

Game de exploração com aprendizado de máquina e engajamento em projetos sociais

Luis Filipe Graef Tinós

UNISAGRADO

Lattes: <http://lattes.cnpq.br/5025258960594228>

Me. Renan Caldeira Menecheli

UNISAGRADO

Lattes: <http://lattes.cnpq.br/1666154141579493>

Dr. Vinicius Santos Andrade

UNISAGRADO

Lattes: <http://lattes.cnpq.br/2353938324822226>

Dr. Patrick Pedreira

UNISAGRADO

Lattes: <http://lattes.cnpq.br/0621550486196515>

Resumo

Os jogos digitais estão em constante ascensão. É inevitável o impacto dessa tecnologia na vida das pessoas. Além de entretenimento, os jogos passaram a desenvolver um papel mais sério dentro da sociedade. Isso permite a relação dos jogos digitais com diversos outros temas, bem como, atividades e projetos sociais que visam beneficiar uma e/ou um grupo de pessoas. O presente trabalho propõe o uso de técnicas e métodos computacionais para a criação de uma prévia de um jogo de exploração, para dispositivos móveis, com reconhecimento de padrões via redes neurais, ficando o progresso no jogo sujeito a apresentação de imagens (via câmera do dispositivo) para ser processada e reconhecida. Além disso, é de interesse do projeto propiciar ferramenta que suporte o estímulo à realização de ações em benefício a instituições/entidades cadastradas em troca de recompensas e do próprio progresso na narrativa do jogo. Para o cumprimento da proposta, foram investigados, por meio de treinamento e validações, modelos de redes neurais convolucionais para a classificação das imagens apresentadas. A relação entre jogador e entidade/instituição foi investigada e implementada para uma futura proposta, essa, capaz de perdurar e ainda se mostrar cativante, no objetivo de atrair o maior número de jogadores possível, ao mesmo tempo em que o projeto vai sendo expandido. A pesquisa mostrou um resultado muito satisfatório, comprovando a possibilidade de uso das redes neurais convolucionais em um jogo mobile, com ótimas métricas e, ainda, de forma otimizada, proporcionando uma experiência gratificante para o usuário.

Palavras-chave: Jogos digitais; Aprendizado de máquina; Gamificação; Visualização computacional.

Introdução

É fato que os jogos digitais desempenham um papel extraordinário em relação a entretenimento, ensino, aprendizado e até mesmo causas sociais, na atualidade. É uma atividade que ganhou destaque ao longo dos anos e se encontra presente nos videogames, computadores e dispositivos móveis.

Também é fato que os *smartphones* e os *tablets* se tornaram aparelhos indispensáveis para muitas pessoas, fazendo parte do cotidiano da sociedade, com cerca de 424 milhões de dispositivos ativos só no Brasil. (FGV, 2020).

Além disso, a Inteligência Artificial também cresceu. E isso é possível de ser observado pelo amplo uso e poder de resolução que as assistentes pessoais dos dispositivos móveis possuem. Tais técnicas também podem ser direcionadas para alavancar o desenvolvimento de soluções gamificadas em prol do lúdico e da responsabilidade social.

Frente ao exposto, o presente projeto tem o intuito de mostrar, a partir de uma prévia (*preview*) de um jogo para dispositivos móveis que utilize o reconhecimento de objetos do mundo real para interação digital no roteiro do game, como a utilização dessas tecnologias são válidas e funcionam mesmo para os dispositivos mais antigos, atrelado ao engajamento social, ambos como recursos que viabilizam o progresso no game.

Jogos digitais

Os jogos eletrônicos, ou jogos digitais, tiveram seu surgimento nos anos 50 e foram criados a partir de estratégias militares em computadores e testes de inteligência artificial (CARVALHO, 2018).

Com o passar dos anos, as tecnologias utilizadas na criação dos games se tornaram cada vez mais avançadas, o que possibilitou a criação de jogos mais desenvolvidos e detalhados. Empresas como Nintendo, Sega, Sony, surgiram no mercado dos consoles (BATISTA *et al.*, 2007) e venderam inúmeras unidades de jogos. O crescimento tecnológico possibilitou, também, a presença dos jogos digitais nos computadores (CARVALHO, 2018).

Levando em consideração o avanço do jogo como atividade, é possível afirmar que os jogos passaram a ser vistos de forma mais profunda. Já não se tem mais a ideia de

um jogo como forma de entretenimento. Mas, também, como forma de aprendizado e sua utilização no ensino (CARVALHO, 2018).

Inteligência artificial

O termo Inteligência Artificial (IA) surge da ideia de o ser humano tornar as máquinas inteligentes. Nessa linha de pesquisa, os computadores adquirem habilidades que simulam a inteligência dos humanos. (NAKABAYASHI, 2009). A inteligência artificial estuda essa emulação comportamental (MCARTHY, 1956 apud NAKABAYASHI, 2009). As habilidades são desenvolvidas a partir de uma inteligência, para as máquinas, criada pelos humanos (NAKABAYASHI, 2009).

A inteligência artificial representa um papel muito importante no cotidiano. Ela está presente em sistemas projetados para a resolução de problemas em relação à economia; com atividades que beneficiam a sociedade como um todo e, também, tem grande participação na pesquisa científica e tecnológica (CERRI, CARVALHO; 2017). Uma ramificação da inteligência artificial é o aprendizado de máquina (*machine learning*), que permite ser conceituado, de forma ampla, como métodos computacionais que usam experiência (tipicamente dados coletados) no intuito de aprimorar performance ou fazer previsões com exatidão (MOHRI, ROSTAMIZADEH, TAWALKAR; 2018).

Isso leva ao desenho de programas capazes de aprender por si sós, utilizando-se um conjunto de dados que representam experiências passadas. Trata-se de uma área de pesquisa multidisciplinar que engloba inteligência artificial, probabilidade e estatística, teoria da complexidade computacional, teoria da informação, filosofia, psicologia, neurobiologia, entre outros. (CERRI; CARVALHO, 2017, p. 298).

Desse modo, é possível relacionar a técnica de aprendizado de máquina com a própria obtenção de conhecimento do ser humano. A técnica ainda é utilizada para reconhecer toda a biologia de uma flor ou planta da mesma espécie, mas de tipos diferentes, por exemplo. O algoritmo vai analisar as características das flores/plantas e, por meio de treinamento, categorizar as flores/plantas diferentes (CERRI, CARVALHO, 2017).


Tom Mitchell (2006) afirma que o *machine learning* tem sucesso em aplicações no mundo real, tais como o reconhecimento de voz, visão computacional, controle robótico etc.

As redes neurais artificiais são outro modo de resolver problemas dentro do campo da inteligência artificial (BARRETO, 2002). Pode-se dizer que as redes neurais têm a capacidade de resolver problemas extremamente complexos através das suas características. Uma característica marcante é seu poder de generalização, ou seja, de imprimir um resultado que não foi previamente apresentado aos circuitos neurais artificiais durante o período de treinamento, mas, que, após reconhecer características similares, produziu a saída adequada (HAYKIN, 2007). Recurso esse fortemente necessário para a proposta desse projeto, no que tange o reconhecimento de objetos comuns e amplamente conhecidos no mundo real.

Especificamente, um problema complexo de interesse é decomposto em um número de tarefas relativamente simples, e atribui-se a redes neurais um subconjunto de tarefas que coincidem com as capacidades inerentes. (HAYKIN, 2007, p. 29).

A Figura 1 apresenta uma exemplificação da representação de uma rede neural Perceptron de múltiplas camadas (MLP).

Figura 1 - Forma de representar uma rede neural artificial




Fonte: PETNews (2011).

Dentre os tipos de algoritmos de *machine learning* e de redes neurais, existem as redes neurais convolucionais (CNN), utilizadas no presente trabalho. Esse algoritmo

realiza a classificação das imagens a partir de convoluções, que resultam em uma matriz de números para que o algoritmo possa identificar o(s) objeto(s) apresentado(s) de forma a correlacioná-los com a classe correta.

A Figura 2 representa a arquitetura de uma rede neural convolucional e suas camadas.

Figura 2 – Exemplo da arquitetura de uma rede neural convoluciona



Fonte: Towards Data Science (2020).

As redes neurais convolucionais – que serão ainda mais exploradas na metodologia do presente trabalho – conseguem receber imagens na camada de entrada e, além de classificar imagens, podem ser usadas para a resolução de diversos outros problemas, como o reconhecimento de áudios e objetos (SILVA, 2018).

Desse modo, a inteligência artificial é fortemente válida para a construção de games e a visão computacional (extração de dados de imagens e impressão de

informações a partir desses dados) pode ser muito bem implementada em celulares, devido à mobilidade e portabilidade dos mesmos.

Dispositivos móveis

É evidente que os dispositivos móveis influenciaram, dinamizaram e continuam alterando a forma em que as pessoas vivem. Em 1947, surgiu um sistema de utilização de telefonia móvel, criado pela empresa americana Bell Company, utilizando o conceito de áreas de cobertura. Porém, esse mesmo sistema foi considerado inviável na época. Somente em 1973 que a tecnologia foi incorporada a um aparelho celular de uso pessoal, pela Motorola (ABREU, 2005).

A tecnologia dos dispositivos móveis evoluiu culminando no que atualmente é conhecido como *smartphones* e *tablets* (HIGUCHI, 2011), com características e funcionalidades múltiplas, complexas e atraentes.

Assim, os celulares e/ou *smartphones* constituem um papel importante na evolução da tecnologia e no comportamento social. É possível chegar em diferentes locais a partir dele (com os softwares de localização e transporte), pedir comida, conversar por mensagens, por chamadas de vídeo, jogar, planejar eventos. Antes, na primeira geração, tínhamos apenas os serviços de voz (MATOS *et al.*, 2019). Hoje, temos uma infinidade de serviços.

Objetivos

O objetivo principal do trabalho é estudar e demonstrar a viabilidade da produção de jogo digital para o engajamento social e a progressão pautada em técnicas de aprendizado de máquina.

Justificativa

A justificativa da realização do presente trabalho está pautada na importância e necessidade de mostrar a viabilidade do uso de tecnologias como as redes neurais convolucionais para a classificação de imagens em um jogo mobile de forma acessível, buscando, sempre, trazer experiências de jogabilidade inovadoras e diversificadas para o usuário. Ainda, a justificativa se pauta na necessidade de analisar como as técnicas e

métodos aplicados podem viabilizar a integração das pessoas aos projetos e ações sociais, apesar de não ser o foco do projeto em questão.

Metodologia

O método utilizado nesta pesquisa foi do tipo análise exploratória, com abordagem quantitativa, quanto à verificação dos resultados referentes à probabilidade de acertos do modelo inteligente, e qualitativa, com testes de protótipo que serão feitos pelo próprio desenvolvedor, para o estudo de engajamento de ação social vinculada com o jogo proposto.

É importante ressaltar que o produto da pesquisa (um *game*) não foi desenvolvido por completo. O trabalho objetiva analisar a viabilidade de construção desse produto com os métodos propostos em consonância com os objetivos anteriormente estabelecidos.

Banco de imagens

Para treinamento do modelo e generalização do reconhecimento de padrões, a formação e obtenção das informações requisitadas pelas técnicas empregadas no projeto foram adquiridas a partir do próprio desenvolvedor do presente projeto.


Ao todo, foram adquiridas mil e dezessete imagens. Desse total, setecentas e setenta e uma imagens foram utilizadas para treinamento e duzentas e quarenta e seis foram para a validação do modelo de rede neural convolucional.

Por ter uma natureza de aprendizado supervisionado, as *features* – imagens inseridas na camada de entrada - são classificadas em classes já esperadas.

O motivo da escolha dos três objetos (caneta, chave e balde) está diretamente relacionado com a narrativa do jogo. No decorrer da história, o jogador precisará de imagens dos respectivos objetos para a progressão.

A Figura 3 mostra exemplos de imagens utilizadas para o treinamento da rede neural convolucional.

Figura 3- Exemplos de imagens de canetas, chaves e baldes que foram utilizadas no treinamento da CNN



Fonte: Autoria própria.

Visão computacional

A proposta do projeto correlaciona um jogo em ambiente digital com sua progressão interrompida à espera de objetos do mundo real. Sendo assim, a câmera do dispositivo móvel será ativada, o objeto requisitado pelo *game* deverá ser apresentado. O software identifica, realiza o processamento da imagem capturada e a classifica.

O pré-processamento das imagens dos *datasets* de treino e validação foi feito a partir da biblioteca Keras pela facilidade e possibilidade de implementação dentro do algoritmo de criação e treinamento do modelo de *machine learning*.

Durante o pré-processamento, foi feito um *rescaling* (reescalonamento) das imagens para 160x160 pixels. Essa padronização é importante para que as imagens que entram na rede tenham um peso menor e se padronizem em um único tamanho, facilitando o treinamento. Além disso, foi feita a normalização de valores para os pixels da imagem, que estavam em escala RGB de três canais. Toda imagem que entra na rede é pré-processada dessa forma. Assim, a classificação de novas *features* se mantém padronizada e eficiente, visto que esse procedimento de pré-processamento reduz o tamanho da imagem e agiliza o processo de classificação.

Após o pré-processamento, as camadas convolucionais extraem as características – ou atributos – das imagens para que, posteriormente, sejam realizados o processamento e a classificação das mesmas (OLIVEIRA *et al.*, 2019).

Para a etapa de inteligência artificial no uso de aprendizado de máquina para reconhecimento de padrões, foi estudado e implementado o modelo de rede neural convolucional para classificação multiclasse com algoritmo de *backpropagation*, aliado a técnicas como *transfer learning*, *data augmentation* e *early stopping*. O modelo é responsável por classificar as imagens em três classes diferentes (caneta, chave ou balde) utilizando *dense layers* com função de ativação *softmax*, retornando a probabilidade de cada classe para a determinada imagem e realizando o treinamento em vinte e cinco épocas. O intuito foi a busca de simplicidade, agilidade e eficiência na obtenção de resultados. Quanto mais rápido for a classificação, melhor, ainda mais para dispositivos móveis. Por isso, optou-se por realizá-la em uma aplicação externa (API).

A construção do algoritmo de redes neurais foi feita a partir do *Google Collab*, utilizando o *Python* como linguagem de programação.

Por fim, assim que obtidas as taxas de generalização consideradas satisfatórias, o modelo foi salvo e implementado à uma API para a comunicação com a aplicação principal.

Resultados

Os resultados foram satisfatórios e condizentes com a proposta da pesquisa. Durante a criação do jogo, foi constatado que a Unity é uma *engine* eficiente para a construção de um jogo mobile e que permite a comunicação com APIs externas, considerada excelente e essencial para trabalhar com a integração do algoritmo de redes neurais à aplicação.

Além disso, em relação à parte gráfica, a utilização de gráficos com dimensões base de 32x32 pixels auxiliou no desempenho da aplicação, levando em consideração que alguns aparelhos são mais antigos e que essas imagens, por serem pequenas, têm um peso menor. Outros recursos que auxiliaram na otimização foram os *tilemaps*. Os *tilemaps* reproduzem a imagem de referência e têm muito mais desempenho em relação à construção de mapas e cenários apenas com *sprites*, o que reduz drasticamente a quantidade de *game objects* em cena.

A Tabela 1 apresenta informações a respeito da diferença de desempenho entre uma cena da Unity com o uso de vários *sprites* e *tilemaps*.

Tabela 1 - Diferença de desempenho entre *sprites* e *tilemaps*

UNITY SCENE USING SPRITES	UNITY SCENE USING TILEMAPS
370,000 lines in the Scene file	30,000 lines in the Scene file
10 MB Scene size	831 KB Scene size
1930 batches	157 batches
244 ms per frame	13 ms per frame
RAM usage: 1.1 GB	RAM usage: 21 MB

Fonte: Unity, 2022.

Foi analisado, também, que um algoritmo de redes neurais convolucionais é uma excelente opção para trabalhar imagens, já que o Tensorflow, por exemplo, aceita imagens na camada de entrada. A utilização do Tensorflow, também, auxiliou muito no processo de treinamento e validação, já que ele proporciona várias bibliotecas e funcionalidades que facilitam o desenvolvimento da rede e o treinamento dos modelos.

Como citado na metodologia do presente trabalho, foram aplicados métodos como *transfer learning*, *data augmentation* na rede neural. Essas técnicas foram implementadas para evitar problemas como o *overfitting* e, além disso, deixar a rede mais robusta e preparada para as entradas.


O *overfitting* ocorre quando o modelo não consegue generalizar com eficácia os dados observados e os nunca vistos (YING, 2019).

Devido à existência do *overfitting* o modelo funciona perfeitamente no conjunto de treinamento, enquanto se ajusta mal no conjunto de teste. Isso se deve ao fato de que o modelo superajustado tem dificuldade em lidar com partes das informações no conjunto de teste, o que pode ser diferente do conjunto de treinamento (YING, 2019, p. 2, tradução nossa).

Foram analisadas métricas importantes e significativas para avaliar o desempenho do modelo de redes neurais convolucionais e, as mesmas, apresentaram resultados excelentes considerando o tamanho dos *datasets*.

A Figura 4 mostra que acurácia da rede foi excepcional, bem como a perda.

Figura 4- Métricas de perda e acurácia para análise de desempenho



Fonte: Autoria própria.

Como demonstrado nos gráficos acima, o modelo aprendeu muito bem e teve sua perda reduzida em um número pequeno de épocas (eixo horizontal). Ao fim do treinamento e validação, o modelo atingiu uma acurácia de 98% e perda de menos de 0.1%.

Considerações finais

Foi concluído que é possível desenvolver o trabalho apresentado neste projeto de pesquisa de uma forma otimizada para inúmeros dispositivos a partir de bibliotecas *open source* e outros recursos para a criação do modelo de redes neurais convolucionais. Todo o processo de criação foi muito positivo e não houve tarefas – previstas antes do início do desenvolvimento do *preview* – que não puderam ser cumpridas.

Para implementações futuras, vale ressaltar algumas observações para melhorias e/ou novas *features*.

O aumento no número e variedade de imagens dos *datasets* resulta em um modelo de rede neural convolucional que consegue generalizar ainda mais as *features* que entram na rede, o que, possivelmente, proporcionaria uma precisão acima dos 98%.

Além disso, sugere-se o contato com instituições/entidades beneficentes para a aplicação da proposta de engajamento social, além da elaboração de formulários avaliativos para analisar a receptividade dessa proposta pelos usuários

Referências

ABREU, Leonardo Marques de. **Usabilidade de Telefones Celulares com base em Critérios Ergonômicos**. 2005. Disponível em: <https://www.maxwell.vrac.puc-rio.br/6705/6705_1.PDF>

BARRETO, Jorge M.. **Introdução às Redes Neurais Artificiais**. 2002. Disponível em: <http://www.inf.ufsc.br/~j.barreto/tutoriais/Survey.pdf>

BATISTA, Thiago José de Souza et al. **Um estudo sobre a história dos jogos eletrônicos**. 2007. Disponível em: <http://re.granbery.edu.br/artigos/MjQ4.pdf>

BRASIL TEM 424 MILHÕES DE DISPOSITIVOS DIGITAIS EM USO REVELA A 31ª PESQUISA ANUAL DO FGV, FGV, 2020. Disponível em: <https://portal.fgv.br/noticias/brasil-tem-424-milhoes-dispositivos-digitais-uso-revela-31a-pesquisa-anual-fgv>. Acessado em 19 mar. 2021

CARVALHO, Gabriel Rios De. **A importância dos jogos digitais na educação**. 2018. Disponível em: https://app.uff.br/riuff/bitstream/1/8945/1/TCC_GABRIEL_RIOS_DE_CARVALHO%20%281%29.pdf

CERRI, Ricardo; CARVALHO, André Carlos Ponce de Leon Ferreira de. **Aprendizado de máquina: breve introdução e aplicações**. 2017. Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/184785/1/Aprendizado-de-maquina-breve-introducao.pdf>

HAYKIN, Simon. **Redes Neurais: Princípios e práticas**. 2007. Disponível em: <https://books.google.com.br/books?hl=pt-BR&lr=&id=bhMwDwAAQBAJ&oi=fnd&pg=PP1&dq=redes+neurais+&ots=08rrIHL SFp&sig=epo03Ilu1dATD3ajDEQWgqR90cc#v=onepage&q=redes%20neurais&f=false>

HIGUCHI, Adriane Aparecida da Silva. **Tecnologias móveis na educação**. 2011. Disponível em: <http://tede.mackenzie.br/jspui/bitstream/tede/1818/1/Adriane%20da%20Silva%20Higuchi.pdf>

MATOS, Leni *et al.* **Evolução da tecnologia de telefonia móvel e estudo e caracterização de um sistema móvel 5G de quinta geração.** 2019. Disponível em: <<https://webcache.googleusercontent.com/search?q=cache:jX7la50xFPsJ:https://periodicos.uff.br/engevista/article/view/27028/16398+&cd=3&hl=pt-BR&ct=clnk&gl=br>>

MITCHELL, Tom M. **The Discipline of Machine Learning.** 2006. Disponível em: <http://ra.adm.cs.cmu.edu/anon/usr0/ftp/anon/ml/CMU-ML-06-108.pdf>

MOHRI, Mehryar; ROSTAMIZADEH, Afshin; TALWALKAR, Ameet. **Foundations of machine learning.** 2. ed. MIT press, 2018.

NAKABAYASHI, Luciana Akemi. **A contribuição da Inteligência Artificial (IA) na Filosofia da Mente.** 2009. Disponível em: <https://tede2.pucsp.br/bitstream/handle/18236/1/Luciana%20Akemi%20Nakabayashi.pdf>

OLIVEIRA, Bruno Alberto Soares *et al.* **Sistema para Classificação de Grãos de Café: Uma Comparação entre Redes Neurais Convolucionais e Processamento Digital de Imagens com MLP.** 2019. Disponível em: < <https://proceedings.science/sbai-2019/papers/sistema-para-classificacao-de-graos-de-cafe--uma-comparacao-entre-redes-neurais-convolucionais-e-processamento-digital-d> >. Acesso em 13 ago. 2022.

SILVA, Rodrigo Emerson Valentim da. **Um estudo comparativo entre redes neurais convolucionais para a classificação de imagens.** 2018. Disponível em: < https://repositorio.ufc.br/bitstream/riufc/39475/1/2018_tcc_revsilva.pdf >. Acessado em 13 ago. 2022.

YING, Xue. **An Overview of Overfitting and its Solutions.** 2019. Disponível em: < <https://iopscience.iop.org/article/10.1088/1742-6596/1168/2/022022/pdf> >. Acesso em: 13 ago. 2022.