

Investigação da Tomada de Decisões em Redes Neurais Evolutivas Aplicadas no Controle de Ratos Virtuais

Daniel M. Souza¹, Ariane A. Costa², Renato Tinós¹

¹*Departamento de Computação e Matemática, FFCLRP, Universidade de São Paulo (USP), Ribeirão Preto - SP, Brasil*

²*Grupo de Redes Complexas Aplicadas de Jataí, ICET, Universidade Federal de Jataí, (UFJ), Jataí - GO, Brasil*

daniel.martins.souza@usp.br, ariadne.costa@ufj.edu.br, rtinos@ffclrp.usp.br

Resumo—Redes neurais artificiais podem ser utilizadas para controlar agentes computacionais empregados no estudo do comportamento de ratos em testes comportamentais. Em investigações anteriores, o agente, denominado rato virtual, foi controlado por uma rede neural recorrente do tipo *Echo State Network* (ESN), cujos pesos da camada de saída foram otimizados por um Algoritmo Genético. A função de aptidão do AG foi formulada de modo a modelar o conflito entre medo e exploração, possibilitando a simulação de diferentes níveis de ansiedade, bem como os efeitos de fármacos ansiolíticos e ansiogênicos, por meio da variação de um parâmetro que pondera punição e recompensa. No entanto, apesar dos resultados promissores, ainda é desafiador interpretar como a rede neural toma decisões, fator essencial para compreender o comportamento do rato virtual. Neste trabalho, investiga-se o processo de tomada de decisão dos agentes por meio da análise das ativações dos neurônios do reservatório da ESN. Propõe-se também o uso de Árvores de Decisão como método explicativo complementar. Foi identificado que um pequeno número de neurônios do reservatório influencia decisivamente as saídas motoras e que Árvores de Decisão conseguem representar de forma simples esses processos, reforçando a viabilidade da abordagem explicável.

Palavras-chaves—Rato Virtual. *Echo State Network*. Algoritmo Genético. Neuroevolução. Inteligência Artificial Explicável.

I. INTRODUÇÃO

As Redes Neurais Artificiais (RNAs) têm se consolidado como ferramentas poderosas para a modelagem de sistemas complexos em Biologia e Neurociências [1]. Nestas aplicações, destacam-se as Redes Neurais Recorrentes (*Recurrent Neural Networks* - RNNs) devido à sua capacidade de processar sequências temporais e dinâmicas [2]. Particularmente, as *Echo State Networks* (ESNs) emergem como uma arquitetura particularmente eficiente por produzirem comportamentos dinâmicos complexos aliados a um baixo esforço

computacional para o treinamento. ESNs são caracterizadas por um reservatório de neurônios recorrentes com pesos aleatórios, sendo que apenas os pesos da camada de saída são ajustados durante o treinamento. Essa característica simplifica o processo de aprendizado, em especial quando saídas desejadas estão disponíveis. Mesmo quando o aprendizado não é supervisionado, como o problema tratado nesta pesquisa, ESNs são atraentes já que um número menor de parâmetros necessita ser otimizado.

Trabalhos anteriores demonstraram a viabilidade de se utilizar RNNs para modelar o comportamento de ratos virtuais em testes comportamentais. Esses estudos utilizaram AGs para otimizar a arquitetura e/ou os pesos das RNNs, permitindo a simulação de comportamentos baseados em conflitos entre medo e exploração. Em [3], um modelo baseado em Redes Recorrentes de Elman foi proposto para o rato virtual. Neste modelo, todos os pesos da Rede Recorrente de Elman são otimizados por um AG. A função de avaliação (*fitness*) compara diretamente a trajetória do agente computacional com trajetórias reais obtidas em experimentos com ratos em um dispositivo conhecido como Labirinto em Cruz Elevado (LCE). A validação dos modelos obtidos é realizada por meio da análise do tempo gasto e número de entradas nos braços abertos e fechados do labirinto, permitindo comparações quantitativas entre o modelo proposto e os ratos reais.

A partir de [4], uma nova abordagem foi adotada, na qual a função de *fitness* passou a ser baseada em um modelo teórico de comportamento proposto por [5], que descreve o comportamento em termos do conflito entre duas forças opostas: a curiosidade, que motiva a exploração, e o medo. Essa formulação foi implementada em todos os estudos posteriores, nos quais a função de *fitness* é composta por dois termos: um que recompensa o comportamento exploratório e outro que penaliza a exposição ao perigo. Nesses modelos, os dados experimentais com ratos reais são utilizados apenas na etapa de validação, e não na otimização do agente. Em

Este trabalho foi parcialmente financiado por Fundação de Amparo à Pesquisa do Estado de São Paulo - FAPESP (processos #2024/15430-5 e #2024/08485-8), Conselho Nacional de Pesquisa - CNPq (processos #304640/2024-7 e #131723/2024-3) e Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - CAPES (processo #88881.076216/2024-01).

[6], apenas os pesos da Rede de Elman são otimizados, ao passo que em [7], a arquitetura da rede também é otimizada. Estes trabalhos mostram que, ao ajustar o peso relativo entre os dois termos da função de *fitness*, é possível simular o comportamento de ratos sob influência de substâncias que modulam o nível de ansiedade, como drogas ansiolíticas ou ansiogênicas.

Em [8], o modelo proposto em [7] foi estendido para o estudo de ratos em outro aparato experimental: a Caixa Claro-Escuro. Já em [9], o rato virtual foi aplicado no aparato de Campo Aberto. O trabalho traz ainda outra inovação: ao invés de utilizar o modelo de Elman, o rato virtual utiliza uma ESN. Como os pesos do reservatório da ESN são aleatórios, apenas os pesos da camada de saída precisam ser ajustados. Para tal, um AG foi proposto. Aqui, o modelo proposto em [9] é investigado enfatizando o processo de tomada de decisão do rato virtual enquanto navega no aparato de Campo Aberto.

Apesar de sua eficiência, RNAs não são interpretáveis. Ou seja, embora sejam capazes de produzir bons mapeamentos entrada-saída, as decisões tomadas por esses modelos não são interpretáveis em termos rotineiramente utilizados por especialistas humanos [10]. Por outro lado, modelos que são interpretáveis, como as Árvores de Decisão (ADs), são em geral pouco eficientes em problemas complexos.

Investigar as interações entre os neurônios do reservatório e seu papel no processo de decisão do rato virtual pode ajudar especialistas a compreender o comportamento dos agentes, computacionais e/ou biológicos. Pode também ajudar a entender como a ESN toma as decisões. Para isso, neste trabalho, propõe-se estudar o processo de tomada de decisões do rato virtual por meio da análise das ativações dos neurônios do reservatório da ESN. O modelo proposto em [9] é utilizado aqui para o treinamento da ESN utilizada para controle de um rato virtual no teste em Campo Aberto. Em [11], o processo de tomada de decisões foi investigado para redes de Elman utilizadas no modelo proposto em [7] para o rato virtual navegando no LCE. Entretanto, a rede ESN, por sua simplicidade, permite analisar de modo mais simples o papel dos neurônios no processo de decisão do rato virtual. Ainda, de forma a obter de forma automática as regras utilizadas pelo rato virtual para as tomadas de decisões a partir das ativações dos neurônios, utiliza-se um modelo *surrogate* interpretável: as ADs.

II. METODOLOGIA

Deseja-se investigar o papel das ativações dos neurônios do reservatório no processo de tomadas de decisões em uma ESN que controla o rato virtual no teste de Campo Aberto [9]. O ambiente virtual é modelado para refletir condições realistas dos experimentos com ratos reais, com dimensões apropriadas, visando observar comportamentos de exploração.

A. Rato Virtual

A ESN utilizada é composta por três componentes principais: entrada, reservatório e saída (Figura 1). O vetor de entrada é dado pela ativação de seis sensores de distância

($s_1, s_2, s_3, s_4, s_5, s_6$) localizados em torno do agente (rato virtual). Esses sensores têm saída igual a 1 quando ativados, isto é, quando há um obstáculo a uma distância menor que o limiar r , e 0 caso contrário. As medidas s_1, s_3 e s_5 são para $r = 10$ cm, enquanto s_2, s_4 e s_6 são para $r = 30$ cm como ilustrado na Figura 2.




Fig. 1: *Echo State Network* utilizada para controlar o rato. Por simplicidade, as conexões recorrentes dos neurônios localizados no reservatório não são mostradas.




Fig. 2: Sensores do rato virtual: s_1, s_3 e s_5 são sensores de curta distância e s_2, s_4 e s_6 são sensores de longa distância

Para cada posição na arena que o rato virtual estiver navegando, a ESN gera uma saída correspondente a uma ação, tendo como entrada as seis leituras dos sensores de distância. O número de ações que o rato pode tomar são quatro: andar para frente, girar 45 graus para a direita, girar 45 graus para a esquerda ou girar 90 graus para esquerda. Desse modo, o número de neurônios na camada de saída da ESN é quatro. O neurônio de saída com máxima ativação define a ação tomada pela ESN a cada instante de tempo. Caso a ação dada pela ESN seja andar para a frente e isso não seja possível devido à presença de uma parede na frente do agente, então o mesmo permanece imóvel. O valor utilizado para o número de neurônios no reservatório, também usado em [9], é 50.

Apenas os pesos entre a camada intermediária (reservatório) e a camada de saída serão otimizados pelo AG. Os pesos do reservatório e os pesos entre a camada de entrada e o reservatório são fixos durante o treinamento. Eles serão gerados aleatoriamente e normalizados no início das execuções

do AG de acordo com o procedimento descrito em [12]. A recorrência entre os neurônios do reservatório é esparsa, com uma taxa de 1%, conforme indicado por [12].

No AG, o indivíduo (vetor de pesos) é avaliado após um determinado número de passos de tempo do agente na arena virtual. O *fitness* do indivíduo é calculado de acordo com a trajetória realizada pelo rato virtual, sendo composto por um somatório envolvendo dois termos: o primeiro termo refere-se à recompensa para o caráter exploratório (curiosidade) do agente; o segundo representa o perigo ao qual o agente é exposto em diferentes regiões da arena (medo) [7]. A função de *fitness* é dada por:

$$f(x) = \sum_{t=1}^T (r(a_t, s_t, m_t) + \beta p(s_t)), \quad (1)$$

sendo:

- T o número de passos de tempo do rato virtual no campo aberto (iterações);
- a_t a ação tomada pelo robô no instante de tempo t ;
- s_t o vetor com a leitura dos sensores no instante de tempo t ;
- m_t o vetor onde são armazenadas as últimas b leituras dos sensores;
- b o tamanho do vetor de memória;
- $r(a_t, s_t, m_t)$ a recompensa, que é igual a 1 se a ação é andar para frente e $z < h(s_t, m_t)$, e 0 caso contrário;
- z um número aleatório com distribuição uniforme no intervalo $[0, 1]$;
- $h(s_t, m_t)$ a variável que assume valor 1 se a leitura atual dos sensores não se iguala a nenhuma das leituras armazenadas em m_t e $h(s_t, m_t) = 1 - \gamma/g(s_t, m_t)$, caso contrário;
- γ uma constante escolhida no intervalo $[0, 1]$;
- $g(s_t, m_t)$ a posição no vetor onde s_t se iguala a $m_t[i]$, para alguma posição i ;
- $p(s_t)$ a punição, que é igual a -1 se $l < k(s_t)$, e 0, caso contrário, sendo l um número aleatório com distribuição uniforme no intervalo $[0, 1]$;
- $k(s_t)$ a variável que modela o fato de o rato ficar mais exposto a punições se um número menor de sensores é ativado. Ou seja, o rato recebe em média um número menor de punições se está mais próximo às paredes. A variável pode assumir valores entre α e $\alpha/7$, de acordo com a equação:

$$k(s_t) = (\alpha)/(q + 1) \quad (2)$$

- q é o número de sensores ativados na leitura s_t ;
- α uma constante escolhida no intervalo $[0, 1]$;
- β o parâmetro que controla a importância relativa de cada um dos dois termos conflitantes da função de *fitness*.

Para a ESN, os seguintes parâmetros são utilizados: tamanho do vetor de entrada (6 sensores), número de neurônios na camada de saída (4 ações) e taxa de recorrência no reservatório (1%). No AG, são utilizados os mesmos hiperparâmetros utilizados em trabalhos anteriores: número de passos de tempo do

rato virtual (300 iterações), número de execuções (30), número de gerações (500), tamanho da população (100 indivíduos), $\alpha = 0,07$ e $\gamma = 0,9$.

Para simular o efeito de ansiedade no rato, são escolhidos diferentes valores de β . Valores menores simulam comportamentos de ratos com menos ansiedade, que tendem a explorar mais o ambiente. Valores maiores de β aumentam o peso da punição (segundo termo da Equação 1), simulando comportamentos de ratos mais ansiosos, para os quais o medo é maior. Alterando o valor de β , o modelo reproduz o comportamento de ratos sob diferentes dosagens de drogas para controle de ansiedade.

Para a simulação dos ratos no ambiente de campo aberto, três regiões da arena foram consideradas, como mostrado na Figura 3. Essas regiões são essenciais para avaliar a ansiedade do rato assim como as características relevantes do comportamento exploratório do rato no teste de campo aberto.




Fig. 3: Campo aberto (200 cm x 120cm) e as três regiões consideradas nas simulações: 1) Região Externa (E), 2) Região Interna (I) e 3) Região Central (C).

Os ratos tendem a evitar áreas abertas e expostas, como a Região Central, preferindo permanecer próximos às áreas periféricas (Região Externa). Assim, um maior tempo gasto na Região Externa pode indicar um maior nível de ansiedade, enquanto um aumento na exploração de outras regiões sugere uma redução na ansiedade. Nesse contexto, a função de *fitness* é responsável por ajustar o nível de ansiedade do modelo por meio do parâmetro β , proporcionando comportamentos mais ansiosos ou exploratórios.

B. Investigação da Influência dos Neurônios no Processo de Decisão

Para cada conjunto de parâmetros testado, o rato virtual com melhor *fitness* dentre 30 execuções foi selecionado para investigação da influência dos neurônios no processo de decisão. Durante a simulação dos ratos no campo aberto, foram registradas, a cada passo de tempo, as ativações dos 50 neurônios do reservatório e das saídas correspondentes da rede. Como cada simulação contém 300 iterações, foram coletados, para cada uma, 300 vetores de ativação do reservatório juntamente com os respectivos valores de ativação da camada

de saída. A trajetória do rato virtual na arena também foi registrada.

Como o número de neurônios do reservatório é grande, propõe-se aqui uma alternativa de modo a gerar automaticamente as regras que definem as decisões da ESN a partir das ativações dos neurônios do reservatório. Para isso, construiu-se uma AD a partir das ativações dos neurônios do reservatório (entradas da AD) e dos neurônios da camada de saída com maior valor de ativação em cada instante de tempo (saídas desejadas da AD).

Uma AD é gerada para cada rato virtual produzido pelo AG para um dado valor de β . Para o treinamento da AD, 80% dos dados coletados na trajetória (formada por 300 pontos) foram utilizados, enquanto os 20% restantes foram reservados para a avaliação do modelo.

O objetivo dessa abordagem é identificar quais neurônios do reservatório exercem maior influência sobre os neurônios da camada de saída e também como a decisão é tomada a partir destas ativações. Dessa maneira, busca-se compreender como as ativações dos neurônios contribuem para o comportamento exploratório do rato no ambiente de campo aberto.

III. RESULTADOS

Os resultados foram obtidos a partir dos melhores indivíduos de 30 execuções do AG, desenvolvido em C/C++, para um dado valor de β . Para isso, utilizou-se o simulador desenvolvido anteriormente pelo grupo de pesquisa [9]. Modificou-se o simulador para coletar as informações necessárias para a análise da tomada de decisão. Cada execução do AG consistiu em 500 gerações e uma população de 100 indivíduos. Foram analisados os dados de 30 ratos virtuais com $\beta = 0,5$ (simulando um baixo nível de ansiedade) e 30 ratos virtuais com $\beta = 6$ (simulando um perfil mais ansioso).

A. Ratos virtuais obtidos pelo AG

As trajetórias obtidas nas simulações revelaram padrões comportamentais distintos entre os grupos com diferentes valores de β . Contudo, para ambos os valores ($\beta = 0,5$ e $\beta = 6$), observou-se uma tendência dos ratos virtuais em permanecer por mais tempo na região externa da arena, associada a uma menor punição devido à proximidade com as paredes. Alguns ratos virtuais inclusive permaneceram parados próximos às paredes, o que diminui a chance de serem punidos, apesar de diminuir também a recompensa devido à exploração.

Os indivíduos com $\beta = 0,5$ apresentaram um comportamento significativamente mais exploratório, percorrendo todas as regiões da arena com frequência, o que está diretamente relacionado à menor penalização imposta nas áreas central e interna. Em contrapartida, os ratos virtuais com $\beta = 6$ exibiram um padrão de movimento mais restrito à periferia da arena, caracterizando um comportamento de esquiva consistente com um perfil ansioso. Essa diferença ocorre devido a como o parâmetro β afeta na distribuição de recompensa e punições durante a exploração da regiões.

Para evidenciar esses comportamentos, a Figura 4 apresenta as trajetórias das simulações dos dois indivíduos mais aptos, i.e., que obtiveram maiores valores de *fitness*, para $\beta = 0,5$. Cada simulação é referente a um rato virtual, i.e., a uma execução do AG. Nestas simulações, observa-se um padrão de movimentação abrangente, caracterizando um comportamento exploratório. Esta tendência é ressaltada pelos mapas de calor correspondentes (Figura 5).




Fig. 4: Trajetórias dos dois ratos virtuais com maiores *fitness* para $\beta = 0,5$. O círculo verde representa a posição inicial do rato, enquanto o círculo vermelho mostra a posição final.




Fig. 5: Mapas de calor das trajetórias apresentadas na Figura 4.

A Figura 6 mostra as trajetórias dos dois ratos virtuais com maiores *fitness* para $\beta = 6$. Nestes casos, os ratos permanecem mais restritos à região externa, com movimentação reduzida. Esse padrão de movimento sugere um comportamento característico de animais ansiosos, que evitam a área central da arena devido ao medo. Na Figura 7, são apresentados os mapas de calor correspondentes, que destacam esses comportamentos de esquiva e baixa movimentação.




Fig. 6: Trajetórias dos dois ratos virtuais com maiores *fitness* para $\beta = 6$.




Fig. 7: Mapa de calor para as trajetórias apresentadas na Figura 6.

B. Análise do comportamento e tomada de decisão dos Ratos Virtuais

Para a análise do processo de tomada de decisão dos ratos virtuais no teste de campo aberto, foram selecionados os agentes com melhores valores de *fitness* para os dois valores de β . Assim, primeiramente foram investigadas graficamente as ativações dos neurônios da camada do reservatório e sua influência nas ativações dos neurônios de saída da ESN. Essa abordagem foi adotada com o objetivo de identificar padrões evidentes nos comportamentos dos neurônios do reservatório da ESN. Por se tratar de um reservatório composto por 50 neurônios, a análise das ativações para compreender como esses neurônios interagem e influenciam a saída da rede durante o processo de tomada de decisão apresentou-se como um desafio.

Inicialmente, analisou-se o rato virtual com comportamento menos ansioso, cuja trajetória é apresentada no gráfico à esquerda da Figura 4. Tal rato possui um perfil predominantemente exploratório, ativando o neurônio de saída 4 com maior frequência, conforme ilustrado na Figura 8. Essa saída é responsável pela ação de andar para frente ou, caso não seja possível avançar devido a obstáculos na arena, manter o rato parado. Quando essa situação ocorreu, o rato tendeu a realizar uma rotação, estimulando a ativação da saída 3, responsável por uma rotação de 90° na arena, conforme ilustrado no gráfico da esquerda na Figura 4. Nota-se que o rato virtual caminha em linha reta até que uma parede seja detectada por um dos sensores da frente, quando então ele faz uma rotação de 90°. Como consequência, o rato virtual se move ao lado das paredes em sentido anti-horário na arena.

Analisando os instantes de $t = 22$ a 50 (Figura 8), é possível perceber a influência de alguns neurônios sobre a ativação das saídas 3 (rotação de 90°) e 4 (andar para frente). Os neurônios 2, 35, 37 e 45 apresentam um comportamento similar: à medida que suas ativações aumentam, a ativação da saída 3 também aumenta, tornando-se predominante. Além disso, esses neurônios geralmente aumentam suas ativações enquanto o rato permanece parado na arena. Como consequência, os neurônios 24, 36, 39, 43 e 50 tendem a diminuir suas ativações, reduzindo, por sua vez, a ativação da saída 4, o que evidencia a influência direta desses neurônios sobre essa saída, conforme ilustrado na Figura 9.

A Figura 10 mostra o resultado da AD para o melhor rato virtual com valor de $\beta = 0,5$, i.e., o rato virtual cujos dados foram apresentados anteriormente. A AD apenas compara a ativação do neurônio 37 do reservatório com o limiar de 0,435. Se a ativação é menor que o limiar, a ação é andar para a frente. Quando o rato não pode mais andar para a frente devido ao obstáculo, a ativação do neurônio 37 aumenta, ocasionando a mudança da ação (para rotação de 90°). O processo de decisão gerado pela AD reforça as observações feitas entre os instantes de $t = 22$ a 50, destacando o neurônio 37 como um dos principais influenciadores da escolha da saída predominante. Esse neurônio, já identificado por seu aumento de ativação quando o rato permanece parado, foi suficiente para separar perfeitamente as classes, evidenciando sua relevância. A análise mostra que certos neurônios do reservatório têm forte impacto nas saídas, o que contribui para uma interpretação mais clara da dinâmica interna da ESN.

Analisando agora um rato virtual com comportamento mais ansioso ($\beta = 6$), cuja trajetória é apresentada no gráfico da esquerda da Figura 6. Foram apresentados apenas o período $t = 12$ a 40, para facilitar a visualização. Observa-se que, diferentemente dos ratos mais exploradores, esse perfil tende a andar menos para a frente, o que ocasiona uma ocorrência maior de rotação do rato. Assim, aparecem comportamentos repetitivos com mais frequência. A ativação reduzida da saída 4 (andar para a frente) é perceptível na Figura 11. Tal comportamento reflete uma estratégia na qual ratos reais ansiosos preferem rotacionar a cabeça, possivelmente avaliando o entorno antes de tomar ações mais diretas como avançar.

Analisando os instantes entre $t = 12$ a 40, é possível perceber a ocorrência de mais ativações da saída 3 (rotacionar 90°). Observa-se também a ocorrência da saída 1 (rotacionar 45 graus para a esquerda) uma única vez durante a trajetória, o que dificulta a compreensão de quais neurônios são mais influentes para a sua ativação. Os neurônios 2 e 45 apresentam um comportamento similar igualmente ao rato virtual menos ansioso, o que reforça a influência destes neurônios para a ativação da saída 3. O mesmo ocorre para os neurônios 24 e 50, que tendem a diminuir suas ativações, reduzindo, por sua vez, a ativação da saída 4 (andar para a frente), conforme ilustrado na Figura 11. Vale destacar que apenas os pesos da camada de saída da ESN variam para os diferentes ratos virtuais gerados pelo AG. Os pesos entre a entrada e o reservatório, e entre os neurônios do reservatório, permanecem inalterados para todos os ratos virtuais. Desta forma, existe uma relação entre os comportamentos dos neurônios do reservatório da ESN para os diferentes ratos virtuais, o que facilita a análise. Destaca-se também que para o rato virtual analisado para $\beta = 6$, a estratégia de navegação foi andar em direção à parede, girar 90° (para a esquerda), e quando a parede lateral é detectada, girar 45° (para a esquerda). A partir daí, aparece um movimento repetitivo: detectar a parede, girar duas vezes em 90°, e andar para frente até detectar a parede novamente.

A Figura 12 apresenta o resultado da AD treinada para o melhor rato virtual com $\beta = 6$. O modelo aponta o neurônio 24 como a raiz da AD, o que reforça sua relevância já observada




Fig. 8: Ativações dos neurônios para o rato virtual obtido para $\beta = 0,5$ cuja trajetória é mostrada a esquerda da Figura 4.




Fig. 9: Ativações dos neurônios de $\beta = 0,5$ entre os instantes $t = 22$ a $t = 50$.




Fig. 10: Árvore de decisão do rato com $\beta = 0,5$. A saída 4 (*Classe₁* da AD) gera a ação de andar para frente; já a saída 3 (*Classe₀* da AD), gera a ação de rotação de 90°).

anteriormente. Além disso, os neurônios 42 e 28 definem quando o rato deve andar para a frente ou rotacionar em 90°. Por outro lado, o neurônio 6 com uma ativação alta acaba sendo responsável também por outro comportamento rotacional (gira 45° para a esquerda), que pode ser executado pelo rato uma única vez. Essa estrutura mostra que, mesmo diante de contextos comportamentais mais complexos, a ESN ainda consegue identificar padrões nos neurônios responsáveis diretamente pelas principais decisões motoras.

IV. CONCLUSÃO

Os resultados obtidos com os ratos virtuais demonstram que diferentes valores do parâmetro β influenciam diretamente no comportamento exploratório, permitindo simular perfis ansiosos e não ansiosos. As análises das ativações dos neurônios do reservatório da ESN revelaram padrões consistentes associados às escolhas das ações motoras, embora a complexidade dessas interações represente um desafio interpretativo, especialmente devido ao número elevado de neurônios envolvidos. Portanto, foi proposta aqui a análise por um modelo surrogate interpretável (árvore de decisão). Este modelo permitiu analisar o processo de tomada de decisões pelos ratos virtuais gerados pelo AG.

Como trabalho futuro, pretende-se investigar a influência da importância e interação dos neurônios do reservatório nos processos de decisão do rato virtual. Para isso, espera-se utilizar o Genetic Algorithm with Linkage Learning (GAwLL). Além de otimizar os pesos da camada de saída da ESN, o GAwLL fornecerá informações sobre as interações relevantes entre neurônios do reservatório, e sua importância, durante o processo de otimização. Esse recurso deve facilitar a interpretação das interações internas da ESN por meio de grafos, o que pode revelar grupos funcionais de neurônios e suas contribuições específicas para as ações tomadas pelo agente. Assim, espera-se que a implementação futura utilizando o GAwLL amplie significativamente a compreensão sobre os mecanismos neurais da ESN, permitindo análises mais automatizadas, robustas e interpretáveis. Além disso, seu

uso pode abrir novas possibilidades na modelagem de comportamentos complexos, aproximando ainda mais os resultados simulados dos padrões observados em experimentos biológicos reais.

REFERENCES

- [1] Y. Cohen, T. A. Engel, C. Langdon, G. W. Lindsay, T. Ott, M. A. Peters, J. M. Shine, V. Breton-Provencher, and S. Ramaswamy, "Recent advances at the interface of neuroscience and artificial neural networks," *Journal of Neuroscience*, vol. 42, no. 45, pp. 8514–8523, 2022.
- [2] H. Jaeger, "The "echo state" approach to analysing and training recurrent neural networks-with an erratum note," *Bonn, Germany: German national research center for information technology gmd technical report*, vol. 148, no. 34, p. 13, 2001.
- [3] H. K. Shimo, A. C. Roque, R. Tinós, J. Tejada, and S. Morato, "Use of evolutionary robots as an auxiliary tool for developing behavioral models of rats in an elevated plus-maze," in *2010 Eleventh Brazilian Symposium on Neural Networks*. IEEE, 2010, pp. 217–222.
- [4] A. A. Costa, A. C. Roque, S. Morato, and R. Tinós, "A model based on genetic algorithm for investigation of the behavior of rats in the elevated plus-maze," in *Intelligent Data Engineering and Automated Learning-IDEAL 2012: 13th International Conference, Natal, Brazil, August 29-31, 2012. Proceedings 13*. Springer, 2012, pp. 151–158.
- [5] K. Montgomery, "The relation between fear induced by novel stimulation and exploratory drive," *Journal of comparative and physiological psychology*, vol. 48, no. 4, p. 254, 1955.
- [6] A. A. Costa, S. Morato, A. C. Roque, and R. Tinós, "A computational model for exploratory activity of rats with different anxiety levels in elevated plus-maze," *Journal of neuroscience methods*, vol. 236, pp. 44–50, 2014.
- [7] A. A. Costa and R. Tinós, "Investigation of rat exploratory behavior via evolving artificial neural networks," *Journal of neuroscience methods*, vol. 270, pp. 102–110, 2016.
- [8] M. A. B. Souza, E. E. B. da Silva, J. P. M. Tarrega, R. Tinós, and A. A. de Costa, "Simulation of rat behavior in a light-dark box via neuroevolution," in *Encontro Nacional de Inteligência Artificial e Computacional (ENIAC)*. SBC, 2022, pp. 449–460.
- [9] L. T. Raineri, R. S. Del Lama, R. M. Candido, A. A. Costa, and R. Tinós, "Robôs evolutivos para a investigação do comportamento de ratos no teste de campo aberto," *Revista Eletrônica de Iniciação Científica em Computação*, vol. 17, no. 2, 2019.
- [10] F. Doshi-Velez and B. Kim, "Towards a rigorous science of interpretable machine learning," *arXiv preprint arXiv:1702.08608*, 2017.
- [11] L. B. Domingos, "Investigação do processo de tomada de decisão em um agente inteligente utilizado em neurociência computacional," Ribeirão Preto, SP, Brasil, 2016, trabalho de Conclusão de Curso em Informática Biomédica.
- [12] H. Jaeger and H. Haas, "Harnessing nonlinearity: Predicting chaotic systems and saving energy in wireless communication," *Science*, vol. 304, no. 5667, pp. 78–80, 2004.




Fig. 11: Ativações dos neurônios para o rato virtual com $\beta = 6$ entre os instantes $t = 12$ a $t = 40$.




Fig. 12: Árvore de decisão do rato com $\beta = 6$. A saída 4 (*Classe₂* da AD) gera a ação de andar para frente, a saída 3 (*Classe₁* da AD) gera a ação de rotação de 90° e a saída 1 (*Classe₀* da AD) gera a ação de rotação de 45° para esquerda.