

Qualification Round


EDITION 2026



Problem A

[5 points]

Um sistema de reconhecimento de som é desenvolvido através dos seis passos mostrados abaixo.




- Rotule cada passo como data collection, training, evaluation, deployment ou inference. Um passo pode ter mais de um rótulo.
- Durante quais passos o sistema está realmente aprendendo? Explique o que significa aprender aqui.

Problem B

[5 points]

Uma estufa controla o seu telhado com esta árvore de decisão:



- Que ação a árvore prevê quando a temperatura é 26 °C e a humidade é 68%?

- (b) Um novo sensor de CO₂ é instalado e o gestor começa a registar as condições juntamente com o que o telhado deveria ter feito:

Temperatura	Humidade	CO ₂	Telhado
31 °C	60%	700 ppm	ABRIR
26 °C	75%	650 ppm	ABRIR
25 °C	60%	800 ppm	MANTER FECHADO
27 °C	68%	1,100 ppm	MANTER FECHADO
24 °C	55%	1,400 ppm	ABRIR
22 °C	50%	1,550 ppm	ABRIR

Ajusta a árvore de decisão para que ela modele corretamente cada observação no registo.

Problem C

[5 points]

Um modelo prevê y a partir de x . Os dados de treinamento são:

x	0	1	2	3
y	1	3.2	4.8	7

Dois modelos são propostos:

$$M_1(x) = 0.2x^3 - 0.9x^2 + 2.9x + 1, \quad M_2(x) = 2x + 1.$$

Os modelos são pontuados usando

$$J = \sum (y - \hat{y})^2 + \lambda \sum_i a_i^2,$$

onde o segundo somatório percorre os coeficientes do modelo para x , x^2 e x^3 .

- (a) Para $\lambda = 1$, calcule a pontuação J para cada modelo. Qual modelo a regra de pontuação seleciona?
- (b) Qual modelo se ajusta melhor aos dados de treinamento? Explique por que a pontuação J seleciona o outro modelo de qualquer forma, e para que serve o termo $\lambda \sum_i a_i^2$.

Problem D

[5 points]

Um modelo de linguagem é treinado para maximizar uma recompensa fixa, de modo que suas saídas correspondam melhor a qualidades desejadas, como ser útil e estar alinhado com as preferências humanas. Sem uma restrição, no entanto, o modelo pode sofrer um drift longe de seu ponto de partida confiável, o modelo de referência, e aprender a manipular a recompensa em vez de produzir respostas genuinamente boas.¹

¹Esta é uma explicação simplificada de RLHF (reinforcement learning from human feedback). Para uma introdução, veja por exemplo <https://huggingface.co/blog/rlhf>.

Seja $t \geq 0$ a medida do drift em relação ao modelo de referência. Suponha que a recompensa seja rt e a penalidade de drift seja βt^2 , com $r, \beta > 0$. A perda resultante é

$$L(t) = -rt + \beta t^2.$$

e o treinamento escolhe o valor de t que a minimiza. Em sistemas reais, o drift é tipicamente medido usando a divergência KL; aqui usamos t^2 por simplicidade.

- Encontre o deslocamento t^* que minimiza a perda e o valor da perda que ele alcança.
- O que acontece com t^* quando $\beta \rightarrow 0$ e quando $\beta \rightarrow \infty$? Explique em uma ou duas frases o que cada caso significa para o modelo de linguagem.
- A estimativa de recompensa r é ruidosa: os engenheiros sabem apenas que $0 < r \leq r_{\max}$. Eles exigem que o deslocamento permaneça abaixo de um limite de segurança T , não importa qual seja o valor de r . Mostre que isso é garantido exatamente quando $\beta \geq \frac{r_{\max}}{2T}$.
- O que o termo $\lambda \sum_i a_i^2$ do Problema C tem em comum com o termo de penalidade βt^2 aqui?

Problem E

[5 points]

Uma organização quer introduzir um sistema de machine learning para agricultores no Nepal rural. Um agricultor fornece informações sobre uma plantação e o sistema recomenda se deve irrigar, aplicar um tratamento, esperar ou contactar um especialista. A organização quer implementar um modelo de linguagem de grande escala (LLM) pronto a usar, como o ChatGPT, Claude ou Gemini. Discute três oportunidades e três riscos de introduzir este sistema.



Instruções de Participação

- ✓ Escreve as tuas soluções à mão em folhas de papel ou digita-as num computador.
- ✓ Envia as tuas soluções online até ao prazo indicado no website.
Website: <https://imlco.org/submission>
- ✓ Não precisas de incluir o enunciado dos problemas no teu documento de solução.
- ✓ Mostra o teu raciocínio para receberes a pontuação máxima. Pontuação máxima: 25.
- ✓ Identifica claramente cada problema e destaca as tuas respostas finais.
- ✓ Precisas de marcar pelo menos 15/17/20 pontos como Junior/Youth/Senior para te qualificares

para a Pre-Final Round. Consulta <https://imlco.org/age-groups> para mais detalhes.

✓ Se tiveres dúvidas, entra em contacto connosco através de: info@imlco.org