



ANÁLISE DE EFICIÊNCIA DO SVM QUÂNTICO

Eduardo PIOLI DO AMARAL¹; Diego SAQUI²

RESUMO

O estudo busca analisar o algoritmo *Support Vector Machine* comparando sua acurácia, *F1-Score*, *Recall* e Curva ROC, com a de sua versão alternativa que utiliza um *kernel* quântico, com o propósito de verificar se o algoritmo quântico possui vantagem sobre o clássico na tarefa de classificação binária de classes. A verificação utiliza datasets gerados sinteticamente para testar os limites de ambos os algoritmos, e posteriormente é testado o algoritmo quântico com hiperparâmetros modificados com o intuito de pontuar possíveis fatores de influência para serem futuramente explorados. É de grande interesse a análise de algoritmos quânticos tendo em vista a recência do aspecto experimental da computação quântica e a potencial vantagem que ela oferece em tarefas de alta complexidade e custo computacional.

Palavras-chave:

Support Vector Machine; Computação Quântica; Classificação; Análise.

1. INTRODUÇÃO

A mecânica quântica rege o mundo microscópico, e é através dela que surgem efeitos e propriedades contra-intuitivas apresentadas por partículas e outras estruturas em nanoescala. A natureza destes objetos é fundamentalmente probabilística e, portanto, dotada de incerteza (BORN, 1926; SCHRÖDINGER, 1926), algo que contribui para o surgimento de efeitos que contrariam o comum do mundo macroscópico.

O comportamento das informações quânticas é uma recente área de estudo que busca utilizar destes efeitos únicos para aplicação em tecnologias de informação como comunicação e computação. E há muito foi especulado que a superposição, o emaranhamento quântico, o comportamento ondulatório concomitante das partículas, entre outras propriedades (DEUTSCH, 1985, p. 109-112), se aliadas a computação, proporcionariam uma vantagem acima dos computadores clássicos, formando o conceito da supremacia dos computadores quânticos.

Permanecendo majoritariamente teórica, a computação quântica já era parcialmente realizada por meio de cálculos e, seus algoritmos desenvolvidos ou cogitados no papel, já no século 20. Um destes algoritmos quânticos, de Shor, fora provado ser capaz de quebrar uma criptografia RSA em tempo poli-logarítmico $O(\log n)$ (SHOR, 1994, p. 130-131). E desde então o interesse pela área aumentou, e com o advento das tecnologias de computação, os primeiros computadores quânticos foram surgindo, possibilitando o desenvolvimento experimental deste campo de estudo.

O *Support Vector Machine* (SVM), um algoritmo supervisionado de aprendizado de

¹Orientando Eduardo Pioli do Amaral, IFSULDEMINAS – Campus Muzambinho. E-mail: eduardo.pioliam@gmail.com.

²Orientador Diego Saqui, IFSULDEMINAS – Campus Muzambinho. E-mail: diego.saqui@muz.ifsuldeminas.edu.br.

máquina, é um notável método de classificação e regressão por sua robustez e eficiência (CORTES, 1995, p. 273-276). Sua forma mais avançada e comum conta com um *kernel*, responsável pela realização de cálculos multidimensionais, o que possibilita a ampliação do escopo do SVM em termos de dimensões dos dados a serem analisados.

Com o crescimento da computação quântica, cientistas começaram a testar versões quânticas de algoritmos já existentes na clássica. Com isso foi proposto um *kernel* quântico capaz de realizar os mesmos tipos de cálculos para o SVM, porém se utilizando dos circuitos quânticos disponíveis, formando o QSVM (HAVLICEK, 2018, p. 2-19).

A fim de testar uma possível vantagem do QSVM acima do SVM, conjuntos de dados sintéticos e de padrões e estruturas variadas foram gerados para servirem de base para execução de ambos, e com os resultados utilizados para medir métricas de acurácia (*F1-Score*, *Recall* e Curva ROC) com o intuito de avaliar ambos os algoritmos. Por fim, o trabalho também propõe buscar, através de modificações e testes, por hiperparâmetros que representam maior impacto no funcionamento do QSVM, para elucidar possíveis regiões a serem exploradas futuramente na busca por uma melhoria do algoritmo.

3. MATERIAL E MÉTODOS

Através da biblioteca *sklearn*, foram gerados os datasets sintéticos: 20 dimensões + 1 de classe e 30 elementos; 7 dimensões + 1 de classe e 500 elementos; 5 dimensões + 1 de classe e 100 elementos (sendo 80% de apenas uma classe); e 5 dimensões + 1 de classe e 100 elementos (ruído em termos de classificação, ou seja, troca aleatória de classes).

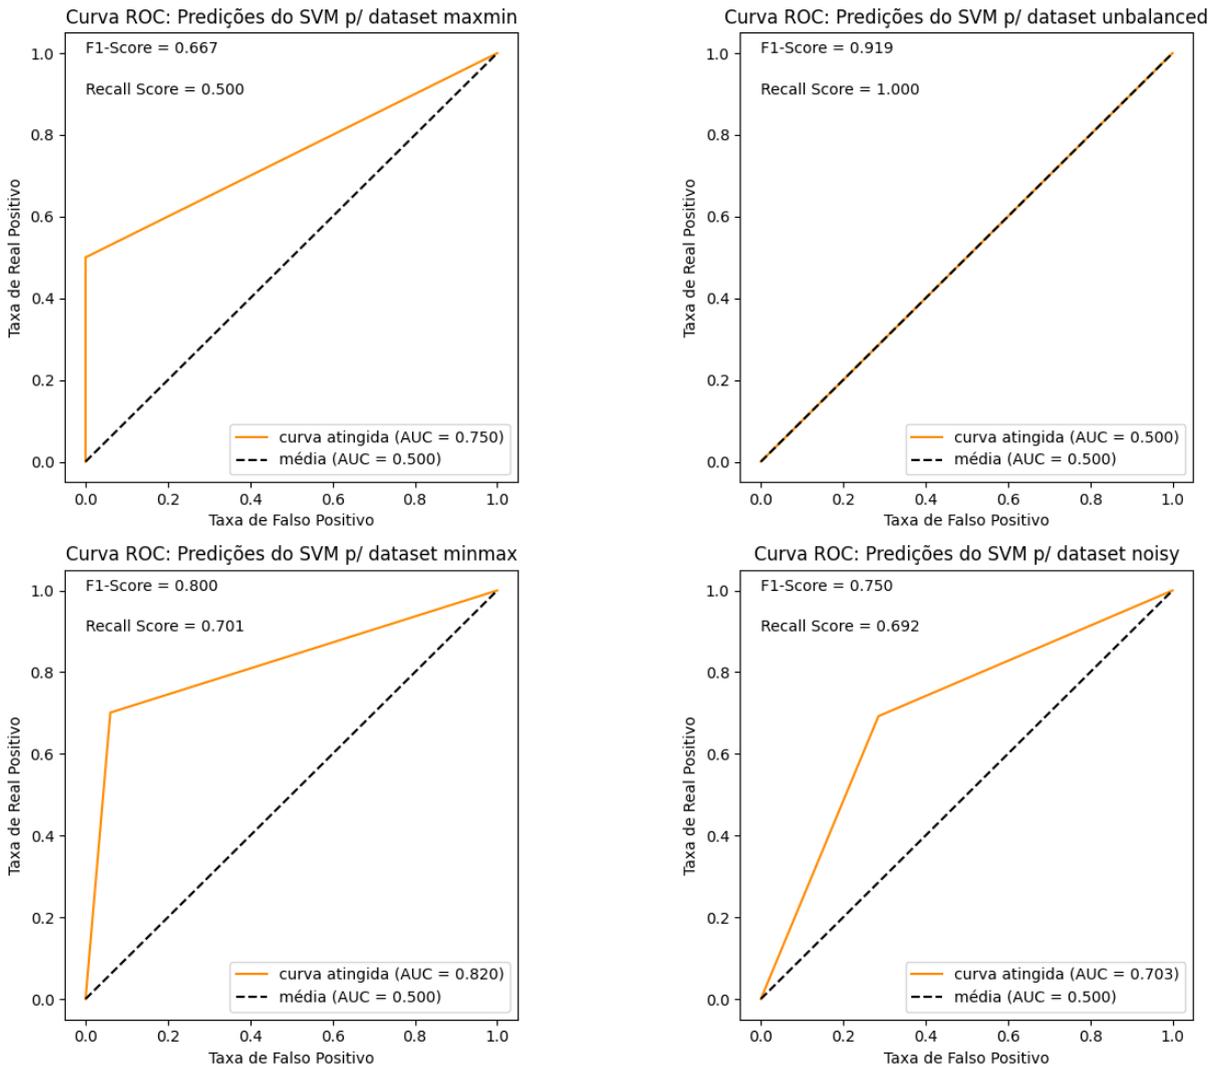
Para cada *dataset*, os dados foram separados entre X e Y, sendo ambos divididos entre treino e teste cada. E cada conjunto de treino X e Y foi passado por uma *pipeline* construída em conformidade com os procedimentos padrões da análise de dados e modelagem de *machine learning*. A *pipeline* normaliza os dados e centraliza suas médias (*Standard Scaler*), aplica a redução de dimensionalidade (PCA) configurada em 5 dimensões e, por fim, aplica-os a um modelo padrão do SVM presente também no *sklearn*.

Com cada modelo formado pelo SVM com cada *dataset*, foram utilizados os dados de predição para extração dos resultados, e com eles calculou-se as métricas de acurácia previamente mencionadas. Com isso foi possível traçar os resultados de forma a simplificar a comparação entre os modelos e verificar como o SVM se comporta com cada tipo de *dataset*.

4. RESULTADOS E DISCUSSÃO

Os resultados obtidos através da *pipeline* do SVM podem ser vistos na Figura 1, abaixo.

Fig. 1: Resultados SVM



Fonte: Autoria própria (2023).

Através dos dados obtidos pode-se notar que o modelo ‘maxmin’ (poucas observações e muitas dimensões) apresentou uma capacidade mediana de realizar a distinção das classes. Por outro lado, o modelo ‘minmax’ (muitas observações e poucas dimensões) teve o melhor desempenho entre todos.

O modelo ‘unbalanced’ (80% de uma só classe) indicariam um ótimo desempenho através do *F1-Score* e *Recall*, porém a curva ROC demonstra o viés do modelo, portanto não foi um bom modelo. Por fim, o modelo ‘noisy’ (ruído nos dados) apresentou boa confiabilidade e pode ser considerado o segundo melhor modelo gerado.

5. CONCLUSÃO

Através dos resultados parciais encontrados pode-se inferir que há uma boa probabilidade do QSVM seguir as mesmas tendências do SVM. Espera-se também que o QSVM possua, de modo

geral, um melhor desempenho do que sua contraparte clássica. Com as diferentes configurações dos hiperparâmetros do *kernel* quântico também é esperado pelo menos um melhor entendimento do funcionamento do algoritmo e dos seus aspectos mais impactantes.

REFERÊNCIAS

BORN, Max. Zur Quantenmechanik der Stoßvorgänge. *Zeitschrift für Physik A Hadrons and Nuclei*, Berlin, v. 37, n. 12, p. 863-867, Dec. 1926. Disponível em:

<https://link.springer.com/article/10.1007/BF01397477>. Acesso em: 16 Jan. 2023.

CORTES, Corinna; VAPNIK, Vladimir. Support-Vector Networks. *Machine Learning*, [s.l.], v. 20, n. 3, p. 273-297, Set. 1995. Disponível em: <https://link.springer.com/article/10.1007/BF00994018>. Acesso em: 15 Jan. 2023.

DEUTSCH, David. Quantum theory, the Church-Turing principle and the universal quantum computer. *Proceedings of the Royal Society of London. A. Mathematical and Physical Sciences*, London, v. 400, n. 1818, p. 97-117, Jul. 1985. Disponível em:

<https://royalsocietypublishing.org/doi/10.1098/rspa.1985.0070>. Acesso em: 20 Jan. 2023.

HAVLICEK, Vojtech. et al. **Supervised learning with quantum enhanced feature spaces**. ArXiv: quant-ph, 1804.11326, Jun. 2018. Disponível em: <https://arxiv.org/abs/1804.11326>. Acesso em: 2 Jan. 2023.

SCHRÖDINGER, Erwin. An Undulatory Theory of the Mechanics of Atoms and Molecules. *The Physical Review*, College Park, v. 28, n. 6, p. 1049-1070, Dez. 1926. Disponível em:

<https://journals.aps.org/pr/abstract/10.1103/PhysRev.28.1049>. Acesso em: 16 Jan. 2023.

SHOR, Peter W. Algorithms for quantum computation: discrete logarithms and factoring.

Proceedings 35th Annual Symposium on Foundations of Computer Science, Santa Fe, v. 35, p. 124-134, Nov. 1994. Disponível em: <https://ieeexplore.ieee.org/document/365700>. Acesso em: 20 Jan. 2023.