

3º Workshop Brasil 

AVANÇOS DA PESQUISA RUMO AO 6G: CONNECTIVIDADE DO FUTURO EM CONSTRUÇÃO



Apoio:



Realização:



3º *Workshop Brasil*

Atividade 3.1 – Aplicações de visão computacional para verticais estratégicas

Aplicações de visão computacional em gerência de feixes para 6G

**Aldebaro Klautau
LASSE**

Universidade Federal do Pará / UFPA

Equipe da Atividade 3.1 no Projeto Brasil 6G



Alcides
Tomas
(Instituto Eldorado)



Aldebaro
Klautau
(UFPA)



Cristiano
Both
(Unisinos)



Felipe
Figueiredo
(Inatel)



Francine
Oliveira
(Instituto Eldorado)



Joanna
Manjarres
(UFRJ)



João
Borges
(UFPA)



José
Rezende
(UFRJ)



Matheus
Silva
(Inatel)

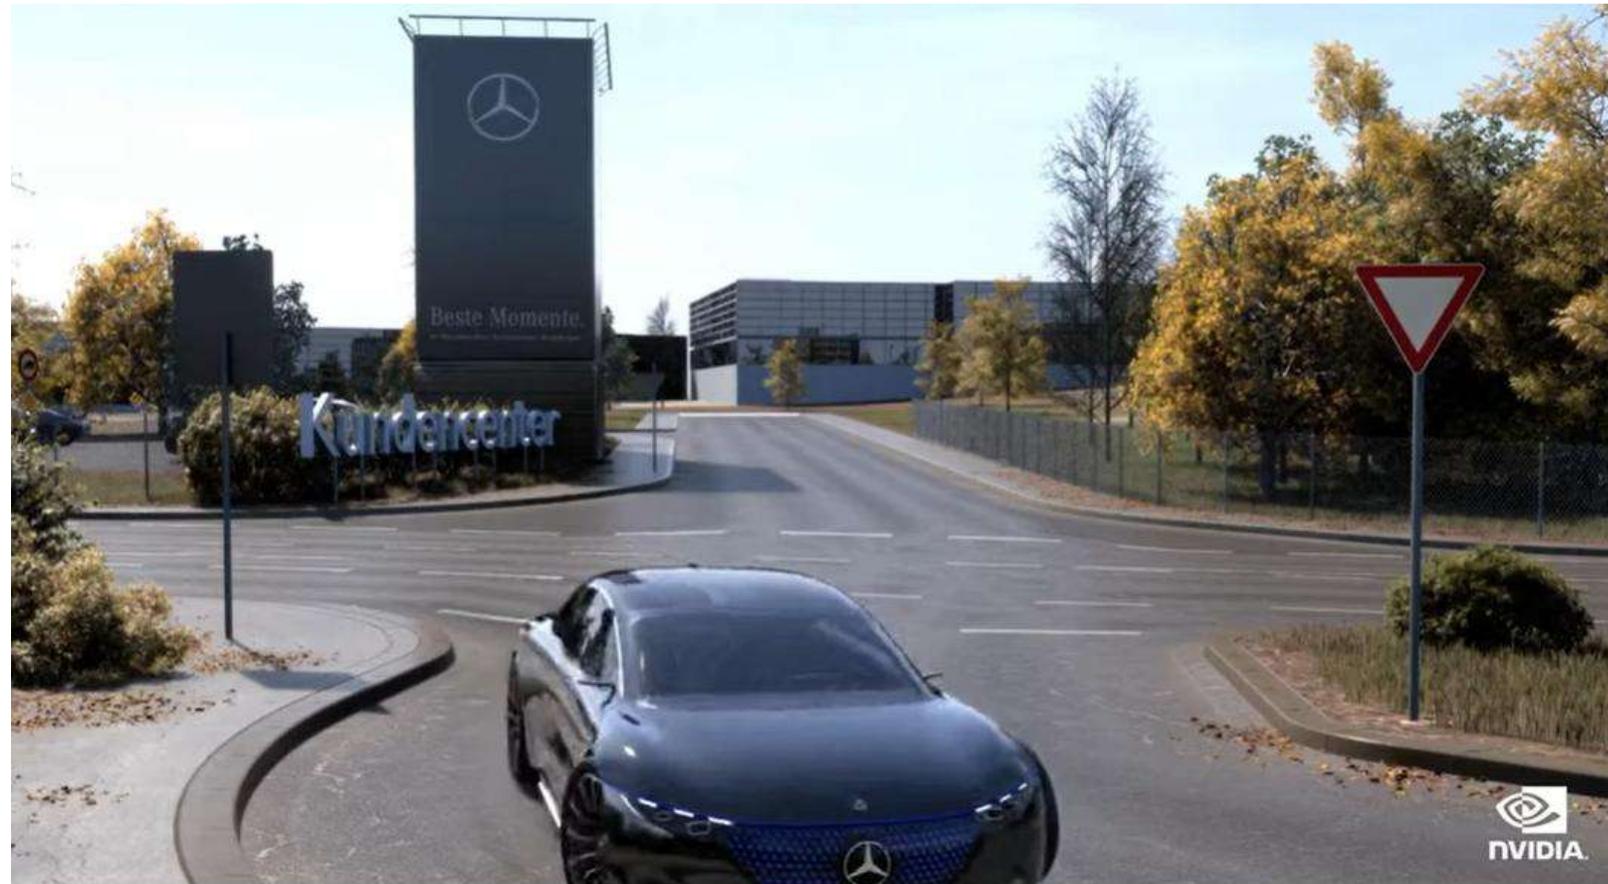


Vanessa
Rennó
(Inatel)



Wesley
Passos
(UFRJ)

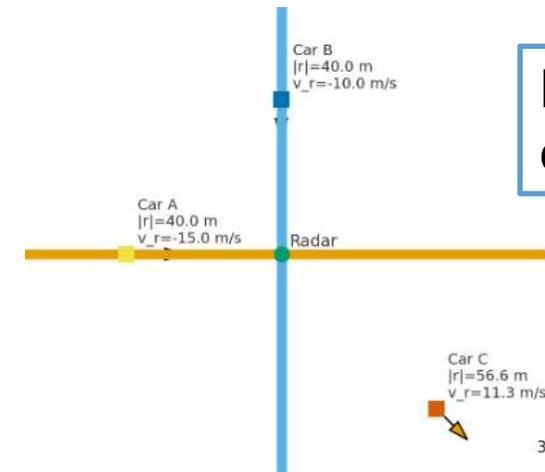
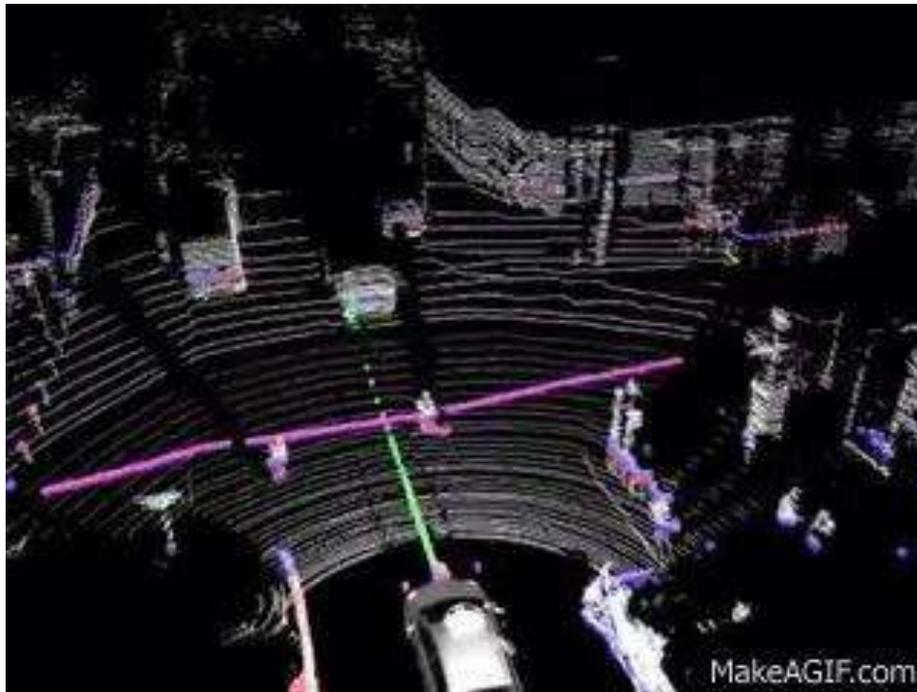
Aplicação de visão computacional em 6G: Veículos autônomos conectados



Nesta apresentação: como as técnicas de visão computacional + IA podem melhorar sistemas 6G? Uso versus suporte

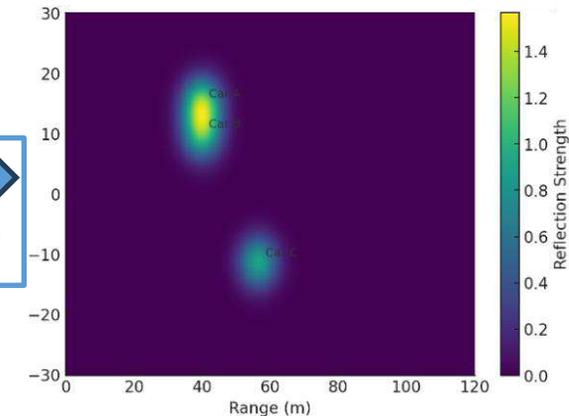
Visão computacional em 6G: ISAC ("Integrated Sensing and Communication")

Adoção de sensores como radar e LIDAR (Light Detection And Ranging)



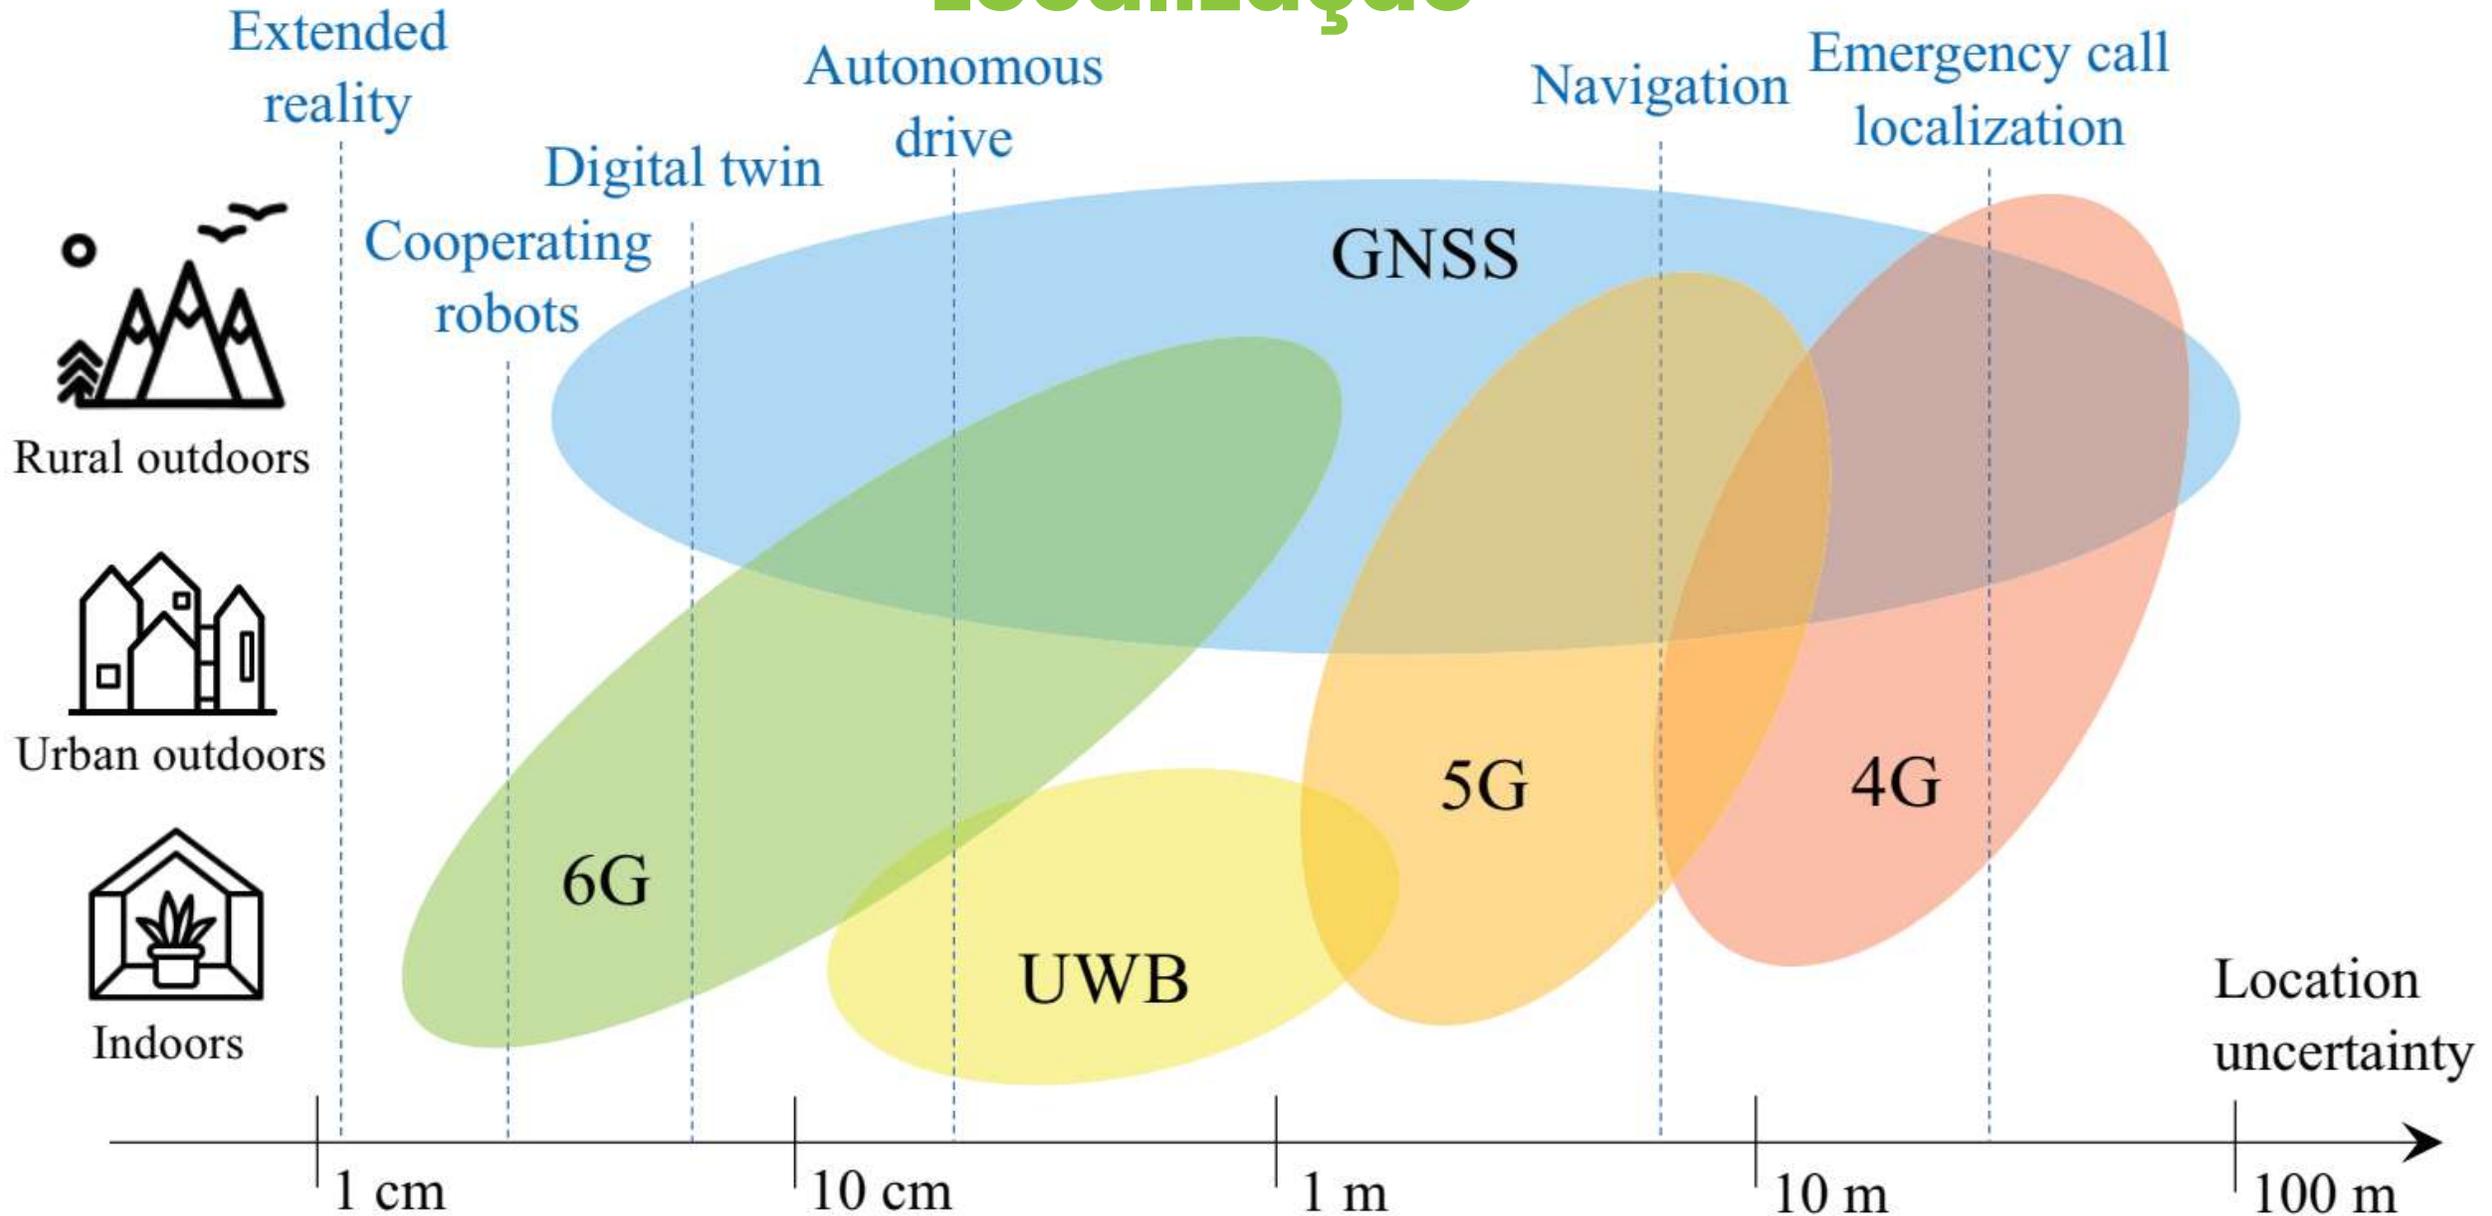
Exemplo com 3 carros e um radar

Radar: mapa alcance x Doppler



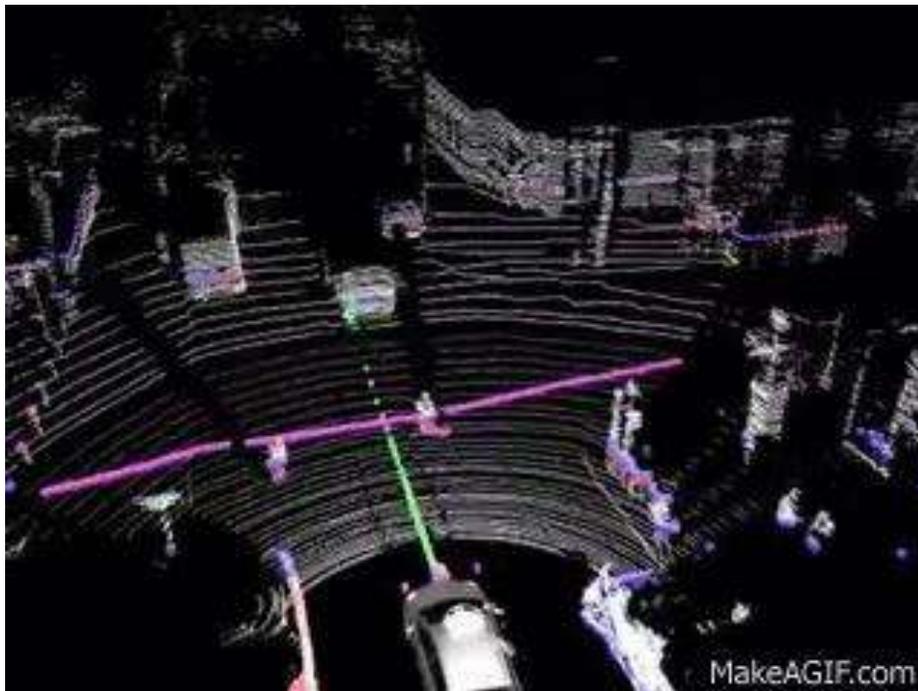
ISAC: desde apenas compartilhar infra-estrutura até usar os mesmos sinais para sensoriamento e comunicações

Localização



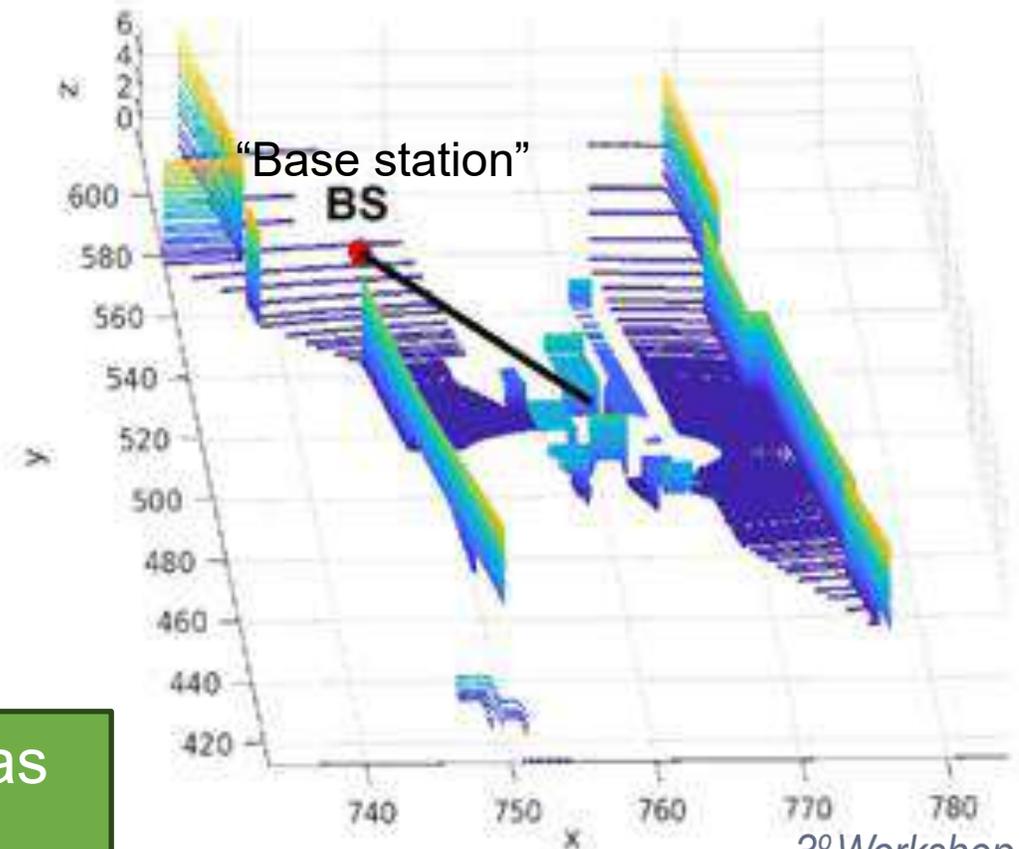
Representações do ambiente 3D a partir de dados de LIDAR

LIDAR no veículo



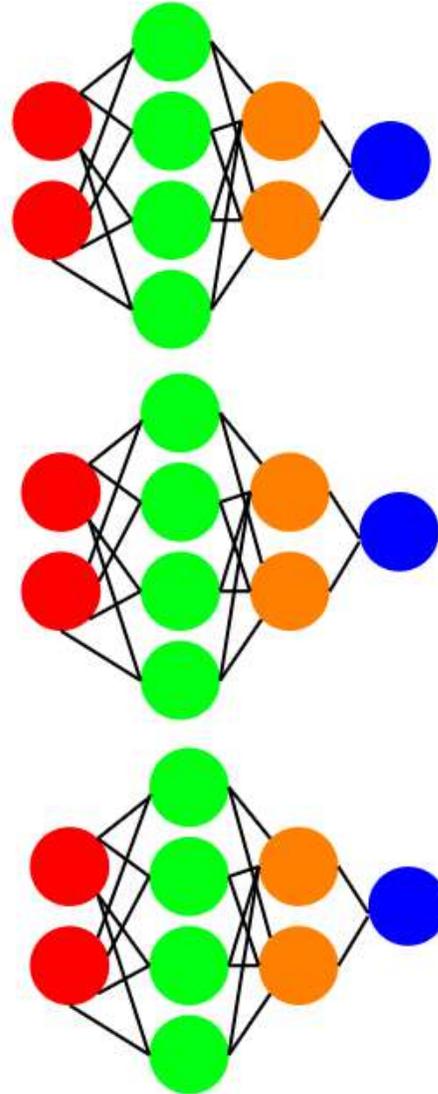
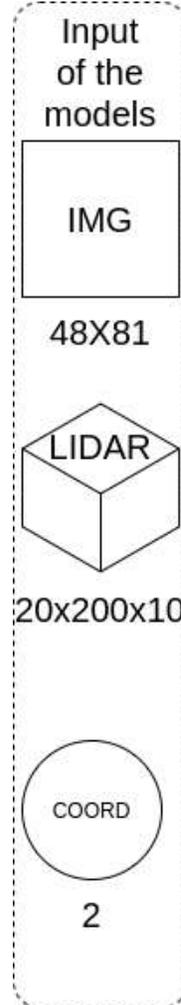
LIDAR é um sensor caro. Mais baratas são câmeras RGB convencionais

Representação obtida a partir do LIDAR permite discernir LoS (“*line of sight*”) versus NLoS, etc.



IA + visão computacional em 6G

Entrada:
dados
multimodais



Dense
RELU

0

1

2

...

255

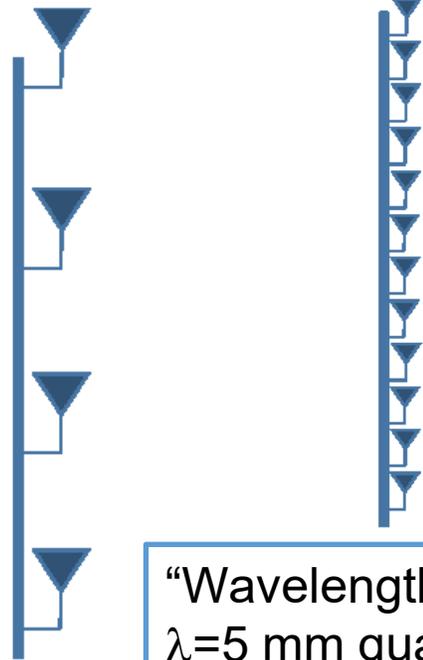
Saída:
informação
de interesse

Modelo: e.g., rede neural profunda

Gerência (seleção) de feixes em 6G

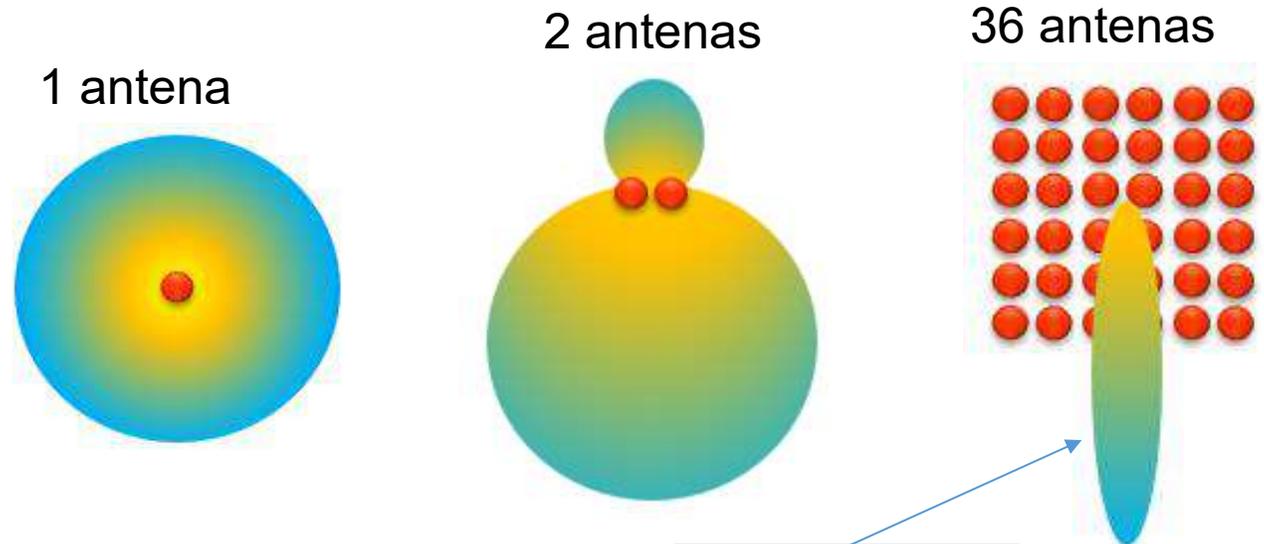
Tamanho do arranjo de antenas diminui com a frequência

Sub-6 GHz mmWave



“Wavelength” $\lambda = c/f$
 $\lambda = 5 \text{ mm}$ quando $f = 60 \text{ GHz}$
Espaço entre elementos de antena = $\lambda/2$

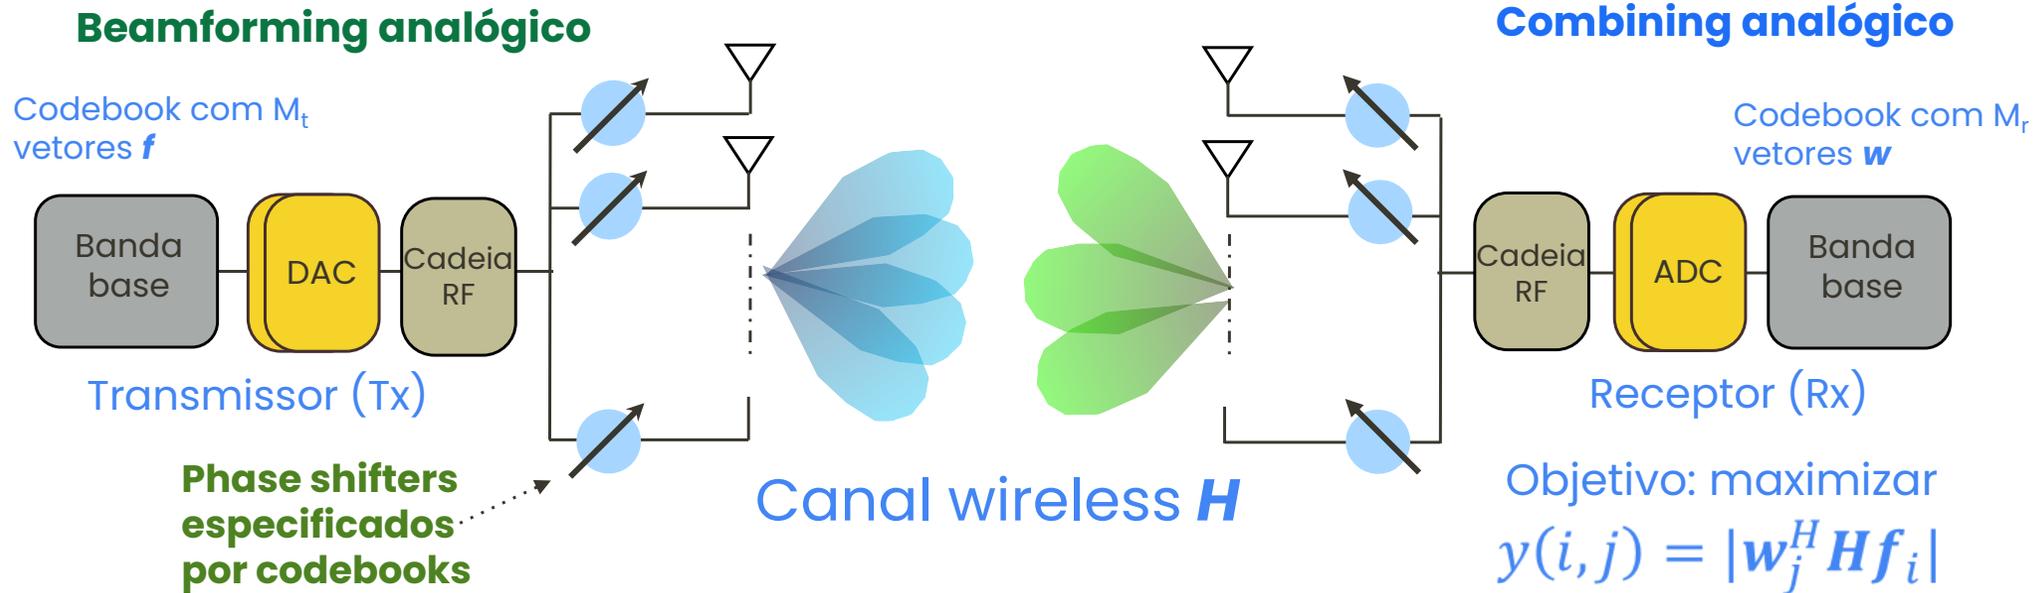
Padrão de radiação



“Beam” ou feixe

Introdução à seleção de feixes MIMO

Alinhar os feixes do transmissor e receptor



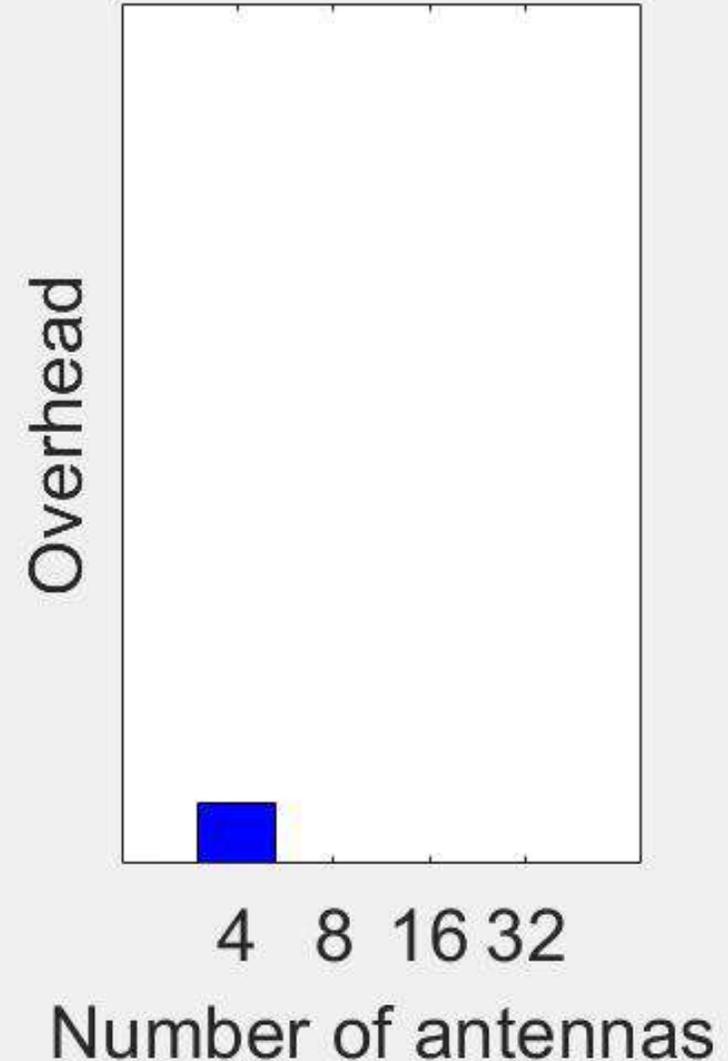
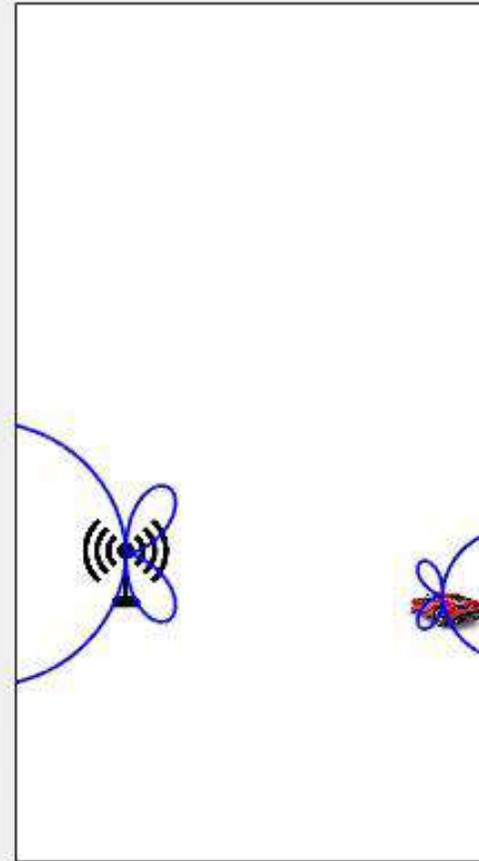
Força bruta para achar o melhores feixes: tentar todos os possíveis $M_t \times M_r$ pares de índices

[1] R. Heath, N. Gonzalez-Prelcic, S. Rangan, W. Roh and A. Sayeed, An Overview of Signal Processing Techniques for Millimeter Wave MIMO Systems, 2016

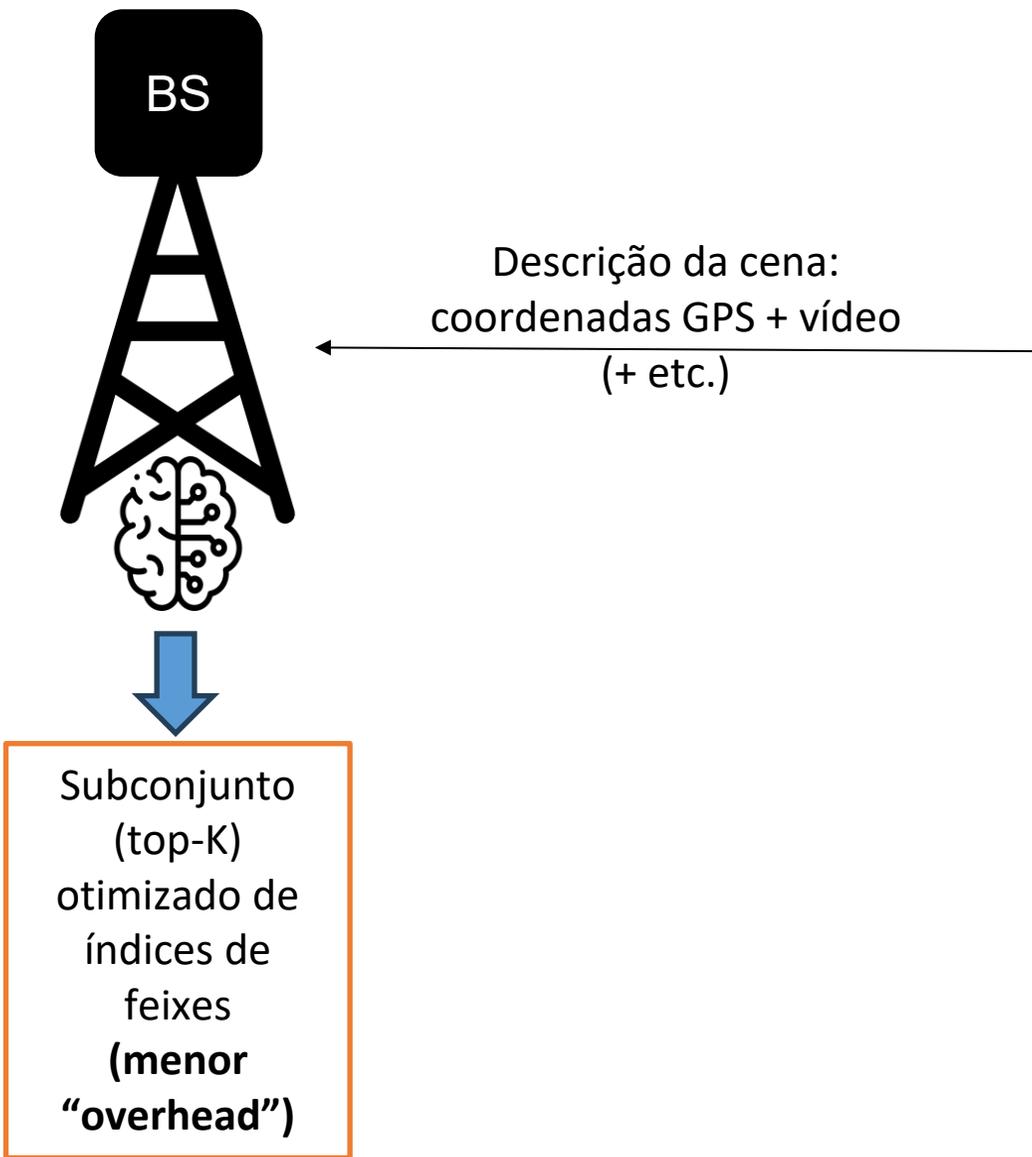
“Overhead” dos métodos convencionais aumenta com o número de antenas

Problema para “extremely large-scale massive MIMO” (XL-MIMO)

Visão computacional + IA podem escolher um subconjunto de (índices de) feixes candidatos



Uso de visão computacional + IA para reduzir o "overhead" em seleção de feixes



Resumo: visão computacional e IA para gerência de feixe nas redes 6G

- Assim como no 5G, é esperado que as redes 6G continuem a aproveitar altas frequências (por exemplo, do espectro **mmWave**) para comunicações wireless
- E para efetivamente usar tais frequências, processos como a **seleção de feixes** se tornam de suma importância para mitigar problemas como o alto desvanecimento (*high-fading*), aumentar alcance e diminuir interferência
- Atualmente, o método mais tradicional para seleção de feixes é baseado na transmissão de “sinais piloto”, o que gera um tráfego extra (**overhead**) na rede devido ao envio e recepção de pilotos durante o processo de refinamento da escolha do feixe
- Para lidar com esse problema, as *releases* mais recentes do 3GPP estão em busca de maneiras de aproveitar **dados multimodais** para auxiliar na redução de *overhead* de pilotos durante o processo de seleção de feixes

Projeto Brasil 6G na expansão do estado da arte em seleção de feixes no 6G: Método multimodal

- **Quatro esforços de pesquisa:**
 - a. Geração de bases de dados (“datasets”) rotulados e “baselines”
 - b. Busca de arquiteturas neurais aplicadas à seleção de feixes
 - c. Visão estérea para previsão de feixes
 - d. Visão computacional para estimação de propriedades eletromagnéticas do meio

<https://www.lasse.ufpa.br/raymobtime>

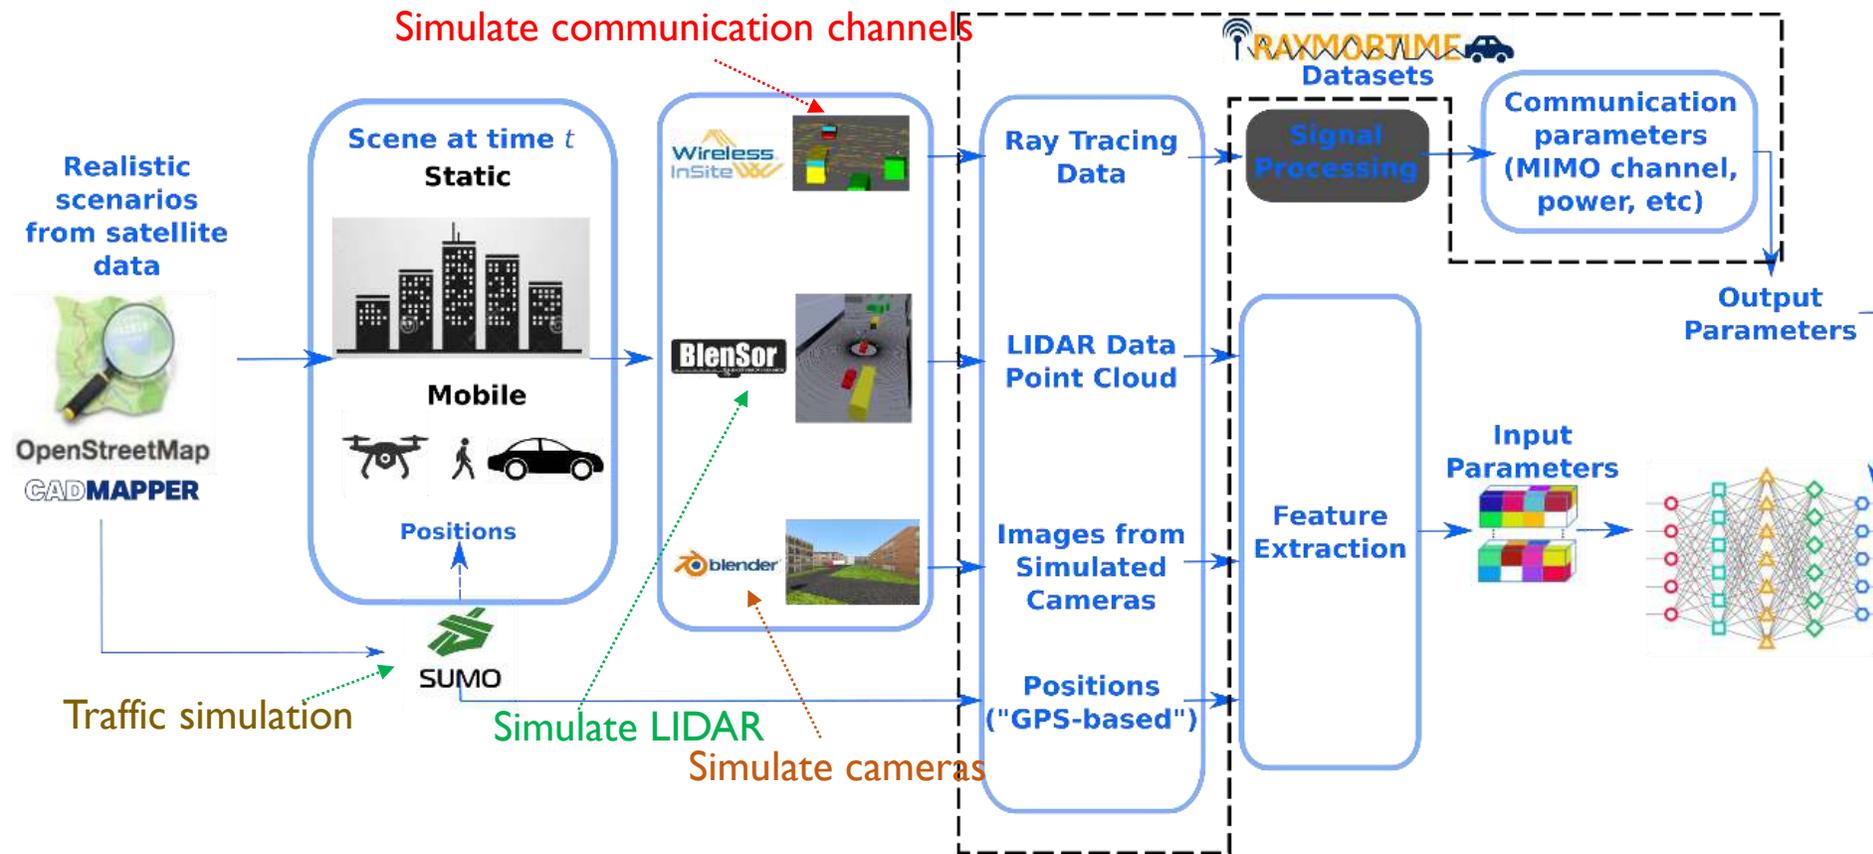
AVAILABLE MULTIMODAL DATASETS (RAY-TRACING + LIDAR + CAMERA IMAGES)

Dataset name	Wireless Insite Version	3D scenario	Frequency	Number of receivers and type	Time between scenes	Time between episodes	Number of episodes	Number of scenes per episode	Number of valid channels
s007	3.3	Beijing	2.8; 60 GHz	10 Mobile	1 s	5 s	50	40	15K
s008	3.2	Roslyn	60GHz	10 Mobile	0.1 s	30 s	2086	1	11K
s009	3.3	Roslyn	60GHz	10 Mobile	0.1 s	30 s	2000	1	10K

Geração de “datasets” rotulados, expandindo o Raymobtime e “baselines” usando algoritmos convencionais padronizados pelo 3GPP

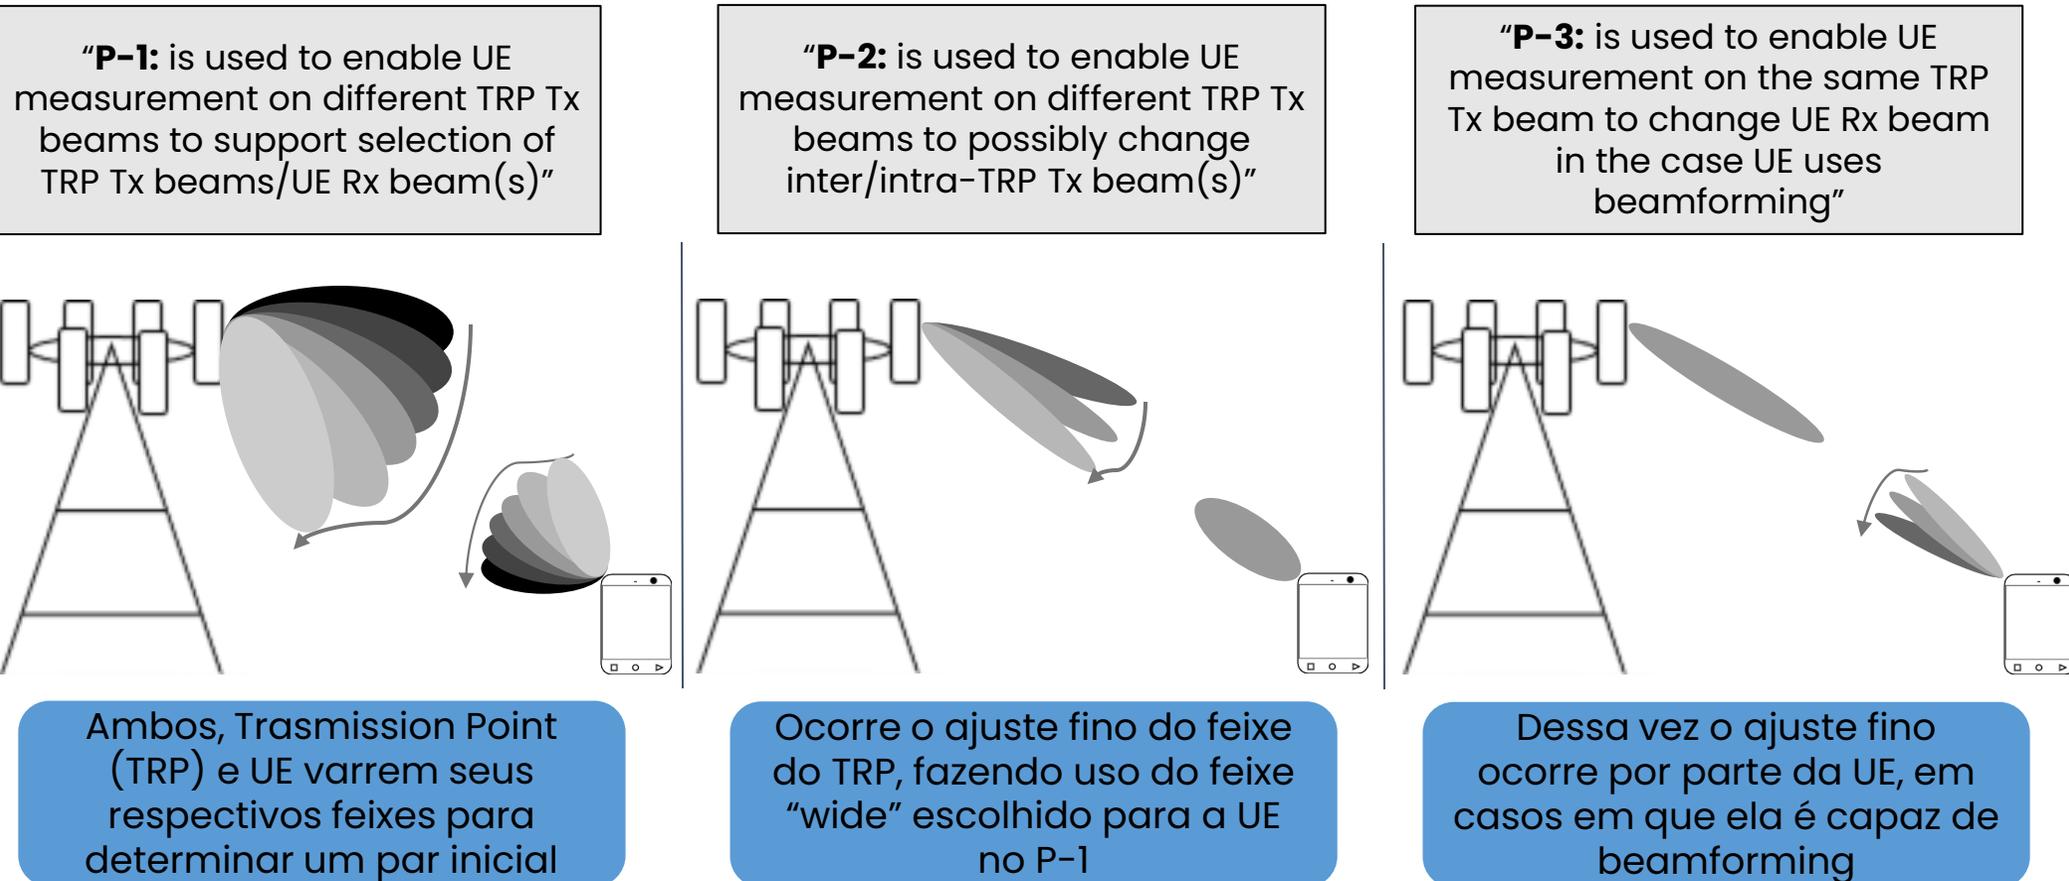
Líderes: UFPA e UNISINOS

Raymobtime: bases de dados rotulados



Raymobtime provê os canais "wireless" gerados com traçado de raios e a respectivas entradas multimodais para simulações com IA

O 3GPP especifica sinais pilotos e procedimentos padrões



3rd Generation Partnership Project (3GPP), "Study on New Radio Access Technology: Physical Layer Aspects (Release 14)," 3rd Generation Partnership Project (3GPP), 3GPP Technical Report TR 38.802 V14.2.0, September 2017, <https://portal.3gpp.org/desktopmodules/Specifications/SpecificationDetails.aspx?specificationId=3066>



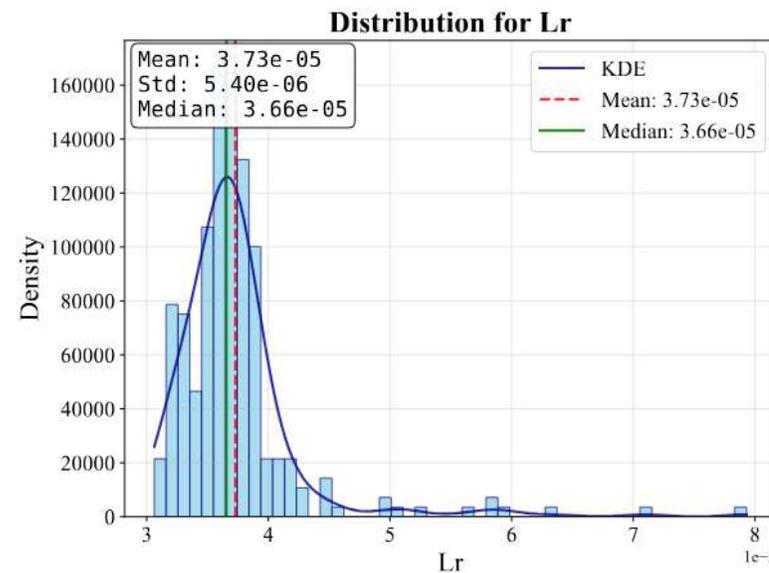
Busca de Arquiteturas Neurais Aplicadas à Seleção de Feixes

Líder: INATEL

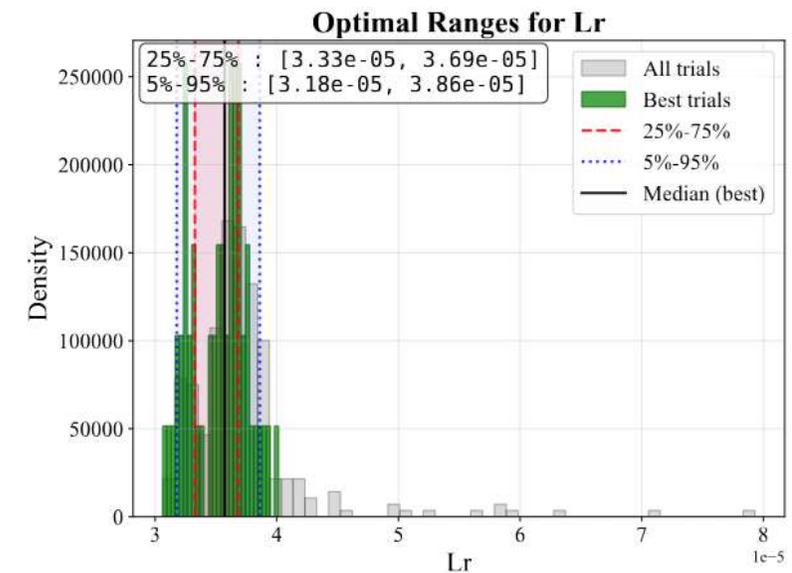
Neural Architecture Search (NAS): é uma técnica automatizada de aprendizado profundo que encontra arquiteturas ótimas de redes neurais para uma determinada tarefa, explorando um espaço de possíveis designs e avaliando seus desempenhos

Busca de Arquiteturas Neurais Aplicadas à Seleção de Feixes

- **Objetivo:** prever o top-K de pares TX-RX que maximizam potência, evitando busca exaustiva no “codebook”. Aplicar NAS para encontrar o melhor modelo



(a) Distribuição numérica do hiperparâmetro learningRate obtida no teste.



(b) Intervalos do hiperparâmetro learningRate observados no teste.

Figura 3: Distribuições e tendências do hiperparâmetro learningRate obtidas durante um teste.

Busca de Arquiteturas Neurais Aplicadas à Seleção de Feixes

- Buscar arquiteturas com NAS usando Optuna TPE (“Tree-structured Parzen Estimator” - optuna.readthedocs.io) para prever conjunto top-K
- Treinamento no dataset Raymobtime S008, 11.194 amostras, 6.482 LoS e 4.712 NLoS
- Validação no dataset Raymobtime S009, 9.638 amostras, 1.473 LoS e 8.165 NLoS
- Explorar pré-processamento e arquitetura, incluindo normalização de entradas, variantes Conv1D/2D/3D com diferentes profundidades, larguras e kernels, estratégias de “pooling”, cabeças densas, tamanhos de “batch”, funções de ativação, regularização, otimizadores, inicialização de pesos, “batch” normalization e “dropout”. Avaliar combinações de canais LiDAR e escaladores de atributos, além de políticas de learning rate
- Otimizar o compromisso entre acurácia top-K, latência de inferência e tamanho do modelo, considerando restrições de implantação

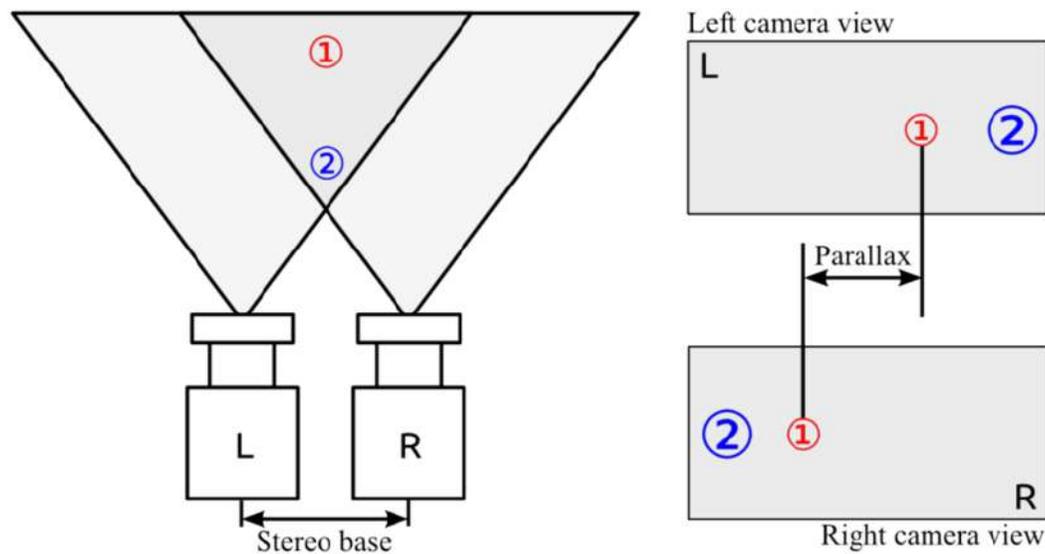


Visão estérea para previsão de feixes

Líder: UFRJ

Visão estérea para previsão de feixes

- A visão monocular (*single camera*) é limitada à inferência de profundidade com base em pistas visuais (oclusão, perspectiva), o que pode levar à incerteza em cenários urbanos complexos
- A visão estérea (duas câmeras na *base station*) permite calcular mapas de disparidade e estimar a profundidade precisa para cada pixel, obtendo uma reconstrução 3D em tempo real do ambiente
 - A *base station* não apenas “vê” os usuários, mas também conhece suas distâncias relativas e a geometria dos obstáculos, que são informações diretamente relevantes para a propagação do feixe.



Visão estérea para previsão de feixes

- A visão estérea permite a triangulação da posição 3D do usuário
 - a *base station* conhece a posição do array → calcula o ângulo de chegada esperado → restringe o espaço de busca do feixe
- O modelo aprende correlação direta entre distância, obstáculos e feixes disponíveis
 - Imagem estérea → mapa de profundidade (usando redes estéreas ou algoritmos clássicos como Semi-Global Matching) → CNN/Fusion Network → Índice de feixe ótimo
- A profundidade ajuda a resolver casos de NLOS estimando a distância do objeto bloqueador e sugerindo feixes alternativos (reflexões, difração)
 - Combina RGB + Profundidade (RGB-D) em arquiteturas multimodais (por exemplo, CNN + PointNet, Vision Transformer multimodal)



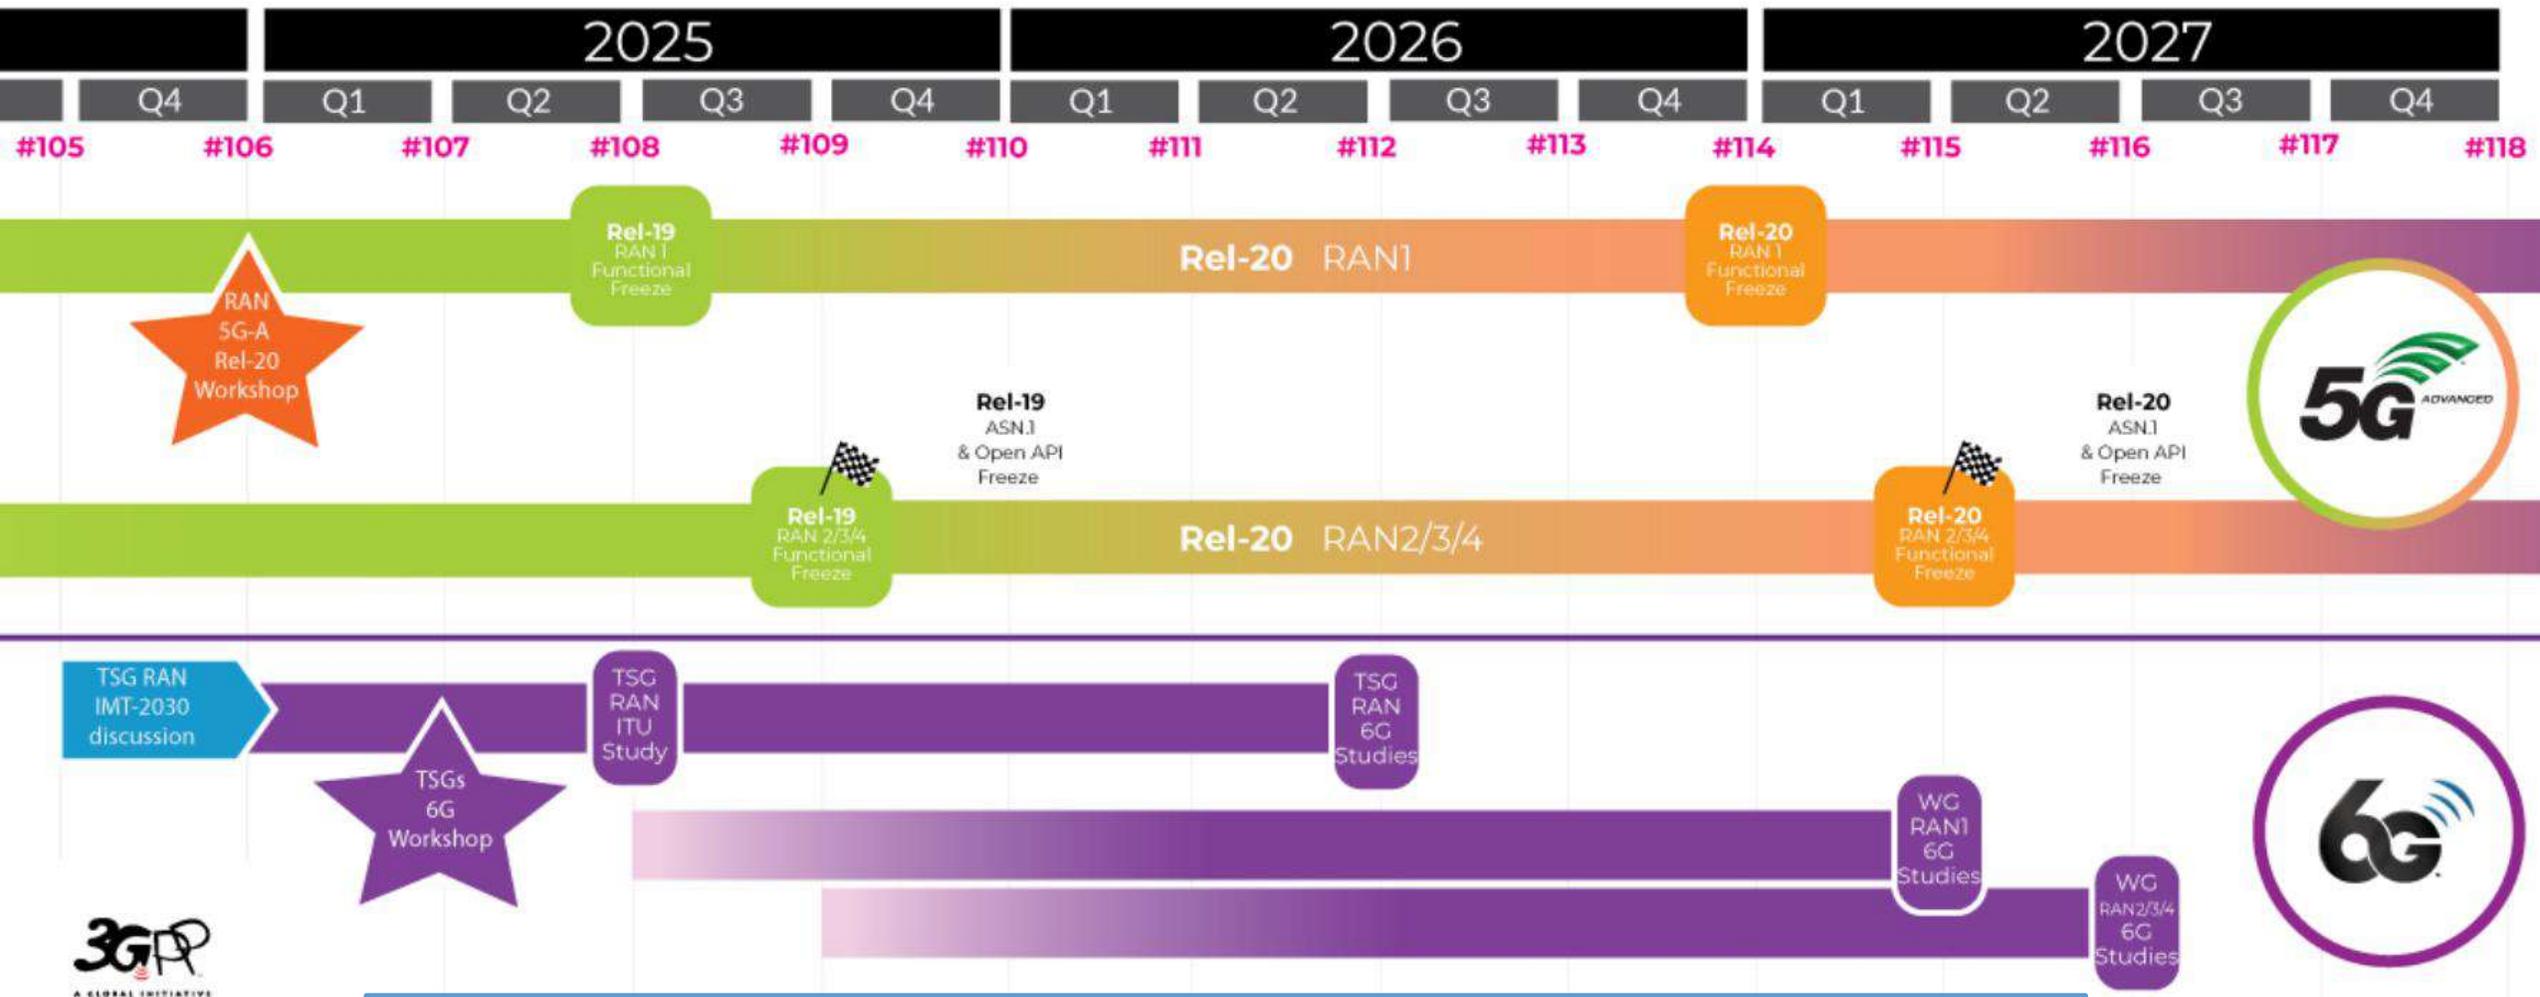
Visão computacional para estimação de propriedades eletromagnéticas do meio

Líder: UFRJ

Visão computacional para estimação de propriedades eletromagnéticas do meio

- Uso de visão computacional integrada com traçado de raios diferenciável
- Estimação de propriedades de materiais (permissividade, condutividade, etc.) a partir de imagens
- Simulações mais adaptáveis e realistas
- Otimização para algoritmos de comunicação em *near real time*
- Fundamento para gêmeos digitais (*digital twins*) em redes 6G

Contextualização da Atividade 3.1 do projeto Brasil 6G em relação às atividades no 3GPP



Das funcionalidades (“features”) propostas nos “study items” (SI) para o 6G investigados na Release 20 aos “working items” (WI) para o 6G da Release 21

Conclusão

- **As pesquisas do projeto Brasil 6G na Atividade 3.1 buscam contribuir com a academia e a indústria no uso de visão computacional e IA para aumento do desempenho das redes 6G, focando-se atualmente no gerenciamento de feixes**
- **Os resultados obtidos até o momento superam os disponíveis na literatura aberta, com as redes neurais treinadas pela equipe do Brasil 6G superando as reportadas em artigos**
- **Espera-se que os resultados passem a ser calibrados com os difundidos no âmbito do 3GPP, de modo que o impacto do projeto possa ser percebido no momento da padronização das funcionalidades do 6G na Release 21**
- **Com os algoritmos e modelos desenvolvidos no projeto Brasil 6G, almeja-se que as redes 6G sejam mais eficazes em termos de taxa, latência, robustez e consumo de energia**

3º Workshop Brasil 

Muito obrigado!

AVANÇOS DA PESQUISA RUMO AO 6G: CONNECTIVIDADE DO FUTURO EM CONSTRUÇÃO



Apoio:



Realização:

