



**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	Estudo de modelos de aprendizado de máquina em dados tabulares para geração de funções heurísticas para planejamento clássico
Autor	EDUARDO FANTINI
Orientador	ANDRÉ GRAHL PEREIRA

Estudo de Modelos de Aprendizado de Máquina em Dados Tabulares para Geração de Funções Heurísticas para Planejamento Clássico

Bolsista: Eduardo Fantini

Orientador: André G. Pereira

Universidade Federal do Rio Grande do Sul

O estudo de heurísticas para guiar buscas em tarefas de planejamento clássico tem recebido ampla atenção da comunidade acadêmica. Uma heurística busca explorar o espaço de estados de uma tarefa de tal forma que uma quantidade mínima de estados sejam expandidos, tornando a busca para a solução mais eficiente. Algoritmos de aprendizado de máquina têm sido utilizados para a obtenção de funções heurísticas, tipicamente tendo como conjunto de treinamento pares (*estado, custo para a solução*). Após o treinamento, as heurísticas retornadas pela rede neural são usadas para a solução de estados em tarefas de planejamento clássico para domínios como *Blocksworld*, *N-Puzzle*, *Visitall*, entre outros. No entanto, as abordagens de aprendizado existentes para a obtenção de funções heurísticas são exclusivamente baseadas em redes neurais (*preditores fortes*), tais como *residual neural networks* (ResNets) e *graph neural networks*. Nosso trabalho busca estudar e comparar métodos de aprendizado baseados em árvores de decisão, que geram *árvores* (ou *preditores*) cujos ramos levam a *decisões* (ou *predições*) com base na informação de uma certa entrada. Por exemplo, durante a etapa de treinamento, os algoritmos *gradient boosting* e *random forest* criam um conjunto de *preditores fracos* cujas respostas individuais são combinadas para produzir uma única *predição forte*. Experimentos preliminares com tempo de treinamento fixo utilizando uma *ResNet* com 2 camadas ocultas de 250 neurônios vs. XGBoost (implementação otimizada de *gradient boosting*) com 1 K preditores indicam uma convergência de treinamento 100 vezes mais rápida no XGBoost, com *predições* similares quando avaliamos os modelos sobre todo o conjunto do espaço de estados de uma tarefa de planejamento. Nossos estudos atuais resumem-se a entender aspectos fundamentais do XGBoost e a buscar outros algoritmos baseados em árvores de decisão para comparação.