez para erro de estado inicial no desempenho dos KFs.	65
Figura 32 – Análise de robustez para erro no modelo de evolução no desempenho dos KFs.	66

LISTA DE TABELAS

Tabela 1 – Valores de referência para sistema 5G adotados.	26
Tabela 2 – Principais Parâmetros de simulação para análise de OMP.	32
Tabela 3 – Tabela de performance do OMP para ULA 16 e SNR de 25 dB.	33
Tabela 4 – Parâmetros do sistema para análise de KFs.	49
Tabela 5 – Parâmetros dos algoritmos de estimação de canal.	50
Tabela 6 – Complexidade dos Algoritmos.	51

LISTA DE ALGORITMOS

Algoritmo 1	– Estimativa de canal MIMO-mmWave por OMP ^(*)	31
Algoritmo 2	– Rastreamento de canal com EKF ^(*)	41
Algoritmo 3	– Rastreamento de canal com UKF	43
Algoritmo 4	– Rastreamento de canal com EnKF	46
Algoritmo 5	– Rastreamento de canal com DEnKF	47

LISTA DE ABREVIATURAS E SIGLAS

3GPP	3rd Generation Partnership Project
5G	5th Generation Wireless Systems
AF	<i>array factor</i>
AoA	<i>angles of arrival</i>
AoD	<i>angles of departure</i>
AS	<i>angle spread</i>
BS	<i>base station</i>
BV	<i>beamforming vector</i>
CSI	<i>channel state information</i>
CS	<i>compressive sensing</i>
CV	<i>combining vector</i>
DEnKF	<i>deterministic ensemble Kalman filter</i>
DFT	<i>discrete Fourier transform</i>
EKF	<i>extended Kalman filter</i>
EnKF	<i>ensemble Kalman filter</i>
FDP	função densidade de probabilidade
FLOP	<i>FLoating-point OPeration</i>
HPBW	<i>half power beam width</i>
IA	<i>initial access</i>
IEEE	Institute of Electrical and Electronics Engineers
KF	<i>Kalman filter</i>
LOS	<i>line-of-sight</i>
LS	<i>least squares</i>
MAP	<i>maximum a posteriori</i>
MIMO	<i>multiple input multiple output</i>
MMSE	<i>minimum mean square error</i>
mmWave	<i>millimeter wave</i>
MT	<i>mobile terminal</i>
NLOS	<i>non-line-of-sight</i>
NMSE	<i>normalized mean square error</i>
NR	New Radio

OMP	<i>orthogonal matching pursuit</i>
RF	radiofrequência
SNR	<i>signal-to-noise ratio</i>
SVD	<i>singular value decomposition</i>
SV	<i>steering vector</i>
UKF	<i>unscented Kalman filter</i>
ULA	<i>uniform linear array</i>
UPA	<i>uniform planar array</i>

LISTA DE SÍMBOLOS

$\ \cdot\ _0$	Norma zero
$\ \cdot\ _2$	Norma Euclidiana
$\ \cdot\ _F$	Norma de Frobenius
$(\cdot)_A$	Indicador de AoA
$(\cdot)_D$	Indicador de AoD
$(\cdot)^H$	Operador Hermitiano
$(\cdot)^T$	Operador transposto
$(\cdot)_f$	Indicador de <i>precoder</i>
$(\cdot)_k$	Índice de bloco
$(\cdot)_l$	Índice de <i>cluster</i>
$(\cdot)_r$	Indicador do MT
$(\cdot)_t$	Indicador da BS
$(\cdot)_w$	Indicador do <i>combiner</i>
$\text{diag}(\cdot)$	Matriz diagonal do argumento
$\text{vec}(\cdot)$	Vetorização de matriz
α	Coefficiente complexo do canal
θ	Componente de elevação
λ	Comprimento de onda
ϕ	Componente azimutal
ρ	Coefficiente de correlação temporal do canal
σ_u	Desvio padrão da incerteza do modelo de evolução
σ_v	Desvio padrão da incerteza do modelo de medição
$\boldsymbol{\chi}$	Variável de estado
D_L	Dimensão do modelo de evolução
L	Número de <i>clusters</i>
N_{ant}	Número de antenas do arranjo

$N_{ant,h}$	Número de antenas de uma ULA em uma UPA
$N_{ant,v}$	Número de ULAs em uma UPA
N_f	Número de <i>precoders</i>
N_{RF}	Número de cadeias de RF
N_{str}	Número de <i>streams</i>
N_w	Número de <i>combiners</i>
T_c	Tempo de coerência
A	Matriz da função linear de evolução
C	Matriz da função linearizada de medição
F	Matriz de <i>precoders</i> híbridos
F_{BB}	Matriz de <i>precoders</i> digitais
F_{RF}	Matriz de <i>precoders</i> analógicos
W	Matriz de <i>combiners</i> híbridos
W_{BB}	Matriz de <i>combiners</i> digitais
W_{RF}	Matriz de <i>combiners</i> analógicos
a	<i>steering vector</i>
k	Vetor de onda
<i>c</i>	Velocidade da luz
<i>f_c</i>	Frequência de operação
<i>v_{MT}</i>	Velocidade do MT
$\mathcal{CN}(\cdot)$	Distribuição Gaussiana complexa circular simétrica
$\mathcal{N}(\cdot)$	Distribuição Gaussiana
$\mathcal{O}(\cdot)$	O-grande
$\mathcal{U}(\cdot)$	Distribuição uniforme

SUMÁRIO

1	INTRODUÇÃO	1
1.1	Motivação	1
1.2	Objetivos e Metodologia	3
1.3	Contribuições	4
1.4	Organização	5
2	INTRODUÇÃO AO BEAMFORMING	6
2.1	Introdução	6
2.1.1	<i>Steering Vector</i>	8
2.1.2	<i>Largura de Feixe</i>	11
2.2	Arquiteturas	12
2.2.1	<i>Codebook</i>	14
2.3	Beamtraining	15
2.4	Beamtracking	17
3	MODELAGEM DE CANAL DINÂMICO PARA SISTEMAS 5G	21
3.1	Modelos do Sistema	21
3.1.1	<i>Modelo de Canal</i>	21
3.1.2	<i>Modelo de Evolução</i>	23
3.1.3	<i>Transmissão de Pilotos</i>	24
3.1.4	<i>Modelo de Medição</i>	25
3.1.5	<i>Parâmetros do 3GPP 5G New Radio</i>	26
3.1.6	<i>Tempo de Coerência</i>	26
3.2	Estimação de Canal baseada em Mínimos Quadrados (LS)	29
3.2.1	<i>Simulações para o Método baseado em OMP</i>	31
4	RASTREAMENTO DE CANAL COM FILTROS DE KALMAN	36
4.1	Formulação Bayesiana do Problema de Beamtracking	36
4.2	Filtros de Rastreamento	37
4.2.1	<i>EKF</i>	37
4.2.2	<i>UKF</i>	41
4.2.3	<i>EnKF</i>	44
4.3	Simulações para o Método baseado em KFs	48

4.3.1	<i>Análise da Influência da SNR</i>	52
4.3.2	<i>Análise da Influência do Número de Espalhadores</i>	54
4.3.3	<i>Análise da Influência de σ_u e da Velocidade do MT</i>	56
4.3.4	<i>Análise da Influência do Tamanho do Arranjo e do Número de Feixes</i> . . .	58
4.3.5	<i>Análise da Influência do Erro de Parâmetro</i>	61
5	CONCLUSÕES	67
	REFERÊNCIAS	69

1 INTRODUÇÃO

Neste trabalho é realizado um estudo quantitativo e qualitativo do uso de filtros de Kalman (KFs, do inglês *Kalman filter*) como algoritmo base de *beamtracking* para canais MIMO (do inglês *multiple input multiple output*) massivo em ondas milimétricas (mmWave, do inglês *millimeter wave*). A análise quantitativa é realizada com base no indicador estatístico NMSE (do inglês *normalized mean square error*) e a qualitativa é realizada tomando como base algoritmos de mínimos quadrados (LS, do inglês *least squares*); ambas as análises são executadas via simulação computacional.

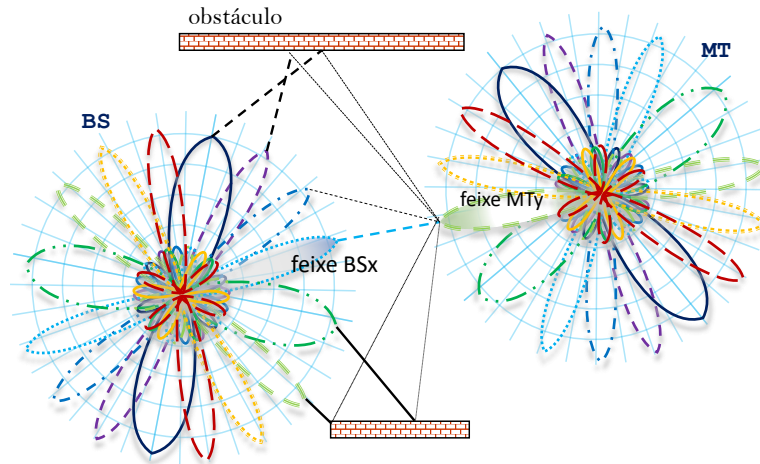
Neste capítulo é apresentada uma introdução resumida ao trabalho, destacando: motivação, objetivo, metodologia e conceitos iniciais.

1.1 Motivação

Devido à projeção do crescimento do tráfego de dados móveis proveniente da novas gerações de serviços móveis, que visam taxas de transmissão maiores que 10 Gbps, suporte a *streams* de vídeos de alta definição e a aplicações de realidade aumentada, entre outros, tem-se estudado o uso do espectro livre de licença na faixa de ondas milimétricas (30 GHz – 300 GHz) para futuros sistemas de comunicações móvel (RUFFINI, 2017). Técnicas de formatação de feixes (do inglês *beamforming*) (KUTTY; SEN, 2016) são frequentemente utilizadas por sistemas de comunicação móveis em ondas milimétricas com múltiplas antenas para fornecer ganho de arranjo. O *beamforming* é aplicado tanto no transmissor como no receptor, de forma que a comunicação é realizada por meio de um par de feixes. Para garantir qualidade de comunicação, o sistema deve ser capaz de identificar o par de feixes que, por exemplo, maximize a SNR (do inglês *signal-to-noise ratio*), num processo conhecido como alinhamento de feixes (LIU *et al.*, 2016) (Fig. 1).

O alinhamento de feixes é garantido no IA (do inglês *initial access*) por meio de um processo de treinamento de feixes (do inglês *beamtraining*). O padrão de rede local sem fios IEEE 802.11ad (ASSOCIATION *et al.*, 2012), um padrão com características 5G (5th Generation Wireless Systems) baseado em *beamforming* analógico com operação na faixa de frequência de 60 GHz, adota como *beamtraining* um mecanismo de busca interativa por feixes no IA

Figura 1 – Ilustração do alinhamento de feixes. Entre todos os pares possíveis de feixes, o par BSx–MTy é o que fornece a maior SNR.



Fonte: criada pelo autor.

(GIORDANI *et al.*, 2016a). Trata-se, inicialmente, de fazer uma busca exaustiva em setores, testando cada par de setores possível para determinar o par que maximize a SNR. Logo em seguida, é realizado o refinamento de feixes, em que cada par de feixes que pertence aos setores escolhidos são testados exaustivamente, determinando, assim, o par de feixes que maximize a SNR. Se existir N_{pares} pares de feixes refinados a serem testados, então a complexidade de treinamento será $\mathcal{O}(N_{pares})$. Para estimação da resposta ao impulso do canal, o padrão IEEE 802.11ad pode requerer mais de $N_{pares} \times 4032$ símbolos num piloto de *beamtraining* (ou no *beamtracking*) (ASSOCIATION *et al.*, 2012).

A complexidade dos esquemas de treinamento de feixes torna-se problemática em cenários de comunicação móvel, em que as variações translacionais e rotacionais do equipamento do usuário causam, constantemente, desalinhamento dos feixes, e conseqüentemente perda de potência (TSANG; POON, 2011). Faz-se necessário que o alinhamento seja periodicamente testado em um processo conhecido como *beamtracking*. O *beamtracking* pode simplesmente identificar o melhor par de feixes por análise de SNR ou estimar a resposta ao impulso do canal para suporte multi-usuário e multi-stream. Esse último, é o mais visado por ser utilizado em arquiteturas *beamforming* digitais ou híbridas. Podemos definir o *beamtracking* como técnicas de estimação de canal para identificação dos feixes que maximize a SNR, fornecendo, assim, o melhor enlace de comunicação em um certo instante de tempo. O grande desafio dos algoritmos de *beamtracking* é de estimar o canal de forma precisa e sem sobrecarregar o mesmo (BO *et al.*, 2015), para não comprometer a taxa de transmissão efetiva do sistema.

Os canais de comunicação móvel são dinâmicos e estocásticos por natureza. É ideal que um algoritmo de rastreamento de canal seja não-adaptativo, para evitar sobrecargas no canal. Com essa restrição, o algoritmo deve ser capaz de estimar o canal baseado somente em uma sequência de símbolos de treinamento recebida.

O filtro de Kalman (KF, do inglês *Kalman filter*) é uma classe de filtros Bayesianos usados para suavizar ou prever sinais provenientes de processos estocásticos. Suas principais características são:

- Filtros estatísticos ótimos ou subótimos para processos Gaussianos aditivos;
- Baixa complexidade assintótica;
- Fácil análise e implementação;
- Paralelizáveis e possibilitam implementação em *hardwares* de baixo custo e consumo de energia.

É possível rastrear variações de ângulos de partida (AoD, do inglês *angles of departure*), ângulos de chegada (AoA, do inglês *angles of arrival*) e coeficientes do canal com estimação paramétrica integrada a um KF, baseado em dados de observação provenientes de uma varredura periódica de feixes (ZHANG *et al.*, 2015), (VA *et al.*, 2016). O método possibilita a estimação completa do canal com baixa complexidade de processamento em comparação com outros métodos propostos na literatura, que são apresentados no Capítulo 2.

1.2 Objetivos e Metodologia

Este trabalho tem como objetivo realizar uma ampla investigação sobre a viabilidade, as vantagens e desvantagens da aplicação de KFs para rastreamento dos parâmetros do canal MIMO-mmWave: os AoAs, AoDs e coeficientes de ganho. Para tanto, o rastreamento dos parâmetros do canal MIMO-mmWave é implementado com base em três versões do KF. Uma é com filtro EKF (do inglês, *extended Kalman filter*) proposta na literatura (ZHANG *et al.*, 2015), (VA *et al.*, 2016), e as outras duas são propostas neste trabalho: o UKF (do inglês *unscented Kalman filter*) e o EnKF (do inglês *ensemble Kalman filter*), bem como sua versão determinística, o DEnKF (do inglês *deterministic ensemble Kalman filter*). O uso do UKF e do EnKF possibilita que o sistema trabalhe com modelos não-lineares sem a necessidade do cálculo da matriz Jacobiana exigido pelo EKF, além de possibilitarem melhorias no desempenho,

como será mostrado no Capítulo 4. O procedimento de avaliação é realizado em simulações computacionais.

Em conformidade com a literatura, serão apresentados resultados com arranjos uniformes lineares de antenas (ULA, do inglês *uniform linear array*) em simulações 2-D, e o indicador estatístico de desempenho adotado será o erro quadrático médio normalizado (NMSE, do inglês *normalized mean square error*). Para uma análise completa, também serão apresentados resultados com arranjos planares uniformes de antenas (UPA, do inglês *uniform planar array*) em simulações 3-D.

Para uma análise qualitativa, foram adotados os algoritmos de estimação de canal MIMO-mmWave baseados em mínimos quadrados (LS, do inglês *least squares*) (LEE *et al.*, 2014), (LIM *et al.*, 2018). Esses algoritmos se assemelham muito com os algoritmos investigados neste trabalho, com a diferença que os LSs não usam estimadores estatísticos. Além do desempenho, será levada em consideração a complexidade assintótica em termos de FLOPs (do inglês, *FLoating-point OPeration*) e a complexidade de treinamento dos KFs e LSs.

Os algoritmos KFs serão avaliados em seis casos de estudo: em regimes de alta e baixa SNR, cenários com alta mobilidade do terminal móvel (MT, do inglês *mobile terminal*), canais com um número variado de *clusters* e espalhadores, sistemas de alta dimensão que resultam de grandes arranjos, arquitetura *beamforming* limitada em níveis de quantização de fase, e erros heurísticos de predeterminação de parâmetros dos filtros.

1.3 Contribuições

Este trabalho contribui com resultados na área literária sobre sistemas de *beamtracking*, que abordam diversas variáveis determinantes do desempenho desses sistemas, além de sintetizar modelos matemáticos 2-D e 3-D primordiais ao tema. O trabalho também apresenta a aplicação do EnKF ao problema de *beamtracking*, filtro relativamente recente, que até então não era abordado na literatura de telecomunicação. Podemos citar algumas combinações de palavras-chave que são inéditas na literatura: EKF/UKF+beamtracking+UPA; EnKF+MIMO+mmWave; EnKF+beamtracking+ULA/UPA.

Durante este trabalho, financiado pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), foram finalizadas as seguintes produções científicas:

(**aceito**) PAIVA, A. R. L.; FREITAS, W., C.; et al. "Indoor Localization Algorithm based on Fingerprint Using a Single Fifth Generation Wi-Fi Access Point". *Revista IEEE América Latina*, 2018.

(**a ser submetido**) PAIVA, A. R. L.; FREITAS, W., C. "Evaluation of a Kalman Filter-based Channel Tracking Method for Beamtracking". *Journal of Communication and Information Systems*.

1.4 Organização

Este trabalho está organizado como se segue:

- **Capítulo 1:** presente capítulo; traz uma introdução sucinta ao problema de *beamtracking* e à aplicação do KF, seguido por objetivo e metodologia;
- **Capítulo 2:** apresenta os conceitos de *beamforming* indispensáveis para o entediamento e criação de ideias sobre o problema e as soluções de *beamtracking*;
- **Capítulo 3:** apresenta os modelos matemáticos de canais dinâmicos MIMO-mmWave, os parâmetros do 3GPP 5G NR, modelo de tempo de coerência revisado para *beamforming*, os métodos de estimação de canal MIMO-mmWave baseados em LS e resultados simulados;
- **Capítulo 4:** apresenta as teorias relacionadas aos filtros de Kalman, os pseudos-código dos algoritmos de rastreamento de canal MIMO-mmWave com KFs e os resultados simulados;
- **Conclusões:** são resumidas as principais conclusões levantadas neste trabalho, assim como algumas perspectivas.

2 INTRODUÇÃO AO BEAMFORMING

2.1 Introdução

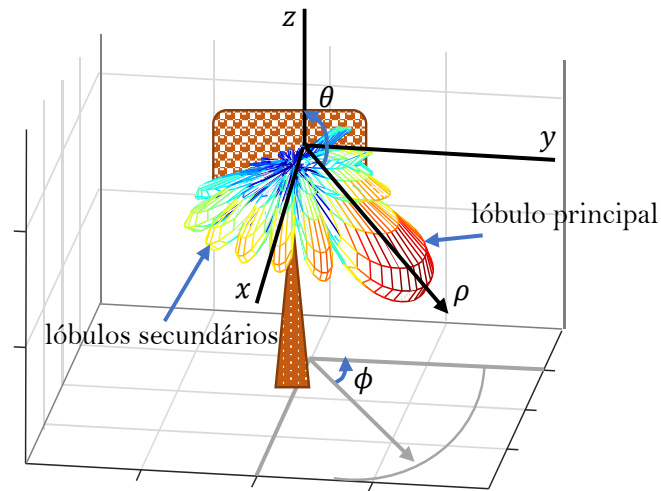
As recentes aplicações de sistemas de teleinformática projetam no futuro uma grande demanda por armazenamento, processamento e transmissão de dados. Tecnologias como realidade virtual, *big data* e sistemas inteligentes, *streams* de vídeo de alta definição, internet das coisas, mídias 3D entre outras, devem consumir grandes quantidades de dados móveis no futuro (RUFFINI, 2017). As futuras redes de comunicação móvel devem, então, fornecer suporte para grandes demandas de tráfego de dados e altas taxas de transmissão. Para alcançar tais requisitos, pesquisas recentes apontam como chave primordial os sistemas MIMO (do inglês *multiple input multiple output*) massivo e as faixas de operação de ondas milimétricas (30 GHz – 300 GHz) (XIAO *et al.*, 2017).

A adoção do espectro de ondas milimétricas (mmWave, do inglês *millimeter wave*) possibilita que os sistemas de comunicação móvel explorem uma banda larga não utilizada de mais de 100 GHz (PI; KHAN, 2011), com baixa interferência, que permite alcançar taxas de transmissão cem vezes maiores que os sistemas de comunicação móvel atuais (XIAO *et al.*, 2017). Devido ao pequeno comprimento de onda, mmWaves sofrem muito com perdas de percurso, absorções atmosféricas e atenuações por bloqueios (devido à fraca difração) (MACCARTNEY *et al.*, 2013). Por outro lado, elas viabilizam a miniaturização de antenas, possibilitando a integração de arranjos maiores de antenas no equipamento da estação base e no MT (HONG *et al.*, 2017) para a formação de um sistema de comunicação móvel MIMO massivo. Por sua vez, grandes arranjos de antenas, combinados com a evolução dos dispositivos de radiofrequência (RF) e dos sistemas digitais, viabilizam a implementação de um equipamentos de formatação de feixes por regulagem de fase dinâmica, tecnologia conhecida como sistema *beamforming*. O *beamforming* trata-se de concentrar a energia de radiação na melhor direção ao receptor, e reciprocamente, atribuindo à transmissão um ganho de arranjo que pode contrabalancear as perdas de propagação das mmWaves, além de reduzir as interferências intra-celulares e aumentar a eficiência espectral. Tal padrão de radiação direcionada é conhecido como feixe (do inglês *beam*).

Na prática, um feixe pode ser descrito, em coordenadas esféricas, pelas componentes

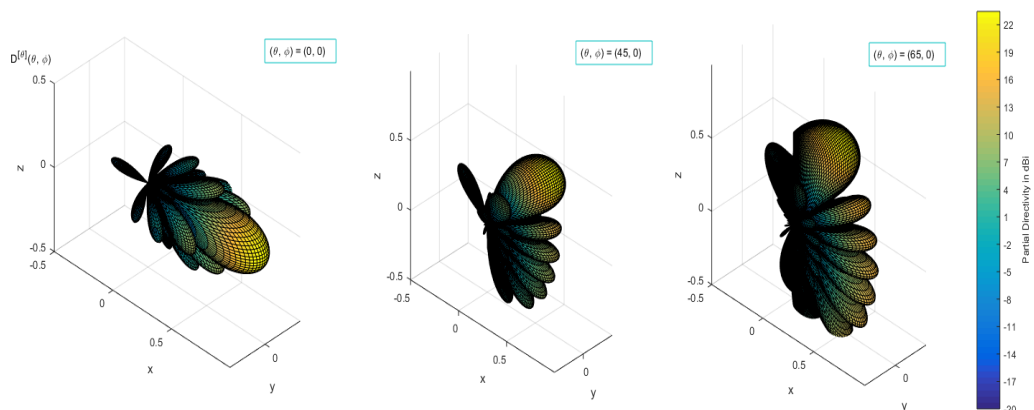
de elevação θ e azimute ϕ do vetor de direção (Figura 2). Essas componentes descrevem a direção do lóbulo principal. Um modelo ideal da diretividade de um feixe considera a formação somente do lóbulo principal com ganho constante. Porém, na prática, a formação de lóbulos secundários são inevitáveis (SILVEIRA *et al.*, 2017) e a diretividade varia com a direção, como ilustra a Figura 3 para diversos ângulos. Esses efeitos indesejados são intrínsecos ao *beamforming*, causando interferências e perdas de diretividade, e de eficiência energética.

Figura 2 – Ilustração do padrão de radiação de um feixe.



Fonte: criada pelo autor.

Figura 3 – Padrões de feixes para elevações de 0° , 45° e 65° . O *beamforming* convencional produz lóbulos secundários e diretividades que variam com a direção.



Fonte: criada pelo autor. Superfícies geradas com QuaDRiGa 2.0 .

Um arranjo de antenas pode ser mais diretivo se implementado com um número maior de pequenos elementos de antenas, dispostos próximos uns dos outros (MEDBO *et al.*,

2015), que se torna praticável devido aos pequenos comprimentos de onda mmWave. Na literatura, protótipos de sistemas MIMO–*beamforming* para BSs são equipados com arranjos de 16 a 256 elementos de antenas (MOLISCH *et al.*, 2017). Sistemas operando em frequência mais alta que 60 GHz podem fornecer larguras mais estreitas de feixes para mitigação do potencial de interferência.

2.1.1 Steering Vector

O direcionamento do feixe em uma arquitetura *beamforming* é realizado por meio das sobreposições das radiações dos elementos individuais no arranjo de antenas, de modo que um feixe é gerado por interferências construtivas no entorno da direção desejada e interferências destrutivas nas demais direções do espaço. Eletronicamente, isso é obtido por controle de amplitude e fase aplicado a cada elemento do arranjo de antenas (HAUPT, 2010). Matematicamente, se os elementos individuais do arranjo forem idênticos, a direção do feixe é obtida do produto entre o padrão de radiação do elemento único e o fator de arranjo (AF, do inglês *array factor*). O AF está relacionado à geometria do arranjo por meio de vetor de direcionamento (SV, do inglês *steering vector*), também conhecido como resposta de arranjo. O SV descreve os atrasos de fase de cada onda plana gerada por um elemento do arranjo de antenas. Por definição, o SV $\mathbf{a}(\theta, \phi) \in \mathbb{C}^{(N_{ant} \times 1)}$ para um UPA (do inglês *uniform planar array*) com N_{ant} elementos de antenas pode ser expresso por:

$$\mathbf{a}(\theta, \phi) = [a_1(\theta, \phi), a_2(\theta, \phi), \dots, a_{N_{ant}}(\theta, \phi)]^T \quad (2.1)$$

tal que

$$a_i(\theta, \phi) = \frac{1}{\sqrt{N_{ant}}} e^{j\mathbf{k}(\theta, \phi)\mathbf{r}_i} \quad (2.2)$$

e

$$\mathbf{k}(\theta, \phi) = \frac{2\pi}{\lambda} [\sin\theta \cos\phi, \sin\theta \sin\phi, \cos\theta] \quad (2.3)$$

em que \mathbf{k} é o vetor de onda, θ e ϕ são as componentes de elevação e azimute da direção de transmissão, respectivamente, \mathbf{r}_i é o vetor coluna de coordenadas relativas da i -ésima antena do arranjo, e λ é o comprimento de onda. As coordenadas relativas dos elementos do arranjo UPA podem ser criadas tomando como origem o elemento central do arranjo e utilizando como passo (espaçamento entre elementos) uma fração do comprimento de onda. Uma boa prática faz

explícitas as coordenadas na equação do arranjo. Desenvolvendo o produto interno na Equação (2.2), tem-se:

$$\mathbf{a}(\theta, \phi) = \frac{1}{\sqrt{N_{ant}}} \exp \left(\frac{j2\pi}{\lambda} \begin{bmatrix} x_1 \sin \theta \cos \phi + y_1 \sin \theta \sin \phi + z_1 \cos \theta \\ \vdots \\ x_{N_{ant}} \sin \theta \cos \phi + y_{N_{ant}} \sin \theta \sin \phi + z_{N_{ant}} \cos \theta \end{bmatrix} \right) \quad (2.4)$$

Um arranjo UPA pode ser visto como empilhamento de M arranjos lineares uniforme de antenas (ULA, do inglês *uniform linear array*) horizontais. Para $x_n = 0$ (arranjo no plano YZ) e para um espaçamento d entre elementos de antenas, tem-se:

$$\mathbf{a}(\theta, \phi) = \frac{1}{\sqrt{N_{ant}}} \exp \left(\frac{j2\pi d}{\lambda} \begin{bmatrix} n \sin \theta \sin \phi + m \cos \theta \\ \vdots \\ N \sin \theta \sin \phi + M \cos \theta \end{bmatrix} \right) \quad (2.5)$$

em que n e m são os índices inteiros da n -ésima antena do m -ésimo arranjo linear horizontal. Os índices n e m são tais, que o produto cartesiano entre eles geram N_{ant} pares ordenados, como ilustra a Figura 4 para uma ULA. Para esses índices inicializando em zero, tem-se:


$$\mathbf{a}(\theta, \phi) = \frac{1}{\sqrt{N_{ant}}} \exp \left(\frac{j2\pi d}{\lambda} \begin{bmatrix} 0 \\ \vdots \\ n \sin \theta \sin \phi + m \cos \theta \\ \vdots \\ (N-1) \sin \theta \sin \phi + (M-1) \cos \theta \end{bmatrix} \right) \quad (2.6)$$

O arranjo centralizado em $(0, 0, 0)$ é tal que:

$$\mathbf{a}(\theta, \phi) = \frac{1}{\sqrt{N_{ant}}} \exp \left(\frac{j2\pi d}{\lambda} \begin{bmatrix} -c_n \sin \theta \sin \phi + -c_m \cos \theta \\ \vdots \\ (n - c_n) \sin \theta \sin \phi + (m - c_m) \cos \theta \\ \vdots \\ (N-1 - c_n) \sin \theta \sin \phi + (M-1 - c_m) \cos \theta \end{bmatrix} \right) \quad (2.7)$$

em que c_n e c_m são as médias dos índices n e m , respectivamente.

Figura 4 – Coordenada y ao longo de m -ésima ULA horizontal do arranjo UPA.



Fonte: criada pelo autor.

Considere a resposta de um arranjo ULA, para $\theta = 0$, dada por (HEATH *et al.*, 2016):

$$\mathbf{a}(x) = \frac{1}{\sqrt{N_{ant}}} [1, e^{j2\pi x}, e^{j2\pi 2x}, \dots, e^{j2\pi(N_{ant}-1)x}]^T \quad (2.8)$$

tal que ¹ $x = \frac{d}{\lambda} \text{sen } \phi$ e $\phi \in [-\pi/2, \pi/2]$

em que x é o ângulo espacial normalizado. A resposta de um arranjo UPA pode ser dada pelo produto de Kronecker entre respostas de dois arranjos ULA, $\mathbf{a}_{el}(x_1) \in \mathbb{C}^{N_{ant,h} \times 1}$ definida ² no azimute para $N_{ant,h}$ antenas na horizontal e $\mathbf{a}_{az}(x_2) \in \mathbb{C}^{N_{ant,v} \times 1}$ definida na elevação para $N_{ant,v}$ na vertical:

$$\mathbf{a}(x_1, x_2) = \mathbf{a}_{el}(x_1) \otimes \mathbf{a}_{az}(x_2),$$

tal que ³ $x_1 = \frac{d}{\lambda} \text{sen } \theta \text{ sen } \phi$, $x_2 = \frac{d}{\lambda} \text{cos } \theta$ (2.9)

$\phi \in [-\pi/2, \pi/2]$ e $\theta \in [-\pi/2, \pi/2]$.

O AF é definido como:

$$AF(\theta, \phi) = \sum_{i=1}^{N_{ant}} w_i \mathbf{a}_i(\theta, \phi) = \mathbf{w}^T \mathbf{a}(\theta, \phi) \quad (2.10)$$

em que o vetor \mathbf{w} representa as excitações dos elementos do arranjo. Assim, o feixe pode ser direcionado por uma simples mudança nos valores de amplitude e fase. Os vetores de pesos que controlam tais parâmetros são comumente chamados de BV para o transmissor (do inglês *beamforming vector*) e CV (do inglês *combining vector*) para o receptor, ou de *codewords*.

¹ A escolha de x depende da convenção de sentidos adotada.

² Como x é função dos ângulos, definimos: $\mathbf{a}(x) \doteq \mathbf{a}(\theta, \phi)$.

³ As escolhas de x_1 e x_2 dependem da convenção de sentidos adotada.

2.1.2 Largura de Feixe

Uma característica importante dos sistemas *beamforming* é a largura de feixe (do inglês *beamwidth*) do lóbulos principal, pois é um fator que influencia diretamente na diretividade e, conseqüentemente, no alinhamento dos feixes. Como será apresentado no Capítulo 3, o tempo de coerência tem uma forte relação com a largura de feixe.

A largura de feixe é definida como a largura do lóbulos principal em meia potência (HPBW, do inglês *half power beam width*). Em outras palavras, é a separação angular na qual a magnitude do padrão de radiação diminui em 50% (−3 dB) do pico do lóbulos principal. Ela é também conhecida como largura de feixe de 3 dB.

Para um arranjo ULA do tipo *broadside* (máxima radiação na direção perpendicular ao eixo do arranjo), a largura de feixe Φ_L em radianos é dada por (CONSTANTINE *et al.*, 2016):

$$\Phi_L = 2 \left| \frac{\pi}{2} - \cos^{-1} \left(\frac{1,39\lambda}{\pi d N_{ant}} \right) \right|. \quad (2.11)$$

Para um arranjo UPA $N_{ant,v} \times N_{ant,h}$, a análise de largura de feixe é realizada no plano $y-z$, onde a largura de feixe é Φ_P (azimute), e no plano $x-y$, onde a largura de feixe é Θ_P (elevação). Para um feixe na direção (θ_0, ϕ_0) , vale as aproximações (CONSTANTINE *et al.*, 2016):

$$\Phi_P = \sqrt{\frac{1}{\cos^2 \phi_0 \left[\Phi_{Lx}^{-2} \cos^2 \theta_0 + \Phi_{Ly}^{-2} \sin^2 \theta_0 \right]}} \quad (2.12)$$

e

$$\Theta_P = \sqrt{\frac{1}{\Phi_{Lx}^{-2} \sin^2 \theta_0 + \Phi_{Ly}^{-2} \cos^2 \theta_0}}. \quad (2.13)$$

Para um arranjo UPA quadrado ($N_{ant,v} = N_{ant,h}$, $\Phi_{Lx} = \Phi_{Ly}$) e para $\phi_0 = 0$ (direção perpendicular ao plano $y-z$), vem que:


$$\Phi_P = \Theta_P = \Phi_{Lx} = \Phi_{Ly}. \quad (2.14)$$

É convencional para arranjos planares definir a largura de feixe em ângulo sólido $\Omega_P = \Phi_P \Theta_P$.

2.2 Arquiteturas

Existem três diferentes arquiteturas de *beamforming* propostas na literatura (HEATH *et al.*, 2016): *beamforming* analógico (VENKATESWARAN; VEEN, 2010), *beamforming* digital e *beamforming* híbrido (BOGALE; LE, 2014). O *beamforming* analógico utiliza apenas uma cadeia de RF para configurar o arranjo de antenas, o que permite um projeto de *hardware* com baixo custo e consumo de energia (Figura 5). Porém, deslocadores de fase analógicos são limitados em níveis de quantização de fases e ajustamento de amplitude, em que apenas um número limitado de fases podem ser controladas. Isso limita a formação de feixes, como por exemplo, a formação de múltiplos lóbulos primários (feixes). Portanto, os lóbulos primários são formados um por vez, o que impossibilita a implementação de sistemas MIMO multi-usuário e multi-*stream* (ALKHATEEB *et al.*, 2014b). Os sistemas baseados em formação analógica utilizam comutação de feixes dentro de um conjunto predefinido de direções, denominado *codebook*, para realizarem o alinhamento de feixes. Tal conjunto de feixes é discreto devido à limitação da arquitetura analógica de gerar feixes num espaço contínuo. O padrão de rede sem fios IEEE 802.11ad (ASSOCIATION *et al.*, 2012) é baseado nesse tipo de arquitetura.


Figura 5 – Sistema MIMO com *beamforming* analógico para ondas milimétricas.



Fonte: criada pelo autor.

A arquitetura de *beamforming* digital, que tem paradigma adequado aos sistemas MIMO convencionais, requer uma cadeia de RF e um DAC/ADC (do inglês *Digital to Analog Converter/Analog to Digital Converter*) dedicado para cada elemento de antena do arranjo (Figura 6). Como consequência, tem-se o projeto de *hardware* muito mais complexo e um consumo maior de energia que, para sistemas mmWave, que operam em alta frequência de portadora e em larga banda, chega a ser inviável. No entanto, as arquiteturas digitais são capazes de gerarem fases num espaço contínuo e de fornecer diretamente suporte para sistemas multi-usuário e multi-*stream*.

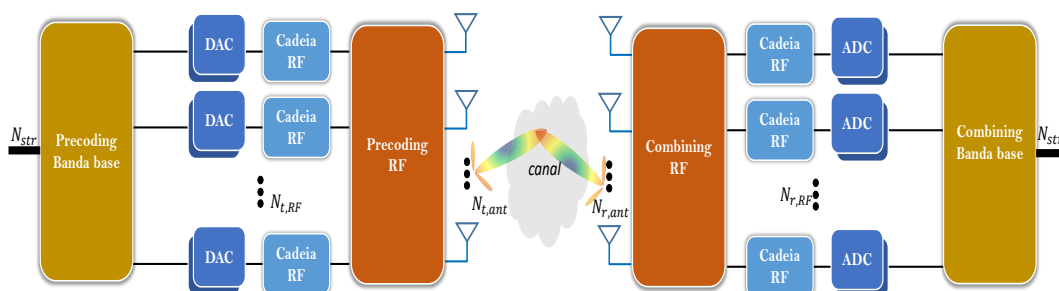
Figura 6 – Sistema MIMO com *beamforming* digital para ondas milimétricas.



Fonte: criada pelo autor.

O *beamforming* híbrido fornece um bom *trade-off* entre o benefício do *hardware* simplificado da arquitetura analógica e o ganho de multiplexação da arquitetura digital (Figura 7). O número mínimo de cadeias de RF necessárias para um serviço *multi-stream* é determinado pelo número de *streams*. Porém, matrizes de canal MIMO mmWave são de baixo *rank* devido ao pequeno número efetivo de espalhadores que essas ondas estão sujeitas. Portanto, o número de *streams* pode ser menor que o número de antenas, e, então, o número de cadeias de RF pode ser reduzido em uma arquitetura híbrida. Considere N_{str} , N_{RF} e N_{ant} como sendo o número de *streams*, de cadeias de RF e de antenas, respectivamente. Então uma arquitetura híbrida possui um domínio analógico e outro digital tal que $N_{str} \leq N_{RF} \leq \min(N_{t,ant}, N_{r,ant})$. A arquitetura analógica seria um caso particular da híbrida em que $N_{str} = N_{RF} = 1$. Numa comunicação *multistream*, no transmissor por exemplo, um *precoder* de banda base $\mathbf{F}_{BB} \in \mathbb{C}^{N_{RF,t} \times N_{str}}$, é aplicado às cadeias de RF, que é seguido por um *precoder* de RF $\mathbf{F}_{RF} \in \mathbb{C}^{N_t \times N_{RF,t}}$ (o BV), usado nos circuitos analógicos que conectam as antenas. O *precoder* resultante é então $\mathbf{F} = \mathbf{F}_{RF} \mathbf{F}_{BB}$. As arquiteturas híbridas são as mais promissoras, porém herdam muitos desafios de seu domínio analógico. O padrão de rede sem fios 802.11ay é baseado nesse tipo de arquitetura (ZHOU *et al.*, 2018).

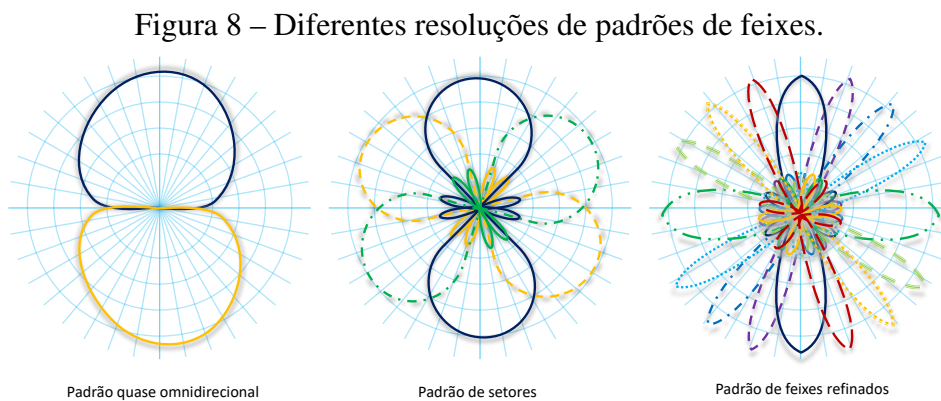
Figura 7 – Sistema MIMO com *beamforming* híbrido para ondas milimétricas.



Fonte: criada pelo autor.

2.2.1 Codebook

O *codebook* (também chamado de *beam-space* em trabalhos sobre arquiteturas digitais) é uma tabela que salva as especificações de configuração predeterminadas do arranjo de antenas para a formatação de feixes que garantem um AF adequado para as camadas MAC e PHY do padrão de rádio. Tais especificações são: ângulos de direcionamento, pesos, resolução de padrões (Figura 8), e propriedades do padrão de radiação do feixe, tais como diretividade máxima do arranjo de antenas e HPBW. É comum na literatura de *beamtracking* que os autores adotem o termo *codebook* para designar matrizes $\mathbf{F}_{RF} \in \mathbb{C}^{N_{t,ant} \times N_{r,beams}}$ e $\mathbf{W}_{RF} \in \mathbb{C}^{N_{r,ant} \times N_{r,beams}}$ predefinidas de *codewords* de RF BV e CV, respectivamente.



Fonte: criada pelo autor.

O projeto de um padrão de feixe otimizado leva em consideração: a frequência central, o espaçamento entre os elementos de antenas, a forma geométrica do arranjo, os deslocadores de fase, a largura e o número de feixes. O *codebook* visa minimizar a perda de ganho do arranjo nas interseções dos padrões de feixes adjacentes dentro do conjunto de feixes que asseguram uma cobertura útil completa (SINGH; RAMAKRISHNA, 2015), (WANG, 2009). A formatação analógica de feixes em cadeias de RF é realizada sobre ganho constante e níveis discretos de direção (quantização angular). Sob essa perspectiva, três tipos de projetos de *codebooks* são amplamente utilizados na literatura de *beamtracking* (WU *et al.*, 2017):

- *Codebook* Uniforme: trabalhos sobre *beamtracking* que lidam diretamente com os ângulos dos feixes utilizam um *codebook* uniforme, tal que as componentes angulares azimute e elevação são equiespaçadas;
- *Codebook Beam-steering*: esse tipo de *codebook* utiliza a mesma forma de resposta de arranjo para produzir os *codewords* BV e CV sobre um número de níveis quantização

angular dos deslocadores de fases, que é expresso em bits. Para um arranjo do tipo ULA, o *codebook* é tal que:

$$\begin{aligned} \mathbf{F}_{RF}(n, b) &= \exp \left[j\pi n \text{sen} \left(\frac{2\pi b}{2^{bits}} \right) \right], \\ \text{tal que } n &= 0, 1, 2, \dots, N_{ant} - 1 \\ \text{e } b &= 1, 2, \dots, 2^{bits} = N_{feixes}. \end{aligned} \quad (2.15)$$

- *Codebook* DFT (YANG *et al.*, 2010): esse *codebook* é tal que as matrizes \mathbf{F}_{RF} e \mathbf{W}_{RF} são matrizes DFTs (do inglês *discrete Fourier transform*). Em (YANG *et al.*, 2010) é demonstrado, para arranjos lineares uniformemente espaçados e canais com correlação espacial, que a matriz DFT corresponde aproximadamente aos vetores de pesos *beamforming*. A propriedade dos *codewords* unitários de *codebook* DFT é bem explorado por algoritmos de estimação de canal baseados em LS (do inglês *least squares*) (LEE *et al.*, 2014). Um *codebook* DFT é normalmente definido para $N_{ant} = N_{feixes}$. Para um arranjo do tipo ULA é tal que:

$$\begin{aligned} \mathbf{F}_{RF}(n, b) &= \exp \left[j \frac{2\pi n b}{N_{ant}} \right], \\ \text{tal que } n &= 0, 1, 2, \dots, N_{ant} - 1 \\ \text{e } b &= 0, 1, 2, \dots, N_{ant} - 1. \end{aligned} \quad (2.16)$$

Para arranjos do tipo UPA, com $N_{ant,h}$ antenas horizontais e $N_{ant,v}$ antenas verticais, um *codebook* 3-D pode ser determinado por meio do produto de Kronecker entre os *codewords* de dois *codebooks* 2-D definidos para $N_{ant,h}$ e $N_{ant,v}$ cada (WU *et al.*, 2017), ou seja, um *codeword* 3-D $\mathbf{f}_b \in \mathbb{C}^{N_{ant} \times 1}$ pode ser dado por:

$$\begin{aligned} \mathbf{f}_b &= \mathbf{f}_{b,v} \otimes \mathbf{f}_{b,h}, \\ \text{tal que } \mathbf{f}_{b,v} &\in \mathbb{C}^{N_{ant,v} \times 1} \quad \text{e} \quad \mathbf{f}_{b,h} \in \mathbb{C}^{N_{ant,h} \times 1}. \end{aligned} \quad (2.17)$$

2.3 Beamtraining

Em sistemas de comunicação móvel com transmissão omnidirecional, o sinal destinado a um usuário se estende ao longo de toda a célula. Como consequência, tem-se: ineficiência energética, interferência intra-celular e vulnerabilidade à espionagem do tráfego de rede. A transmissão por *beamforming* é capaz de concentrar grande parte da energia em uma direção, aumentando a eficiência energética, a segurança, e reduzindo as interferências. No entanto, para um direcionamento eficaz é necessário uma estimativa completa do canal MIMO. A adoção de feixes estreitos implica em algoritmos de alta complexidade na fase de IA, principalmente com

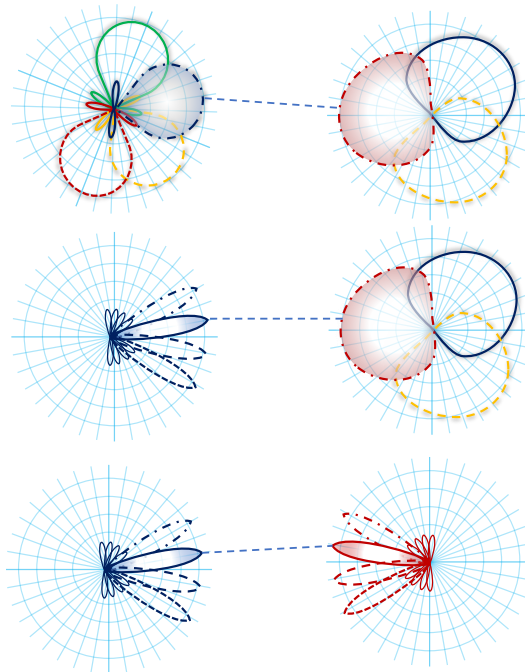
arquitecturas analógicas, em que o espaço não é completamente varrido em uma única transmissão de *beacons* ou pilotos. A alta diretividade em redes 5G gera desafios com algoritmos de busca ágil por feixes que maximizem a SNR, conhecidos como algoritmos de *beamtraining*, de tal forma que a complexidade desses algoritmos é inversamente proporcional à largura dos feixes. A formatação de feixes estreitos requer um arranjo de antenas maior, de forma que quanto mais estreito for o feixe, maior deve ser o arranjo, resultando numa matriz de canal com grandes dimensões. Além disso, as largas bandas da faixa de operação mmWave aumenta a potência do ruído, tornando baixa a SNR de recepção antes mesmo da formatação do feixe (ALKHATEEB *et al.*, 2014b). Pode-se citar, da literatura, dois métodos clássicos de *beamtraining* (GIORDANI *et al.*, 2016b): exaustivo e iterativo. Ainda pode-se citar os métodos baseados em histórico de medições (MOHAMED *et al.*, 2015), (NITSCHKE *et al.*, 2015).

No *beamtraining* analógico baseado em busca exaustiva, todos os pares de feixes transmissor/receptor do *codebook* são testados um por vez. Considere um exemplo em que a BS tem N feixes e o MT tem M feixes. Inicialmente, a BS transmite uma sequência de M *probe frames* em diferentes intervalos de tempo, de modo que cada *probe frame* é destinado a um feixe do MT. Em cada intervalo de tempo, o MT seleciona um de seus feixes para receber o *probe frame* e, em seguida, mede e armazena o valor de SNR. Prosseguindo, o MT seleciona o feixe no qual percebeu a SNR máxima, para *feedback*. A BS, então, armazena o valor de SNR recebido e, em seguida, o processo é repetido para os demais feixes. No final do treinamento, o par de feixes transmissor/receptor que tem SNR máxima é escolhido para estabelecer o enlace de comunicação. Nesse caso o *beamtraining* tem complexidade de $\mathcal{O}(NM)$ (desconsiderando as sinalizações).

O *beamtraining* definido no padrão IEEE 802.11ad é baseado em busca iterativa, como ilustra a Figura 9. Basicamente, o padrão IEEE 802.11ad adota um protocolo de treinamento de feixe iterativo em diferentes resoluções de padrões de radiação. O protocolo é dividido em duas fases: varredura em nível de setor (SLS, do inglês *sector level sweep*) e refinamento de feixes (BRP, do inglês *beam refinement protocol*). Na fase SLS, uma varredura exaustiva é executada em setores para reduzir o espaço de busca. As antenas da BS são configuradas para padrões de feixes setoriais, tendo no máximo 128 setores, de modo que cada um transmita ou receba *probe frames* de SLS por vez. A BS, por exemplo, pode iniciar o treinamento e transmitir *probe frames* de SLS por um de seus feixes setoriais e o MT pode receber os *probe frames* em

seus quase omni-feixes e então relatar as medidas de SNR. Repete-se o processo para cada setor da BS, de modo que cada par de feixes setoriais transmissor/receptor seja testado para determinar o par que fornece a SNR máxima. Na fase BRP, os feixes setoriais encontrados na fase SLS são refinados e alinhados. O melhor par encontrado na fase SLS garante trocas confiáveis de *frames* na fase BRP. Dentro do par de setores são executados testes de SNR por par de feixes refinados (ou estreitos), e então o melhor par de feixes é escolhido para definir o enlace de comunicação. A complexidade do *beamtraining* cresce de forma quadrática, $\mathcal{O}(N_{\text{feixes_finos}}^2)$, com o número de feixes refinados (BO *et al.*, 2015).

Figura 9 – Exemplo de um método de busca iterativa.



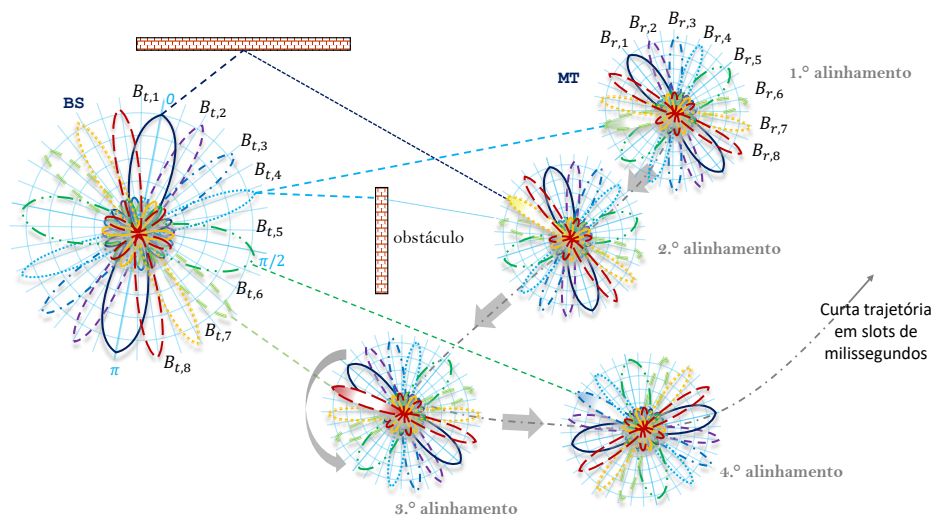
Fonte: criada pelo autor.

2.4 Beamtracking

O *beamtraining* é realizado para definir o IA do MT ao BS com o melhor enlace possível através do alinhamento de feixes e garantir tal alinhamento durante a comunicação. Devido à alta complexidade do *beamtraining*, é desejado que ele seja executado o mínimo de vezes possível durante a conexão com MT. Porém, os MTs estão sujeitos aos rápidos movimentos do usuário (descolamento e rotação), que causam variações no canal mmWave. Por exemplo, o movimento da mão do usuário pode chegar a mais de $80^\circ/\text{s}$ (TSANG; POON, 2011). Isso implica em rápidas variações dos AoAs. Assim, faz-se necessário um novo processo, periódico e de baixa complexidade, que mantenha o alinhamento ao longo da comunicação até que haja uma

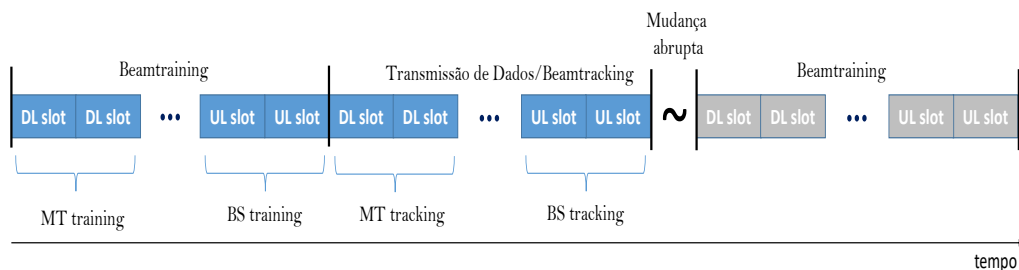
mudança brusca no canal, momento no qual um novo *beamtraining* seria exigido (Figura 10). Tal processo é chamado de *beamtracking*. Idealmente, os protocolos de *beamtracking* não usam *frames* dedicados para não afetar drasticamente a taxa de transmissão. Em vez disso, utilizam os *frames* de dados como base para agregar campos de treinamento e medidas de potência ou SNR para estimação de canal (Figura 11).

Figura 10 – Exemplo de aplicação de um *beamtracking*. Fenômenos repentinos, como obstáculos e rotação, que podem ocorrer com MT em velocidade consideravelmente alta, causam desalinhamento na ausência do *beamtraining*. O *beamtracking* garante o alinhamento do feixe durante os fenômenos repentinos.



Fonte: criada pelo autor.

Figura 11 – Exemplo de *beamtraining* e *beamtracking* no tempo com TDD.



Fonte: criada pelo autor.

Por uma questão de viabilidade, o padrão IEEE 802.11ad faz *beamtracking*, estimando SNR e a resposta do canal pelo envio de mais de $N_{\text{pares_feixes}} \times 4032$ símbolos de piloto, sobre um conjunto de no máximo 8 feixes refinados, indicados pelo *beamtraining* (ASSOCIATION *et al.*, 2012). Tal *beamtracking* funciona bem para canais lentos. Porém, altas velocidades e rotações do MT geram cenários mais severos, com canais de tempos de coerência curtos. Além

disso, o *beamtracking* do IEEE 802.11ad não garante a matriz completa do canal, pois somente poucos feixes são utilizados no espaço, o que pode impossibilitar a multiplexação espacial.

Um método clássico de estimação completa de canal baseado em LS explora a propriedade esparsa da matriz do canal *beamforming* mmWave. Para reduzir a complexidade no cálculo da pseudo-inversa, em (LEE *et al.*, 2014) é empregado amostragem compressiva (do inglês *compressed sensing*) utilizando o algoritmo OMP (do inglês *orthogonal matching pursuit*). Porém, a complexidade continua consideravelmente alta devido à forma exaustiva de teste de casamento de *codewords* entre o *codebook* e o dicionário de *codewords*, que cresce quadraticamente em estimativas 3-D. Além disso, para altos desempenhos, o métodos exige um *codebook* DFT com um considerável número de feixes de treinamento, que deve ser igual ou maior que o número de antenas.

O método proposto em (HE *et al.*, 2014) rastreia, por treinamento, os BV e CV analógicos de uma arquitetura híbrida, de forma a reduzir o espaço de busca de *codewords*. A estimativa dos vetores *beamforming* analógicos (de RF) é realizada por rotações dos vetores do instante anterior, sobre a consideração de uma proximidade relativa entre *codewords* de instantes adjacentes, tal que, de um grupo de códigos rotacionados, é selecionado o *codeword* que maximiza a potência recebida. Em seguida, os *codewords* digitais são atualizados empregando uma técnica de estimativa de canal por mínimos quadrados. O algoritmo é computacionalmente complexo e restrito à baixa mobilidade.

Em (ALKHATEEB *et al.*, 2014a), é proposto um algoritmo de estimação completa de canal para *beamtracking* baseado em um *codebook* de multiresolução (WANG, 2009), para arquiteturas *beamforming* híbridas. O algoritmo explora bem a esparsidade da matriz do canal *beamforming* mmWave, e combina-a com um método de amostragem compressiva adaptativo para estimação. Porém, uma precisa formatação de feixes em multiresolução requer um número considerável de cadeias de RF, que pode ser inviável quando poucas cadeias de RF estão disponíveis, ou quando se trabalha com arquiteturas puramente analógicas. Além disso, o método possui alta complexidade computacional.

Em (PALACIOS *et al.*, 2017) é proposto um algoritmo de *beamtracking* probabilístico para arquiteturas híbridas. O método trabalha sobre os preâmbulos dos *frames* de dados, no domínio analógico, recebido pelo MT ou BS. Trata-se de estimar (rastrear) os ângulos AoA

ou AoD, chamado de vetor θ , por meio de um problema de minimização do critério de Bayes, que tem como *a priori* a probabilidade do vetor θ e como função objetivo a probabilidade do sinal recebido no domínio analógico dado θ . O método trabalha como modelo paramétrico de canal, distribuições Gaussianas e com o preâmbulo recebido pelo padrão de feixe atual. Porém, a restrição do espaço de busca e a suposição de estatísticas da distribuição *a priori* impede a estimação completa de canal e pode gerar grandes erros de estimação de alinhamento de feixe, principalmente em cenários mais hostis. Além disso, esse método é restrito a arquiteturas híbridas.

Em (ZHANG *et al.*, 2015), é proposto um método *beamtracking* de baixa complexidade baseado em rastreamento dos parâmetros do canal com KF. O método realiza estimativa completa do canal a partir de um modelo de canal parametrizado pelo AoD e AoA de cada *cluster*. Requer, inicialmente, o conhecimento *a priori* do CSI (do inglês *channel state information*), de onde são extraídas as informações de *clusters*, AoD e AoA. Um EKF é, então, utilizado para rastrear os parâmetros AoD e AoA atuais a partir dessas informações *a priori* do estado inicial e de observações atuais de símbolos recebidos por uma varredura completa do *codebook*. O método é preciso, de complexidade relativamente baixa, pode ser bem robusto e é facilmente adaptado para qualquer arquitetura *beamforming*. Além disso, os KFs podem ser paralelizáveis (BAYOUMI *et al.*, 1992).

Um método de *beamtracking* definitivo ainda é um problema em aberto na literatura. Um algoritmo de *beamtracking* ideal deve ser de baixa complexidade computacional e de treinamento, e deve ser escalável, ao mesmo tempo que fornece uma estimativa completa de canal de forma precisa e robusta (e estável). Deve trabalhar sob um regime de baixa SNR e de curto tempo de coerência. Deve se manter fiel as restrições de hardware e independe da geometria do arranjo de antenas.

Neste trabalho, são realizadas variações sobre o método apresentado em (ZHANG *et al.*, 2015), com aplicações das seguintes variações do KF: EKF, UKF, EnKF e DEnKF. Tal método é fiel às restrições de complexidade computacional e de treinamento, e possui potencial para ser estável devido à aplicação do KF. Serão analisados os desempenhos desses filtros sob condições diferentes de SNR, complexidade de treinamento e tempo de coerência, e sob distribuições não Gaussianas de AoA e AoD.

3 MODELAGEM DE CANAL DINÂMICO PARA SISTEMAS 5G

3.1 Modelos do Sistema

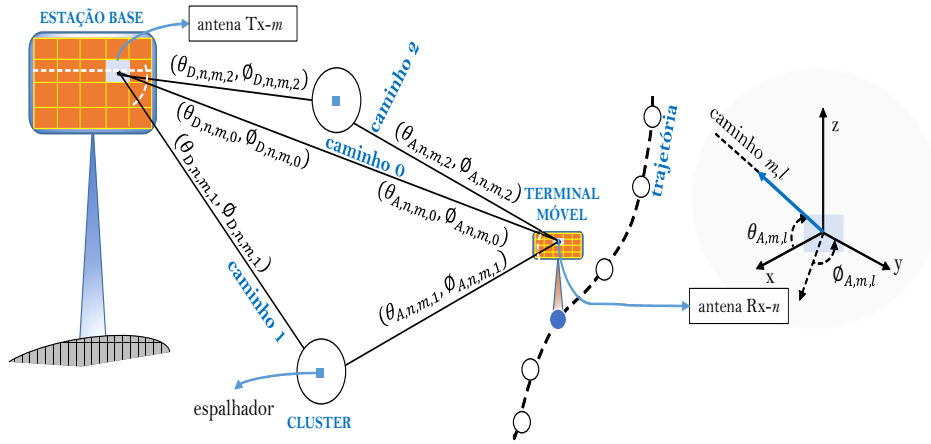
Nesta seção serão descritos os modelos matemáticos necessários para implementação dos filtros de rastreamento. Esses modelos são: modelo de canal espacial para MIMO-mmWave, modelos de evolução dos parâmetros do canal MIMO-mmWave e modelo de recepção de símbolos de treinamento.

3.1.1 Modelo de Canal

Em sistemas de comunicações móveis MIMO convencionais, cujas frequências de operação estão abaixo de 5 GHz, considera-se modelos de canais ricos em espalhadores. Contudo, canais massivos MIMO-mmWave são modelados com poucos espalhadores devido às características de alta diretividade, feixes estreitos e fortes atenuações. O número de caminhos de propagação para esses tipos de canais é então limitado, o que resulta numa matriz de canal esparsa (RAPPAPORT *et al.*, 2013). No domínio angular, devido a essa natureza esparsa, a matriz de canal pode ser bem definida em termos de AoA, AoD e ganhos de caminho. Isso viabiliza a adoção de modelos de canais paramétricos na estimação de canais mmWave, tal que a estimativa se reduz a estimar tais parâmetros.

Medições empíricas de canais MIMO-mmWave mostram que versões atrasadas do sinal chegam ao receptor em *clusters* (ou grupos), como mostra a Figura 12, tal que cada *cluster* possui algumas características estatísticas de ângulos, potência e atraso (RAPPAPORT *et al.*, 2013). Um *cluster* representa uma macro região em que ocorre reflexão, difração, atenuação e espalhamento do sinal em torno de médias estatísticas bem-definidas. Assim, um *cluster* é um agrupamento de espalhadores com estatísticas semelhantes.

Considere uma BS equipada com um arranjo UPA de N_t elementos de antenas, indexados por $m = 1, 2, \dots, N_t$, e um MT equipado com um arranjo UPA de N_r elementos de antenas, indexados por $n = 1, 2, \dots, N_r$. Neste trabalho, considere L *clusters* constituídos de um único espalhador. Então, para cada combinação entre um elemento de antena receptora n , um elemento de antena transmissora m e um *cluster* l , existe um único caminho c de índice (n, m, l) . Um canal mmWave pode ser expresso em relação aos seguintes parâmetros definidos para cada

Figura 12 – Modelo de canal espacial com *clusters*.

Fonte: criada pelo autor.

caminho c : AoA, AoD e ganho complexo α (como na Figura 12).

Considere os parâmetros mencionados e os seguintes parâmetros: atraso κ_l e deslocamento Doppler ν_l do *cluster* l . A resposta de um canal MIMO-mmWave¹ no domínio da frequência, para uma componente f , pode ser dada por (HEATH *et al.*, 2016):

$$\mathbf{H}(f)[k] = \sum_{l=1}^L \alpha_l[k] e^{j2\pi(\nu_l k - \kappa_l f)} \mathbf{a}_r(\theta_{A,l}[k], \phi_{A,l}[k]) \mathbf{a}_t^H(\theta_{D,l}[k], \phi_{D,l}[k]) \quad (3.1)$$

em que os subíndices l , D , A , t e r indicam *cluster*, AoD, AoA, transmissor e receptor, respectivamente, o superíndice H indica o conjugado Hermitiano, k indica instante de tempo e L indica o número de *clusters* ou caminhos dominantes, que será considerado fixo.

É possível eliminar os parâmetros κ_l e ν_l se forem feitas as seguintes considerações: Considere que o canal varia muito lentamente dentro do intervalo T_s de um símbolo, então podemos aproximar o termo $e^{j2\pi\nu_l T_s} \approx 1$. Além disso, considere também que a largura de banda do canal W é suficientemente pequena, tal que $e^{-j2\pi\kappa_l W} \approx 1$. Assim, a Equação (3.1) pode ser simplificada, escrevendo-a como (HEATH *et al.*, 2016):

$$\mathbf{H}[k] = \sum_{l=1}^L \alpha_l[k] \mathbf{a}_r(\theta_{A,l}[k], \phi_{A,l}[k]) \mathbf{a}_t^H(\theta_{D,l}[k], \phi_{D,l}[k]) \quad (3.2)$$

em que $\mathbf{H}[k] \in \mathbb{C}^{N_r \times N_t}$ é a resposta em frequência de um canal MIMO-mmWave limitado em banda num instante k , parametrizada por AoA, AoD e α . Para obter potências normalizadas, multiplica-se α_l por $\sqrt{N_r N_t / L}$. Note que a Equação (3.2), adotada na grande maioria das propostas de soluções para *beamtracking*, depende da geometria do arranjo devido aos SVs.

¹ válido para um sistema MIMO-OFDM em que o domínio da frequência resulta das operações IFFT e FFT.

A Equação (3.2) também pode ser escrita de forma matricial como:

$$\mathbf{H}[k] = \mathbf{A}_r[k] \mathbf{H}_a[k] \mathbf{A}_t^H[k] \quad (3.3)$$

tal que

$$\mathbf{A}_t[k] = [\mathbf{a}_t(\theta_{f,1,k}, \phi_{f,1,k}), \mathbf{a}_t(\theta_{f,2,k}, \phi_{f,2,k}), \dots, \mathbf{a}_t(\theta_{f,L,k}, \phi_{f,L,k})], \quad (3.4)$$

$$\mathbf{A}_r[k] = [\mathbf{a}_r(\theta_{w,1,k}, \phi_{w,1,k}), \mathbf{a}_r(\theta_{w,2,k}, \phi_{w,2,k}), \dots, \mathbf{a}_r(\theta_{w,L,k}, \phi_{w,L,k})] \quad (3.5)$$

e

$$\mathbf{H}_a[k] = \text{diag}(\mathbf{a}[k]), \quad (3.6)$$

tal que $\mathbf{a}[k] = [\alpha_{1,k}, \alpha_{2,k}, \dots, \alpha_{L,k}]$. Quando se utiliza as respostas de arranjo (2.1) com um *codebook* DFT, as matrizes \mathbf{A}_r e \mathbf{A}_t são feitas unitárias (matrizes DFT), tal que a Equação (3.3) é uma decomposição em valores singulares (SVD, do inglês *singular value decomposition*) da matriz \mathbf{H} .

3.1.2 Modelo de Evolução

Considere as seguintes variáveis vetoriais: $\boldsymbol{\theta}_{D,k} = [\theta_{D,k,1}, \dots, \theta_{D,k,L}]$, $\boldsymbol{\theta}_{A,k} = [\theta_{A,k,1}, \dots, \theta_{A,k,L}]$, $\boldsymbol{\phi}_{D,k} = [\phi_{D,k,1}, \dots, \phi_{D,k,L}]$, $\boldsymbol{\phi}_{A,k} = [\phi_{A,k,1}, \dots, \phi_{A,k,L}]$, $\boldsymbol{\alpha}_k^{real} = \Re(\mathbf{a}_k)$ e $\boldsymbol{\alpha}_k^{img} = \Im(\mathbf{a}_k)$. Então, define-se o vetor de estado como:

$$\boldsymbol{\chi}_k = [\boldsymbol{\phi}_{D,k}, \boldsymbol{\phi}_{A,k}, \boldsymbol{\theta}_{D,k}, \boldsymbol{\theta}_{A,k}, \boldsymbol{\alpha}_k^{real}, \boldsymbol{\alpha}_k^{img}]^T, \quad (3.7)$$

tal que $\boldsymbol{\chi}_k$ tem dimensão $D_L = 6L$.

Considera-se que essas variáveis são independentes entre si. Para cada variável em $\boldsymbol{\chi}$ será atribuída uma variância. Por simplicidade, para os ângulos, suas variâncias serão escritas em função de uma variância única σ_u^2 . Geometricamente, para movimentos translacionais, as variações das componentes de elevação e azimute da direção da visada direta depende da trajetória do MT em relação à BS. Para uma certa trajetória, foram adotadas as seguintes regras

de variação:

$$\begin{cases} \sigma_{\phi,l}^2 = \sigma_u^2 & \forall l \\ \sigma_{\theta,l}^2 = 0.5\sigma_u^2 & l \neq 0 \\ \sigma_{\theta,l}^2 = 0.05\sigma_u^2 & l = 0. \end{cases} \quad (3.8)$$

Para α_l , baseado em (VA *et al.*, 2016), foi adotado o seguinte modelo:

$$\alpha_l[k] = \rho \alpha_l[k-1] + u_{\alpha,l}[k] \quad (3.9)$$

em que ρ é o coeficiente de correlação temporal do canal e $u_{\alpha,l} \sim \mathcal{CN}(0, (1 - \rho^2))$.

O modelo de evolução de estado adotado é um modelo linear Gaussiano dado por:

$$\boldsymbol{\chi}[k] = \mathbf{A}\boldsymbol{\chi}[k-1] + \mathbf{u}[k] \quad (3.10)$$

em que $\mathbf{A} = \text{diag}([\mathbf{1}_{1 \times 4L}, \rho \mathbf{1}_{1 \times 2L}])$ e $\mathbf{u} \sim \mathcal{N}(0, \boldsymbol{\Sigma})$, tal que $\boldsymbol{\Sigma} = \text{diag}([\boldsymbol{\sigma}_\phi, \boldsymbol{\sigma}_\phi, \boldsymbol{\sigma}_\theta, \boldsymbol{\sigma}_\theta, \boldsymbol{\sigma}_\alpha, \boldsymbol{\sigma}_\alpha])$. Sendo que \mathbf{u} é uma variável randômica Gaussiana, a geração da variável $\boldsymbol{\chi}$ também pode ser dada por:

$$\boldsymbol{\chi}[k] \sim \mathcal{N}(\mathbf{A}\boldsymbol{\chi}[k-1], \boldsymbol{\Sigma}). \quad (3.11)$$

3.1.3 Transmissão de Pilotos

Considere os vetores de direcionamento de transmissão \mathbf{f} (BV) e de recepção \mathbf{w} (CV). Uma cadeia de RF produz um único feixe regido por um vetor BV ou CV que, parametrizado pelos ângulos de direcionamento, é dado por:

$$\mathbf{f} = \mathbf{a}_t(\theta_f, \phi_f) \quad (3.12)$$

e

$$\mathbf{w} = \mathbf{a}_r(\theta_w, \phi_w) \quad (3.13)$$

em que os subíndices f e w indicam BV e CV, respectivamente. Considere um símbolo piloto s , transmitido com um BV \mathbf{f} e recebido por um CV \mathbf{w} . O símbolo recebido y é dado por:

$$y = \mathbf{w}^H \mathbf{H} \mathbf{f} s + \mathbf{w}^H \mathbf{v} \quad (3.14)$$

em que $\mathbf{v} \sim \mathcal{CN}(\mathbf{0}, \sigma_v^2 \mathbf{I}_{N_r})$. Considere a comunicação somente em *downlink*. O *codebook* (KUTTY; SEN, 2016) contém $N_f = N_t$ direções de transmissão e $N_w = N_r$ direções de recepção. Considere também que cada elemento de antena do arranjo tem padrão de radiação omnidirecional. Neste trabalho, para cada instante do *beamtracking*, é realizada uma varredura completa entre cada par BV-CV do *codebook*, sendo transmitidos $N_f N_w$ pilotos por instante de *beamtracking*. Considere que o canal não varia durante a varredura.

3.1.4 Modelo de Medição

Um símbolo recebido y_{qp} de um símbolo conhecido s (por isso façamos $s = 1$), transmitido com p -ésimo BV e recebido pelo q -ésimo CV num instante k é dado por:

$$y_{qp}[k] = \mathbf{w}_q^H \mathbf{H}(\boldsymbol{\chi}_k) \mathbf{f}_p + \mathbf{w}_q^H \mathbf{v}[k] \quad (3.15)$$

em que $\mathbf{H}(\boldsymbol{\chi}_k) \doteq \mathbf{H}[k] \doteq \mathbf{H}_k$.

O instante k representa um bloco. Fazendo $\mathbf{W}_{RF} = [\mathbf{w}_1, \dots, \mathbf{w}_{N_w}]$ e $\mathbf{F}_{RF} = [\mathbf{f}_1, \dots, \mathbf{f}_{N_f}]$, em que $\mathbf{F}_{RF} \in \mathbb{C}^{N_t \times N_f}$ e $\mathbf{W}_{RF} \in \mathbb{C}^{N_r \times N_w}$ são matrizes *beamforming* de RF, então, para uma varredura completa, tem-se o seguinte modelo de medição:

$$\mathbf{Y}(\boldsymbol{\chi}_k) = \mathbf{W}_{RF}^H \mathbf{H}(\boldsymbol{\chi}_k) \mathbf{F}_{RF} + \mathbf{W}_{RF}^H \mathbf{V}_k \quad (3.16)$$

em que $\mathbf{V} \sim \mathcal{CN}(0, \sigma_v^2 \mathbf{I}_{N_w N_f})$. Para uma arquitetura híbrida, as matrizes de *beamforming* \mathbf{F}_{RF} e \mathbf{W}_{RF} são substituídas por \mathbf{F} e \mathbf{W} , tal que $\mathbf{F} = \mathbf{F}_{RF} \mathbf{F}_{BB}$ e $\mathbf{W} = \mathbf{W}_{RF} \mathbf{W}_{BB}$.

Aqui, é feita uma pequena distinção particular a este trabalho. Definimos como vetor de observação o vetor de símbolos recebidos do canal e de vetor de medição o vetor de símbolos recebido estimado pelo modelo de medição. Se o modelo de canal utilizado na simulação for exatamente o mesmo utilizado na implementação do filtro, então os vetores de observação e medição são equivalentes, que é o caso adotado neste trabalho. Considere o vetor de observação \mathbf{y} dado pela vetorização $\mathbf{y} = \text{vec}(\mathbf{Y})$ e vetor de medição \mathbf{g} para um estado estimado $\hat{\boldsymbol{\chi}}$ dado pela vetorização $\mathbf{g} = \text{vec}(\mathbf{W}^H \mathbf{H}(\hat{\boldsymbol{\chi}}) \mathbf{F})$. Para que os filtros não gerem valores de estado complexos, utiliza-se os vetores $\mathbf{y}_{(R|I)} = \begin{bmatrix} R(\mathbf{y}) \\ I(\mathbf{y}) \end{bmatrix}$ e $\mathbf{g}_{(R|I)} = \begin{bmatrix} R(\mathbf{g}) \\ I(\mathbf{g}) \end{bmatrix}$. Então, podemos reescrever (3.16) como:

$$\mathbf{y}(\boldsymbol{\chi}_k) = \mathbf{g}(\boldsymbol{\chi}_k) + \mathbf{v}_k \quad (3.17)$$

em que $\mathbf{v}_k = \text{vec}(\mathbf{W}^H \mathbf{V}_k)$.

3.1.5 Parâmetros do 3GPP 5G New Radio

Os parâmetros do sistema adotados neste trabalho foram retirados dos mais recentes relatórios técnicos 3GPP 5G NR (dos inglês 3rd Generation Partnership Project, 5th Generation Wireless Systems e New Radio). Baseados na estrutura de *frame* e numerologia relatados em (3GPP, 2018), (CHOI, 2018), foi montada a Tabela 1 de valores de referência adotados para sistema 5G.

Tabela 1 – Valores de referência para sistema 5G adotados.

Geração	3GPP 5G NR
Frequência de operação	28 GHz, banda n257
Banda	50 MHz
Espaçamento de subportadora	240 kHz
Duração do <i>frame</i>	10 ms
Número de <i>subframe</i>	10
Número de <i>slots</i> por <i>frame</i>	160
Número de símbolo por <i>slot</i>	14
Duração do <i>slot</i>	62,5 μ s ou 0,0625 ms
Duração de um símbolo	4,46 μ s

Fonte: criada pelo autor.

3.1.6 Tempo de Coerência

O tempo de coerência T_c de um canal expressa o quão rápido o canal varia no tempo, de forma que quanto menor o tempo de coerência, mais rápidas são as flutuações do canal. Como consequência, existe uma relação entre tempo de coerência T_c , correlação temporal ρ e velocidade do MT. O tempo de coerência pode ser aproximadamente calculado pelo inverso do espalhamento Doppler. Resultados clássicos (GOLDSMITH, 2005), propostos para padrões de radiação omnidirecionais, mencionam que o espalhamento Doppler aumenta de forma proporcional ao aumento da frequência da portadora f_c . Isso implica que redes móveis operando na faixa de frequência milimétrica podem apresentar uma queda no tempo de coerência de até 30 vezes em relação às redes de 2 GHz. Como consequência, se o tempo de coerência chegar a ser menor que o tempo de duração de símbolo, o canal será seletivo no tempo. O tempo de coerência tem relação diretamente inversa com a velocidade máxima do MT v_{MT} que, para um coeficiente de correlação temporal de 0.5, T_c pode ser dado por (DU; SWAMY, 2010):

$$T_c = \frac{9}{16\pi v_{MT}}. \quad (3.18)$$

Pode-se citar também dois modelos clássicos de coeficiente de correlação temporal para uma frequência máxima Doppler $f_D = f_c v_{MT}/c$, em que c é a velocidade da luz, e um período T (GOLDSMITH, 2005):

$$\begin{aligned} \text{Guassiano: } & e^{-(\pi f_D T)^2} \\ \text{Espalhamento uniforme: } & J_0(2\pi f_D T) \end{aligned} \tag{3.19}$$

em que $J_0(x)$ é a função de Bessel de ordem zero do primeiro tipo.

Porém, novos trabalhos (CHIZHIK, 2004), (VA *et al.*, 2017) defendem que esses modelos clássicos apresentados acima, entre outros, não são suficientemente precisos para sistemas mmWave de feixes estreitos, e que a recepção direcionada pode aumentar o tempo de coerência do canal. Em (VA *et al.*, 2017) é incorporado o efeito da largura do feixe na mitigação do espalhamento Doppler e no aumento da susceptibilidade ao erro de alinhamento. Neste trabalho é adotada a relação de T_c com ρ e v_{MT} desenvolvida em (VA *et al.*, 2017). Para uma estimativa do T_c mínimo, considerando desvanecimento rápido e uma largura de feixe Φ_L em radianos, para NLOS e direções de feixes não paralelas à direção da trajetória do MT, é dado por:

$$\begin{aligned} T_c(\Phi_L) &= \frac{1}{2\pi f_D} \sqrt{-2\Phi_L^{-2} \log \rho - (\log \rho)^2} \\ \text{tal que } & f_D = f_c v_{MT}/c. \end{aligned} \tag{3.20}$$

O coeficiente de correlação temporal pode ser calculado pela inversão da Equação (3.20):

$$\rho(T_c) = \exp \left[\frac{-1 + \sqrt{1 - (2\pi T_c f_D \Phi_L^2)^2}}{\Phi_L^2} \right]. \tag{3.21}$$

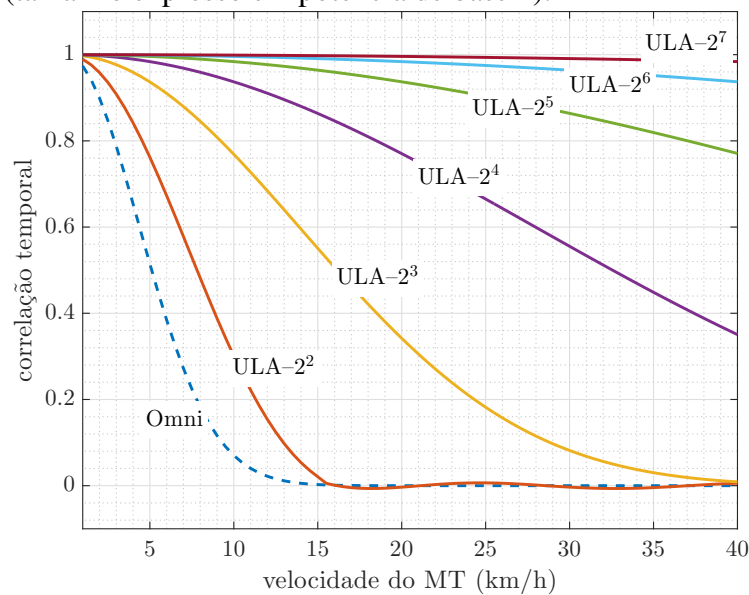
A Equação (3.21) é obtida pelo desacoplamento do erro de alinhamento devido ao movimento do MT com o efeito do espalhamento Doppler.

Se o alinhamento de feixe do *beamtracking* for completamente executado dentro do tempo de coerência, pode considerar-se que os melhores feixes de transmissão e recepção sempre serão escolhidos. Em harmônia com o tempo de *frame* do 3GPP 5G NR e a duração de um treinamento completo que considera um símbolo por par de feixes, neste trabalho, o tempo de coerência é fixado em 2 ms (duração de dois *subframes*). Então, para $T_c = 2$ ms e $f_c = 28$ GHz,

é analisada a influência da largura do feixe sobre o coeficiente de correlação temporal, em comparação com o modelo Gaussiano da Equação (3.19) para padrão omnidirecional.

Na Figura 13 é apresentada a resposta do coeficiente de correlação temporal em relação à velocidade do MT utilizando a Equação (3.19) e a Equação (3.21) para diferentes tamanhos de arranjo ULA. A largura de feixe foi calculada utilizando a Equação (2.11). De acordo com a Figura 13, nota-se que quanto mais estreito é o feixe (quanto maior o número de antenas), maior é o coeficiente de correlação temporal, enquanto que para feixes largos, a curva de correlação se aproxima do modelo Gaussiano de padrão omnidirecional. A largura de feixe pode definir a faixa de variação de AoAs dos multipercursos, tal que quanto menor for a largura de feixe, mais estreita será essa faixa. Por sua vez, cada AoA pode ser mapeado a uma frequência de deslocamento Doppler, o que faz com que o deslocamento Doppler seja limitado a uma faixa de frequência devido à recepção direcionada. Como conclusão, feixes estreitos influenciam fortemente no desempenho dos sistemas MIMO-mmWave *beamforming*, enquanto que, para feixes muito largos, o efeito Doppler devido aos multipercursos é um fator limitante de desempenho (VA *et al.*, 2017).

Figura 13 – Influência da largura de feixe no coeficiente de correlação temporal. A curva tracejada representa modelo Gaussiano da Equação (3.19), enquanto que as curvas de linha cheia representam a Equação (3.21) para diferentes tamanhos de arranjo ULA (tamanho expresso em potência de base 2).



Fonte: criada pelo autor.

3.2 Estimação de Canal baseada em Mínimos Quadrados (LS)

A estimativa do canal \mathbf{H}_k na Equação (3.16) pode ser obtida diretamente por mínimos quadrados (LS, do inglês *least squares*). Considere a identidade algébrica $\text{vec}(\mathbf{ABC}) = (\mathbf{C}^T \otimes \mathbf{A}) \cdot \text{vec}(\mathbf{B})$, em que \otimes representa o produto de Kronecker. Podemos reescrever a Equação (3.16) como:

$$\begin{aligned} \mathbf{y}_k &= (\mathbf{F}^T \otimes \mathbf{W}^H) \cdot \text{vec}(\mathbf{H}_k) + \text{vec}(\mathbf{W}^H \mathbf{V}_k) \\ &= \mathbf{Q} \cdot \mathbf{h}_k + \text{vec}(\mathbf{W}^H \mathbf{V}_k) \end{aligned} \quad (3.22)$$

tal que $\mathbf{Q} = (\mathbf{F}_{RF} \mathbf{F}_{BB})^T \otimes (\mathbf{W}_{RF} \mathbf{W}_{BB})^H \in \mathbb{C}^{N_{sr}^2 \times N_r N_t}$ para o espaço híbrido completo ou $\mathbf{Q} = \mathbf{F}_{RF}^T \otimes \mathbf{W}_{RF}^H \in \mathbb{C}^{N_{RF,r} N_{RF,t} \times N_r N_t}$ para o subespaço analógico, e $\mathbf{h}_k = \text{vec}(\mathbf{H}_k)$. Aplicando LS, temos que:

$$\mathbf{h}_k \approx (\mathbf{Q}^H \mathbf{Q})^{-1} \mathbf{Q}^H \mathbf{y}_k. \quad (3.23)$$

No subespaço analógico, se \mathbf{F}_{RF} e \mathbf{W}_{RF} são matrizes unitárias (*codewords* de um *codebook* DFT), então \mathbf{Q} também é unitária¹, sendo válida a relação $(\mathbf{Q}^H \mathbf{Q})^{-1} = \mathbf{I}_{N_r N_t}$. Para \mathbf{F} e \mathbf{W} não unitárias, $\mathbf{Q}^H \mathbf{Q}^{-1}$ possuirá complexidade assintótica² $\mathcal{O}((N_r N_t)^3)$ em relação às operações em ponto flutuante (FLOP, do inglês *FLoating-point OPeration*), que domina a complexidade do algoritmo. Fazendo $N_{RF,t} = N_f$, $N_{RF,r} = N_w$ e $N_w N_f \geq N_r N_t$, a complexidade assintótica é $\mathcal{O}((N_r N_t)^2 N_w N_f)$. A operação pode requerer um grande esforço computacional devido às dimensões que um sistema MIMO massivo pode ter. Além disso, o método LS não é adequado em processos estocásticos. É possível aplicar técnicas de amostragem compressiva (CS, do inglês *compressive sensing*) para reduzir a complexidade e melhorar o desempenho (LEE *et al.*, 2014). Isso se deve à propriedade SVD na Equação (3.3).

Como feito em (LEE *et al.*, 2014), uma vez que os ângulos do canal são desconhecidos pelo sistema de *beamtracking*, as matrizes \mathbf{A}_t e \mathbf{A}_r devem ser montadas sobre um *grid* de ângulos discretos, que é uma aproximação do domínio angular do canal. Assim, considere o *grid* uniforme $\Phi_G = \{\phi_g \in [0, \pi) : g = 1, 2, \dots, G\}$, em que G é o tamanho do *grid* que define a resolução. Para uma aproximação precisa, faz-se necessário que $G \gg L$. Então, chamamos de $\bar{\mathbf{A}}_t \in \mathbb{C}^{N_t \times G}$ e $\bar{\mathbf{A}}_r \in \mathbb{C}^{N_r \times G}$ as matrizes \mathbf{A}_t e \mathbf{A}_r montadas sobre o *grid* Φ_G . Podemos aproximar

¹ Se \mathbf{A} e \mathbf{B} são matrizes unitárias, então: $(\mathbf{A} \otimes \mathbf{B})^{-1} = \mathbf{A}^{-1} \otimes \mathbf{B}^{-1} = \mathbf{A}^H \otimes \mathbf{B}^H = (\mathbf{A} \otimes \mathbf{B})^H$.

² considerando inversão por eliminação de Gauss–Jordan.

a matriz \mathbf{H} como:

$$\mathbf{H} \cong \bar{\mathbf{A}}_r \bar{\mathbf{H}}_a \bar{\mathbf{A}}_t^H \quad (3.24)$$

em que $\bar{\mathbf{H}}_a \in \mathbb{C}^{G \times G}$ é uma matriz L -esparsa (L elementos não-nulos). Então, a Equação (3.22) pode ser reescrita como:

$$\begin{aligned} \mathbf{y} &\cong (\mathbf{F}^T \otimes \mathbf{W}^H) \cdot (\bar{\mathbf{A}}_t^* \otimes \bar{\mathbf{A}}_r) \cdot \text{vec}(\bar{\mathbf{H}}_a) + \text{vec}(\mathbf{W}^H \mathbf{V}_k) \\ &= \bar{\mathbf{Q}} \cdot \bar{\mathbf{h}}_a + \text{vec}(\mathbf{W}^H \mathbf{V}_k) \end{aligned} \quad (3.25)$$

em que $\bar{\mathbf{Q}} = (\bar{\mathbf{A}}_t^H (\mathbf{F}_{RF} \mathbf{F}_{BB}))^T \otimes ((\mathbf{W}_{RF} \mathbf{W}_{BB})^H \bar{\mathbf{A}}_r) \in \mathbb{C}^{N_s^2 \times G^2}$ para o espaço híbrido completo e $\bar{\mathbf{Q}} = (\bar{\mathbf{A}}_t^H \mathbf{F}_{RF})^T \otimes (\mathbf{W}_{RF}^H \bar{\mathbf{A}}_r) \in \mathbb{C}^{N_f N_w \times G^2}$ para o subespaço analógico, e $\bar{\mathbf{h}}_a = \text{vec}(\bar{\mathbf{H}}_a)$. O vetor $\bar{\mathbf{h}}_a$ pode ser recuperado com técnicas de recuperação de sinais esparsos, como OMP (do inglês *orthogonal matching pursuit*) (TROPP; GILBERT, 2007), tal que $\bar{\mathbf{Q}}$ pode ser visto como uma matriz de medição do sinal $\bar{\mathbf{h}}_a$, sendo \mathbf{y} o vetor de observação, ou como uma matriz-dicionário de *codewords* de tamanho $D = G^2$. Trata-se de um problema de otimização que pode ser formulado como:

$$\begin{aligned} \underset{\bar{\mathbf{h}}_a}{\text{minimize}} \quad & \|\mathbf{y} - \bar{\mathbf{Q}} \bar{\mathbf{h}}_a\|_2 \\ \text{sujeito a} \quad & \|\bar{\mathbf{h}}_a\|_0 = L. \end{aligned} \quad (3.26)$$

O OMP que resolve o problema (3.26) é descrito no Algoritmo 1. Em cada iteração n , é determinada a coluna i de $\bar{\mathbf{Q}}$ que maximiza o módulo da correlação com um vetor de resíduo \mathbf{r} . Esse etapa possui complexidade assintótica $\mathcal{O}(N_L N_w N_f G^2)$ em relação a FLOPs, que domina a complexidade do algoritmo. As colunas encontradas são colecionadas em um conjunto suporte Ω . Então, para cada interação n , é determinado o canal \mathbf{h} que minimize o erro de aproximação da Equação (3.25) em relação às colunas de $\bar{\mathbf{Q}}$ indicadas pelo conjunto Ω que pode ser resolvido via LS com complexidade $\mathcal{O}(N_L^2 N_w N_f)$, que é bem menor que a complexidade $\mathcal{O}((N_r N_t)^2 N_w N_f)$ obtida antes. O resíduo é, então, atualizado. O Algoritmo 1 é executado dentro de um laço de comprimento $N_L \geq L$. O algoritmo retorna a matriz esparsa estimada $\hat{\mathbf{H}}_a$, que é aproximadamente L -esparsa. A estimativa do canal $\hat{\mathbf{H}}$ é, então, obtida pelo produto $\bar{\mathbf{A}}_r \hat{\mathbf{H}}_a \bar{\mathbf{A}}_t^H$. Será mostrado no Capítulo 4 que OMP apresenta desempenho melhor ou no mínimo igual ao LS.

Algoritmo 1: Estimativa de canal MIMO-mmWave por OMP^(*)

Inicialização: $\Omega \leftarrow \emptyset, \mathbf{r} \leftarrow \mathbf{y}$

Entrada: \mathbf{y}

Saída: $\hat{\mathbf{H}}_a$

Variáveis Estáticas: $\bar{\mathbf{Q}}, \delta, i = \{1, 2, \dots, G^2\}$

início

enquanto $n \leq N_L$ **fazer**

$$i_{opt} \leftarrow \arg \max_i |\bar{\mathbf{Q}}^H(i)\mathbf{r}|$$

$$\Omega \leftarrow \Omega \cup \{i_{opt}\}$$

$$\mathbf{h}_{opt} \leftarrow \arg \min_{\mathbf{h}} \|\mathbf{y} - \bar{\mathbf{Q}}(\Omega)\mathbf{h}\|_2^{(**)}$$

$$\mathbf{r} \leftarrow \mathbf{y} - \bar{\mathbf{Q}}(\Omega)\mathbf{h}_{opt}$$

fim_enquanto

para todo i **fazer**

se $i \in \Omega$ **fazer**

$$\hat{\mathbf{h}}_a(i) \leftarrow \mathbf{h}_{opt}(i)$$

caso contrário fazer

$$\hat{\mathbf{h}}_a(i) \leftarrow 0$$

fim_se

fim_para todo

$$\hat{\mathbf{H}}_a \leftarrow \text{vec}^{-1}(\hat{\mathbf{h}}_a)^{(***)}$$

fim

*algoritmo proposto em (LEE et al., 2014).

**a solução pode ser obtida por LS: $(\bar{\mathbf{Q}}^H(\Omega)\bar{\mathbf{Q}}(\Omega))^{-1}\bar{\mathbf{Q}}^H(\Omega)\mathbf{y}$.

*** vec^{-1} : matriz obtida da inversão do processo de vetorização.

3.2.1 Simulações para o Método baseado em OMP

Considere uma estimação de canal realizada no domínio puramente analógico. O parâmetro comprimento do laço N_L é determinante no desempenho do algoritmo OMP. Teoricamente, conhecendo a esparsidade do canal L , fazer $N_L = L$ resulta em um bom desempenho. Porém, para o sistema em questão neste trabalho, que apresenta dimensão no modelo de aquisição de $N_f N_w$, o OMP apresentou um valor de N_L ótimo maior que L , cuja distância entre esses valores depende da resolução do *grid* (G), da SNR e do tamanho do arranjo.

O ambiente de simulação foi desenvolvido utilizando os modelos e parâmetros do sistema descritos neste capítulo. Os principais parâmetros estão resumidos na Tabela 2. Foram utilizados dois tipos de arranjos: um arranjo ULA de 16 e um outro UPA de 4×4 . Para uma análise primordial, os canais foram gerados utilizando a Equação (3.3). Os ângulos iniciais foram gerados com a distribuição uniforme $\mathcal{U}(-\frac{\pi}{2}, \frac{\pi}{2})$ e os coeficientes do canal com a distribuição Gaussiana complexa circular simétrica $\mathcal{CN}(0, \frac{N_r N_t}{L})$, e a evolução do canal no tempo foi gerada pela Equação (3.10). Para fins de simulação, define-se um bloco como um período de tempo em que não há variação de canal (tempo de coerência). É considerado que dentro de um bloco é realizada uma varredura completa dos pares de feixes, de forma que a incerteza no vetor de observação \mathbf{Y} , Equação (3.16), é devida somente ao ruído de recepção. Como medida de desempenho, foi adotado o erro quadrático médio normalizado (NMSE, do inglês *normalized mean square error*) definido como $\frac{\mathbb{E}(\|\hat{\mathbf{H}} - \mathbf{H}\|_F^2)}{\mathbb{E}(\|\mathbf{H}\|_F^2)}$, em que \mathbf{H} é a matriz verdadeira do canal, $\hat{\mathbf{H}}$ é a estimada e $\|\star\|_F$ é a norma de Frobenius.

Tabela 2 – Principais Parâmetros de simulação para análise de OMP.

Arranjo	ULA-16 e UPA- 4×4
Número de <i>clusters</i>	$L = 4$
Número de iterações	L a 50
<i>Codebook</i>	DFT com $N_{feixes} = N_{ant}$
Laço de Monte Carlo	50
Número de blocos	10

Fonte: criada pelo autor.

A Figura 14 mostra o desempenho do OMP em função da SNR e do número de iterações N_L para um *grid* de 181 pontos, que equivale a um *grid* de resolução de 1° no intervalo de -90° a 90° . Na Figura 14a pode-se observar que para $N_L = 4$ (curva inferior), o OMP não garante um desempenho linearmente crescente com o aumento da SNR. Para encontrar o valor de N_L que garanta máximo desempenho no limite do intervalo de SNR, na Figura 15b foi gerada a curva de NMSE por N_L para a SNR de 25 dB, em que se vê claramente o ponto de máximo desempenho que ocorre em $N_L = 13$. A Figura 15 mostra a influência da resolução do *grid* na determinação desse ponto de máximo, em que se vê uma tendência de redução de N_L à medida que o tamanho do *grid* aumenta, em outras palavras, à medida que a esparsidade da matriz estimada $\hat{\mathbf{H}}$ se aproxima de L . Grandes valores N_L geram matrizes de canal cada vez menos esparsas, aumentando o erro do algoritmo. Porém, dado que o tamanho D do dicionário $\bar{\mathbf{Q}}$ (número de colunas) aumenta com o quadrado do tamanho do *grid*, é desejado que o *grid* seja

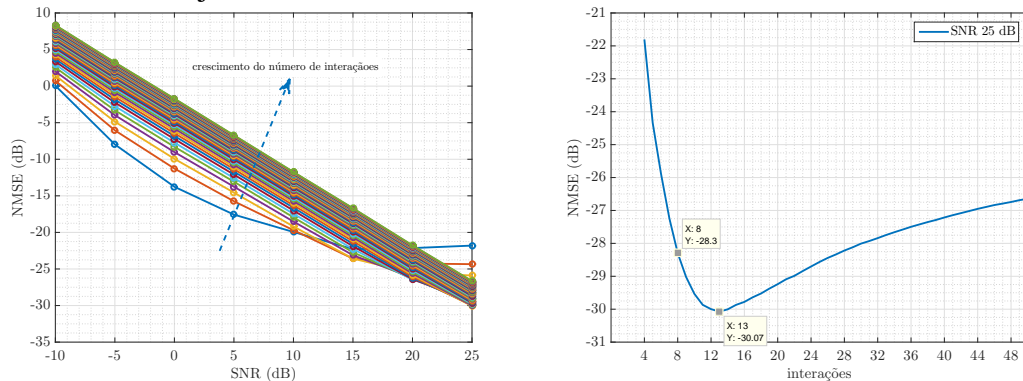
o menor possível. Nesse sentido, se contabilizarmos a complexidade computacional \mathcal{O} pelo produto de N_L com G^2 , montando a Tabela 3 com os resultados obtidos, pode-se concluir que $G = 50$ fornece um bom compromisso entre complexidade e desempenho, enquanto $G = 180$ fornece uma matriz mais esparsa, a custo de uma complexidade seis vezes maior.

Tabela 3 – Tabela de performance do OMP para ULA 16 e SNR de 25 dB.

G	N_L	$\mathcal{O} (\times N_f N_w 10^3)$	NMSE (dB)
20	50	125	-12,9
50	27	67	-27,6
100	16	160	-29,0
180	13	421	-30,0
250	11	687	-30,6

Fonte: criada pelo autor.

Figura 14 – Análise de desempenho do OMP com $G = 181$ para diferentes números de iterações com arranjo ULA 16.

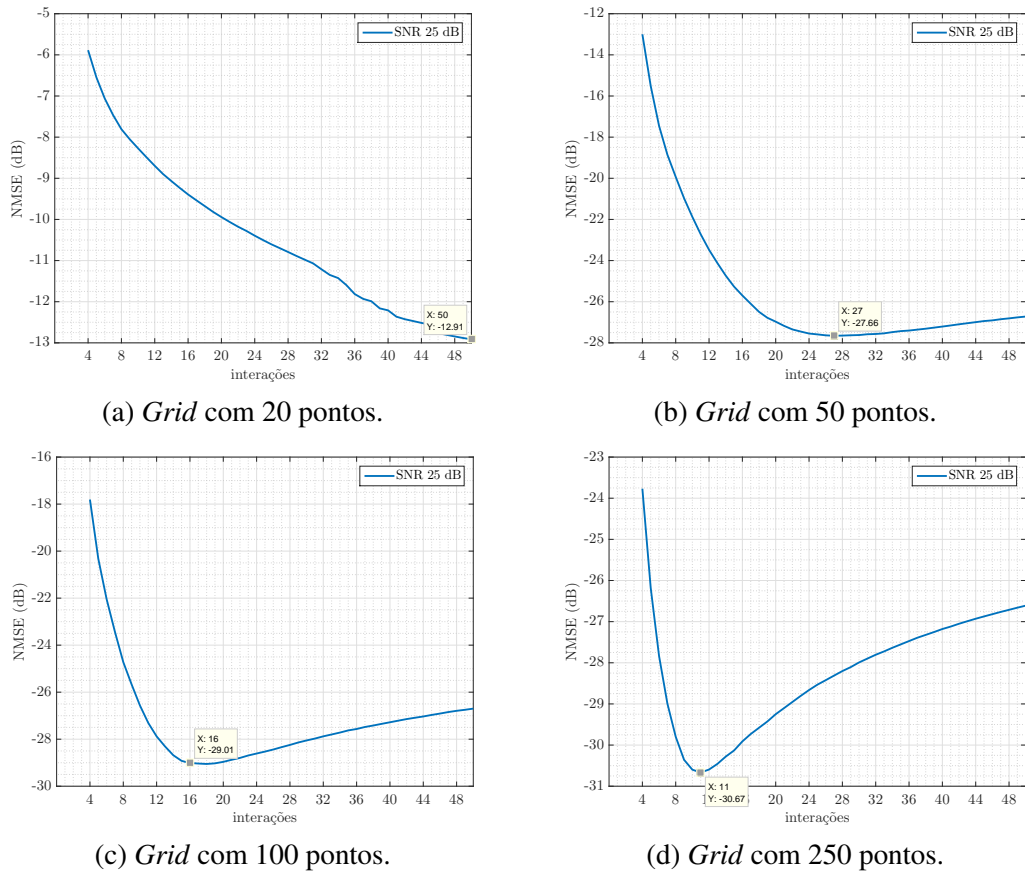


(a) Desempenho do sistema por SNR para 4 a 50 iterações. (b) Desempenho do sistema por número de iterações para SNR de 25 dB.

Fonte: criada pelo autor.

Um outro fator limitante de desempenho é o tamanho do arranjo, pois, como será mostrado no Capítulo 4, a principal desvantagem do algoritmo OMP é que ele requer um *codebook* DFT com $N_{feixes} \geq N_{ant}$, e portanto, o aumento no tamanho do arranjo implica no aumento do número de feixes, que por sua vez implica no aumento da dimensão do dicionário (número de linhas). A Figura 16 mostra o desempenho do sistema em função do número de iterações e do tamanho do arranjo para SNR de 25 dB e $G = 180$. Analisando a malha da Figura 16, nota-se que quanto maior o arranjo, maior a demanda computacional exigida para se alcançar alto desempenho. Também pode-se notar uma instabilidade dos algoritmos para um arranjo de 4

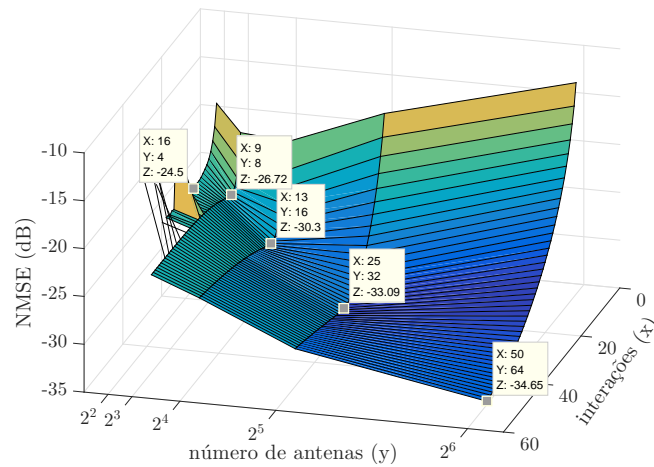
Figura 15 – Análise de desempenho do OMP para diferentes números de iterações com arranjo ULA 16.



Fonte: criada pelo autor.

antenas. Em conclusão, o OMP para grandes arranjos, em regime de alta SNR, requer um grande esforço computacional.

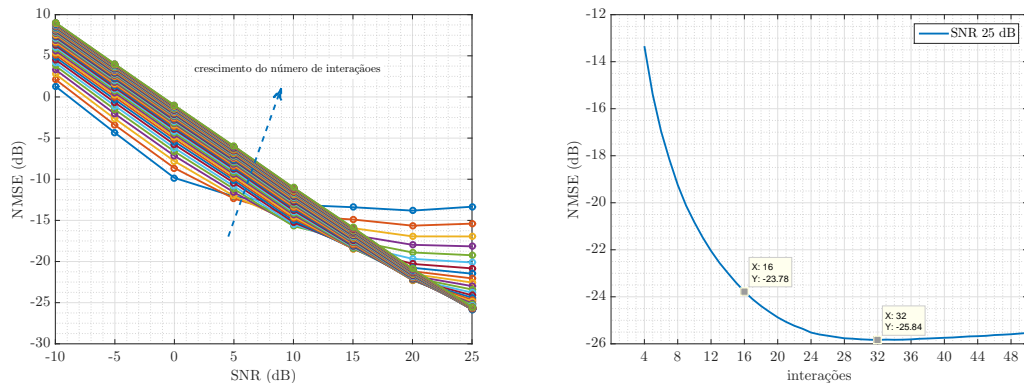
Figura 16 – Desempenho do sistema por número de antenas e iterações para SNR de 25 dB e $G = 180$.



Fonte: criada pelo autor.

Quando se lida com arranjos do tipo ULA, se trabalha somente com a componente azimute do ângulo do SV. Para aplicação do algoritmo OMP, faz-se necessário um *grid* unidimensional. Porém, para arranjos do tipo UPA, trabalha-se com as componentes de elevação e azimute do ângulo do SV, e para aplicação do OMP, faz-se necessário um *grid* bidimensional. O *grid-2D* pode ser obtido pelo produto de Kronecker entre dois *grids-1D*. Se G_v é o tamanho do *grid-1D* de azimute e G_h o tamanho do *grid-1D* de elevação, então o *grid-2D* tem tamanho $G_{2D} = G_h G_v$, e o dicionário tem tamanho $D = (G_h G_v)^2$. Assim, se como no caso ULA, for adotado um *grid-1D* de tamanho $G = 50$ para cada dimensão, então teremos $G_{2D} = 2,5 \text{ k}^3$ e $D = 6,25 \text{ M FLOPs}$. Portanto, para o caso UPA, o OMP demanda uma grande sobrecarga computacional. Na Figura 17, é analisado o desempenho do OMP para um arranjo UPA 4×4 , como um *grid-2D* de 20 pontos por dimensão, para os parâmetros da Tabela 2, em que se vê que o ponto de máximo desempenho (-25 dB) ocorre em $N_L = 35$. Pela Figura 17b, nota-se que foi necessário um *grid* $G_{2D} = 2,5 \text{ k}$ pontos para se alcançar mesmo nível de desempenho com arranjo ULA de *grid* $G = 50$ pontos e $N_L = 27$, para uma SNR de 25 dB , o que possui uma complexidade 76 vezes menor.

Figura 17 – Análise de desempenho do OMP para diferentes números de iterações com arranjo UPA 4×4 e $G = 400$.



(a) Desempenho do sistema por SNR para 4 a 50 iterações. (b) Desempenho do sistema por numero de iterações para SNR de 25 dB .

Fonte: criada pelo autor.

³ múltiplo de unidades quilo, assim como M (Mega) e G (Giga).

4 RASTREAMENTO DE CANAL COM FILTROS DE KALMAN

Neste capítulo será desenvolvida a formulação Bayesiana do problema de rastreamento dos parâmetros do canal MIMO-mmWave, bem como as soluções subótimas do problema baseadas em versões diferentes do filtro de Kalman. Em seguida, as soluções são avaliadas via simulações computacionais.

4.1 Formulação Bayesiana do Problema de Beamtracking

Dado o espaço de parâmetros do canal MIMO-mmWave formado por AoA, AoD e α , definidos para cada caminho dominante c de índices (n, m, l) num *slot* ou bloco de tempo k , tal que $n = 1, 2, \dots, N_r$, $m = 1, 2, \dots, N_t$ e $l = 1, 2, \dots, L$, em que N_r , N_t e L são o número de antenas no receptor, número de antena no transmissor e o número de *clusters*, respectivamente, e organizados em um vetor $\boldsymbol{\chi}_k$, e dada uma sequência \mathbf{Y}_k de símbolos de treinamento recebida num instante ou num bloco k , $\hat{\boldsymbol{\chi}}_k$ pode ser estimada pelo método do mínimo erro quadrático médio (MMSE, do inglês *minimum mean square error*) (RISTIC *et al.*, 2003):

$$\hat{\boldsymbol{\chi}}_k = \mathbb{E}[\boldsymbol{\chi}_k | \mathbf{Y}_k] \quad (4.1)$$

ou pela probabilidade máxima *a posteriori* (MAP, do inglês *maximum a posteriori*):

$$\hat{\boldsymbol{\chi}}_k = \arg \max_{\boldsymbol{\chi}_k} Pr(\boldsymbol{\chi}_k | \mathbf{Y}_k) \quad (4.2)$$

Conhecendo a probabilidade *a posteriori* $Pr(\mathbf{Y}_k | \boldsymbol{\chi}_k)$, a probabilidade $Pr(\boldsymbol{\chi}_k | \mathbf{Y}_k)$ pode ser formulada por meio do Teorema de Bayes por:

$$Pr(\boldsymbol{\chi}_k | \mathbf{Y}_k) = \frac{Pr(\mathbf{Y}_k | \boldsymbol{\chi}_k) Pr(\boldsymbol{\chi}_k | \mathbf{Y}_{k-1})}{Pr(\mathbf{Y}_k | \mathbf{Y}_{k-1})} \quad (4.3)$$

em que $Pr(\mathbf{Y}_k | \mathbf{Y}_{k-1})$ é uma constante de normalização e $Pr(\boldsymbol{\chi}_k | \mathbf{Y}_{k-1})$ é dada pela equação de Chapman–Kolmogorov:

$$Pr(\boldsymbol{\chi}_k | \mathbf{Y}_{k-1}) = \int Pr(\boldsymbol{\chi}_k | \boldsymbol{\chi}_{k-1}) Pr(\boldsymbol{\chi}_{k-1} | \mathbf{Y}_{k-1}) d\boldsymbol{\chi}_{k-1} \quad (4.4)$$

A solução recursiva pelas Equações (4.3) e (4.4) é apenas conceitual e não possui solução analítica para o caso geral. Para o caso particular em que os modelos do sistema são

equações estocásticas lineares Gaussianas, o KF clássico fornece o estimador ótimo (RISTIC *et al.*, 2003). Se os modelos são não-lineares e Gaussianos, variações do KF, como UKF e EnKF, fornecem um estimador subótimo (RISTIC *et al.*, 2003). Para o caso geral, sem nenhuma restrição, o Filtro de Partículas fornece um estimador subótimo a custo de um grande esforço computacional (RISTIC *et al.*, 2003). Os KFs são de fácil implementação, possuem custo computacional menor e não sofrem com problema da “maldição da dimensão”(cálculos de probabilidade de vetores de alta dimensão geram espaço de probabilidade quase nulo, fazendo com que as partículas entrem em colapso) que o Filtro de Partículas está sujeito (??).

4.2 Filtros de Rastreamento

O modelo de *beamtracking* baseado em KF, proposto em (ZHANG *et al.*, 2015), é interpretado em três blocos como se segue:

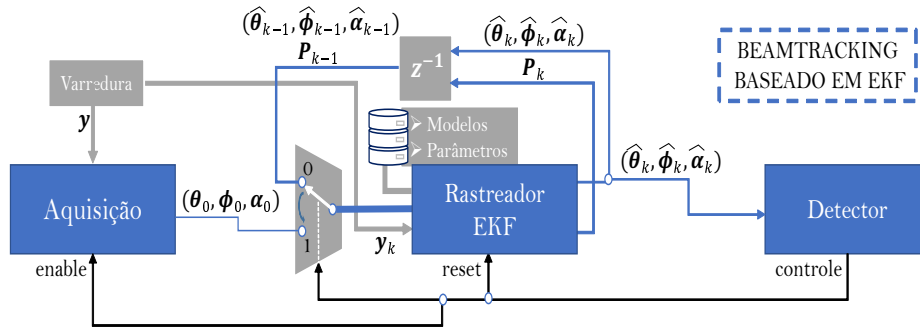
- **Bloco de aquisição do canal:** é realizada uma estimação completa e precisa do canal, normalmente de custo computacional elevado. Possui como saída os parâmetros do canal.
- **Bloco de rastreamento com KF:** rastreia as variações dos parâmetros do canal sem afetar a taxa de transmissão efetiva, utilizando como conhecimento *a priori* os parâmetros passados pelo bloco de aquisição. Possui como saída as estimativas dos parâmetros do canal atual.
- **Bloco de detecção de mudanças abruptas no canal:** utiliza a saída do KF e o vetor de observação atual para detectar mudanças abruptas no canal. Possui como saída um sinal de controle que ativa o bloco de aquisição e reinicializa o KF quando detecta uma mudança abrupta, e que desativa o bloco de aquisição e conecta a realimentação do KF caso contrário.

O diagrama de bloco do sistema citado acima está ilustrado nas Figuras 18 e 19. Este trabalho se restringe ao bloco de rastreamento de canal. O modelo é implementado utilizando quatro tipos de KFs: EKF, UKF, EnKF e DEnKF.

4.2.1 EKF

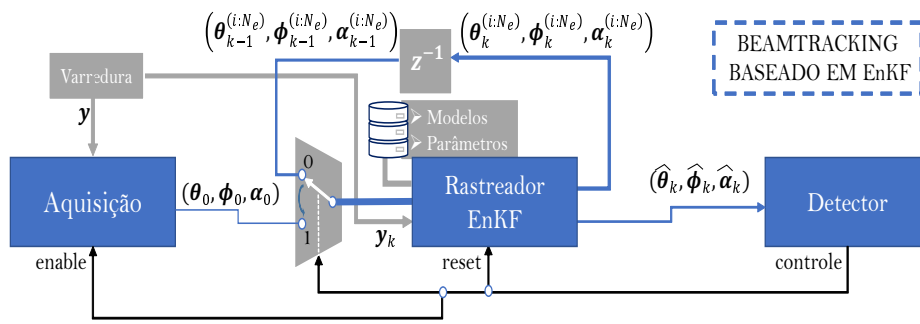
O KF clássico é a solução ótima quando os modelos são lineares e Gaussianos. Para filtragem não-linear, é possível linearizar os modelos para aplicação direta do KF. Tal versão

Figura 18 – Esquema de estimação de canal com EKF.



Fonte: criada pelo autor. Baseado no algoritmo de (ZHANG *et al.*, 2015).

Figura 19 – Esquema de estimação de canal com EnKF.



Fonte: criada pelo autor.

do KF é subótima e conhecida como EKF (do inglês *extended Kalman filter*). O EKF trabalha precisamente com muitos modelos não lineares e é de fácil implementação, porém, requer extensos cálculos de derivadas.

Considere um sistema dinâmico não-linear discreto no tempo, regido por:

$$\begin{aligned} \boldsymbol{\chi}_{k+1} &= f(\boldsymbol{\chi}_k) + \mathbf{u}_k \\ \mathbf{y}_k &= h(\boldsymbol{\chi}_k) + \mathbf{v}_k \end{aligned} \quad (4.5)$$

em que $f(\cdot)$ e $h(\cdot)$ são as funções de evolução e medição, respectivamente, $\boldsymbol{\chi}_k \in \mathbb{R}^N$, $\mathbf{y}_k \in \mathbb{R}^M$, $\mathbf{u}_k \sim \mathcal{N}(\mathbf{0}, \mathbf{Q}_k)$ e $\mathbf{v}_k \sim \mathcal{N}(\mathbf{0}, \mathbf{R}_k)$. Considere que $\mathbf{A}_k \in \mathbb{R}^{N \times N}$ e $\mathbf{C}_k \in \mathbb{R}^{M \times N}$ são as matrizes Jacobianas do modelo de estado e de medição, respectivamente. O EKF procura o estado estimado $\hat{\boldsymbol{\chi}}_k$ de $\boldsymbol{\chi}_k$ com base nas medições \mathbf{y}_k por MMSE linear, isto é, procura minimizar

$\text{tr}(E[\mathbf{e}_k \mathbf{e}_k^T])$, em que $\mathbf{e}_k = \boldsymbol{\chi}_k - \hat{\boldsymbol{\chi}}_k$. Define-se como covariância do erro de predição as matrizes:

$$\begin{aligned} \mathbf{P}_{x,k|k-1} &= E[\mathbf{e}_{k|k-1}(\mathbf{e}_{k|k-1})^T] \quad (\text{erro de predição do estado}), \\ \mathbf{P}_{xy,k|k-1} &= E[\mathbf{e}_{k|k-1}(\mathbf{y}_k - \mathbf{y}_{k|k-1})^T] = \mathbf{P}_{x,k|k-1} \mathbf{C}_k^T, \\ \mathbf{P}_{yy,k|k-1} &= E[(\mathbf{y}_k - \mathbf{y}_{k|k-1})(\mathbf{y}_k - \mathbf{y}_{k|k-1})^T] = \mathbf{C}_k \mathbf{P}_{x,k|k-1} \mathbf{C}_k^T + \mathbf{R}_k, \end{aligned} \quad (4.6)$$

em que $\mathbf{y}_{k|k-1} = \mathbf{C}_k \boldsymbol{\chi}_{k|k-1}$ e $\mathbf{e}_{k|k-1} = \boldsymbol{\chi}_k - \boldsymbol{\chi}_{k|k-1}$. Para o caso não-linear, a matriz $\mathbf{C}_k \in \mathbb{R}^{M \times N}$ é a matriz Jacobiana da função de medição $h(\cdot)$ no ponto $\hat{\boldsymbol{\chi}}_k$. O EKF trabalha em duas etapas. (i) A etapa de predição, em que as variáveis propagantes são atualizadas com base no modelo de evolução e em seus valores estimados:

$$\begin{aligned} \boldsymbol{\chi}_{k|k-1} &= f(\hat{\boldsymbol{\chi}}_{k-1|k-1}), \\ \mathbf{P}_{x,k|k-1} &= \mathbf{A}_{k-1} \mathbf{P}_{x,k-1|k-1} \mathbf{A}_{k-1}^T + \mathbf{Q}_{k-1}, \end{aligned} \quad (4.7)$$

em que $\mathbf{A}_{k-1} \in \mathbb{R}^{N \times N}$ é a matriz Jacobiana da função de evolução $f(\cdot)$ no ponto $\hat{\boldsymbol{\chi}}_{k-1|k-1}$. (ii) A etapa de análise, em que as variáveis propagantes são estimadas com base no vetor de observação \mathbf{y}_k :

$$\begin{aligned} \mathbf{K}_k &= \mathbf{P}_{x,k|k-1} \mathbf{C}_k^T (\mathbf{C}_k \mathbf{P}_{x,k|k-1} \mathbf{C}_k^T + \mathbf{R}_k)^{-1}, \\ \hat{\boldsymbol{\chi}}_k &= \boldsymbol{\chi}_{k|k-1} + \mathbf{K}_k (\mathbf{y}_k - h(\boldsymbol{\chi}_{k|k-1})), \\ \hat{\mathbf{P}}_{x,k|k} &= (\mathbf{I}_N - \mathbf{K}_k \mathbf{C}_k) \mathbf{P}_{x,k|k-1}. \end{aligned} \quad (4.8)$$

Notemos que $\mathbf{g}(\boldsymbol{\chi}_k)$ no modelo de medição (3.17) é não-linear. Para implementação do EKF é necessário linearizar tal modelo. Faz-se, então, necessário calcular a seguinte matriz Jacobiana:

$$\mathbf{C} = \begin{bmatrix} \frac{\partial g_{1,1}(\hat{\boldsymbol{\chi}})}{\partial \chi_1} & \frac{\partial g_{1,1}(\hat{\boldsymbol{\chi}})}{\partial \chi_2} & \dots & \frac{\partial g_{1,1}(\hat{\boldsymbol{\chi}})}{\partial \chi_{D_L}} \\ \frac{\partial g_{2,1}(\hat{\boldsymbol{\chi}})}{\partial \chi_1} & \frac{\partial g_{2,1}(\hat{\boldsymbol{\chi}})}{\partial \chi_2} & \dots & \frac{\partial g_{2,1}(\hat{\boldsymbol{\chi}})}{\partial \chi_{D_L}} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial g_{N_w,1}(\hat{\boldsymbol{\chi}})}{\partial \chi_1} & \frac{\partial g_{N_w,1}(\hat{\boldsymbol{\chi}})}{\partial \chi_2} & \dots & \frac{\partial g_{N_w,1}(\hat{\boldsymbol{\chi}})}{\partial \chi_{D_L}} \\ \frac{\partial g_{1,2}(\hat{\boldsymbol{\chi}})}{\partial \chi_1} & \frac{\partial g_{1,2}(\hat{\boldsymbol{\chi}})}{\partial \chi_2} & \dots & \frac{\partial g_{1,2}(\hat{\boldsymbol{\chi}})}{\partial \chi_{D_L}} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial g_{q,p}(\hat{\boldsymbol{\chi}})}{\partial \chi_1} & \frac{\partial g_{q,p}(\hat{\boldsymbol{\chi}})}{\partial \chi_2} & \dots & \frac{\partial g_{q,p}(\hat{\boldsymbol{\chi}})}{\partial \chi_{D_L}} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial g_{N_w,N_f}(\hat{\boldsymbol{\chi}})}{\partial \chi_1} & \frac{\partial g_{N_w,N_f}(\hat{\boldsymbol{\chi}})}{\partial \chi_2} & \dots & \frac{\partial g_{N_w,N_f}(\hat{\boldsymbol{\chi}})}{\partial \chi_{D_L}} \end{bmatrix}, \quad (4.9)$$

em que

$$g_{q,p}(\hat{\boldsymbol{\chi}}) = \mathbf{w}_q^H \mathbf{H}(\hat{\boldsymbol{\chi}}) \mathbf{f}_p, \quad (4.10)$$

e tal que $\mathbf{C} \in \mathbb{C}^{N_w N_f \times D_L}$. As derivadas em relações as variáveis θ , ϕ e α são:

$$\begin{aligned} \frac{\partial g_{q,p}(\hat{\boldsymbol{\chi}})}{\partial \phi_{D,l}} &= \alpha_l \mathbf{w}_q^H \mathbf{a}_r(\theta_{A,l}, \phi_{A,l}) \left[\mathbf{j} \mathbf{a}_t(\theta_{D,l}, \phi_{D,l}) \circ \left(\frac{\partial \mathbf{k}(\theta_{D,l}, \phi_{D,l})}{\partial \phi_{D,l}} \mathbf{R}_t \right)^T \right]^H \mathbf{f}_p, \\ \frac{\partial g_{q,p}(\hat{\boldsymbol{\chi}})}{\partial \phi_{A,l}} &= \alpha_l \mathbf{w}_q^H \left[\mathbf{j} \mathbf{a}_r(\theta_{A,l}, \phi_{A,l}) \circ \left(\frac{\partial \mathbf{k}(\theta_{A,l}, \phi_{A,l})}{\partial \phi_{A,l}} \mathbf{R}_r \right)^T \right] \mathbf{a}_t(\theta_{D,l}, \phi_{D,l})^H \mathbf{f}_p, \\ \frac{\partial g_{q,p}(\hat{\boldsymbol{\chi}})}{\partial \theta_{D,l}} &= \alpha_l \mathbf{w}_q^H \mathbf{a}_r(\theta_{A,l}, \phi_{A,l}) \left[\mathbf{j} \mathbf{a}_t(\theta_{D,l}, \phi_{D,l}) \circ \left(\frac{\partial \mathbf{k}(\theta_{D,l}, \phi_{D,l})}{\partial \theta_{D,l}} \mathbf{R}_t \right)^T \right]^H \mathbf{f}_p, \\ \frac{\partial g_{q,p}(\hat{\boldsymbol{\chi}})}{\partial \theta_{A,l}} &= \alpha_l \mathbf{w}_q^H \left[\mathbf{j} \mathbf{a}_r(\theta_{A,l}, \phi_{A,l}) \circ \left(\frac{\partial \mathbf{k}(\theta_{A,l}, \phi_{A,l})}{\partial \theta_{A,l}} \mathbf{R}_r \right)^T \right] \mathbf{a}_t(\theta_{D,l}, \phi_{D,l})^H \mathbf{f}_p, \\ \frac{\partial g_{q,p}(\hat{\boldsymbol{\chi}})}{\partial \alpha_l^{real}} &= \mathbf{w}_q^H \mathbf{a}_r(\theta_{A,l}, \phi_{A,l}) \mathbf{a}_t(\theta_{D,l}, \phi_{D,l})^H \mathbf{f}_p \quad \text{e} \\ \frac{\partial g_{q,p}(\hat{\boldsymbol{\chi}})}{\partial \alpha_l^{img}} &= j \mathbf{w}_q^H \mathbf{a}_r(\theta_{A,l}, \phi_{A,l}) \mathbf{a}_t(\theta_{D,l}, \phi_{D,l})^H \mathbf{f}_p, \end{aligned} \quad (4.11)$$

em que \mathbf{k} é o vetor de onda dado pela Equação (2.3), $\mathbf{R} \in \mathbb{R}^{3 \times N_{ant}}$ é uma matriz de coordenadas dos elementos de antena do arranjo e (\circ) é o produto de Hadamard. Para que o EKF não gere valores de estado complexos, utiliza-se a matriz $\mathbf{C}_{(R|I)} = \begin{bmatrix} \mathbf{R}(\mathbf{C}) \\ \mathbf{I}(\mathbf{C}) \end{bmatrix}$.

Aplicando o EKF ao problema de estimação de canal descrito no Capítulo 3, temos as seguintes correspondências e considerações:

- $\boldsymbol{\chi}$ é o vetor de estado, de dimensão D_L , constituído das componentes de azimuth e elevação dos AoDs e AoAs, e das partes reais e imaginárias dos coeficiente do canal, ambos definidos para cada *cluster*;
- o modelo de evolução é linear e constante, dado por $\mathbf{A} = \text{diag}([\mathbf{1}_{1 \times 4L}, \rho \mathbf{1}_{1 \times 2L}])$ para arranjo UPA ou $\mathbf{A} = \text{diag}([\mathbf{1}_{1 \times 2L}, \rho \mathbf{1}_{1 \times 2L}])$ para arranjo ULA;
- as matrizes de covariância $\mathbf{Q} \in \mathbb{R}^{D_L \times D_L}$ e $\mathbf{R} \in \mathbb{R}^{2N_f N_w \times 2N_f N_w}$ do modelo de evolução e de medição, respectivamente, são constantes e diagonais (amostras descorrelacionadas);
- o modelo de medição é não-linear e variante no tempo; a matriz do modelo $\mathbf{C}_k \in \mathbb{R}^{2N_f N_w \times D_L}$ é dada pela Equação (4.9) e a função do modelo dada pela Equação (4.10);

- o vetor de observação $\mathbf{y} \in \mathbb{R}^{2N_f N_w}$ (a variável externa) é simulado pela Equação (3.17).

O Algoritmo 2 estima recursivamente por EKF os parâmetros do canal $\boldsymbol{\chi}_k$ em cada bloco baseado na estimativa anterior $\hat{\boldsymbol{\chi}}_{k-1|k-1}$ e nas observações atuais \mathbf{y}_k . Requer armazenamento das variáveis propagantes $\boldsymbol{\chi} \in \mathbb{R}^{D_L \times 1}$ e $\mathbf{P}_x \in \mathbb{R}^{D_L \times D_L}$. Com base nas operações matriciais do Algoritmo 2, a complexidade assintótica do algoritmo em termos de FLOPs é $\mathcal{O}((N_w N_f)^3)$ se $N_f N_w \geq D_L$ ou $\mathcal{O}(D_L^2 N_w N_f)$ se $N_f N_w < D_L$.

Algoritmo 2: Rastreamento de canal com EKF^(*)

Inicialização: $\hat{\boldsymbol{\chi}}_{0|0} \leftarrow \boldsymbol{\chi}_0, \mathbf{P}_{x,0|0} \leftarrow \mathbf{0},$
Entrada: $\hat{\boldsymbol{\chi}}_{k-1|k-1}, \mathbf{P}_{x,k-1|k-1}, \mathbf{y}_k$
Saída: $\hat{\boldsymbol{\chi}}_k, \mathbf{P}_{x,k|k}$
início
 %PREDIÇÃO:
 $\boldsymbol{\chi}_{k|k-1} \leftarrow \mathbf{A} \hat{\boldsymbol{\chi}}_{k-1|k-1}$
 $\mathbf{P}_{x,k|k-1} \leftarrow \mathbf{A} \mathbf{P}_{x,k-1|k-1} \mathbf{A}^T + \mathbf{Q}$
 %GANHO:
 $\mathbf{K}_k \leftarrow \mathbf{P}_{x,k|k-1} \mathbf{C}_k^T (\mathbf{C}_k \mathbf{P}_{x,k|k-1} \mathbf{C}_k^T + \mathbf{R})^{-1}$
 %ESTIMADOR:
 $\hat{\boldsymbol{\chi}}_{k|k} \leftarrow \boldsymbol{\chi}_{k|k-1} + \mathbf{K}_k (\mathbf{y}_k - \mathbf{g}(\hat{\boldsymbol{\chi}}_{k|k-1}))$
 $\mathbf{P}_{x,k|k} \leftarrow (\mathbf{I}_{D_L} - \mathbf{K}_k \mathbf{C}_k) \mathbf{P}_{x,k|k-1}$
fim

* algoritmo proposto em (ZHANG *et al.*, 2015).

4.2.2 UKF

O KF clássico e o EKF usam transformações lineares dos modelos que sustentam a suficiência do momento de primeira e segunda ordem central como estimadores estatísticos do problema. De fato, se uma distribuição tem média $\bar{\mathbf{x}}$ e covariância \mathbf{P}_x , a distribuição resultante da aplicação de uma transformação linear \mathbf{T} , possui, convenientemente, média $\mathbf{T}\bar{\mathbf{x}}$ e covariância $\mathbf{T}\mathbf{P}_x\mathbf{T}^T$. Contudo, para garantir precisão, sistemas não-lineares de ordem maior requerem linearização de ordem maior. Isso pode ser obtido com um EKF de mais alta ordem, que propaga momentos estatísticos centrais de ordem maior que dois, a custo de um grande esforço computacional (JULIER; UHLMANN, 2004). Além disso, o EKF necessita que a matriz

Jacobiana seja definida, que não é possível quando descontinuidades predominam no problema. Diferente do EKF, o UKF (do inglês *unscented Kalman filter*) (WAN; MERWE, 2000), (JULIER; UHLMANN, 2004) usa a função não-linear exata aplicada a uma distribuição de probabilidade aproximada. A denominada transformada *unscented* trata-se da aplicação da transformação não-linear do modelo a uma distribuição de probabilidade discreta de pontos, os *sigma points*, de forma que as estatísticas dos *sigma points* transformados possam ser calculadas e utilizadas como estimadores da transformada não-linear. Diferente das partículas do filtro baseado em sequências de Monte Carlo, os *sigma points* não são gerados aleatoriamente, e sim, são deterministicamente escolhidos para que contenham certas propriedades específicas.

Em (WAN; MERWE, 2000), o UKF é implementado usando $2D_x + 1$ *sigma points* \mathbf{X} , em que D_x é a dimensão do estado \mathbf{x} , tal que os *sigma points* são dados por:

$$\begin{aligned}\mathbf{X}_0 &= \bar{\mathbf{x}} \\ \mathbf{X}_i &= \bar{\mathbf{x}} + \left(\sqrt{(D_x + \lambda) \mathbf{P}_x} \right)_i, \quad \text{para } i = 1, 2, \dots, L \\ \mathbf{X}_i &= \bar{\mathbf{x}} - \left(\sqrt{(D_x + \lambda) \mathbf{P}_x} \right)_{i-L}, \quad \text{para } i = L + 1, L + 2, \dots, 2L,\end{aligned}\tag{4.12}$$

e seus pesos por:

$$\begin{aligned}\mathbf{W}_{mean}^{(0)} &= \lambda / (D_x + \lambda), \\ \mathbf{W}_{cov}^{(0)} &= \lambda / (D_x + \lambda) + (1 - \alpha^2 + \beta), \\ \mathbf{W}_{mean}^{(i)} &= \mathbf{W}_{cov}^{(i)} = 1 / (2D_x + 2\lambda), \quad \text{para } i = 1, 2, \dots, 2L.\end{aligned}\tag{4.13}$$

em que $\lambda = \alpha^2(D_x + \kappa) - D_x$ é o parâmetro de escala, α é o parâmetro de espelhamento dos *sigma points* em torno do estado médio $\bar{\mathbf{x}}$, κ é o parâmetro de escala secundário (normalmente é zero) e β é o parâmetro que incorpora o conhecimento da distribuição de \mathbf{x} (é 2 para modelos Gaussianos).

Uma vez determinadas as matrizes de covariância dadas por:

$$\begin{aligned}\hat{\mathbf{Y}}_k &= \left[\hat{\mathbf{y}}_k^{(0)}, \dots, \hat{\mathbf{y}}_k^{(2D_L)} \right], \\ \hat{\mathbf{y}}_k &= \sum_{i=0}^{2D_L} \mathbf{W}_{mean}^{(i)} \hat{\mathbf{Y}}_{i,k}, \\ \mathbf{P}_{y_k} &= \hat{\mathbf{Y}}_k \mathbf{W}_{cov} \hat{\mathbf{Y}}_k^T + \mathbf{Q}_v \quad \text{e} \\ \mathbf{P}_{xy_k} &= \hat{\mathbf{X}}_{k|k-1} \mathbf{W}_{cov} \hat{\mathbf{Y}}_k^T,\end{aligned}\tag{4.14}$$

o ganho do filtro é calculado por:

$$\mathbf{K}_k = \mathbf{P}_{xy_k} \mathbf{P}_{y_k}^{-1}. \quad (4.15)$$

O UKF utiliza o mesmo estimador do EKF.

O Algoritmo 3 estima recursivamente por UKF os parâmetros do canal $\boldsymbol{\chi}_k$ em cada bloco baseado na estimativa anterior $\hat{\boldsymbol{\chi}}_{k-1|k-1}$ e nas observações atuais \mathbf{y}_k . Requer o mesmo armazenamento e possui a mesma complexidade do EKF.

Algoritmo 3: Rastreamento de canal com UKF

Inicialização: $\hat{\boldsymbol{\chi}}_{0|0} \leftarrow \boldsymbol{\chi}_0, \mathbf{P}_{x_{0|0}} \leftarrow \mathbf{Q}_u,$

Entrada: $\hat{\boldsymbol{\chi}}_{k-1|k-1}, \mathbf{P}_{x_{k-1|k-1}}, \mathbf{y}_k$

Saída: $\hat{\boldsymbol{\chi}}_k, \mathbf{P}_{x_{k|k}}$

Variáveis Estáticas: $\alpha, \beta, \kappa, \lambda = \alpha^2(D_L + \kappa),$

$$W_m^{(0)} = 1 - \frac{D_L}{\lambda}, W_m^{(i)} = \frac{1}{2\lambda}, W_c^{(i)} = W_m^{(i)},$$

$$W_c^{(0)} = W_m^{(0)} + (1 - \alpha^2 + \beta), \mathbf{w}_m = [W_m^{(0)}, \dots, W_m^{(2D_L)}]^T,$$

$$\mathbf{W}_c = (\mathbf{I}_{2D_L+1} - \mathbf{w}_m \mathbf{1}^*) \times \text{diag}(W_c^{(0)}, \dots, W_c^{(2D_L)}) \\ \times (\mathbf{I}_{2D_L+1} - \mathbf{w}_m \mathbf{1})^T$$

início

%PREDIÇÃO:

$$\hat{\mathbf{X}}_{k-1|k-1} \leftarrow \hat{\boldsymbol{\chi}}_{k-1|k-1} \mathbf{1} \\ + \sqrt{\lambda} \left[\mathbf{0}^{**}, \sqrt{\mathbf{P}_{x_{k-1|k-1}}}, -\sqrt{\mathbf{P}_{x_{k-1|k-1}}} \right]$$

$$\hat{\mathbf{X}}_{k|k-1} \leftarrow \mathbf{A} \hat{\mathbf{X}}_{k-1|k-1}$$

$$\hat{\boldsymbol{\chi}}_{k|k-1} \leftarrow \hat{\mathbf{X}}_{k|k-1} \mathbf{w}_m$$

$$\mathbf{P}_{x_{k|k-1}} \leftarrow \hat{\mathbf{X}}_{k|k-1} \mathbf{W}_c \hat{\mathbf{X}}_{k|k-1}^T + \mathbf{Q}_u$$

%ANÁLISE:

$$\hat{\mathbf{X}}_{k|k-1} \leftarrow \hat{\boldsymbol{\chi}}_{k|k-1} \mathbf{1} + \sqrt{\lambda} \left[\mathbf{0}, \sqrt{\mathbf{P}_{x_{k|k-1}}}, -\sqrt{\mathbf{P}_{x_{k|k-1}}} \right]$$

para cada coluna $\hat{\mathbf{x}}_{k|k-1}^{(i)}$ de $\hat{\mathbf{X}}_{k|k-1}$ **faça**

$$\hat{\mathbf{y}}_k^{(i)} \leftarrow \mathbf{g}(\hat{\mathbf{x}}_{k|k-1}^{(i)})$$

fim_para

$$\hat{\mathbf{Y}}_k \leftarrow [\hat{\mathbf{y}}_k^{(0)}, \dots, \hat{\mathbf{y}}_k^{(2D_L)}]$$

$$\hat{\mathbf{y}}_k \leftarrow \hat{\mathbf{Y}}_k \mathbf{w}_m$$

$$\mathbf{P}_{y_k} \leftarrow \hat{\mathbf{Y}}_k \mathbf{W}_c \hat{\mathbf{Y}}_k^T + \mathbf{Q}_v$$

$$\mathbf{P}_{xy_k} \leftarrow \hat{\mathbf{X}}_{k|k-1} \mathbf{W}_c \hat{\mathbf{Y}}_k^T$$

%GANHO:

$$\mathbf{K}_k \leftarrow \mathbf{P}_{xy_k} \mathbf{P}_{y_k}^{-1}$$

%ESTIMADORES:

$$\hat{\boldsymbol{\chi}}_{k|k} \leftarrow \hat{\boldsymbol{\chi}}_{k|k-1} + \mathbf{K}_k (\mathbf{y}_k - \hat{\mathbf{y}}_k)$$

$$\mathbf{P}_{x_k|k} \leftarrow \mathbf{P}_{x_k|k-1} - \mathbf{K}_k \mathbf{P}_{y_k} \mathbf{K}_k^T$$

fim

* $\mathbf{1}$ é uma vetor linha de 1s, de dimensão $1 \times 2D_L + 1$.

** $\mathbf{0}$ é uma vetor coluna de 0s, de dimensão $D_L \times 1$.

Criado pelo autor, baseado no algoritmo UKF em (WAN; MERWE, 2000).

4.2.3 EnKF

O EnKF (do inglês *ensemble Kalman filter*) (EVENSEN, 2003) é uma classe de formulações subótimas do KF baseada em sequências de Monte Carlo, visando problemas de filtragem não-linear. Trata-se de gerar N_e amostras (livre interpretação, do inglês *ensembles*) da distribuição do modelo de evolução, e a partir dessas amostras, gerar amostras do modelo de medição para obtenção das matrizes de covariância necessárias no cálculo do ganho. Por meio dessa abordagem, é possível tratar problemas de natureza não-linear sem a necessidade de determinar a matriz Jacobiana dos modelos, além da possibilidade de redução da complexidade computacional e da dimensão das variáveis propagantes.

Uma vez determinadas as matrizes de covariância dadas por:

$$\begin{aligned} \hat{\mathbf{x}}_{k|k-1} &= \frac{1}{N_e} \sum_{i=1}^{N_e} \hat{\mathbf{x}}_{k|k-1}^{(i)}, \\ \hat{\mathbf{y}}_k &= \frac{1}{N_e} \sum_{i=1}^{N_e} \hat{\mathbf{y}}_k^{(i)}, \\ \mathbf{P}_{y_k} &= \frac{1}{N_e - 1} \sum_{i=1}^{N_e} \left(\hat{\mathbf{y}}_k^{(i)} - \hat{\mathbf{y}}_k \right) \left(\hat{\mathbf{y}}_k^{(i)} - \hat{\mathbf{y}}_k \right)^T, \\ \mathbf{P}_{xy_k} &= \frac{1}{N_e - 1} \sum_{i=1}^{N_e} \left(\hat{\mathbf{x}}_{k|k-1}^{(i)} - \hat{\mathbf{x}}_{k|k-1} \right) \left(\hat{\mathbf{y}}_k^{(i)} - \hat{\mathbf{y}}_k \right)^T, \end{aligned} \tag{4.16}$$

o ganho do filtro é calculado por:

$$\mathbf{K}_k = \mathbf{P}_{xy_k} (\mathbf{P}_{y_k} + \mathbf{Q}_v)^{-1}. \tag{4.17}$$

O estimador é dado por:

$$\begin{aligned} \hat{\mathbf{x}}_{k|k}^{(i)} &= \hat{\mathbf{x}}_{k|k-1}^{(i)} + \frac{1}{2} \mathbf{K}_k \left(\mathbf{y}_k + \mathbf{v}_k^{(i)} - \hat{\mathbf{y}}_k^{(i)} \right), \\ \hat{\mathbf{x}}_k &= \frac{1}{N_e} \sum_{i=1}^{N_e} \hat{\mathbf{x}}_{k|k-1}^{(i)}. \end{aligned} \tag{4.18}$$

Então, diferente do EKF, o EnKF espalha os *ensembles* independentes em torno do estado anterior, e cada *ensemble* é evoluído de forma paralela para o estado atual, com ajuste baseado na combinação linear entre o estado anterior $\hat{\mathbf{x}}_{k|k}^{(i)}$, o vetor de observação atual perturbado $\mathbf{y}_k + \mathbf{v}_k^{(i)}$ e o vetor de medição $\hat{\mathbf{y}}_k^{(i)}$, como mostra a Figura 20. A perturbação no vetor de observação é usada para evitar que os *ensembles* entrem em colapso. Dessa forma, o EnKF pode explorar diferentes possibilidades de transições entre os estados. O estimador é então definido como a média dos *ensembles* evoluídos e o erro de estimação como a média dos erros. A diferença entre o EnKF e o UKF, é que muitos *ensembles* são gerados randomicamente para captar, mais precisamente, o espaço de possibilidades, enquanto que poucos *sigma points* são gerados deterministicamente com o mesmo propósito, mas podendo resultar em menor precisão.

O Algoritmo 4 estima recursivamente por EnKF os parâmetros do canal $\boldsymbol{\chi}_k$ em cada bloco baseado nos *ensembles* anteriores $\mathbf{X}_{k-1|k-1} = \{\hat{\mathbf{x}}_{k-1|k-1}^{(1)}, \dots, \hat{\mathbf{x}}_{k-1|k-1}^{(N_e)}\}$ e nas observações atuais \mathbf{y}_k . Requer armazenagem de $\mathbf{X} \in \mathbb{R}^{D_L \times N_e}$, tal que $N_e \ll 2N_r N_f$. Com base nas operações matriciais do Algoritmo 4, a complexidade assintótica do algoritmo em termos de FLOPs pode ser determinado em dois casos: quando as observações são descorrelacionadas e quando são correlacionadas. Se \mathbf{y} é descorrelacionado, então a complexidade é $\mathcal{O}((N_w N_f)^2 N_e)$ se $N_f N_w \geq D_L$ ou $\mathcal{O}(N_w N_f D_L N_e)$ se $N_f N_w < D_L$. Se \mathbf{y} é correlacionado, então a matriz de covariância \mathbf{P}_{yy} é não-diagonal, e a complexidade é $\mathcal{O}((N_w N_f)^3)$ se $N_e < N_f N_w \geq D_L$ ou $\mathcal{O}((N_w N_f)^2 D_L)$ se $N_e < N_f N_w < D_L$. Portanto, se \mathbf{y} é descorrelacionado, que é o caso mais comum, a complexidade do EnKF é função de N_e , tal que, se $N_e < D_L > N_f N_w$ ou se $N_e < N_f N_w > D_L$, então o EnKF pode resultar em uma complexidade menor que o EKF em termos de FLOPs.

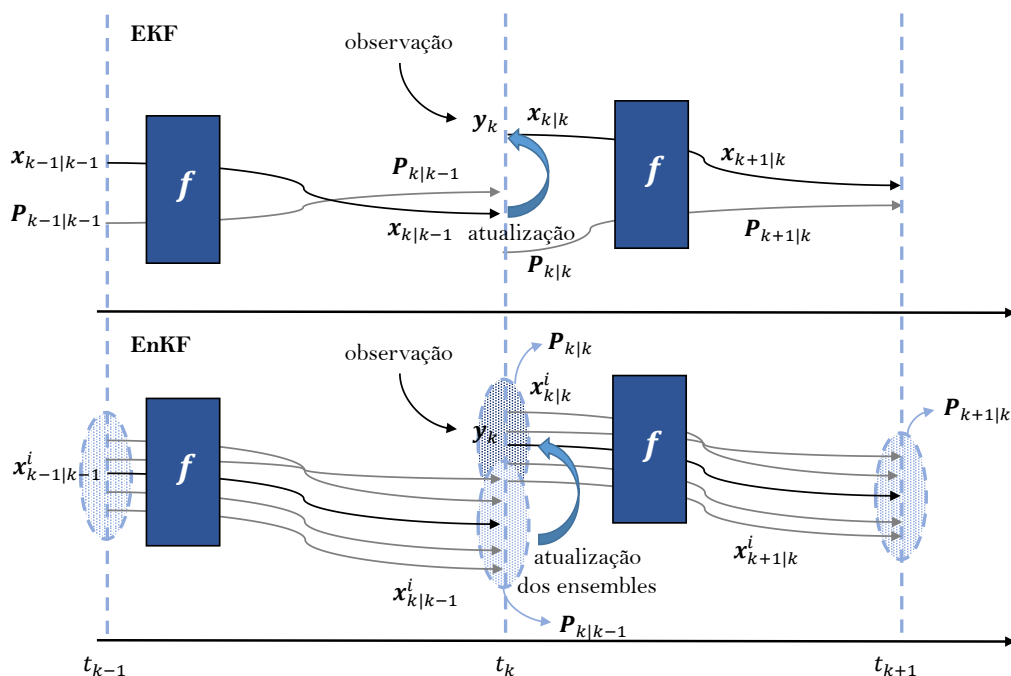
O uso de perturbações no vetor de observações permite que o filtro seja capaz de fazer ajustes maiores nos *ensembles*, que podem levar a erros quando pequenas correções são necessárias e suficientes para o problema. Em (SAKOV; OKE, 2008) é proposto o DEnKF, uma versão do EnKF sem perturbações na variável observada, para modelos com pequenas variações, que reduzir a covariância do erro de predição. O algoritmo de rastreamento de canal com DEnKF (do inglês *deterministic ensemble Kalman filter*) é descrito no Algoritmo 5. Requer a mesma armazenagem do EnKF e possui a mesma complexidade.

Os EnKFs são amplamente usados em sistemas de meteorologia, cujos modelos de evolução e medição são de alta ordem e não-lineares, e os estados iniciais são incertos. Além disso, a natureza probabilística da formulação e a coerência com o paradigma de computação

paralela podem ser vantajosas em muitas aplicações.

Como considerações finais, o EnKF reduz as restrições dos modelos, possibilitando integrar variações de modelos de mais alta ordem ou mesmo trabalhar com geração de números aleatórios dada a FDP do modelo. Também, pode proporcionar uma arquitetura com custo computacional reduzido usando atualizações seriais das amostras para cada observação escalar que chega (KATZFUSS *et al.*, 2016), que permite, no cálculo do ganho, calcular $2N_r N_t$ inversas de vetores $D_L \times 1$ em vez de calcular uma matriz $2N_w N_f \times 2N_w N_f$, além de permitir assimilação assíncrona.

Figura 20 – Comparação entre os paradigmas do EKF e do EnKF.



Fonte: Reconstituída de (REICHLÉ *et al.*, 2002) pelo autor.

Algoritmo 4: Rastreamento de canal com EnKF

Inicialização: $\hat{\mathbf{x}}_0^{(1:N_e)} \leftarrow \mathbf{x}_0$,

Entrada: $\hat{\mathbf{x}}_{k-1|k-1}^{(1:N_e)}, \mathbf{y}_k$

Saída: $\hat{\mathbf{x}}_k, \hat{\mathbf{x}}_{k|k}^{(1:N_e)}$

Variável Estática: N_e

início

%PREDIÇÃO:

```

para todo  $i \in 1, 2, \dots, N_e$  faça
     $\hat{\mathbf{x}}_{k|k-1}^{(i)} \leftarrow fdp(\hat{\mathbf{x}}_{k-1|k-1}^{(i)})$ 
     $\hat{\mathbf{y}}_k^{(i)} \leftarrow \mathbf{g}(\hat{\mathbf{x}}_{k|k-1}^{(i)})$ 
fim_para

%ANÁLISE:
 $\hat{\mathbf{x}}_{k|k-1} \leftarrow \frac{1}{N_e} \sum_{i=1}^{N_e} \hat{\mathbf{x}}_{k|k-1}^{(i)}$ 
 $\hat{\mathbf{y}}_k \leftarrow \frac{1}{N_e} \sum_{i=1}^{N_e} \hat{\mathbf{y}}_k^{(i)}$ 
 $\mathbf{P}_{y_k} \leftarrow \frac{1}{N_e-1} \sum_{i=1}^{N_e} (\hat{\mathbf{y}}_k^{(i)} - \hat{\mathbf{y}}_k) (\hat{\mathbf{y}}_k^{(i)} - \hat{\mathbf{y}}_k)^T$ 
 $\mathbf{P}_{xy_k} \leftarrow \frac{1}{N_e-1} \sum_{i=1}^{N_e} (\hat{\mathbf{x}}_{k|k-1}^{(i)} - \hat{\mathbf{x}}_{k|k-1}) (\hat{\mathbf{y}}_k^{(i)} - \hat{\mathbf{y}}_k)^T$ 

%GANHO:
 $\mathbf{K}_k \leftarrow \mathbf{P}_{xy_k} (\mathbf{P}_{y_k} + \mathbf{Q}_v)^{-1}$ 

%ESTIMADOR DE ENSEMBLES:
para todo  $i \in 1, 2, \dots, N_e$  faça
     $\hat{\mathbf{x}}_{k|k}^{(i)} \leftarrow \hat{\mathbf{x}}_{k|k-1}^{(i)} + \frac{1}{2} \mathbf{K}_k (\mathbf{y}_k + \mathbf{v}_k^{(i)} - \hat{\mathbf{y}}_k^{(i)})$ 
fim_para

%ESTIMADOR:
 $\hat{\boldsymbol{\chi}}_k \leftarrow \frac{1}{N_e} \sum_{i=1}^{N_e} \hat{\mathbf{x}}_{k|k-1}^{(i)}$ 
fim

```

Criado pelo autor, baseado no algoritmo EnKF em (EVENSEN, 2003).

Algoritmo 5: Rastreamento de canal com DEnKF

Inicialização: $\hat{\mathbf{x}}_0^{(1:N_e)} \leftarrow \boldsymbol{\chi}_0$,

Entrada: $\hat{\mathbf{x}}_{k-1|k-1}^{(1:N_e)}, \mathbf{y}_k$

Saída: $\hat{\boldsymbol{\chi}}_k, \hat{\mathbf{x}}_{k|k}^{(1:N_e)}$

Variável Estática: N_e

início

%PREDIÇÃO:

para todo $i \in 1, 2, \dots, N_e$ **faça**

$$\hat{\mathbf{x}}_{k|k-1}^{(i)} \leftarrow fdp(\hat{\mathbf{x}}_{k-1|k-1}^{(i)})$$

$$\hat{\mathbf{y}}_k^{(i)} \leftarrow \mathbf{g}(\hat{\mathbf{x}}_{k|k-1}^{(i)})$$

```

fim_para
%ANÁLISE:

$$\hat{\mathbf{x}}_{k|k-1} \leftarrow \frac{1}{N_e} \sum_{i=1}^{N_e} \hat{\mathbf{x}}_{k|k-1}^{(i)}$$


$$\hat{\mathbf{y}}_k \leftarrow \frac{1}{N_e} \sum_{i=1}^{N_e} \hat{\mathbf{y}}_k^{(i)}$$


$$\mathbf{P}_{y_k} \leftarrow \frac{1}{N_e-1} \sum_{i=1}^{N_e} \left( \hat{\mathbf{y}}_k^{(i)} - \hat{\mathbf{y}}_k \right) \left( \hat{\mathbf{y}}_k^{(i)} - \hat{\mathbf{y}}_k \right)^T$$


$$\mathbf{P}_{xy_k} \leftarrow \frac{1}{N_e-1} \sum_{i=1}^{N_e} \left( \hat{\mathbf{x}}_{k|k-1}^{(i)} - \hat{\mathbf{x}}_{k|k-1} \right) \left( \hat{\mathbf{y}}_k^{(i)} - \hat{\mathbf{y}}_k \right)^T$$

%GANHO:

$$\mathbf{K}_k \leftarrow \mathbf{P}_{xy_k} \left( \mathbf{P}_{y_k} + \mathbf{Q}_v \right)^{-1}$$

%ESTIMADOR:

$$\tilde{\mathbf{x}}_{k|k} \leftarrow \frac{1}{2} \mathbf{K}_k \left( \mathbf{y}_k - \mathbf{g}(\hat{\mathbf{x}}_{k|k-1}) \right)$$


$$\hat{\mathbf{x}}_k \leftarrow \hat{\mathbf{x}}_{k|k-1} + 2\tilde{\mathbf{x}}_{k|k}$$

%ESTIMADOR DE ENSEMBLES:
para todo  $i \in 1, 2, \dots, N_e$  faça

$$\hat{\mathbf{x}}_{k|k}^{(i)} \leftarrow \hat{\mathbf{x}}_{k|k-1}^{(i)} + \frac{1}{2} \mathbf{K}_k \left( \mathbf{y}_k - \hat{\mathbf{y}}_k^{(i)} \right) + \tilde{\mathbf{x}}_{k|k}$$

fim_para
fim

```

Criado pelo autor, baseado no algoritmo DEnKF em (SAKOV; OKE, 2008).

4.3 Simulações para o Método baseado em KFs

Nesta seção é realizada uma análise de desempenho dos algoritmos de rastreamento de canal baseados em KFs, propostos neste capítulo. Todos os cenários de simulação consideram comunicação com um simples usuário no *downlink* e sempre será considerado o domínio puramente analógico de *precoders*. Os fatores que podem influenciar diretamente no desempenho desses filtros são: SNR de recepção, tamanho do arranjo de antenas, tamanho do *codebook*, erro de estado inicial e dos parâmetros de configuração dos filtros, intensidade da variação do canal e velocidade do MT. Esses fatores são analisados por simulações computacionais e os resultados são comparados com os métodos LS e OMP discutidos no Capítulo 3.

O ambiente de simulação foi desenvolvido utilizando os modelos do sistema descritos no Capítulo 3. Os parâmetros adotados nas simulações, listados nas Tabela 4 e Tabela 5, são baseados nos parâmetros 3GPP 5G NR da Tabela 1. Sempre que um parâmetro não for alvo

de análise, será utilizado seu valor padrão (Tabela 4). Para cada fator listado acima, foram executadas simulações com arranjo ULA e UPA. As simulações com ULA utilizam canais 2-D em conformidade com a literatura, logo a dimensão da variável de estado é $D_L = 4L$ e modelos que foram definidos somente para UPA podem ser adaptados reduzindo a dimensão. Para uma análise primordial, os canais foram gerados pela Equação (3.3). Os ângulos iniciais foram gerados com $\mathcal{U}(-\frac{\pi}{2}, \frac{\pi}{2})$ e os coeficientes do canal com $\mathcal{CN}(0, \frac{N_r N_t}{L})$, e a evolução do canal no tempo foi gerada pela Equação (3.10) e Equação (4.19). As simulações foram realizadas em blocos, tal que um bloco tem comprimento igual ao tempo de coerência, de forma que o canal não varia nesse intervalo. É considerado que dentro de um bloco é realizada uma varredura completa dos pares de feixes, de forma que a incerteza no vetor de observação \mathbf{Y} , Equação (3.16), é devida somente ao ruído de recepção. Como medida de desempenho, foi adotado o erro quadrático médio normalizado (NMSE, do inglês *normalized mean square error*), definido como $\frac{\mathbb{E}(\|\hat{\mathbf{H}} - \mathbf{H}\|_F^2)}{E(\|\mathbf{H}\|_F^2)}$, em que \mathbf{H} é a matriz verdadeira do canal, $\hat{\mathbf{H}}$ é a estimada e $\|\star\|_F$ é a norma de Frobenius.

Tabela 4 – Parâmetros do sistema para análise de KFs.

Sistema	
Frequência de operação	28 GHz, banda n257
Tempo de bloco	2 ms
Arranjo	ULA (padrão) e UPA
Tamanho padrão do arranjo para Tx e Rx	16 elementos de antenas com espaçamento $\lambda/2$
HPBW padrão	$6,3^\circ$
Coefficiente de correlação temporal padrão	0,9838
Velocidade padrão do MT	5 km/h
Variação angular padrão	$0,64^\circ$
SNR padrão	20 dB
Número de <i>clusters</i>	$L = 4$
Característica estocástica padrão dos modelos	Gaussiano aditivo de média nula
<i>Codebook</i> e tamanho padrão	DFT, $N_{feixes} = N_{ant}$
Número de simulações (laço de Monte Carlo)	50
Número de blocos	50

Fonte: criada pelo autor.

Nas simulações seguintes, o objetivo é encontrar alguma tendência particular ou de instabilidade entre os algoritmos, sendo que, neste trabalho, uma vez que os canais implementa-

Tabela 5 – Parâmetros dos algoritmos de estimação de canal.

Filtros de Kalman	
σ_u e σ_v padrões	ideais
Estado inicial padrão	ideal
Número de <i>ensembles</i>	80
OMP	
Número de interações (N_L)	$2L$ para ULA e $4L$ para UPA
Tamanho do <i>grid</i> (G)	180 para ULA e 20×20 para UPA

Fonte: criada pelo autor.

dos foram versões simplificadas (não são tão realistas), um algoritmo será considerado melhor ou pior que o outro se mantiver uma diferença de pelo menos 5 dB no desempenho ao longo da simulação.

Tempo de bloco

Um *frame* do padrão 3GPP 5G NR (3GPP, 2018), (CHOI, 2018) possui duração de 10 ms e pode ser dividido em 10 *subframes* de 1 ms. Para o espaçamento de subportadora de 240 kHz, um *frame* possui 160 *slots* (unidades de escalonamento) com duração de 62,5 μ s cada, e que cada *slot* acomoda até 14 símbolos com duração de 4,46 μ s. Se considerarmos uma arquitetura *beamforming* analógica, em que é testado um par de feixes por vez, aplicando um *codebook* de 16 *codewords* na BS e no MT, uma varredura completa, considerando um símbolo por par de feixes, terá duração de mais ou menos $16 \times 16 \times 4,46 \mu\text{s} = 1,14$ ms. Em termos de *subframes*, é necessário dois *subframes* para acomodar um treinamento completo. Então, o tempo de coerência foi fixado em 2 ms que, pelos resultados da Figura 13 para 16 antenas, garante correlação temporal de no mínimo 0,8 para um MT à velocidade de até 10 km/h e de no mínimo 0,7 para velocidade de até 20 km/h.

Complexidade computacional

Além do requisito de desempenho dos algoritmos de estimação de canal, um outro requisito de grande importância é a complexidade computacional do algoritmo. Na prática, a complexidade pode implicar em complexidade de *hardware* (custo, dimensão, consumo e poder de processamento), complexidade temporal de treinamento, devido à duração da varredura, e atraso de resposta. Na Tabela 6 são listadas as complexidades assintóticas de processamento, em termos de FLOPs, e a complexidade de treinamento para cada algoritmo em relação ao domínio analógico.

Tabela 6 – Complexidade dos Algoritmos.

Algoritmo	Complexidade Assintótica	Complexidade de Treinamento	Armazenamento
EKF	$\mathcal{O}((N_w N_f)^3)$ $N_f N_w \geq D_L$ $\mathcal{O}(D_L^2 N_w N_f)$ $N_f N_w < D_L$	$\leq N_f N_w$	$\hat{\mathbf{x}} \in \mathbb{R}^{N_v L \times 1}$ $\mathbf{P}_x \in \mathbb{R}^{N_v L \times N_v L}$
UKF	$\mathcal{O}((N_w N_f)^3)$ $N_f N_w \geq D_L$ $\mathcal{O}(D_L^3)$ $N_f N_w < D_L$	$\leq N_f N_w$	$\hat{\mathbf{x}} \in \mathbb{R}^{N_v L \times 1}$ $\mathbf{P}_x \in \mathbb{R}^{N_v L \times N_v L}$
EnKF DEnKF	(y descorrelacionado) $\mathcal{O}((N_w N_f)^2 N_e)$ $N_f N_w \geq D_L$ $\mathcal{O}(N_w N_f D_L N_e)$ $N_f N_w < D_L$ (y correlacionado) $\mathcal{O}((N_w N_f)^3)$ $N_e < N_f N_w \geq D_L$ $\mathcal{O}((N_w N_f)^2 D_L)$ $N_e < N_f N_w < D_L$	$\leq N_f N_w$	$\hat{\mathbf{X}} \in \mathbb{R}^{N_v L \times N_e}$
OMP	$\mathcal{O}(N_L N_w N_f G^2)$ (dominante) $\mathcal{O}(N_L^2 N_w N_f)$ (inversão de matriz)	$\geq N_f N_w$	não
LS	$\mathcal{O}((N_t N_r)^2 N_w N_f)$ (<i>precoders</i> não unitários)	$\geq N_f N_w$	não

Pela Tabela 6, nota-se que o método de estimação de canal OMP fornece um algoritmo de complexidade assintótica menor que os demais. Porém, segundo os resultados do Capítulo 3 e dos resultados apresentados mais à frente nesta seção, para alcançar alto desempenho em domínio analógico, o OMP requer um *codebook* DFT tal que $N_f N_w \geq N_r N_t$ e um *grid* de alta resolução (G), que cresce quadraticamente para arranjos do tipo UPA, resultando numa alta complexidade assintótica. O método LS também requer um *codebook* DFT com $N_f N_w \geq N_r N_t$. Já o método baseado KF, apresenta bom desempenho para $N_f N_w \leq N_r N_t$, que pode proporcionar uma redução de complexidade considerável, principalmente para arranjos do tipo UPA, além de ser independente do esquema de *codebook*.

O método de estimação de canal baseado em KF pode proporcionar desempenho superior ao método baseado em LS/OMP por utilizar, além das medições do treinamento, a informação do estado anterior para estimar o estado presente. Porém, o preço que se paga por essa característica é a necessidade de armazenamento das variáveis de propagação dos KFs, como mostra a Tabela 6, que pode se tornar preocupante se a dimensão do estado for muito grande, ou seja, se no sistema for necessário considerar um grande número de *clusters* e espalhadores.

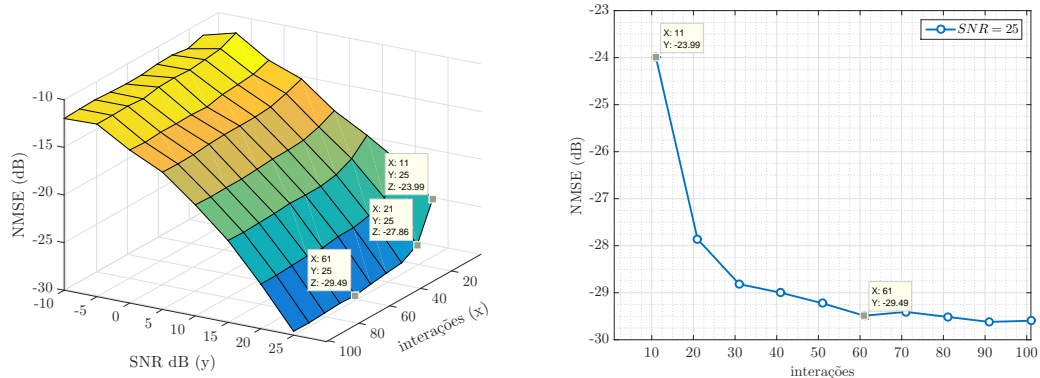
4.3.1 Análise da Influência da SNR

O ruído de recepção é fonte de incerteza sobre a medição do símbolo conhecido s , logo influencia diretamente no desempenho dos algoritmos.

No Capítulo 3, foram analisados os parâmetros do OMP para vários valores de SNR. Baseados nesses resultados, pode-se afirmar com segurança que, para o ambiente de simulação desenvolvido neste trabalho, no cenário $L = 4$ e arranjo ULA, o OMP alcança alto desempenho para $G = 181$ e $N_L = 2L = 8$. Com arranjo do tipo UPA, por uma questão de adequação computacional, foi utilizado $G = 20 \times 20$ e $N_L = 4L = 16$.

Nas Figura 21 e 22, é avaliado o desempenho do EnKF em função do número de *ensembles* N_e para diferentes valores de SNR e para arranjos do tipo ULA e UPA. Das figuras, pode se ver que para $N_e \geq 60$ o desempenho do EnKF se mantém constante para ambos os tipos de arranjos. Opta-se por $N_e = 80$ para as próximas simulações.

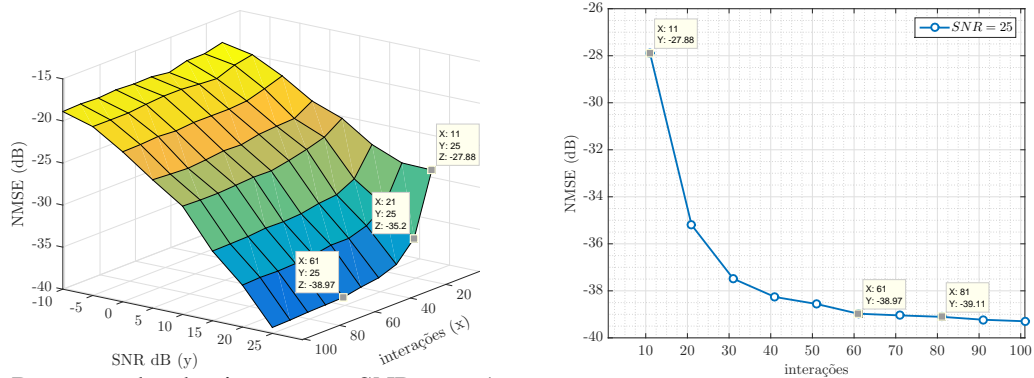
Figura 21 – Análise de desempenho do EnKF para diferentes números de iterações com arranjo ULA.



(a) Desempenho do sistema por SNR para 1 a 100 iterações. (b) Desempenho do sistema por número de iterações para SNR de 25 dB.

Fonte: criada pelo autor.

Figura 22 – Análise de desempenho do EnKF para diferentes números de iterações com arranjo UPA.




(a) Desempenho do sistema por SNR para 1 a 100 iterações. (b) Desempenho do sistema por número de iterações para SNR de 25 dB.

Fonte: criada pelo autor.


Na Figura 23 são analisados os desempenhos dos algoritmos para ULA-16 sob regimes de baixa e alta SNR e modelos Gaussianos, em que são rastreadas as variáveis ângulo de azimute e coeficientes do canal. A dimensão do modelo de estado é então $D_L = 4L$. Da figura, vemos que OMP mostrou resultado melhor que o LS. O OMP procura por máxima correlação as respostas de arranjo dentro de um dicionário, que o torna menos suscetível a erros por ruído em relação ao LS. Já os KFs são estimadores estatísticos por definição, adequados pra suavizar ou prever variações do sinal em mais amplo intervalo de SNR. Essa característica é refletida nos resultados da Figura 23, pode-se ver que os KFs garantem desempenho abaixo de -5 dB para um regime de SNR abaixo de 0 dB. Também, pode-se notar que os modelos de rastreamento baseados em UKF e EnKF, propostos neste trabalho, mostraram desempenho melhor que o EKF proposto em (ZHANG *et al.*, 2015) em alta SNR (sistema quase determinístico). Como mostra a Figura 23c, a fonte de erro do EKF foi no desempenho de rastreamento do coeficiente do canal.

A mesma simulação foi repetida com arranjo UPA- (4×4) . O caso UPA se diferencia do caso ULA na resposta do arranjo, e portanto na matriz Jacobiana para o EKF, e na dimensão de estado, por ser considerada a variável ângulo de elevação. A dimensão do modelo de estado é então $D_L = 6L$. Da Figura 24, pode-se ver que os algoritmos KFs apresentaram desempenhos superiores ao OMP. Também nota-se, que para o modelo de medição UPA, os KFs apresentaram desempenho melhor que para o modelo de medição ULA. Como se pode vê pelas tabelas 4-6, o OMP alcançou uma alta demanda computacional devido ao *grid-2D*, chegando a aproximadamente $0,7 \text{ G}^1$ FLOPs, enquanto que os KFs permaneceram sob a mesma


Figura 23 – Análise de SNR para arranjo ULA-16.



(a) Rastreamento completo do canal.



(b) Rastreamento dos ângulos do canal.



(c) Rastreamento dos coeficientes do canal.

Fonte: criada pelo autor.

complexidade para $N_w N_f \geq D_L$, de aproximadamente 17 M FLOPs.


Conclui-se nesta subseção, que o método de estimação de canal baseado em KF pode proporcionar um sistema de *beamtracking* de alto desempenho numa larga faixa de SNR, sendo superior em toda faixa ao método baseado em LS/OMP, principalmente para arranjo do tipo UPA, mantendo a mesma complexidade assintótica para arranjos do tipo ULA e UPA, e podendo fornecer complexidade menor que o OMP.

4.3.2 Análise da Influência do Número de Espalhadores


O número de *clusters* L determina a dimensão do vetor de estado, que aumenta o grau de liberdade do sistema, influenciando diretamente no desempenho dos KFs. A dimensão do estado é dada por $D_L = 4L$ para ULA e $D_L = 6L$ para UPA. Mais especificamente, o que

¹ múltiplo de unidades Giga, assim como M (Mega) e k (quilo).


Figura 24 – Análise de SNR para arranjo UPA–(4 × 4).



(a) Rastreamento completo do canal.



(b) Rastreamento dos ângulos do canal.



(c) Rastreamento dos coeficientes do canal.

Fonte: criada pelo autor.

determina a dimensão é o número total de espalhadores. Porém, o ambiente de simulação desenvolvido neste trabalho se restringe ao cenário de um espalhador por *cluster*. Para tentar captar o efeito do número de espalhadores, podemos aumentar, de forma irreal, o número de *clusters*.

Um grande número de *ensembles* N_e do EnKF tende a melhorar a precisão do algoritmo. O número de *ensembles* tem relação diretamente proporcional a dimensão do sistema, seja da variável de estado ou observação. Para fazer com que o EnKF mantenha precisão com o aumento do número de *clusters* ao longo da simulação, foi feito $N_e = 1000$. Para o número de interações N_L do OMP, também pode ser fixado um valor extremo. Porém, para se alcançar o ponto ótimo, como na Figura 14, de uma simulação computacional foi obtida a seguinte relação entre N_L e L : $N_L = \text{ceil}\left(\frac{L+0,9}{0,38}\right)$.

A Figura 25 mostra os resultados para um arranjo ULA–16. Da figura, nota-se que


a dimensão do sistema praticamente não influencia no desempenho do método baseado em LS, enquanto que os KFs respondem a mudança da dimensão, positiva ou negativamente. Para $L = 1$ (LOS), os KFs apresentaram altos desempenhos em relação ao LS/OMP. Para $L > 20$, o desempenho começa a cair, tornando mais vantajoso o método LS/OMP. De fato, os graus de liberdade de LS não dependem de L , porque a matriz $\hat{\mathbf{H}}$ é obtida diretamente da resolução de um sistema linear com dimensões $N_f N_w$ e $N_r N_t$, enquanto que o L influencia somente no parâmetro N_L para o algoritmo OMP. Diferentemente, as variáveis que se propagam em KFs possuem dimensões proporcionais a L e influenciam nos graus de liberdade no cálculo do ganho do filtro, o que pode reduzir a precisão de estimação. Um ponto importante que se observa é a melhoria de desempenho que os KFs propostos neste trabalho apresentaram em relação ao EKF. Uma vez que o EnKF gera, com base no desvio padrão do modelo, e evolui vários *ensembles* em torna do estado anterior, uma gama estados atuais é explorada, o que o torna mais capaz de rastrear rápidas variações.

Em conclusão, o método baseado em KFs é vantajoso se o número de espalhadores não for muito grande. Uma vez que os canais MIMO-mmWave são caracterizados por serem pobres em *cluster*, principalmente em ambientes *outdoors*, essa limitação não chega a ser tão preocupante.


4.3.3 Análise da Influência de σ_u e da Velocidade do MT

A principal desvantagem que o uso de KFs em sistemas de *beamtracking* pode apresentar, é a limitação de rastrear, com taxa de amostragem limitada, variações rápidas no canal, que pode surgir com a alta velocidade do MT. A velocidade do MT, seja de movimento rotacional ou translacional, implica em rápidas mudanças do AoA, devido à variação rápida de posicionamento do MT em relação à BS, bem como a probabilidade de surgimento de novos *clusters*. Também, o espelhamento Doppler se torna um fator de variação, que pode reduzir consideravelmente o tempo de coerência e, conseqüentemente, a correlação temporal do canal. Esses efeitos implicam em altos valores dos desvios padrões σ_u e ρ que modelam a incerteza no modelo de estado dos KFs.


As simulações, cujos resultados são mostrados nas Figura 26 e Figura 27, foram realizadas em dois cenários: velocidade translacional do MT de 5 km/h e ângulos variando sob desvio padrão σ_u de $0,1^\circ$ a $2,0^\circ$; velocidade translacional do MT de 1 a 20 km/h, tal que pra



(a) Rastreamento completo do canal.



(b) Rastreamento dos ângulos do canal.



(c) Rastreamento dos coeficientes do canal.

Figura 25 – Desempenho em função do número de espalhadores para o arranjo ULA–16.

cada velocidade foi atribuído uniformemente um σ_u de $0,5^\circ$ a $1,0^\circ$. De acordo com a Equação (3.21) e os parâmetros na Tabela 4, a correlação temporal do canal foi de 0,9993 ($v_{MT} = 1$ km/h) a 0,7902 ($v_{MT} = 20$ km/h).

Da Figura 26, pode-se ver que a variação dos parâmetros do canal pouco influencia no desempenho do LS/OMP, uma vez que esses dependem somente das medições de varredura do bloco atual. Como na Figura 26b, o LS/OMP podem sofrer alguma queda de desempenho devido ao aumento da variação dos coeficientes do canal. Já os KFs respondem negativamente a cada aumento da variação de σ_u e v_{MT} , devido ao aumento da decorrelação entre as amostras de estado em instantes adjacentes. Entre os algoritmos KFs, os EnKFs respondem de forma menos acentuada as variações angulares e apresentam desempenho superior ao EKF ao longo de toda simulação devido à geração e evolução de *ensembles*. Ainda pela Figura 26, nota-se que os EnKFs mantiveram desempenho superior ao LS por toda a faixa de σ_u e superior ao OMP para $\sigma_u < 1^\circ$. Considerando o desvio médio absoluto de uma distribuição Gaussiana, podemos dizer que o decolamento angular médio para $\sigma_u = 1^\circ \pi/180$ é $\sqrt{2/\pi}\sigma_u \approx 0,0139$ rad. Para um tempo

de bloco de 2 ms, o descolamento angular médio equivale a uma rotação do MT de 6,9500 Hz ou 417 rpm. Segundo medições empíricas em (TSANG; POON, 2011), um usuário pedestre pode submeter o MT a uma rotação de até 68 rpm em atividades comuns e de até 133 rpm com jogos. Baseado nesses dados, $\sigma_u < 1^\circ$ é bom limite para as atividades de um usuário pedestre de serviços móveis. Em termos de velocidade média do MT, os EnKFs mantiveram desempenho superior ao OMP para $v_{MT} < 9$ km/h (faixa de velocidade de pedestre).

As mesmas simulações foram repetidas com modelo de medição para arranjo UPA- (4×4) , e os resultados são apresentados na Figura 27. Dos resultados, nota-se que, assim como nos resultados da Figura 24, os KFs apresentam desempenhos relativamente melhores, com uma diferença suficiente para se manterem superiores ao longo de toda intervalo de σ_u e v_{MT} .

Conclui-se que os KFs fornecem alto desempenho para usuários pedestres, caracterizados por apresentarem velocidade inferior 9 km/h e desvio padrão angular de 1° para os dois tipos de arranjos, podendo ainda fornecer desempenho considerável para velocidade maiores, principalmente com arranjo UPA.

4.3.4 Análise da Influência do Tamanho do Arranjo e do Número de Feixes

O tamanho do arranjo N_{ant} implica no número de feixes e na largura do feixe, bem como nos graus de liberdade do sistema. Arranjos com grandes números de antenas viabilizam a formatação de feixes mais estreitos, e esses estão mais sujeitos ao desalinhamento, que pode resultar em baixo desempenho se a variação angular for suficientemente grande.

Um número maior de feixes estreitos, que varre todo espaço, pode ser formatado com grandes arranjos. Porém, se um algoritmo de estimação de canal requer um treinamento com todos os feixes para fornecer um desempenho satisfatório em relação ao NMSE, então, tal algoritmo possuirá alta complexidade de tempo de treinamento, reduzindo, portanto, a taxa de transferência efetiva do sistema.

Nesta subseção, os algoritmos KFs e os LSs serão avaliados em função do tamanho do arranjo e também do número de feixes de treinamento.

A Figura 28 mostra os desempenhos dos algoritmos em relação ao tamanho de um arranjo ULA para os valores de $\sigma_u = \{0,2^\circ, 0,64^\circ, 1,0^\circ, 2,0^\circ\}$. Uma vez que a largura de feixe

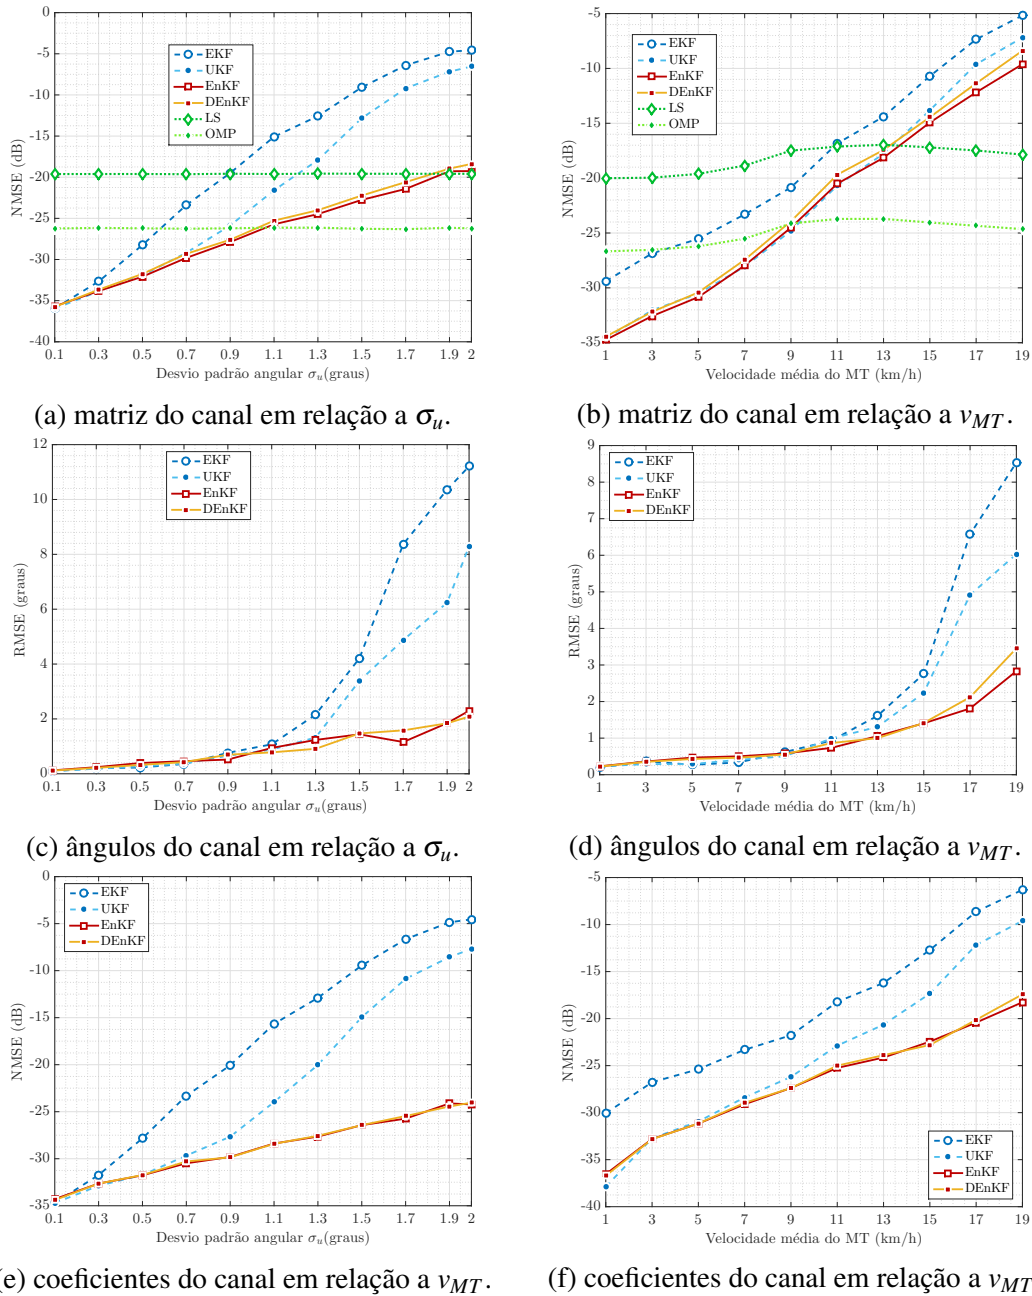


Figura 26 – Desempenho em função do AS e da velocidade do MT para um arranjo ULA–16 e SNR de 20 dB.

diminui à medida que o tamanho do arranjo aumenta, o coeficiente de correlação temporal do canal é recalculado pela Equação (3.21) a fim de manter o tempo de coerência em 2 ms para cada tamanho de arranjo na simulação. A Equação (3.21) diz que quanto menor a largura do feixe maior a correlação temporal.

Da Figura 28 nota-se que para σ_u pequeno, o desempenho do EnKF melhora à medida que N_{ant} aumenta. Já o EKF e UKF não mantiveram melhoria no desempenho para um valor crescente do N_{ant} . O EKF apresentou desempenho máximo em $N_{ant} = 16$ e o UKF

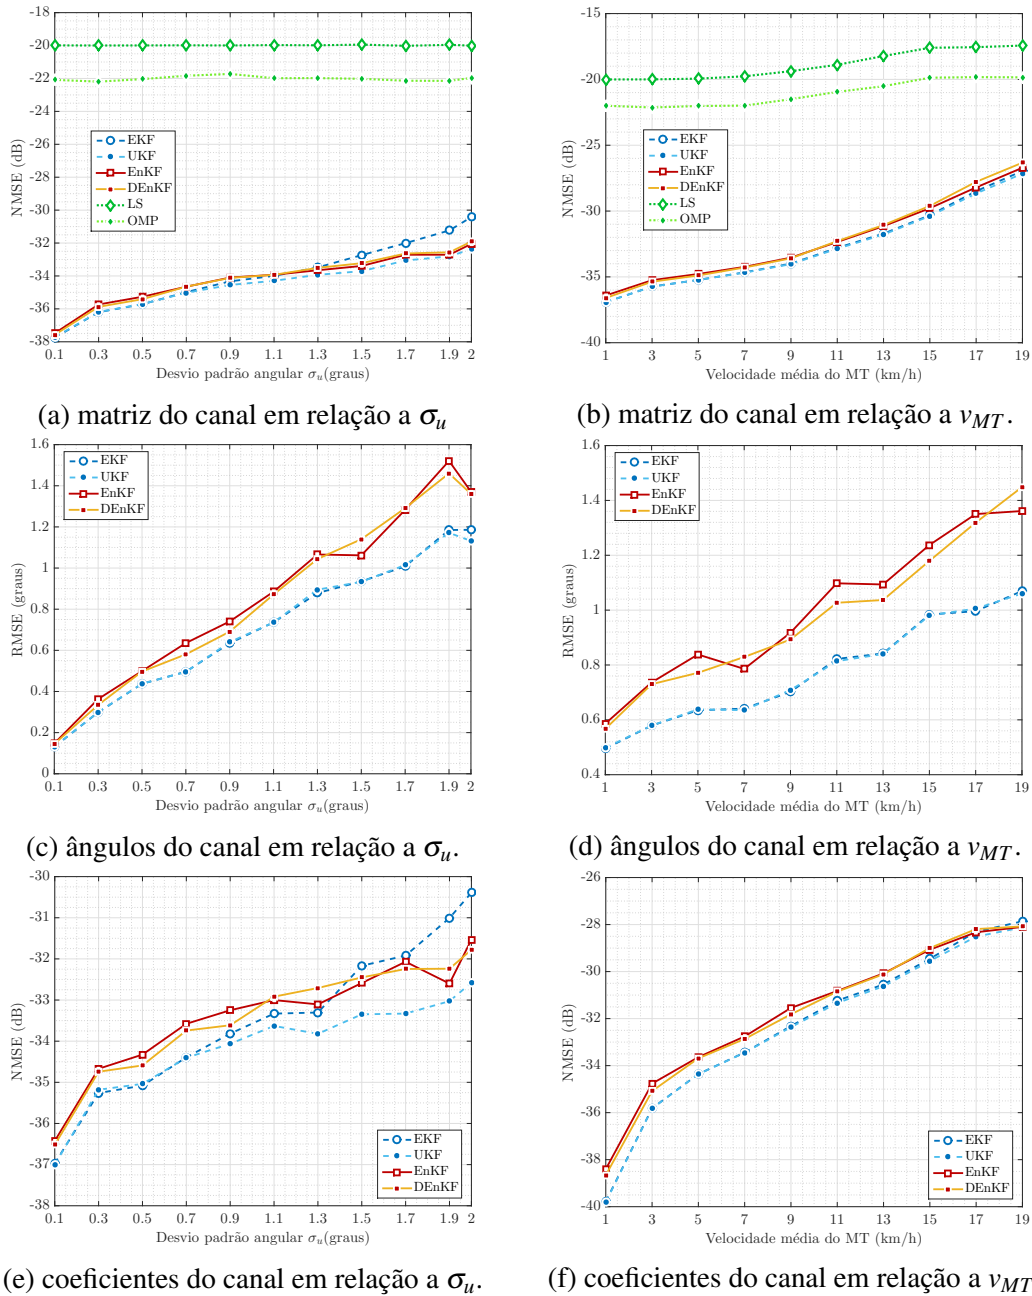


Figura 27 – Desempenho em função do AS e da velocidade do MT para um arranjo UPA-(4 × 4) e SNR de 20 dB.

em $N_{ant} = 32$. A medida que σ_u aumenta, o EnKF passa a apresentar desempenho máximo em $N_{ant} = 16$ ou $N_{ant} = 32$, e assim se mantém, enquanto os desempenhos máximos do EKF e UKF recuam para $N_{ant} = 8$. O LS, que não sofre com a influência do σ_u (Figura 26), praticamente não varia, pois na maior parte da simulação, o ρ se manteve acima de 0,9 e os *codewords* em consideração são puramente analógicos. Já OMP apresentou desempenho máximo em $N_{ant} = 16$.

Agora, considere a Figura 29. Pode-se notar, que os LSs são instáveis se a relação $N_{feixes} \geq N_{ant}$ não for satisfeita, enquanto que os KFs podem fornecer valores consideráveis de

NMSE para $N_{\text{feixes}} < N_{\text{ant}}$ e até -5 dB para um bit de quantização em grandes arranjos.

Pode-se concluir que para grandes arranjos ULA, $N_{\text{ant}} \geq 32$, os EKF e o UKF são inapropriados devido ao baixo desempenho. Por sua vez, o EnKF e os LSs fornecem alto desempenho para diversos tamanhos de arranjos ULA, com destaque para o EnKF, que além de fornecer desempenho superior aos LSs para $\sigma_u < 1^\circ$, é viável para $N_{\text{feixes}} < N_{\text{ant}}$, podendo trabalhar até com um bit de quantização. Portanto, o EnKF garante alto desempenho para diversos tamanhos de arranjo ULA, podendo fornecer mais baixa complexidade de processamento e treinamento que os algoritmos LSs.

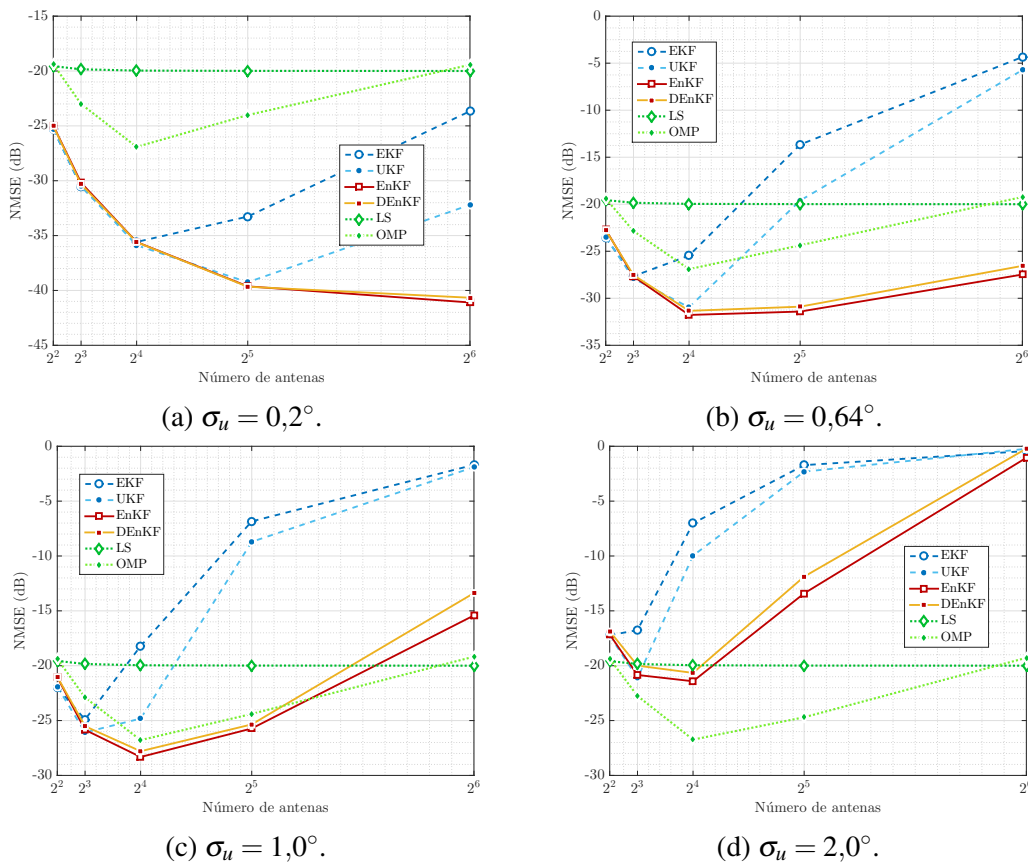


Figura 28 – Desempenho dos algoritmos em relação ao tamanho de um arranjo ULA, num regime de SNR de 20 dB, para diferentes valores de σ_u .

4.3.5 Análise da Influência do Erro de Parâmetro

A última análise realizada neste trabalho é a influência dos erros de parâmetros sobre os KFs que podem ocorrer devido a erros heurísticos na determinação dos parâmetros: σ_u , ρ , estados iniciais $\boldsymbol{\chi}_0$ e modelos de evolução.

A Figura 30 mostra o desempenho dos KFs configurados com $\sigma_u = 1^\circ$ em um cenário

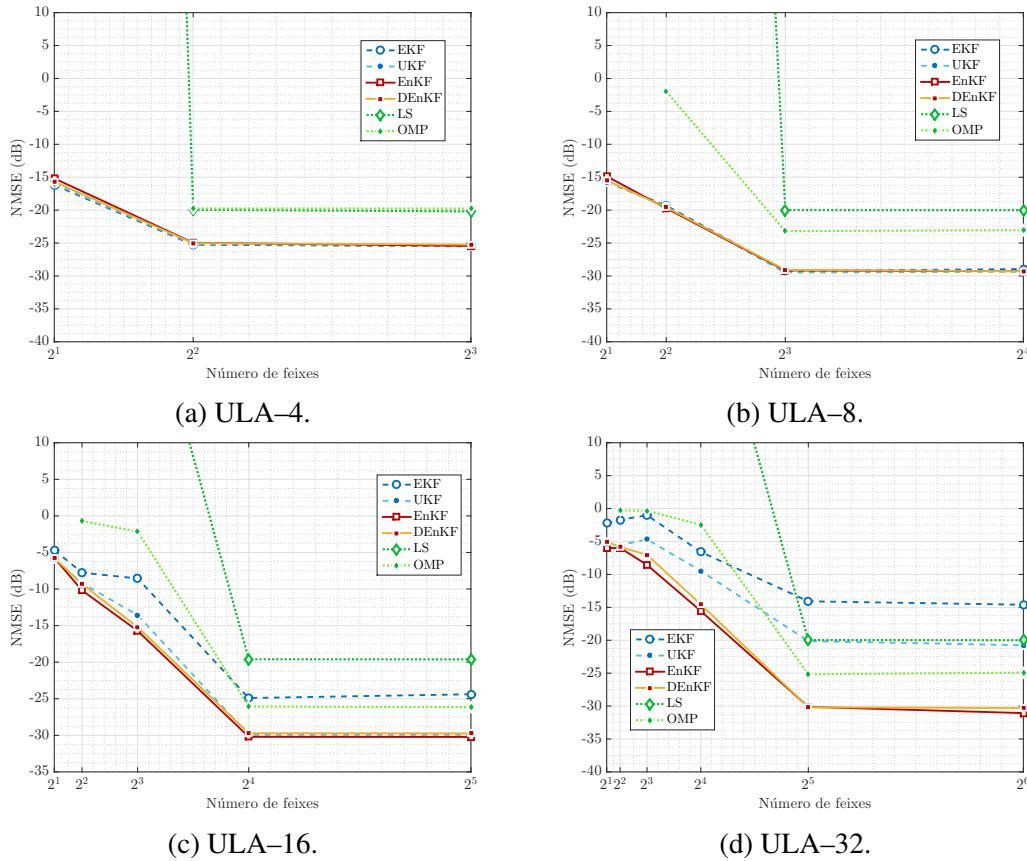


Figura 29 – Desempenho dos algoritmos em relação ao número de feixes de treinamento para diferentes tamanhos de arranjos ULA.




em que $\sigma_u = 0,64^\circ$. Nota-se que os algoritmos mais afetados pelo erro em σ_u foram os EnKFs. Isso ocorre porque um erro em σ_u gera erros de amostragem na fase de síntese dos *ensembles*. Mesmo com incerteza no valor de σ_u , os KFs mostraram bom resultados em relação aos LSs. Já a Figura 31 mostra os desempenhos dos KFs com incerteza nos valores de estado inicial. A incerteza foi modelada com uma Gaussiana de média nula e desvio padrão de $(2^\circ)\pi/180$ radianos para os ângulos e 2 para os coeficientes do canal. Nota-se que erro pouco influenciou no desempenho dos KFs. Porém, os KFs não abrem mão do conhecimento prévio do canal, de forma que os ângulos e coeficientes do canal no instante $k = 0$, bem como o número de *clusters*, devem ser estimados.

Por último, foi avaliado um modelo da mistura de duas Gaussianas (PRIEBE *et al.*, 2011), de média μ_i , covariância Σ_i e peso w_i , dado por:

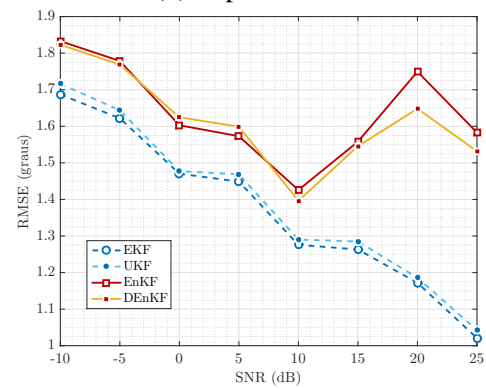
$$\begin{aligned} \boldsymbol{\chi}[k] \sim & w_1 \mathcal{N}(\mathbf{A}\boldsymbol{\chi}[k-1] + \mu_1, \Sigma_1) + \\ & w_2 \mathcal{N}(\mathbf{A}\boldsymbol{\chi}[k-1] + \mu_2, \Sigma_2). \end{aligned} \quad (4.19)$$

Objetivo agora é analisar o comportamento do EKF e do UKF na presença de distribuições



de incerteza desconhecidas. Foram simulados uma distribuição unimodal, com $\mu_1 = \mu_2 = 0$, $\sigma_2^2 = 2\sigma_1^2 = 2(0,64\pi/180)^2$ e $\mathbf{w} = \{0,3;0,7\}$, e outra bimodal, com $\mu_1 = -0,1\mathbf{A}\boldsymbol{\chi}$, $\mu_2 = 0,1\mathbf{A}\boldsymbol{\chi}$, $\sigma_2^2 = \sigma_1^2 = (0,64\pi/180)^2$ e $\mathbf{w} = \{0,5;0,5\}$. O modelo da Equação (3.10) foi mantido para o EKF e o UKF, e o parâmetro σ_u do filtro foi configurado em $2\pi/180$ para o modelo unimodal. Já para o EnKF, podendo trabalhar diretamente com FDPs, foram utilizadas as distribuições verdadeiras, visando destacar a vantagem prática de adaptar o EnKF a variações de modelos simplesmente mudando a FDP. A Figura 32 mostra os desempenhos dos KFs para as duas distribuições citadas. Nota-se que o EKF e o UKF apresentaram bom desempenho para a distribuição unimodal, mas para a distribuição bimodal o desempenho caiu significativamente. Os KFs são desenvolvidos sobre a presunção de incerteza Gaussiana aditiva, que viabiliza a predeterminação da média e da covariância dos modelos. Por isso, é possível obter bons resultados se a distribuição de probabilidade da incerteza for semelhante a uma Gaussiana. Em particular, em relação aos EnKFs, devido à flexibilidade de trabalharem diretamente com a FDP do modelo de evolução, sem precisar do conhecimento explícito do modelo, é possível obter bons resultados com distribuições multimodais se a distribuição verdadeira for usada para sintetizar *ensembles*, como mostra a Figura 32.

(a) \mathbf{H} para ULA.(b) \mathbf{H} para UPA.

(c) AoA e AoD para ULA.



(d) AoA e AoD para UPA.

(e) α para ULA.(f) α para UPA.Figura 30 – Análise de robustez para um erro de σ_u .








Figura 31 – Análise de robustez para erro de estado inicial no desempenho dos KFs.

(a) \mathbf{H} do modelo 1.(b) \mathbf{H} do modelo 2.

(c) ângulos do modelo 1.



(d) ângulos do modelo 2.



(e) α do modelo 1.(f) α do modelo 2.

Figura 32 – Análise de robustez para erro no modelo de evolução no desempenho dos KFs.

5 CONCLUSÕES

Neste trabalho foi avaliado, por meio de simulações computacionais, o uso de filtros de Kalman como algoritmos de rastreamento de canal MIMO–mmWave para aplicação em algoritmos de *beamtracking*. O critério quantitativo de desempenho adotado foi o NMSE das matrizes de canal estimada e verdadeira. Foram analisadas as influências da SNR, do número de espalhadores, da velocidade de variação dos parâmetros do canal, do tamanho do arranjo, do número de feixes de treinamento e do erro de parâmetros de configuração. Foram utilizados arranjos ULA e UPA. Três tipos de KFs foram analisados: EKF, UKF e EnKF/DEnKF. Os KFs foram comparados com métodos baseados em LS. Além do desempenho em relação ao NMSE, foram avaliados a complexidade assintótica de processamento e a complexidade de treinamento.

Em relação ao método de estimação de canal baseado em KF, foram evidenciadas as seguintes conclusões:

- Pode proporcionar um sistema de *beamtracking* de alto desempenho numa larga faixa de SNR em comparação com LS/OMP;
- Mostrou desempenho melhor para arranjo do tipo UPA em comparação com ULA, em que manteve a mesma complexidade assintótica do arranjos ULA. Pode, também, fornecer complexidade menor que o OMP, principalmente para arranjo UPA;
- É vantajoso se o número de espalhadores não for muito grande. Pode fornecer bom desempenho para número de espalhadores em conformidade com canais MIMO-mmWave;
- Fornece alto desempenho para usuários pedestres, caracterizados por apresentarem velocidade inferior a 9 km/h e desvio padrão angular inferior a 1° ;
- Diferente do LS/OMP, é viável para $N_{feixes} < N_{ant}$, podendo trabalhar com até com um bit de quantização;
- Para grandes arranjos ULA, $N_{ant} \geq 32$, o EKF e o UKF são inapropriados devido ao baixo desempenho. O EnKF e os LSs fornecem alto desempenho para diversos tamanhos de arranjos, sendo que o EnKF pode ainda fornecer mais baixa complexidade de processamento que os algoritmos LSs;
- Sofre com erros heurísticos no parâmetro σ_u , principalmente o EnKF, e com incoerências nos modelos de distribuição de incerteza. Nesse caso, o EnKF pode apresentar bom desempenho devido à praticidade de poder mudar os modelos de distribuição de incerteza

pela simples mudança da FDP;

- Diferente do LS/OMP, tem como saída os parâmetros separados do canal, ângulos e coeficientes, que podem ser usados diretamente em outras aplicações.

Como conclusão geral, os métodos LS só são vantajosos em relação aos KFs em cenários de alta velocidade, alta SNR e pequenos arranjos de antenas. Já os KFs são vantajosos em cenários de baixa mobilidade, mas podem trabalhar com uma larga faixa de SNR, diversos *codebooks* e grandes arranjos. Entre os KFs, destaca-se o EnKF por poder trabalhar melhor em cenários de mais alta mobilidade.

Trabalhos Futuros

Neste trabalho foi considerado que o canal não varia durante o treinamento. Variações ao longo do treinamento podem gerar erros de estimação de canal mais acentuados que erro de ruído do modelo de medição. Além disso, foram considerados somente os *codewords* analógicos. Os *codewords* digitais podem ser estimados tomando como base os *codewords* analógicos, como feito em (HE *et al.*, 2014). Como melhorias promissoras a este trabalho, pode-se citar:

- Considerar cenários dinâmicos mais realistas, com traçados de raios, obstruções e princípios físicos eletromagnéticos;
- Considerar um cenário em que o canal varia ao longo do treinamento e em que os modelos do sistema podem divergir, em certos instantes, dos modelos reais;
- Considerar uma arquitetura *beamforming* híbrida, com estimação de *codewords* nos domínios analógicos e digitais;
- Avaliar o uso de técnicas de aprendizado de máquina para a determinação inteligente dos parâmetros e modelos dos KFs. Nesse sentido, o UKF e o EnKF são vantajosos por não necessitarem de cálculos de derivadas, além do EnKF poder trabalhar diretamente com a FDP do modelo de evolução.

REFERÊNCIAS

Ericsson. **3GPP TR 38.817-02**. 2018. Data de acesso: 13 jun. 2018. Disponível em: <<https://portal.3gpp.org/ngppapp/CreateTdoc.aspx?mode=view&contributionUId=R4-1714547>>.

ALKHATEEB, A.; AYACH, O.E.; LEUS, G.; HEATH, R.W. Channel estimation and hybrid precoding for millimeter wave cellular systems. **IEEE Journal of Selected Topics in Signal Processing**. v.8, n.5, p.831–846, out. 2014.

ALKHATEEB, A.; MO, J.; GONZALEZ-PRELCIC, N.; HEATH, R.W. MIMO precoding and combining solutions for millimeter-wave systems. **IEEE Communications Magazine**. v. 52, n.12, p. 122–131, dez. 2014.

ASSOCIATION, I.S. *et al.* **802.11-2012-IEEE standard for information technology – telecommunications and information exchange between systems local and metropolitan area networks—specific requirements part 11: Wireless lan medium access control (MAC) and physical layer (PHY) specifications**. IEEE, v. 802, 2012.

BAYOUMI, M.A.; RAO, P.; ALHALABI, B. VLSI parallel architecture for Kalman filterAn algorithm specific approach. **VLSI Signal Processing**. v.4, n. 2-3, p. 147–163, mai. 1992.

BO, G.; CHANGMING, Z.; DEPENG, J.; LIEGUANG, Z. Compressed SNR and channel estimation for beamtracking 60 GHz WLAN. **China Communications**, v.12, n.6, p. 46–58, jun. 2015.

BOGALE, T.E.; LE, L.B. Beamforming for multiuser massive MIMO systems: Digital versus hybrid analog-digital. **Global Communications Conference (GLOBECOM), IEEE**. p. 4066–4071, 2014.

CHIZHIK, D. Slowing the time-fluctuating MIMO channel by beam forming. **IEEE Transactions on Wireless Communications**. v.3, n.5, p. 1554–1565, 2004.

CHOI, W. **5G NR Overview**. 2018. Data de acesso: 13 jun. 2018. Disponível em: <http://www.e4ds.com/webinar_tech_dn.asp?idx=263>.

CONSTANTINE, A.B. *etal.* **Antenna theory: analysis and design**. 4 ed. John Wiley & Sons, 2016.

DU, K. L.; SWAMY, M.N. **Wireless communication systems: from RF subsystems to 4G enabling technologies**. Cambridge University Press, 2010.

EVENSEN, G. The ensemble Kalman filter: Theoretical formulation and practical implementation. **Ocean dynamics**, Springer, v. 53, n. 4, p. 343–367, 2003.

GIORDANI, M.; MEZZAVILLA, M.; BARATI, C.N.; RANGAN, S.; ZORZI, M. Comparative analysis of initial access techniques in 5G mmWave cellular networks. **Information Science and Systems (CISS)**. p. 268–273, 2016.

- GOLDSMITH, A. **Wireless communications**. Cambridge University press, 2005.
- HAUPT, R.L. **Antenna arrays: a computational approach**. John Wiley & Sons, 2010.
- HE, J.; KIM, T.; GHAUCH, H.; LIU, K.; WANG, G. Millimeter wave MIMO channel tracking systems. **IEEE Globecom Workshops (GC Wkshps)**. p. 416–421, Dec 2014.
- HEATH, R.W.; GONZALEZ-PRELCIC, N.; RANGAN, S.; ROH, W.; SAYEED, A.M. An overview of signal processing techniques for millimeter wave MIMO systems. **IEEE Journal of Selected Topics in Signal Processing**. v.10, n.3, p. 436–453, abr. 2016.
- HONG, W.; BAEK, K.H.; KO, S. Millimeter -wave 5G antennas for smartphones: Overview and experimental demonstration. **IEEE Transactions on Antennas and Propagation**. v. 65, n. 12, p. 6250–6261, dez. 2017.
- JAECKEL, S.; RASCHKOWSKI, L.; BORNER, K.; THIELE, L. Quadriga: A 3-D multi-cell channel model with time evolution for enabling virtual field trials. **IEEE Transactions on Antennas and Propagation**. v. 62, n. 6, p. 3242–3256, 2014.
- JULIER, S. J.; UHLMANN, J. K. Unscented filtering and nonlinear estimation. **Proceedings of the IEEE**. v. 92, n. 3, p. 401–422, 2004.
- KATZFUSS, M.; STROUD, J. R.; WIKLE, C. K. Understanding the ensemble Kalman filter. **The American Statistician**. v. 70, n. 4, p. 350–357, 2016.
- KUTTY, S.; SEN, D. Beamforming for millimeter wave communications: An inclusive survey. **IEEE Communications Surveys Tutorials**. v. 18, n. 2, p. 949–973, 2016.
- LEE, J.; GIL, G.T.; LEE, Y.H. Exploiting spatial sparsity for estimating channels of hybrid MIMO systems in millimeter wave communications. **IEEE Global Communications Conference**. p. 3326–3331, 2014.
- LIM, S. H.; KIM, J. B. S.; SHIM, B.; CHOI, J. W. Efficient beam training and channel estimation for millimeter wave communications under mobility. **CoRR**. abs/1804.07973, 2018.
- LIU, C.; LI, M.; HANLY, S.V.; COLLINGS, I.B.; WHITING, P. Millimeter wave beam alignment: Large deviations analysis and design insights. **IEEE Vehicular Technology Conference (VTC-Fall)**. abs/1611.04212, 2016.
- MACCARTNEY, G.R.; ZHANG, J.; NIE, S.; RAPPAPORT, T.S. Path loss models for 5G millimeter wave propagation channels in urban microcells. **IEEE Global Communications Conference (GLOBECOM)**. p. 3948–3953, dez. 2013.
- MEDBO, J.; ASPLUND, H.; BERG, J.-E. 60 GHz channel directional characterization using extreme size virtual antenna array. **Personal, Indoor, and Mobile Radio Communications (PIMRC)**, 2015 IEEE 26th Annual International Symposium on. p. 176–180, 2015.

MOHAMED, E. M.; SAKAGUCHI, K.; SAMPEI, S. Millimeter wave beamforming based on WiFi fingerprinting in indoor environment. **IEEE International Conference on Communication Workshop (ICCW)**, abs/1505.05579, 2015.

MOLISCH, A. F.; RATNAM, V. V.; HAN, S.; LI, Z.; NGUYEN, S. L. H.; LI, L.; HANEDA, K. Hybrid beamforming for massive MIMO: A survey. **IEEE Communications Magazine**. v. 55, n. 9, p. 134–141, 2017.

NITSCHKE, T.; FLORES, A.B.; KNIGHTLY, E.W.; WIDMER, J. Steering with eyes closed: Mm-Wave beam steering without in-band measurement. **IEEE Conference on Computer Communications (INFOCOM)**. p. 2416–2424, 2015.

PALACIOS, J.; DONNO, D.D.; WIDMER, J. Tracking mm-wave channel dynamics: Fast beam training strategies under mobility. **IEEE INFOCOM - IEEE Conference on Computer Communications**. p. 1–9, 2017.

PI, Z.; KHAN, F. An introduction to millimeter-wave mobile broadband systems. **IEEE Communications Magazine**. v. 49, n. 6, p. 101–107, jun. 2011.

PRIEBE, S.; JACOB, M.; KUERNER, T. AoA, AoD and ToA characteristics of scattered multipath clusters for THz indoor channel modeling. **European Wireless – Sustainable Wireless Technologies**. p. 1–9, 2011.

RAPPAPORT, T.S.; SUN, S.; MAYZUS, R.; ZHAO, H.; AZAR, Y.; WANG, K.; WONG, G.N.; SCHULZ, J.K.; SAMIMI, M.; GUTIERREZ, F. Millimeter wave mobile communications for 5G cellular. **IEEE Access**. v.1, p. 335–349, 2013.

REICHLER, R.H.; WALKER, J.P.; KOSTER, R.D.; HOUSER, P.R. Extended versus ensemble Kalman filtering for land data assimilation. **Journal of hydrometeorology**, v.3, n. 6, p.728–740, 2002.

RISTIC, B.; ARULAMPALAM, S.; GORDON, N. **Beyond the Kalman filter: Particle filters for tracking applications**. Artech house, 2003.

RUFFINI, M. Multidimensional convergence in future 5G networks. **J. Lightwave Technol**, v. 35, n. 3, p. 535–549, fev. 2017.

SAKOV, P.; OKE, P.R. A deterministic formulation of the ensemble Kalman filter: an alternative to ensemble square root filters. **Dynamic Meteorology and Oceanography**. Taylor & Francis, v. 60, n. 2, p. 361–371, 2008.

SILVEIRA, E. S.; NASCIMENTO, D. C.; TINOCO-S., A. F.; PINA, M. V. P. Design of Microstrip Antenna Array with Suppressed Back Lobe. **Journal of Microwaves, Optoelectronics and Electromagnetic Applications**. Scielo, v. 16, p. 460 – 470, 2017.

SINGH, J.; RAMAKRISHNA, S. On the feasibility of codebook -based beamforming in millimeter wave systems with multiple antenna arrays. **IEEE Transactions on Wireless Communications**. IEEE, v. 14, n. 5, p. 2670–2683, 2015.

TROPP, J.A.; GILBERT, A.C. Signal recovery from random measurements via orthogonal matching pursuit. **IEEE Transactions on Information Theory**. v. 53, n. 12, p. 4655–4666, dez. 2007.

TSANG, Y. M.; POON, A. S. Y. Detecting human blockage and device movement in mmWave communication system. **IEEE Global Telecommunications Conference**. p. 1–6, 2011.

VA, V.; CHOI, J.; HEATH, R.W. The impact of beamwidth on temporal channel variation in vehicular channels and its implications. **IEEE Transactions on Vehicular Technology**. v.66, n. 6, p. 5014–5029, jun. 2017.

VA, V.; VIKALO, H.; HEATH, R. W. Beam tracking for mobile millimeter wave communication systems. **IEEE Global Conference on Signal and Information Processing (GlobalSIP)**. p. 743–747, 2016.

VENKATESWARAN, V.; VEEN, A.-J. Analog beamforming in MIMO communications with phase shift networks and online channel estimation. **IEEE Transactions on Signal Processing**. IEEE, v. 58, n. 8, p. 4131–4143, 2010.

WAN, E. A.; MERWE, R. V. D. The unscented Kalman filter for nonlinear estimation. **Proceedings of the IEEE Adaptive Systems for Signal Processing, Communications, and Control Symposium**. p. 153–158, 2000.

WANG, J. Beam codebook based beamforming protocol for multi-Gbps millimeter-wave WPAN systems. **IEEE Journal on Selected Areas in Communications**. IEEE, v. 27, n. 8, 2009.

WU, W.; LIU, D.; LI, Z.; HOU, X.; LIU, M. Two -stage 3D codebook design and beam training for millimeter -wave massive MIMO systems. **IEEE Vehicular Technology Conference (VTCSpring)**. p. 1–7, 2017

XIAO, M.; MUMTAZ, S.; HUANG, Y.; DAI, L.; LI, Y.; MATTHAIIOU ,M.; KARAGIANNIDIS ,G. K.; BJÖRNSON, E.; YANG, K.; I, C.L.; GHOSH ,A. Millimeter wave communications for future mobile networks. **IEEE Journal on Selected Areas in Communications**, v. 35, n. 9, p.1909 –1935, set. 2017.

YANG, D.; YANG, L.L.; HANZO, L. DFT-based beamforming weight-vector codebook design for spatially correlated channels in the unitary precoding aided multiuser downlink. **IEEE International Conference on Communications**. p. 1–5, 2010.

ZHANG, C.; GUO, D.; FAN, P. Tracking angles of departure and arrival in a mobile millimeter wave channel. **CoRR**. abs/1512.06383, 2015.

ZHOU, P.; CHENG, K.; HAN, X.; FANG, X.; FANG, Y.; HE, R.; LONG, Y.; LIU, Y. IEEE 802.11ay based mmwave WLANs: Design challenges and solutions. **IEEE Communications Surveys Tutorials**. p. 1–1, 2018.