

## **Tipos de Modelagem Computacional para Treinamento de IA/ML: Classificatória e Generativa**

### **Autor(es)**

Antonio Carlos De Oliveira Cruz Júnior

Carlos André Pimentel Quintas

Daniel Dos Santos Alves

### **Categoria do Trabalho**

Trabalho Acadêmico

### **Instituição**

FACULDADE ANHANGUERA DE JACAREÍ

### **Introdução**

A Inteligência Artificial (IA) e o Aprendizado de Máquina (ML) vêm se consolidando como pilares da inovação tecnológica nas últimas décadas. Para viabilizar tais avanços, a modelagem computacional desempenha papel essencial, fornecendo as bases matemáticas e estatísticas necessárias para a construção de sistemas inteligentes. Entre as principais abordagens, destacam-se os modelos classificatórios, voltados à categorização de dados com base em padrões aprendidos, e os modelos gerativos, que possibilitam a criação de novas amostras com características realistas. Conforme apresentado por Bishop (2006), Murphy (2012) e Goodfellow et al. (2016), a escolha entre essas estratégias depende diretamente dos objetivos do projeto e da natureza dos dados disponíveis. A compreensão aprofundada dessas técnicas é fundamental para o desenvolvimento de soluções eficazes e inovadoras nos mais diversos setores.

### **Objetivo**

Apresentar as principais abordagens de modelagem computacional aplicadas ao treinamento de sistemas de IA e ML, com ênfase nos modelos classificatórios e gerativos, destacando suas aplicações, fundamentos teóricos e contribuições tecnológicas (BISHOP, 2006; MURPHY, 2012; GOODFELLOW et al., 2016).

### **Material e Métodos**

A construção deste estudo baseou-se em revisão teórica e bibliográfica de obras fundamentais da área de aprendizado de máquina e inteligência artificial. Foram analisadas metodologias descritas em fontes reconhecidas, como Bishop (2006), Murphy (2012), Goodfellow et al. (2016), entre outros. As abordagens classificatórias examinadas incluem Regressão Logística, Árvores de Decisão, Redes Neurais, Máquinas de Vetores de Suporte e algoritmos baseados em instâncias. Para modelagem gerativa, foram explorados os Autoencoders Variacionais, Redes Adversariais Gerativas, Modelos Baseados em Difusão e Modelos de Transformadores. A análise considerou aspectos técnicos, aplicações e limitações de cada técnica.

### **Resultados e Discussão**



A análise evidenciou diferenças marcantes quanto à finalidade e ao funcionamento dos modelos. Os classificatórios demonstraram eficácia em tarefas como reconhecimento de padrões, diagnóstico e sistemas de recomendação, destacando-se pela capacidade de organizar dados em categorias com alta acurácia. Técnicas como SVMs e Redes Neurais mostraram-se especialmente eficientes em cenários complexos.

Já os modelos generativos revelaram grande potencial na criação de dados sintéticos, utilizados em simulações, aumento de bases de dados e aplicações criativas, como geração de imagens e textos. As GANs e os modelos baseados em difusão, por exemplo, têm se destacado pela qualidade e realismo das amostras geradas, impulsionando inovações em áreas como design, arte digital e entretenimento. Já os modelos de transformadores como GPT e BERT têm revolucionado o processamento de linguagem natural, com impactos significativos em tradutores automáticos, assistentes virtuais e ferramentas de escrita.

### **Conclusão**

A modelagem computacional aplicada à IA e ao ML constitui um campo em constante evolução, com aplicações que abrangem desde classificações simples até a geração de conteúdos altamente sofisticados. Já os modelos classificatórios são essenciais para decisões automatizadas, os modelos generativos representam um passo além, permitindo a simulação e criação de novas realidades digitais. A correta aplicação dessas técnicas são fundamentais para o desenvolvimento de soluções inovadoras

### **Referências**

- BISHOP, C. M. *Pattern Recognition and Machine Learning*. New York: Springer, 2006.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. Cambridge: MIT Press, 2016.
- MURPHY, K. P. *Machine Learning: A Probabilistic Perspective*. Cambridge: MIT Press, 2012.