



XII Congresso sobre Planeamento e Gestão das Zonas Costeiras



Amostragem adaptativa com AUV's usando descritores de regimes de temperatura

Pedro Marques Lobão

João Borges de Sousa · Renato Mendes

FEUP · LSTS · 2026

Ideia central: usar padrões históricos de temperatura para diminuir a incerteza no control de execução de AUV's.

Dos AUV's à exploração robótica guiada por modelos

A motivação geral é observar melhor o oceano costeiro; a motivação direta da tese vem do ciclo de model-driven robotic exploration.

Motivação geral para usar AUV's

1 Observação costeira de alta resolução

AUV's recolhem dados in situ de forma flexível e com menor pegada operacional.

2 Um único veículo raramente chega

Frentes, plumas e gradientes podem evoluir mais depressa do que a cobertura disponível.

3 Equipas como sensores distribuídos

Vários AUV's permitem cobertura mais útil, menos redundante e mais adequada a missões costeiras.


Fechar
o ciclo

Amostrar região
de maior valor

Motivação
do trabalho

Motivação direta — Mendes et al. (2025)

“Towards Ocean Model-Driven Robotic Exploration”: <https://tos.org/oceanography/article/toward-ocean-model-driven-robotic-exploration>




FRESNEL: ocean model + AUVs + assimilation in a tight control loop

previsão → incerteza → AUV → assimilação → nova previsão

Questão de planeamento: onde gastar tempo limitado de veículo para gerar dados úteis ao modelo?

Da amostragem fixa à amostragem adaptativa




Modelo → Planeamento → Amostragem → Atualização → Replaneamento

Neste trabalho, o foco está na fase de planeamento: como enriquecer o mapa que diz ao AUV onde deve ir.

Incerteza elevada não é o mesmo que estrutura térmica recorrente


Mapa de incerteza / STD



Mostra onde o produto do modelo tem maior dispersão.




Estrutura térmica recorrente



Uma fronteira recorrente pode ser informativa mesmo quando não coincide com o máximo de STD.

Pergunta: padrões históricos de temperatura podem complementar a incerteza no planeamento pré-missão?


A ideia: transformar memória histórica em mapas úteis para o planeamento



O contributo não é substituir o modelo oceânico nem o planeador de trajetória PCVRP existente

- O planner existente é mantido
- Mudamos apenas o mapa de recompensa usado no planeamento
- A validação avalia o comportamento das rotas

370 dias de temperatura produziram seis padrões espaciais recorrentes



370

Dias históricos

2023-10-28 → 2024-10-31

6


classes / protótipos de campo completo

30–107

Dias por classe

- Interpretação simples**
- Algumas classes têm fronteiras/regiões distintas
 - Outras são mais homogêneas
 - Os rótulos descrevem mapas completos, não células isoladas

Dos padrões históricos aos descritores de amostragem



Exemplo: proximidade à fronteira térmica

- A fronteira vem do protótipo histórico
- O descritor dá maior valor perto dessa fronteira
- O parâmetro de escala controla a largura da região atrativa

R — valor de recompensa atribuído a cada posição do mapa.

O planeador utiliza essa recompensa para procurar uma rota que maximize a recompensa recolhida, respeitando as restrições da missão.

STD + Descriptor → Reward

$$R = (1 - \alpha) \cdot \text{STD} + \alpha \cdot \text{Descriptor}$$

“α” controla a contribuição do descritor; o solver e as restrições continuam iguais.

Como testamos: comparação controlada de mapas de recompensa

Baseline **STD-only** vs. **Enriched** **STD + descritor do protótipo**

mesma data · mesma ROI · mesma duração · mesmo planner

C01 2024-08-24

boundary-rich

C06 2023-12-22



boundary-rich

C02 2024-10-30

single-gradient control

A variável que muda é apenas o mapa de recompensa: STD-only versus STD + descriptor.

Resultado 1: um pequeno descritor já muda a rota do AUV



Baseline STD-only

score 90.650 · rota 38.053 km

$C01 \cdot r1 \cdot \alpha = 0.25$


96.881

score de incerteza coletada

1.069

STD retention

Resultado 2: descritores podem incentivar amostragem complementar



Os mapas específicos por veículo encorajaram comportamentos distintos em classes com fronteiras/regiões.

Limite importante: as rotas foram resolvidas separadamente; isto ainda não é otimização multi-AUV conjunta.

Resultado 3: a abordagem não ajuda automaticamente em qualquer regime

OCTOBER CONTROL · C02

**protótipo de
gradiente único**

Neste regime, não existe uma separação complementar suficientemente clara para construir recompensas específicas por veículo.



Caso misto 25/75 com troca de papéis

0.974

retenção de STD

0.000

especialização

1.000

sobreposição

**Extremo “apenas descritor”:
duas execuções falharam
(recompensa máxima = 0).**

Otimizações separadas produziram trajetórias idênticas;
a coordenação não foi otimizada em conjunto.

Conclusão científica: o ganho dos descritores depende da estrutura do regime, do descritor utilizado e do peso escolhido.

O que fica desta apresentação

1

Há memória espacial útil nos campos históricos

Os 370 dias de temperatura permitiram identificar padrões recorrentes no Canhão da Nazaré.

2

Essa memória pode entrar no planeamento

Os protótipos foram convertidos em descritores compatíveis com o reward map do planner existente.

3

O efeito é condicional, mas promissor

Em classes boundary-rich houve mudança de rotas e amostragem complementar; no controlo, não.

Próximos passos

validar impacto na assimilação · testar mais datas/estações · otimização multi-AUV conjunta · replaneamento online

Obrigado

Questões?


Padrões térmicos recorrentes podem complementar mapas de incerteza e alterar o planeamento pré-missão dos AUVs — sem substituir o planner existente.

Demonstrámos alterações no planeamento; o impacto na assimilação e na previsão ainda necessita de validação



Pedro Marques Lobão
FEUP / LSTS

Backup: como os padrões foram aprendidos



Pipeline técnico

normalização dos campos de temperatura
 patches 40×24 e dictionary learning
 sparse codes como assinatura compacta
 feature standardisation
 Ward hierarchical clustering
 SD = 0.25 → seis classes

Os parâmetros foram escolhidos como compromisso entre reconstrução, capacidade e interpretabilidade.


Backup: equações de reward e normalização

Normalização min-max

$$M_{\text{norm}}(s) = [M(s) - M_{\text{min}}] / [M_{\text{max}} - M_{\text{min}}]$$

Single-AUV reward

$$R = (1 - \alpha) \cdot \text{USTD}_{\text{norm}} + \alpha \cdot D_{\text{norm}}$$



Os pesos moldam o reward; não são uma estimativa direta de redução de incerteza.

Backup: métricas usadas e limites da validação

Métricas


- STD collected score
- STD retention vs baseline
- descriptor response
- route overlap / Jaccard
- specialisation in two-AUV cases
- solver status and runtime

Limitações


- poucas datas e uma única ROI
- comportamento do planner, não impacto direto na assimilação
- two-AUV avaliado com solves separados
- sem anti-overlap objetivo
- descritores dependem da qualidade dos protótipos

Claim seguro: ponte reproduzível entre padrões espaciais recorrentes e reward-map shaping.

Backup: seleção de parâmetros não foi só otimização numérica



40x24 foi escolhido pela avaliação composta.



Dictionary size 4 foi mantido por capacidade, apesar de size 2 minimizar ICV médio.