



UM ESTUDO DO SISTEMA DE DOIS OSCILADORES HARMÔNICOS FRACAMENTE ACOPLADOS USANDO APRENDIZADO DE MÁQUINA.

Luiz Davi Duarte Serafim¹
Aurélio Wildson Teixeira De Noronha²

RESUMO

O estudo das oscilações sempre se mostrou uma área de grande interesse da física em geral. Sua grande ocorrência em diversos fenômenos da natureza fez com que inúmeros estudos se voltassem para a sua compreensão e entendimento do seu funcionamento. Dentre inúmeras subáreas presentes nesse tema, uma delas que tem chamado bastante atenção no ramo das oscilações entre as quais são chamadas de oscilações do tipo acopladas que se caracterizam pela presença de uma força de acoplamento no sistema que fazem com que as partículas que os compõem se encontrem ligadas entre si. Nesse sentido, o presente trabalho propõe a determinação de uma solução para o sistema de oscilações acopladas limitada por certas condições iniciais. Além disso, também exibiremos o caso particular de uma força acoplada quando a mesma é relativamente fraca e diante disso algumas considerações que nos levam a alguns resultados interessantes. Para o qual, desenvolvemos uma resolução baseada especificamente em métodos analíticos. Logo após apresentamos as possíveis soluções do nosso sistema juntamente com a representação gráfica usando o Python como ferramenta computacional e através do algoritmo construído usaremos técnicas de classificação e de regressão de Machine Learning (ML) com o intuito de compreender e analisar a previsão de séries temporais para o sistema montado.

Palavras-chave: Aprendizagem de Máquina; Oscilações Acopladas; Mecânica Clássica.

UNILAB, ICEN, Discente, luiz.serafim@aluno.unilab.edu.br¹
UNILAB, ICEN, Docente, aurelionoronha@unilab.edu.br²



INTRODUÇÃO

Uma série temporal é qualquer evento que pode ser registrado com a passagem do tempo. As séries temporais estão presentes em diversas áreas do conhecimento como: Economia, Medicina, Meteorologia, Física, entre outras[1]. As predições feitas através das análises de séries temporais auxiliam na compressão de diversos fenômenos que encontramos no mundo real, mesmo que essas predições nunca estejam totalmente corretas, elas conseguem prever corretamente diversos eventos ao oferecerem modelos que possuem um alto grau de precisão quando são comparados em situações cotidianas.

A modelagem computacional de dados na predição de eventos na física se mostra bastante útil quando não há disposição de aparatos adequados para a realização do evento em maneira real. Mesmo que um evento real seja muito complicado de se simular, dado ao complexo número de variáveis presentes no evento, ainda temos uma ótima representação que se mostra como uma ferramenta poderosa para a visualização dos eventos.

Através da elaboração de um modelo computacional que seja eficiente para o nosso problema também é questionável se conseguimos fazer com que o sistema consiga aprender as relações existentes da nossa simulação para que a própria máquina consiga fazer simulações de valores futuros que não foram programados inicialmente. Estas predições podem ser feitas por diversos modelos de aprendizagem de máquina que são chamados de Machine Learning (ML) através de métodos alguns dos mais conhecidos são: de classificação e regressão presentes no modelo de árvore de decisão, também temos o SVM (Support Vector Machine), ou o modelo Kernel Regression que são algoritmos de ML que conseguem fazer essa análise e ensinar o programa a prever os futuros valores.

Partindo disso, começamos estudo de um sistema composto por duas partículas que se encontram ligadas entre si através de uma mola de acoplamento, essa mola possui uma força de acoplamento relativamente fraca e estudamos o seu comportamento no sistema e após a montagem do problema através da linguagem de programação python trabalhamos com a utilização de métodos de ML para ensinar o sistema a prever valores futuros do nosso problema. Ao final, esperamos conseguir compreender os algoritmos de classificação e regressão do método de árvore de decisão do ML, além de verificar como se comportam as séries temporais feitas a partir de osciladores harmônicos cujas as soluções sejam conhecidas e tentaremos determinar os melhores scores de treinamento para o modelo. Posteriormente, avaliamos outros modelos de aprendizagem de máquina como o SVM e Kernel Regression realizando os mesmos testes a procura dos melhores scores de treinamento, havendo sido encontrado os melhores métodos também, com a gama de ferramentas a disposição tentaremos prever valores de algumas grandezas, como a constante de acoplamento, a partir dos dados treinados.

METODOLOGIA

Para a realização desse projeto trabalhamos com o sistema físico, descrito pelas equações do movimento do sistema. Em que elas descrevem o movimento de dois osciladores harmônicos fracamente acoplados. Todo o ambiente virtual foi montado a partir da linguagem de programação Python e através da montagem desse sistema usamos a biblioteca scikit-learn de Machine Learning (ML), mais especificamente os modelos de classificação e regressão da árvore de decisão para ensinar o sistema a prever valores futuros da mesma. Usamos as métricas: Mean squared error (MSE que por sua vez mede a média dos erros quadrados entre as previsões do modelo e os valores reais observados e R² Score (R²), que é a medida da proporção da variância total dos dados explicada pelo modelo e Mean Absolute Error (MAE), que mede a diferença média



absoluta entre as previsões feitas pelo modelo e os valores reais correspondentes nos dados de teste. Tudo isso para verificarmos a qualidade das nossas aprendizagens. Ao final, para avaliarmos a qualidade do modelo de previsões buscamos outras maneiras de realizar a predição através de outros modelos de aprendizagem como: SVM e o Kernel Regression e verificaremos se os mesmos se qualificam como bons métodos para predição de valores do nosso sistema.

RESULTADOS E DISCUSSÃO

Começamos a construção das funções através da linguagem de programação Python e através das condições impostas inicialmente, conseguimos realizar o esboço das funções. Com equações analíticas das posições das partículas, também conseguimos escrever a velocidade de cada partícula. A partir das velocidades analíticas também conseguimos construir o diagrama das velocidades. Usando as posições, podemos construir o diagrama de configuração do nosso sistema e conseguimos ver a capacidade que o Python possui em representar em esboçar funções. No entanto, o nosso foco é conseguir fazer a predição das funções com ela tendo sido treinada a priori. Nesse sentido, usando a biblioteca Scikit-learn juntamente com o método de aprendizagem de Regressão da Árvore de Decisão conseguimos estipular os valores da função tendo sido treinada. Assim, escrevemos as funções em duas partes. A primeira, um função gerada pelo próprio programa indo do intervalo de $[0,6000]$ e na segunda parte a função feita a partir do programa treinado, ou seja, a função feita pelo programa depois de ter aprendido as técnicas de reprodução que será exposta no intervalo de $[6001,10000]$.

Em ambos os casos foram testados diferentes valores da "max depth" que é a profundidade máxima, ou seja, a quantidade de aprendizagem de detalhes com que cada árvore pode assumir. Na posição da partícula 1, temos 7 max depth diferentes: 30, 35, 40, 45, 50, 55 e 60. Cada um mostra um melhor aperfeiçoamento da função à medida que aumentamos a quantidade de detalhes que o método de árvore de decisão vai possuir. Já na posição temos boas aproximações quando escolhemos os seguintes max depth: 30, 35, 40, 45, 50, 55 e 60. No entanto, estamos interessados em saber a partir de qual "max depth" temos uma melhor predição dos valores em questão. Para isso, usaremos os métodos de MSE e R^2 . Logo, conseguimos definir quais são os melhores valores de "max depth" para o nosso sistema. À medida que os valores vão se ajustando conseguimos observar que cada vez mais os scores, MSE e R^2 , vão se ajustando, com o MSE tendendo cada vez mais a 0 e o R^2 tendendo ao valor 1. Ademais, para testar ainda mais o nosso sistema pretendemos observar o funcionamento da previsão para a energia potencial de acoplamento da partícula 1. A expressão que descreve a energia potencial para esse sistema. Nesse teste, buscamos perceber se através de uma função treinada da energia potencial U_1 conseguimos obter uma boa aproximação da mesma e usamos a aproximação para dar continuidade na construção total da mesma. A plotagem do gráfico com a condição de treinamento de max depth = 60.

Havendo observado o poder do modelo de árvore de decisão do scikit-learn. Vamos partir para a observação de outros modelos e verificar se os mesmos também se mostram como ótimos modelos de aproximação. Iniciamos com o modelo SVM (Support Vector Machine) este por sua vez procura determinar o melhor hiperplano que maximize a margem entre as classes de dados de entrada. Isso significa que procuramos encontrar a melhor linha, ou superfície dependendo da distribuição de dados, que melhor separa os diversos tipos de dados.

Usaremos o método em questão para comparar os valores previstos, de maneira análoga ao que foi feito anteriormente no método de árvore de decisão. Em ambos os casos foram testados diferentes valores de "gamma", que é um parâmetro que influencia na forma que a superfície de dados é separada, a medida que



diminuímos os Valores gamma resultam em uma maior influência dos vetores de suporte na superfície de separação. No entanto, quando aumentamos os valores de gamma fazemos com que a influência seja mais localizada, isto é, cada vetor de suporte tem uma maior ao seu entorno. Nas funções a seguir, atribuímos diversos valores de gamma que são: 0.001, 0.01, 0.1, 1 e 10. Esta técnica foi feita tanto para a partícula 1 como para a partícula 2 das funções a partir do método SVM. Em que, usamos os métodos MSE, MAE e R^2 para a verificação da qualidade dos nossos resultados.

Agora de maneira análoga ao modelo anterior usaremos o método de aprendizagem Kernel Regression e em seguida verificaremos como são as nossas aproximações. Novamente, vamos realizar os ajustes a partir dos valores variados de gamma. Ao qual, usamos, novamente, os métodos MSE e MAE para a verificação.

Ademais, também buscamos determinar uma expressão para a constante de acoplamento K_{12} . Caso tenhamos os valores: D , w_0 , M e K . Assim, temos uma expressão que mostra o valor para K_{12} a partir de valores conhecidos. Quando usamos o nosso programa para determinar o valor de k_{12} com as condições que foram postas inicialmente. No entanto, determinar os valores de K_{12} e M a partir de séries temporais é um trabalho mais complexo. E mesmo que venhamos a procurar determiná-los é necessário um conjunto maior de parâmetros, ou seja mais variáveis, para a sua determinação concisa. Um exemplo disso, é a determinação do K_{12} que mesmo com os valores das séries temporais treinadas ainda é necessário conhecer a massa dos osciladores.

CONCLUSÕES

Concluimos, que conseguimos realizar as predições com os algoritmos de classificação e de regressão de ML, vimos como se comportam, quando analisamos séries temporais produzidas por osciladores harmônicos cujas soluções sejam conhecidas. Ademais, determinamos os algoritmos de classificação e regressão do método de árvore de decisão do ML que conseguem obter melhores scores de treinamento. Verificamos outros algoritmos aprendizagem de máquina capazes de fazer previsões que foram os SVM e o Kernel Regression e definimos os seus melhores scores de treinamento. Além disso, com o conjunto de dados tentamos determinar algumas grandezas do sistema, por exemplo, a constante de acoplamento K_{12} , a priori o trabalho analítico para obter a constante de acoplamento não foi muito trabalhoso, porém não conseguimos obter a mesma de maneira independente, precisamos conhecer a massa dos osciladores, e não foi possível elaborar um modelos com os dados de treinamento para a obtenção do K_{12} a partir das séries temporais em virtude do trabalho ser bastante complexo.

AGRADECIMENTOS

Agradeço à Unilab pelo financiamento da pesquisa intitulada UM ESTUDO DO SISTEMA DE DOIS OSCILADORES HARMÔNICOS FRACAMENTE ACOPLADOS USANDO APRENDIZADO DE MÁQUINA. e executada entre 01/10/2022 e 30/09/2023, através do Programa Institucional de Bolsas de Iniciação Científica (Pibic) e Tecnológica (Pibiti), da Unilab.

REFERÊNCIAS

[1] NIELSEN A. Análise Prática de Séries Temporais: Predição com Estatística e aprendizado de máquina; Rio de Janeiro(RJ): Alta Books,2021.



- [2] THORTON S. T. MARIO, J. B. Dinâmica Clássica de Partículas e Sistemas. [S.l.]:Cengage Learning, 2011.
- [3] SCIKIT-LEARN. Scikit-learn: Machine Learning in Python. Disponível em: <https://scikit-learn.org/stable/index.html>. Acesso em: 18 mar. 2023.
- [4] PYTHON. Python Software Foundation. Disponível em: <https://www.python.org>. Acesso em: 18 mar. 2023.
- [5] Downey, A. B. Pense em Python: Pense como um cientista da computação, São Paulo(SP), Novatec, 2016