

DE MODELOS DE CAIXA PRETA A MODELOS TRANSPARENTES: PROGRAMAÇÃO GENÉTICA CARTESIANA NA ANÁLISE DE IMAGENS BIOMÉDICAS



Yuri Lavinias
University Toulouse Capitole

YURI LAVINAS, QUEM????



Graduação - Ciência da Computação, Universidade de Brasília, Brasil, 2016

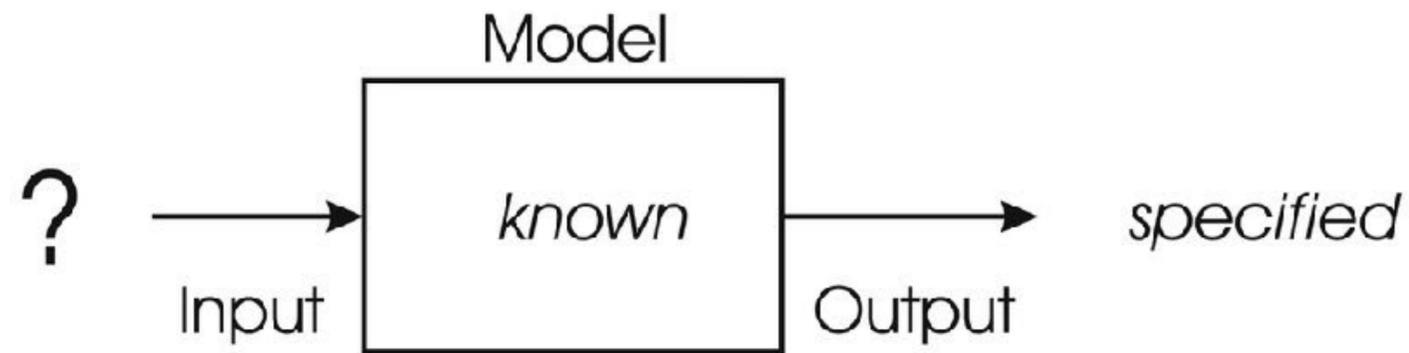
Mestrado e Doutorado - Engenharia, Universidade de Tsukuba, Japão - Algoritmos Evolutivos Multiobjetivos - 2018/2023

Pós-doutorado - Programação Genética Cartesiana para Dados de Saúde, França, 2023/24

Professor Associado - Universidade de Toulouse Capitole/IRIT, Toulouse, França, 2024~



MODELOS



Mineração de dados e aprendizado de máquina

Para encontrar um modelo do mundo que corresponda à nossa experiência anterior

Modelos de caixa preta

Nenhum conhecimento de seu funcionamento interno

Oposto (caixa branca)

Componentes internos ou lógica estão disponíveis para inspeção

Espaço de busca

Todos os modelos que descrevem o fenômeno

Produz a saída correta para cada entrada

ALGORITMOS EVOLUTIVOS

Evolution		Problem solving
Environment	↔	Problem
Individual	↔	Candidate solution
Fitness	↔	Quality

Ao olhar para a natureza e como ela acha “soluções para os problemas”:

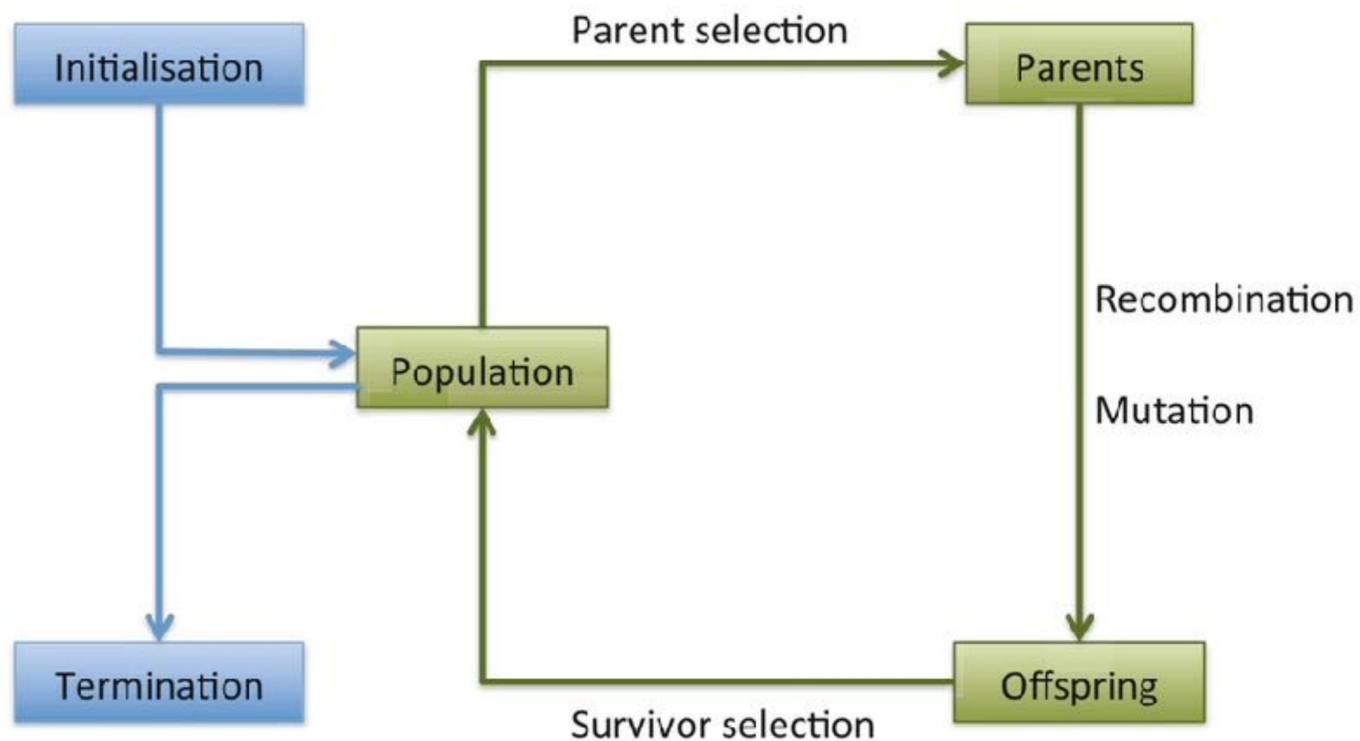
- O cérebro humano: que criou grandes coisas —> computação neural (redes neurais,...)
- Evolução: que criou o cérebro humano —> algoritmos genéticos, prog genético.

Algoritmos Evolutivos:

Baseado em ideias da evolução natural/evolução darwiniana

Seleção, fitness, variação (crossover/mutação)

COMO EVOLUÇÃO FUNCIONA?



```
BEGIN
  INITIALISE population with random candidate solutions;
  EVALUATE each candidate;
  REPEAT UNTIL ( TERMINATION CONDITION is satisfied ) DO
    1 SELECT parents;
    2 RECOMBINE pairs of parents;
    3 MUTATE the resulting offspring;
    4 EVALUATE new candidates;
    5 SELECT individuals for the next generation;
  OD
END
```

Componentes principais:

- Representação (definição de indivíduos)
Estruturas de dados: matrizes, árvores, gráficos...
- Função de avaliação (ou função de condicionamento físico)
O indivíduo mais apto é considerado a solução para o problema
- População
- Mecanismo de seleção dos pais
- Operadores de variação, crossover e mutação
- Mecanismo de seleção de sobreviventes (substituição)



CARTESIAN GENETIC PROGRAMMING

O QUE É GP?

Um Algoritmo Evolutivo

Tradicionalmente usado com árvores de análise

Método para a síntese de programas de computador

Cria programas com base em funções/operadores predefinidos

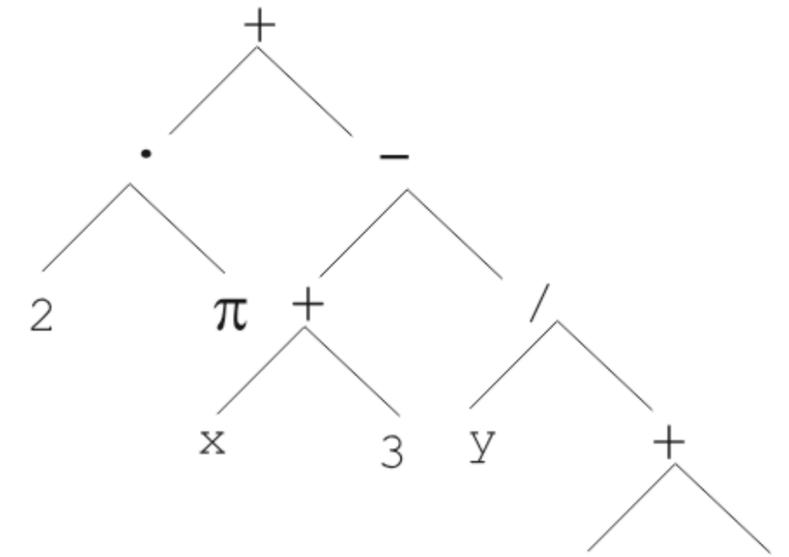
Seleção humana e um bom conjunto de funções faz toda grande diferença

Árvore GP - 1990

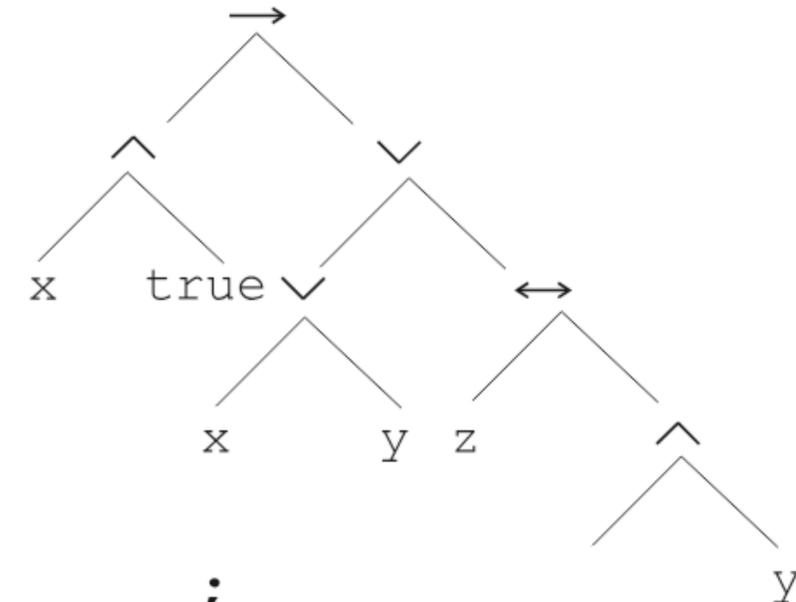
GP Linear - 1993

CGP - 1999

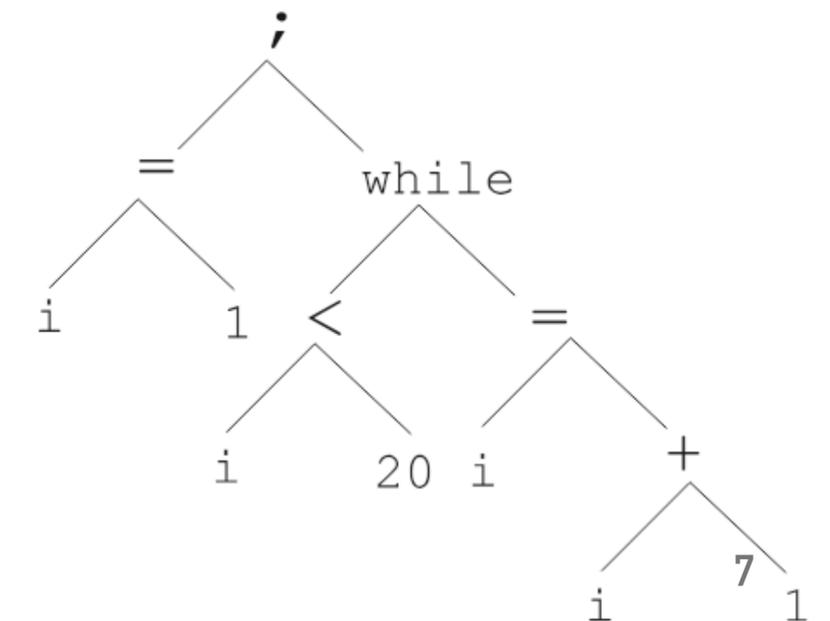
$$2 \cdot \pi + ((x + 3) - \frac{y}{5 + 1}),$$



$$(x \wedge true) \rightarrow ((x \vee y) \vee (z \leftrightarrow (x \wedge y))),$$



```
i = 1;  
while (i < 20)  
{  
    i = i+1;  
}
```



L/C/TREE/PUSH/GRAMMAR-GP

Alfabeto de GPs: “Uma GP por estrutura de dados”

Tree (Árvore) GP (1)

GraphGP: GP linear, GP cartesiano... (2)

Pilha: stackGP, pushGP

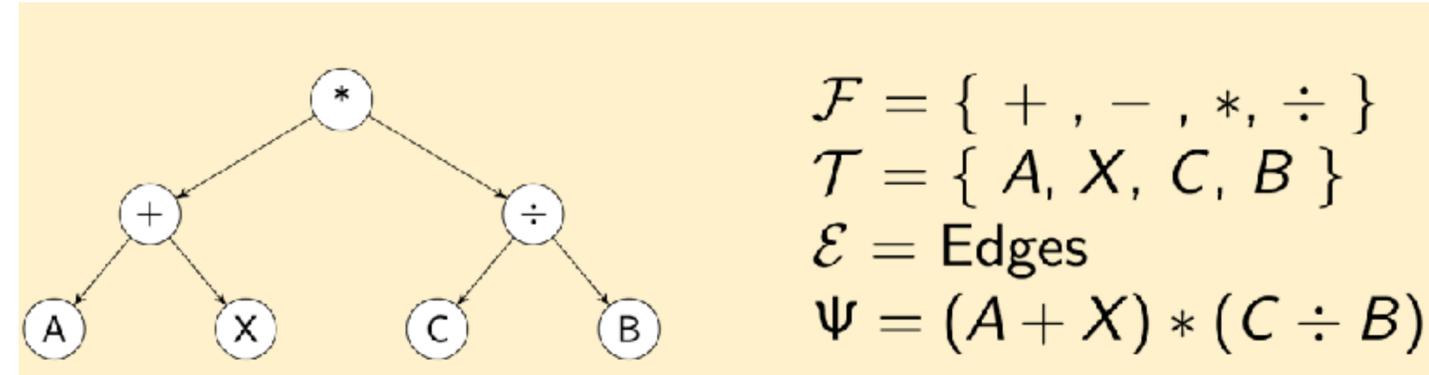
Gramática: ponyGE (3)

Qual é “melhor”?

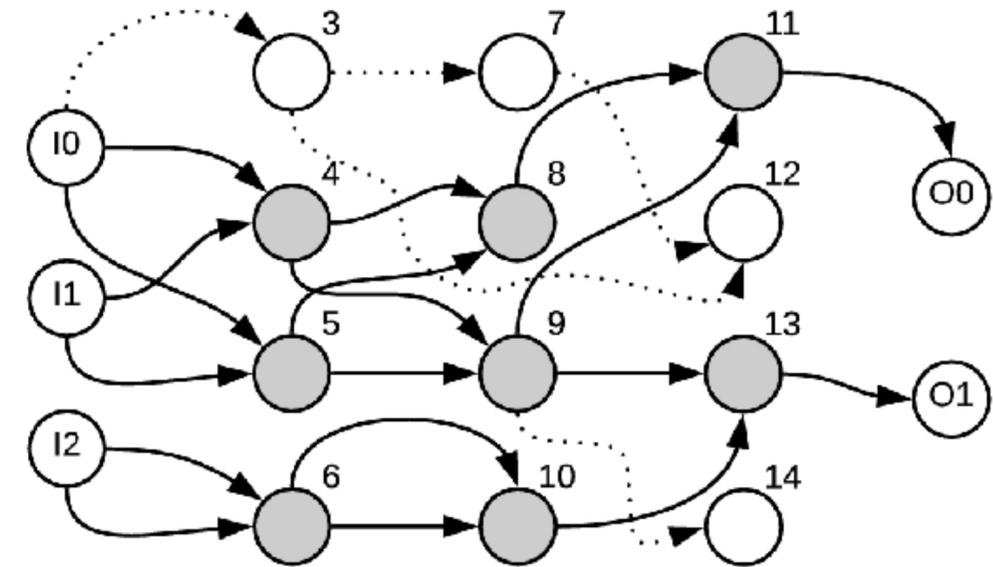
Diferentes representações levam à exploração de diferentes espaços de pesquisa

Dependente do problema

(1)



(2)



(3)

1: $r[3] = r[0] \text{ XOR } r[1]$
2: $r[4] = r[0] \text{ AND } r[1]$
3: $r[5] = r[2] \text{ AND } r[3]$
4: $r[6] = r[3] \text{ AND } 1.0$
5: $r[0] = r[5] \text{ OR } r[4]$
6: $r[1] = r[2] \text{ XOR } r[3]$

PROBLEMAS COM O ALFABETO

Cada GP tem suas limitações:

Tree GP, por exemplo: bloat (inchaço)

CGP, por exemplo: sem crossover

Nós nos tornamos especialistas em
“apenas um”

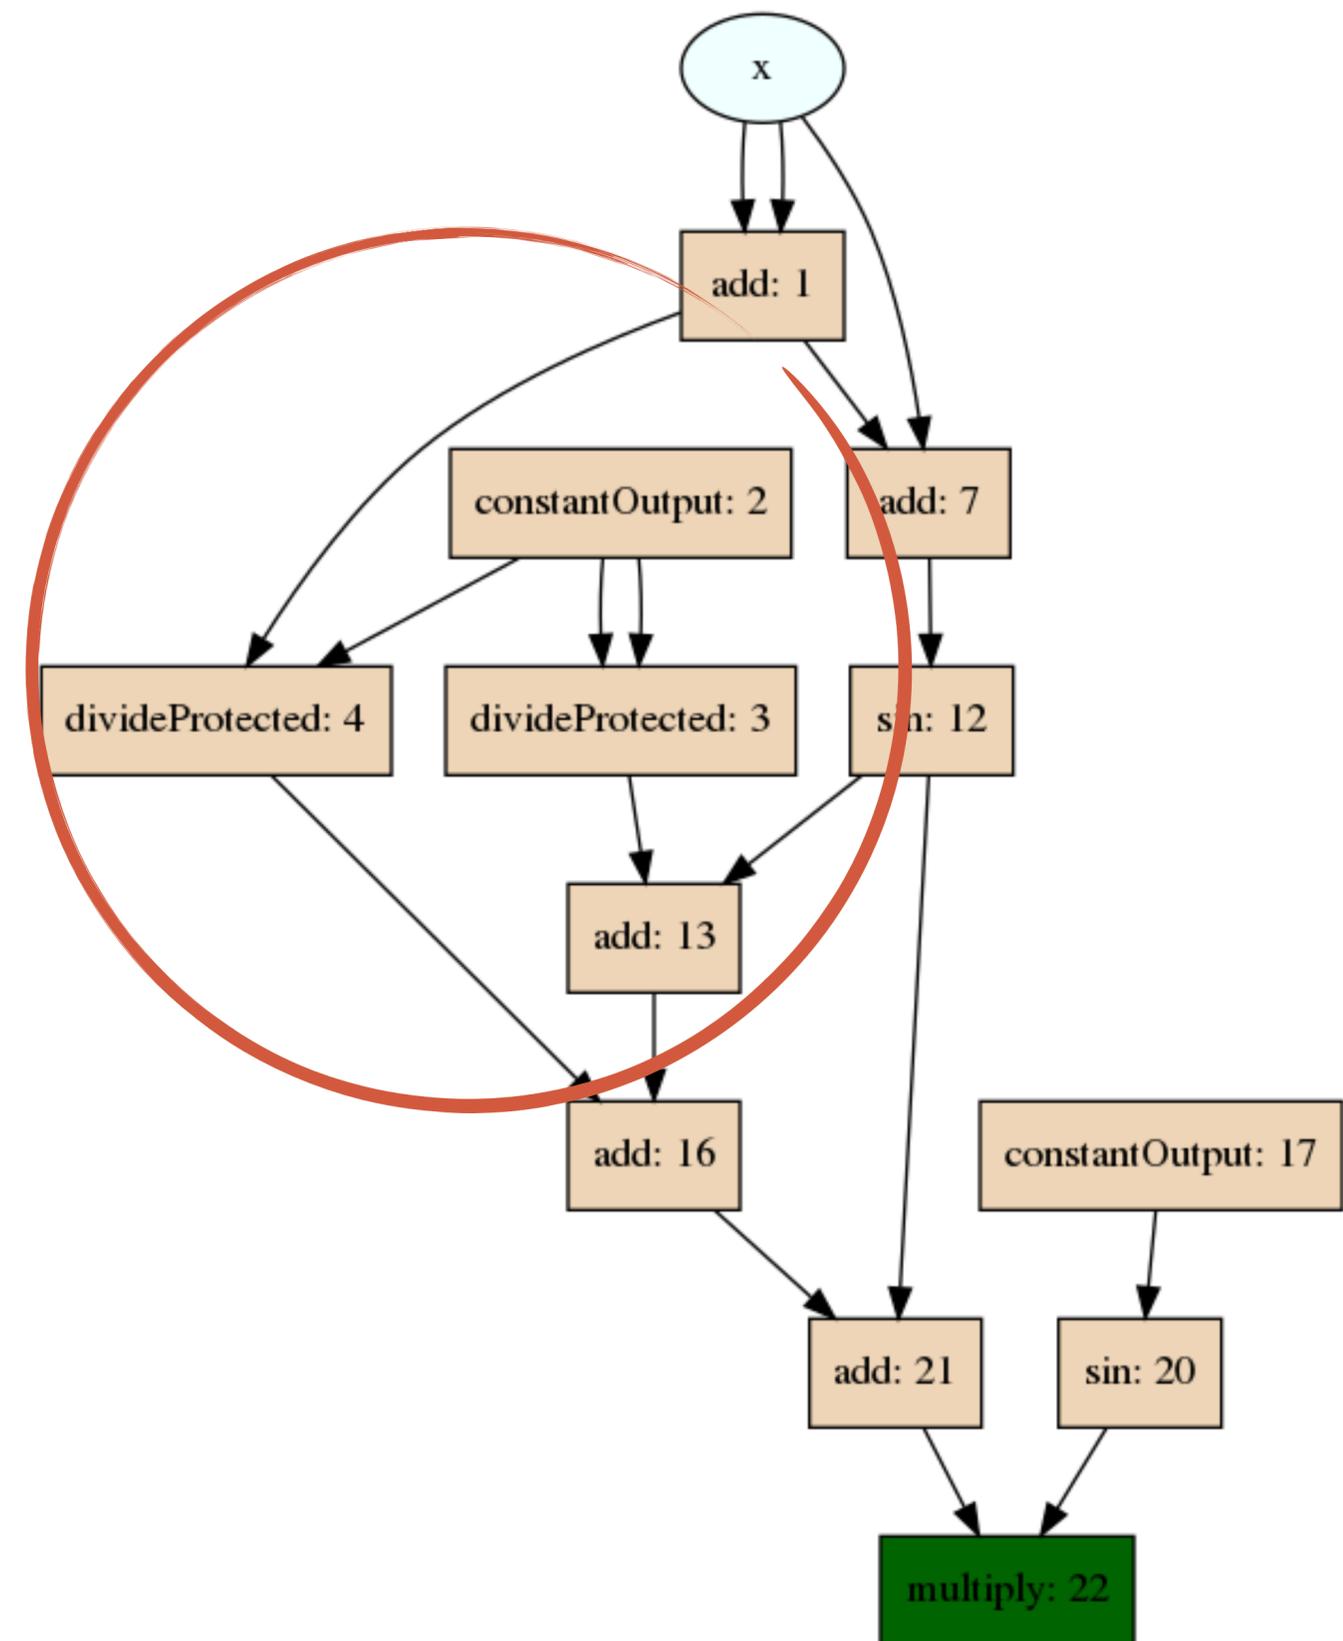
Estado da arte, hiperparâmetros...

Mas cada GP têm seus benefícios:

CGP

Reutilização/modularidade

Várias entradas e saídas



COMO CGP FUNCIONA?

Representa programas genéticos como uma grade bidimensional

Primitivos do programa

Vagamente inspirado na arquitetura dos circuitos digitais

Genoma de comprimento fixo

Cada gene tem tamanho dado por:

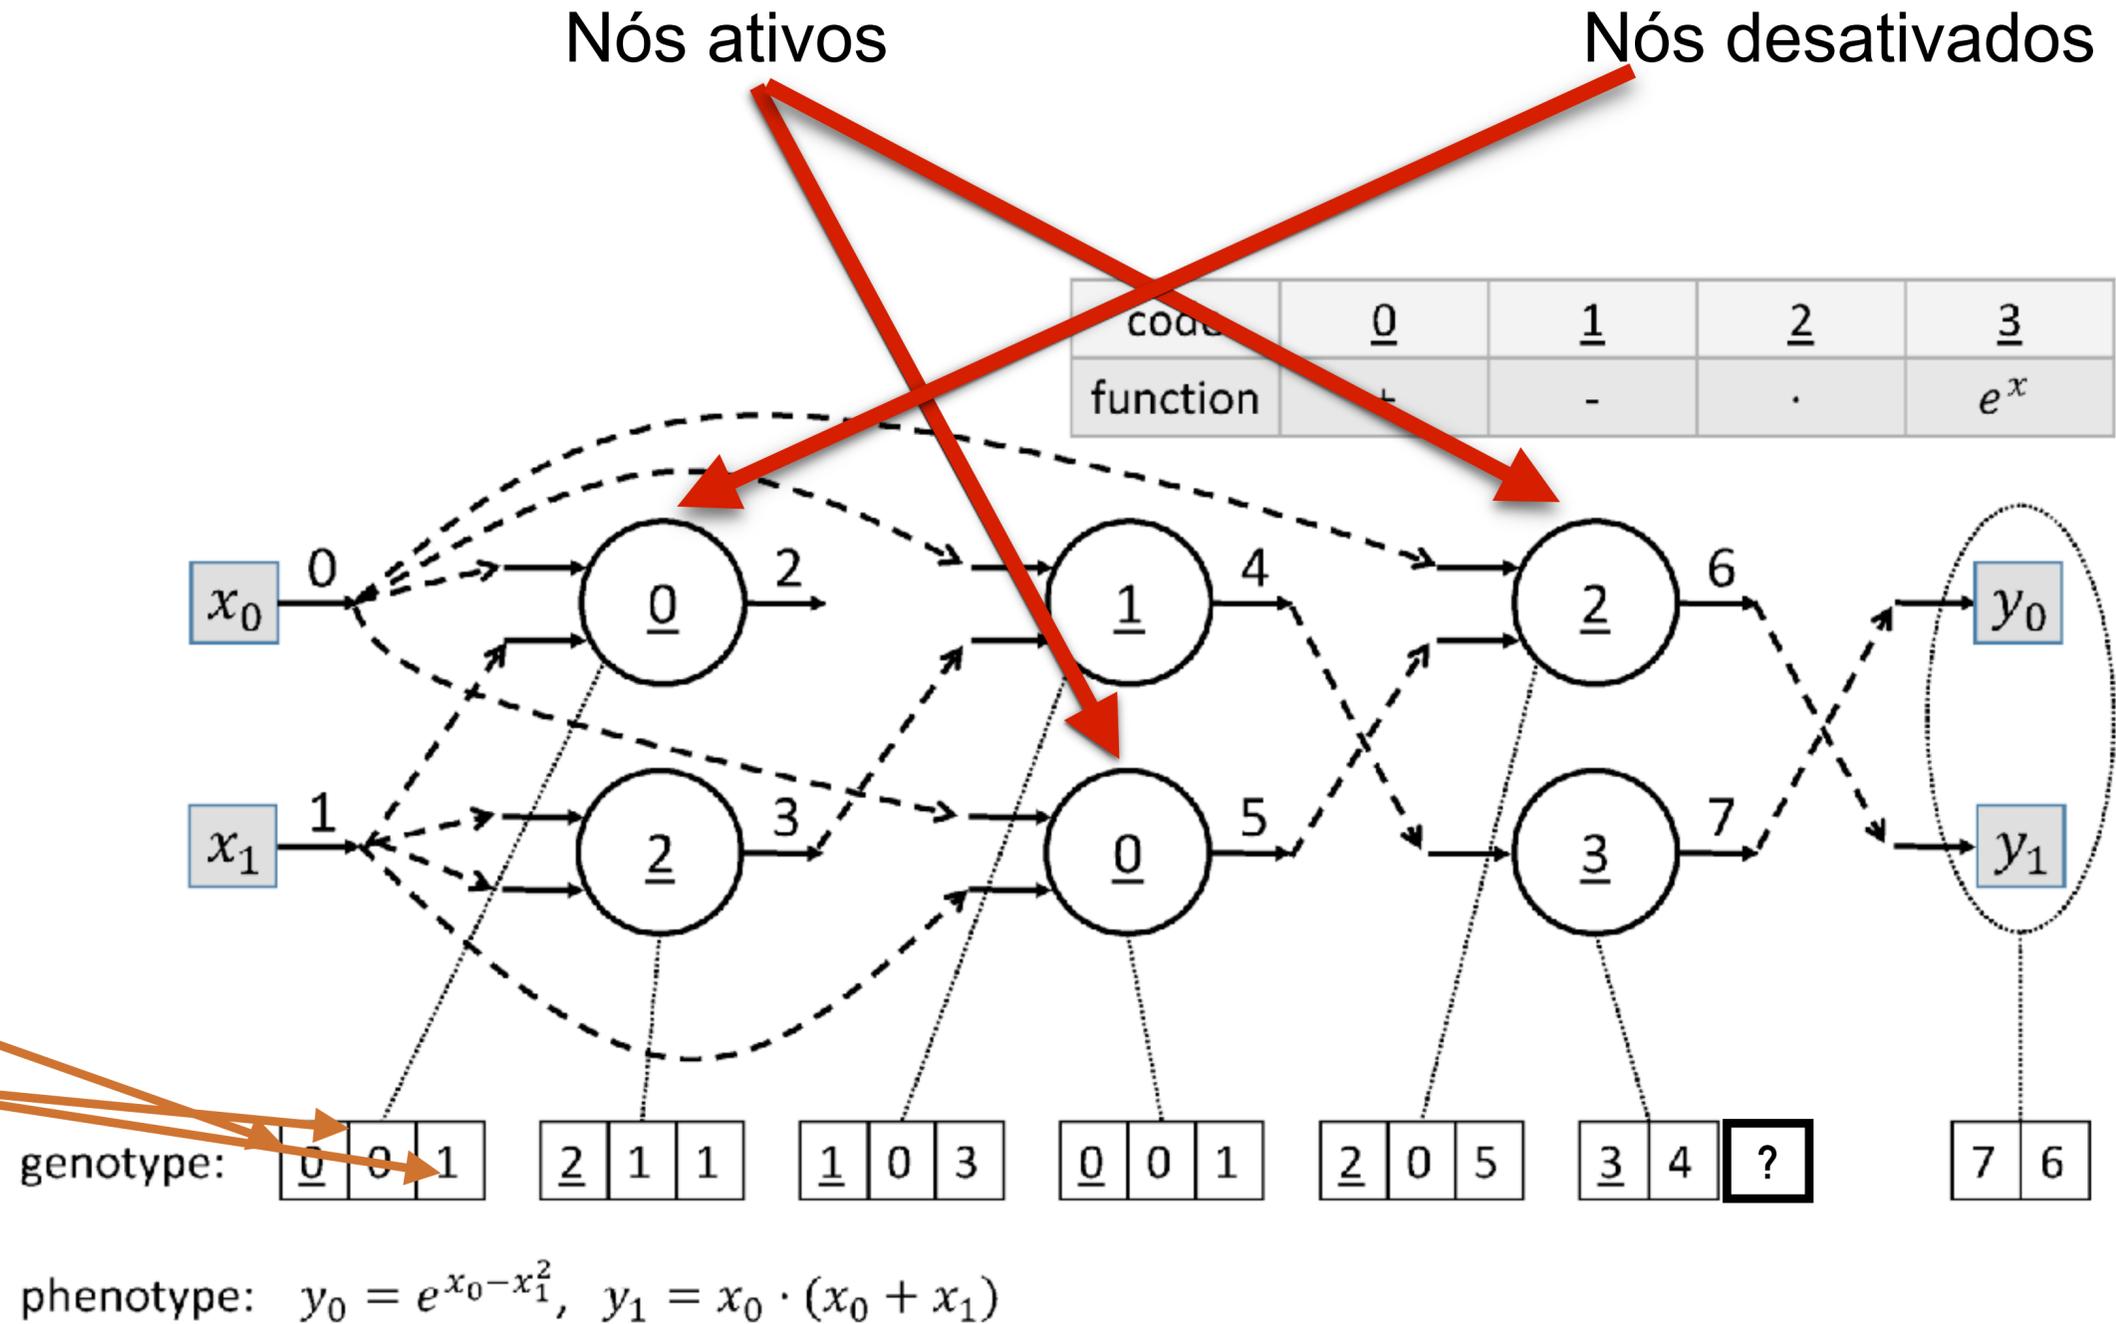
1o grupo: mapeamento de funções

2o grupo: aridade máxima, número máximo de entradas de uma função

3o grupo: argumentos para as funções (nenhuma no exemplo)

4o, 5o, etc. grupo: informações extras?

Entradas e saídas não são alterados



Cartesian genetic programming for diagnosis of Parkinson disease through handwriting analysis: Performance vs. interpretability issues Enhancing Local Decisions in Agent-Based Cartesian Genetic Programming by CMA-ES

PORQUE (C)GP

Transparente - depurar?

Poucos pontos de dados para treinamento

Bom desempenho

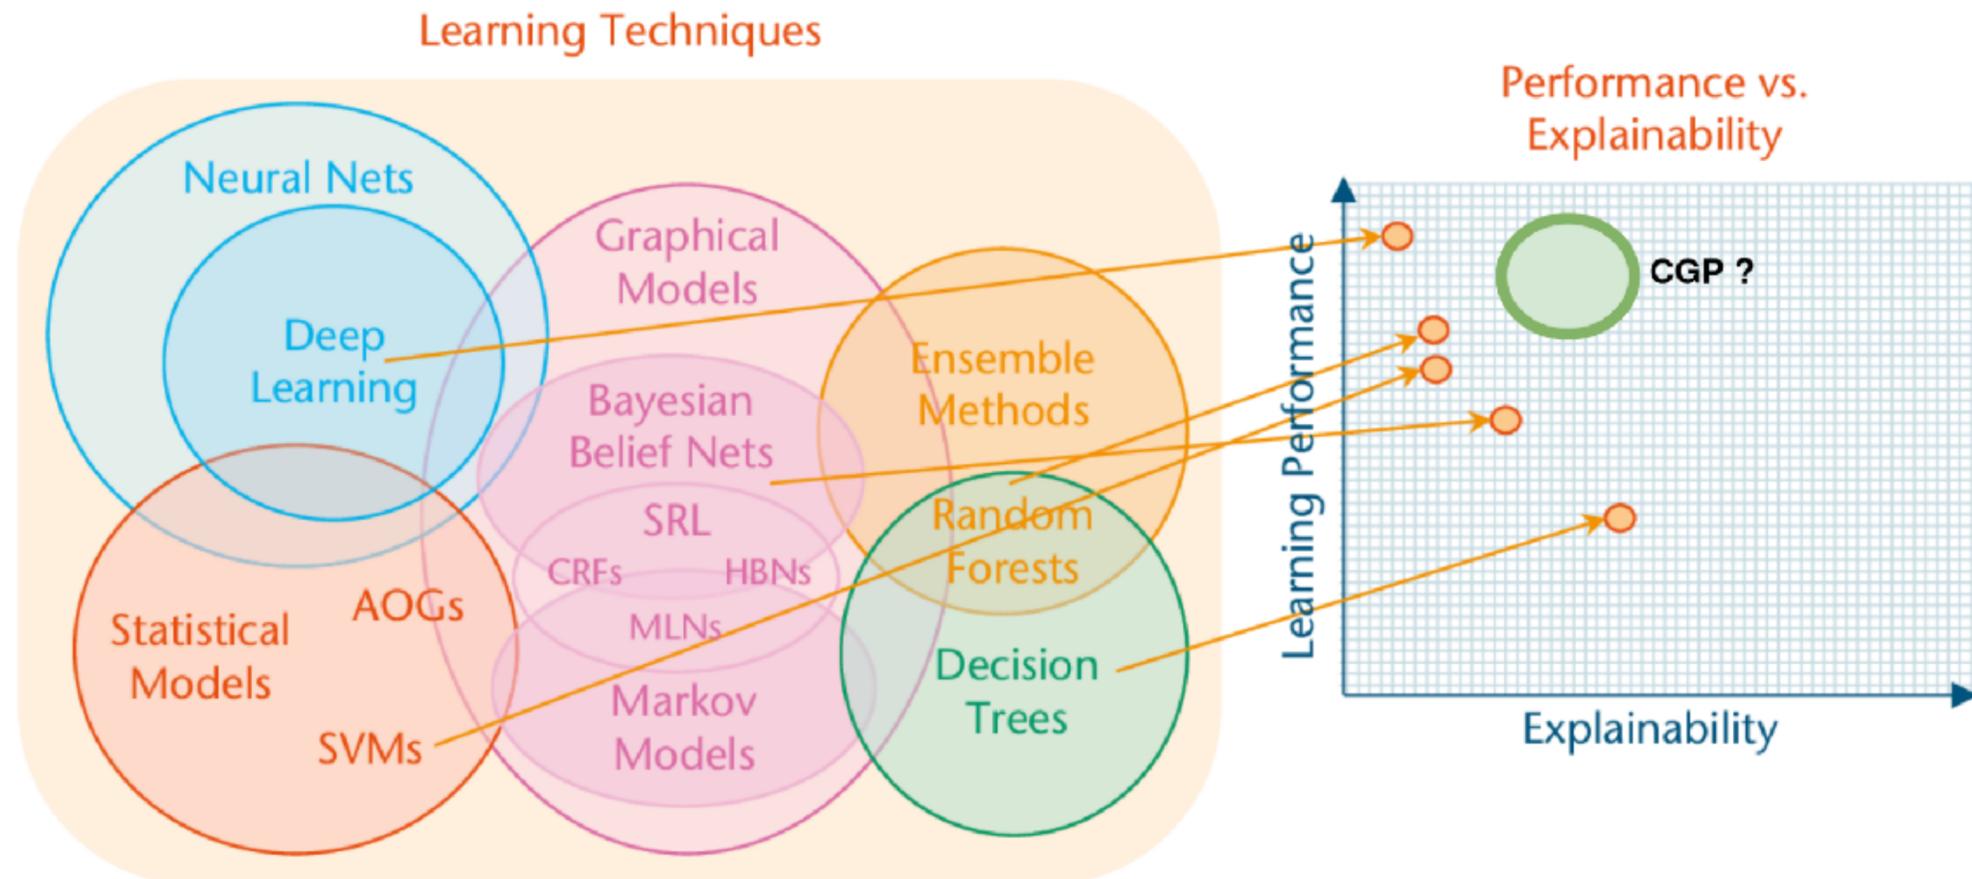
Resistente ao ruído

Pode rodar só em CPU

Pode ser criativo

Interpretabilidade - como (tem limites)

Explicabilidade - onde (como outros métodos de caixa preta)



EXPLICABILIDADE VS INTERPRETABILIDADE

Muitas vezes utilizados indistintamente, mas têm significados diferentes

Interpretabilidade: grau em que um ser humano pode compreender a mecânica de um modelo de aprendizagem automática

Exemplos: regressão linear, árvore de decisão ou sistemas baseados em regras

Explicabilidade: análise dos comportamentos do modelo

Utilização frequente de técnicas post-hoc (simplificação do modelo ou modelos de modelos - surrogates)

Relevante para modelos caixa preta, como Redes Neurais ou modelos de ensemble (Random Forest, voting...)

O QUE É INTERPRETABILIDADE?

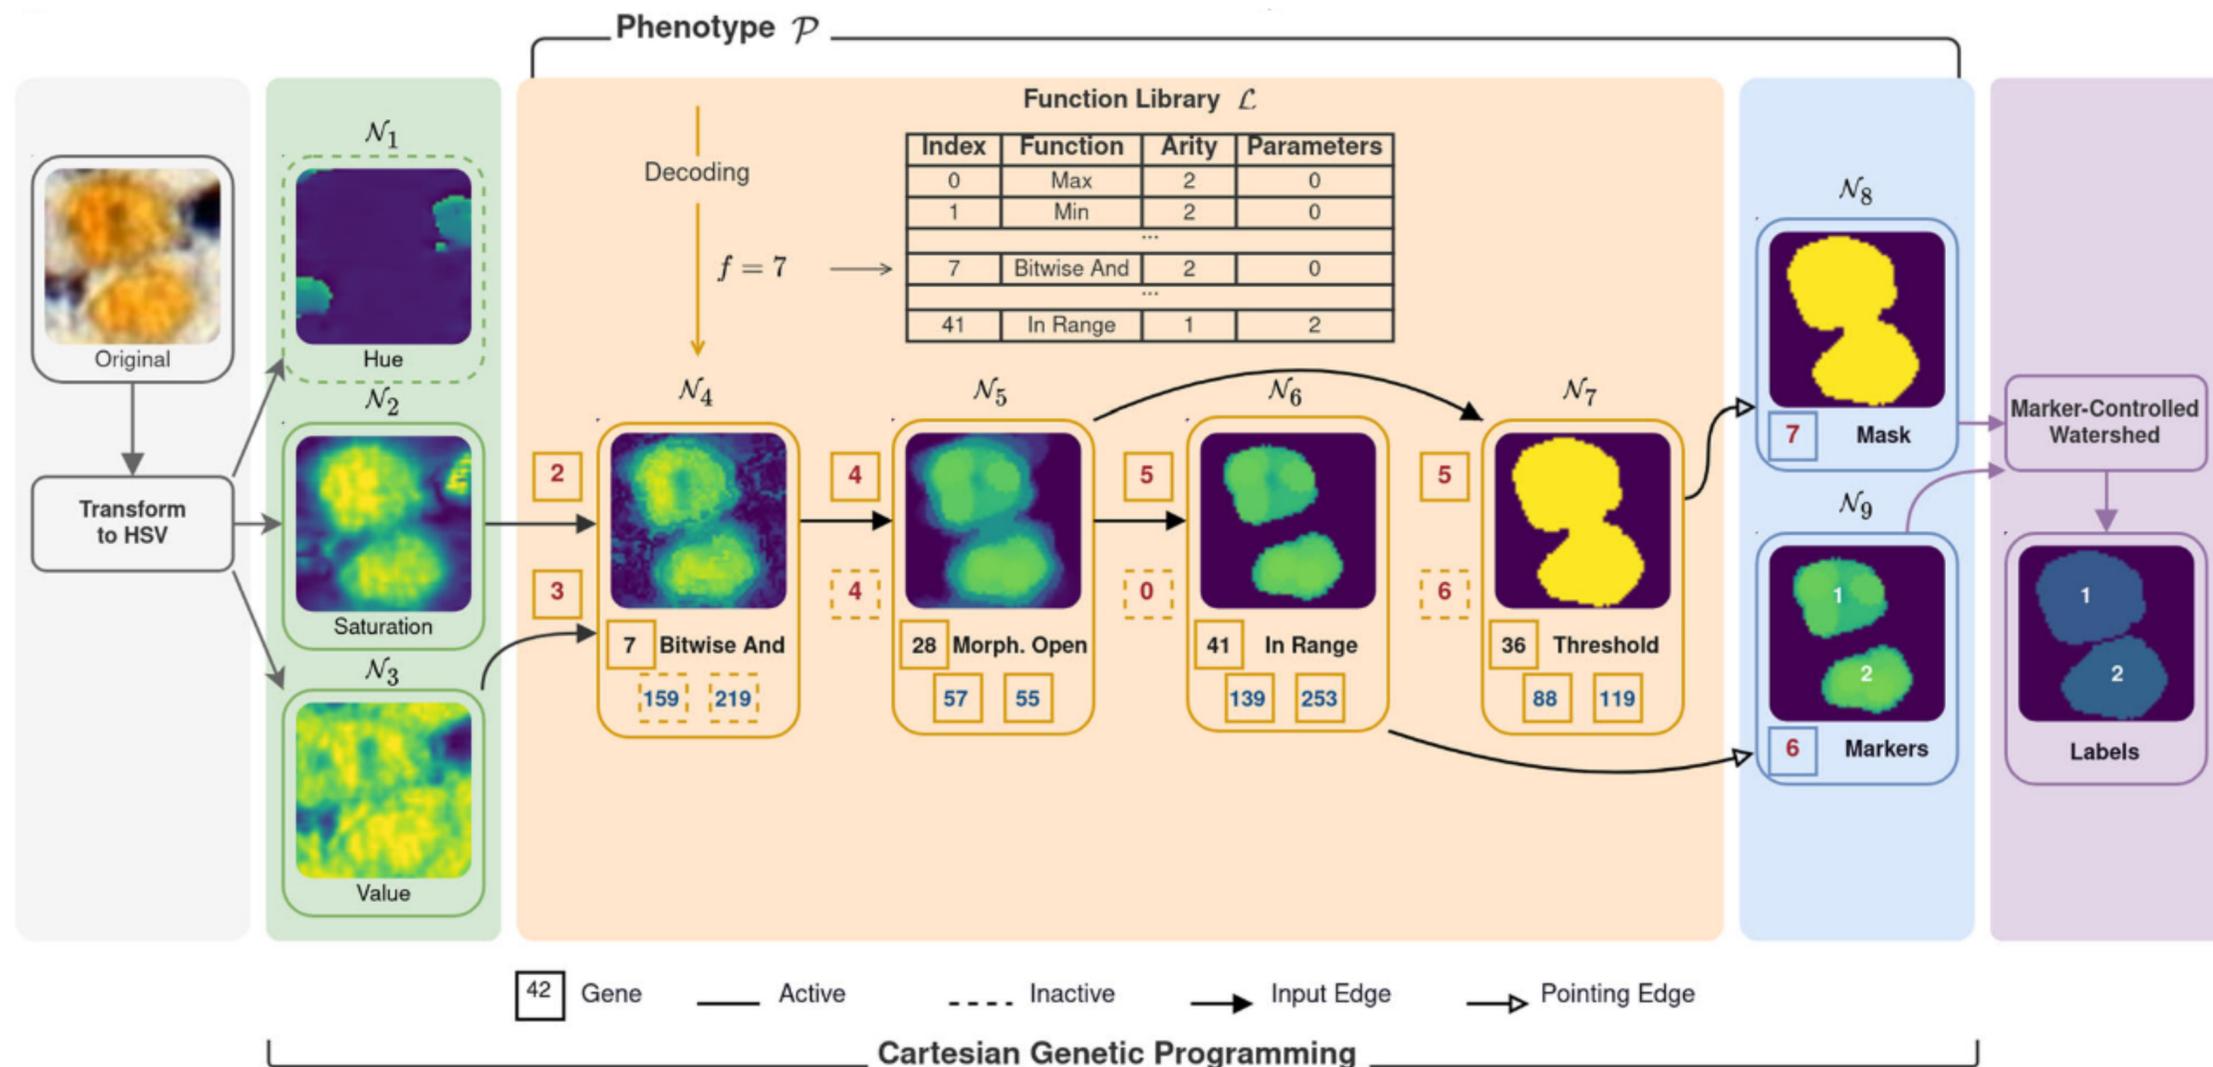
- Taxonomia da interpretabilidade [Du 2019]
- Interpretabilidade inerente vs. interpretabilidade post-hoc
- Interpretabilidade global vs. interpretabilidade local
- Componentes necessários da interpretabilidade [Lipton 2018]
- Simulabilidade: pode um humano reproduzir o processo de decisão no cérebro?
- Decomponibilidade: o processo de decisão pode ser decomposto em operadores atômicos interpretáveis?
- Transparência: garantia de convergência do processo de treino



SEGMENTAÇÃO DE IMAGEM INTERPRETÁVEL

CGP vs Deep Learning (DL) - menos dados, boa generalização

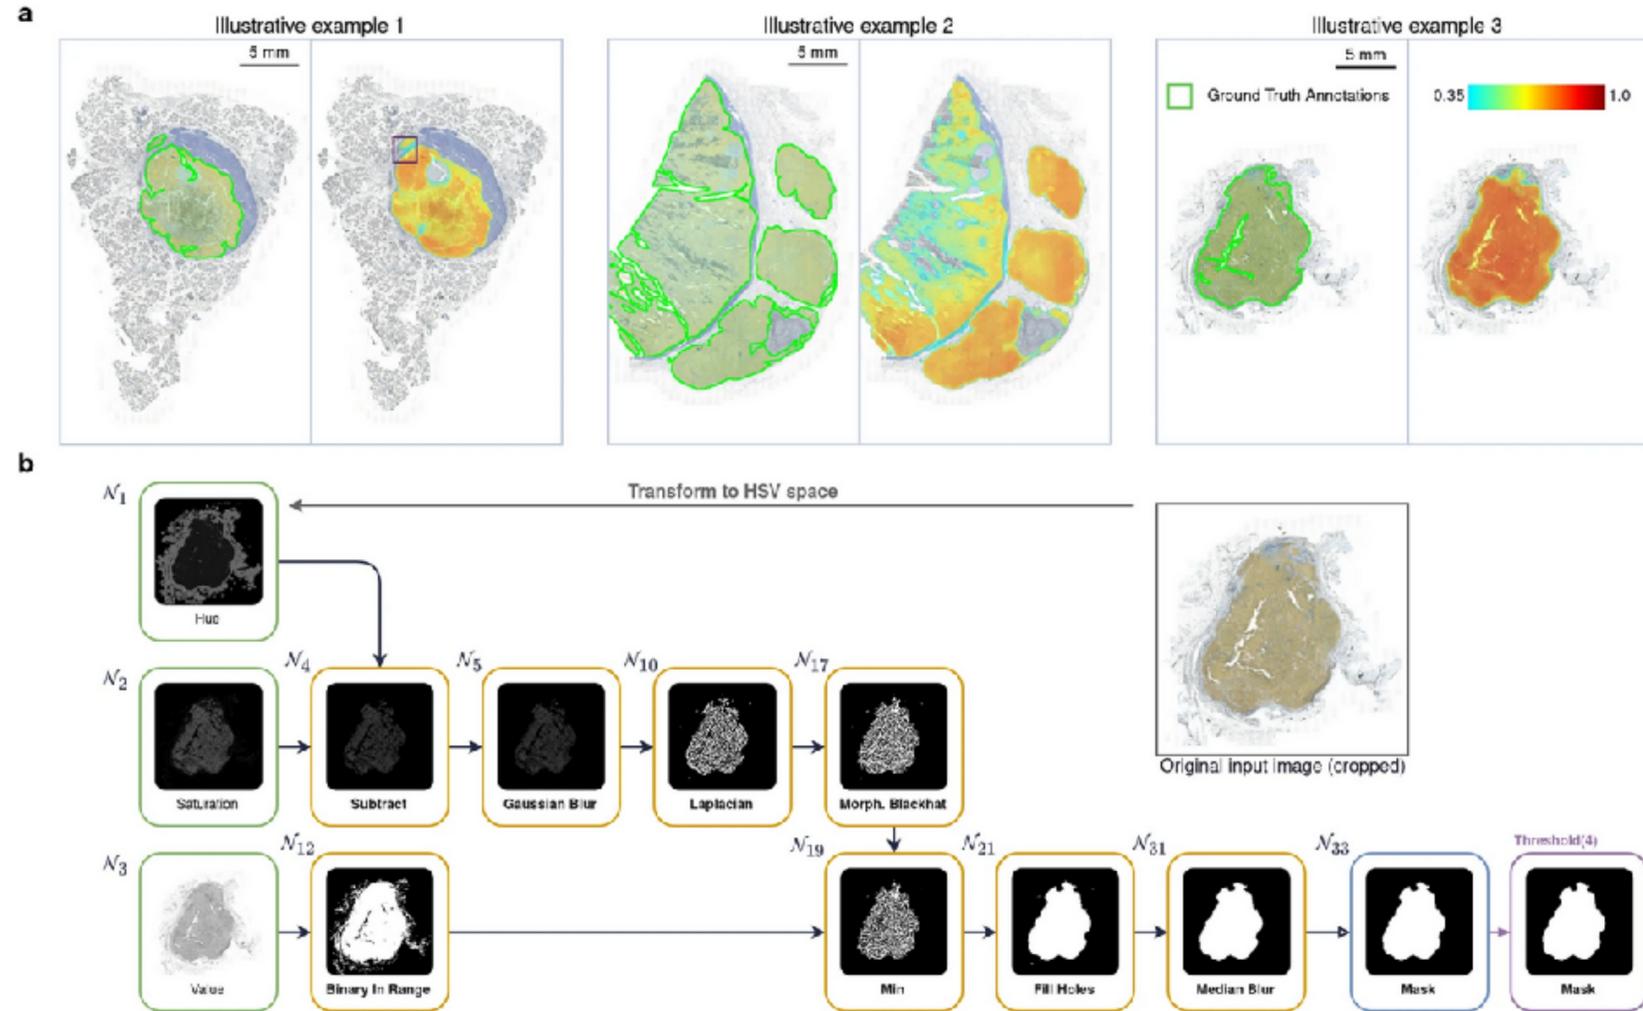
CGP PARA SEGMENTAÇÃO DE IMAGENS



42 Functions for Segmentation	
Max, Min, Mean	Add, Subtract
Not, Or, And, AndMask, Xor	
Sqrt, Pow, Exp, Log	
MedianBlur, GaussianBlur, Sharpen	
Laplacian, Sobel, Canny, Roberts	
Erode, Dilate, Open, Close, TopHat, BlackHat, Gradient	
Threshold, InRange	
Fluo TopHat, Absdiff, RelDiff	
RemoveSmallObjects, RemoveSmallHoles	

Cortacero, K., McKenzie, B., Müller, S. et al. Evolutionary design of explainable algorithms for biomedical image segmentation. Nature Communications 14, 7112 (2023)

MÉDICOS MODEM INTERPRETAR



The first step (node 3) of this pipeline consisted of subtracting the Hue channel (node 0) from the Saturation channel (node 1), **allowing for the exclusion of pixels corresponding to CD8+ T cells and to other cells belonging to the tumor microenvironment**. Then Kartezio used a Gaussian Blur filter (node 4) in order to smooth the previously obtained area. Next, Kartezio chose a Laplacian filter (node 10) to detect the variations in the image obtained in node 4, thus **delimiting the tumor borders**. Interestingly, the sequence Gaussian Blur/Laplacian filters is frequently used by image analysts for image segmentation tasks. To highlight the segmented areas, Kartezio used Morphological Black Hat (node 17) which **reveals small objects that are darker than their surroundings**. Altogether, these initial calculations provided an accurate estimation of tumor area.

In parallel, node 12 created a binary mask of the Value channel (brightness) allowing for **the establishment of a global map of the area of interest**. The next step selected by Kartezio consisted of **merging the two maps with the min operator** (node 19). This allowed for **the elimination of all pixels detected by the first calculation (results of node 17) that fell outside the area of interest**. Kartezio next selected a Fill Hole filter in order to transform the selected area limits into a solid binary mask. A final step consisted of removing the noise from the edges of the mask using a Median Blur filter (node 31)

nature communications

Article

<https://doi.org/10.1038/s41467-023-42664-x>

Evolutionary design of explainable algorithms for biomedical image segmentation

Received: 17 April 2023

Accepted: 18 October 2023

Published online: 06 November 2023

Check for updates

Kévin Cortacero^{1,2,3}, Brienne McKenzie^{1,2,3}, Sabina Müller^{1,2,3}, Roxana Khazen^{1,2,3}, Fanny Lafouresse^{1,2,3}, Gaëlle Corsaut^{1,2,3}, Nathalie Van Acker⁴, François-Xavier Frenois⁴, Laurence Lamant⁴, Nicolas Meyer⁵, Béatrice Vergier^{6,7}, Dennis G. Wilson⁸, Hervé Luga⁸, Oskar Stauffer^{9,10}, Michael L. Dustin¹¹, Salvatore Valitutti^{1,2,3,4,11} & Sylvain Cussat-Blanc^{8,11} ✉

CGP VS DL - SEGMENTAÇÃO - PERFORMANCE SIMILAR

Abordagens de aprendizado profundo:

DL: Mask RCNN, Stardist, CellPose

CGP

O CGP pode resolver essa tarefa com

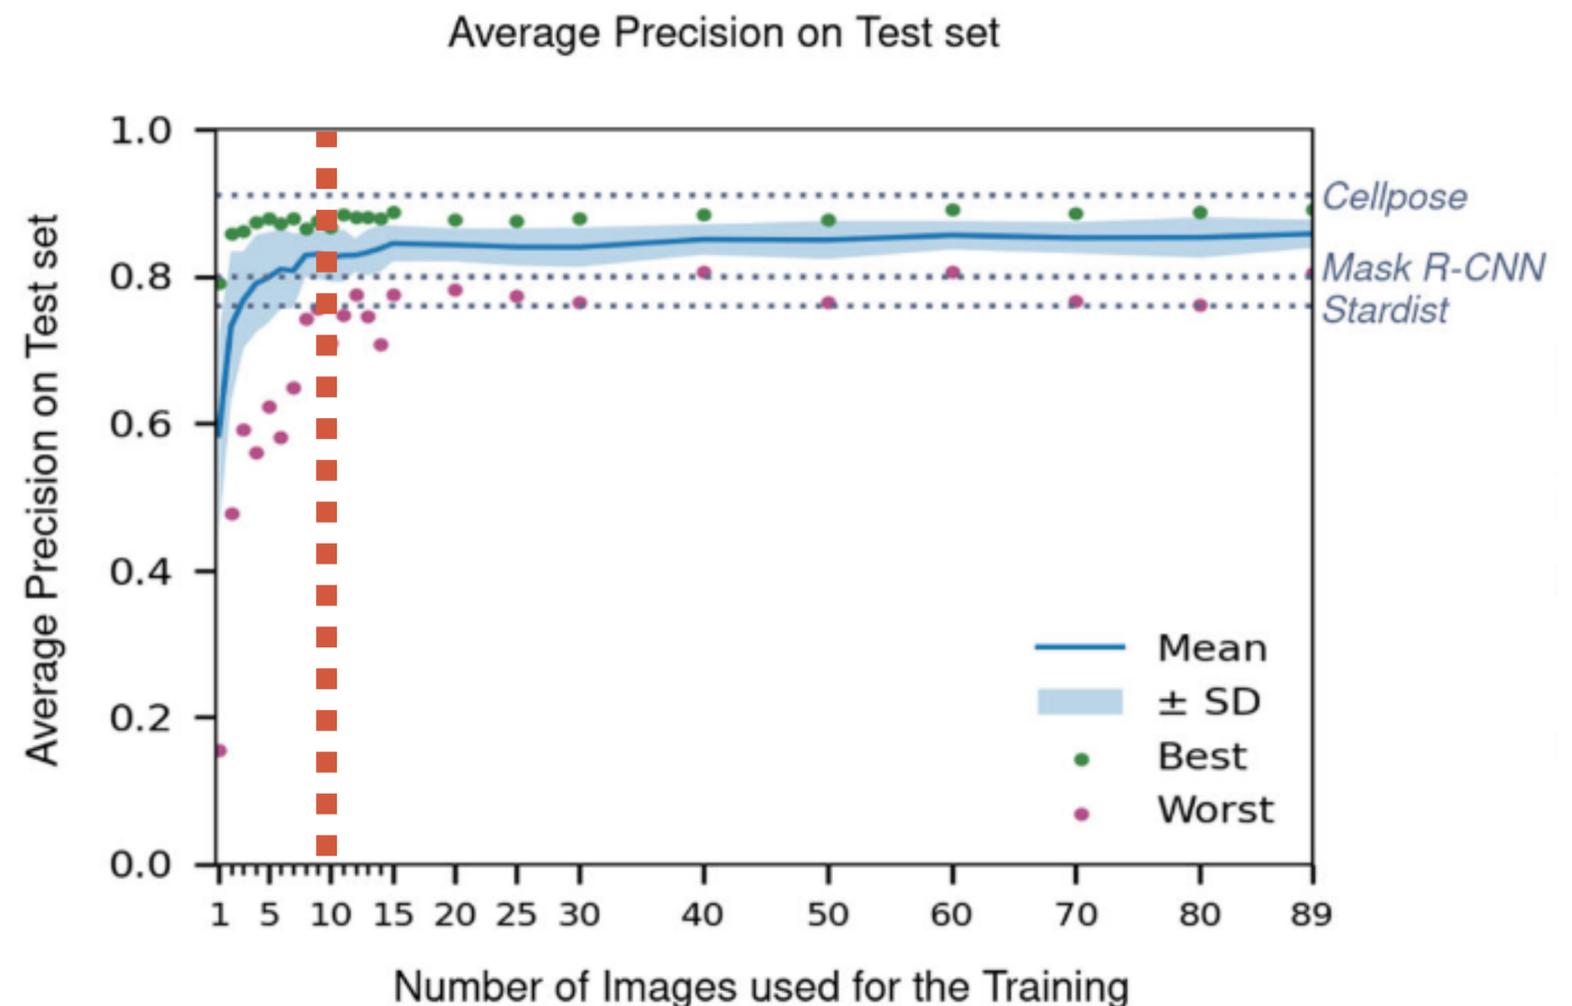
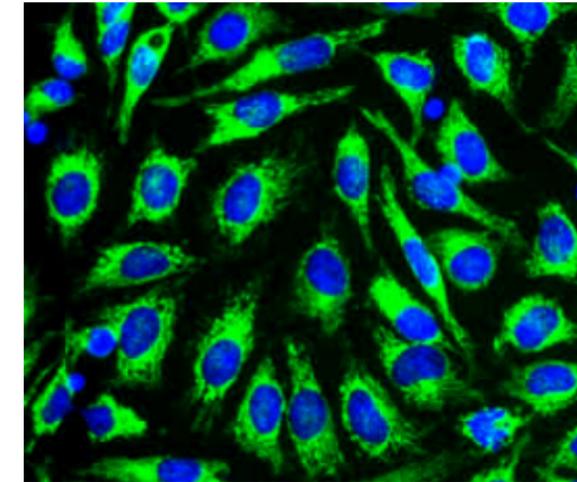
Eficiência equivalente em comparação com DL

Poucas imagens em torno de 10% (~10-15)

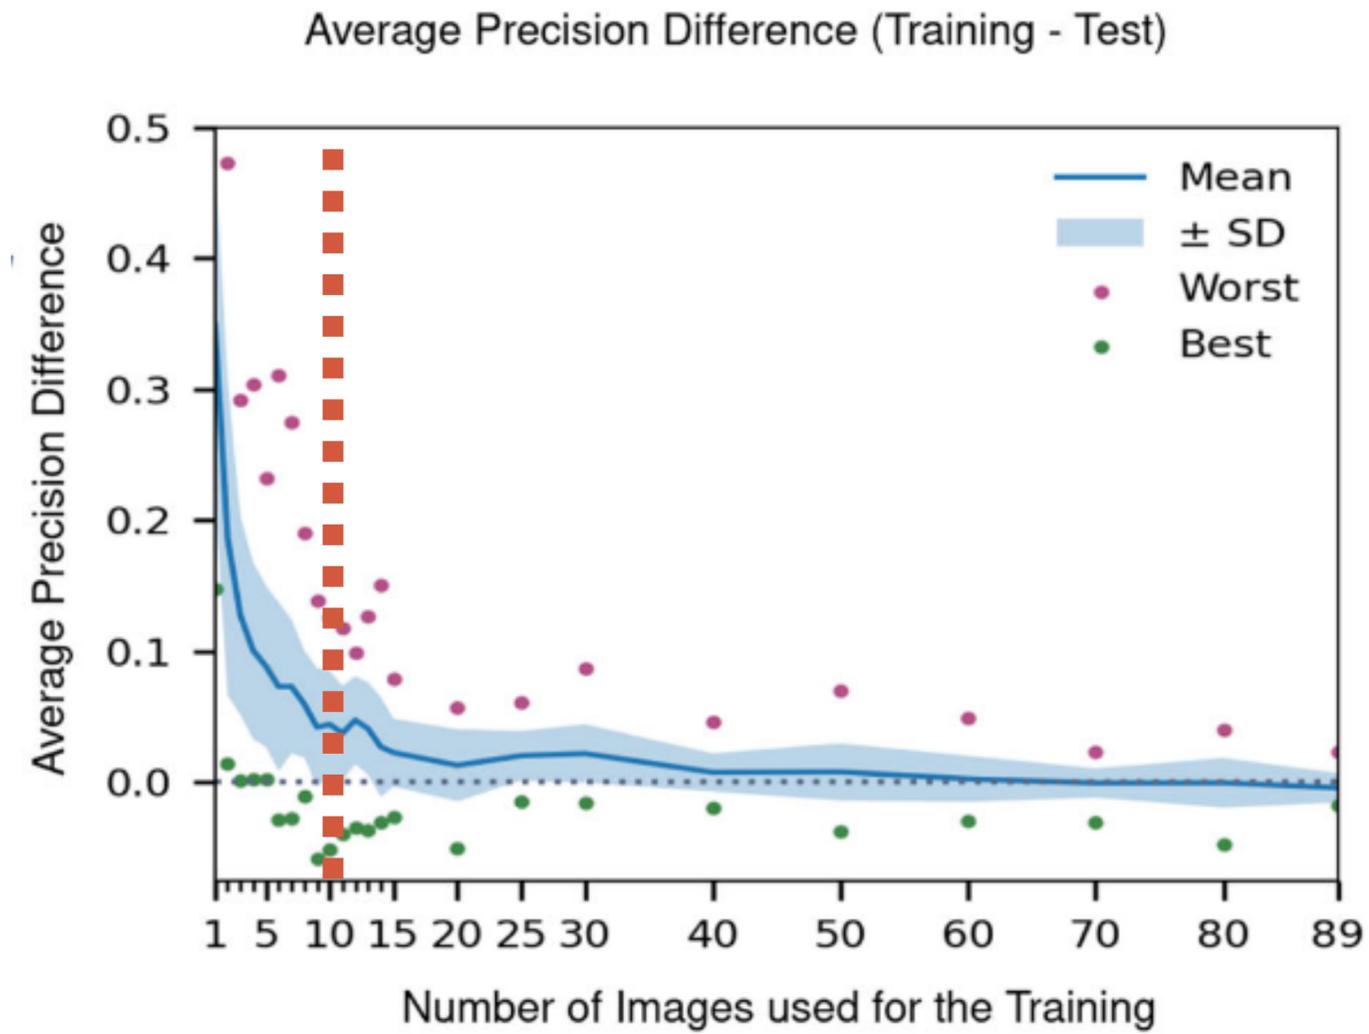
Boas capacidades de generalização

Dataset - CellPose

Segmentação de instâncias de células



CGP VS DL - SEGMENTAÇÃO - BOA GENERALIZAÇÃO



PODEMOS TORNAR A (C)GP MAIS ATRAENTE?

Menos dados para treinamento: escassez de dados, resultados mais rápidos, menos anotações necessárias

Multitipo/semântica: Imagem, texto, numérico, etc.

Interpretabilidade vs Explicabilidade

Seleção e engenharia de dados

Configurações diferentes

Exploração do espaço de busca

Multiobjetivo (interpretabilidade, nitidez, velocidade, complexidade, etc.)

Projeto de algoritmo consciente de problemas - crossover, seleção

Robustez e nitidez

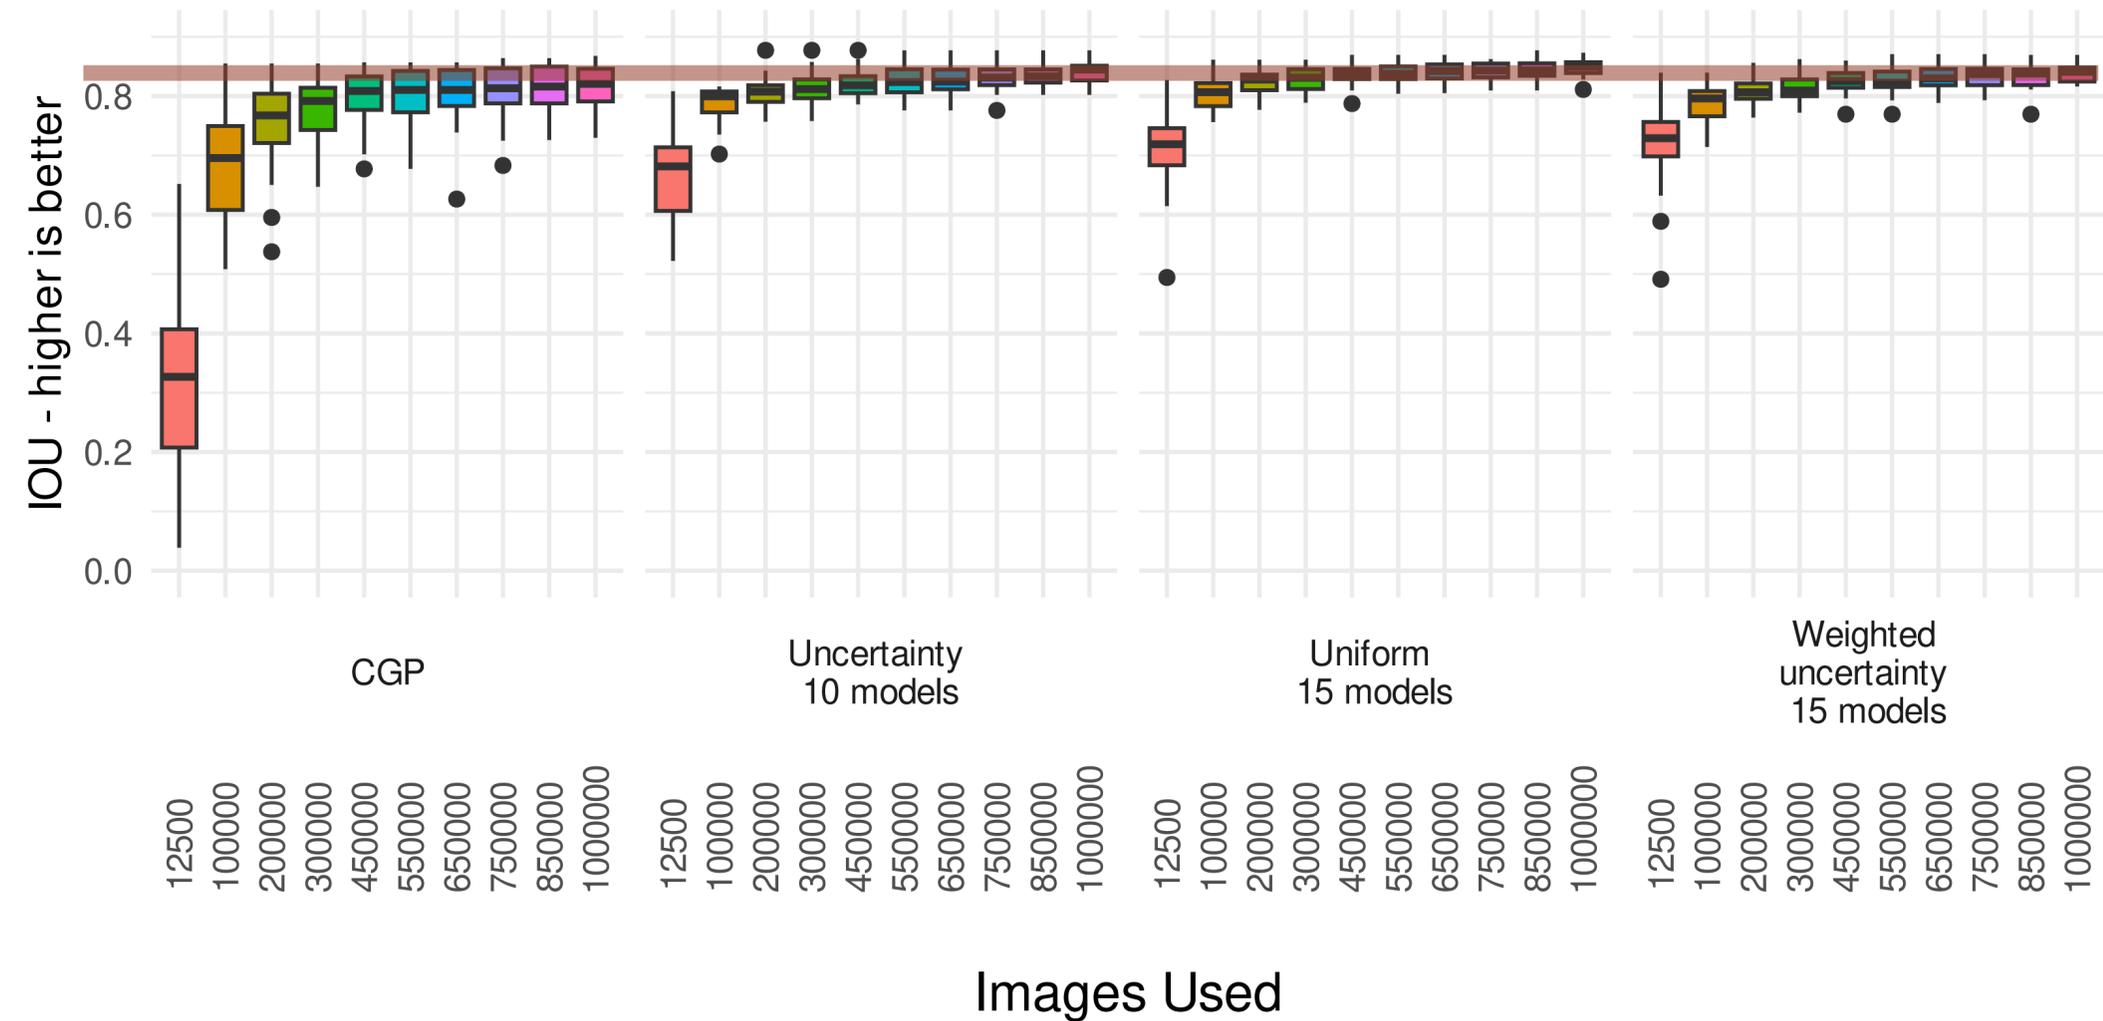
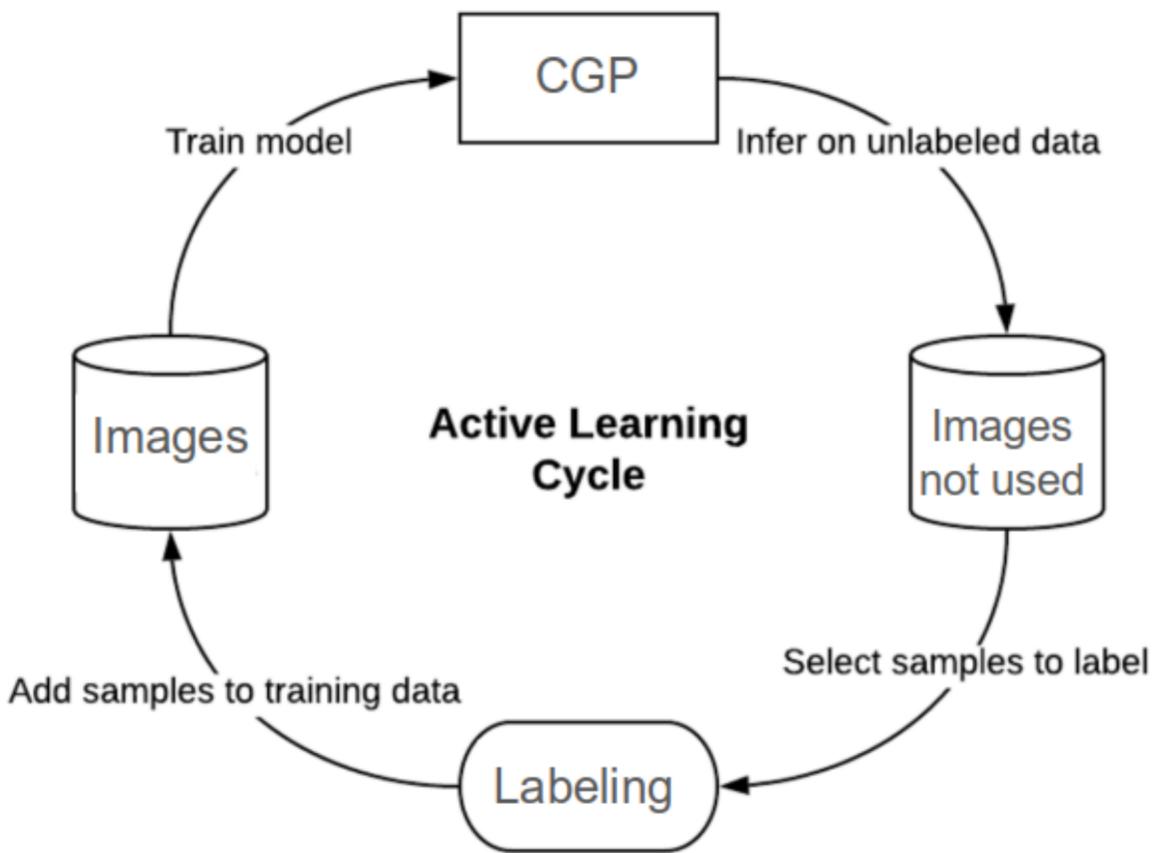
Aplicações: imagem, astronomia, robótica, etc.



SELECIONANDO DADOS

Convergência rápida, baixa variação

MENOS DADOS

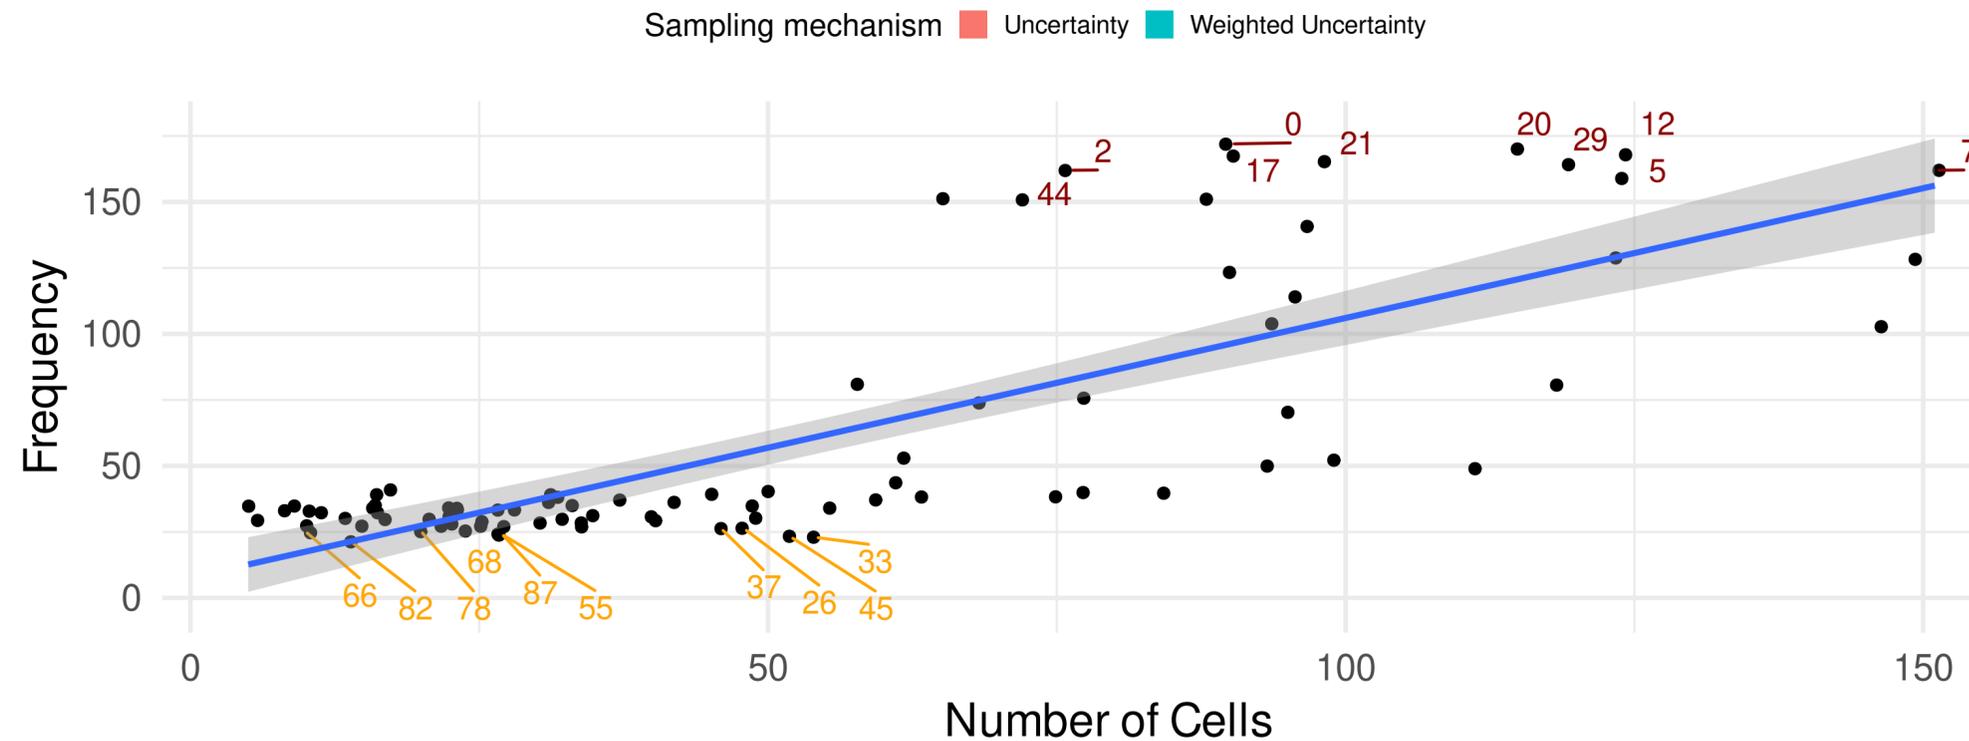
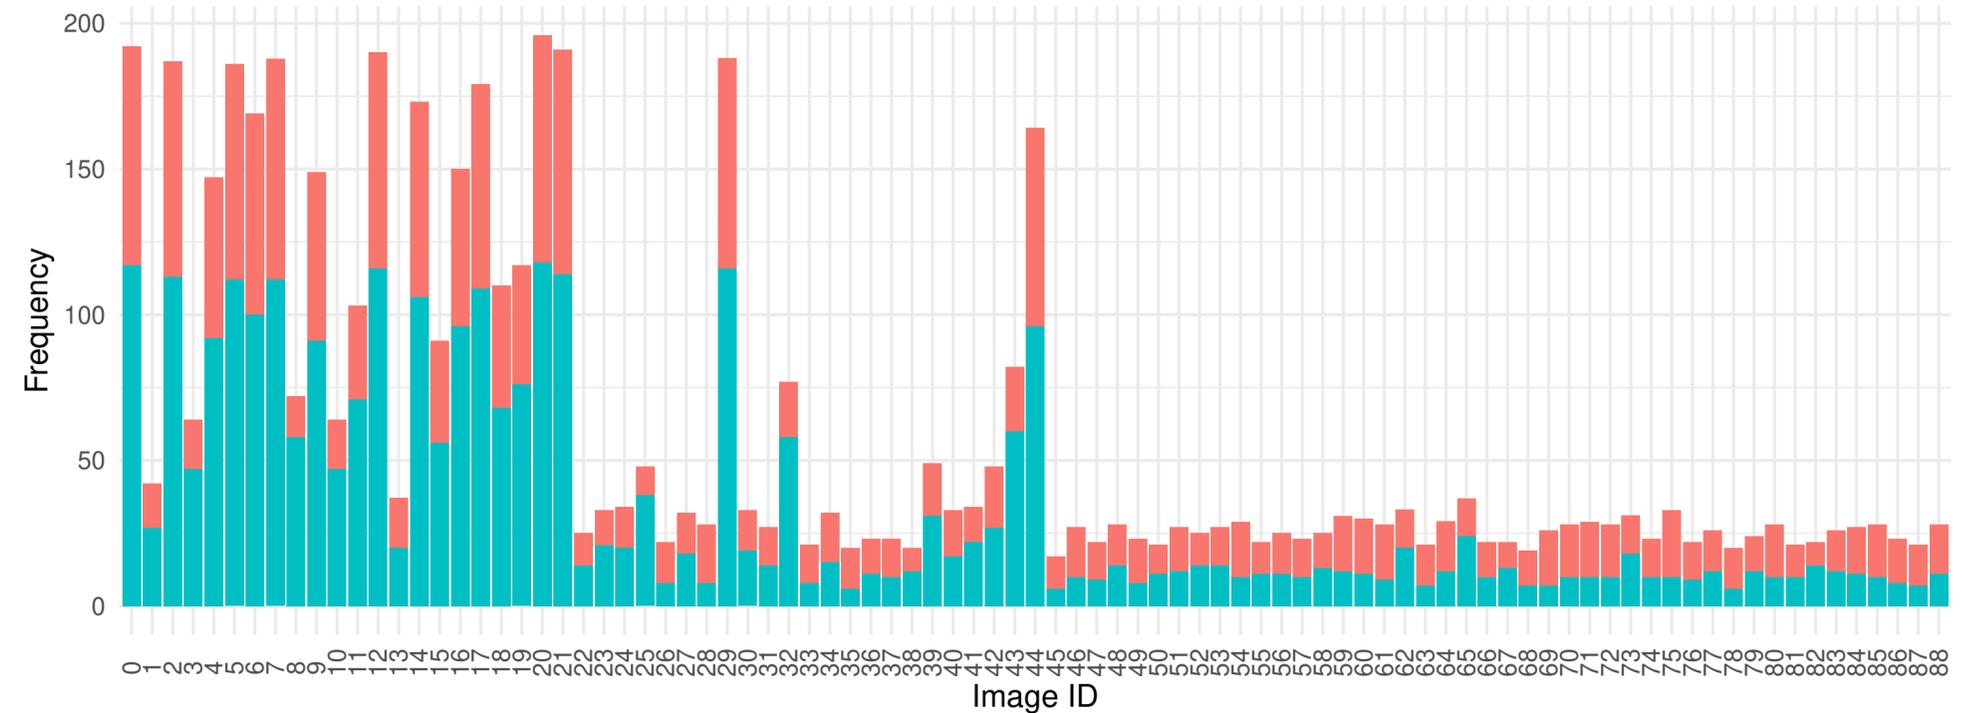


QUAIS DADOS?

Algumas imagens são mais usadas por ambos os métodos de amostragem

O número de células na imagem parece afetar a escolha

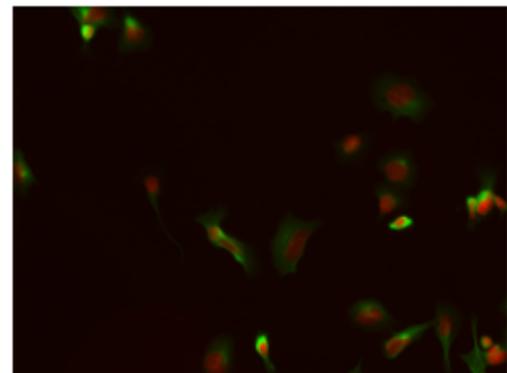
Há algo que eles possam nos dizer?



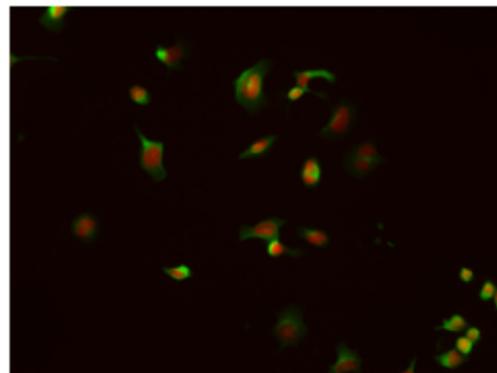
COMO ELES SE PARECEM?

Menos amostrado

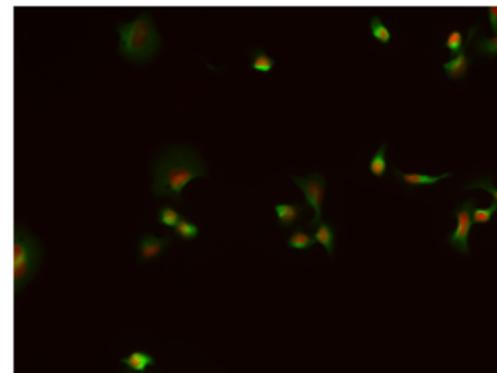
Frequentemente amostrado



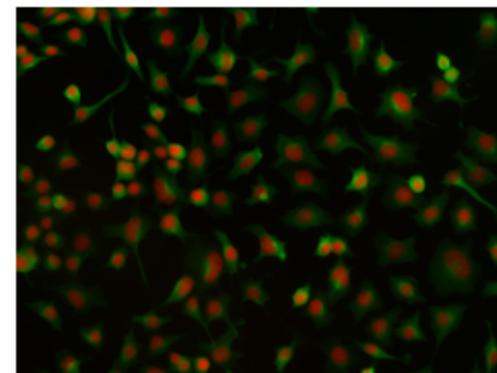
(a) Image of index 81.



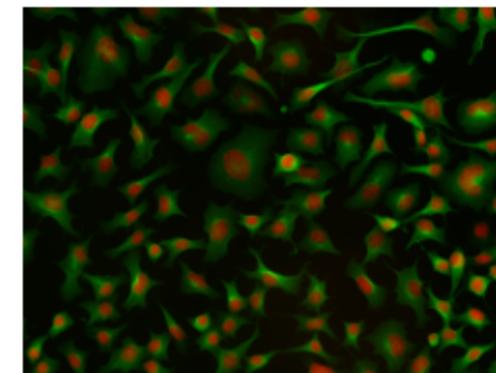
(b) Image of index 83.



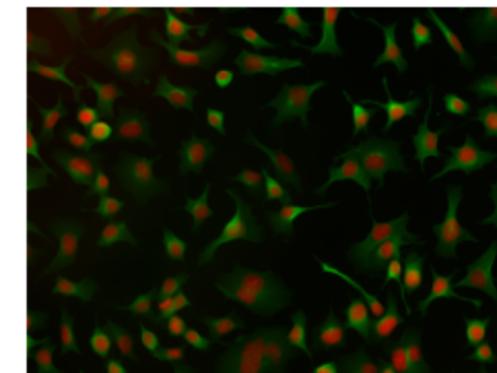
(c) Image of index 86.



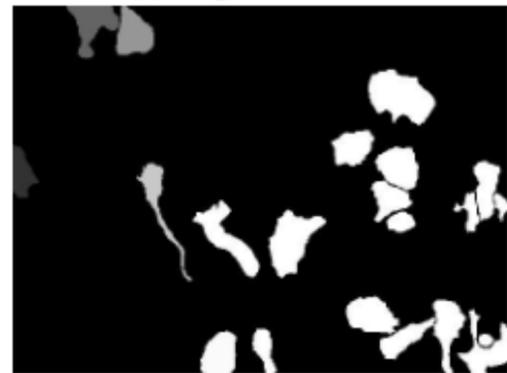
(a) Image of index 5.



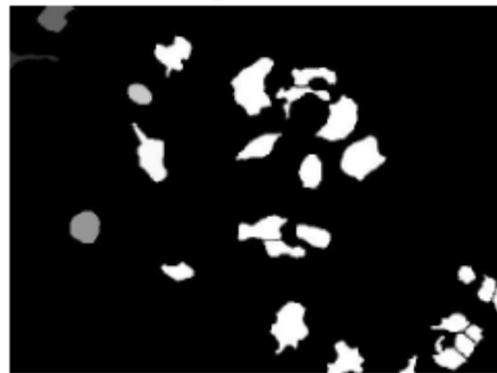
(b) Image of index 20.



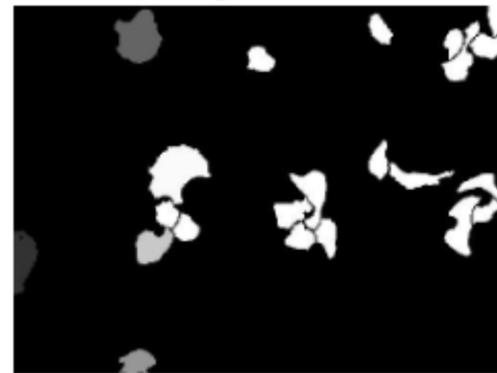
(c) Image of index 21.



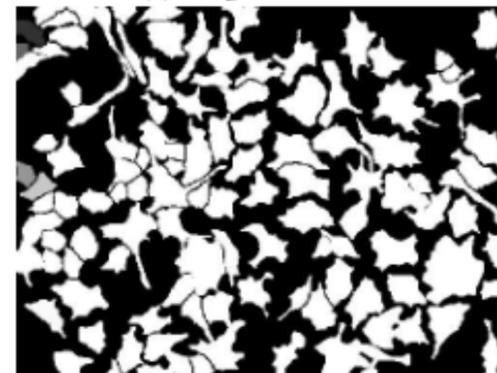
(d) Labeled mask of index 81.



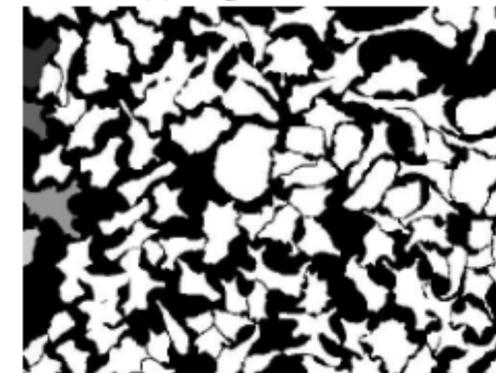
(e) Labeled mask of index 83.



(f) Labeled mask of index 86.



(d) Labeled mask of index 5.



(e) Labeled mask of index 20.



(f) Labeled mask of index 21.

O APRENDIZADO ATIVO É IMPORTANTE

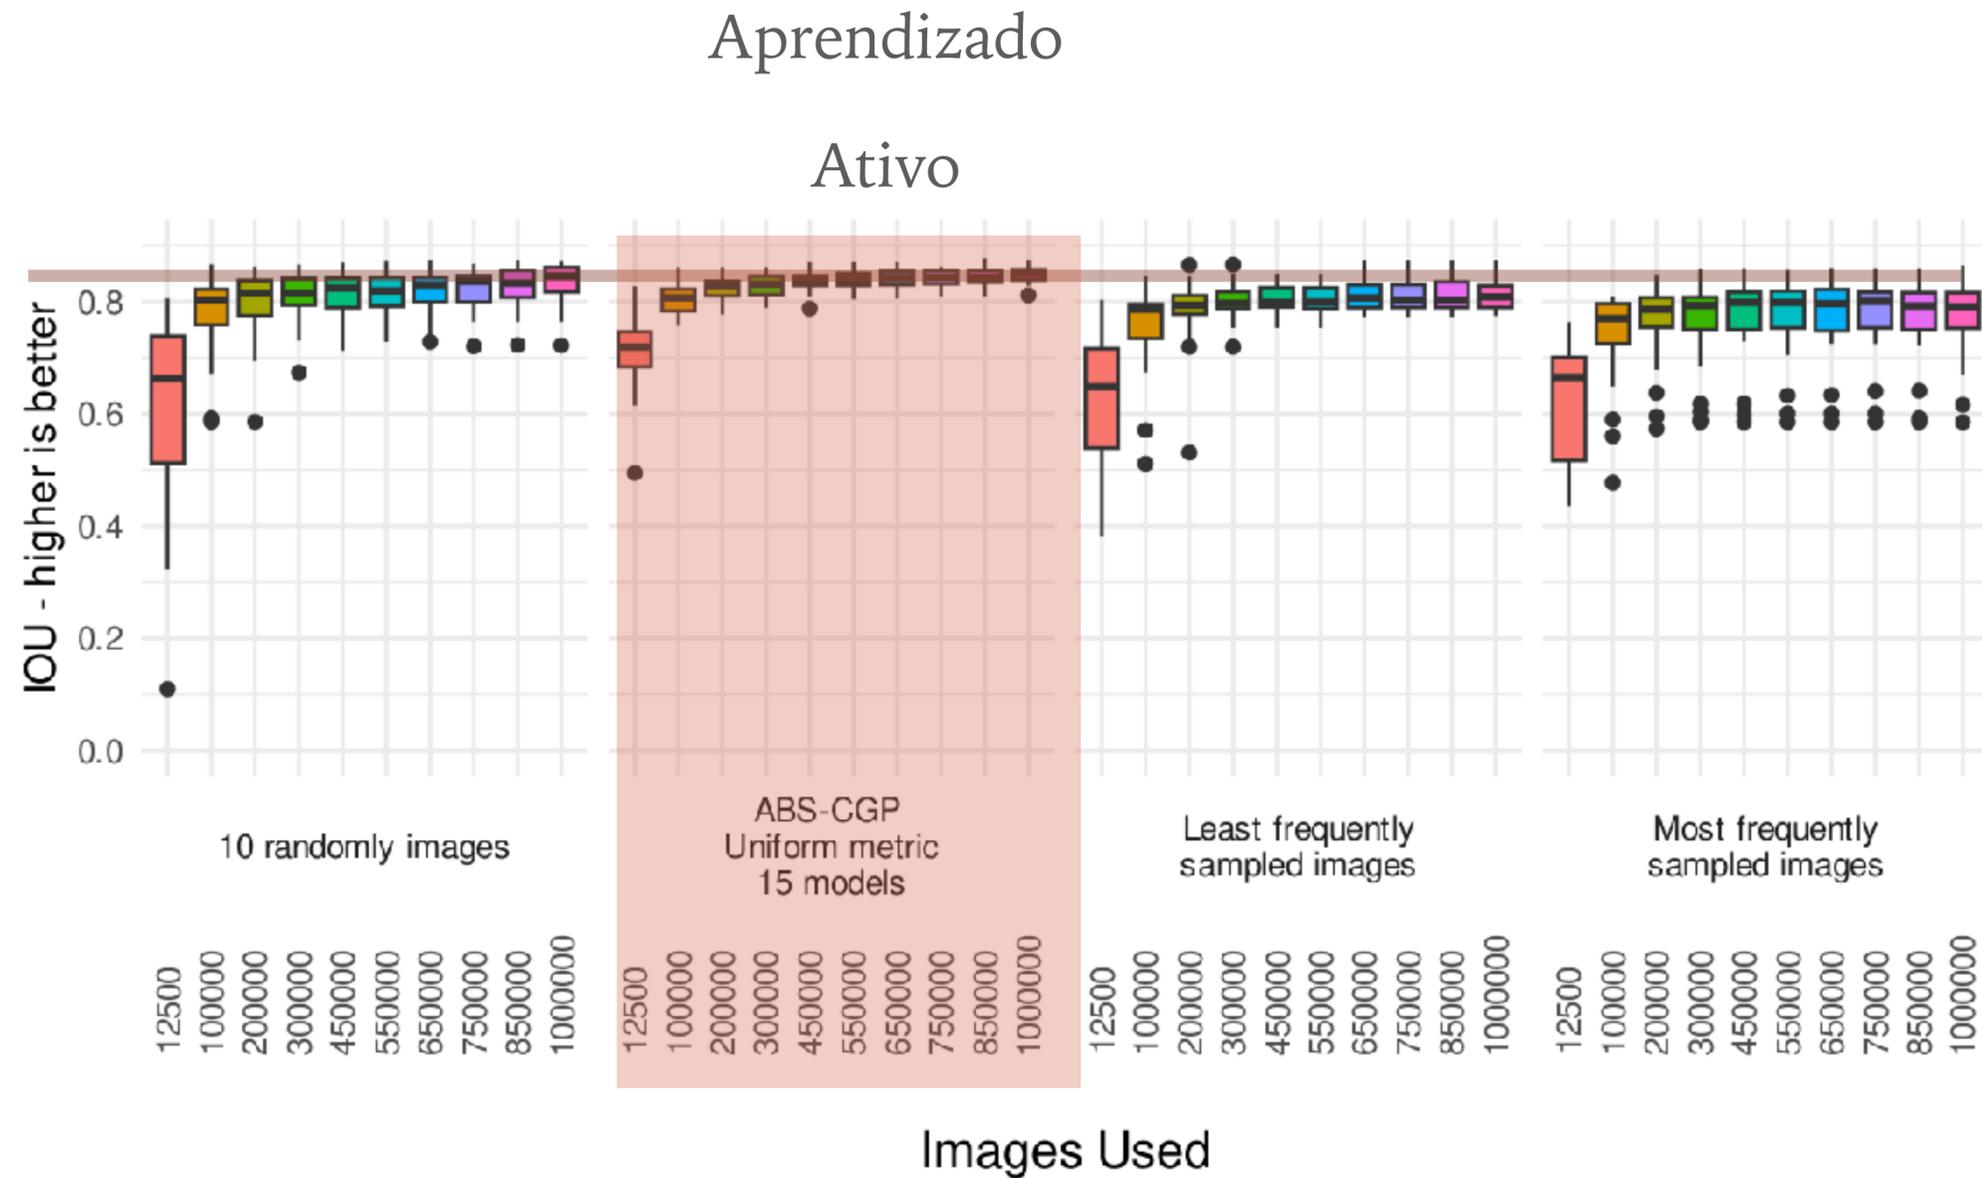
Usar menos dados de forma mais eficiente

Desvio padrão menor

Usar imagens com menos ou mais frequência não é suficiente

Sem variação de dificuldade

A escolha de dados para o treino não é óbvia

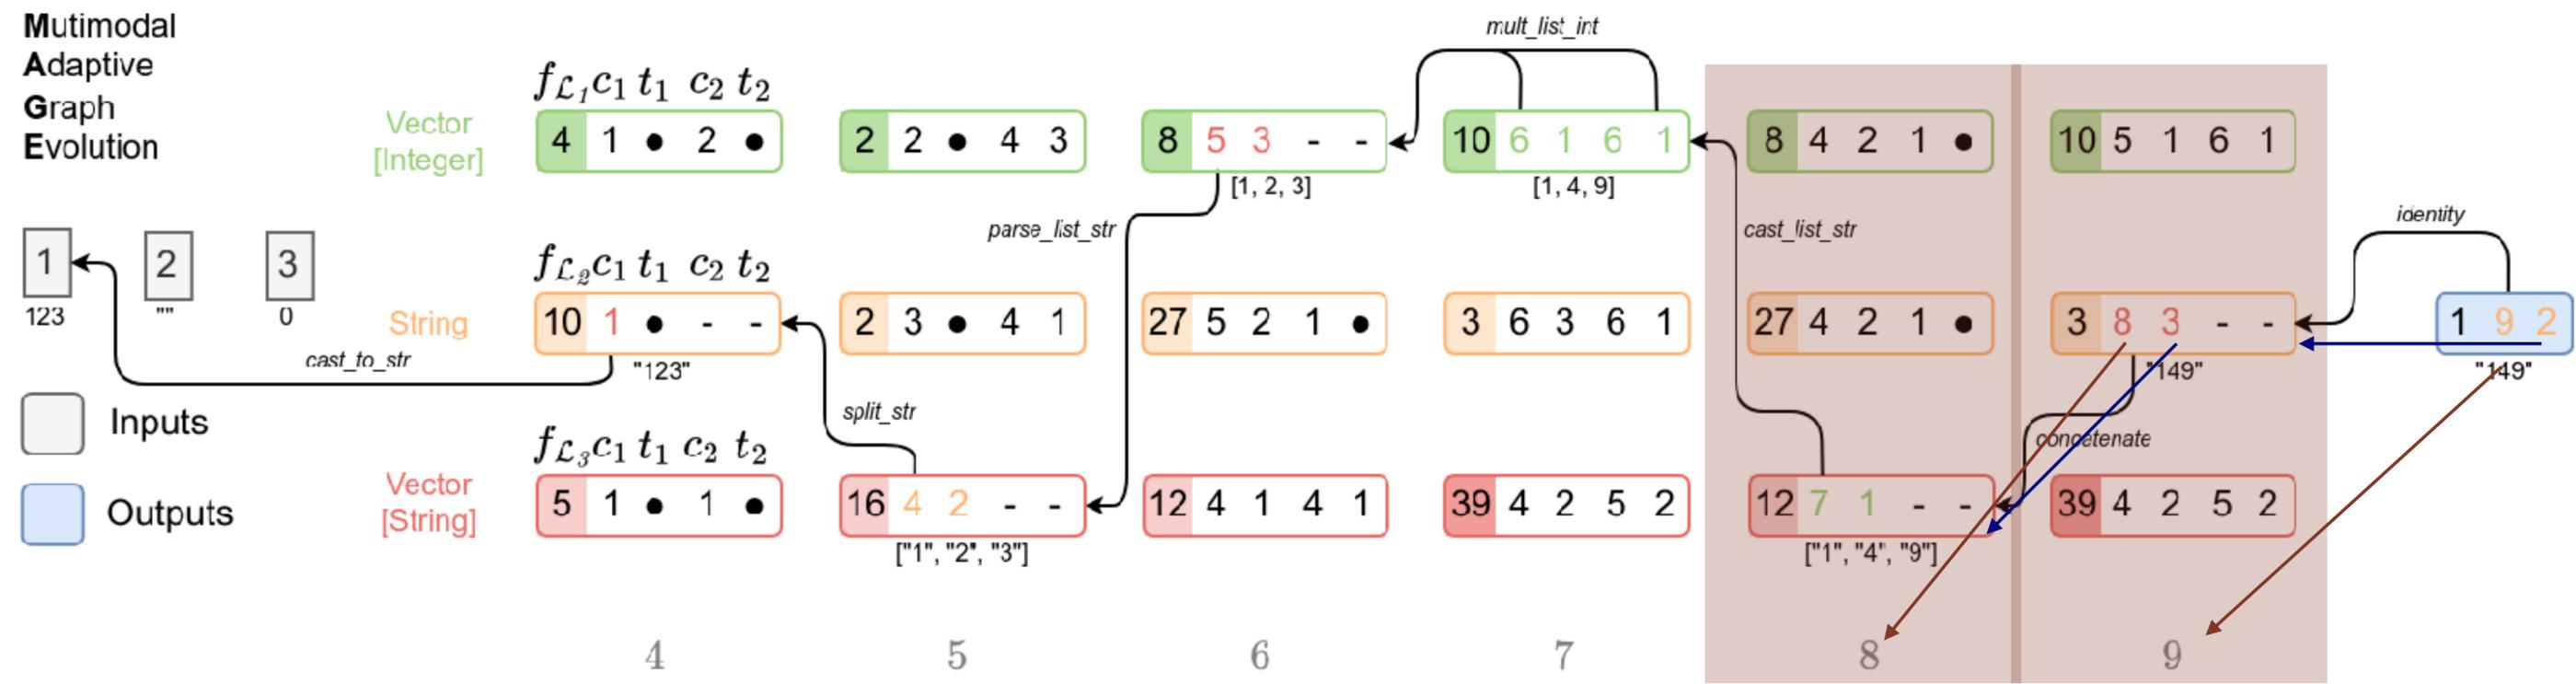




CGP MULTITIPO – CLASSIFICAÇÃO DE IMAGEM

O feedback dos médicos provou ser valioso

CLASSIFICAÇÃO DE IMAGENS – CGP MULTITIPO/SEMÂNTICO

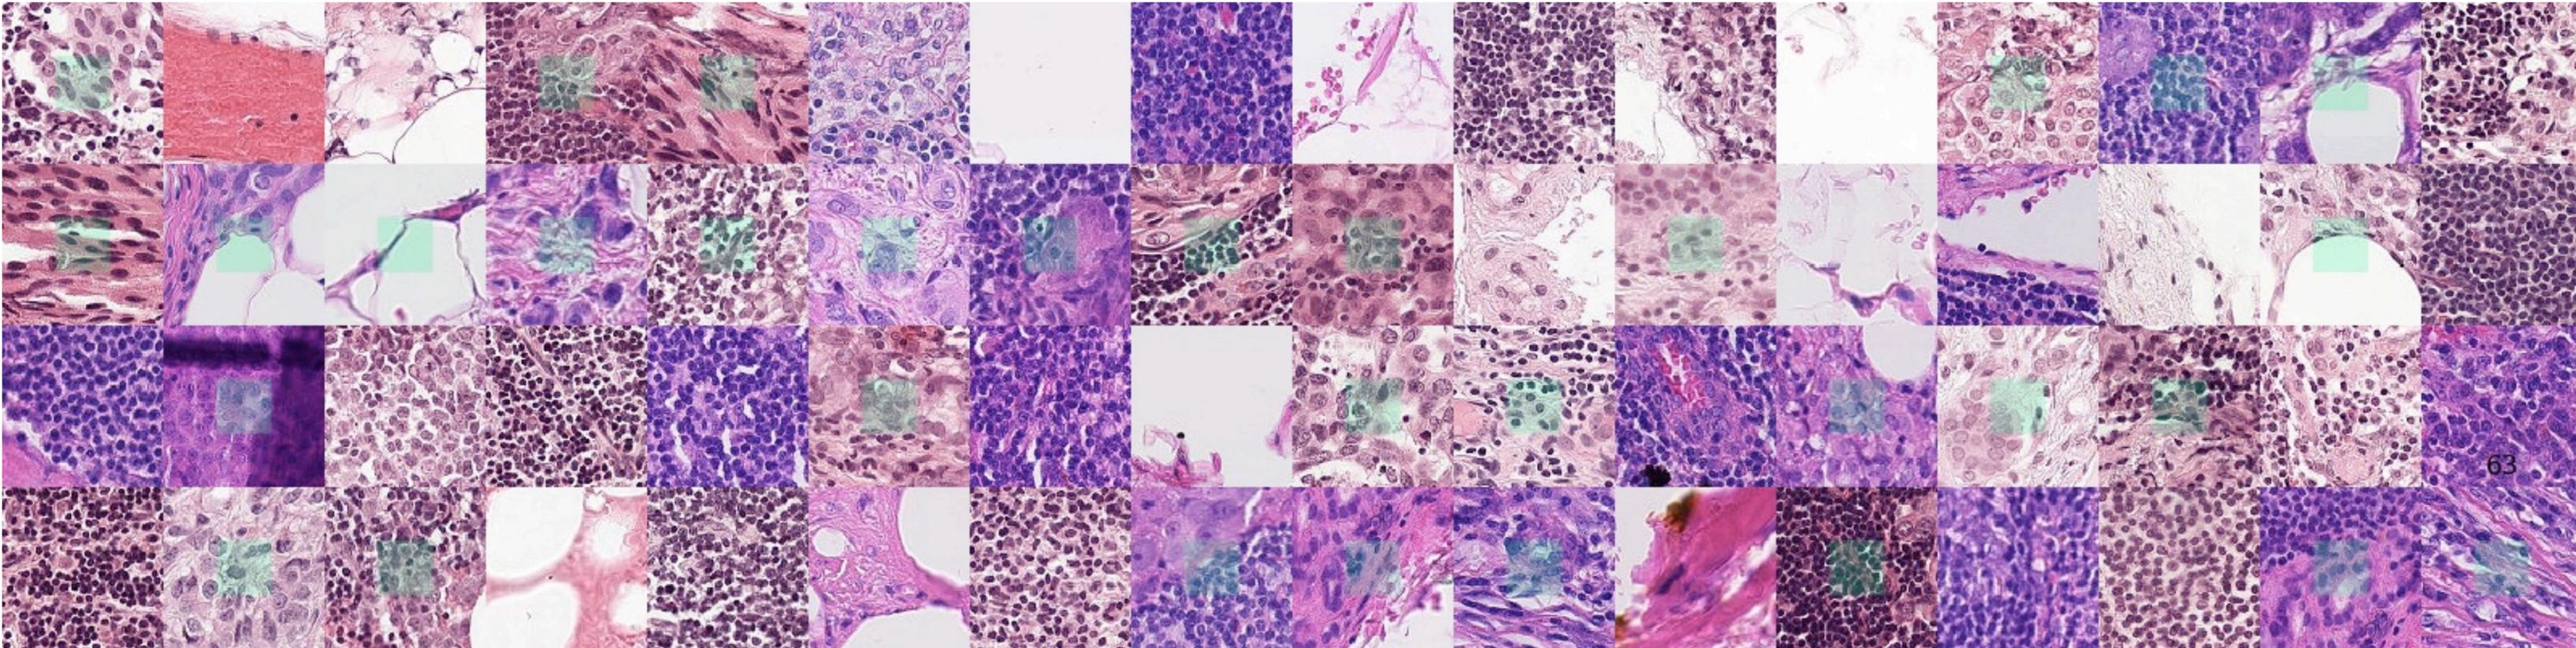


Vários cromossomos

Uma biblioteca de função específica de tipo de dados de saída por cromossomo

Mutação segura de dados intra e inter-cromossomos

CLASSIFICAÇÃO DE IMAGEM - PCAM - DADOS HISTOPATOLÓGICOS DE SEÇÕES DE LINFONODOS



O rótulo indica que a região central contém pelo menos um pixel de tecido tumoral.

O tecido tumoral na região externa do adesivo não influencia o rótulo.

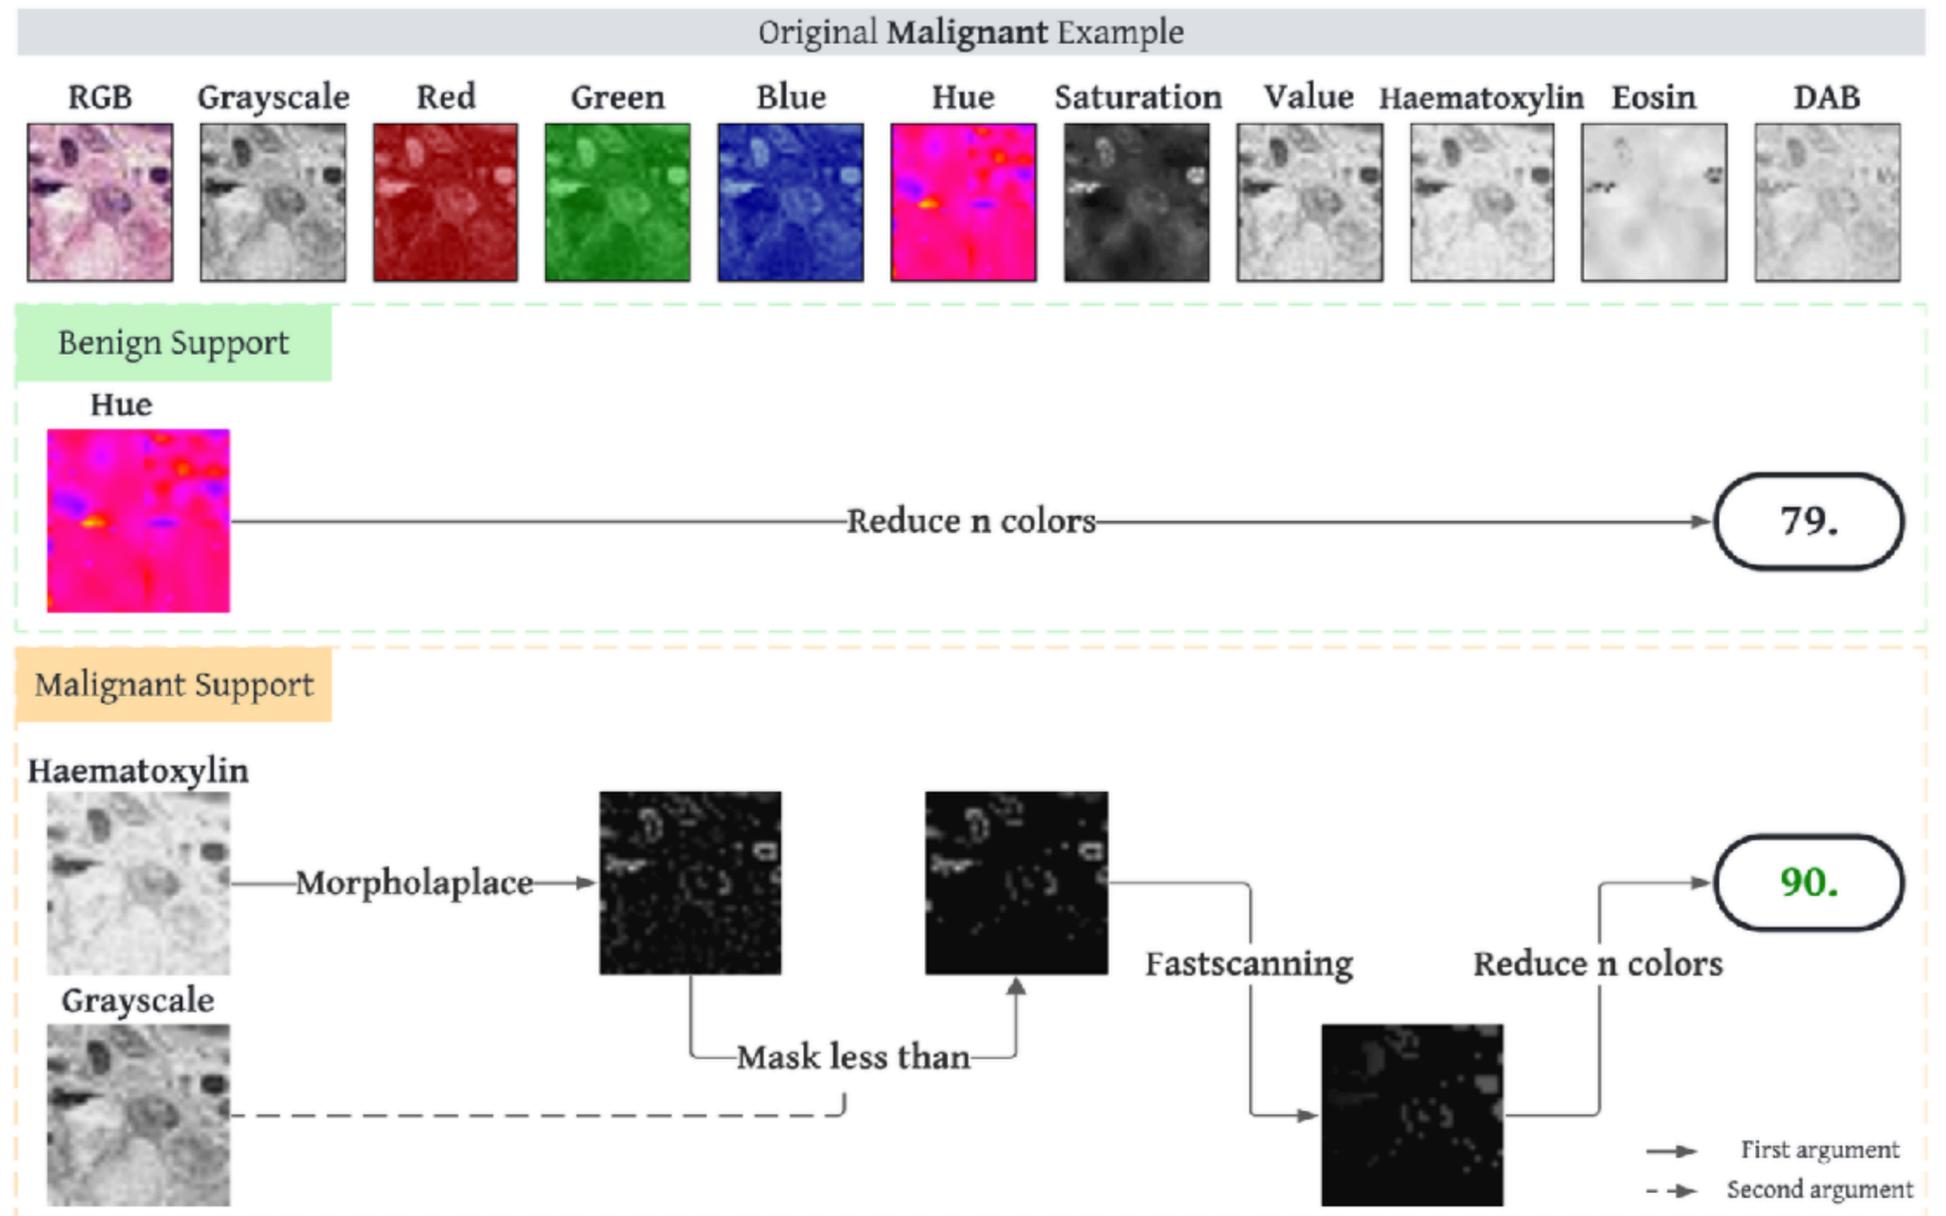
PCam é derivado do Desafio Camelyon16 - WSIs corados por hematoxilina e eosina de seções de linfonodos sentinelas.

APOIO DE MÉDICOS

Robin Schwob, Camille Franchet: médicos envolvidos na análise do pipeline

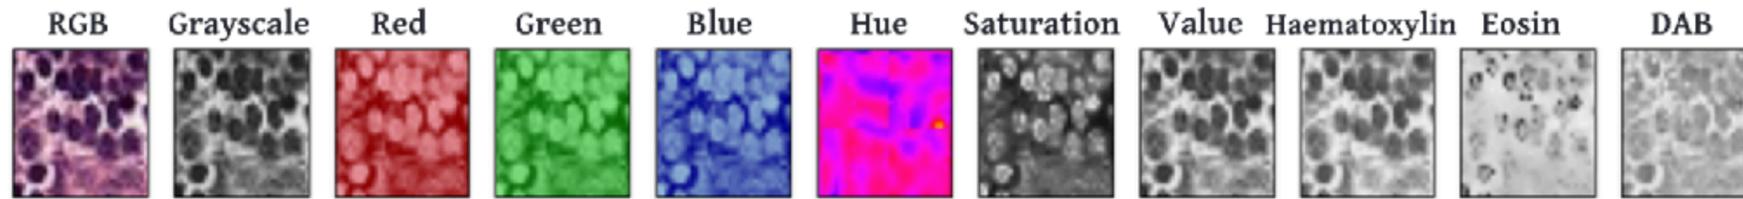
Eles sugeriram o canal HSV, pois entendem que esse canal é importante

O HUE foi introduzido e a CGP escolheu usá-lo - sem influência humana (direta)



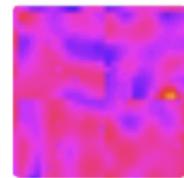
INTERPRETABILIDADE

Original Benign Example



Benign Support

Hue

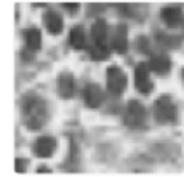


Reduce n colors

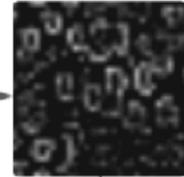
60.

Malignant Support

Haematoxylin



Morpholaplace



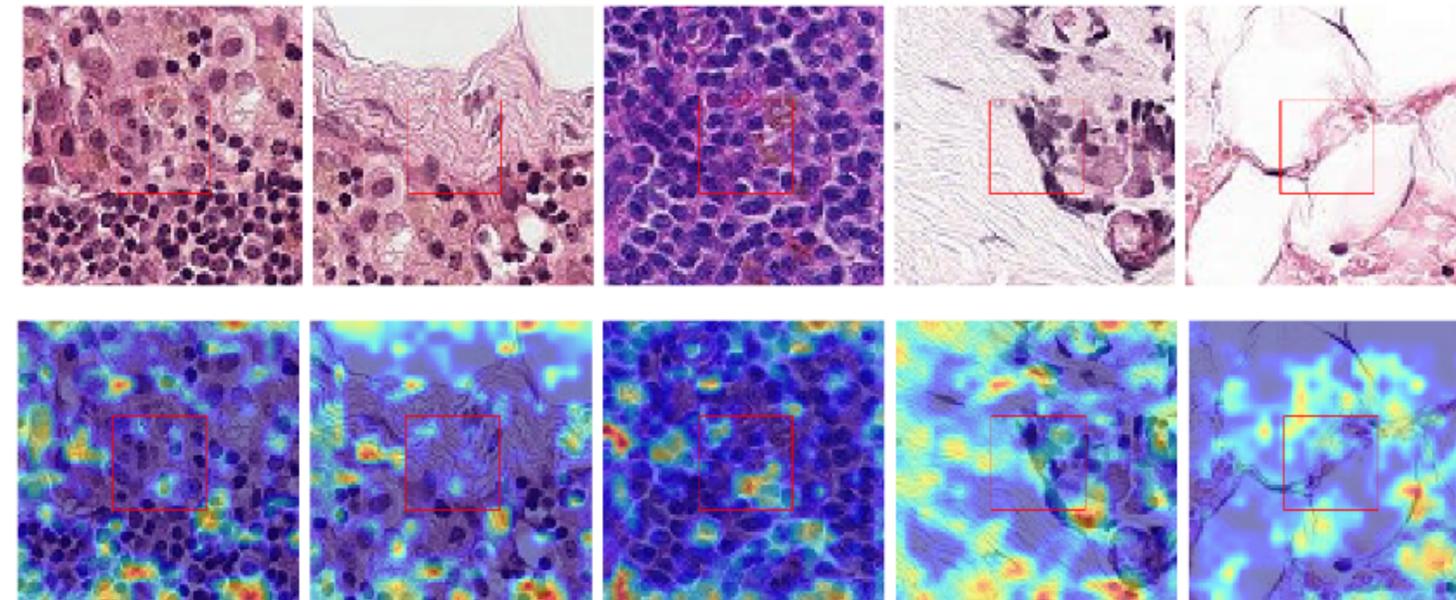
Mask less than



Fastscanning

Reduce n colors

1.



Resnet18's Grad-CAM

Só podemos usar técnicas de explicabilidade que claramente tem limitações

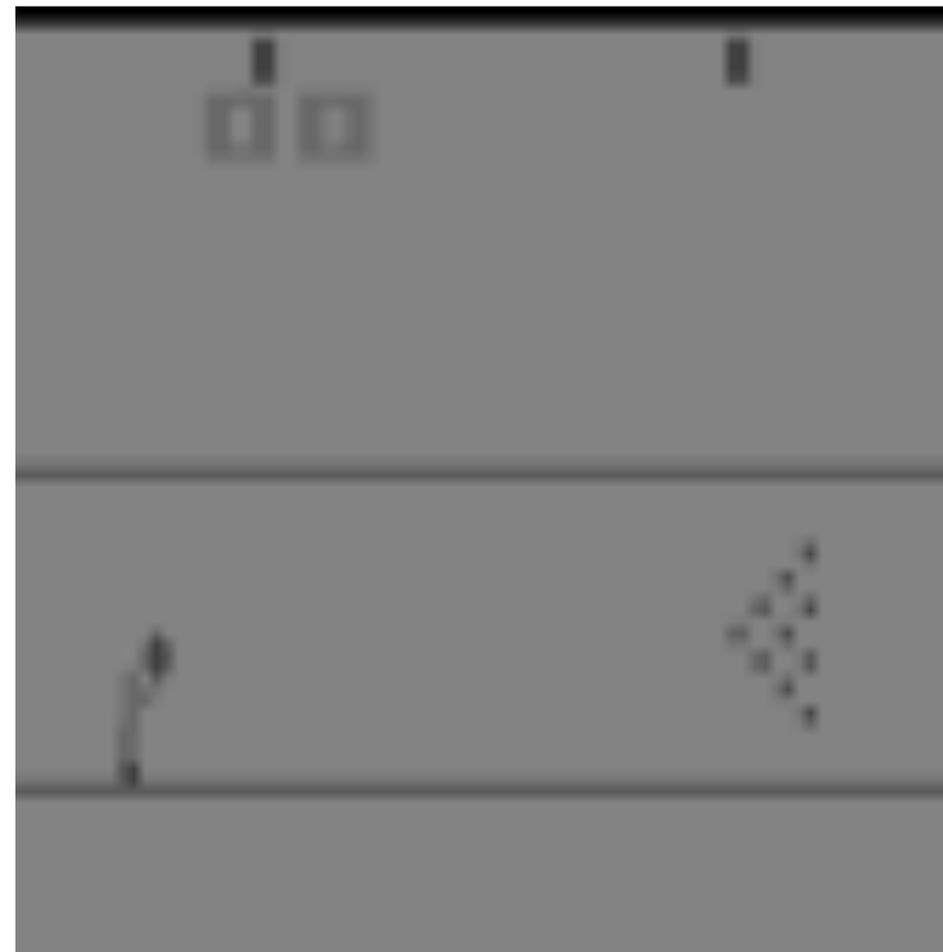
- Classificação de 'patches' de imagem histopatológica como câncer / não câncer



CONTROLE DE ROBÔS

A interpretabilidade é bem-sucedida quando a explicabilidade falha (e o oposto?)

INTERPRETABILIDADE VS EXPLICABILIDADE – ROBÓTICA/CASO DE CONTROLE

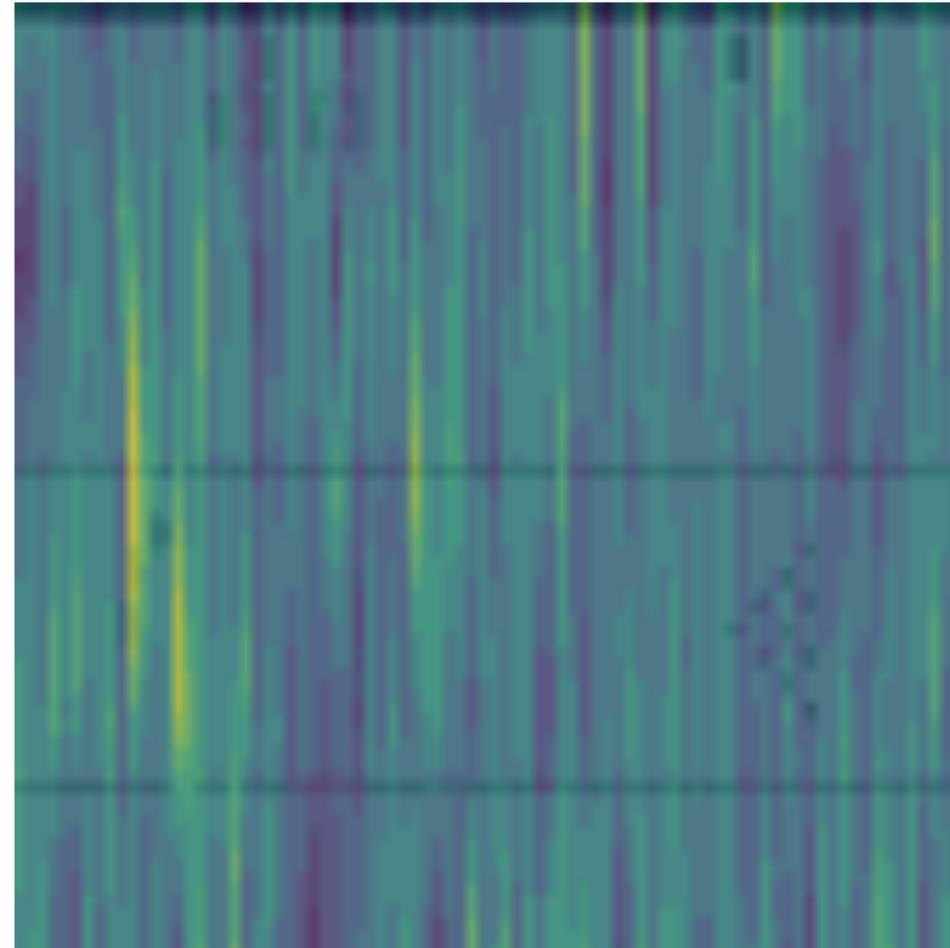


EXPLICABILIDADE – PODE PROVER INFORMAÇÕES ÚTEIS



Occlusion

EXPLICABILIDADE - ÚTIL, MAS COMO VERIFICÁ-LAS?



RISE

INTERPRETABILIDADE – CO; O CÓDIGO TEMOS TODOS DETALHES

```
ACTIONS = [0,1,2,3]
function evolved_policy_bowling(frame1, frame2, frame3, frame4)
  # OUTPUT NOOP
  output_noop = reduce_ncolors(frame2)

  # OUTPUT FIRE
  remove_top_bottom = maskfromto(frame4, exp(-1.0), 60.0)
  exponent = vertical_argmax(remove_top_bottom) # has the player
  reach the top ?
  # normally the exponent will be one if the player hasn't, 3
  otherwise
  n_diff_pixel_values = reduce_ncolors(frame1)
  details = tophat(frame4, n_diff_pixel_values,) # big Kernel =>
  makes pins salient
  whitest_pixel = argmax_position(details) # usually the pins
  whitest_pixel_orig_frame1 = argmax_position(frame1) # usually
  the head of the player
  dist_player_pins = dist(whitest_pixel_orig_frame1, whitest_pixel
  )
  output_fire = dist_player_pins^exponent

  # OUTPUT UP
  blackest_pixel = argmin_position(dilation(frame4))
  constant_coordinate = (27, 84) # last pixel
  closed_frame1 = closing(frame1)
  player = argmax_position(closed_frame1)
  player_vector = direction(player, constant_coordinate) # player
  to bottom_left
  output_up = dist_second(player_vector, blackest_pixel) # compare
  horizontal coordinate for both

  # OUTPUT DOWN
  output_down = 1.0

  outputs = (output_noop, output_fire, output_up, output_down)
  return ACTIONS[argmax(outputs)]
end
```

Algorithm 3 Pseudo-code of simplified Bowling player.

Input: f_1, f_2, f_3, f_4 ▶ last 4 game frames (f_4 is current)

Output: action \in {NOOP, FIRE, UP, DOWN}

▶ Never do DOWN

▶ Verify the top portion of the screen

player_reach_top \leftarrow has_player_reach_top(f_4)

if screen_blinks(f_4) and player_reach_top **then**

 player_reach_top \leftarrow false ▶ A strike causes a blink which

 causes the player to disappear momentarily

end if

if player_reach_top **then**

return FIRE

 ▶ and keeps pressing FIRE

end if

nb_grays \leftarrow nb_of_distinct_gray_values(f_2)

▶ The only

support for NOOP

▶ Usually the ball or the player

darkest_pixel \leftarrow get_darkest_horizontal_position(f_4)

dist_to_corner \leftarrow approx_dist_to_corner(darkest_pixel)

if nb_grays \geq dist_to_corner **then**

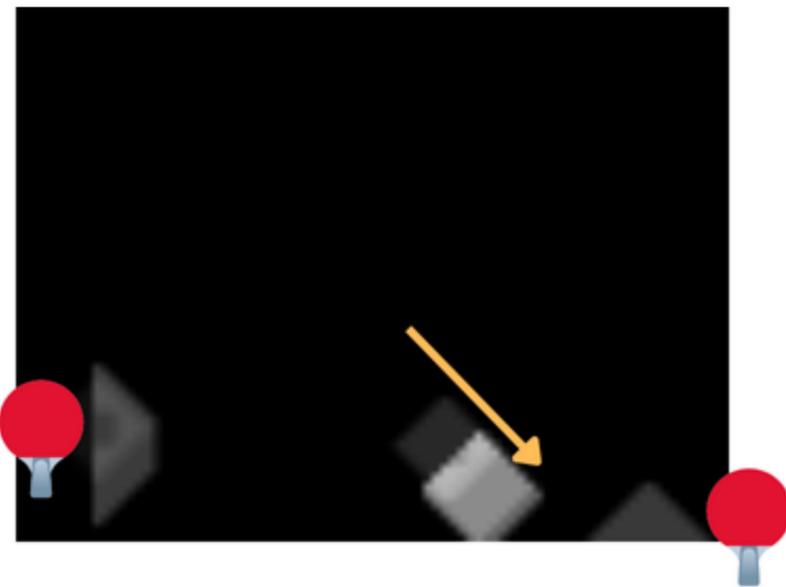
return NOOP

else

return UP

end if

INTERPRETABILIDADE – PODEMOS INTERPRETAR O QUE A MÁQUINA ESTÁ FAZENDO



Algorithm 1 Pseudo-code of Pong player.

Input: f_1, f_2, f_3, f_4 ▶ last 4 game frames (f_4 is current)

Output: action $\in \{\text{NOOP}, \text{UP}, \text{DOWN}\}$

▶ decision-making for NOOP

$x_{\text{mid}} \leftarrow f_{\text{width}}/2$ ▶ horizontal midpoint of frame

if $x_{\text{ball}, f_2} < x_{\text{mid}}$ **then** ▶ ball in frame 2 did not cross midpoint

return NOOP

end if

▶ decision-making for UP

$d_{f_2}, d_{f_4} \leftarrow \text{dilate}(f_2), \text{dilate}(f_4)$ ▶ image dilation on frames

$\text{bias} \leftarrow \text{img_diff}(d_{f_4}, d_{f_2})$ ▶ left bias when ball goes down, right

bias when ball goes up

$\text{biased}_{f_2} \leftarrow \text{img_add}(\text{bias}, d_{f_2})$ ▶ biased frame

$x_{\text{up}} \leftarrow \text{x_of_brightest}(\text{biased}_{f_2})$

▶ decision-making for DOWN

$\text{details}_{f_2} \leftarrow \text{top-hat}(f_2)$ ▶ extract details/small elements

$x_{\text{down}} \leftarrow \text{x_of_brightest}(\text{details}_{f_2})$

if $x_{\text{up}} \geq x_{\text{down}}$ **then**

return UP

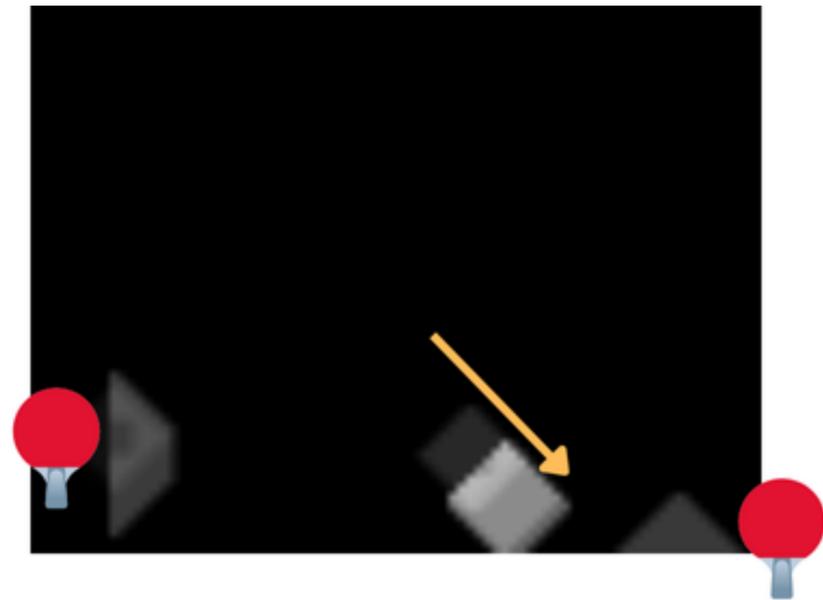
else

return DOWN

end if

O jogador de Pong dilata a bola para capturar a direção da bola.

EXPLICABILIDADE – NÃO MOSTRA ISSO...





FEATURE SELECTION

Good in simple datasets, but reality has its ways...

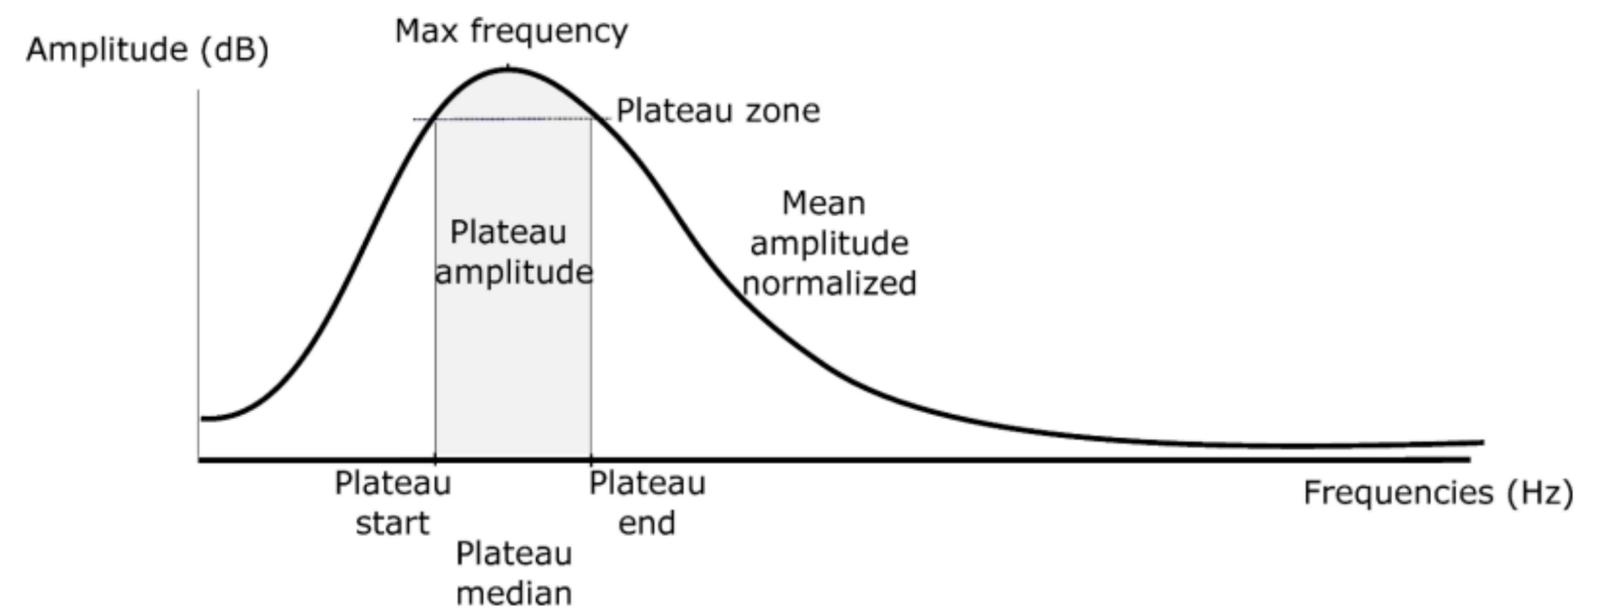
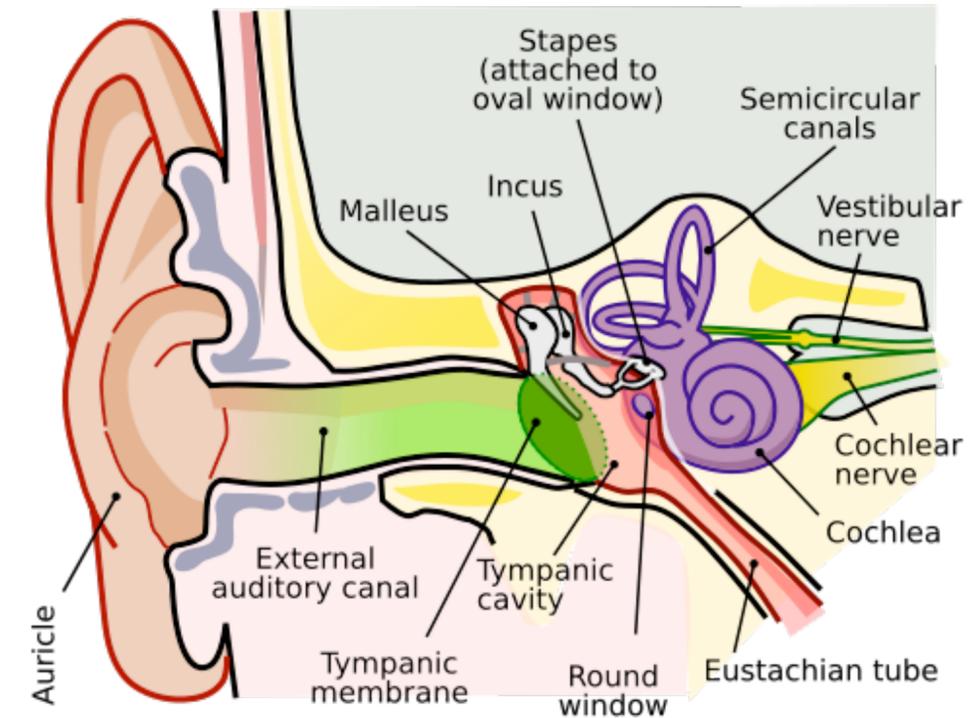
PERDA AUDITIVA

Paul Sauzel, Sylvain-Cussat Blanc,
Patricia Balaresque

Perda auditiva → Preocupação crescente
com a saúde

Alguns fatores têm um impacto (idade)

Existem outros recursos importantes?

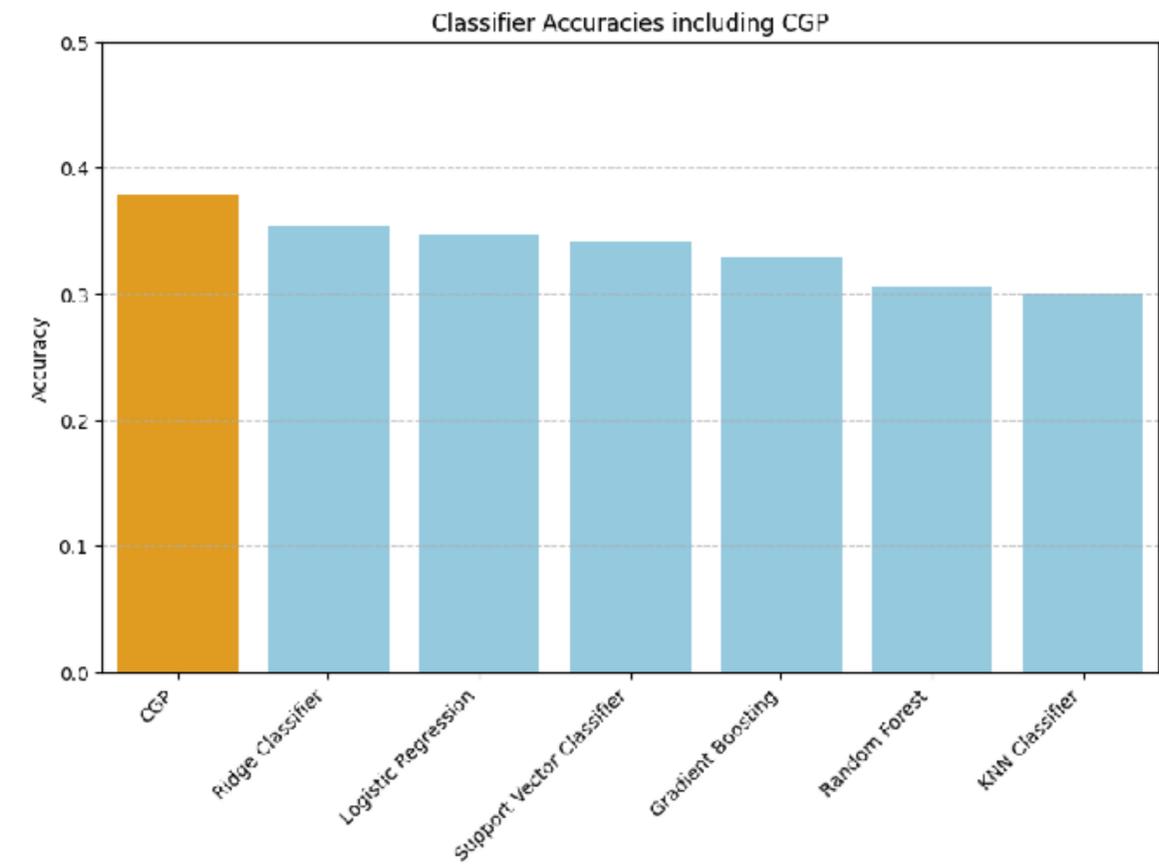


SELEÇÃO DE ATRIBUTOS – LIMITES

Dataset sociológico

Code pop	Population	Country	Mother language	Family language class	Environmental elements	N	Nf	Nm
AND	Teligote	Ecuador	Quechua, Spanish	Amerindian & Indo-European	Rural-High altitude	36	19	17
BUK	Bukhara	Uzbekistan	Uzbek, Tajik	Altai & Indo-European	Urban-steppes	46	23	23
CHA	Chateauville	Gabon	Fang	Niger-Congo	Rural-forest	24	13	11
COL	Colta	Ecuador	Quechua, Spanish	Amerindian & Indo-European	Rural-High altitude	47	23	24
CPT	Cape Town	South Africa	English	Indo-European	Urban-plains	45	25	20
DOU	Doumassi	Gabon	Baka	Niger-Congo	Rural-forest	27	18	9
ESG	Essang	Gabon	Baka	Niger-Congo	Rural-forest	29	14	15
ESS	Essicot	Gabon	Fang	Niger-Congo	Rural-forest	13	7	6
LEI	Leicester	England	English	Indo-European	Urban-plains	42	23	19
MEB	Meubeum	Gabon	Fang	Niger-Congo	Rural-forest	19	12	7
NUK	Nukus	Uzbekistan	Karakalpak	Altai	Urban/Rural-Steppes	53	29	24
QUI	Quito	Ecuador	Spanish	Indo-European	Urban-altitude	50	25	25
XHO	Cape Town Xhosa	South Africa	Xhosa	Niger-Congo	Urban-plains	17	11	6
All populations						448	242	206

CGP falha... ML também



SELEÇÃO DE ATRIBUTOS – MAS PODE FUNCIONAR

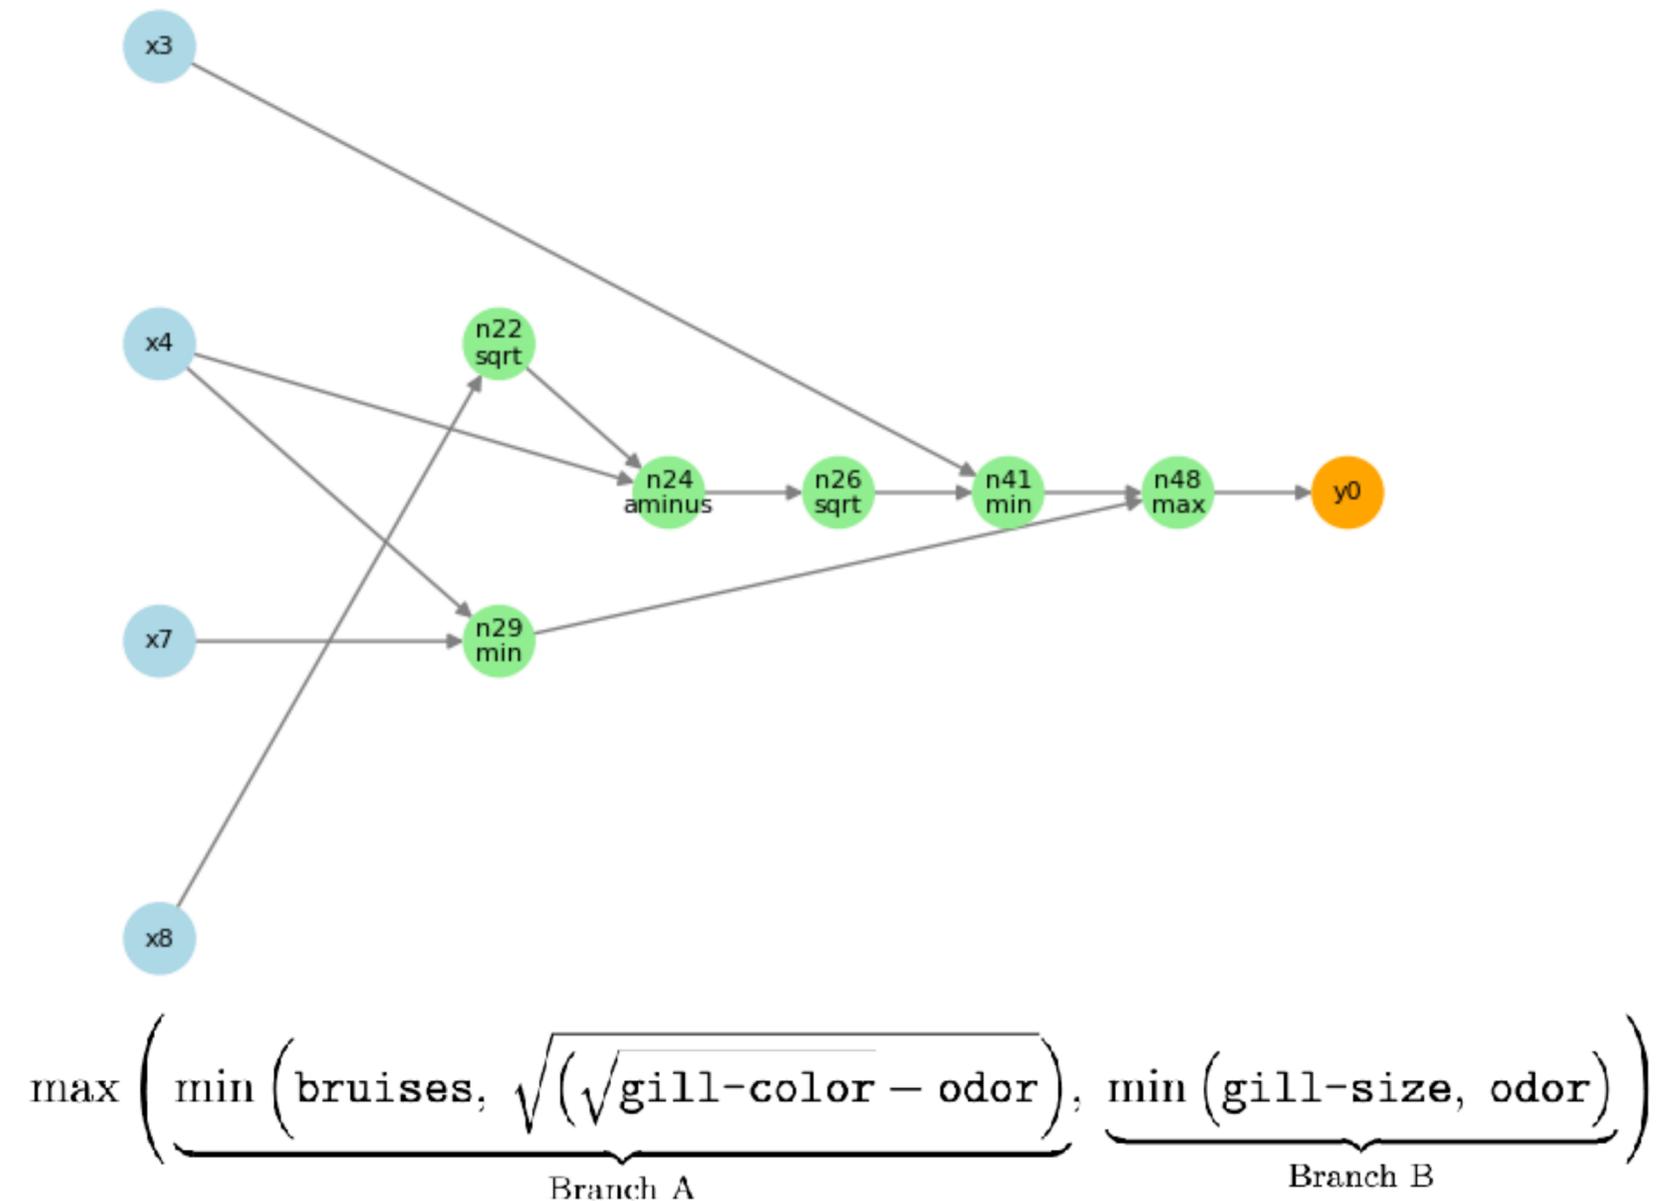
22 características categóricas

Um modelo CGP selecionou 4 atributos e obteve 95% de acurácia

Table 5.3: Performance comparison of CGP and baseline models on three datasets. Values are mean R2/accuracy and \pm is standard deviation.

Model	1027_ESL	Car Evaluation	Mushroom
CGP	0.76 \pm 0.00	0.80 \pm 0.01	0.92 \pm 0.01
Logistic / Linear Reg.	0.84 \pm 0.03	0.82 \pm 0.01	0.95 \pm 0.01
Ridge Reg./Classifier	0.84 \pm 0.03	0.77 \pm 0.01	0.93 \pm 0.01
Random Forest	0.83 \pm 0.03	0.98 \pm 0.01	1.00 \pm 0.00
Gradient Boosting	0.83 \pm 0.03	0.98 \pm 0.01	1.00 \pm 0.00
SVR / SVC	0.83 \pm 0.03	0.96 \pm 0.01	1.00 \pm 0.00
KNN Regr./Classifier	0.83 \pm 0.03	0.96 \pm 0.01	1.00 \pm 0.00

Active Genome Graph (Inputs \rightarrow Internal \rightarrow Outputs)



SOMENTE 2 CLASSES?

PMLB dataset para classificação

CGP vs XGboost e Random Forest

Com e sem Boruta - estado da arte em 'feature selection'

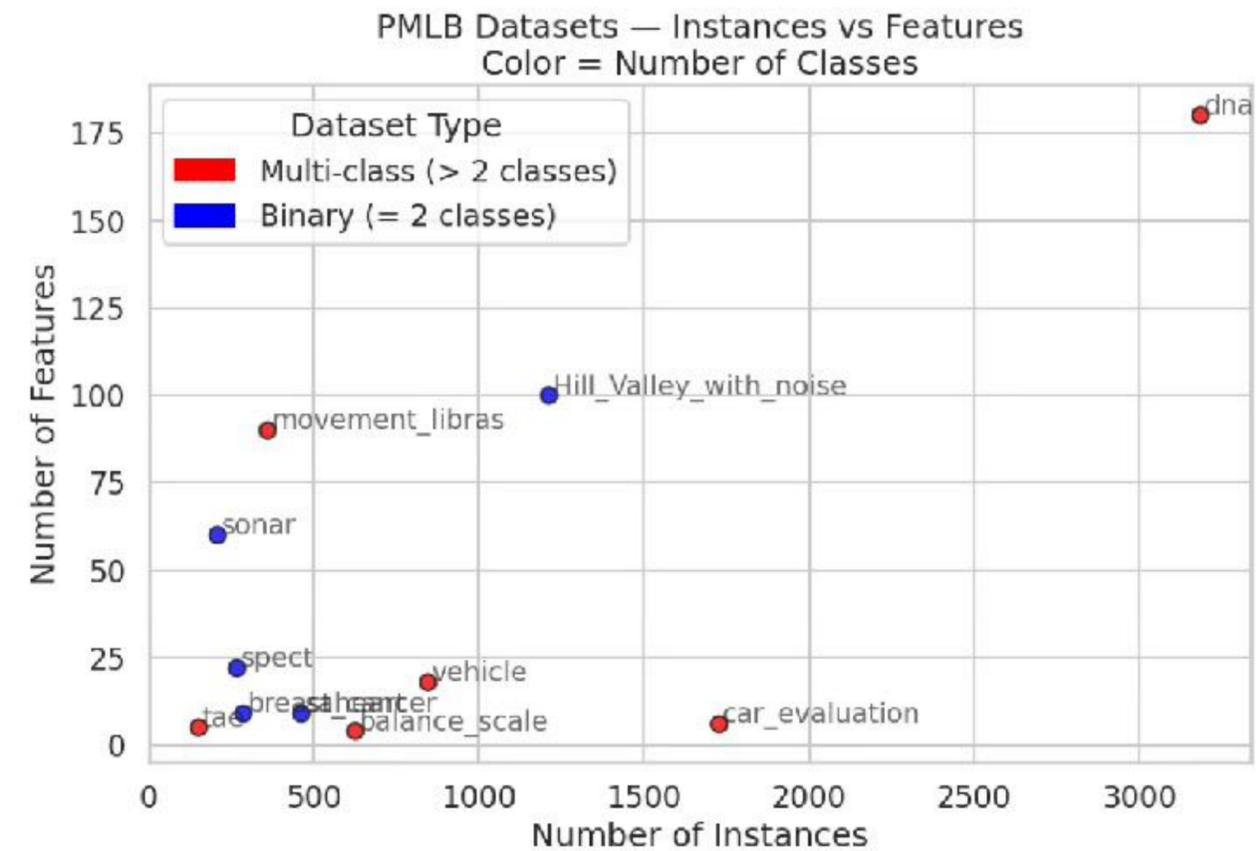


Fig. 1. PMLB dataset comparison.

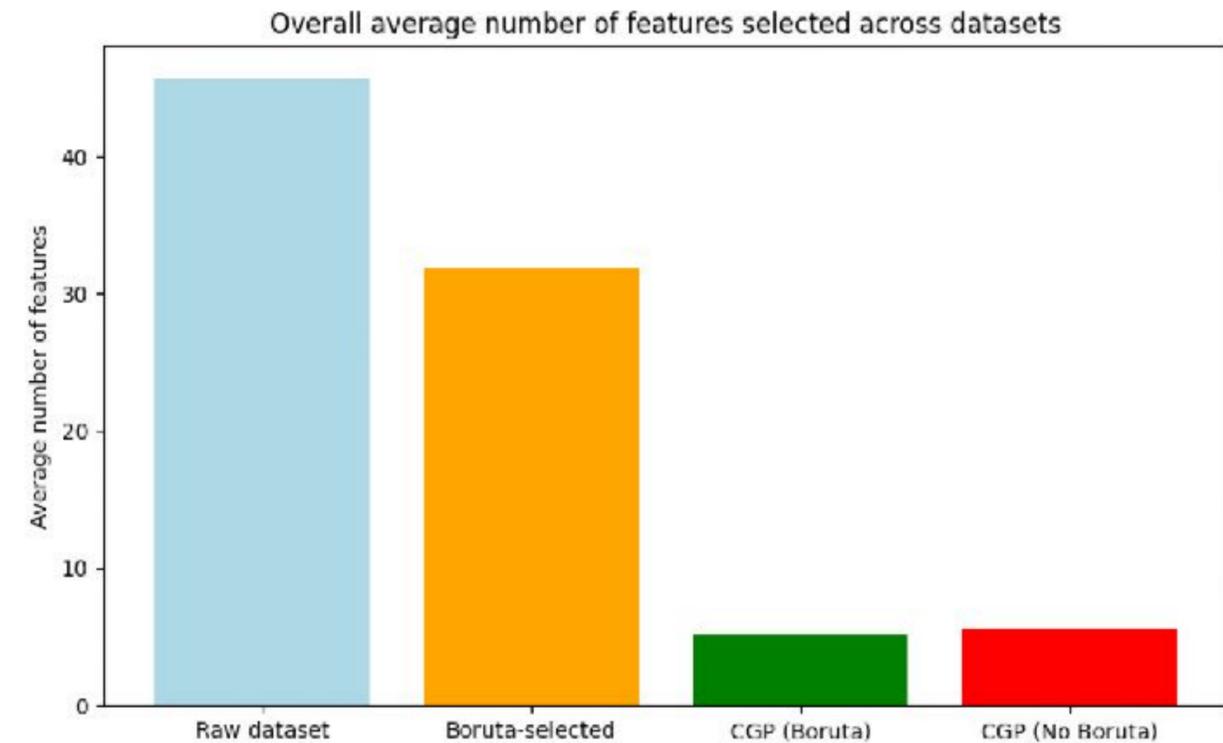


Fig. 2. Average number of features across method

SOMENTE 2 CLASSES?

Surpresa: boruta não tem efeito positivo claro

CGP funciona bem em problemas com 2 classes

Funciona mal em problemas com vários atributos e classes

Method / Dataset	Saheart (2)	Sonar (2)	Hill Valley (2)
CGP1 (Boruta)	0.68 (0.03)	0.67 (0.07)	0.66 (0.04)
CGP2 (Boruta)	0.66 (0.04)	0.65 (0.07)	0.64 (0.06)
Random Forest (Boruta)	0.64 (0.01)	0.75 (0.02)	0.58 (0.01)
XGBoost (Boruta)	0.63 (0.00)	0.76 (0.00)	0.58 (0.00)
CGP1 (Default)	0.71 (0.03)	0.67 (0.07)	0.67 (0.03)
CGP2 (Default)	0.70 (0.03)	0.67 (0.04)	0.64 (0.06)
Random Forest (Default)	0.68 (0.01)	0.78 (0.01)	0.58 (0.01)
XGBoost (Default)	0.65 (0.00)	0.76 (0.00)	0.58 (0.00)

Method / Dataset	Breast Canc (2)	Spect (2)	TAE
CGP1 (Boruta)	0.70 (0.03)	0.80 (0.00)	0.50 (0.06)
CGP2 (Boruta)	0.72 (0.03)	0.80 (0.00)	0.45 (0.06)
Random Forest (Boruta)	0.64 (0.01)	0.80 (0.00)	0.61 (0.00)
XGBoost (Boruta)	0.64 (0.00)	0.80 (0.00)	0.52 (0.00)
CGP1 (Default)	0.71 (0.03)	0.80 (0.02)	0.47 (0.08)
CGP2 (Default)	0.70 (0.04)	0.80 (0.03)	0.48 (0.07)
Random Forest (Default)	0.64 (0.01)	0.87 (0.01)	0.61 (0.00)
XGBoost (Default)	0.64 (0.00)	0.85 (0.00)	0.52 (0.00)

Method / Dataset	Balance Scale	DNA	Vehicle
CGP1 (Boruta)	0.78 (0.11)	0.40 (0.02)	0.45 (0.03)
CGP2 (Boruta)	0.76 (0.11)	0.39 (0.05)	0.44 (0.03)
Random Forest (Boruta)	0.79 (0.00)	0.96 (0.00)	0.74 (0.01)
XGBoost (Boruta)	0.86 (0.00)	0.97 (0.00)	0.78 (0.00)
CGP1 (Default)	0.80 (0.08)	0.40 (0.01)	0.46 (0.03)
CGP2 (Default)	0.75 (0.09)	0.40 (0.02)	0.44 (0.03)
Random Forest (Default)	0.79 (0.00)	0.96 (0.00)	0.74 (0.01)
XGBoost (Default)	0.86 (0.00)	0.97 (0.00)	0.78 (0.00)



TAKEAWAYS

Is this the end?

TAKEAWAYS

O CGP funciona bem e é interpretável

Funciona bem com dados biomédicos limitados

Interpretável (até um ponto) e tão explicável quanto DL

Aplique seu método de interesse a diferentes domínios - encontre onde seu trabalho não funciona

Objetivos Futuros

Exploração do espaço de busca mais profunda

Multitarefa/Design multiobjetivo → precisão, interpretabilidade, robustez, etc.

Operadores evolutivos (crossover, mutação, etc.) adaptados à estrutura do problema

Explicabilidade vs interpretabilidade (Rogel Thompson)

OBRIGADO

**DE MODELOS DE CAIXA PRETA A MODELOS TRANSPARENTES:
PROGRAMAÇÃO GENÉTICA CARTESIANA NA ANÁLISE DE IMAGENS
BIOMÉDICAS**

*Yuri Lavinas
University Toulouse Capitole*