

Introdução

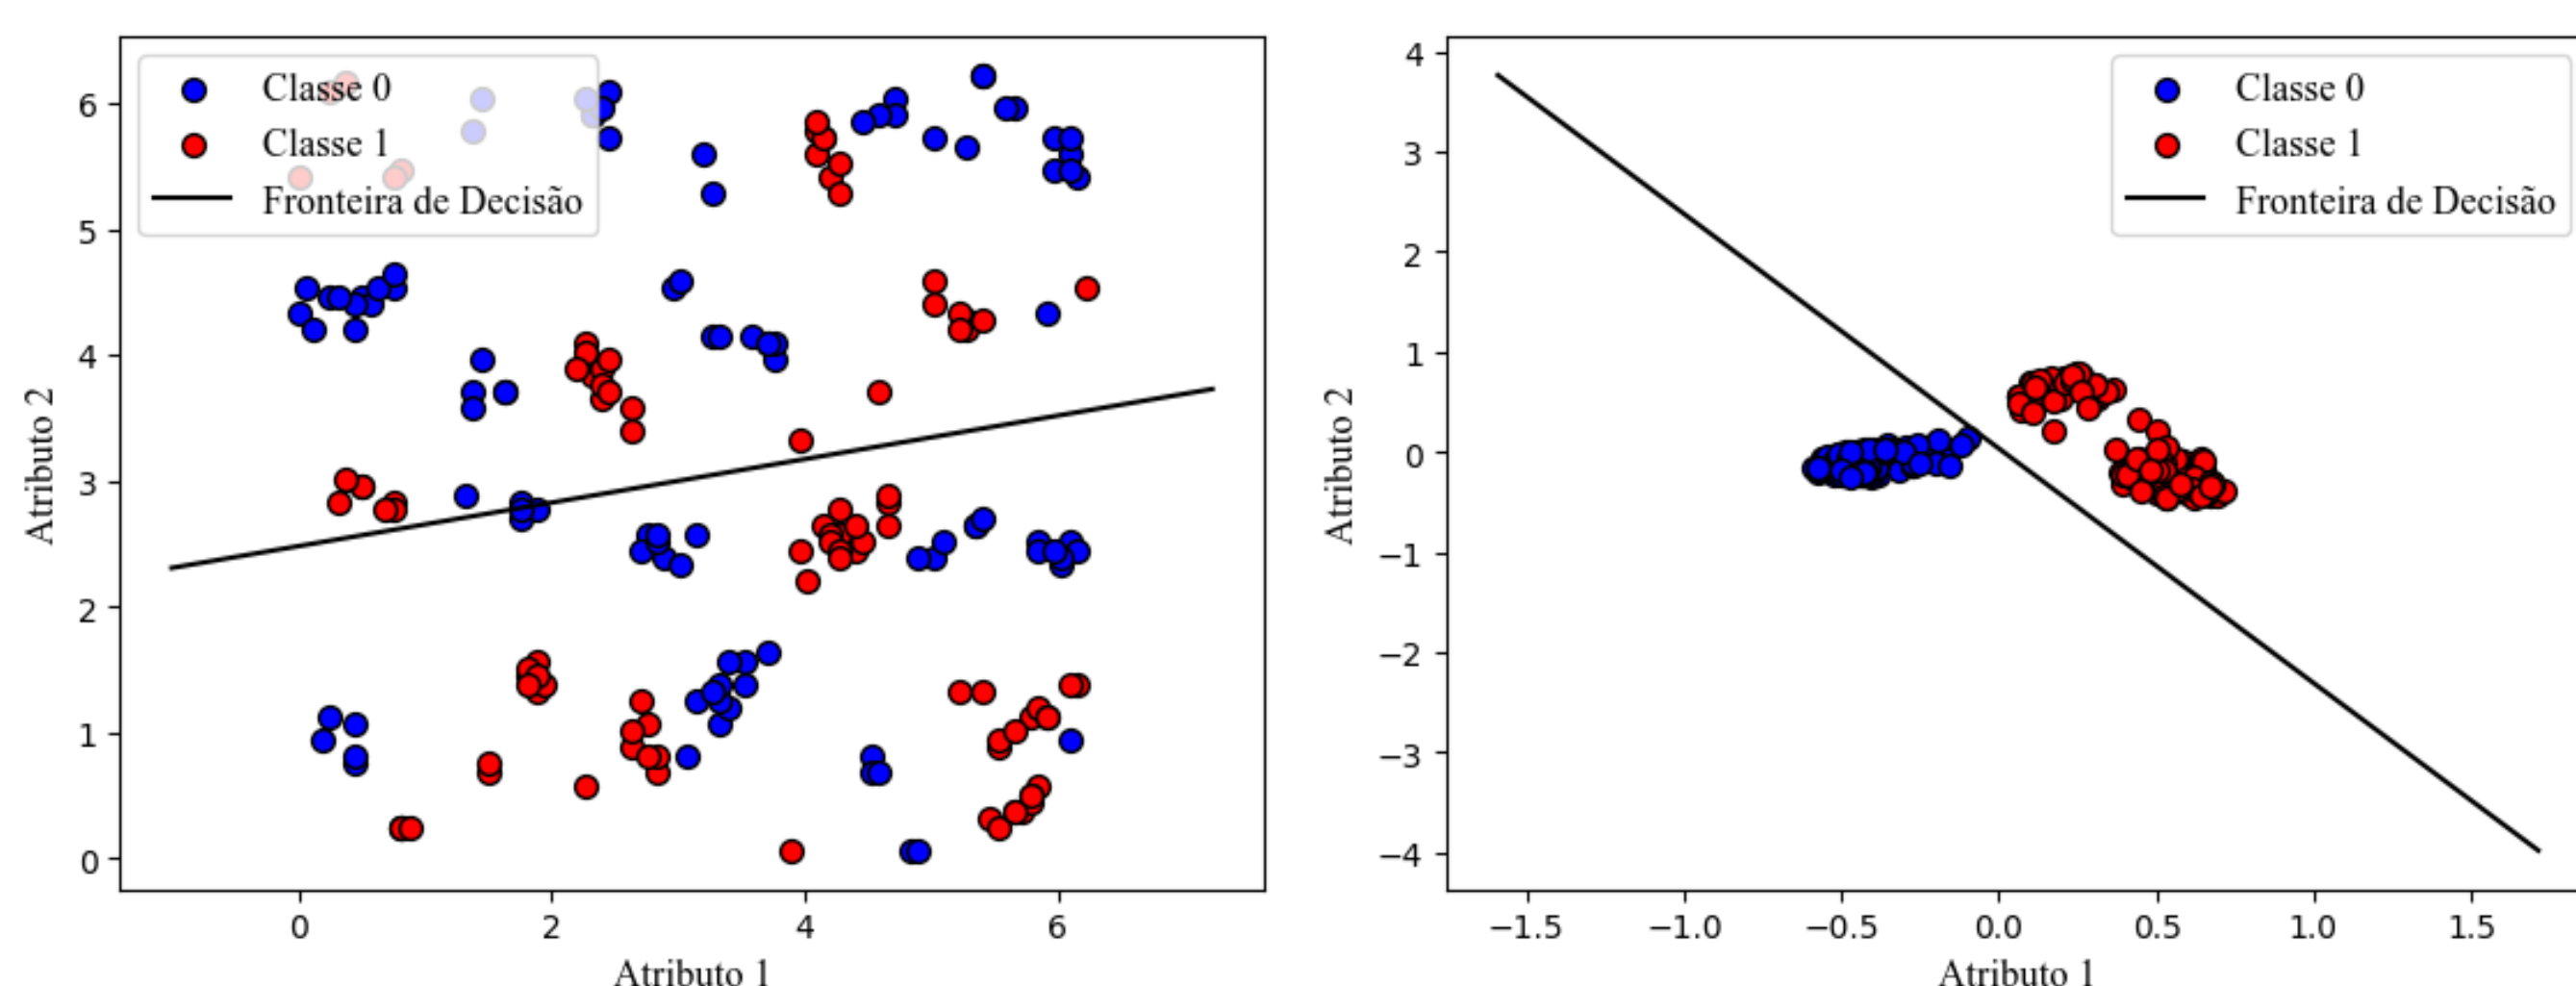
- A esquizofrenia afeta, aproximadamente, 1% da população mundial e é dita como o mais grave entre os transtornos psiquiátricos;
- A esquizofrenia apresenta consequências devastadoras tanto econômicas quanto sociais e, especialmente, para os familiares do paciente (MARDER;CANNON, 2019);
- Um artigo publicado em 2007 aponta que o diagnóstico precoce da esquizofrenia acompanhado de tratamento melhora seu prognóstico, ademais, o tratamento pode ser ministrado antes da ocorrência de uma crise (LOUZÃ, 2007).

Machine Learning

- Machine Learning é uma subárea de Inteligência Artificial definida pelo aprendizado inerente aos algoritmos;
- No aprendizado supervisionado, o modelo observa os pares entrada e saída de um determinado fenômeno e precisa aproximar a função que liga o domínio de entrada com o contradomínio da saída.

Computação Quântica

- Por meio da superposição coerente de estados quânticos e emaranhamento, em tese, é possível obter um melhor desempenho em computadores quânticos para determinados problemas;
- Outra característica relevante na utilização de algoritmos de Quantum Machine Learning é a codificação de atributos.
- Em geral, computadores quânticos possuem operações não lineares internas à sua estrutura matemática. Logo, utiliza-se algoritmos que sejam capazes de resolver o problema proposto como por exemplo a técnica Quantum Support Vector Machine (QSVM) a qual utiliza *kernels* quânticos.



Figuras 1 e 2 – Dados artificiais projetados por *principal component analysis* (PCA) com *kernel* quântico. Adaptado de (HAVLICEK et al., 2019).

Motivação

Um diagnóstico realizado por meio de algoritmos de classificação aplicados a dados coletados por meio de ressonância magnética mostra-se como um candidato para uma técnica de diagnóstico não invasivo (AKSOY et al., 2024).

Esse diagnóstico é capaz de auxiliar na atenuação dos sintomas e prevenção de crises em seus pacientes, melhorando a sua condição e qualidade de vida a longo prazo. Por outro lado, essas soluções demandam grande poder computacional ou necessitam de diferentes abordagens para obter melhores métricas de desempenho. Sendo assim, avalia-se a aplicação de computação quântica nesse cenário.

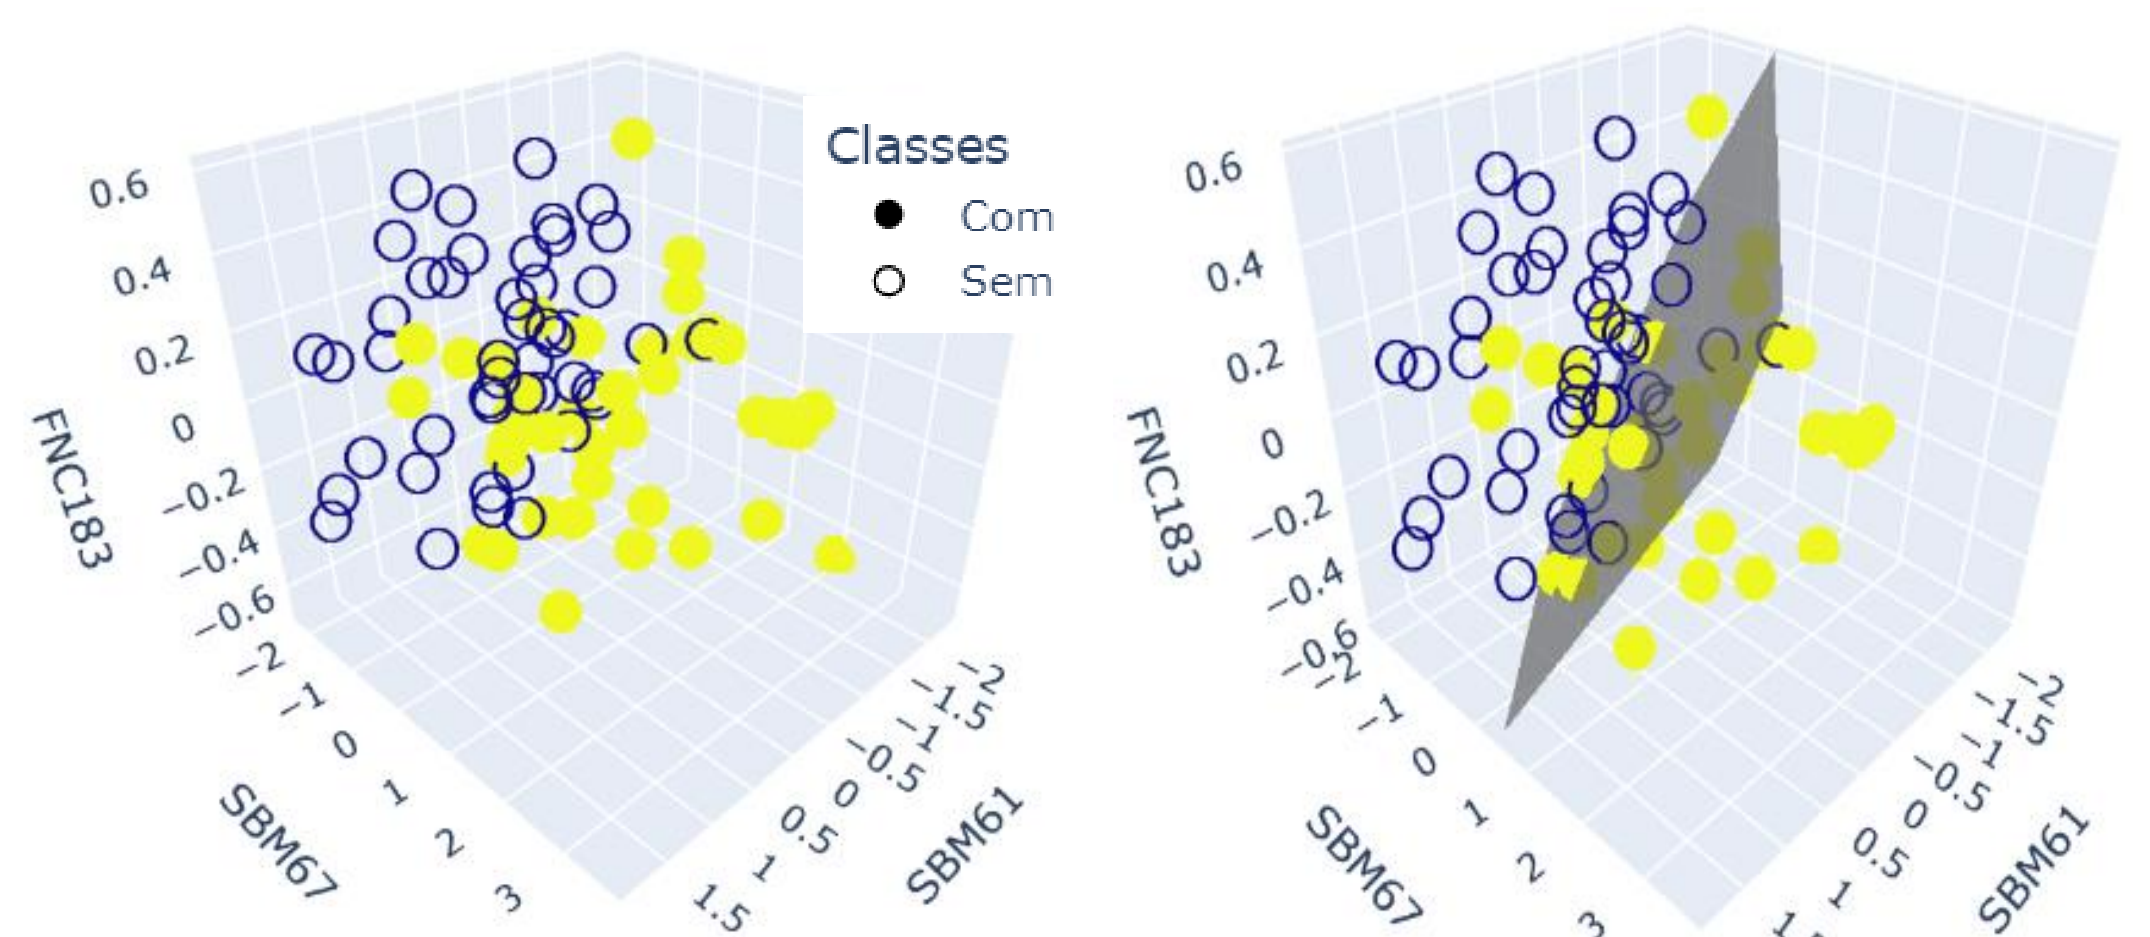


Figura 3 – Gráfico dos três atributos escolhidos para realizar a classificação.

Figura 4 – Superfície de decisão do algoritmo Support Vector Machine (SVM) sem *kernel* (linear).

Resultados e Análises

Os resultados obtidos mostram que o *dataset*, com exceção de algumas amostras, pode ser considerado como linearmente separável. O *kernel* quântico apresenta não-linearidades inerentes aos processos de medida utilizados nos circuitos quânticos. É válido ressaltar que os *kernels* tem como função transformar problemas não linearmente separáveis em linearmente separáveis ao projetar os dados em um espaço de vetores não linear. A eficácia de um *kernel* depende das características intrínsecas dos dados e, portanto, nem todo *kernel* é capaz de melhorar as métricas de desempenho de um determinado *dataset*.

No caso das figuras 1 e 2 adaptadas de Havlicek et al. (2019), a figura 1 representa um conjunto de dados não linearmente separáveis e a figura 2 apresenta como a técnica de PCA com *kernel* quântico. Na figura 2, o problema de exemplo torna-se linearmente separável.

Para o auxílio de diagnóstico em esquizofrenia, o *kernel* quântico apresenta mais desvantagens do que vantagens, pois o conjunto de dados em questão apresenta um comportamento próximo de um conjunto de dados linearmente separáveis.

Tabela 1 – Resultados Obtidos.

Método	Acurácia	Revocação	Precisão
K-NN	67%	58%	88%
Naive Bayes	72%	67%	89%
Árvore de Classificação	67%	50%	100%
Floresta Aleatória	89%	83%	100%
SVM (linear)	72%	58%	100%
QSVM - ZFeature	50%	50%	100%
QSVM - ZZFeature	44% (56%)	17% (83%)	100% (63%)

Integrante: Leonardo Spagnuolo Belluzzo