

TRANSFER LEARNING APLICADO À COMPUTAÇÃO INSPIRADA NA BIOLOGIA

Universidade Presbiteriana Mackenzie

Coordenadoria de Fomento à Pesquisa - Pró-reitoria de Pesquisa e Pós-Graduação

Pedro Henrique Rodrigues Corrêa (IC)¹

Apoio: PIBIC Mackpesquisa

Eurico Luiz Prospero Ruivo (Orientador)²

Faculdade de Computação e Informática (FCI)¹

Faculdade de Computação e Informática – Universidade Presbiteriana Mackenzie²

RESUMO

Este artigo investiga a aplicação de transferência de aprendizado em sistemas imunológicos artificiais, com foco na adaptação do algoritmo aiNet para tarefas de classificação de sentimentos. O estudo considera dois subdomínios pertencentes ao mesmo domínio geral de reviews: o conjunto IMDB Reviews, relacionado a avaliações de filmes, e o conjunto Amazon Reviews, relacionado a avaliações de produtos. A metodologia proposta explora duas estratégias complementares. Na primeira, populações de anticorpos treinadas no domínio-fonte são utilizadas diretamente para inferência no domínio-alvo, permitindo observar o grau de generalização do conhecimento previamente adquirido. Na segunda, essas populações pré-treinadas são empregadas como ponto de partida para um processo de ajuste fino no novo conjunto de dados, sendo comparadas com populações inicializadas aleatoriamente. A representação vetorial dos textos foi realizada com Word2Vec, possibilitando a transformação semântica das reviews em vetores adequados ao processamento pela aiNet. Os resultados indicam que o conhecimento transferido preserva utilidade mesmo diante de mudanças de contexto, além de acelerar o processo de treinamento quando empregado como inicialização para o domínio-alvo. Observou-se, ainda, ganho de precisão e convergência mais rápida no cenário com população pré-treinada, em comparação com a inicialização aleatória. Conclui-se que a transferência de aprendizado apresenta potencial relevante para ampliar a eficiência de sistemas imunológicos artificiais em problemas de classificação textual e adaptação entre subdomínios.

Palavras-chave: sistemas imunológicos artificiais. transferência de aprendizado. análise de sentimentos.

ABSTRACT

This article investigates the application of transfer learning in artificial immune systems, focusing on the adaptation of the aiNet algorithm to sentiment classification tasks. The study considers two subdomains belonging to the same general review domain: the IMDB Reviews dataset, related to movie evaluations, and the Amazon Reviews dataset, related to product evaluations. The proposed methodology explores two complementary strategies. In the first, antibody populations trained in the source domain are directly used for inference in the target domain, allowing the observation of how well previously acquired knowledge generalizes. In the second, these pre-trained populations are employed as the starting point for a fine-tuning process in the new dataset and are compared with randomly initialized populations. Text representation was performed with Word2Vec, enabling the semantic transformation of reviews into vectors suitable for processing by aiNet. The results indicate that transferred knowledge remains useful even when the context changes and also accelerates training when used as initialization for the target domain. Higher accuracy and faster convergence were observed in the pre-trained population setting when compared with random initialization. The study concludes that transfer learning has relevant potential to increase the efficiency of artificial immune systems in textual classification problems and in adaptation across related subdomains.

Keywords: artificial immune systems. transfer learning. sentiment analysis.

1. INTRODUÇÃO

A computação inspirada na natureza utiliza fenômenos e processos naturais para o desenvolvimento de algoritmos que solucionam desafios em variadas áreas do conhecimento (ROZENBERG; BÄCK; KOK, 2012; CASTRO, 2007; DARWISH, 2018). Principalmente, essas inspirações emergem de insetos, da teoria neo-darwiniana da evolução, sistemas imunológicos e redes neurais. Apesar da crescente atenção a esses paradigmas, há uma escassez de trabalhos focados na aplicação de sistemas imunológicos artificiais para problemas de classificação, principalmente com ênfase na técnica de *transfer learning* (TORREY; SHAVLIK, 2010; PAN; YANG, 2010).

Este estudo fará uso do conceito de sistemas imunológicos artificiais, especialmente no algoritmo aiNet adaptado para classificação (CASTRO; TIMMIS, 2002; MIKHERSKII; MIKHERSKII, 2021). A implementação do aiNet utilizada (CORRÊA, 2023) enfatiza o treinamento de diferentes populações de anticorpos, especificamente treinadas para se especializar em determinados conjuntos de dados.

O objetivo primordial é explorar o potencial do uso da técnica de transferência de aprendizado (*transfer learning*) (PAN; YANG, 2010) entre subdomínios distintos, utilizando o conhecimento adquirido de um subdomínio para melhorar a performance inicial em outro que esteja contido no mesmo domínio, em contraste com uma inicialização aleatória. Os resultados deste projeto servirão como base para investigações futuras, ampliando a aplicação de técnicas inspiradas na natureza e explorando novos paradigmas de modelagem e classificação.

Os objetivos específicos são:

1. Estudar os conceitos e metodologias associados ao *transfer learning*;
2. Atualizar os estudos sobre sistemas imunológicos artificiais, com ênfase no algoritmo aiNet;
3. Identificar o tipo de *transfer learning* a ser usado em conjunto com a aiNet (indutivo ou transdutivo);
4. Definir a forma de transferir conhecimento para o algoritmo aiNet;
5. Formalizar uma metodologia de *transfer learning* para o aiNet, denominada Tr-aiNet.

2. REFERENCIAL TEÓRICO


Este trabalho se concentra em dois assuntos centrais que serão abordados de maneira breve: a aplicação da técnica de Transferência de Aprendizado (*transfer learning*); e Sistemas Imunológicos Artificiais.

A técnica de Transferência de Aprendizado (*transfer learning*) (WEISS; KHOSHGOFTAR; WANG, 2016; ZHUANG et al., 2020) vem se tornando cada vez mais relevante. Isso pode ser justificado dada a crescente demanda por dados de treinamento para alimentar os

mais diversos tipos de modelos de aprendizagem de máquina, assim como a demanda computacional.

De forma geral, os métodos de aprendizado de máquina utilizam dados de treinamento e teste que possuem o mesmo espaço de características (*feature space*) e a mesma distribuição, de forma que os modelos sejam gerados com dados pertencentes ao mesmo domínio (TAN; STEINBACH; KUMAR, 2005; CASTRO; FERRARI, 2016; WITTEN et al., 2016; HAN; PEI; KAMBER, 2011). Porém, há casos em que esses tipos de dados não estão disponíveis ou são difíceis de serem obtidos, requerendo o desenvolvimento de métodos de aprendizagem capazes de aproveitar o conhecimento de um domínio em outro, conforme ilustrado na Figura 1.

Figura 1: Ilustração do processo de transferência de aprendizado no contexto da aiNet.



Fonte: Elaboração própria, com base em (YANG; MEI, 2021)

Transfer learning pode ser contextualizado considerando um domínio $D = \{\chi, P(X)\}$, onde χ representa o espaço de características e $P(X)$ a distribuição de probabilidade. Em uma tarefa de classificação de textos, por exemplo, χ engloba todos os vetores de termos e X é uma amostra desses termos. Dada a tarefa $T = \{\gamma, f(\cdot)\}$, γ é o espaço de rótulos e $f(\cdot)$ é a função que pretendemos aprender a partir dos dados. Se temos um domínio fonte DS e um domínio alvo DT , transfer learning busca melhorar a aprendizagem em DT com o conhecimento adquirido em DS , especialmente quando $DS \neq DT$ ou as tarefas associadas a eles diferem.

Após a publicação do artigo de revisão de (PAN; YANG, 2010), a pesquisa e a literatura sobre transfer learning vêm se ampliando cada vez mais. Outros trabalhos recentes de revisão sobre o tema (LU et al., 2015; WEISS; KHOSHGOFTAAR; WANG, 2016; ZHUANG et al., 2020) baseiam-se principalmente na discrepância entre os domínios. Os modelos de transfer learning podem ser divididos em homogêneos, cujos domínios pertencem ao mesmo espaço de características, ou heterogêneos, cujos domínios possuem diferentes espaços de características (WEISS; KHOSHGOFTAAR; WANG, 2016). Outras formas de categorizar as metodologias de transfer learning baseiam-se no paradigma de aprendizagem (transdutiva, indutiva e não supervisionada), ou nas instâncias, características, parâmetros e relacionamentos (ZHUANG et al., 2020).

Abordemos os Sistemas Imunológicos Artificiais por meio da implementação do Algoritmo de Redes Imunológicas Artificiais (aiNet) adaptado para problemas de classificação, partindo do paradigma da Computação Natural, campo de estudo que abrange a intersecção da computação e da natureza (CASTRO, 2006; CASTRO, 2007; ROZENBERG; BÄCK; KOK, 2012). A Computação Natural tem se destacado no desenvolvimento de algoritmos de otimização e análise de dados (YANG, 2020; NANDA; PANDA, 2014).

Os Sistemas Imunológicos Artificiais (SIA), como a aiNet, compõem uma das principais subáreas da Computação Natural (CASTRO, 2006; ABDEL-BASSET; ABDEL-FATAH; SANGAIAH, 2018; BANSAL; SINGH; PAL, 2019; KAR, 2016; KENNEDY; EBERHART; SHI, 2001; PARPINELLI; LOPES, 2011). O algoritmo aiNet, inspirado na interação entre anticorpos e antígenos no sistema imunológico humano, permite o reconhecimento de padrões de patógenos ou antígenos através de anticorpos interconectados com pesos variáveis (CASTRO; ZUBEN, 2001).

A aiNet se destaca por sua robustez diante de dados incompletos ou *outliers* (GUO et al., 2021), sua habilidade de generalização (ZHANG et al., 2017), a preservação da diversidade da população (BROWNLEE; WOODWARD, 2005), e sua capacidade de aprender e memorizar padrões (DASGUPTA; YU; NINO, 2003). Assim, este projeto visa complementar as qualidades da aiNet com a aplicação da técnica de transferência de aprendizado.

2.1 Algoritmo aiNet

O algoritmo aiNet implementado (CORRÊA, 2023) foi baseado no pseudocódigo que pode ser encontrado na literatura (FRANÇA et al., 2010), conforme demonstrado no Algoritmo 1.

2.1.1 Medida de Distância

Neste estudo foi adotada a distância euclidiana, uma das medidas de distância mais comuns, como a medida de distância no algoritmo aiNet. A distância euclidiana entre dois indivíduos x e y no espaço n -dimensional é definida como:

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$$

Onde x_i e y_i são, respectivamente, a i -ésima característica (ou *feature*) de x e y (BISHOP, 2006; HAN; PEI; KAMBER, 2005).

2.1.2 Normalização

Neste estudo foi adotado o método de normalização Min-Max. Este método redimensiona todos os valores para uma escala de 0 a 1. Faz isso subtraindo o valor mínimo e dividindo pelo intervalo dos valores (máximo - mínimo). Este procedimento é ilustrado pela seguinte fórmula:

Algoritmo 1 aiNet

Requer: N (tamanho inicial da população)
Requer: n (número de clones)
Requer: m (porcentagem de células para memória)
Requer: σ_1 (limiar de supressão anticorpo-anticorpo)
Requer: σ_2 (limiar de supressão anticorpo-antígeno)
Requer: d (porcentagem de células aleatórias introduzidas à população)
Requer: i (número de iterações)

- 1: **para** cada $iter = 1$ **até** i **faça**
- 2: **para** cada antígeno **faça**
- 3: Determinar afinidade com as células da rede
- 4: Selecionar n células de maior afinidade
- 5: Gerar clones das células selecionadas (quantidade proporcional à afinidade)
- 6: Aplicar hiper-mutação aos clones
- 7: Avaliar afinidade dos clones com o antígeno
- 8: Manter $m\%$ dos clones de maior afinidade
- 9: Eliminar clones com afinidade abaixo de σ_2 , exceto um
- 10: Suprimir clones com alta afinidade mútua acima de σ_1
- 11: Inserir clones remanescentes na população
- 12: **fim para**
- 13: **para** cada anticorpo na população **faça**
- 14: Suprimir anticorpos com alta similaridade acima de σ_1
- 15: **fim para**
- 16: Introduzir $d\%$ de novas células aleatórias na população
- 17: **fim para**

Fonte: Elaboração própria

$$x_{\text{norm}} = \frac{x - x_{\min}}{x_{\max} - x_{\min}}$$

Onde x é o valor original, $x_{\min}$ é o valor mínimo da característica e $x_{\max}$ é o valor máximo da característica. A normalização Min-Max é uma escolha comum para a normalização de dados porque é simples, eficaz e tem o benefício adicional de manter exatamente os mesmos valores para todos os dados que já estão entre 0 e 1 (VRIES; CHAWLA, 2001; DUDA; HART; STORK, 2012).

3. METODOLOGIA

3.1 Base de Dados

Os *datasets* escolhidos para a realização dos estudos paramétricos foram IMDB Reviews (MAAS et al., 2011) e Amazon Reviews (HE; MCAULEY, 2016). Ambos são datasets textuais binários que classificam o sentimento presente nas análises como positivo ou negativo. As reviews do IMDB são voltadas para filmes, enquanto as da Amazon focam em produtos.

3.2 Transfer Learning

3.2.1 Domínios

Dentro da análise de sentimento em reviews, podemos identificar uma estrutura hierárquica que relaciona domínios e subdomínios. O domínio geral é o de reviews, que tem como objetivo principal identificar o sentimento (positivo ou negativo) expresso pelo autor da análise. No caso dos datasets utilizados, temos dois subdomínios distintos: filmes (IMDB Reviews) e produtos (Amazon Reviews).

Apesar de ambos os subdomínios pertencerem ao domínio maior de análise de sentimento em reviews, cada um tem suas particularidades e nuances. Por exemplo, a linguagem e os critérios usados para avaliar um filme podem ser diferentes daqueles usados para avaliar um produto. No entanto, o fato de ambos os subdomínios compartilharem o mesmo domínio de análise de sentimento faz com que haja uma sobreposição considerável em termos de características e padrões.

3.2.2 Abordagem Indutiva

O transfer learning realizado neste experimento é de natureza indutiva. No aprendizado de transferência indutivo, o objetivo é transferir o conhecimento de um domínio-fonte para um domínio-alvo, mantendo a mesma tarefa de aprendizado. Neste caso, tanto o IMDB Reviews quanto o Amazon Reviews têm a mesma tarefa: classificar o sentimento das análises como positivo ou negativo. No entanto, o domínio em que essas análises são feitas é diferente: filmes para IMDB e produtos para Amazon, conforme um fluxo genérico demonstrado na Figura 2.


Em contraste, o aprendizado de transferência transdutivo se refere à transferência de conhecimento entre tarefas diferentes sob o mesmo domínio. O foco principal está em usar informações do domínio-alvo para melhorar a performance em uma tarefa no domínio-fonte, conforme previsto de forma genérica pela Figura 3.

No contexto deste experimento, o modelo foi primeiro treinado no dataset IMDB Reviews e depois aplicado ao Amazon Reviews, tentando aplicar o conhecimento adquirido em um subdomínio a um novo subdomínio, mantendo a mesma tarefa de classificação de sentimento. Isso é indicativo de um cenário de aprendizado de transferência indutivo, em que o domínio muda, mas a tarefa permanece constante.

3.2.3 Relevância

É nesse contexto que o transfer learning se mostra relevante (PAN; YANG, 2010). O aprendizado de transferência permite aproveitar o conhecimento adquirido em um subdomínio e aplicá-lo a outro, mesmo que haja diferenças entre eles. Essa abordagem pode ser especialmente útil para acelerar o processo de treinamento e melhorar a performance em casos nos quais os dados de um subdomínio específico podem ser escassos ou insuficientes, conforme a Figura 4, para treinar um modelo robusto por conta própria.

Figura 2: Fluxo genérico de uma análise de sentimentos.




Fonte: Elaboração própria

No experimento realizado, a abordagem de aprendizado de transferência foi implementada em duas etapas. Na primeira, populações foram treinadas no dataset IMDB Reviews, com um número específico de dimensões determinado pelo Word2Vec. Após o treinamento bem-sucedido no IMDB Reviews, essas populações foram diretamente utilizadas para classificar os antígenos presentes no Amazon Reviews. O objetivo era avaliar a capacidade dessas populações pré-treinadas de generalizar e se adaptar a um novo subdomínio sem qualquer treinamento adicional.

Na segunda etapa, essas populações treinadas no IMDB Reviews também foram utilizadas como ponto de partida para o treinamento adicional no dataset Amazon Reviews. Esse método foi contrastado com uma abordagem alternativa, em que uma população inicializada de forma completamente aleatória foi treinada no Amazon Reviews. A ideia foi comparar o desempenho e a eficiência de uma população pré-treinada versus uma população iniciada aleatoriamente. Esperava-se que a população pré-treinada, graças ao conhecimento adquirido no subdomínio de filmes, alcançasse uma performance superior ou ao menos comparável, mas com uma convergência mais rápida, quando exposta ao subdomínio de produtos. Essa experimentação ajuda a elucidar a eficácia real do transfer learning no contexto de análise de sentimento entre diferentes subdomínios.

Figura 3: Aprendizagem indutiva e transdutiva.




Fonte: Elaboração própria, com base em (HE; YU, 2010)

3.3 Word2Vec

O modelo Word2Vec (MIKOLOV et al., 2013a; MIKOLOV et al., 2013b) tornou-se um dos pilares fundamentais na representação de palavras e documentos no espaço vetorial, oferecendo uma maneira compacta e expressiva de capturar a semântica das palavras com base no contexto em que aparecem. Ao transformar palavras em vetores, o Word2Vec consegue abstrair e representar relações semânticas entre elas, conforme ilustrado na Figura 5, permitindo que palavras semanticamente semelhantes tenham representações vetoriais próximas no espaço. Ao lidar com a análise de sentimentos em datasets textuais, como o IMDB Reviews e o Amazon Reviews, utilizar o Word2Vec é crucial para converter dados brutos em um formato adequado, no qual a aiNet possa operar eficientemente.

Na prática, quando se considera a representação vetorial de sentimentos positivos e negativos, a disposição desses vetores no espaço oferece insights claros sobre a natureza e a qualidade do modelo. Sentimentos positivos e negativos tendem a ser agrupados em clusters distintos no espaço vetorial. Isso se deve ao fato de que palavras e frases que carregam sentimentos positivos compartilham um contexto semântico semelhante, e o mesmo acontece com sentimentos negativos. Por exemplo, palavras como incrível, fantástico e maravilhoso provavelmente se agruparão mais próximas umas das outras do que de palavras como terrível ou horrível. Essa distinção oferece uma vantagem significativa quando se aplica um modelo

Figura 4: Ganho de dados para treinamento no contexto da aiNet.



Fonte: Elaboração

própria, com base em (BAHETI, 2021)

como a aiNet, que opera no espaço vetorial, identificando e classificando padrões com base na proximidade e distância vetorial.


Podemos utilizar como exemplo a representação vetorial de palavras dentro do contexto de um domínio, conforme demonstrado na Figura 6.

A etapa de pré-processamento dos dados é fundamental (BIRD; KLEIN; LOPER, 2009) para garantir que a representação vetorial capture a essência semântica dos dados com a máxima eficácia. A tokenização, por exemplo, divide o texto em unidades menores, permitindo que o modelo lide com palavras ou frases individualmente. A remoção de palavras irrelevantes, como conectivos muito frequentes, ajuda a reduzir o ruído nos dados, focando apenas nas palavras que carregam significado semântico significativo. Além disso, converter todo o texto para minúsculas garante uniformidade, evitando que a mesma palavra seja representada de maneira diferente devido a variações de caixa. Esse cuidado no pré-processamento permite que o Word2Vec concentre-se no que é realmente essencial: capturar a semântica subjacente do texto e representá-la de forma eficiente no espaço vetorial.

4. RESULTADOS E DISCUSSÃO

Este estudo explora os benefícios do aprendizado transferido em duas frentes: primeiro, usando uma população treinada em um subdomínio para realizar inferências em outro, avaliando sua precisão; e, segundo, iniciando o treinamento de uma nova população a partir de uma previamente treinada em outro subdomínio, comparando sua evolução a cada iteração.

Figura 5: Exemplificação de relações semânticas no Word2Vec.



Fonte:

Elaboração própria, com base em (SWATIMEENA, 2020)

4.1 Comparação de Inferência

A Tabela 1 demonstra o desempenho das populações de anticorpos nas revisões do IMDB, enquanto a Tabela 2 demonstra o desempenho nas revisões da Amazon.

Adotando o método 10-fold cross-validation, abordagem na qual o conjunto de dados é dividido em 10 partes, obtivemos:


Tabela 1: Relatório de classificação – IMDB Reviews.

Métrica	Classe 0	Classe 1	Média/Total
Precisão	0,82	0,79	0,80
Recall	0,79	0,82	0,80
F1-score	0,80	0,80	0,80
Suporte	2500	2500	5000

Fonte: Elaboração própria

Os resultados apontam para uma redução na precisão quando a população treinada no subdomínio IMDB é aplicada diretamente ao subdomínio Amazon. Apesar da queda, o desempenho se mantém relativamente alto, indicando que o conhecimento adquirido no treinamento do IMDB possui relevância e aplicabilidade mesmo em um subdomínio diferente, reforçando o potencial do aprendizado transferido.

Figura 6: Distribuição de palavras em um espaço vetorial representando a relação semântica.



Fonte: Elaboração própria, com base em (LIU et al., 2021)

4.2 Treinamento com Transferência de Aprendizado

Para investigar o impacto da inicialização no treinamento, foram testados dois cenários diferentes: no primeiro, uma população foi inicializada aleatoriamente e treinada no subdomínio Amazon Reviews; no segundo, a população foi inicializada a partir da já treinada no dataset IMDB Reviews e submetida a um treinamento de *fine-tuning*.

O desempenho de ambas as abordagens foi avaliado a cada 5 iterações, conforme demonstrado na Tabela 3:

Ao observar os resultados da Figura 7, fica claro o benefício da inicialização por *fine-tuning*. Enquanto a população com inicialização aleatória levou entre 40 e 50 iterações para alcançar a precisão que a população inicializada pelo *fine-tuning* obteve logo no início, esta última demonstrou uma curva de aprendizado mais eficiente ao longo das iterações. Além disso, a população submetida ao *fine-tuning* conseguiu superar em precisão a inicialização aleatória ao final das iterações, reforçando a eficácia e o potencial da técnica de transferência de aprendizado.

Tabela 2: Relatório de classificação – Amazon Reviews.

Métrica	Classe 0	Classe 1	Média/Total
Precisão	0,71	0,68	0,69
Recall	0,68	0,71	0,69
F1-score	0,69	0,69	0,69
Suporte	2500	2500	5000

Fonte: Elaboração própria

Tabela 3: Comparação de precisão entre abordagens ao longo das iterações.

Iteração	Precisão	
	Inicialização Aleatória	População Pré-Treinada
5	0,38	0,68
10	0,47	0,71
15	0,43	0,74
20	0,44	0,77
25	0,52	0,79
30	0,57	0,81
35	0,62	0,80
40	0,66	0,83
45	0,65	0,82
50	0,68	0,84
55	0,71	0,81
60	0,74	0,83
65	0,77	0,82
70	0,79	0,84
75	0,81	0,85
80	0,80	0,83
85	0,83	0,86
90	0,82	0,85
95	0,84	0,87
100	0,81	0,86

Fonte: Elaboração própria


5. CONSIDERAÇÕES FINAIS

O emergente campo da transferência de aprendizado, especialmente na análise de sentimento, mostrou resultados promissores neste estudo. Embora a análise de sentimento seja uma área estabelecida, a incorporação de aprendizado transferido em sistemas imunológicos artificiais para diferentes subdomínios é um avanço pouco explorado.

Este estudo revelou ganhos notáveis ao utilizar transferência de aprendizado. Usando conhecimento prévio de um subdomínio, observamos treinamentos mais rápidos e melhorias na precisão. Notavelmente, a inicialização por fine-tuning reduziu consideravelmente as iterações necessárias, superando frequentemente a inicialização aleatória.

Contudo, a literatura atual tem poucos estudos que se debrucem sobre esse tema. Essa lacuna evidencia tanto o caráter inovador da abordagem quanto a urgência de mais pesquisas na área. A transferência de aprendizado não só tem potencial para otimizar treinamentos e suprir deficiência de dados de treino em determinados subdomínios, mas também para ampliar nossa compreensão sobre sistemas imunológicos artificiais, ressaltando seus benefícios no

Figura 7: População aleatória e população pré-treinada.



Fonte: Elaboração própria

contexto de aprendizado por conta de sua natureza robusta, podendo contribuir para processos que contem com bases de dados repletas de outliers e ruído.

Além das vantagens já destacadas, a utilidade da transferência de aprendizado em sistemas imunológicos artificiais aponta para um potencial de utilidade na criação de bases de dados sintéticos. Essa abordagem pode ser fundamental para algoritmos generativos. A capacidade de transferir informações aprendidas de um domínio para outro pode proporcionar a esses algoritmos uma rica e extensa base de dados em temas pouco explorados, melhorando sua eficiência e capacidade de gerar conteúdo relevante. Isso pode resultar em sistemas mais robustos e adaptáveis, capazes de produzir soluções mais versáteis em diversos campos de aplicação.

O código para este projeto pode ser encontrado online no repositório GitHub do autor: <<https://github.com/pedrordrighs/Tr-aiNet>>.

AGRADECIMENTOS

Gostaria de expressar minha profunda gratidão ao Instituto Presbiteriano Mackenzie pelo generoso apoio por meio da bolsa de estudos MackPesquisa.

Essa bolsa foi fundamental para a realização deste trabalho e contribuiu significativamente para o avanço da pesquisa apresentada neste artigo.

REFERÊNCIAS

ABDEL-BASSET, M.; ABDEL-FATAH, L.; SANGAIAH, A. K. *Metaheuristic Algorithms: A Comprehensive Review*. [S.l.]: Academic Press, 2018.

- BAHETI, P. *A Newbie-Friendly Guide to Transfer Learning*. Medium, 2021. Acessado em: 12 de março de 2026. Disponível em: <<https://www.v7labs.com/blog/transfer-learning-guide>>.
- BANSAL, J. C.; SINGH, P. K.; PAL, N. R. *Evolutionary and Swarm Intelligence Algorithms*. [S.l.]: Springer, 2019.
- BIRD, S.; KLEIN, E.; LOPER, E. *Natural Language Processing with Python: Analyzing Text with the Natural Language Toolkit*. [S.l.]: O'Reilly Media, Inc, 2009.
- BISHOP, C. M. *Pattern Recognition and Machine Learning*. New York, NY: Springer, 2006.
- BROWNLEE, J.; WOODWARD, C. Tuning of clonal selection algorithm parameters using taguchi methods. In: *Congress on Evolutionary Computation*. [S.l.: s.n.], 2005. v. 1, p. 102–109.
- CASTRO, L. de; FERRARI, D. *Introdução à Mineração de Dados: Conceitos Básicos, Algoritmos e Aplicações*. [S.l.]: Saraiva, 2016.
- CASTRO, L. N. de. *Fundamentals of Natural Computing: Basic Concepts, Algorithms, and Applications*. [S.l.]: Chapman Hall/CRC, 2006.
- CASTRO, L. N. de. Fundamentals of natural computing: an overview. *Physics of Life Reviews*, v. 4, n. 1, p. 1–36, 2007.
- CASTRO, L. N. de; TIMMIS, J. I. *Artificial Immune Systems: A New Computational Intelligence Approach*. [S.l.]: Springer, 2002.
- CASTRO, L. N. de; ZUBEN, F. J. V. ainet: An artificial immune network for data analysis. Idea Group Publishing, 2001.
- CORRÊA, P. H. R. *Tr-aiNET*. GitHub, 2023. Acessado: 16/06/2023. Disponível em: <<https://github.com/pedrordrigs/Tr-aiNET>>.
- DARWISH, A. Bio-inspired computing: Algorithms review, deep analysis, and the scope of applications. *Future Computing and Informatics Journal*, v. 3, n. 2, p. 231–246, 2018.
- DASGUPTA, D.; YU, S.; NINO, F. Recent advances in artificial immune systems: Models and applications. *Applied Soft Computing*, v. 3, n. 2, p. 113–132, 2003.
- DUDA, R. O.; HART, P. E.; STORK, D. G. Pattern classification. *John Wiley & Sons*, 2012.
- FRANÇA, F. O. d. et al. Conceptual and practical aspects of the ainet family of algorithms. *International Journal of Natural Computing Research*, v. 1, n. 1, p. 6, January-March 2010.
- GUO, P. et al. Immunological intelligent systems: Based on the immune system. *IEEE Transactions on Cybernetics*, v. 51, n. 5, p. 2486–2501, 2021.
- HAN, J.; PEI, J.; KAMBER, M. Data mining: concepts and techniques. *Elsevier*, 2005.
- HAN, J.; PEI, J.; KAMBER, M. *Data mining: concepts and techniques*. [S.l.]: Elsevier, 2011.
- HE, R.; MCAULEY, J. Ups and downs: Modeling the visual evolution of fashion trends with one-class collaborative filtering. *Proceedings of the 25th international conference on world*

wide web, p. 507–517, 2016.

HE, Z.; YU, W. Stable feature selection for biomarker discovery. *Computational Biology and Chemistry*, v. 34, n. 4, p. 215–225, 2010. ISSN 1476-9271. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1476927110000502>>.

KAR, A. K. Bio inspired computing – a review of algorithms and scope of applications. *Expert Systems with Applications*, v. 59, p. 20–32, 2016.

KENNEDY, J.; EBERHART, R. C.; SHI, Y. *Swarm Intelligence*. [S.l.]: Morgan Kauffman Publishers, 2001.

LIU, J. et al. Cross-domain sentiment aware word embeddings for review sentiment analysis. *International Journal of Machine Learning and Cybernetics*, v. 12, 02 2021.

LU, J. et al. Transfer learning using computational intelligence: A survey. *Knowledge-Based Systems*, v. 80, p. 14–23, 2015.

MAAS, A. L. et al. Learning word vectors for sentiment analysis. In: *Proceedings of the 49th Annual Meeting of the Association for Computational Linguistics: Human Language Technologies*. [S.l.: s.n.], 2011.

MIKHERSKII, R. M.; MIKHERSKII, M. R. Analysis of the use of artificial immune systems. In: *IOP Conference Series: Materials Science and Engineering*. [S.l.: s.n.], 2021. v. 1069, p. 012025.

MIKOLOV, T. et al. Efficient estimation of word representations in vector space. *arXiv preprint arXiv:1301.3781*, 2013.

MIKOLOV, T. et al. Distributed representations of words and phrases and their compositionality. In: *Advances in Neural Information Processing Systems*. [S.l.: s.n.], 2013.

NANDA, S. J.; PANDA, G. A survey on nature inspired metaheuristic algorithms for partitional clustering. *Swarm and Evolutionary Computation*, v. 16, p. 1–18, 2014.

PAN, S. J.; YANG, Q. A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering*, v. 22, n. 10, p. 1345–1359, 2010.

PARPINELLI, R. S.; LOPES, H. S. New inspirations in swarm intelligence: a survey. *International Journal of Bio-Inspired Computation*, v. 3, n. 1, p. 1–16, 2011.

ROZENBERG, G.; BÄCK, T.; KOK, J. N. *Handbook of Natural Computing*. [S.l.]: Springer, 2012.

SWATIMEENA. *Training Word2Vec using Gensim*. Medium, 2020. Acessado em: 12 de março de 2026. Disponível em: <<https://swatimeena989.medium.com/training-word2vec-using-gensim-14433890e8e4>>.

TAN, P.; STEINBACH, M.; KUMAR, V. *Introduction to Data Mining*. 1. ed. Boston: Addison-Wesley Longman Publishing Co., Inc., 2005.

TORREY, L.; SHAVLIK, J. Transfer learning. In: *Handbook of research on machine learning applications and trends: algorithms, methods, and techniques*. [S.l.]: IGI global, 2010. p.

242–264.

VRIES, T. de; CHAWLA, S. Normalization methods for distance-based outlier detection. In: SPRINGER. *European Conference on Principles of Data Mining and Knowledge Discovery*. [S.l.], 2001. p. 357–368.

WEISS, K.; KHOSHGOFTAAR, T. M.; WANG, D. A survey of transfer learning. *Journal of Big data*, SpringerOpen, v. 3, n. 1, p. 1–40, 2016.

WITTEN, I. et al. *Data Mining - Practical Machine Learning Tools and Techniques*. [S.l.]: Morgan Kaufmann Publishers, 2016.

YANG, X.-S. Nature-inspired optimization algorithms: Challenges and open problems. *Journal of Computational Science*, v. 46, p. 101104, 2020.

YANG, Y.; MEI, G. Deep transfer learning for identifications of slope surface cracks. 08 2021.

ZHANG, Y. et al. Artificial immune network-based multi-objective optimization algorithm. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, v. 47, n. 7, p. 1292–1305, 2017.

ZHUANG, F. et al. A comprehensive survey on transfer learning. *Proceedings of the IEEE*, IEEE, v. 109, n. 1, p. 43–76, 2020.

Contatos: pedrowente@gmail.com e eurico.ruivo@mackenzie.br