

1 Introdução

Devido à popularização das bolsas de valores, o número de negociadores ativos tem tido um significativo aumento, o que intensifica a competição por oportunidades de lucro. Diversos fatores influem nos preços dos ativos negociados, o que exige que os negociadores dispensem uma maior atenção aos mesmos. A quantidade de ofertas para um ativo, as últimas flutuações nos preços, e o volume de ativos disponíveis para venda, são alguns dos fatores que podem contribuir para a alteração do valor de negociação de um determinado ativo. Além desses poucos fatores citados, muitos outros influenciam.

Algoritmos que analisam esses fatores para gerar um plano de negociações foram propostos por vários autores (seção 1.3). Com a alta concorrência pelo lucro, a aplicação de tais algoritmos vem se mostrando cada vez mais importante na negociação de ativos.

1.1 Definição do Problema

O problema da execução otimizada de transações (encontrado na literatura como *optimized trade execution* ou *one-way trading problem*), consiste em vender (respectivamente, comprar) V ativos dentro de um intervalo especificado de tempo H (horizonte), visando maximizar o montante financeiro recebido (respectivamente, minimizar o montante pago) (Nevmyvaka et al. 2006).

O nosso trabalho consiste em desenvolver e comparar estratégias de negociação, para a resolução do problema supracitado, no caso particular de $V = 1$. Devido a essa restrição, durante o horizonte de negociação, nossas estratégias só podem efetuar uma venda (ou compra), mas podem fazer várias ofertas em diferentes instantes do período de negociações, até que uma seja executada.

1.2 Contribuições

Estratégias sofisticadas de negociação, que usam técnicas de aprendizado de máquina e de programação dinâmica, são aplicadas ao problema de

execução otimizada de transações desde a década de 90, mostrando que os pesquisadores da área há algum tempo se preocupam em aumentar os lucros em negociações nos mercados financeiros. No nosso trabalho não propomos nenhuma nova estratégia de negociação, mas implementamos algumas propostas por outros autores. Inserido no contexto do problema de execução otimizada de transações, este trabalho apresenta as seguintes contribuições:

- **Desenvolvimento de um ambiente de simulação.** Desenvolvemos um simulador dos mercados financeiros que se baseia em dados históricos de ativos negociados na BOVESPA & BMF para simular as transações. Essa ferramenta aceita a execução de várias instâncias de estratégias e, ao término da simulação, fornece um relatório com o desempenho de cada uma;
- **Estudo comparativo das estratégias.** Além de algumas estratégias simples (Aleatória, Ótima, *Submit and Leave* e *Submit and Execute*), implementamos duas estratégias sofisticadas (*Kearns e Reinforcement Learning*) propostas por outros autores (vide capítulo 3). Executamos instâncias dessas estratégias em nosso simulador para obter os resultados dos experimentos. Analisando os resultados, fizemos um estudo comparativo indicando os pontos fortes e fracos de cada estratégia. Nossa análise, exposta no capítulo 4, indica que as estratégias mais eficientes são as que usam algoritmos de aprendizado de máquina.

1.3

Trabalhos Relacionados

No trabalho apresentado por Bertsimas (Bertsimas & Lo 1998), uma estratégia ótima de negociação é proposta. Essa estratégia minimiza o custo esperado de negociar um grande conjunto de ativos em um determinado período de tempo. Especificamente, dado um conjunto de ativos S , que deve ser executado por completo dentro de um número finito de períodos T , e dada uma função que fornece o preço de execução de uma negociação individual em função dos ativos negociados e das condições de mercado, essa estratégia gera uma sequência de operações que minimiza o custo esperado de executar S nos T períodos.

O trabalho publicado por El-Yaniv (El-Yaniv et al. 2001) aborda dois problemas: *time series search* e *one-way trading problem*. No *time series search problem*, o objetivo do jogador é procurar pelo preço máximo (ou mínimo) em uma sequência que só pode ser vista sequencialmente, um preço de cada vez. Durante a busca, o jogador pode decidir aceitar um determinado preço p . Neste

caso, o jogo termina e a pontuação obtida pelo jogador é p . No *one-way trading problem*, a um negociador é dada uma determinada quantidade de dinheiro em uma moeda e uma tarefa de usar esse dinheiro na compra de outra moeda (dólar para real, por exemplo). A cada dia, uma nova taxa de conversão das moedas é anunciada e o negociador precisa decidir quantos dólares ele irá converter para real com a taxa anunciada. O jogo termina quando o negociador converter todos os dólares em reais e sua pontuação é a quantidade de reais adquirida (O *one-way trading problem* é exatamente o problema que abordamos em nosso trabalho: Execução Otimizada de Transações). Os autores propõem estratégias para a obtenção de resultados otimizados dos problemas mencionados.

Chan (Chan & Shelton 2001) apresenta um modelo de aprendizado adaptativo para execução otimizada de transações financeiras usando aprendizado por reforço. Nenhum conhecimento do mercado, como ordem de chegada das ofertas ou o processo de variação de preços, é assumido. O agente aprende a partir da experiência em mercados em tempo real, desenvolvendo estratégias de negociação. Usando essa abordagem, múltiplos objetivos foram alcançados pelo agente de aprendizado, incluindo a maximização de lucros. Os resultados das simulações demonstram o sucesso alcançado pelos autores ao usar técnicas de aprendizado de máquina para construir algoritmos de negociação de ações.

No trabalho publicado por Tesauro (Tesauro & Bredin 2002), um *framework* é proposto para a criação de algoritmos de programação dinâmica que podem ser usados para formular estratégias de negociações de ações. Neste *framework*, os estados são representados inicialmente pelos dados do agente (volume de ações a negociar, por exemplo) e as probabilidades de transição de estado são estimadas a partir do histórico dos valores das ações. Os estados e as probabilidades de transição são usados na formulação do algoritmo de programação dinâmica. Um programa dinâmico é resolvido cada vez que o agente precisa fazer uma oferta, visando otimizar o lucro. O algoritmo proposto se mostrou superior ao anteriormente proposto por Gjerstad (Gjerstad & Dickhaut 1998).

Coggins (Coggins et al. 2003) propõe uma abordagem para otimização de transações em mercados de ofertas limitadas. Sua proposta é baseada em um método para gerar planos de execução de transações. Para a geração desses planos, uma análise comparativa é feita entre as variações do preço das ações durante o dia e o risco das ações assumirem preços adversos em um futuro próximo. Os planos de execução correspondem às soluções de problemas de programação dinâmica. Os planos de execução são criados e testados para três ações importantes da bolsa de valores australiana. Os desempenhos dos planos são obtidos a partir de execuções em conjuntos de testes extraídos dos

históricos das ações e comparados aos obtidos por três estratégias mais simples.

Kakade (Kakade et al. 2004) introduz modelos de algoritmos online para dois importantes aspectos dos mercados financeiros modernos, dentre eles, o problema de execução otimizada de ofertas limitadas. Os autores provêm um estudo de algoritmos competitivos para esses modelos e os relacionam com algoritmos de transações de ações anteriormente propostos.

Nevmyvaka (Nevmyvaka et al. 2005), ressalta a importância de execução eficiente em mercados eletrônicos. Nesse trabalho, é demonstrado empiricamente que combinando ofertas de mercado (que permite execução imediata da oferta independente de preço) e ofertas limitadas (que oferece execução incerta a um preço específico), podemos obter, em média, preços melhores que se usarmos apenas ofertas de mercado. Na análise dos autores, é destacado o *trade-off* entre a melhoria de preço esperada das ofertas limitadas e o risco de não execução. É mostrado como determinar o preço ótimo de uma oferta limitada em uma configuração de mercado simples e é sugerido como essa abordagem pode ser generalizada para uma configuração de mercado completa.

Nevmyvaka (Nevmyvaka et al. 2006), apresenta a primeira aplicação empírica extensiva de aprendizado por reforço no problema de execução otimizada de transações, usando grandes conjuntos de dados de transações da NASDAQ. A metodologia de experimentos apresentada consiste dos seguintes passos.

1. Identificação de um conjunto de variáveis de estado, que pode ser derivado da configuração do mercado e das próprias ações do algoritmo de aprendizado por reforço. Essas variáveis são divididas em variáveis “privadas” (tempo de execução, por exemplo) e variáveis de “mercado” (que refletem atributos das atividades de transação).
2. Aplicação de um algoritmo adaptado de aprendizado por reforço, que explora a estrutura do problema para aumentar a eficiência computacional em grandes conjuntos de dados.
3. Comparação empírica das políticas aprendidas com uma variedade de estratégias de negociação mais naturais.

As principais contribuições dos autores são:

1. Uma cuidadosa demonstração experimental de que a abordagem de aprendizado por reforço é bastante lucrativa para execuções otimizadas, resultando em melhorias substanciais nos resultados obtidos. Foi mostrado que as políticas de execução aprendidas podem melhorar a lucratividade em mais de 50% em relação aos outros algoritmos comparados.

2. Um algoritmo eficiente de aprendizado por reforço que explora a micro-estrutura de mercado para aumentar o seu desempenho.
3. Um estudo das possíveis variáveis de mercado.
4. Uma análise detalhada das políticas aprendidas pelo algoritmo de aprendizado por reforço e como elas dependem das variáveis de estado.

1.4

Organização

Técnicas de aprendizado por reforço e de validação de algoritmos de aprendizado de máquina são fundamentais para o bom entendimento dos algoritmos implementados e dos experimentos realizados, respectivamente. Tais técnicas são apresentadas no capítulo 2. Todas as estratégias de negociação implementadas são detalhadas no capítulo 3. No capítulo 4, detalhamos os dados históricos coletados e analisamos os resultados obtidos nos experimentos. Finalmente, no capítulo 5, apresentamos nossas conclusões e as propostas de trabalhos futuros.