



**REENCONTROS
NOVOS ESPAÇOS
OPORTUNIDADES**

XXXIV SIC Salão Iniciação Científica

**26 - 30
SETEMBRO
CAMPUS CENTRO**

Evento	Salão UFRGS 2022: SIC - XXXIV SALÃO DE INICIAÇÃO CIENTÍFICA DA UFRGS
Ano	2022
Local	Campus Centro - UFRGS
Título	Aprendizado não supervisionado em sistemas de spins
Autor	PEDRO HENRIQUE MENDES DUARTE
Orientador	HEITOR CARPES MARQUES FERNANDES

Aprendizado Não Supervisionado em Sistemas de Spins

Aluno: Pedro Henrique Mendes
Professor: Heitor C. M. Fernandes

Porto Alegre, Agosto de 2022

O presente trabalho propõe o uso de ML [1] para tratar o tema de transições de fase em sistemas de *spins*. Já se sabe que ML pode ser eficiente na determinação tanto do ponto onde a transição de fase ocorre [2] quanto do tipo de simetria que é quebrado [3]. E é justamente os resultados que estamos interessados em reproduzir e entender. Um sistema de *spins* é caracterizado pelo valor em cada um dos seus sítios. E cada sistema, em uma rede quadrada, possui $N = L \times L$ sítios, onde L é o tamanho do lado da rede. Assim, o trabalho buscou formas de reduzir a dimensão dos sistemas de *spins*, utilizando a Análise dos Componentes Principais, *Principal Component Analysis* (PCA). O PCA é um algoritmo que busca correlações nos dados e indica o número mínimo de fatores que ele acredita ser necessário para apontar todas informações relevantes. Em um primeiro momento foi utilizado o modelo de Ising [4], pela sua simplicidade e vasta literatura. Ao aplicar o PCA no modelo de Ising foi notado que apenas um componente principal. Ao projetar os dados originais, que são as configurações de *spins*, no componente principal, foi identificado que o componente principal é a magnetização do sistema. Ao reduzir o sistema em um número menor de características podemos visualizar melhor como ele se comporta e aplicar algoritmos de clusterização, outro método de aprendizado não supervisionado. Pode-se citar algumas perspectivas de continuidade do projeto: aplicar outros métodos de aprendizado não supervisionado e aplicar em outros modelos, como o Potts ou Gás de Rede.

Referências

- [1] G. Carleo, I. Cirac, K. Cranmer, L. Daudet, M. Schuld, N. Tishby, L. Vogt-Maranto, and L. Zdeborová, “Machine learning and the physical sciences,” *Reviews of Modern Physics*, vol. 91, Dec 2019.
- [2] K. Fukushima and K. Sakai, “Can a cnn trained on the ising model detect the phase transition of the q -state potts model?,” 2021.
- [3] L. Wang, “Discovering phase transitions with unsupervised learning,” *Phys. Rev. B*, vol. 94, p. 195105, Nov 2016.
- [4] M. E. J. Newman and G. T. Barkema, *Monte Carlo methods in statistical physics*. Oxford: Clarendon Press, 1999.