



Recyclebot: jogo para ensino de reciclagem utilizando um agente inteligente

Recyclebot: game for teaching recycling using an intelligent agent

Thiago da Silva Teixeira

tteixeira@alunos.utfpr.edu.br

Universidade Tecnológica Federal do Paraná, Ponta Grossa, Paraná, Brasil

Helyane Bronoski Borges

helyane@utfpr.edu.br

Universidade Tecnológica Federal do Paraná, Ponta Grossa, Paraná, Brasil

RESUMO

Este trabalho apresenta um jogo com temática de reciclagem denominado RecycleBot, voltado ao público infantil e deficiente intelectual. O alto consumo de recursos naturais e crescente industrialização, criam resíduos que agredem o ambiente. Um dos modos de recuperar estes recursos naturais é por meio da reciclagem. O hábito da reciclagem é um problema cultural, que pode ser aprendido de maneira prática. O jogo proposto visa simular a reciclagem com a ajuda de um agente inteligente, sendo um aprendizado em conjunto. O agente imita o jogador, tentando classificar cada lixo apresentado na tela, em que cada acerto do jogador desencadeia um treino de aprendizado por redes neurais do tipo perceptron de múltipla camada. Foi utilizada uma estratégia de pseudo-imitação do jogador, possibilitando que o agente aprenda mais rápido. O jogo apresentou bons resultados em termos de temática e treino do agente inteligente, porém requer testes com o público alvo, avaliando melhor o impacto de seu caráter educativo.

PALAVRAS-CHAVE: Jogo educacional. Redes neurais artificiais. Reciclagem.

ABSTRACT

This paper presents a recycling-themed game called RecycleBot, aimed at children and people with intellectual disabilities. The high consumption of natural resources and the increasing industrialization create residues that harm the environment. One of the ways to recover these natural resources is through recycling. Recycling is a cultural problem that can be learned in a practical way. The proposed game aims to simulate recycling with the help of an intelligent agent, being a joint learning process. The agent imitates the player, trying to classify each garbage presented on the screen, where each success of the player triggers a training of learning by multi-layer perceptron neural networks. A pseudo-imitation strategy of the player was used, enabling the agent to learn faster. The game presented good results in terms of theme and training of the intelligent agent, but requires testing with the target audience, better evaluating the impact of its educational character.

KEYWORDS: Educational game. Artificial neural networks. Recycling.



INTRODUÇÃO

Em 1987, a Organização das Nações Unidas (ONU) publicou o relatório *Our Common Future* (Nosso Futuro Comum). Um de seus tópicos é o desenvolvimento sustentável, definido como a forma de como as atuais gerações satisfazem as suas necessidades sem, no entanto, comprometer a capacidade de gerações futuras satisfazerem as suas próprias necessidades (IMPERATIVES, 1987). Com base neste princípio, foi criado os indicadores de desenvolvimento sustentável, que tem como um de seus indicadores a taxa de reciclagem nacional por toneladas de material reciclado (CF, 2015).

A iniciativa de crescimento sustentável, visa um crescimento econômico sem prejudicar gerações futuras, como aquecimento global (CLINE *et al.*, 1992) e destruição do ambiente natural (NAS-ROLLAHI *et al.*, 2020). Uma das estratégias para alcançar este objetivo é a recuperação de recursos em áreas de descarte, que possuem três abordagens: reciclagem, reutilização e remanufaturar (FERRER; WHYBARK, 2000). Este trabalho visa reforçar a primeira abordagem, a reciclagem.

A reciclagem contribui para um desenvolvimento sustentável, minimizando a utilização de fontes naturais, diminuindo quantidade de resíduos e aterramentos, formando uma consciência ecologia, valorizando a limpeza pública e gerando empregos (DONATO *et al.*, 2015).

A adoção da reciclagem pode ser feita através da criação de um hábito em meio população, onde ainda resiste a reciclagem por motivos culturais (ALMEIDA *et al.*, 2013), processo feito no Brasil em sua grande parte por catadores de lixo reciclável (SIQUEIRA;MORAES, 2009). Um modo de mudar este cenário cultural é por meio da educação (ALMEIDA *et al.*, 2013).

O ensino escolar possui seus desafios, utilizando recursos com loja, giz e avaliações do conhecimento passado em aula. Tal processo cria um distanciamento do indivíduo da experiência real, comparado a um aprendizado contextualizado de condição no seu dia adia, o que reforçaria o real aprendizado na criação do hábito da reciclagem (MAZZARINO;MUNHOZ; KEIL, 2012). Este trabalho propõem um jogo para reforço deste aprendizado pratico.

Jogos educativos computadorizados são atividades inovadoras no processo de ensino, que promovem o interesse e motivação, aumentando a atenção do aluno e criam a sensação que aprender é algo divertido (MORATORI, 2003). Sua aplicação em sala de aula pode ser um recurso didático de ensino para os educadores, sendo um rico instrumento para a construção do conhecimento (GRÜBEL; BEZ, 2006).

Neste sentido, este trabalho apresenta um jogo educacional denominado RecycleBot. Este jogo tem como tema principal a reciclagem. Explorando uma nova categoria de interação entre o jogador e um agente inteligente (RUSSELL; NORVIG, 2002), o qual é treinado por meio da aprendizagem por imitação (HUSSEIN *et al.*, 2017). O agente aprende conforme o desempenho do jogador, ou seja, quanto mais o jogador classifica corretamente a relação objeto-lixreira, mais o agente aprende utilizando um conceito de pseudo aprendizado por imitação.

Segundo o Ministério da Educação, dos 700.824 alunos matriculados na modalidade de educação especial, 47% apresentam deficiência intelectual (DUTRA *et al.*, 2007). Porém, grande parte dos docentes ainda seguem a proposta didática tradicional, sem adaptação de conteúdo, não considerando a diversidade da turma (GLAT; BLANCO, 2007). Espera-se de jogos educacionais melhorem o recurso didático dos docentes (GRÜBEL; BEZ, 2006), promovendo uma educação mais inclusiva.



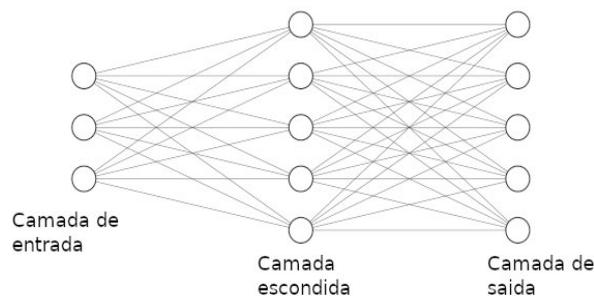
MATERIAIS E MÉTODOS

A área de estudo da inteligência artificial pode ser resumida como: o esforço para automatizar tarefas intelectuais normalmente feitas por humanos (CHOLLET, 2017). Uma de suas sub-áreas é a aprendizagem de máquina que pode ser definida como a capacidade de melhorar o desempenho na realização de alguma tarefa por meio da experiência (LORENA *et al.*, 2000).

Uma das técnicas que podem ser usadas na aprendizagem de máquina é a rede neural artificial (CHOLLET, 2017), que tem como base o conceito de perceptron (ROSENBLATT, 1958). Trata-se de um algoritmo bio-inspirado no neurônio, baseado na regra de Hebb (SUDJANTO; HASSOUN, 1994), em que quando um neurônio desencadeia outro neurônio, a conexão entre eles é reforçada. O perceptron utiliza esta regra considerando o erro de sua previsão, ajustando os pesos de suas conexões para contribuir para uma previsão correta (GÉRON, 2019).

O perceptron de múltipla camada (*Multi-Layer Perceptron (MLP)*) consistem em várias camadas de neurônios, processados por uma função sigmoide, que interagem utilizando conexões com peso (PAL; MITRA, 1992). As camadas de neurônios são divididas em camadas de entrada, camada escondida e camada de saída. A Figura 1 mostra um exemplo de configuração de uma MLP, com três neurônios na camada de entrada, cinco na camada escondida e cinco na camada de saída. A informação em uma MLP é transmitida de camada a camada, começando pela camada de entrada e terminando na camada de saída (LORENA *et al.*, 2000).

Figura 1 – Representação visual de um perceptron de múltipla camada, em que cada círculo representa um neurônio, com traços representando as conexões. Possui uma camada de entrada, escondida e de saída, da esquerda para direita, respectivamente.



Fonte: autoria própria.

O treinamento supervisionado de uma MLP possui duas fases, uma fase para frente (*forward*) e outra para trás (*back-propagation*). Na fase de *forward* da MLP recebe um vetor binário de tamanho igual ao número de neurônios na camada de entrada, a informação é transmitida de camada para camada por meio de uma ativação sigmoide, a ativação da camada de saída é comparada com o valor supervisionado, esta diferença é o erro cometido pela rede (PAL; MITRA, 1992). Na fase de *back-propagation*, o MLP propaga o erro da rede ajustando os pesos dos neurônios. O ajuste de pesos é definido por derivadas parciais, utilizando um gradiente descendente (RUDER, 2016) da função sigmoide (LORENA *et al.*, 2000).

RESULTADOS E DISCUSSÕES

Na modelagem do jogo, foi definido os aspectos de interação do jogo. Considerando a reciclagem como tema do jogo, foi definido uma interface de tela de jogo, onde contém as opções de lixeiras coloridas e os objetos (lixos) a serem reciclados. Com esse sistema, o jogador classifica os objetos que aparecem na tela



sendo observado por um agente inteligente, que aprende com o jogador a classificar corretamente o par objeto-lixeira.

Na definição de ferramentas, para o desenvolvimento do jogo foi escolhido o motor de jogo Godot (MANZUR; MARQUES, 2018), que envolve toda a programação de jogo, incluindo a do agente inteligente.

Cinco categorias de lixeira foram consideradas, não reciclável, metal, papel, plástico e vidros, respectivamente apresentados na Figura 2. Cada lixeira possui três objetos associados, que aparecem aleatoriamente para o jogador e o agente inteligente classificarem corretamente os pares objeto-lixeira.

Figura 2 - As categorias de lixeiras do jogo, cada uma com três objetos associados, sendo elas o não reciclável, metal, papel, plástico e vidro, respectivamente representados da esquerda para direita.

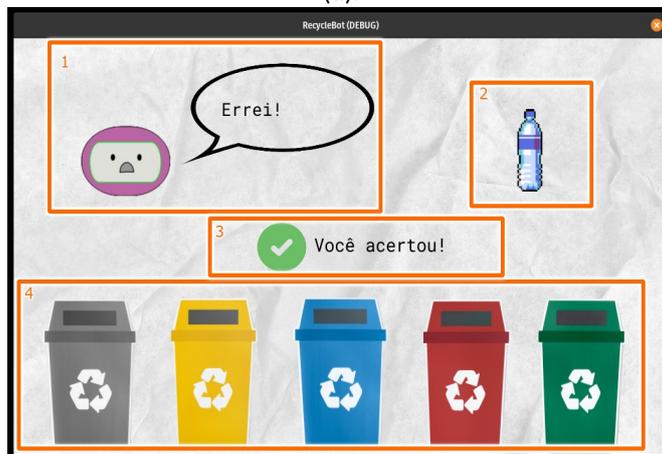


Fonte: Autoria própria.

A interface do jogo educacional RecycleBot é mostrada na Figura 2. O jogo funciona em uma estrutura de repetição formada por 6 etapas:

1. O jogo seleciona aleatoriamente um objeto para ser classificado pelo jogador, conforme ilustra a Figura 3b.
2. O agente inteligente avalia o objeto e diz sua hipótese de classificação (ver Figura 3a).
3. O jogador escolhe uma das lixeiras para inserir o objeto selecionado (ver Figura 3d).
4. O jogo retorna uma mensagem de acerto ou erro para o jogador (ver Figura 3c).
5. O Agente diz se ele acertou ou errou (ver Figura 3a).
6. Reinicia o Passo 1.

Figura 3 – A interface do jogo separada por áreas, sendo a face do agente juntamente com sua fala (a), o objeto a ser classificado pelo jogador (b), a confirmação de acerto ou erro do jogador (c) e as cinco lixeiras para escolha do jogador (d).



Fonte: Autoria própria.

O agente inteligente utiliza uma MLP para classificar os objetos em classes de lixeira. Para isso é necessária uma vetorização destes dados, como modo de redução de complexidade. A Tabela 1 mostra os vetores binários definidos para representar tanto os objetos, quanto as lixeiras.

Tabela 1 – Vetores binários de representação de objetos e lixeira, de uma determinada classe.

Classe	Vetor do objeto	Vetor da lixeira
Metal	100	10000
Não reciclado	010	01000
Papel	001	00100
Plástico	110	00010
Vidro	011	00001

Fonte: Autoria própria.

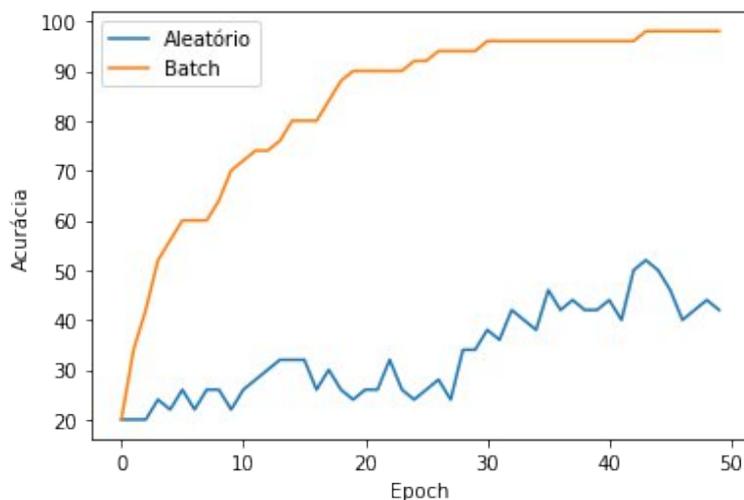
A MLP do agente inteligente contém três neurônios na camada de entrada, cinco na camada escondida e cinco na camada de saída. Mesma configuração observada na Figura 1. Sendo compatível com o tamanho dos vetores binários de dados da Tabela 1, com entrada tamanho três e saída de tamanho cinco.

O agente não classifica os objetos corretamente no começo do jogo, pois a MLP é inicializada com pesos aleatórios. Para o agente classificar um objeto, sua rede neural recebe de entrada o vetor correspondente aquele objeto (Tabela 1) e avalia a saída da rede neural, escolhendo o neurônio de maior ativação e comparando com a classe correspondente.

A cada acerto do jogador, o agente inteligente melhora seu desempenho na classificação dos objetos, caracterizando um processo de aprendizado. Após um acerto é realizada uma etapa de treino na rede, utilizando os dados da Tabela 1, tal processo é chamado de *epoch* de treino.



Figura 4 – Gráfico de treino da MLP considerando a acurácia da classificação do objeto por *epoch* de treino. Comparando a imitação direta do jogador (aleatório) e pseudo-imitação, treino com as relações objeto-lixeira (*Batch*).



Fonte: Autoria própria.

Na imitação direta o agente aprende somente o que o jogador acertar. Como a classe de objeto aparece de forma aleatória, mesmo o jogador acertando tudo o agente requer uma certa quantidade de iteração (aprendizado) de iterações para convergir em acurácia total, como mostra a linha azul da Figura 4.

Porém, ao considerar todos os dados da Tabela 1 para treino, chamado de *batch* na Figura 4 (curva em laranja), o agente aprende com um número menor de *epoch* quando comparado diretamente com o aleatório. O resultado é um agente inteligente que aprende em um tempo menor de jogo, somente se o jogador acertar a classe de lixeira, aprendendo indiretamente com o jogador.

A Figura 4 mostra uma comparação entre o aprendizado do agente inteligente, por imitação direta (Aleatório) do jogador e por pseudo-imitação (*Batch*).

Por se tratar de eventos aleatórios, tanto na inicialização dos pesos da MLP quanto na escolha do objeto, os dados da Figura 4 mostram uma média de um compilado de 10 rodadas para cada caso, aleatório e *batch*.

CONCLUSÃO

A geração de resíduos pela sociedade é que agride o meio ambiente e pode ser amenizado pela criação do hábito de reciclagem. Este trabalho apresentou o jogo educacional RecycleBot que visa auxiliar no ensino de reciclagem, utilizando um agente inteligente que aprende conforme o desempenho do jogador.

O trabalho explorou a utilização de redes neurais artificiais, utilizada para o aprendizado do agente inteligente. Para isto, surgiram desafios em relação à representação dos objetos e lixeiras, resolvidos com vetores binários, e utilização de aprendizado por imitação do jogador, resolvido com um pseudo aprendizado por imitação, onde o agente treina sua rede neural artificial, com todas as relações objeto-lixeira, a cada acerto do jogador.

Para trabalhos futuros, será realizado testes de *feedback* do jogo proposto, utilizando um publico deficiente intelectual da instituição parceira do projeto de extensão, avaliando o impacto didático do trabalho. Tal teste foi impossibilitado pelo fechamento da instituição parceira na pandemia e pela falta de acesso a computadores pessoais em domicílio, por parte dos alunos deficiente intelectuais.



AGRADECIMENTOS

O presente trabalho foi realizado com o apoio da Universidade Tecnológica Federal do Paraná – UTFPR Campus Ponta Grossa.

REFERÊNCIAS

ALMEIDA, Ellen Maria Pestili de; MONTANHA, Solange Maria; SANTANA, Patrícia Mariana Costa; SOARES, Lanny Cristina Burlandy. Educação ambiental na escola: estudo da relação entre a alimentação e a produção de resíduos. **Revista Brasileira de Educação Ambiental (RevBEA)**, v. 8, n. 2, p. 131–149, 2013.

CF, ODDS. Transforming our world: the 2030 agenda for sustainable development. **United Nations: New York, NY, USA**, 2015.

CHOLLET, Francois. **Deep learning with Python**. [S.l.]: Simon and Schuster, 2017.

CLINE, William R *et al.* **The economics of global warming**. [S.l.]: Institute for International Economics, 1992.

DONATO, Laryssa de Almeida; BARBOSA, Maria de Fátima Nóbrega; BARBOSA, Erivaldo Moreira. Reciclagem: O caminho para o desenvolvimento sustentável. **Polêm! ca**, v. 15, n. 2, p. 023–034, 2015.

DUTRA, Claudia Pereira *et al.* Política nacional de educação especial na perspectiva da educação inclusiva. Brasília, 2007.

FERRER, Geraldo; WHYBARK, D Clay. From garbage to goods: Successful remanufacturing systems and skills. **Business Horizons**, Elsevier Advanced Technology Publications, v. 43, n. 6, p. 55–55, 2000.

GÉRON, Aurélien. **Mãos à Obra: Aprendizado de Máquina com Scikit-Learn & TensorFlow**. [S.l.]: Alta Books, 2019.

GLAT, Rosana; BLANCO, Leila de Macedo Varela. Educação especial no contexto de uma educação inclusiva. **Educação inclusiva: cultura e cotidiano escolar**. Rio de Janeiro, v. 7, p. 15–35, 2007.

GRÜBEL, Joceline Mausolff; BEZ, Marta Rosecler. Jogos educativos. **Renote**, v. 4, n. 2, 2006.

IMPERATIVES, Strategic. Report of the world commission on environment and development: Our common future. **Accessed Feb**, v. 10, p. 1–300, 1987.

LORENA, Ana Carolina; GAMA, João; FACELI, Katti. **Inteligência Artificial: Uma abordagem de aprendizado de máquina**. [S.l.]: Grupo Gen-LTC, 2000.

MANZUR, Ariel; MARQUES, George. **Godot Engine Game Development in 24 Hours, Sams Teach Yourself: The Official Guide to Godot 3.0**. [S.l.]: Sams Publishing, 2018.

MAZZARINO, Jane Márcia; MUNHOZ, Angélica Vier; KEIL, Jaqueline Luciana. Currículo, transversalidade e sentidos em educação ambiental. 2012.



SEI-SICITE 2021

Pesquisa e Extensão para um mundo em transformação

XI Seminário de Extensão e Inovação
XXVI Seminário de Iniciação Científica e Tecnológica
08 a 12 de Novembro - Guarapuava/PR



MORATORI, Patrick Barbosa. Por que utilizar jogos educativos no processo de ensino aprendizagem. **UFRJ. Rio de Janeiro**, p. 04, 2003.

NASROLLAHI, Zahra; HASHEMI, Mohadeseh-sadat; BAMERI, Saeed; TAGHVAEE, Vahid Mohamad. Environmental pollution, economic growth, population, industrialization, and technology in weak and strong sustainability: using stirpat model. **Environment, Development and Sustainability**, Springer, v. 22, n. 2, p. 1105–1122, 2020.

PAL, Sankar K; MITRA, Sushmita. Multilayer perceptron, fuzzy sets, classification. 1992.

ROSENBLATT, Frank. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological review**, American Psychological Association, v. 65, n. 6, p. 386, 1958.

RUDER, Sebastian. An overview of gradient descent optimization algorithms. **arXiv preprint arXiv:1609.04747**, 2016

RUMELHART, David E; HINTON, Geoffrey E; WILLIAMS, Ronald J. **Learning internal representations by error propagation**. [S.l.], 1985.

RUSSELL, Stuart; NORVIG, Peter. Artificial intelligence: a modern approach. 2002.

SIQUEIRA, Mônica Maria; MORAES, Maria Silvia de. Saúde coletiva, resíduos sólidos urbano se os catadores de lixo. **Ciência & Saúde Coletiva**, SciELO Brasil, v. 14, p. 2115–2122, 2009.

SUDJANTO, Agus; HASSOUN, MH. Nonlinear hebbian rule: A statistical interpretation. In: IEEE. Proceedings of 1994 **IEEE International Conference on Neural Networks (ICNN'94)**. [S.l.], 1994. v. 2, p. 1247–1252.

ZHANG, Zhengyou; LYONS, Michael; SCHUSTER, Michael; AKAMATSU, Shigeru. Comparison between geometry-based and gabor-wavelets-based facial expression recognition using multi-layer perceptron. In: IEEE. **Proceedings Third IEEE International Conference on Automatic face and gesture recognition**. [S.l.], 1998. p. 454–459.