

PAULO C. JUNIOR

APLICAÇÃO DE SISTEMAS MULTIAGENTES AO
MERCADO BRASILEIRO DE AÇÕES

Texto apresentado à Escola Politécnica da
Universidade de São Paulo como requisito
para obtenção do Título de Especialista
(MBA) em Engenharia Financeira, junto
ao PECE.

Área de Concentração:
Engenharia Financeira

Orientador:
Danilo Figueiredo

São Paulo
2016

10.891/EF
2016
A 59a/



FICHA CATALOGRÁFICA

m 2016

Junior, Paulo Fernando Cabral dos Anjos
APLICAÇÃO DE SISTEMAS MULTIAGENTES AO MERCADO
BRASILEIRO DE AÇÕES/ P. C. Junior. São Paulo, 2016.
52 p.

Monografia (MBA em Engenharia Financeira) — Escola Politécnica da Universidade de São Paulo. PECE.

1. Sistemas Multiagentes #1. 2. Mercado de Ações #2. 3. Programação Genética #3. I. Universidade de São Paulo. Escola Politécnica. PECE. II. t.

RESUMO

O presente trabalho propõe a utilização do modelo de sistemas multiagentes, com aprendizado através de programação genética, para a previsão de preços no mercado de ações brasileiro, sendo feito, inclusive, um experimento utilizando o software Altreva Adaptive Modeler aplicado às ações preferenciais das empresas Petrobrás e Vale. É feita também uma discussão sobre a eficiência do mercado de ações e como, em mercados eficientes, o esforço para realizar previsões não seria premiado.

Palavras-Chave: Sistemas Multiagentes. Programação Genética. Mercado de Capitais.

ABSTRACT

This work proposes the use of multiagent systems, combined with genetic programming learning method, to forecast prices in the Brazilian stock market. An experiment was carried out using Altreva Adaptive Modeler software applied to the Petrobrás and Vale preferencial stocks. Also, a discussion about the stock market efficiency is treated and how, in efficient markets, the effort to make forecasts wouldn't be rewarded.

Keywords: Multiagent Systems. Genetic Programming. Stock Market.

SUMÁRIO

Lista de Ilustrações

Lista de Tabelas

Lista de Abreviaturas e Siglas

1	Introdução	11
1.1	Passeio aleatório, mercado eficiente e previsões	11
1.2	Objetivos	12
1.3	Justificativa do tema	12
2	Metodologia	14
2.1	Sistemas Multiagentes	14
2.2	Lógicas dedutiva e indutiva	15
2.2.1	A indeterminância da lógica dedutiva	16
2.2.2	Usando a lógica indutiva	18
2.3	Programação genética	19
2.4	Altrevia Adaptive Modeler	20
2.4.1	Programação genética fortemente tipada no Adaptive Modeler	22
2.4.2	O modelo baseado em agentes-RI do Adaptive Modeler . .	24

3	Experimento	25
3.1	Dados	25
3.1.1	Descrição dos dados	26
3.2	Configuração do modelo	26
3.3	Informações relevantes do experimento	28
3.4	Evolução do modelo	31
4	Resultados	41
4.1	Métodos de análise	41
4.1.1	Utilização das sugestões de negociação no mercado real	41
4.1.2	Utilização na previsão da direção das variações	43
5	Conclusões e trabalhos futuros	45
	Referências	47
	Apêndice A	48

LISTA DE ILUSTRAÇÕES

1	Inicialização do modelo	27
2	Inicialização dos agentes	27
3	Valores iniciais dos parâmetros a serem acompanhados no experimento	29
4	Relação entre “idade” e riqueza da população	30
5	Evolução depois de 289 dias - Parâmetros	32
6	Evolução depois de 289 dias - Idade x Riqueza	33
7	Evolução depois de 622 dias - Parâmetros	35
8	Evolução depois de 622 dias - Idade x Riqueza	36
9	Evolução ao fim de 2015 - Parâmetros	38
10	Evolução ao fim de 2015 - Idade x Riqueza	39
11	Evolução do patrimônio - Petrobrás	42
12	Evolução do patrimônio - Vale	42
13	Preços reais x Preços previstos - Petrobrás	43
14	Preços reais x Preços previstos - Vale	44

LISTA DE TABELAS

1	Tipos - Adaptive Modeler	23
2	Diagnóstico Petrobrás - Previsões de direção do mercado	43
3	Diagnóstico Vale - Previsões de direção do mercado	44
4	Relação entre funções (gene), tipos de argumentos e de retornos .	48
4	Relação entre funções (gene), tipos de argumentos e de retornos (continuação)	49
4	Relação entre funções (gene), tipos de argumentos e de retornos (continuação)	50
4	Relação entre funções (gene), tipos de argumentos e de retornos (continuação)	51
4	Relação entre funções (gene), tipos de argumentos e de retornos (continuação)	52

LISTA DE ABREVIATURAS E SIGLAS

PG Programação Genética

PGFT Programação Genética Fortemente Tipada

1 INTRODUÇÃO

1.1 Passeio aleatório, mercado eficiente e previsões

Uma das hipóteses mais antigas e mais utilizadas sobre o mercado de ações é a de que este é um mercado eficiente, o que significa, neste âmbito, que dada a simetria na informação os preços refletem instantaneamente novas informações implicando na conclusão de que os preços das ações é completamente aleatório e, portanto, imprevisível.

Esta conclusão se baseia no artigo de Paul Samuelson (SAMUELSON, 1965) que contém a prova de que num mercado informacionalmente eficiente as mudanças nos preços são imprevisíveis se incorporam as expectativas e informações de todos os participantes do mercado, e argumenta que, buscando o lucro a todo segundo, os participantes do mercado reagem instantaneamente a qualquer nova informação fazendo com que os preços a absorvam.

Essa aleatoriedade dos preços é modelada em diversos trabalhos (por exemplo (BLACK; SCHOLES, 1965), (MARKOWITZ, 1959) e (SHARPE, 1964)) como um passeio aleatório, o que gerou diversos avanços, como o desenvolvimento do mercado de opções, a capacidade de especificar derivativos e a criação de produtos financeiros exóticos.

Por outro lado, nas décadas de 70 e 80 surgem trabalhos, (LEROY, 1989) e (LUCAS, 1978), que buscam evidenciar que, mesmo em mercados informacionais

mente eficientes, os preços não seguem um passeio aleatório e outros, (GROSSMAN; STIGLITZ, 1980), vão além ao afirmar que estes mercados são uma impossibilidade dado que o retorno em colher informações para gerar lucro seria ínfimo o que levaria a um colapso do mercado. Todos estes trabalhos se aproveitam do fato de que a hipótese dos mercados eficientes não leva em consideração um dos principais fatores do mercado, o risco.

Considerando o risco, os trabalhos que questionam a hipótese do mercado eficiente e o modelo de passeio aleatório para os preços, passa-se a buscar modelos de previsão e, com o avanço da ciência da computação, esses modelos se tornam mais sofisticados, indo de modelos de regressão simples a modelos que levam em consideração notícias e o “humor do mercado”, passando pelas técnicas de aprendizagem de máquina, como redes neurais e algoritmos genéticos.

1.2 Objetivos

O objetivo deste trabalho é estudar a aplicação do modelo de sistemas multiagentes como preditor de preços de ações no mercado brasileiro, que passa por estudar os principais conceitos de sistemas multiagentes, alguns métodos relacionados de previsão de preços e a elaboração um estudo de caso utilizando o software Altreva Adaptive Modeler (<http://www.altreva.com/>). Com isso buscou-se comparar os preços previstos pelo modelo com os preços reais dos ativos.

1.3 Justificativa do tema

A utilização de sistemas multiagentes no mercado de ações é um assunto novo que resulta, principalmente, do avanço computacional, que permite que a coleta de dados e o processamento das regras sejam feitos em tempo hábil para a utilização da informação, e da informatização das bolsas de valores que permite

o contato direto dos modelos com os dados e possibilita a automatização das estratégias de negociação.

É um tema que reúne modelagem computacional, aprendizagem de máquina, estratégias de negociação e previsão de preços de ações, que são cada vez mais abordados em artigos, livros e em salas de aula, porém para essa aplicação, ao mercado brasileiro de ações, tem-se conhecimento de poucos trabalhos, (AZEVEDO et al., 2008), apesar de trabalhos em outras aplicações, como (PEREIRA; RIBEIRO; SECURATO, 2012) no mercado de commodities agrícolas.

2 METODOLOGIA

2.1 Sistemas Multiagentes

Imagine um programa agente que faz transações comerciais em seu nome. A tarefa deste agente é mapear bens à venda em diversas lojas online ao longo do tempo, e comprar alguns deles caso o preço seja atrativo. Para cumprir essa tarefa de maneira satisfatória, o agente deve incorporar suas preferências por produtos, sua capacidade financeira e seu conhecimento sobre o ambiente em que operará. Além disso, o agente deve incorporar o seu conhecimento de agentes similares com os quais irá interagir, incluindo suas preferências e conhecimento. Um grupo destes agentes forma um sistema multiagente.

Outra definição, mais formal, é a que diz que um agente é um ente computacional (geralmente um programa de computador) situado num ambiente, que é capaz de ações autônomas e flexíveis neste ambiente para atingir os objetivos para os quais foi construído. Estes agentes também possuem habilidades sociais e interagem entre si e com humanos para solucionar seus próprios problemas. Eles também podem se comportar de maneira cooperativa e colaborar para a solução de um problema em comum. Para concluir suas tarefas e interagir entre si, agentes inteligentes compõem um sistema multiagentes (SHOHAM; LEYTON-BROWN, 2010).

A definição de sistemas multiagentes revela uma possibilidade interessante de aplicação que é utilizar estes sistemas para simular o mercado real num ambiente

completamente controlado, isto é, com controle do condutor do experimento sobre a informação disponível, o método de decisão dos agentes e a performance de cada um deles. Para atingir este nível de simulação se faz necessária a presença da inteligência artificial, instituindo um processo de aprendizagem para que o sistema se adapte e evolua facilitando a identificação de padrões de comportamentos emergentes, que são os reais objetos de interesse.

Os agentes artificialmente inteligentes (agentes-I) são, dessa forma, introduzidos como a junção dos agentes com a inteligência artificial e definidos como programas que contém heurísticas e algoritmos de aprendizagem computacional, com a intenção de capturar aspectos particulares do comportamento humano, e serão os agentes utilizados neste trabalho.

2.2 Lógicas dedutiva e indutiva

Lógica dedutiva é o processo lógico que utiliza uma ou mais premissas para chegar a conclusões. Esse tipo de pensamento lógico se baseia na ideia de que, se as premissas são verdadeiras e as regras lógicas são seguidas as conclusões são, necessariamente, verdadeiras. Utilizada como base do pensamento matemático, a lógica dedutiva busca encontrar regras que contemplam todo o domínio discutido e aplicar aos casos particulares, se contrapondo à lógica indutiva, em que observações de casos particulares são extrapoladas para o domínio completo baseando-se na probabilidade indutiva, sendo essa a base do pensamento estatístico.

Dessa maneira, ambas as abordagens apresentam problemas em aplicações relacionadas a agentes-I dado que, no caso da lógica dedutiva é necessário que o agente tenha conhecimento do todo, o que é difícil de ser garantido e, no caso da lógica indutiva, há de se conviver com a incerteza e admitir que o agente cometerá erros. A escolha do processo lógico a ser utilizado para as tomadas de decisão dos

agentes requer o cuidado de escolher qual dos pensamentos mais se assemelha ao processo decisório dos agentes do mercado real, ou seja, as pessoas.

2.2.1 A indeterminância da lógica dedutiva

Considere um mercado com um único ativo com um payoff estocástico d_t , com um ativo livre de risco com retorno r por período. Cada agente i deve formar suas expectativas individuais para o payoff e o preço do próximo período, respectivamente $E[d_{t+1}|I_t]$ e $E[p_{t+1}|I_t]$, com variância condicional $\sigma_{i,t}^2$, dada a informação de mercado I_t . Assumindo o mercado sem arbitragem, o preço de equilíbrio, como descrito em (LEBARON, 1996), será:

$$p_t = \beta \sum_j w_{j,t} (E_j[d_{t+1}|I_t] + E_j[p_{t+1}|I_t]) \quad (2.1)$$

Em outras palavras, o preço do ativo p_t reflete as expectativas (ponderadas) dos indivíduos do mercado, descontada pelo fator $\beta = \frac{1}{(1+r)}$, com os pesos, $w_{j,t} = \frac{1}{\sigma_{j,t}^2} / \sum_k \frac{1}{\sigma_{k,t}^2}$ sendo a confiança relativa colocada nas previsões de cada agente j .

Assumindo investidores inteligentes, o que resta determinar para que se calcule o preço do ativo são as expectativas $E[d_{t+1}|I_t]$ e $E[p_{t+1}|I_t]$, para isso precisa-se determinar como estas são formadas. O argumento padrão de que tais expectativas podem ser formadas racionalmente, isto é, usando-se o pensamento dedutivo se baseia no seguinte raciocínio. Assuma investidores homogêneos que,

1. usam a informação disponível I_t de maneira idêntica na formação de suas expectativas de payoff,
2. sabem que os outros agentes têm as mesmas expectativas,
3. são perfeitamente racionais,
4. sabem que o preço do ativo seguirá a equação (2.1) e

5. sabem que (3) e (4) são de conhecimento comum.

Dessa maneira, a expectativa para os payoffs futuros são conhecidas, compartilhadas e idênticas e a homogeneidade nos possibilita fazer $w_{i,t} = \frac{1}{N} \forall i$, e, conforme mostrado em (DIBA; GROSSMAN, 1988), reduzir a equação para o preço conforme segue,

$$p_t = \sum_{k=1}^{\infty} \beta^k E[d_{t+k}|I_t] \quad (2.2)$$

Considerando as expectativas de payoff não-viesadas, o mercado terá, em média, as mesmas previsões para os próximos payoffs. Além disso, o preço muda com o tempo de acordo com as mudanças da informação disponível I_t , refletindo assim o valor “fundamental” do ativo, portanto lucros especulativos não estão consistentemente disponíveis. Dessa forma, com o apoio da homogeneidade, a precificação do ativo se torna dedutivamente determinada, isto é, os agentes podem, simplesmente, derivar logicamente o preço do ativo.

Buscando um modelo mais próximo do mundo real, vamos assumir que os agentes do mercado são inteligentes mas heterogêneos, que podem diferir entre si. Continuamos com a informação I_t sendo compartilhada entre os agentes, entretanto há diversas maneiras diferentes, e estatisticamente válidas, de usar essa informação para prever payoffs futuros. Isso já é suficiente para trazer indeterminância para o modelo de precificação (2.1). Além disso, as expectativas de preço heterogêneas $E_i[p_{t+1}|I_t]$ também são indeterminadas. Suponha que o agente i tente racionalmente deduzir (usar a lógica dedutiva) a sua expectativa, ele utilizará a equação (2.1) para o tempo $t + 1$ e terá,

$$E_i[p_{t+1}|I_t] = \beta E_i \left[\sum_j w_{j,t+1} (E_j[d_{t+2}|I_t] + E_j[p_{t+2}|I_t])|I_t \right] \quad (2.3)$$

Desse modo, o agente tem a necessidade de, na formação da sua expectativa de preço, levar em consideração as suas expectativas das expectativas de preço

e payoff dos outros agentes (e seus pesos de mercado relativos) dois períodos à frente e isso acontece iterativamente conforme há a necessidade de prever as expectativas mais passos à frente, ou seja, a lógica dedutiva, levando em consideração a heterogeneidade do mercado, nos leva a uma subjetividade infinita e, consequentemente, a expectativas que não são determináveis.

2.2.2 Usando a lógica indutiva

A lógica dedutiva não pode ser usada pelos agentes para compor suas expectativas e os preços dos ativos do mercado, sendo assim, como estes formarão tais expectativas? Podem ser usados modelos baseados em dados de mercado, na natureza do mercado, no comportamento dos outros investidores ou algum modelo altamente sofisticado baseado na lógica subjetiva. Porém, no final das contas, estes modelos seriam apenas possíveis hipóteses de difícil validação.

Entretanto, a abordagem usada neste trabalho é a de dar a cada agente a autonomia de utilizar diferentes “hipóteses de mercado” do que influencia os preços de mercado e os payoffs. E cada um testará simultaneamente diversas estratégias. Algumas terão boas performances prevendo os movimentos do mercado e ganharão a confiança do sistema sendo mantidas e usadas nas decisões de comprar ou vender. Outras terão performances ruins e serão descartadas. E outras serão geradas e terão suas performances testadas no mercado. Como ficará claro quais agentes se saem bem e agentes ruins são substituídos por novos formados, prioritariamente, pela combinação das estratégias dos melhores, o sistema aprende e se adapta. Este tipo de comportamento é chamado de lógica indutiva e estes agentes são racionalmente indutivos (agentes-RI).

A utilização de agentes inteligentes com lógica indutiva requer um método de aprendizagem que consiga tirar conclusões estatisticamente válidas para o todo a partir de observações, o que remete ao método natural de evolução genética,

que escolhe uma população de indivíduos a partir da aptidão individual em lidar com o ambiente. Este comportamento é simulado computacionalmente pela programação genética.

2.3 Programação genética

O método escolhido para o aprendizado dos agentes foi a Programação Genética (PG), que consiste numa técnica evolutiva inspirada pela evolução biológica para otimizar a performance de uma população de programas de computador em uma certa tarefa (KOZA, 1992). Os programas (ou genomas) representam possíveis soluções a uma dada tarefa ou problema e são avaliados por uma função de aptidão que mede o quanto bem cada programa resolve o problema. Os programas mais aptos são selecionados para participar das operações de reprodução e recombinação para a criação de uma nova geração de programas. Numa operação de recombinação como o crossover, partes (conjuntos de genes) escolhidas aleatoriamente de dois programas são trocadas para criar dois novos programas. Um operador de mutação também pode ser aplicado para modificar aleatoriamente pequenas partes de um programa. O processo de criar novas gerações é repetido até que um ou mais programas na população atinja um nível de aptidão satisfatório. A primeira geração é criada aleatoriamente.

PG usa programação funcional para codificar os genomas. Em programação funcional um programa é escrito como uma expressão ao contrário da programação imperativa, em que os programas consistem em sequências de instruções. Um programa funcional é um conjunto de funções matemáticas e outros símbolos, chamados de funções e terminais. Funções são operadores como soma ou média que levam argumentos. Terminais são constantes ou variáveis que não levam argumentos. As funções podem ser usadas como argumentos e assim criar expressões mais complexas.

Para resolver um problema com PG, um conjunto de funções e terminais deve ser definido de maneira apropriada, por isso o conhecimento específico do domínio tem papel importante, pois a escolha correta de funções e terminais e a definição da função de aptidão adequada podem ter grande impacto na performance da PG.

A criação de programas com PG tem um uso severo de fatores aleatórios. Na criação da primeira geração e nas operações de crossover e mutação para a criação das próximas gerações são usados números aleatórios com o intuito de garantir que o espaço de procura (de todos os programas possíveis) seja completamente explorado. Porém, a criação aleatória de programas pode levar a programas que não fazem sentido ou que não podem ser avaliados corretamente, pois a função argumento não retorna o tipo de valor adequado para a função.

Para contornar este problema utiliza-se a programação genética fortemente tipada (PGFT), em que um conjunto de tipos é definido (definindo o domínio do problema) e toda função e terminal deve retornar um tipo específico e todo argumento de função deve ser de um determinado tipo. Isso define quais funções e terminais podem ser usados para argumentos para outras funções.

Fica claro que para conduzir o experimento proposto há a necessidade de utilizar uma ferramenta que combine a ideia de agentes-RI com a PGFT e, idealmente, tenha uma estrutura de mercado de ações para a evolução dos agentes. Um software que atende a estes requisitos é Altrevia Adaptive Modeler.

2.4 Altrevia Adaptive Modeler

O software Adaptive Modeler simula um modelo de mercado baseado em agentes-RI com gerações de agentes criadas através de PG que, como apontado anteriormente, é um método interessante para a aplicação de sistemas multiagen-

tes ao mercado de ações brasileiro.

O modelo consiste numa população de milhares de agentes, cada um com sua própria regra de negociação, e um mercado virtual, construído como um mercado de leilão duplo em lote em que todas as ordens de compra e venda são coletadas e o preço de equilíbrio é definido como aquele em que o maior volume de negociações pode ser atingido. Este preço será a previsão de preço do modelo.

O modelo então é evoluído passo a passo enquanto alimentado com os preços do ativo e outras variáveis:

- Após cada preço recebido os agentes avaliam suas regras de negociação e colocam (ou não) ordens de compra, venda ou cash (fechamento de qualquer posição aberta) no mercado virtual, onde um preço em que as ordens são executadas é determinado;
- Agentes e suas regras de negociação evoluem através de programação genética adaptativa e aqueles com performance abaixo do exigido são substituídos por novos agentes com novos métodos de negociação criados pela recombinação e mutação das regras de negociação do agentes com as melhores performances; e
- A cada preço processado, o modelo gera uma previsão para a próxima cotação baseado no comportamento do mercado virtual.

O software foi desenhado para negociação de ações e índices de ações com grande volatilidade e bid-ask spreads (diferença entre o melhores preços de compra e venda) pequenos, porém outros tipos de ativos também podem ser usados, pois o Adaptive Modeler pode tratar qualquer tipo de série temporal e utiliza programação genética para adaptar o comportamento dos agentes de acordo com a experiência.

2.4.1 Programação genética fortemente tipada no Adaptive Modeler

Adaptive Modeler usa uma forma especial de PGFT em que os genomas (programas) são regras de negociação de agentes. O problema dos agentes no contexto da negociação de ativos é definir a estratégia de compras e vendas do ativo baseados em sua análise dos dados históricos, dessa maneira a função de aptidão é a medida do retorno sobre o investimento do agente num certo período, portanto os agentes que gerarem maiores aumentos de capital com relação ao início do período serão considerados melhores em comparação com os que tiverem variações de capital menores.

Levando em consideração as necessidades especiais do uso da programação genética na negociação de ativos financeiros, a implementação do Adaptive Modeler da PGFT possui as seguintes diferenças do uso convencional:

- No Adaptive Modeler a avaliação feita através da função de aptidão não envolve a aplicação repetida hipotética da sua regra de negociação nas informações históricas, isso porque os agentes já executaram suas regras de negociação nos preços históricos anteriormente e porque o interesse está nos retornos que os agentes já “concretizaram” na simulação do modelo de agentes-RI e não em retornos teóricos que o agente teria caso pudesse voltar no tempo.
- No uso convencional da PGFT, os programas são avaliados pela mesma função de aptidão em todas as gerações. Para os propósitos de negociação de ativos, uma função de aptidão dinâmica se faz necessária, pois, toda vez que a aptidão dos agentes é avaliada, o período de cálculo do retorno se move à frente para incluir as cotações mais recentes, que acabaram de ser adicionadas ao modelo. Além disso, o processo de criar novas gerações de agentes no Adaptive Modeler não tem critério de parada, já que não há um

nível de aptidão fixado que deve ser atingido. Enquanto novas informações continuarem sendo adicionadas ao modelo ele continuará evoluindo.

- Gerações inteiras não são substituídas, em vez disso é usada uma abordagem de curso estável em que apenas uma pequena parte da população é substituída a cada evolução no tempo. Isso permite uma mudança gradual na população que é necessária para manter uma certa estabilidade, evitando que agentes com potencial de se tornarem os melhores sejam substituídos prematuramente e que as sugestões de negociação sejam baseadas em estratégias pouco testadas.

Para caracterizar o domínio e utilizar a tipação forte os tipos definidos pelo Adaptive Modeler são descritos na tabela abaixo.

Tabela 1: Tipos - Adaptive Modeler

Descrição	Tipo
Combinação de um Position e um Limit	Advice
Valor da posição em porcentagem da riqueza	Position
Preço limite da ordem	Limit
Direção da posição (comprado, vendido ou mercado)	Direction
Valor absoluto da posição como porcentagem da riqueza	Leverage
Preço do ativo no mercado (real ou virtual)	Quote
Volume negociado	Volume
Mercado real ou virtual	Market
Diferença entre dois valores, em porcentagem	Change
Número de cotações	Lag
Booleano (verdadeiro ou falso)	Bool
Valor de uma variável de entrada personalizada	Custom
Dígito numérico	Digit

As relações entre os genes (funções e terminais) e seus tipos de retorno e de argumentos são descritas no Apêndice A. Terminais, que não têm argumentos, têm nomes começando com letra maiúscula e são listados em cima, as funções são listadas abaixo dos terminais e podem ser definidas mais de uma vez, para diferentes tipos de argumentos.

2.4.2 O modelo baseado em agentes-RI do Adaptive Modeler

O modelo baseado em agentes-RI consiste primariamente numa população de agentes e um mercado virtual onde os agentes podem negociar ativos, estes agentes representam investidores com seus próprios patrimônios (dinheiro ou cotas dos ativos) e suas próprias estratégias.

Depois que uma nova cotação é recebida, agentes podem colocar ordens ou permanecer inativos, de acordo com suas estratégias. Depois que todos os agentes avaliaram suas estratégias de negociação, o mercado executa todas as ordens executáveis de acordo com o preço de equilíbrio do mercado e gera a previsão para o próximo preço. Finalmente, o processo de criação e substituição de agentes, através da PG, é iniciado. Todo este processo se repete para a próxima cotação.

3 EXPERIMENTO

3.1 Dados

O experimento para utilização de sistemas multiagentes no mercado acionário brasileiro foi conduzido com o software Altrevia Adaptive Modeler, cuja adequação foi discutida anteriormente na Seção 2.4, e diversas opções foram consideradas para compor os dados analisados, desde derivativos até fundos imobiliários, entretanto, fez-se a opção de utilizar os dados de ações.

Essa opção foi feita tendo em vista a necessidade de liquidez e de que, dada a utilização de um método de aprendizagem de máquina, o ativo tivesse grande quantidade de dados disponíveis. Além disso fez-se a escolha pelo mercado mais maduro e consistente levando a uma maior representatividade dos experimentos e a facilidade em divulgar o método versando sobre um mercado mais conhecido.

Escolhidos o mercado e a metodologia, resta escolher quais ativos específicos serão discutidos e, para isso, analisou-se os ativos mais líquidos, que tiveram volatilidade expressiva e que, de alguma forma, servem como referência para o mercado acionário brasileiro.

As duas empresas das quais as ações preferenciais serão utilizadas neste trabalho são Petrobrás e Vale que, historicamente, são as duas com maior liquidez no mercado acionário brasileiro e altamente representativas em diversos índices de mercado (como o Ibovespa, o IBrX 50 e o IBrx 100). A não escolha dos pró-

prios índices se baseou no fato de que a comparação com outros trabalhos sobre o mesmo assunto mas que usam a abordagem fundamentalista, que utiliza os dados financeiros da empresa, será facilitada ao contrário do caso dos índices que são compostos por diversas empresas.

3.1.1 Descrição dos dados

As cotações das ações preferenciais de Petrobrás (PETR4) e Vale (VALE5) foram obtidas da base de dados do Yahoo Finanças (<https://br.financas.yahoo.com/>), que disponibiliza as cotações diárias de abertura, máxima, mínima, de fechamento e de fechamento ajustadas que já computam os impactos dos dividendos, desdobramentos e agrupamentos ocorridos ao longo do tempo. Os experimentos deste trabalho foram conduzidos com todas as cotações corrigidas por proventos.

A fim de alimentar o modelo com o maior número de dados para viabilizar um nível maior de aprendizagem ao chegar às datas mais atuais, foram coletados os dados diários desde a data mais antiga para cada ação disponível no Yahoo Finanças, 03/01/2000 para PETR4 e 01/01/2003 para VALE5.

3.2 Configuração do modelo

A fim de iniciar a utilização do Altrevia Adaptive Modeler é necessária a configuração do modelo multiagentes, o que inclui a quantidade de agentes do sistema, custo de corretagem, método de previsão (preço do mercado virtual ou dos melhores agentes), semente para geração dos parâmetros aleatórios que foram configurados como mostrado na Figura 1.

A inicialização dos agentes envolve a definição de suas riquezas (patrimônio inicial) que pode ser feita igualmente para todos ou seguindo a distribuição de

Pareto ou de Maxwell-Boltzmann e da posição dos agentes no ativo em questão. Estes parâmetros foram definidos como mostrado na Figura 2.

Figura 1: Inicialização do modelo

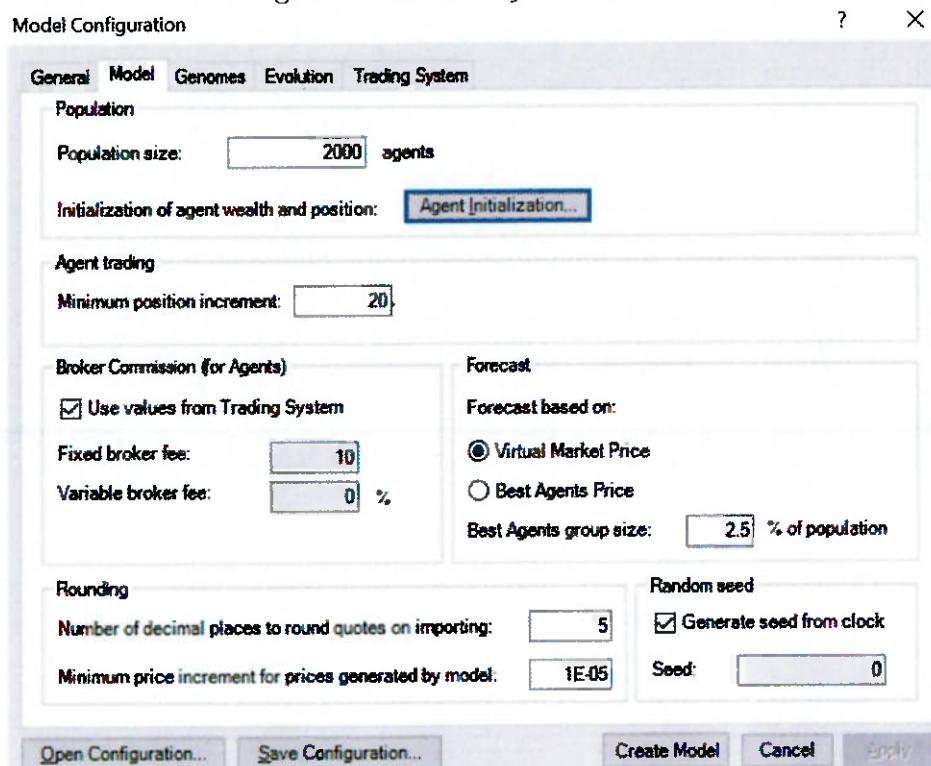
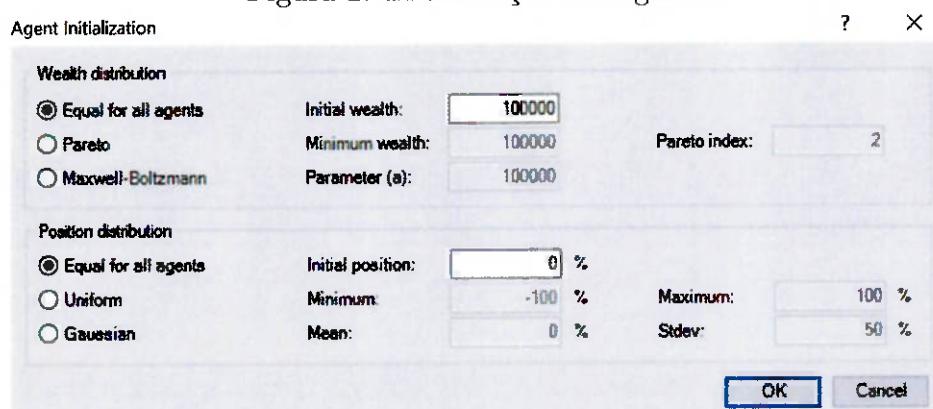


Figura 2: Inicialização dos agentes



Outras configurações, como tamanho dos genomas ou as funções que geram estes genomas podem ser redefinidas, porém foram mantidas como o padrão proposto pelo software para simplificar o experimento e facilitar sua replicação.

3.3 Informações relevantes do experimento

Após a definição das configurações iniciais do sistema precisa-se definir quais parâmetros acompanhar. É possível acompanhar parâmetros do modelo (como a distribuição da riqueza e das posições), informações individuais dos agentes, comportamento da população (como qual a relação entre a “idade” e a riqueza dos agentes), fluxo de criação de agentes (como a quantidade de agentes criados a cada iteração do modelo) e informações sobre as previsões (como a comparação entre preços reais e previsões e marcação de previsões certas e erradas).

Os principais parâmetros para o estudo em questão são:

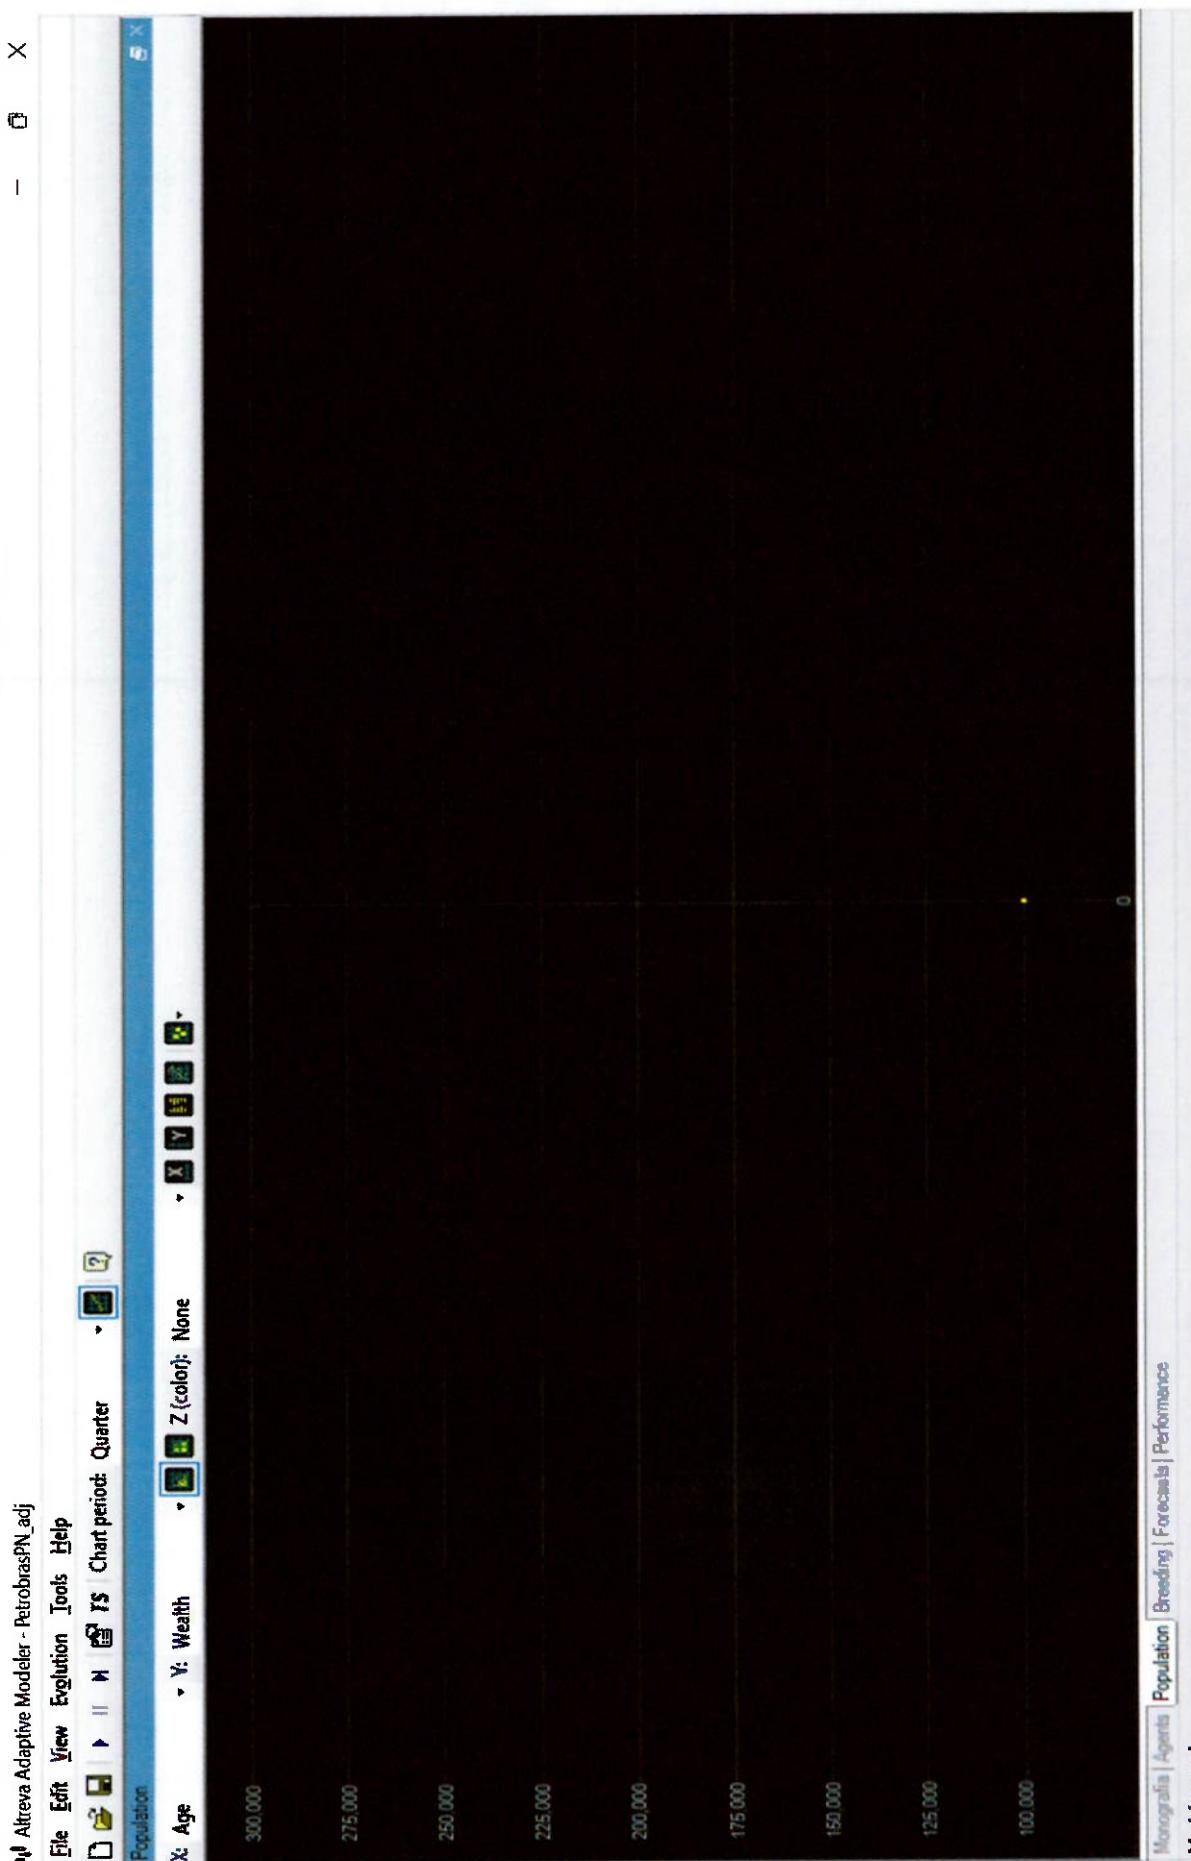
- Distribuição de riqueza da população.
- Distribuição das posições.
- Criação de novos agentes.
- Erro médio quadrático das previsões.
- Relação entre “idade” e riqueza da população.

Esses parâmetros foram definidos para observação, pois evidenciam a influência dos agentes de melhor performance no resultado financeiro e dão visibilidade ao processo de renovação dos agentes; seus valores iniciais são mostrados nas Figuras 3 e 4. Ao final, as análises serão concentradas nas acurácia das previsões do modelo para as duas ações escolhidas.

Figura 3: Valores iniciais dos parâmetros a serem acompanhados no experimento



Figura 4: Relação entre “idade” e riqueza da população



3.4 Evolução do modelo

Buscando a clareza do modelo utilizado a evolução será feita com descrições em pontos em que evidências da mecânica de sistemas multiagentes possam ser extraídas e expostas através dos parâmetros escolhidos para acompanhamento. Essa evolução será feita apenas para a ação PETR4, pois o modelo usado para a VALE5 é exatamente o mesmo.

Evoluindo o modelo até o dia 08/02/2001, depois do modelo ter passado por um período de aprendizagem de 289 dias, o sistema se apresenta com a maior parte dos agentes com riqueza perto do valor inicial de 100.000,00, uma leve predominância de posições vendidas, número de criações de novos agentes com grande amplitude, erro médio caindo rapidamente, conforme a Figura 5, e a relação entre idade e riqueza começa a evidenciar a premiação da PG a agentes com as melhores performances, conforme Figura 6.

Figura 5: Evolução depois de 289 dias - Parâmetros

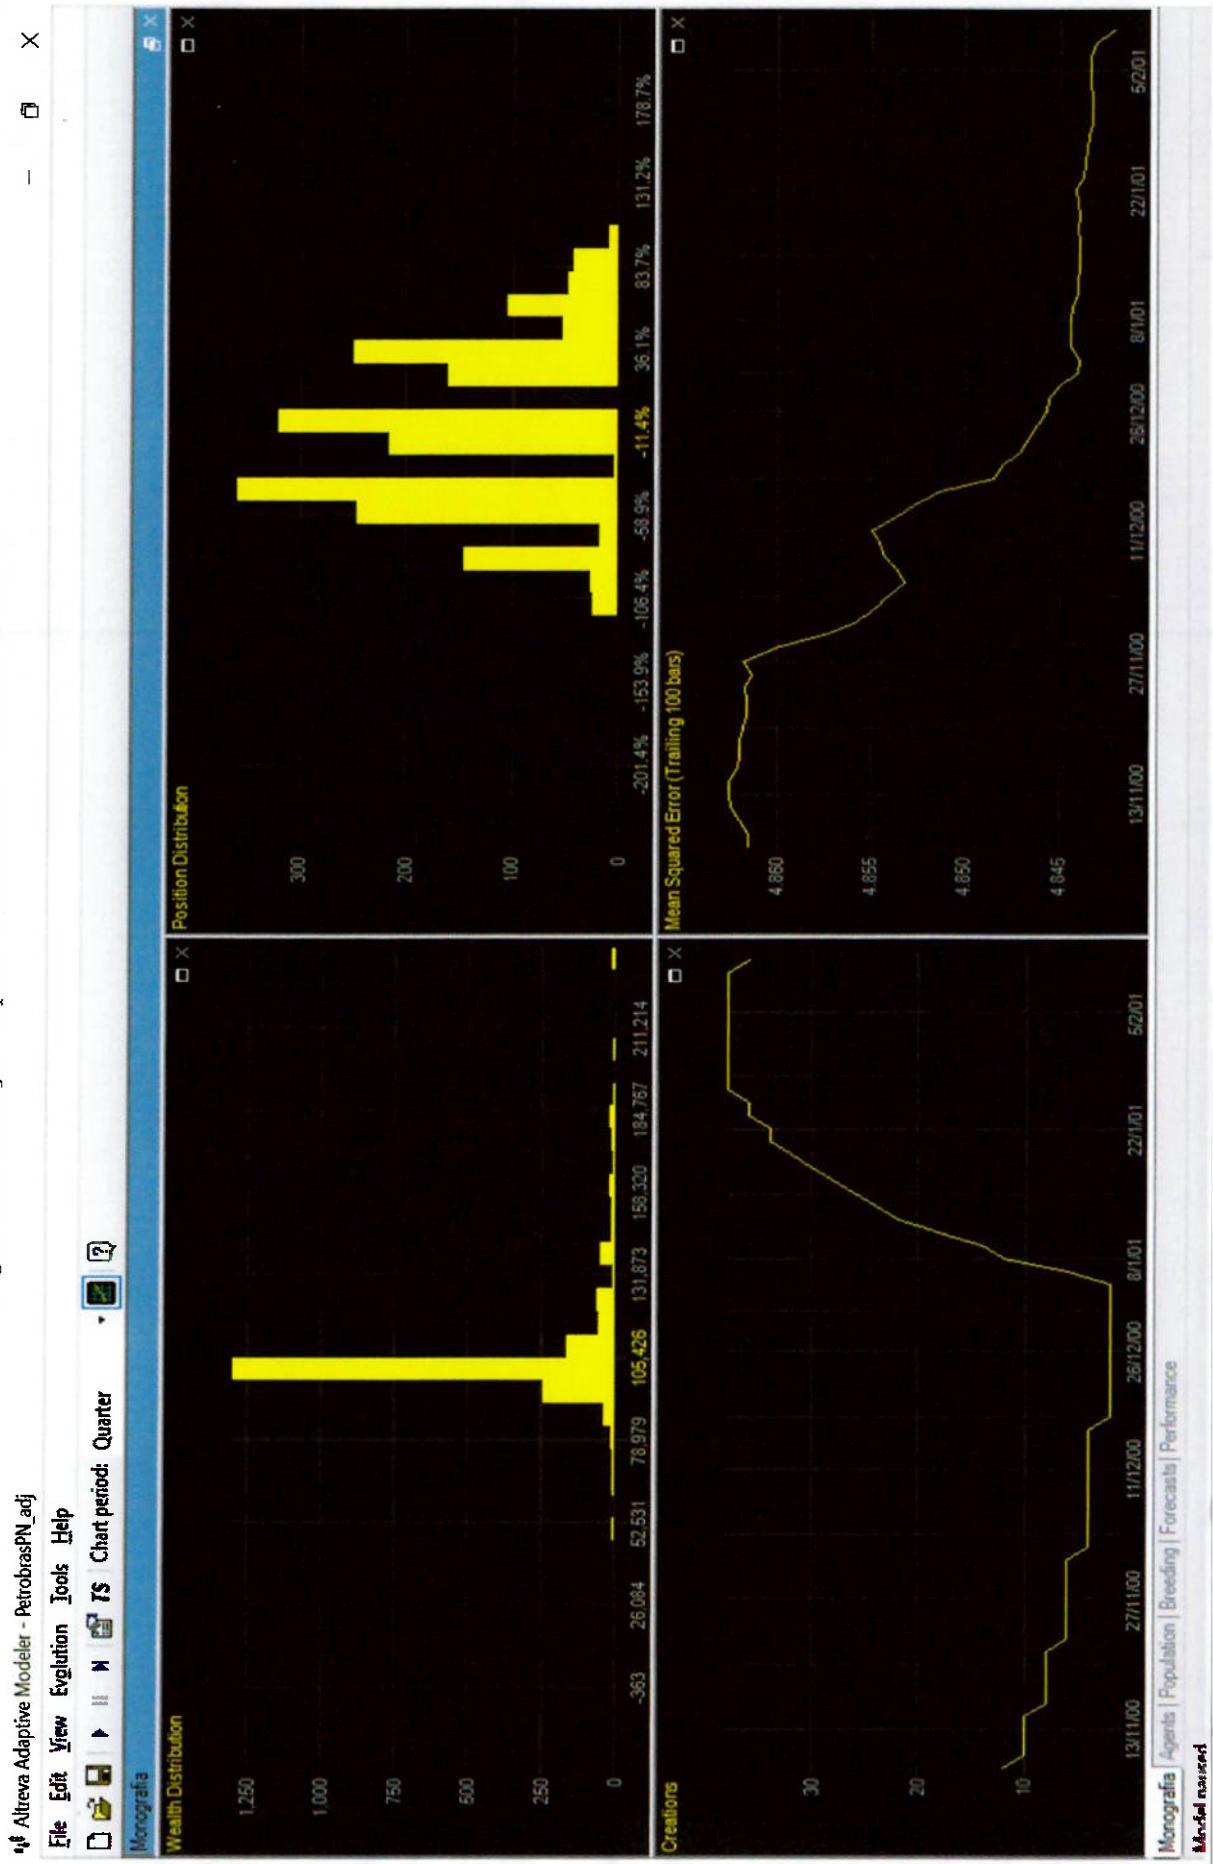
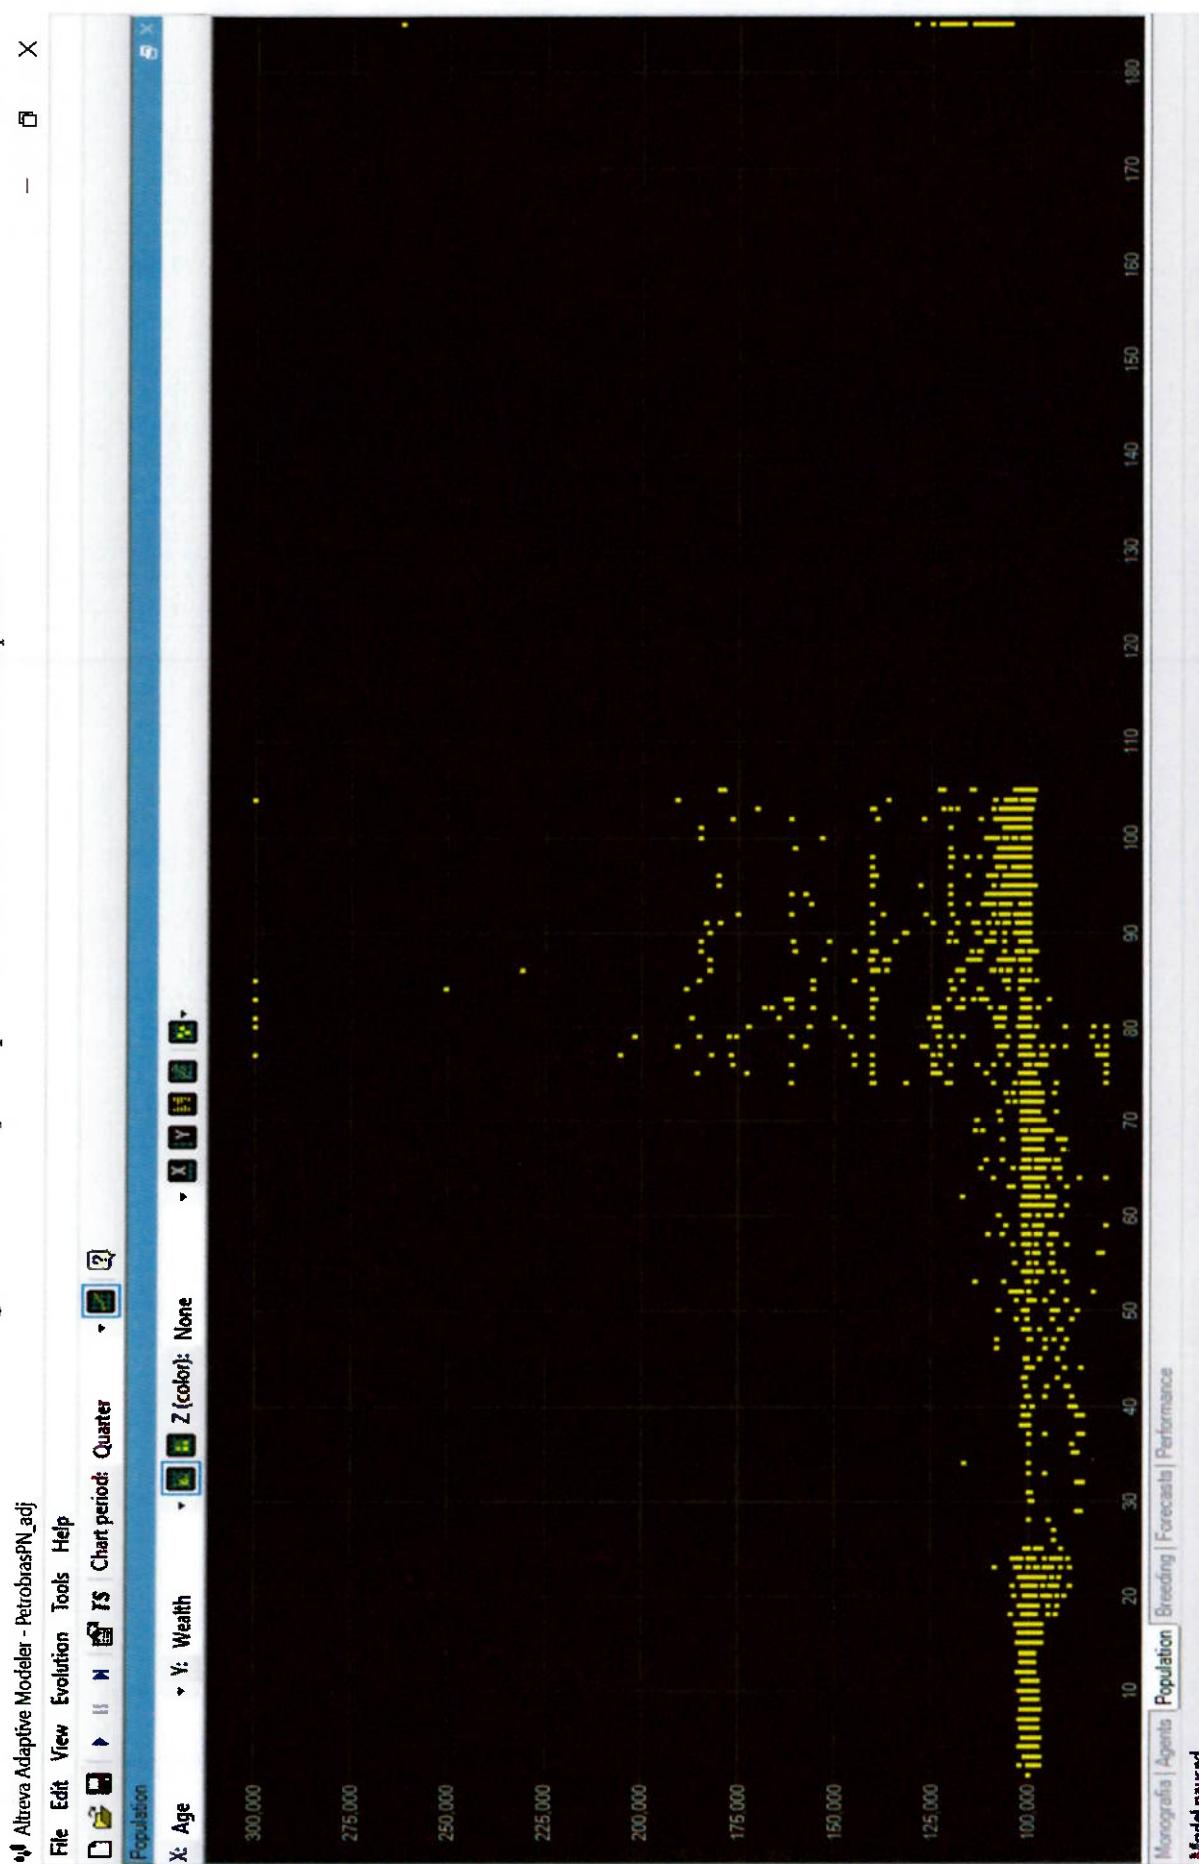


Figura 6: Evolução depois de 289 dias - Idade x Riqueza.



Após 622 dias de evolução, o modelo mostra leve melhora do ponto de vista da riqueza dos agentes que se concentraram na média dos 107.000,00, a distribuição da posição passou a ser predominantemente comprada e o erro médio das previsões teve uma queda significativa após o pico de criação de agentes, evidenciando a eficácia do processo de aprendizagem. Além disso, a relação entre “idade” e riqueza dos agentes passa por um momento de agrupamento de gerações, caracterizando um padrão emergente interessante, de que agentes da mesma geração que sobrevivem pelo mesmo tempo tendem a ter um nível de riqueza parecido.

Figura 7: Evolução depois de 622 dias - Parâmetros

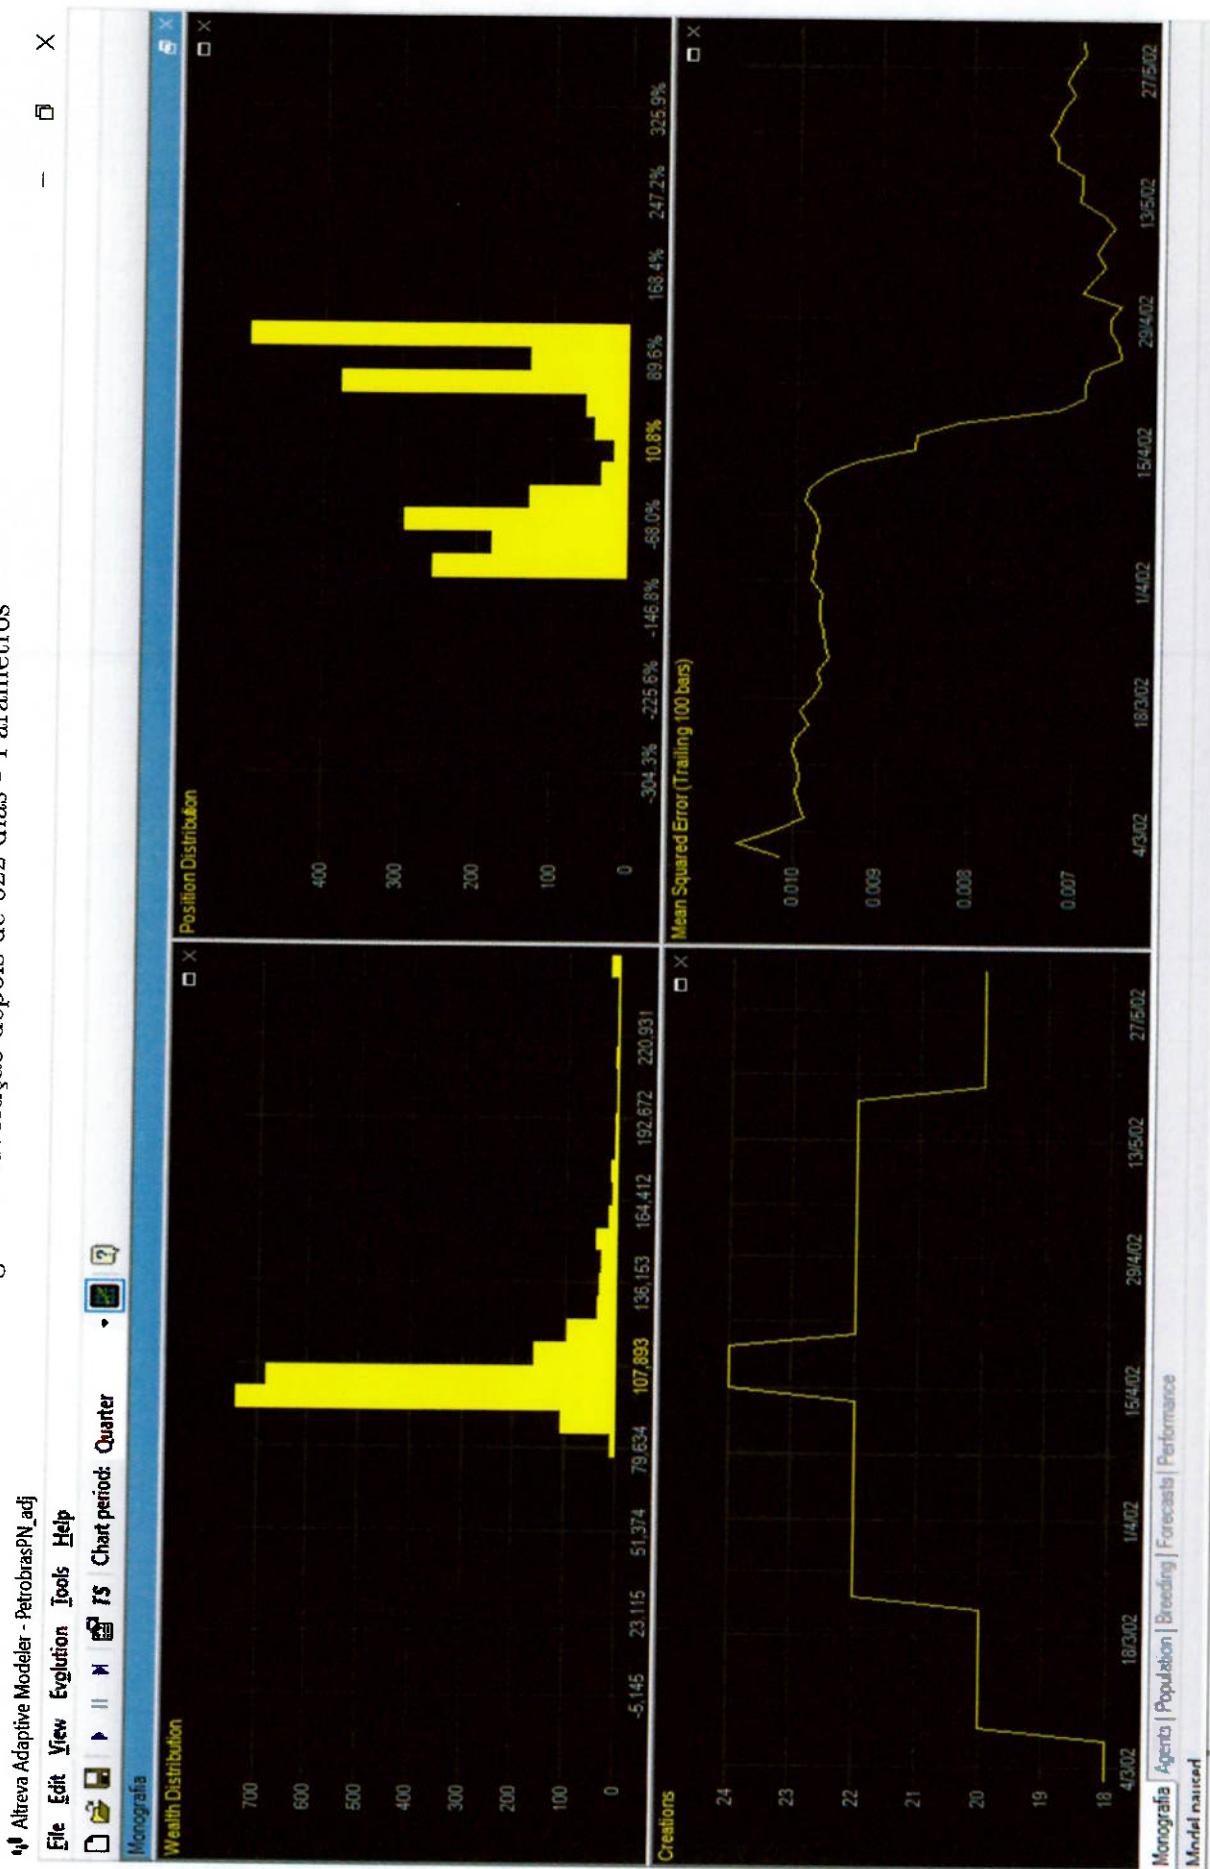
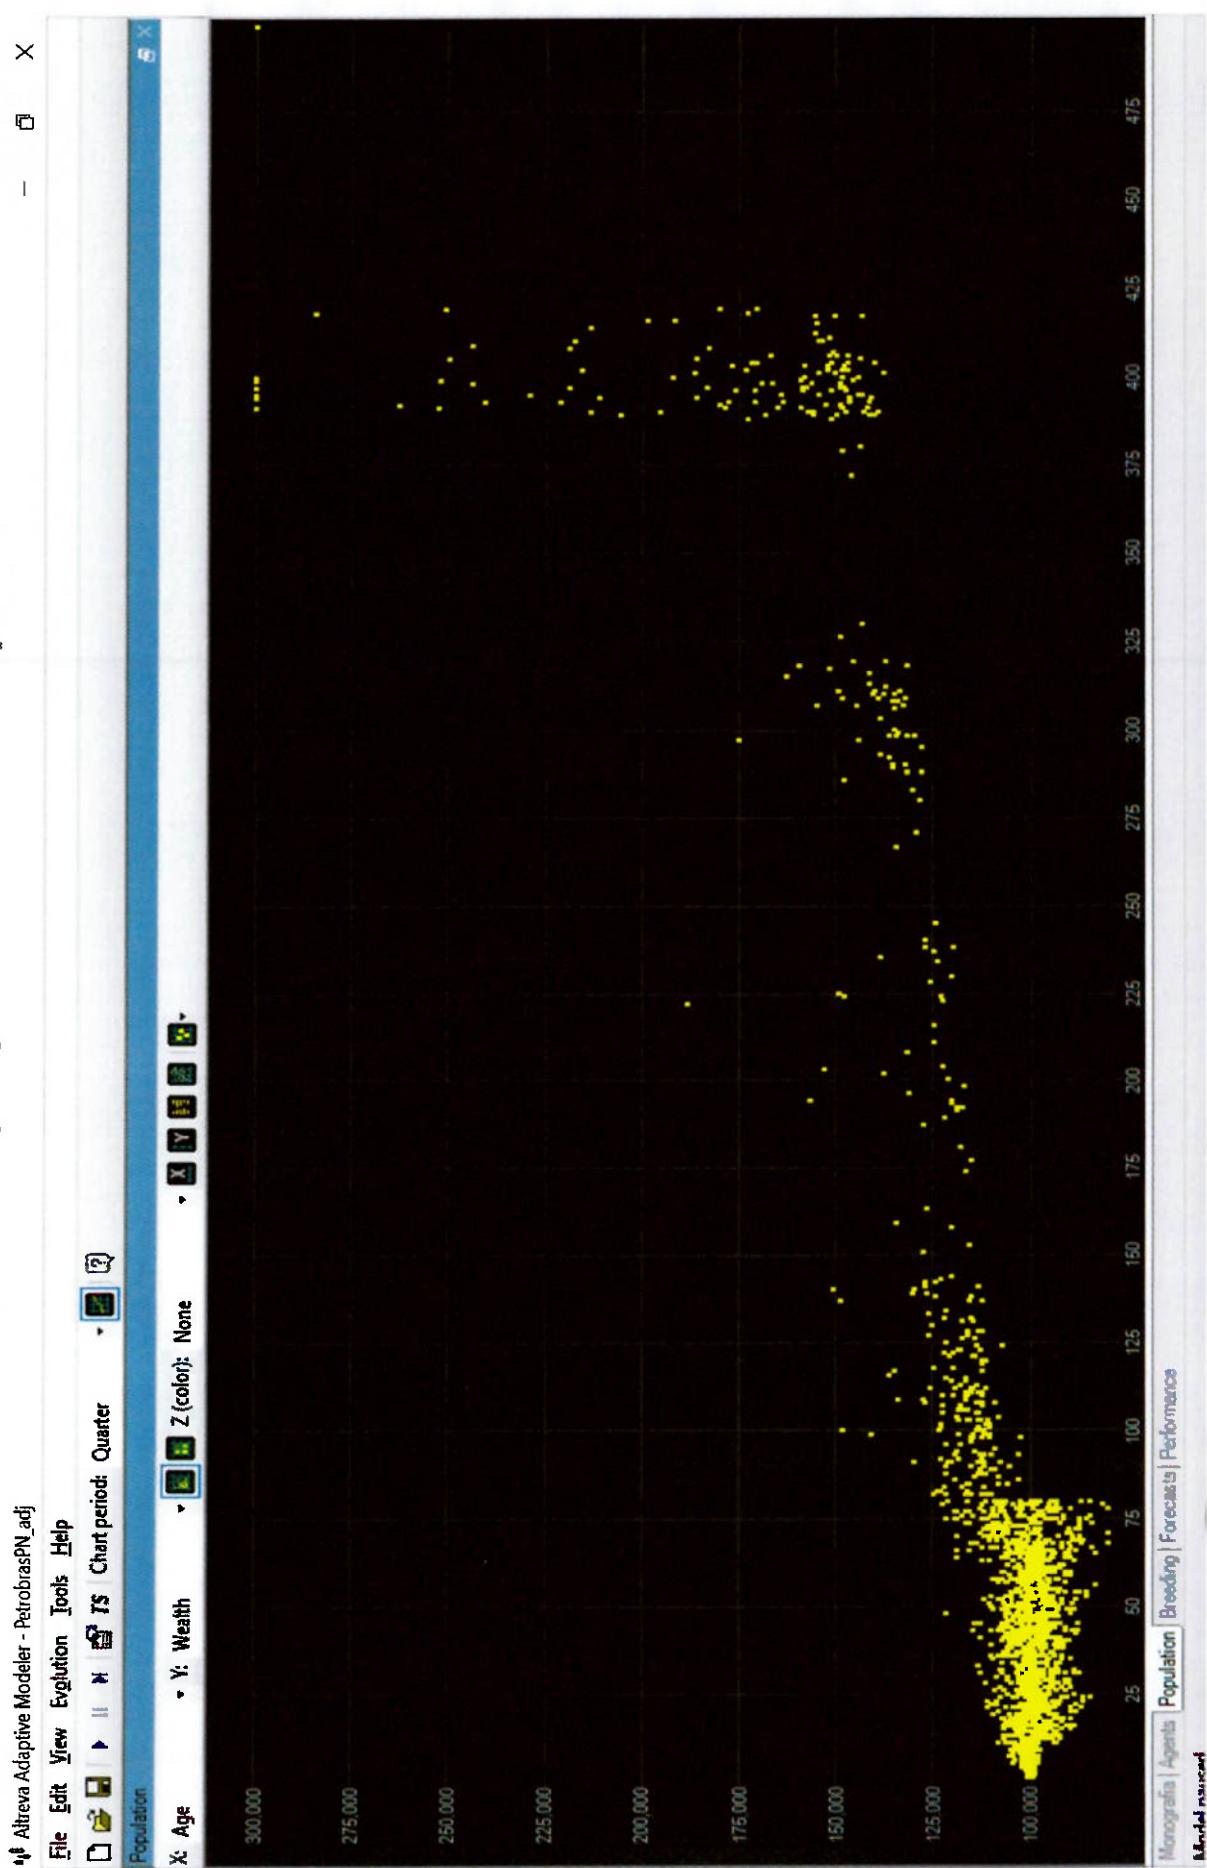


Figura 8: Evolução depois de 622 dias - Idade x Riqueza



Evoluindo até o fim do ano de 2015, a distribuição de riqueza se aproximou da média de 141.000,00, porém a distribuição das posições evoluiu para uma bilateralidade do sistema, com praticamente o mesmo número de posições muito compradas e muito vendidas. O número de agentes criados convergiu para 10% da população e o erro médio se manteve na grandeza de 10^{-1} . Além disso, os novos agentes passam a aprender mais rápido e alcançar maiores riquezas em menos tempo, evidência do real aprendizado do sistema.

Figura 9: Evolução ao fim de 2015 - Parâmetros

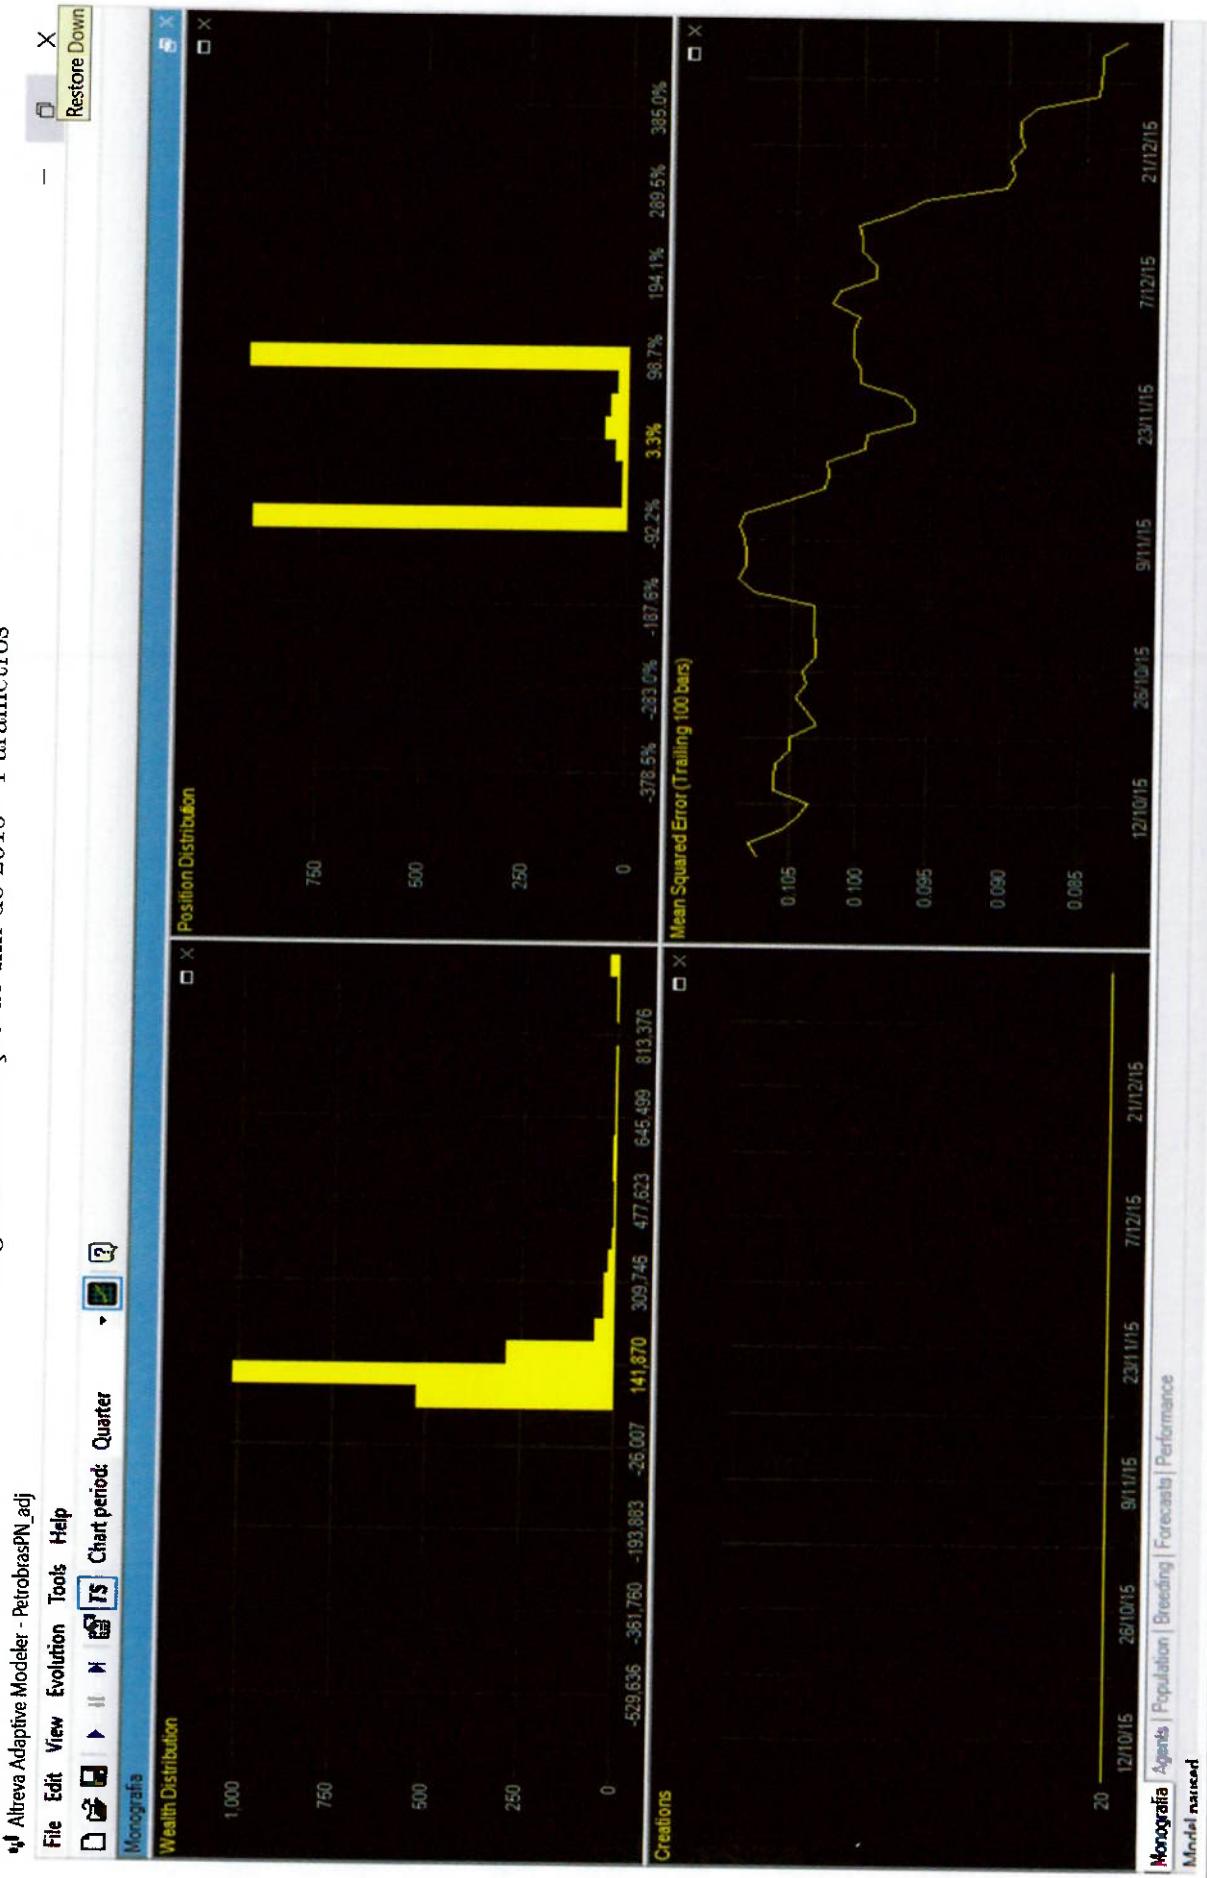
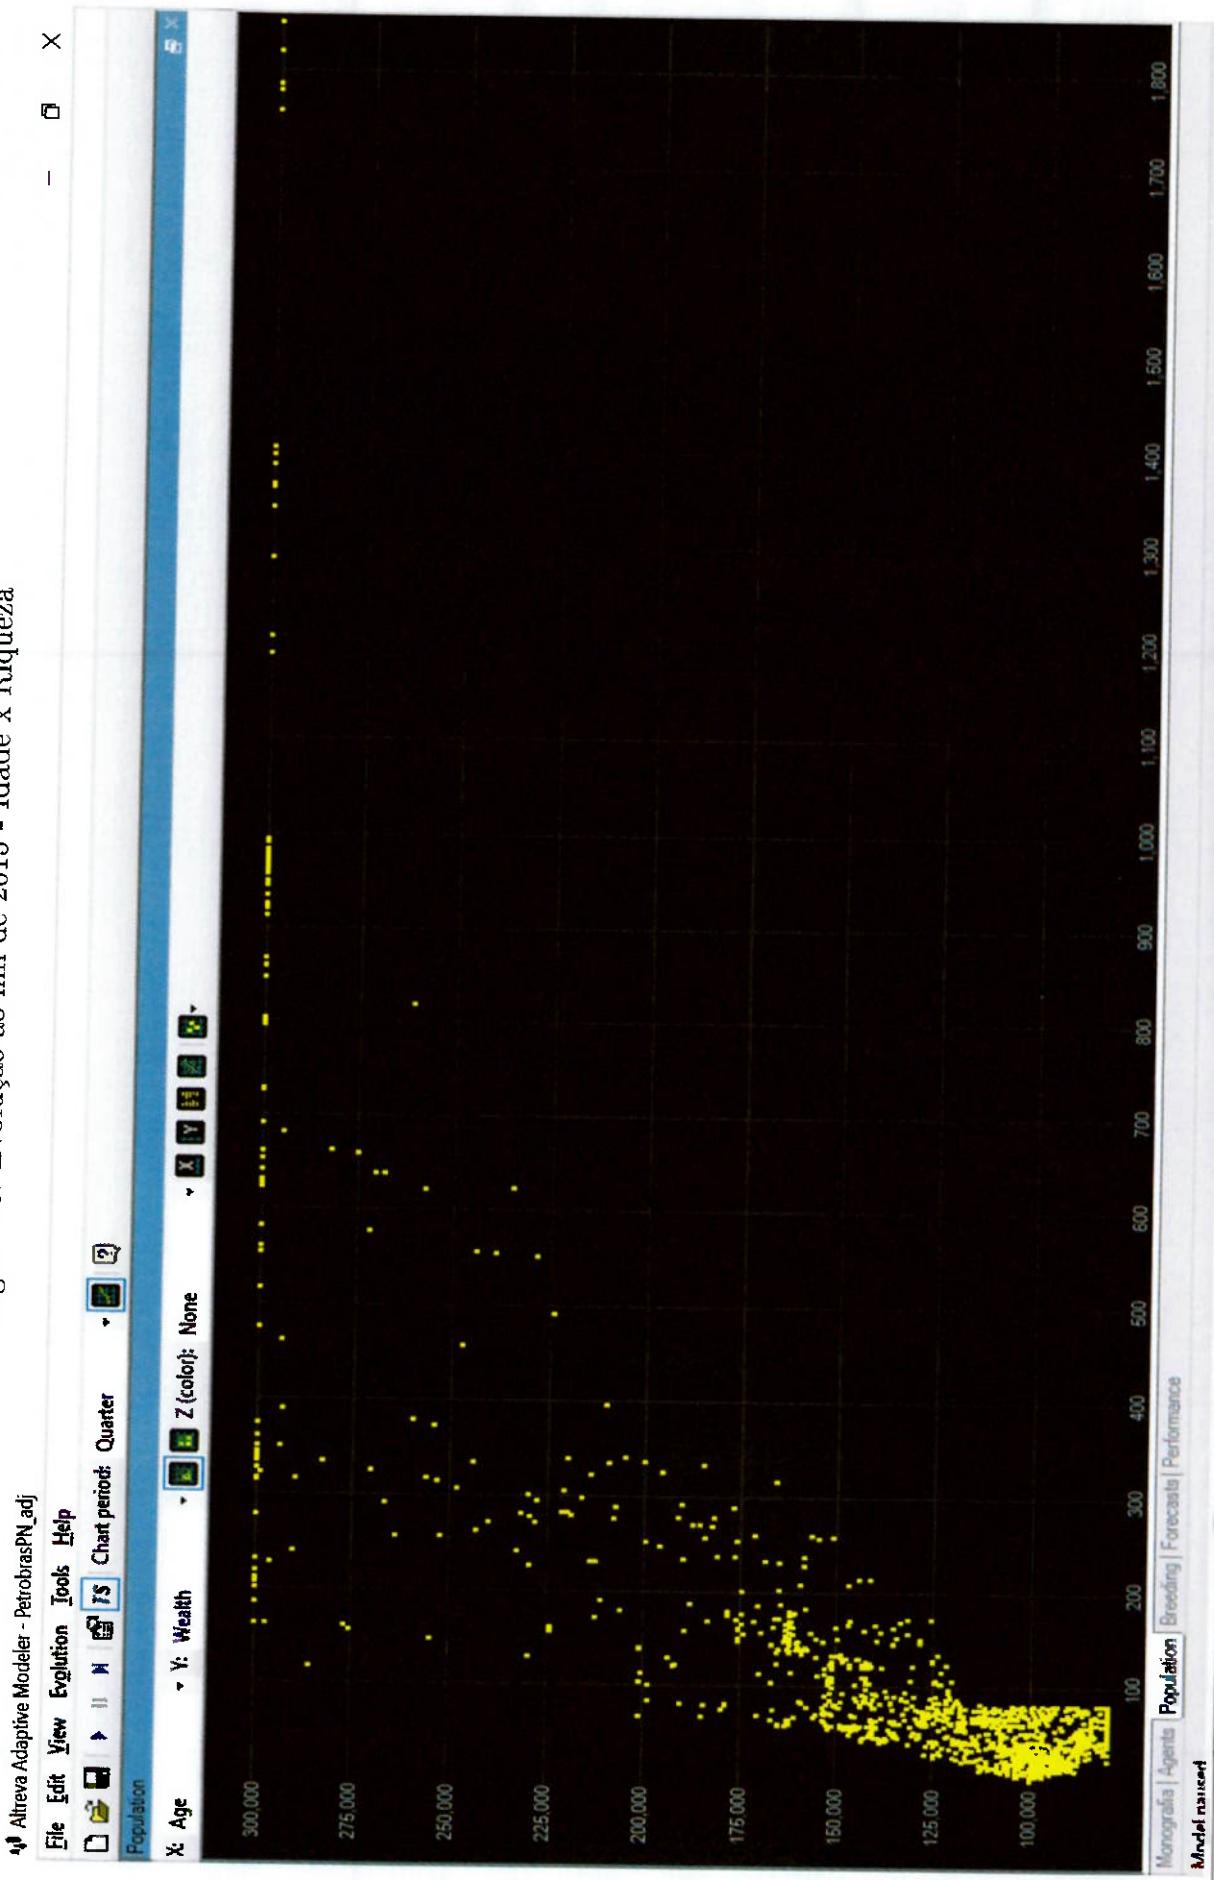


Figura 10: Evolução ao fim de 2015 - Idade x Riqueza.



A evolução do modelo pode ser estudada a partir de outras visões (como a comparação da composição dos genomas ou da duração das negociações com a riqueza dos agentes) ou com diferentes parâmetros do modelo (utilizando as sugestões de preços dos melhores agentes, por exemplo). No Capítulo 4 serão comentadas as saídas do Adaptive Modeler para as duas ações utilizadas e discutido se existe a eficácia do modelo, utilizando o software, para aplicação no mercado acionário brasileiro.

4 RESULTADOS

4.1 Métodos de análise

A fim de estruturar a análise final dos resultados obtidos neste trabalho foram usadas duas perspectivas. Uma é a de analisar como as sugestões de negociação (short, long ou cash) se sairiam se fossem utilizadas para negociar os ativos no mercado real e a outra é testar se o modelo consegue prever as direções do mercado com base no aprendizado com os dados diários.

4.1.1 Utilização das sugestões de negociação no mercado real

A versão utilizada do Adaptive Modeler permite a exportação de 500 períodos e destes foram extraídos apenas os referentes ao ano de 2016 para serem analisados como se as sugestões do modelo fossem de fato usados em negociações reais.

A simulação começa no dia 04/01/2016 e vai até o dia 23/11/2016 com o patrimônio de 100.000,00 e sua evolução pode ser vista nas Figuras 11 e 12.

O gráfico da Petrobrás mostra que o uso do modelo, através do Adaptive Modeler, levaria a uma redução de 30% do patrimônio e para a Vale a redução seria de 18%. É interessante notar que, para a Petrobrás, o patrimônio não superou os 100.000,00 iniciais e, por outro lado, no caso da Vale o modelo chegou a atingir um retorno de 43% ao atingir o valor de 142.990,47.

Essa diferença evidencia um período de alto entendimento do modelo em

Figura 11: Evolução do patrimônio - Petrobrás



Figura 12: Evolução do patrimônio - Vale



relação ao comportamento da ação da Vale no começo do ano de 2016, o que não ocorre com a Petrobrás que tem alguns períodos de retorno positivo mas sem mostrar consistência.

4.1.2 Utilização na previsão da direção das variações

Dada a dificuldade em prever as cotações ou os retornos das ações, uma técnica importante utilizada é a de prever a direção do mercado, isto é, prever se os retornos serão positivos ou negativos num certo período. Em caso de sucesso é possível compor estratégias de arbitragem.

A comparação gráfica entre preços reais e previsões de 2016, Figuras 13 e 14, dá esperança de capacidade preditiva do modelo, entretanto os resultados em quantidade de acertos e erros, nas Tabelas 2 e 3, nos mostram o contrário.

Figura 13: Preços reais x Preços previstos - Petrobrás

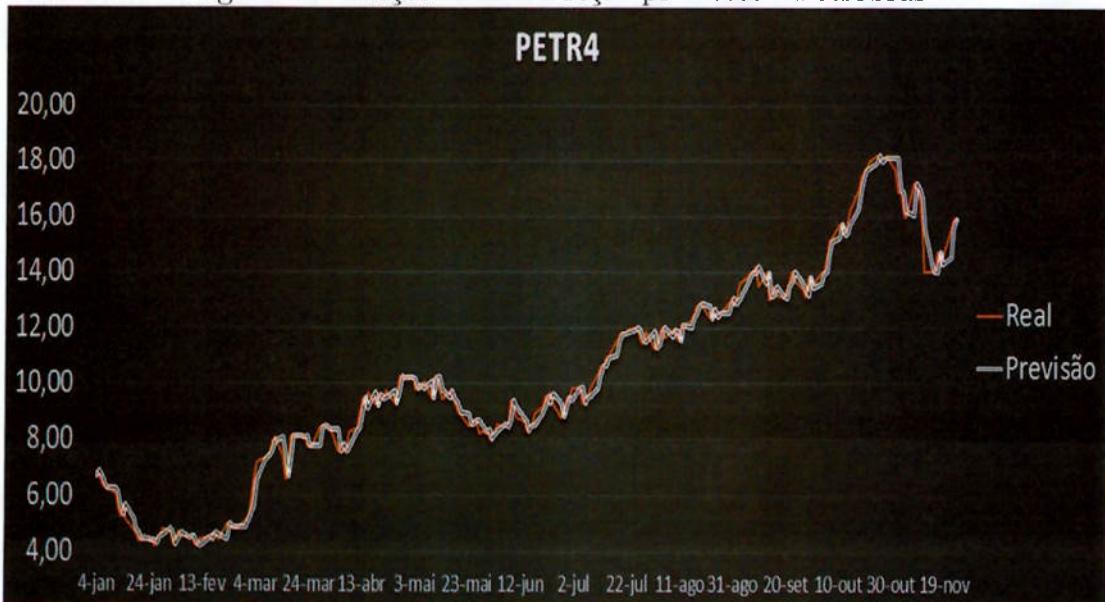


Tabela 2: Diagnóstico Petrobrás - Previsões de direção do mercado

Período	2015 a 2016	2015	2016
Acertos	33% (161)	26% (59)	40% (102)
Erros	67% (325)	74% (171)	60% (154)

Figura 14: Preços reais x Preços previstos - Vale



Tabela 3: Diagnóstico Vale - Previsões de direção do mercado

Período	2015 a 2016	2015	2016
Acertos	36% (175)	35% (89)	37% (86)
Erros	64% (314)	65% (167)	63% (147)

5 CONCLUSÕES E TRABALHOS FUTUROS

Neste trabalho foi feito um estudo sobre a aplicação de sistemas multiagentes para a previsão dos preços do mercado acionário brasileiro. A fim de embasar a aplicação foi realizada uma revisão nas definições de sistemas multiagentes, e seus campos de aplicação, e do método de aprendizagem computacional chamado programação genética. Para a implementação do experimento buscou-se um software que combinasse sistemas multiagentes e PG para a previsão de preços de ações (neste caso PETR4 e VALE5) e o Altrevia Adaptive Modeler foi utilizado.

O modelo não apresentou bons resultados ao ter suas sugestões de negociação aplicadas ao mercado acionário brasileiro, gerando redução do patrimônio nos dois casos estudados tampouco foi capaz de prever as direções do mercado, tendo menos de 40% de acerto. Contudo é importante ter em mente a dificuldade de previsão intrínseca do mercado acionário e, em especial, neste período do mercado brasileiro que teve fatores externos ao mercado tendo papel determinante nas variações de preço, como investigações sobre corrupção em construtoras e estatais e a turbulência política.

Outro fator importante é que o modelo foi alimentado apenas com dados diários (corrigidos por proventos) de abertura, máxima, mínima e fechamento, o que limita a capacidade em aprender o que acontece no mercado real e os impactos dos diversos fatores externos.

Dessa forma, trabalhos futuros podem tratar a inclusão de indicadores ex-

ternos como entradas para o modelo, testar a capacidade em prever índices de ações, derivativos e fundos imobiliários, fazer experimentos com dados “intraday” e testar o Adaptive Modeler com diferentes configurações.

REFERÊNCIAS

- AZEVEDO, S. et al. Multi-Agent System for Stock Exchange Simulation-MASSES. 2008.
- BLACK, F.; SCHOLES, M. The pricing of options and corporate liabilities. *The Journal of Political Economy*, 3, 637-654, 1965.
- DIBA, B.; GROSSMAN, H. The theory of rational bubbles in stock prices. *The Economic Journal*, 98, 1988.
- GROSSMAN, S.; STIGLITZ, J. On the impossibility of informationally efficient markets. *American Economic Review*, 70, 393-408, 1980.
- KOZA, J. *Genetic Programming: On the Programming of Computers by Means of Natural Selection*. [S.l.]: MIT Press, 1992.
- LEBARON, B. Asset pricing under endogenous expectations in artificial stock market. *Economic Notes*, 26, 1996.
- LEROUY, S. Efficient capital markets and martingales. *Journal of Economic Literature*, 27, 1583-1621, 1989.
- LUCAS, R. Asset prices in an exchange economy. *Econometrica*, 46, 1429-1446, 1978.
- MARKOWITZ, H. *Portfolio Selection: Efficient Diversification of Investments*. [S.l.]: John Wiley and Sons, 1959.
- PEREIRA, L.; RIBEIRO, C.; SECURATO, J. Agricultural commodities pricing model applied to the brazilian sugar market. *The Australian Journal of Agricultural and Resource Economics*, 56, 542â557, 2012.
- SAMUELSON, P. Proof that properly anticipated prices fluctuate randomly. *Industrial Management Review*, 6, 41-49, 1965.
- SHARPE, W. Capital asset prices: A theory of market equilibrium under conditions of risk. *The Journal of Finance*, 1964.
- SHOHAM, Y.; LEYTON-BROWN, K. *Multiagent Systems*. [S.l.]: Cambridge, 2010.

APÊNDICE A

Tabela 4: Relação entre funções (gene), tipos de argumentos e de retornos

Gene	Tipo de Retorno	Arg1 tipo	Arg2 tipo	Arg3 tipo	Arg4 tipo
CurPos	Position				
LevUnit	Leverage				
FullLev	Leverage				
Rmarket	Market				
Vmarket	Market				
Long	Direction				
Short	Direction				
Cash	Direction				
Bar	Lag				
InvPos	Position				
RndPos	Position				
RndLim	Limit				
MktOrder	Limit				
IsMon	Bool				
IsTue	Bool				
IsWed	Bool				
IsThu	Bool				
IsFri	Bool				
Digit0	Digit				

Tabela 4: Relação entre funções (gene), tipos de argumentos e de retornos (continuação)

Gene	Tipo de Retorno	Arg1 tipo	Arg2 tipo	Arg3 tipo	Arg4 tipo
Digit1	Digit				
Digit2	Digit				
Digit3	Digit				
Digit4	Digit				
Digit5	Digit				
Digit6	Digit				
Digit7	Digit				
Digit8	Digit				
Digit9	Digit				
open	Quote	Lag	Market		
high	Quote	Lag	Market		
low	Quote	Lag	Market		
close	Quote	Lag	Market		
bid	Quote	Lag	Market		
ask	Quote	Lag	Market		
average	Quote	Lag	Market		
min	Quote	Lag	Market		
max	Quote	Lag	Market		
volume	Volume	Lag	Market		
avgvol	Volume	Lag	Market		
minvol	Volume	Lag	Market		
maxvol	Volume	Lag	Market		
custom	Custom	Lag	Digit	Digit	

Tabela 4: Relação entre funções (gene), tipos de argumentos e de retornos (continuação)

Gene	Tipo de Retorno	Arg1 tipo	Arg2 tipo	Arg3 tipo	Arg4 tipo
avgcustom	Custom	Lag	Digit	Digit	
mincustom	Custom	Lag	Digit	Digit	
maxcustom	Custom	Lag	Digit	Digit	
>	Bool	Quote	Quote		
>	Bool	Volume	Volume		
>	Bool	Custom	Custom		
>	Bool	Change	Change		
spread	Change	Market			
barrange	Change	Lag			
change	Change	Quote	Quote		
change	Change	Volume	Volume		
change	Change	Custom	Custom		
+	Lag	Lag	Lag		
+	Leverage	Leverage	Leverage		
*	Change	Change	Lag	Direction	
dir	Bool	Lag	Market		
isupbar	Bool	Lag	Market		
upbars	Bool	Lag	Lag	Market	
bsmin	Lag	Lag	Market		
bsmax	Lag	Lag	Market		
volat	Change	Lag	Market		
rsi \geq 80	Bool	Lag	Market		
rsi \leq 20	Bool	Lag	Market		

Tabela 4: Relação entre funções (gene), tipos de argumentos e de retornos (continuação)

Gene	Tipo de Retorno	Arg1 tipo	Arg2 tipo	Arg3 tipo	Arg4 tipo
sk>sd	Bool	Lag	Market		
sd<sd	Bool	Lag	Market		
ema	Quote	Lag	Market		
mfi>=80	Bool	Lag	Market		
mfi<=20	Bool	Lag	Market		
pos	Position	Direction	Leverage		
addpos	Position	Direction	Leverage		
lim	Limit	Quote	Quote	Lag	Direction
mrlim	Limit	Market	Lag		
tflim	Limit	Market	Lag		
advice	Advice	Position	Limit		
and	Bool	Bool	Bool		
or	Bool	Bool	Bool		
not	Bool	Bool			
if	Quote	Bool	Quote	Quote	
if	Lag	Bool	Lag	Lag	
if	Change	Bool	Change	Change	
if	Bool	Bool	Bool	Bool	
if	Advice	Bool	Advice	Advice	
if	Market	Bool	Market	Market	
if	Direction	Bool	Direction	Direction	
if	Limit	Bool	Limit	Limit	
if	Leverage	Bool	Leverage	Leverage	

Tabela 4: Relação entre funções (gene), tipos de argumentos e de retornos (continuação)

Gene	Tipo de Retorno	Arg1 tipo	Arg2 tipo	Arg3 tipo	Arg4 tipo
if	Position	Bool	Position	Position	
if	Volume	Bool	Volume	Volume	
if	Custom	Bool	Custom	Custom	