

**UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO TECNOLÓGICO
DEPARTAMENTO DE ENGENHARIA DE PRODUÇÃO**

AGNELLO HUPP

**AVALIAÇÃO DA PERFORMANCE DE UM MODELO DE
REDE NEURAS ARTIFICIAIS NO MERCADO DE
CÂMBIO**

**VITÓRIA
2014**

AGNELLO HUPP

**AVALIAÇÃO DA PERFORMANCE DE UM MODELO DE
REDE NEURAIS ARTIFICIAIS NO MERCADO DE
CÂMBIO**

Projeto de Pesquisa do Trabalho de Conclusão de Curso em Engenharia de Produção Plena apresentado à Universidade Federal do Espírito Santo, sob a orientação do Prof. Dr. Marta Monteiro da Costa Cruz.

**VITÓRIA
2014**

AGNELLO HUPP

**AVALIAÇÃO DA PERFORMANCE DE UM MODELO DE
REDE NEURAIAS ARTIFICIAIS NO MERCADO DE
CÂMBIO**

Projeto de Pesquisa do Trabalho de Conclusão de Curso em Engenharia de
Produção Plena apresentado à Universidade Federal do Espírito Santo

Aprovada em ____ de _____ de 2014.

COMISSÃO EXAMINADORA

Prof. Dr. Marta Monteiro da Costa Cruz
Universidade Federal do Espírito Santo
Orientador

Rodrigo Silva Cosme

Prof. Dr.
Universidade Federal do Espírito Santo

DEDICATÓRIA

Dedico esse projeto a meus pais, familiares e amigos, meus grandes motivadores e incentivadores, aqueles que contribuíram com seu apoio e não nos deixaram desanimar nesta etapa tão importante para nós.

AGRADECIMENTOS

Especialmente, aos meus pais, Margarida e David (i.m.), pela incansável dedicação, sacrifícios e pelo exemplo de vida. Aos meus amados irmãos pelo apoio, incentivo e conselhos. A todos os outros amigos, familiares e professores que me incentivarem nesta caminhada. Obrigado!

Agnello Hupp

Agradeço também a orientadora deste trabalho, Marta Monteiro da Costa Cruz, por toda dedicação e apoio. Ao Rodrigo Silva Cosme, pelas discussões na realização deste trabalho.

LISTA DE FIGURAS

Figura 1 - Retorno real da poupança.....	14
Figura 2 - Stochastic Cyber Cycle	18
Figura 3 - <i>Relative Strenght Index</i>	19
Figura 4 - <i>Inverse Fisher Transform</i>	20
Figura 5 - JJRSX Index	20
Figura 6 - Directional Movement Index.....	21
Figura 7 – Indicador de Aceleração/Desaceleração.....	22
Figura 8 - Histograma MACD	23
Figura 9 - Chaikin Oscilator	24
Figura 10 - Exemplo de Rede MLP	25
Figura 11 - Exemplo de utilização de SL.....	31
Figura 12 - Projeto de uma RNA	33
Figura 13 - Gráfico do EUR/USD 2005 - 2014	34
Figura 14 - Função tangente hiperbólica	36
Figura 15 - Funcionamento do SL móvel	37
Figura 16 - Funcionamento geral do sistema	Erro! Indicador não definido.
Figura 17 - RNA utilizada nos testes iniciais	41

LISTA DE TABELAS

Tabela 1 - Modelos de Teste.....	40
Tabela 2 - Testes iniciais com os indicadores Erro! Indicador não definido.	
Tabela 3 - Efeito dos parâmetros nos resultados finais.....	45

LISTA DE SIGLAS

RSI – *Relative Strength Index* (Índice de Força Relativa)

RNA – Redes Neurais Artificiais

MLP – *Multilayer Perceptron*

MTS – *Mechanical Trading System* (Sistema Mecânico de Negociação)

SL – *Stop Loss* (Valor estabelecido para a venda de uma posição perdedora)

TP – *Take Profit* (Valor estabelecido para a venda de uma posição ganhadora)

MACD - *Moving Average Convergence Divergence* (Convergência/Divergência das Médias Móveis)

DMI - *Directional Movement Index* (Índice de Movimento Direcional)

SP – *Short Position* (Venda a Descoberto ou Venda Curta)

LP – *Long Position* (Venda Coberta)

CFD - *Contract For Difference*

RESUMO

O presente trabalho contemplou o desenvolvimento e a análise de resultados financeiros de um modelo de Rede Neural Artificial (RNA) aplicado no mercado de câmbio, mais especificamente ao par de moedas EURUSD. Os sinais de entrada e saída foram gerados através de uma RNA do tipo *feedforward* que foi treinada e validada entre o período 2005 e 2011 utilizando um algoritmo genérico. Testes finais foram realizados em uma terceira amostra no período de 2012 e 2013 de modo a verificar a capacidade de generalização da rede. A plataforma utilizada para programação, simulação e obtenção dos dados foi a MetaTrader 5. Além disso, fez-se a utilização de indicadores da Análise Técnica como dados de entrada. O resultado final obtido com o sistema na operação do ativo foi de 15,89% em um período de 2 anos. A alteração dos parâmetros da rede neural, como aumento do número de neurônios e camadas ocultas, mostrou-se, de uma maneira geral, positiva ao rendimento e a redução dos riscos. Técnicas de gestão de risco e de dinheiro foram também utilizadas.

Palavras-chave: Análise Técnica, Mercado de Câmbio, Gestão de Risco, Gestão de Dinheiro, Redes Neurais Artificiais.

SUMÁRIO

1	INTRODUÇÃO	13
1.1	CONSIDERAÇÕES INICIAIS	13
1.2	OBJETIVOS	15
1.3	JUSTIFICATIVA	15
1.4	ESTRUTURA DO TRABALHO	16
2	REVISÃO BIBLIOGRÁFICA.....	16
2.1	ANÁLISE TÉCNICA	16
2.2	INDICADORES.....	17
2.2.1	<i>Stochastic Cyber Cycle</i>	17
2.2.2	<i>Relative Strength Indicator (RSI)</i>	18
2.2.3	<i>Inverse Fisher Transform</i>	19
2.2.4	<i>JJRSX Index</i>	20
2.2.5	<i>Directional Movement Index (DMI)</i>	20
2.2.6	Indicador de Aceleração/Desaceleração (AC).....	21
2.2.7	Histograma MACD	22
2.2.8	<i>Chaikin Oscillator</i>	23
2.3	TÉCNICAS AVANÇADAS – REDES NEURAIS	24
2.3.1	Contexto	24
2.3.2	Parâmetros da Rede Neural	25
2.3.3	Treinamento de uma Rede Neural Artificial	26
2.3.4	Algoritmo de Otimização e Treinamento	27
2.3.5	Validação do Treinamento	27
2.4	SISTEMAS MECÂNICOS DE NEGOCIAÇÃO (MECHANICAL TRADING SYSTEMS).....	28
2.4.1	Regras de Entrada e Saída	28
2.4.2	Controle de Risco	29

2.4.3	Gerenciamento de Dinheiro	31
2.5	MENSURAÇÃO DE RISCO.....	32
2.5.1	<i>Drawdown Máximo</i>	32
2.5.2	<i>Sharpe Ratio</i>	32
3	METODOLOGIA	33
3.1	CONTEXTUALIZAÇÃO DO PROBLEMA.....	33
3.2	PRÉ-SELEÇÃO DOS DADOS DE ENTRADA:	35
3.3	PRÉ-PROCESSAMENTO DOS DADOS:.....	35
3.4	DEFINIÇÃO DA ESTRATÉGIA	35
3.4.1	Parâmetros de Entrada e Saída	35
3.4.2	Gerenciamento de Risco.....	36
3.4.3	Gerenciamento de Dinheiro	37
3.4.4	Sistema.....	38
3.5	DEFINIÇÃO DO ESCOPO DE TESTE	39
3.6	TREINAMENTO E VALIDAÇÃO	41
3.7	PÓS-PROCESSAMENTO	41
4	ANÁLISE DOS RESULTADOS	42
4.1	PRÉ-SELEÇÃO DOS DADOS	42
4.2	PARÂMETROS DA REDE	44
5	CONCLUSÃO	46
5.1	TRABALHOS FUTUROS	47
	REFERENCIAS.....	49
	ANEXO I – Modelo 6 x 4 x 2 utilizado na segunda fase de testes.....	52
	ANEXO II – Resultados modelo 10 x 8 x 1 x 2	53
	ANEXO III – Resultados modelo 10 x 4 x 2.....	54
	ANEXO IV – Resultados modelo 10 x 4 x 1 x 2.....	55
	ANEXO V – Resultados modelo 6 x 8 x 2	56

ANEXO VI – Resultados modelo 10 x 8 x 2	57
ANEXO VII – Resultados modelo 6 x 4 x 2	58
ANEXO VIII – Resultados modelo 6 x 12 x 2	59
ANEXO XIX – Resultados modelo 6 x 12 x 1 x 2	60

1 INTRODUÇÃO

1.1 CONSIDERAÇÕES INICIAIS

Devido a redução dos retornos financeiros proporcionados pelos investimentos de renda fixa, percebe-se um aumento da quantidade de pessoas migrando de investimentos de renda fixa para investimentos de venda variável, como o mercado de ações e o mercado de câmbio, que pode ser observado nas Figuras 1 e 2.

Além disso, grande parte das negociações no mercado de renda variável, especialmente no mercado de câmbio, tem sido executadas com o auxílio de sistemas. Segundo Choudhury; Verlaine (2014), 66% de todas as transações de 2013, referentes ao mercado de câmbio, foram executadas a partir de negociação eletrônica. A previsão é que este número tenda a aumentar para 76% dentro de 5 anos, de com Aite Group LLC.

Segmento Bovespa – evolução do volume médio diário por grupo de investidores (R\$ bilhões)

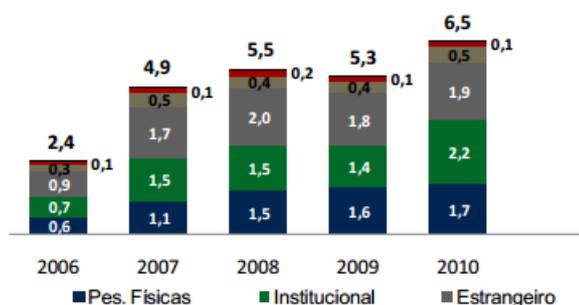


Figura 1 - Volume médio diário investido

Fonte: BMF&BOVESPA, 2014

Murphy(1999) cita algumas vantagens da atualização de sistemas mecânicos como: eliminação de emoção humana, maior disciplina e não necessidade de acompanhamento.

Nesse contexto, observa-se a possibilidade do desenvolvimento de sistemas eletrônicos de compra e venda de ativos de renda variável.

Assim o presente estudo analisará a rentabilidade e os riscos decorrentes da aplicação de uma Rede Neural Artificial no mercado de câmbio.

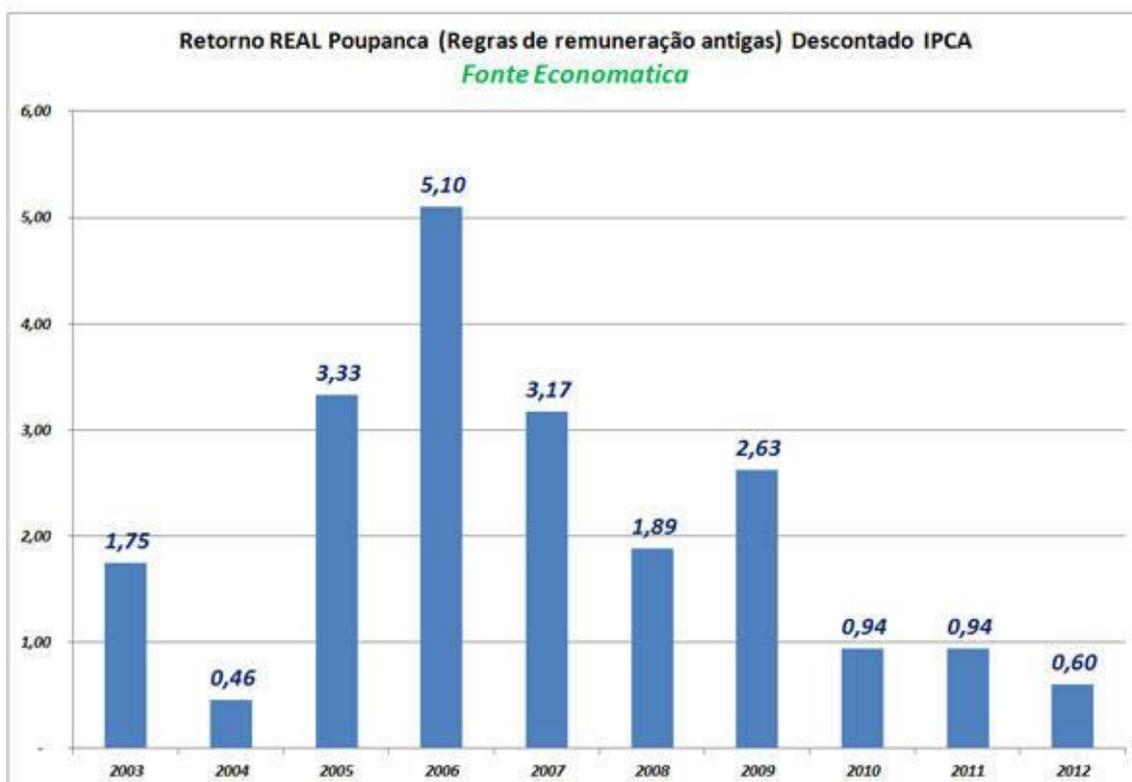


Figura 2 - Retorno real da poupança

Fonte: <http://exame.abril.com.br/>

Para o desenvolvimento da trading system um software especializado para o mercado de capitais será utilizado: a plataforma MetaTrader. O software foi desenvolvido pela empresa MetaQuotes Software e liberado ao mercado em 2000. A plataforma foi inicialmente desenvolvida voltada para o mercado de Forex. Sua mais recente versão, MetaTrader 5, permite a negociação no mercado de câmbio, CFD (contract for difference), Futuros e no mercado de ações.

O motivo da escolha da plataforma é que essa reúne o conjunto de recursos necessários a realização deste trabalho, que são: indicadores dos mercados já embutidos no sistema, possibilidade de realização de *backtesting* e validação dos sistemas criados, análise estatística dos resultados, além de permitir que o *trader* desenvolva, através de programação na linguagem MQL5, seus próprios algoritmos de compra e venda de ações.

1.2 OBJETIVOS

O objetivo geral desta pesquisa é analisar a rentabilidade e os riscos decorrentes da aplicação de uma Rede Neural Artificial no mercado de câmbio. Alterações de parâmetros da rede como: número de camadas ocultas e número de neurônios ocultos serão realizadas e analisadas.

Além disso, testes serão realizados com diferentes indicadores técnicos, de modo a identificar aquele que apresenta o melhor retorno no período analisado.

Por fim, os resultados obtidos serão comparados com os retornos médios da poupança.

1.3 JUSTIFICATIVA

Percebe-se que, um modo geral o brasileiro, não possui o hábito de investir. Em uma pesquisa realizada em 2010 pela GFK CR Brasil, em que foram envolvidas mil pessoas, apenas 39% dos entrevistados afirmaram poupar e investir, O Diário (2011).

Dados de uma empresa americana de pesquisa, Saad (2014), mostram que entre 1998 e 2008, 60% dos americanos detiam uma ação. A partir de 2008, devido à crise do mercado financeiro este número foi reduzido a quase 50%.

Por fim, a TOV Educacional realizou uma pesquisa revelando que 43% dos entrevistados não investem por falta de conhecimento e que 24% não investem por falta de tempo Ucho (2012).

Diante deste cenário, sistemas de negociação automatizados, que possuem como base métodos de tomadas de decisão quantitativas, podem ser grande auxílio a estas pessoas. Assim, esse trabalho visa analisar a rentabilidade e os riscos de tal abordagem.

1.4 ESTRUTURA DO TRABALHO

Este trabalho está organizado em cinco capítulos, sendo o Capítulo 1 a Introdução.

No Capítulo 2 é apresentada a revisão bibliográfica e as referências da literatura utilizadas como base para o projeto, mais especificamente a Análise Técnica e as Redes Neurais Artificiais (RNA).

No Capítulo 3 trata da metodologia utilizada no trabalho. Inclui todos as etapas a serem seguidas para o desenvolvimento da RNA.

No Capítulo 4 é realizada a análise dos resultados obtidos e a comparação dos resultados entre os diferentes parâmetros, assim como a comparação com os rendimentos do mercado.

O Capítulo 5 contém as conclusões do presente trabalho e recomendações o desenvolvimento de para trabalhos futuros.

2 REVISÃO BIBLIOGRÁFICA

2.1 ANÁLISE TÉCNICA

Antes de explicar os diferentes métodos e indicadores existentes, é preciso antes explicar em que consiste a Análise Técnica. Existem divergências quanto ao surgimento exato das técnicas, mas sua utilização remonta ao século XVIII com o uso de técnicas de *candlesticks* (Wikipédia: *candlestick* é o nome de uma técnica de análise gráfica de mercado, criada no Japão em meados do século XVIII, nas antigas bolsas de arroz de Osaka). Porém, as técnicas analíticas vieram a ganhar força a partir do século XVIII quando estudos foram feitos no início deste mesmo século, principalmente por Charles Dow.

Para Murphy(1999) a análise técnica é o estudo dos movimentos do mercado, primariamente pelo uso de gráficos, com o propósito de antever as tendências dos futuros preços. Por estudo dos movimentos do mercado entende-se por preço, volume de negociações e posições abertas.

Ainda segundo Murphy (1999) a abordagem de análise técnica é baseada em três premissas:

1. Os preços de mercado descontam tudo;
2. Os preços movem em tendências;
3. A história se repete;

O primeiro ponto é uma das bases da análise técnica. Baseando-se nela, o analista técnico acredita que todas as formas possíveis de afetar os preços já estão refletidas nos preços dos ativos, sejam estes fatores psicológicos, políticos ou econômicos. Murphy(1999) ressalta que se tudo o que pode afetar o mercado é representado nos preços dos ativos, então basta somente estudar a tendência dos preços.

O segundo ponto, depende em certa forma da aceitação do primeiro. O propósito da análise técnica é a identificação de uma tendência que está iniciando e então operar no sentido desta tendência. Esse tipo de abordagem é a seguidora de tendência (*trend-following*).

Ainda em relação a este segundo ponto, diz-se que uma tendência em andamento é mais provável se manter do que reverter (uma adaptação da primeira lei de Newton).

E finalmente o último ponto, a análise técnica se baseia em padrões gráficos que aconteceram inúmeras vezes no passado e que, segundo a terceira premissa, continuará acontecendo. Essa repetição dos padrões gráficos é explicada através do estudo da psicologia humana. Como este não é objetivo deste estudo, a explicação será restringida a ideia de que psicologia humana tende a não se alterar ao longo do tempo.

2.2 INDICADORES

2.2.1 *Stochastic Cyber Cycle*

Como sugere o nome, o *Cyber Cycle Stochastic* é um indicador estocástico. O indicador foi criado por Witold. Sua principal vantagem reside no fato de se adaptar as volatilidades e aos diferentes ciclos de mercado, fato que não ocorre na maioria dos indicadores estocásticos. Seus valores são calculados

de acordo com valores de um outro indicador, o *CyberCycle*, e não em séries temporais. Uma representação do indicador é mostrada na Figura 2.

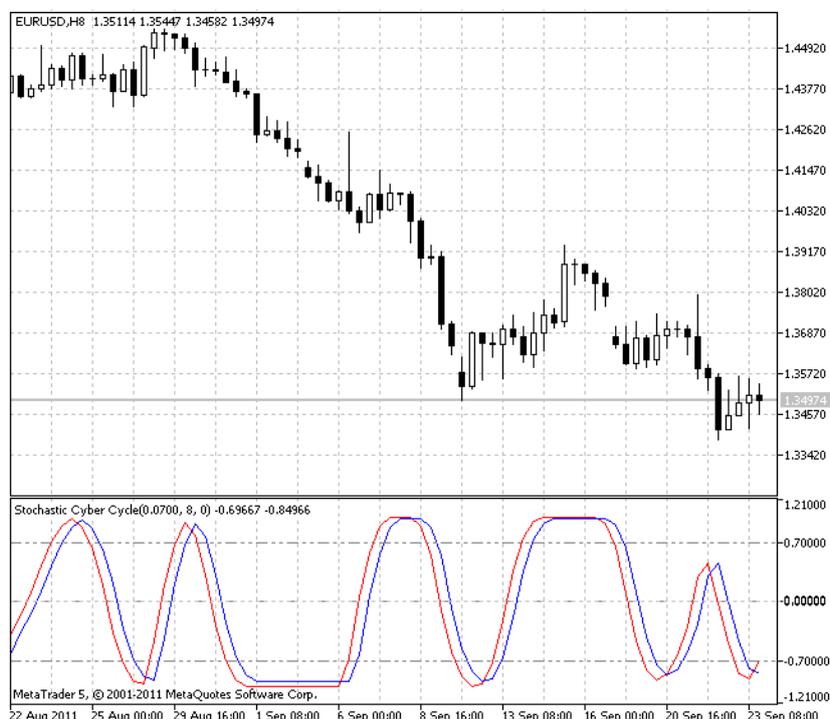


Figura 3 - Stochastic Cyber Cycle

Fonte: <http://www.mql5.com/>

2.2.2 *Relative Strength Indicator (RSI)*

O RSI foi criado por J. Welles Wilder (1978). Segundo o livro *The Encyclopedia of Technical Market Indicators*, o indicador é o mais popular dos indicadores de momentum de mercado.

Seu criador, propõe diferentes utilizações para o indicador. Uma delas, é com análise de sobre compra e sobre venda de um ativo. De acordo com suas análises, acima de 70 pontos o indicador sugere que existe uma sobre compra, ou seja, uma grande força compradora. Já quando o indicador indica abaixo dos 30 pontos, quer dizer que existe uma sobre venda, ou seja, uma grande força vendedora. O indicador é representado na Figura 3.



Figura 4 - *Relative Strenght Index*

Fonte: www.stockcharts.com

Além deste tipo de aplicação, ele propõe ainda a utilização do RSI como indicador de divergências. A figura da direita acima exemplifica dois casos de divergência. No primeiro caso, os preços alcançam um topo superior ao anterior, enquanto que o indicador RSI forma topos inferiores. Esse movimento caracteriza a discordância, e a indicação de venda.

2.2.3 *Inverse Fisher Transform*

O indicador foi criado recentemente em 2002 Ehlers; Wiley (2002). Mais adiante, o indicador foi alterado e aplicado ao RSI, sendo assim o indicador considerado como um dos melhores de identificação de pontos de entrada e saída. Um exemplo é demonstrado na figura Figura 4.



Figura 5 - Inverse Fisher Transform

Fonte: <http://www.mql5.com/>

2.2.4 JJRSX Index

O indicador é baseado no indicador padrão RSI (*Relative Strength Indicator*) salvo pelo modo de suavização utilizada já que este usa a ultra linear. O indicador pode ser visualizado na Figura 5.

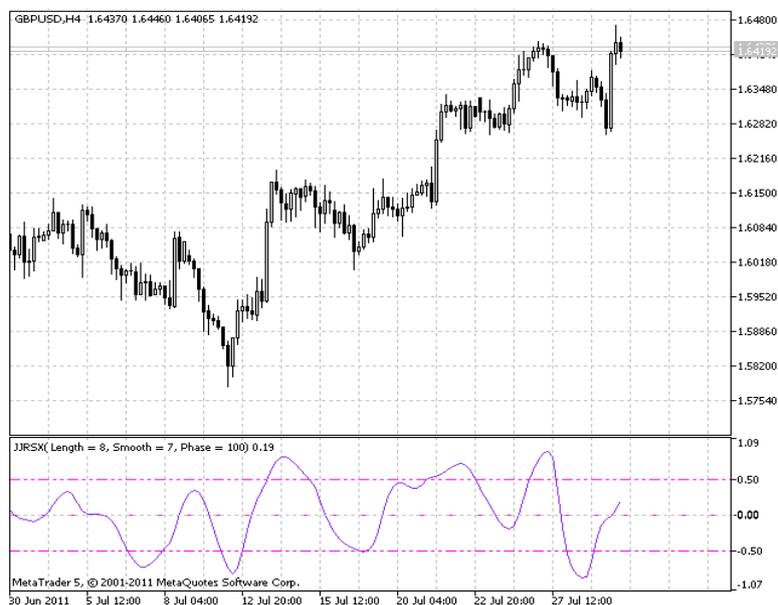


Figura 6 - JJRSX Index

Fonte: <http://www.mql5.com/>

2.2.5 Directional Movement Index (DMI)

O DMI foi criado por J. Welles Wilder (1978). O autor foi responsável pela criação de diversos indicadores entre eles o DMI e o RSI que são atualmente

amplamente utilizados e encontrados em quase todas plataformas de negociação. Em seu livro, J. Welles Wilder (1978) discorre que os mercados apresentam fortes tendências em apenas 30% do tempo. Assim, o autor criou o indicador DMI que sinaliza quando o mercado exibe sinais de forte mudança de tendência. WELLES indicou a utilização do indicador como filtro em sistemas seguidores de tendência.

A Figura 6 exibe o um exemplo de gráfico contendo o indicador.



Figura 7 - Directional Movement Index

Fonte: <http://www.forexrealm.com/>

2.2.6 Indicador de Aceleração/Desaceleração (AC)

O indicador de Aceleração/Desaceleração (AC) mede o nível de aceleração e desaceleração da força de mercado. O indicador AC normalmente muda de direção antes que qualquer mudança na força de mercado tenha sido percebida, fornecendo assim prévios sinais de entrada ou saída. A Figura 7 representa o indicador.



Figura 8 – Indicador de Aceleração/Desaceleração

Fonte: <http://www.mql5.com/>

Os sinais de entrada e saída são gerados de duas formas. A primeira é o caso em que as barras já se encontram ou abaixo ou acima da linha zero. Assim um sinal de compra é indicado uma vez que duas barras verdes são geradas acima da linha zero. Para a venda, basta que duas barras vermelhas sejam geradas abaixo da mesma linha.

A segunda forma ocorre quando se quer operar contra a força dominante do mercado. Assim, para que um sinal de compra seja confirmado, neste caso o indicador se encontra abaixo da linha zero, uma terceira barra na cor verde deve ser gerada para que a confirmação da compra ocorra.

2.2.7 Histograma MACD

O histograma MACD foi implementado por Thomas Aspray ao MACD em 1980, e foi de considerável avanço. O Histograma mede a diferença entre a linha MACD e a linha de Sinal e é traçado sob a forma de barras verticais. Abaixo pode ser visualizada os dois indicadores atuando ao mesmo tempo.

Dois sinais são gerados pelo indicador. O primeiro, que é mais confiável, consiste no momento em que as barras do histograma invertem de posição na linha zero. Quando o movimento ocorre de baixo para cima um sinal de compra

é indicado. O sinal de venda acontece da maneira contrária. Quando esse tipo de sinal ocorre, o indicador sinaliza uma reversão de tendência.

O segundo tipo de sinal gerado, consiste na formação de vale ou topos. Estes são menos confiáveis, visto que a formação de um topo ou vale, indica apenas o enfraquecimento da tendência e não sua reversão, como acontece no primeiro caso. Os dois tipos de sinais estão presentes na Figura 8.



Figura 9 - Histograma MACD

Fonte: <http://www.mql5.com/>

2.2.8 Chaikin Oscillator

O indicador Chaikin leva em consideração não só os movimentos dos preços, mas este também considera a importância do volume na movimentação final dos preços. Ele se baseia em três premissas. A primeira considera que quanto mais próximo do máximo for o fechamento, mais ativa é a acumulação, ou seja mais positivo o movimento.

A segunda considera que um aumento dos preços deve ser acompanhado por um aumento do volume, uma vez que este é o combustível dos mercados.

A terceira e última, considera que através da análise do histórico do volume, é possível identificar variações úteis no curto e médio prazo. A Figura 9 apresenta a dinâmica do indicador.



Figura 10 - Chaikin Oscilator

Fonte: <http://www.mql5.com/>

2.3 TÉCNICAS AVANÇADAS – REDES NEURAIIS

2.3.1 Contexto

Dentre as técnicas de comercialização eletrônica, as redes neurais têm ganhado cada vez mais destaque e utilização, especialmente no mercado de câmbio.

Para Ruggiero(1997), as redes neurais são muito mais poderosas que técnicas de regressão e podem ser programados para identificar e entender para vários relacionamentos complexos e padrões que métodos estatísticos normais não conseguem. Assim, para ele, a eficiência das redes neurais no reconhecimento de padrões as torna ideais para o desenvolvimento de trading systems.

Em termos gerais, uma rede artificial neural pode ser definida como um conjunto de unidades processadoras, ligados por conexões ponderadas.

O conceito por trás do funcionamento das redes neurais é relativamente simples. Entretanto sua aplicação e execução se mostram complexas.

2.3.2 Parâmetros da Rede Neural

Quando do desenvolvimento de uma Rede Neural Artificial para resolução de um problema, um dos pontos de maior dificuldade é a definição da quantidade de neurônios ocultos assim como a quantidade de camadas ocultas.

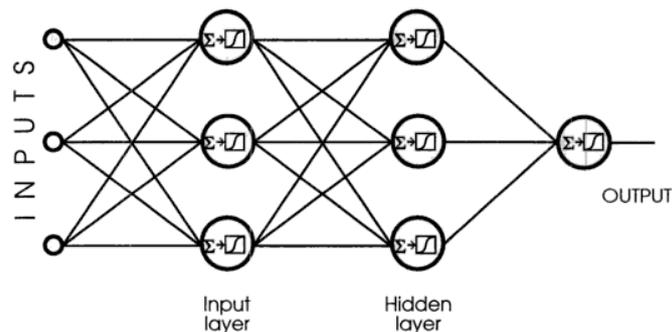


Figura 11 - Exemplo de Rede MLP

Fonte: **Neural Nets: Applications in Geography: Applications for Geography** (1994)

A Figura 10 representa um modelo de Rede Neural Artificial do tipo *feed-forward*, ou também conhecida como Rede *Multi-Layer Perceptron* (MLP). A rede apresenta três camadas. A primeira camada, é chamada de camada de entrada. A última, é chamada de camada de saída e, a do meio, de camada oculta. Neste modelo MLP, a saída de cada um dos neurônios é repassada a todos os neurônios da camada seguinte.

Para obtenção do número adequado de neurônios na(s) camada(s) oculta(s), algumas recomendações podem ser encontrados na literatura. Murata et al. (1994), propõem alguns métodos de obtenção destes valores:

- O número de neurônios ocultos deve ser entre o tamanho da camada de entrada e o tamanho da camada de saída;
- O número de neurônios ocultos deve ser entre 2/3 do tamanho da camada de entrada, mais o tamanho da camada de saída;
- O número de neurônios ocultos deve ser menos que dobro do tamanho da camada de entrada.

Em sua tese, Simeão de Medeiros (1999) faz referência a estudos relacionados ao Teorema de Kolmogorov em que, segundo demonstrações do Teorema, uma única camada oculta é suficiente para representar a maioria dos problemas de generalização. Todavia, neste estudo não é apresentado o número ideal de neurônios ocultos na camada oculta.

Para Panchal et al. (2011), problemas que demandam duas camadas ocultas são raramente encontrados em nosso cotidiano. Além disso, segundo o estudo, não existem, atualmente, fundamentos teóricos que justifiquem a utilização de mais de duas camadas ocultas.

Panchal et al. (2011) ainda sugere que a quantidade inicial de camadas ocultas seja de um, com o número de neurônios ocultos sendo igual à soma dos de entradas mais os de saída.

2.3.3 Treinamento de uma Rede Neural Artificial

Em relação ao treinamento e validação de uma RNA, existem alguns pontos essenciais a serem cobertos:

- Seleção de quantas camadas ocultas utilizar;
- Decisão de quantos neurônios utilizar em cada camada;
- Encontrar uma solução global evitando assim mínimos locais;
- Convergir para uma solução global em um período de tempo representativo;
- Validação do treinamento através de dados de validação;

Segundo Panchal et al. (2011), duas camadas ocultas pode ser útil na identificação de padrões do tipo dente de serra, sujeito ao risco de se cair um mínimo local.

O uso de poucos neurônios na camada oculta pode levar ao under fitting. No extremo oposto um grande número de neurônios associado com um número reduzido de dados, pode levar ao over fitting.

Assim, Panchal et al. (2011) recomenda que o número final seja obtido através de tentativa e erro, e que esta seja guiada por algumas técnicas de obtenção do número de neurônios e camadas.

2.3.4 Algoritmo de Otimização e Treinamento

Na ausência do algoritmo *backpropagation* para o treinamento da RNA, o algoritmo utilizado será então o algoritmo genético rápido.

Esse tipo de otimização é baseado no algoritmo genérico, e pesquisa os melhores valores dos parâmetros de entrada que, no caso de uma rede neural, são os pesos.

Uma otimização com todas combinações que poderia levar dias de otimização é realizada em algumas horas com o algoritmo rápido.

Segundo, Brewka (1996) o algoritmo genético tem tido um difundido impacto em problemas de otimização.

O algoritmo baseia-se na seleção do parâmetro mais adaptado, ou seja, que fornece o melhor resultado de acordo com o parâmetro escolhido.

O processo de treinamento consiste no fornecimento de diferentes pesos para os as diferentes entradas, de modo que haja a minimização do critério de erro escolhido. Assim para cada conjunto de pesos apresentado, uma comparação entre a saída produzida e a saída desejada é feita, e o erro é calculado. Ao final do processo, os pesos que apresentaram o menor erro são escolhidos.

2.3.5 Validação do Treinamento

Para Twomey; Smith (1997), a análise e validação de um modelo de rede neurais artificiais pode se basear em um ou mais critérios de medição dos erros. Os mais comuns são: erro absoluto médio, erro quadrático médio ou raiz quadrada do erro quadrático médio. Os erros são somados durante a validação, considerando a previsão da rede neural e os valores reais, e normalizados de acordo com a amostra.

Os autores Svozil et al. (1997) fazem referência a outras pesquisas e citam que a validação do treinamento deve ser feita seja utilizando um banco de dados

diferente daquele utilizado para o treinamento da rede neural seja utilizando o mesmo conjunto de dados. Neste último caso um método diferente deve ser utilizado, o chamado *cross-validation*.

2.4 SISTEMAS MECÂNICOS DE NEGOCIAÇÃO (MECHANICAL TRADING SYSTEMS)

Para Faith; Foster (2007) a base de um bom Sistema Mecânico de Negociação (SMN) deve ser estabelecida onde haja uma vantagem estatística (*trading with a statistical edge*). Essa zona é obtida através de observações e análises estatísticas, de acordo com o comportamento do mercado. Um exemplo de zona de vantagem estatística no mercado de ações são os suportes e resistências.

Segundo o autor, com uma vantagem estatística, tem-se uma maior probabilidade de ter um balanço positivo no longo prazo. A ideia pode ser melhor entendida com o ajuda de um conceito estatístico já bem disseminado: o Valor Esperado.

Segundo ele, a compreensão e aplicação deste conceito é um dos pontos-chaves para a obtenção de um bom SMN.

Assim, realizando operações em áreas com vantagem estatística, ou seja, em regiões com probabilidades favoráveis a de sua negociação, assegurariam que, no longo prazo, o *trader* obtenha resultados positivos.

Segundo Chande (1997), um sistema de compra e venda consiste em três principais funções, a saber:

- Regras de entrada e saída;
- Gerenciamento de risco;
- Gerenciamento de dinheiro;

2.4.1 Regras de Entrada e Saída

Para Ruggiero (1997), fundamentos e critérios de sinais de entrada e de saída de são diferentes. Como já mencionado anteriormente, quando do desenvolvimento de sinais de entrada, procura-se construir uma tática que

produza, estatisticamente, um bom valor de risco/recompensa e valor esperado.

Ruggiero (1997) ainda recomenda que alguns testes sejam realizados de modo a avaliar quão bem uma determinada regra de entrada ou saída se aplica na previsão de direção de mercado. Ruggiero (1997) menciona algumas regras de entrada e saída que podem ser utilizadas nos testes:

- Sair após manter o ativo por N barras;
- Sair após N barras negativas ou N barras positivas;
- Sair após N barras consecutivas de um movimento contrário ao desejado;
- Sair quanto atingir um limite de lucro;

Ruggiero (1997) ainda sugere que algumas técnicas de gerenciamento de dinheiro de dinheiro sejam aplicadas em conjunto, tanto em regras de entrada quanto de saída.

2.4.2 Controle de Risco

No contexto de investimentos e aplicações no mercado de renda variável, como o mercado de ações, opções e moedas, por exemplo, o investidor geralmente se preocupa com a quantidade máxima de perda aceita no caso de um movimento do mercado contrário ao movimento desejado. Essa abordagem é conhecida como gerenciamento de riscos.

Assim, um método comumente utilizado de gerenciamento de riscos é colocação de ordens de compra/venda de um ativo, estabelecendo assim um patamar pré-determinado, no qual o sistema encerra automaticamente as negociações. Isso permite ao investidor, posicionar uma venda ou compra, sabendo de antemão qual será seu prejuízo em caso de movimento contrário ao desejado. Tal ferramenta é conhecida como *Stop Loss*.

Segundo Chande (1997), um sistema seguidor de tendência, como um sistema de média móvel por exemplo, terá normalmente um maior número de negociações negativas do que negociações positivas. Quando analisada em

termos financeiros, essa afirmação ainda pode levar a um sistema com resultados positivos, desde de que a esperança matemática seja positiva.

Ainda segundo Chande (1997), cerca de 5% das negociações realizadas por um Sistema seguidor de tendência, são responsáveis pelos grandes ganhos. Isso reforça a necessidade do uso do *Stop Loss*, uma vez que a maioria das negociações são negativas, deve-se garantir que estas sejam limitadas através do cálculo pré-determinado.

Dependendo do valor do *Stop Loss* empregado, o a negociação terá um maior ou menor nível de liberdade de flutuação. Quanto menor o *Stop Loss*, maior a probabilidade de que, com uma queda dos preços, a operação seja encerrada e, portanto, menor o valor das perdas. Ainda, pequenos valores de *Stop Loss*, acabam, por muitas vezes, sendo afetados por flutuações aleatórias dos preços, gerando assim muitas operações e não dando um grau de liberdade adequada a flutuações dos preços.

Por outro lado, um grande *Stop Loss* permite uma boa movimentação dos preços ao custo de um risco mais elevado. Chande (1997) apresenta algumas evidências que sugerem que o uso de pequenos *Stop Losses* prejudicam o rendimento de um portfólio.

Existem bastante variedades de *Stop Loss* que podem ser empregados e simulados como: stop de volatilidade, stop com porcentagem fixa, stop baseado em suportes e resistências, stop baseados no tempo de operação, Dev-Stop, baseados no desvio-padrão, entre outros.

O *Stop Loss* móvel pode vir a ser uma interessante alternativa de *Stop Loss*, uma vez que este recalcula os níveis a medida que os preços se desenvolvem. Em uma tendência de alta, stop móvel nunca assume um valor inferior ao *Stop Loss* pré-estabelecido. Sua principal vantagem reside no fato de que, à medida que os preços seguem a favor da operação, uma parcela dos lucros é mantida inatingível.

A figura abaixo, exibe um simples exemplo de utilização de *Stop Loss* móvel. O indicador utilizado pode ser uma média móvel ou qualquer outro indicador que sirva ao propósito.

No exemplo, considerando a média móvel (linha rosa) como o indicador a ser seguido como novo *Stop Loss*, uma operação que tivesse tido origem em Novembro de 2006, seria encerrada ao final de fevereiro. Neste período houve a inversão dos preços da parte superior da média móvel para a inferior. Neste momento de inversão, o *trader* deveria encerrar suas posições, uma vez que tal movimento indicaria uma reversão de tendência. Assim, o *trader* assegura que pelo menos parte do seu lucro não seja perdido.

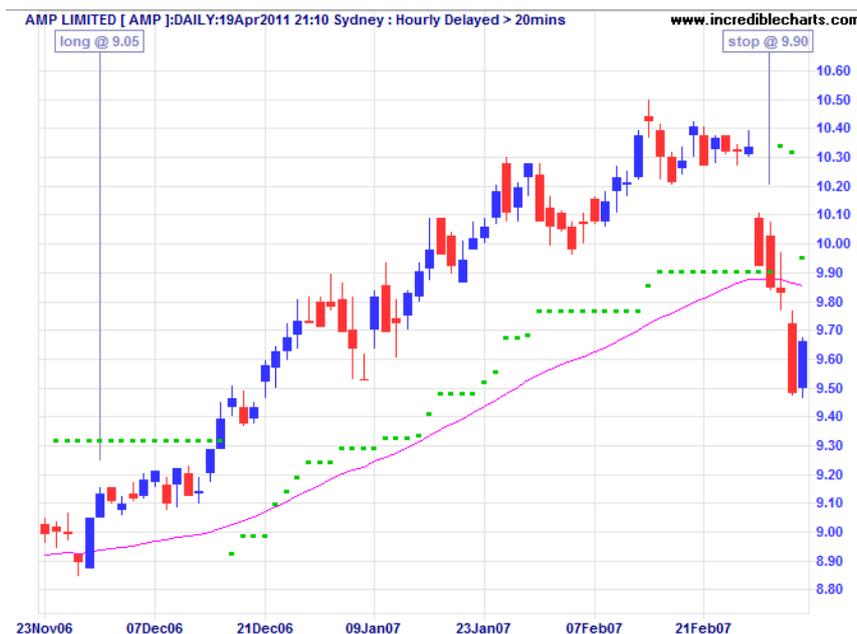


Figura 12 - Exemplo de utilização de SL

Fonte: <http://www.incrediblecharts.com/>

2.4.3 Gerenciamento de Dinheiro

O gerenciamento do dinheiro, também conhecido no mercado de ativos como tamanho de lote ou tamanho da posição, refere-se à quantidade total de dinheiro investida em cada negociação. Para Faith; Foster (2007), o cálculo da quantidade a ser empregada em cada negociação deve ser realizado baseando-se na porcentagem do capital que o *trader* aceitaria perder, em conjunto com um indicador de volatilidade chamado de ATR (sigla em inglês *Average True Range*). Para eles, o comprometimento do capital na quantia de 1% em risco representa um valor justo, já o comprometimento de 1,5% se enquadraria preferencialmente no perfil de um investidor arrojado. Considerando um o risco de 1%, por exemplo, e ainda que um ATR represente

4% da movimentação dos preços, o *trader* investiria 25% do capital neste ativo ($0.01/0.04=0.25$).

Assim como o controle de risco, o controle de dinheiro é relacionado ao tipo de sistema empregado e os tipos de variáveis consideradas. Como todo sistema possui um certo potencial para perda, há então a necessidade de se determinar a quantidade máxima de capital a ser exposta em cada negociação, tendo em vista uma quantidade inicial de capital fixa.

Além de método supracitado, existem inúmeros outros métodos de obtenção do valor do lote. Alguns deles são: ótimo f Ralph Vince (1995), Kelly System Balsara (1992), entre outros.

2.5 MENSURAÇÃO DE RISCO

Dois tipos de medidas serão utilizadas para identificar o nível de risco envolvido nas negociações: o *Drawdown* e o *Sharpe Ratio*.

2.5.1 *Drawdown Máximo*

O *drawdown* é uma medida de queda que leva em conta o valor máximo (o topo) e o valor mínimo (fundo) em um determinado período de tempo. Assim quanto maior seu valor, maior o nível de oscilação apresentado, portanto maior o risco. O *drawdown* pode ser obtido através da fórmula (1).

$$DD = \frac{\text{Topo} - \text{Fundo}}{\text{Topo}} \quad (1)$$

2.5.2 *Sharpe Ratio*

Segundo Lo (2002) *Sharpe ratio* é um dos índices mais citados quando se tratando de análise financeira. O índice é calculado através da diferença entre o retorno esperado do investimento e um investimento livre de riscos, como a poupança, dividido pelo desvio padrão do investimento (2).

$$S_r = \frac{\text{Retorno do Investimento} - \text{Retorno Livre de Risco}}{\text{Desvio Padrão do Investimento}} \quad (2)$$

Assim, quanto maior o índice, menos volátil e menos arriscado é o investimento.

3 METODOLOGIA

No estudo em questão, uma rede neural será utilizada como a fonte geradora de sinais de entrada e saída. Trata-se uma rede neural *Multi-Layer Perceptron*, utilizando o algoritmo genérico para realizar a otimização dos pesos. As operações serão realizadas no curto prazo.

As etapas envolvidas no projeto são apresentadas na Figura 12. Na sequência do trabalho, maiores detalhes serão apresentados em relação as etapas envolvidas no projeto.



Figura 13 - Projeto de uma RNA

Fonte: Adaptação do modelo sugerido por Simeão de Medeiros (1999)

3.1 CONTEXTUALIZAÇÃO DO PROBLEMA

Consiste em definir qual conjunto de indicadores e parâmetros da rede neural MLP, resultariam em uma maior margem de retorno, considerando o seguinte cenário:

- Moeda operada: EURUSD – Cotação do Euro em relação ao Dólar;
- Período I: 01/01/2005 à 31/12/2011, para teste e validação;
- Período II: 01/01/2012 à 31/12/2013 para teste de final;
- Periodicidade de operação: Intra-diário 4 horas;

Para critério de seleção do par de moedas, foi utilizado o fato dela se posicionar entre as que apresentam os maiores volumes de movimentação no mercado de moedas serviu como um fator de peso. Esse status garante uma excelente liquidez nas operações. Além disso, esse alto nível de liquidez também garante menores taxas de spread realizando maiores trades, reduzindo assim os custos de corretagem por operação.

Algumas características do par de moedas:

- Apresenta um *spread* normalmente entre 1-3 pips;
- A variação diária média observada varia entre 90 e 100 pips;
- O período mais relevante das negociações ocorre entre 07:00 GMT – 17:00 GMT.

*pip: indica o mínimo movimento que uma moeda pode realizar (1/100 de 1%) e é usada para calcular o lucro e a perda de um investidor.

Em relação ao período selecionado para o treinamento e validação, de 2007 à 2010, buscou-se selecionar um período em que o mercado foi submetido a diferentes tipos de movimentações, com altas, baixas e lateralização, totalizando 7 anos de amostras. Além disso, no período selecionado houveram períodos de alta volatilidade resultante da crise econômica de 2008. A Figura representa o contexto apresentado.



Figura 14 - Gráfico do EUR/USD 2005 - 2014

Fonte: <http://www.xe.com/>

Finalmente, no Período II, um teste definitivo será realizado de modo a verificar a capacidade do algoritmo em se adaptar as diferentes condições mercadológicas, ou seja, que não houve supertreinamento (overfitting).

3.2 PRÉ-SELEÇÃO DOS DADOS DE ENTRADA:

Os indicadores selecionados como dados de entrada do sistema, são mesclados de modo a abranger: indicadores seguidores de tendência, osciladores e ainda indicadores de força e de volume.

A lista compreende todos os indicadores que foram apresentados na seção Referências Bibliográficas. Estes indicadores serão submetidos a teste iniciais, e então analisados. Os resultados dos testes serão discutidos em Análise dos Resultados.

3.3 PRÉ-PROCESSAMENTO DOS DADOS:

Para que uma comparação entre dados distintos possa ser efetivamente realizada, estes devem, previamente, ser submetidos a técnicas de normalização. Para isso a normalização dos dados será realizada através do método de normalização Z-score.

Além disso, Nishida (2010) recomenda a normalização de cada um dos dados de entrada para redução do tempo de treinamento o algoritmo. A normalização Z-score pode ser calculada através das fórmulas (3) e (4):

$$S_a = \frac{1}{n} (|V_1 - \bar{A}| + |V_2 - \bar{A}| + \dots + |V_n - \bar{A}|) \quad (3)$$

$$V' = \frac{V_i - \bar{A}}{S_A} \quad (4)$$

3.4 DEFINIÇÃO DA ESTRATÉGIA

3.4.1 Parâmetros de Entrada e Saída

Para geração de sinais entrada, um neurônio da camada da saída será especificamente treinado para a realização desta operação. Da mesma forma, para geração de sinais de saída, um outro neurônio será utilizado.

Na fase de simulação, será ainda verificada a viabilidade da adição de um neurônio na camada de saída, sendo este especificamente treinados para o

encerramento de uma posição. Os resultados desta simulação serão mais adiante discutidos na seção Análise dos Resultados.

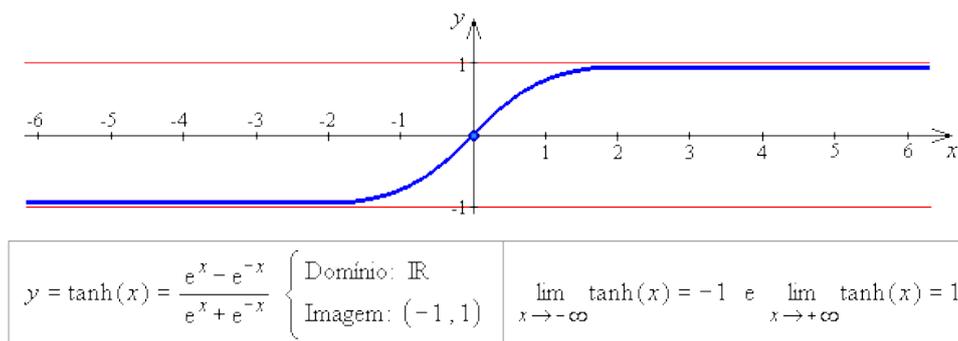


Figura 15 - Função tangente hiperbólica

Visto que alguns dos indicadores utilizados como entrada para o processamento dos dados podem assumir valores negativos, a função de ativação escolhida foi a função tangente hiperbólica. Esta função processa dados negativos e positivos de maneira não linear.

Assumindo então que os neurônios de saída assumem valores entre -1 e 1, os sinais de entrada são gerados caso o valor da saída assumam valor maior ou menor que zero.

Os indicadores previamente selecionados e mencionados inicialmente neste trabalho são indicadores suavizados. Tal seleção foi feita objetivando a redução da influência de ruídos no momento do processamento dos dados pela Rede Neural.

3.4.2 Gerenciamento de Risco

Como descrito anteriormente, o controle de risco se preocupa com a proteção de posições abertas, em que o dinheiro está em risco, limitando assim as perdas. No estudo em questão, serão feitos o uso de dois tipos de *stops*. Em um primeiro momento, será posicionado um nível de *Stop Loss* fixo. Tal nível será obtido através de um algoritmo de otimização. Num segundo momento, um *Stop Loss* móvel baseado em um indicador de volatilidade passa a obter novos valores para o *Stop Loss*. O funcionamento do controle pode ser analisado através da Figura 15 abaixo.

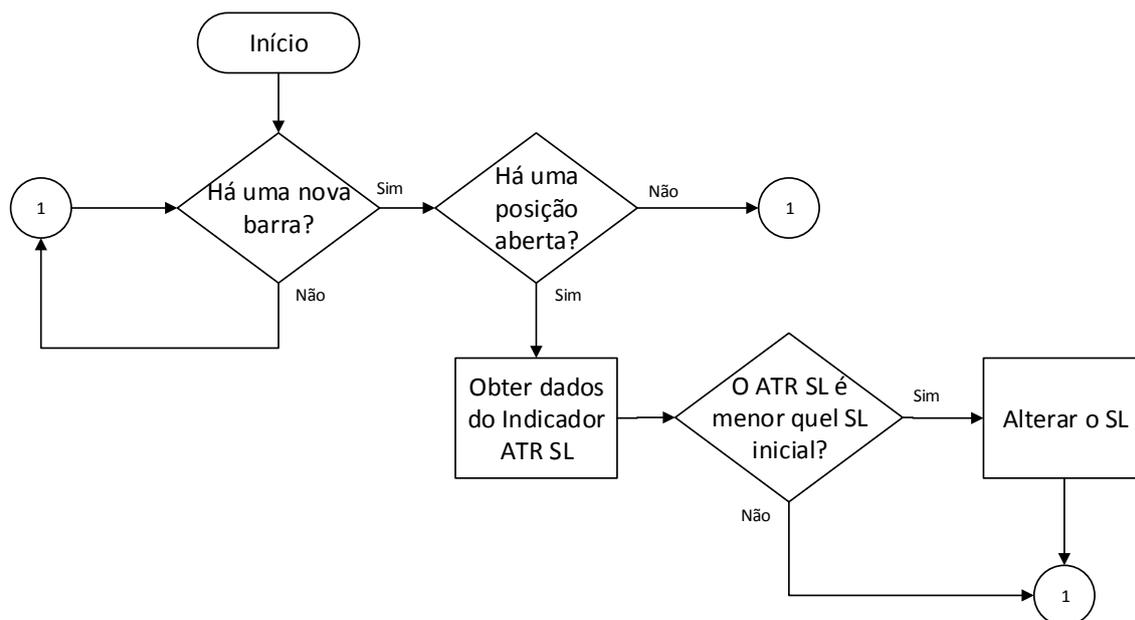


Figura 16 - Funcionamento do SL móvel

Fonte: O Autor

O algoritmo encarregado da análise do *Stop Loss*, realiza uma verificação recorrente da existência de uma posição em aberto. Caso ela exista, o algoritmo busca os últimos dados referentes ao indicador *ATR Stop Loss* e realiza uma comparação com o atual, que é estabelecido no momento da compra.

Caso o valor fornecido pelo indicador seja favorável, isto é, se ele apresentar uma redução dos riscos, o algoritmo atribui o valor do indicador ao valor do *Stop Loss*. Feito isso, o algoritmo volta a verificar a existência de uma nova barra para que toda a análise seja novamente realizada.

3.4.3 Gerenciamento de Dinheiro

De modo a evitar que as influências do método de gerenciamento de dinheiro impactem sobre o resultado final, foi escolhido um tamanho de lote fixo (como sugerido por Elder). Além da facilidade de implementação, isso evita que um árduo trabalho de análise deva ser realizado, de modo a estipular quanto do resultado é atribuído ao sistema neural e quanto é atribuído ao método de lotes.

3.4.4 Sistema

O esquema abaixo nos permite melhor compreender as bases de funcionamento do sistema. Alguns detalhes técnicos referentes a conexão com o servidor e entre outros, foram omitidos do esquema de modo a evitar um sobrecarregamento de informações. Os detalhes podem ser visualizados na Figura 16.

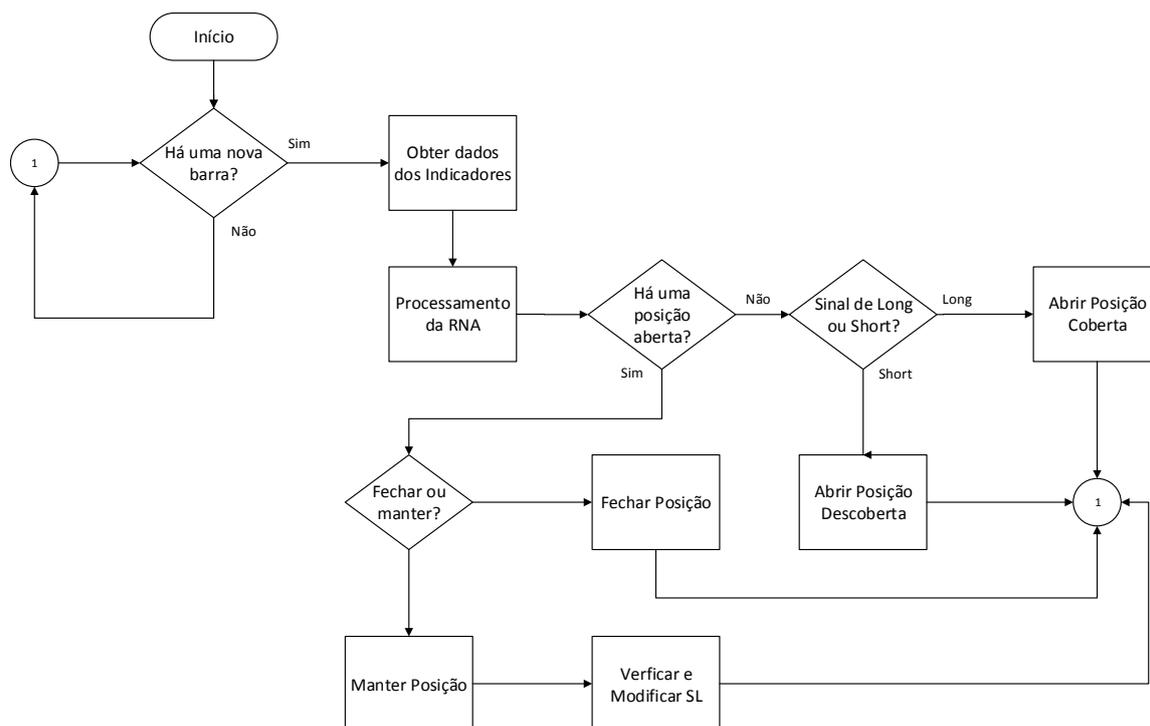


Figura 17 - Funcionamento geral do sistema

Fonte: Autor

Uma vez definidos os parâmetros de entrada do sistema, estrutura das redes neurais, assim como os parâmetros do stop móvel, o sistema se inicia verificando se existe uma nova informação que deve ser processada. No caso do sistema, uma nova informação é representada por uma nova barra. Esta dependerá da periodicidade escolhida (minutos, horas, dias, semanas ou meses). Se resposta for verdadeira, o sistema prossegue, caso contrário aguarda até que uma nova barra seja gerada.

Uma vez identificada uma nova barra, o sistema capta as novas informações dos indicadores de entrada e segue para outro processo decisório: se existe ou não uma posição em aberto (Comprada ou Vendida). Caso exista uma posição

em aberto, o sistema prossegue para a análise do algoritmo de *Stop Loss* móvel. Este algoritmo analisa se a posição em aberto deve ser encerrada ou mantida, tendo em vista a relação dos preços e do indicador de *Stop Loss* móvel, o *Average True Range*. Dependendo da relação, o sistema encerra ou mantém a posição em aberto. Em seguida o sistema recomeça, analisando assim a existência de uma nova barra.

Caso não haja uma posição em aberto, o sistema utiliza as informações coletadas dos indicadores, para o processamento nas redes neurais. Dependendo do sinal gerado pelos neurônios na camada de saída, o sistema pode efetuar ou o envio da ordem de compra (Comprada) ou da ordem de venda (Vendida). Finalmente, ele retorna ao início e verifica novamente a formação de uma nova barra para continuidade da análise.

3.5 DEFINIÇÃO DO ESCOPO DE TESTE

Nesta etapa, alguns testes serão realizados utilizando diferentes combinações de dados de entrada. Além disso, os diferentes métodos de normalização serão testados.

Para o teste dos dados de entrada, os indicadores serão testados de 2 em 2. Por exemplo, uma possível combinação seria o Indicador RSI periodicidade semanal com o indicador Chaikin diário.

Para esta fase inicial, uma Rede Neural Artificial com a seguinte configuração será utilizada (Figura 17):

- Dois indicadores na camada de entrada;
- Duas camadas ocultas, a primeira com 5 neurônios e a segunda com 3 neurônios;
- Dois neurônios na camada de saída.

Após a fase de testes, o melhor resultado obtido será selecionado para a realização de otimização dos parâmetros da rede neural.

Uma vez definido o indicador utilizado como dado de entrada, assim como o método de normalização, dar-se-á início uma segunda etapa de testes. Nessa, serão definidos aspectos referentes a estrutura da Rede Neural Artificial.

Assim, ao final dessa segunda fase de testes, os seguintes pontos deverão ter sido definidos:

- Número de camadas ocultas;
- Número de neurônios em cada camada oculta (caso exista mais que uma camada);
- Número de neurônios na camada de saída;

O escopo de teste será composto por um conjunto de modelos, que são apresentados na Tabela 1. Os modelos de teste foram restringidos ao máximo de 100 conexões haja vista restrições computacionais para a simulação.

Tabela 1 - Modelos de Teste

Modelo	Parâmetros da RNA				N° de Conexões
	Entradas	Cam. Oculta I	Cam. Oculta II	Cam. de Saída	
1	6	4	0	2	32
2	6	8	0	2	64
3	6	12	0	2	96
4	6	12	1	2	86
5	10	4	0	2	48
6	10	8	0	2	96
7	10	8	1	2	90
8	10	4	1	2	46

Como pode ser visto na Tabela 1, procurou-se manter alguns parâmetros fixos, enquanto outros variam, de modo que o impacto no resultado final possa ser analisado individualmente. Por exemplo, nos modelos 1 e 2, manteve-se o número de dados de entrada e saída constantes, havendo somente uma modificação na quantidade de dados da camada oculta. Isso permitirá que uma comparação dos resultados finais possa ser feita, sem influência de outros parâmetros.

De maneira semelhante, uma análise do impacto da alteração da quantidade de dados de entrada será realizada.

Por fim, serão também analisados os resultados da adição de uma camada oculta na rede neural dos modelos VI, VII e VIII.

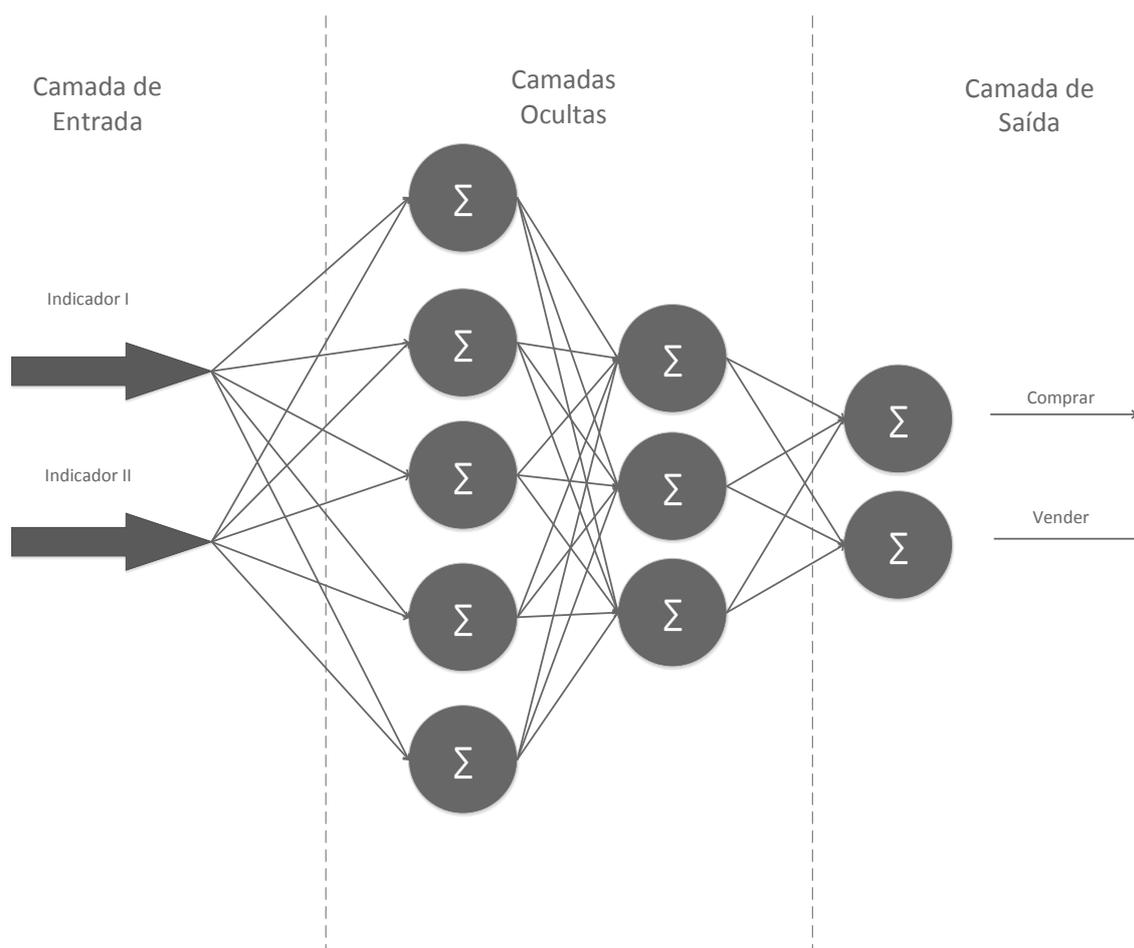


Figura 18 - RNA utilizada nos testes iniciais

Fonte: O autor

3.6 TREINAMENTO E VALIDAÇÃO

O treinamento dos modelos estabelecidos será realizado através do Algoritmo Genérico, como discutido anteriormente.

Uma vez que os pesos otimizados foram obtidos, a validação dos mesmos será efetuada pela plataforma *Meta Trader 5*. Para isso, a plataforma utiliza uma parte referente a 25% dos melhores resultados, testando sua performance em uma amostra fora daquela utilizada para o treinamento.

3.7 PÓS-PROCESSAMENTO

Por fim, nesta etapa, os parâmetros do melhor resultado da fase de validação serão utilizados para a realização de um teste em uma terceira amostra, de modo a verificar a capacidade da RNA em se adaptar a outros ambientes fora daquele em que foi submetida o teste.

4 ANÁLISE DOS RESULTADOS

O objetivo da análise dos cenários é verificar se os indicadores utilizados assim como os parâmetros da RNA se mostram eficazes, assegurando um bom retorno no período analisado.

A análise será feita em duas etapas. Na primeira etapa serão discutidos os resultados obtidos na pré-seleção dos dados de entrada, assim como a utilização de diferentes periodicidades. Na segunda etapa, tendo sido escolhidos o indicador de entrada, serão apresentados os resultados de oito diferentes estruturas da RNA (Tabela 1).

4.1 PRÉ-SELEÇÃO DOS DADOS

O objetivo da análise da pré-seleção dos dados é identificar o comportamento da periodicidade e da quantidade de dados passados no resultado final do teste. Dessa maneira, o conjunto quantidade de dados passados e periodicidade que retornar o maior resultado será empregado nos testes finais. Os resultados podem ser visualizados na Tabela 2.

Como pode-se visualizar na figura 16, apenas dois dados de entrada foram utilizados nesta fase.

Como pode ser visualizado na Tabela 2, para cada um dos indicadores, diferentes periodicidades foram utilizadas. Por exemplo, no modelo 1.1, um dos dados de entrada consiste na última barra gerada pelo indicador Histograma MACD na periodicidade 4 horas, enquanto que a outra entrada consiste na última barra gerada pelo indicador na periodicidade diária. Já o segundo modelo, faz-se a utilização da diferença entre a última e a antepenúltima barra gerada, para cada uma das periodicidades, intradiária e diária. Por fim, no modelo 3, os dados de entrada consistem na diferença entre três periodicidades, a intradiária, a diária e a semanal.

Analisando os resultados da Tabela 2, observa-se que os piores resultados finais são obtidos através da utilização dados referentes a apenas um dia.

Apenas um dos oito indicadores, o Modelo 1.1, apresentou resultado positivo nesta fase de testes.

Pode-se ainda observar que, à medida que mais dados antigos são utilizados, como sugere o modelo 2, uma melhoria dos resultados ocorre, passando de 686 mil para 811 mil o resultado acumulado dos indicadores. A únicas exceções foram os indicadores Histograma MACD e A/C (Modelos 2.5 e 2.7 respectivamente), que no primeiro haviam obtido resultados superiores.

Ainda no modelo 2, observa-se que houve, de uma maneira geral, uma melhoria da capacidade de generalização da rede, uma vez que os resultados dos testes se aproximaram mais dos resultados de validação.

Por fim, no modelo 3, constata-se uma pequena redução da performance (-\$34, 153.00) em relação ao modelo 2. O indicador *Cyber Cycle Stochastic*, foi o que obteve o melhor resultado quando comparado a outros modelos e indicadores.

Visto a pequena diferença entre o resultado do modelo 3 e do modelo 2, o indicador selecionado para simulação nas etapas posteriores foi o *Cyber Cycle Stochastic*. O terceiro modelo será utilizado, o que leva em conta dados semanais, diários e intradiários como entradas do sistema.

Tabela 2 - Testes iniciais com os indicadores

Modelo	Par de Indicadores		Otimização	Validação		Teste
	Dado de Entrada I	Dado de Entrada II		Otimização	Forward	
1.1	Histograma MACD D(0)	Histograma MACD H(0)	266958	\$ 233,531	\$ 151,385	\$ 117,549
1.2	A/C D(0)	A/C H(0)	226286	\$ 189,870	\$ 132,053	\$ 95,365
1.3	JRSX D(0)	JRSX H(0)	274272	\$ 216,875	\$ 154,626	\$ 89,677
1.4	RSI Fisher Transform D(0)	RSI Fisher Transform H(0)	190000	\$ 149,413	\$ 141,073	\$ 87,116
1.5	DMI D(0)	DMI H(0)	206472	\$ 166,773	\$ 166,647	\$ 82,421
1.6	RSI D(0)	RSI H(0)	192124	\$ 138,528	\$ 154,388	\$ 81,113
1.7	Stochastic Cycle D	Stochastic Cycle H(0)	277940	\$ 207,829	\$ 181,085	\$ 67,961
1.8	Chaikin Oscilator D(0)	Chaikin Oscilator H(0)	214008	\$ 169,182	\$ 148,016	\$ 65,058
Modelo 1	Total		1848060	\$ 1,472,001	\$ 1,229,273	\$ 686,260
2.1	Chaikin Oscilator D (0-3)	Chaikin Oscilator H (0-3)	219656	\$ 142,137	\$ 160,134	\$ 126,402
2.2	JRSX D (0-3)	JRSX H (0-3)	246403	\$ 212,509	\$ 166,589	\$ 104,504
2.3	Stochastic Cycle D (0-3)	Stochastic Cycle H (0-3)	262215	\$ 204,517	\$ 137,229	\$ 102,381
2.4	RSI D (0-3)	RSI H (0-3)	140224	\$ 139,351	\$ 93,616	\$ 99,369
2.5	Histograma MACD D (0-3)	Histograma MACD H (0-3)	215182	\$ 181,429	\$ 156,587	\$ 96,061
2.6	RSI Fisher Trans. D (0-3)	RSI Fisher Trans. H (0-3)	201951	\$ 134,280	\$ 139,861	\$ 93,906
2.7	A/C D (0-3)	A/C H (0-3)	201623	\$ 124,149	\$ 152,625	\$ 93,132
2.8	DMI D(0-3)	DMI H(0-3)	212596	\$ 128,596	\$ 143,587	\$ 95,650
Modelo 2	Total		1699850	\$ 1,266,968	\$ 1,150,228	\$ 811,405
3.1	Stochastic Cycle (D-H)	Stochastic Cycle (W-D)	234737	\$ 149,176	\$ 159,701	\$ 130,737
3.2	A/C (D-H)	A/C H (W-D)	209417	\$ 171,573	\$ 135,446	\$ 103,939
3.3	Histograma MACD (D-H)	Histograma MACD (W-D)	236064	\$ 201,680	\$ 66,340	\$ 101,305
3.4	JRSX (D-H)	JRSX (W-D)	274824	\$ 238,236	\$ 62,423	\$ 98,348
3.5	DMI (D - H)	DMI (BaixaD - BaixaH)	197421	\$ 167,489	\$ 149,157	\$ 97,530
3.6	RSI (D-H)	RSI (W-D)	242820	\$ 171,153	\$ 149,540	\$ 93,060
3.7	Chaikin Oscilator (D-H)	Chaikin Oscilator (W-D)	232557	\$ 204,083	\$ 151,681	\$ 80,208
3.8	RSI Fisher T. (D-H)	RSI Fisher T. (W-D)	216779	\$ 181,350	\$ 142,811	\$ 72,125
Modelo 3	Total		1844619	\$ 1,484,740	\$ 1,017,099	\$ 777,252

Legenda: D(0) - Última barra da periodicidade diária | D(1) - Penúltima barra da periodicidade diária
Otimização: 01/2005 - 04/2010 Validação: 04/2010 - 31/12/2011 Teste: 01/2012 - 12/2013 Quantia Inicial: \$100,000.00

4.2 PARÂMETROS DA REDE

O propósito desta etapa é de analisar o efeito da mudança de parâmetros da rede neural nos resultados dos testes finais. Como especificado na etapa anterior, o indicador de entrada utilizado para o teste foi o indicador *Cyber Cycle Stochastic*, uma vez que este apresentou o melhor resultado na etapa de teste preliminar.

A Tabela 3 contém os resultados obtidos em cada um dos modelos (relatórios mais detalhados podem ser encontrados em anexo a este trabalho). Percebe-se nos resultados que, para o número de entrada equivalente a 6 (Modelos 1,2,3 e 4), o aumento do número de neurônios na camada oculta I resulta em uma redução da performance da rede neural nas etapas de otimização e de *forward*. Entretanto, quando analisamos os resultados do teste *out-of-sample*, o aumento do número de neurônios resulta em uma melhoria dos resultados de todos os resultados. Além da melhoria da rentabilidade, houve também o aumento do *Sharpe Ratio*, o que indica que ocorreu uma diminuição do risco com o aumento da quantidade de neurônios. Houve também uma melhora

significativa da porcentagem de acertos das operações, sendo que as vendas cobertas (*Long Trades*) passaram de 21% para 50%, com o aumento de 4 neurônios para 12 neurônios.

No modelo 4, procurou-se estudar os resultados da adição de uma nova camada oculta contendo um neurônio. Com a exceção dos resultados de validação, a adição da nova camada resultou em perda de performance em todos os outros pontos.

Tabela 3 - Efeito dos parâmetros nos resultados finais

Modelo	Entradas	Cam.	Cam.	Cam. de	Otimização		Validação		Out-of-Sample	Drawdown (%)	Sharpe Ratio	Long Trades	Short Trades
		Oculto I	Oculto II	Saída	Otimização	Forward							
1	6	4	0	2	\$ 272,508	\$ 236,998	\$153,171	\$ 88,966	16.94	-0.11	21%	14%	
2	6	8	0	2	\$ 273,235	\$ 245,715	\$158,752	\$ 100,711	10.78	0.02	29%	38%	
3	6	12	0	2	\$ 249,038	\$ 233,428	\$114,891	\$ 112,065	6.08	0.09	50%	38%	
4	6	12	1	2	\$ 248,383	\$ 236,768	\$149,744	\$ 90,479	16.08	-0.10	32%	25%	
5	10	4	0	2	\$ 244,714	\$ 233,173	\$150,234	\$ 84,768	17.05	-0.25	32%	20%	
6	10	8	0	2	\$ 266,887	\$ 256,154	\$114,997	\$ 99,217	8.78	0.00	41%	26%	
7	10	4	1	2	\$ 224,832	\$ 210,820	\$145,859	\$ 102,855	7.71	0.04	40%	29%	
8	10	8	1	2	\$ 248,298	\$ 248,298	\$109,756	\$ 115,891	5.56	0.20	53%	45%	
Quantia inicial de: \$ 100,000.00				Backtest: 01/05 - 04/10			Validação: 04/10 - 12/11			Teste: 01/12 - 12/13			

Seguindo com a análise, percebe-se que ocorreu também uma melhoria dos resultados dos modelos 5 e 6 com o aumento do número de neurônios na camada oculta I. Apesar dos modelos 5 e 6 apresentarem uma rentabilidade negativa no período analisado, o aumento resultou em uma diminuição de quase 50% do *drawdown*, o que também representa uma diminuição dos riscos.

Nos modelos contendo 10 dados de entrada, foram adicionados uma segunda camada oculta contendo um neurônio. Desta vez, ao contrário do acontecido com o modelo 4, a adição de uma camada oculta resultou na melhoria dos rendimentos e na diminuição dos riscos. Assim, o modelo 8, apresentou o menor *drawdown*, de 5.56%, e os melhores índices de acerto, com 53% de acerto nas operações de venda coberta, e de 45% nas operações de venda descoberta.

A princípio os resultados percentuais de acerto e erro parecem sugerir um resultado final negativo, uma vez que menos da metade das operações foram bem sucedidas. Entretanto, quando analisamos o valor médio obtido nas operações vencedoras, que foi de \$1736,65, e nas operações perdedoras, que

foi de \$ 897,24, percebe-se que o valor esperado é positivo (\$ 387,59), indicando que no longo prazo o sistema tende a ser positivo.

Por fim, o modelo de melhor performance na segunda etapa de testes, o número 8, retornou no período de 2 anos, 15,89%, sendo que, no mesmo período, o ativo EURUSD acumulou uma alta equivalente a 5,69%. Assim, o modelo mostrou-se superior à média desse mercado.

A princípio o resultado pode parecer satisfatório, porém quando comparado a um investimento de renda fixa no mesmo período, como o da poupança que foi de 12,89%, o resultado pode ser considerado baixo, visto que se trata de um investimento de renda variável, e portanto apresenta riscos.

Alguns resultados da primeira etapa de testes, em que foram considerados apenas dois dados de entrada, se mostraram superiores aos da segunda etapa. Entretanto, como o objetivo do primeiro teste foi unicamente a seleção do melhor indicador, os resultados dos modelos 1.1 e 3.1 não serão considerados neste estudo. Além disso, nesta etapa não foram feitas uma análise de risco. Um futuro estudo poderá ser realizado para identificar o motivo pelo qual estes modelos apresentaram resultados superiores. Neste caso, o resultado pode ter sido influenciado ou pelos parâmetros da rede neural e/ou o fato de terem sido utilizadas duas entradas.

5 CONCLUSÃO

O presente estudo teve como objetivo analisar a rentabilidade, assim como os riscos decorrentes da aplicação de um modelo de redes neurais artificiais em um par de moedas no mercado de câmbio. O tipo de RNA utilizada foi o *feedforward*, sendo que a otimização dos pesos foi realizada através do uso de um algoritmo genérico.

Os testes iniciais voltados para a análise dos indicadores evidenciam a importância da escolha de não só um bom indicador, mas também das diferentes formas de apresentar os dados para a rede neural. A utilização de dados de diferentes periodicidades e de dados passados, mostrou-se favorável a obtenção de melhores resultados.

Os modelos simulados nos testes finais ficaram restringidos a redes neurais com no máximo 100 conexões, devido ao esforço computacional exigido.

Observou-se que modo geral, houve uma melhoria da rentabilidade e redução dos riscos, quando elevado o número de neurônios na camada oculta. Além disso, para os modelos contendo 10 dados de entrada, a adição de uma camada oculta contendo um neurônio mostrou-se benéfica, havendo assim uma redução dos riscos e um aumento da rentabilidade.

O melhor resultado obtido foi de 15,89% no período de 2 anos, o que supera a média do ativo EURUSD, que acumulou uma alta equivalente a 5,69% no mesmo período.

Vale ressaltar que este trabalho focalizou em uma única moeda, o EURUSD, utilizando também um único indicador de análise técnica, o indicador *Cyber Cycle Stochastic*.

5.1 TRABALHOS FUTUROS

Para trabalhos futuros é recomendada a utilização de um modelo de rede neural já desenvolvida ou que requeira menos esforço computacional. A redução dos esforços computacionais permitirá não somente a simulação de redes com uma maior quantidade de neurônios, mas também a simulação de modelos com múltiplas redes neurais. Essas redes podem ser treinadas para a identificação de tendências e para pontos de sobre compra ou sobre venda.

Além disso, ainda resta a ser avaliada a utilização simultânea de indicadores que apresentam diferentes propósitos, como um indicador de identificação de tendência em conjunto com um oscilador.

Além disso, um estudo do comportamento dos riscos pode ser realizado aplicando, simultaneamente, o mesmo modelo múltiplos pares de moedas no mercado de câmbio ou em outro mercado de ativos, como o mercado de ações.

REFERENCIAS

BALSARA, N. J. **Money management strategies for futures traders**. 1992.

BREWKA, G. **Artificial intelligence - a modern approach**. 2ed ed. 1996.

CHANDE, T. Beyond Technical Analysis. **FUTURES-CEDAR FALLS IOWA ...**, p. 143, 1997. Disponível em: <<http://scholar.google.com/scholar?hl=en&btnG=Search&q=intitle:Beyond+Technical+Analysis#2>>. Acesso em: 24/6/2014.

EHLERS, J.; WILEY, J. By John Ehlers. , , n. November, p. 1–5, 2002.

FAITH, C.; FOSTER, M. **Way of the Turtle**. 2007.

J. WELLES WILDER. **New Concepts in Technical Trading Systems**. 1978.

LO, A. W. The Statistics of Sharpe Ratios. ,2002.

MURATA, N.; YOSHIZAWA, S.; AMARI, S. Network information criterion-determining the number of hidden units for an artificial neural network model. **IEEE transactions on neural networks / a publication of the IEEE Neural Networks Council**, v. 5, n. 6, p. 865–72, 1994. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/18267861>>. .

Neural Nets: Applications in Geography: Applications for Geography. Springer, 1994.

NISHIDA, T. [Data transformation and normalization]. **Rinsho byori. The Japanese journal of clinical pathology**, v. 58, n. 10, p. 990–7, 2010. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/22187680>>. .

PANCHAL, G.; GANATRA, A.; KOSTA, Y.; PANCHAL, D. Behaviour analysis of multilayer perceptrons with multiple hidden neurons and hidden layers. **International Journal of ...**, v. 3, n. 2, p. 332–337, 2011. Disponível em: <<http://www.ijcte.org/papers/328-L318.pdf>>. Acesso em: 28/6/2014.

RALPH VINCE. **New Money Management: A Framework for Asset Allocation**. 1995.

RUGGIERO, M. Cybernetic trading strategies. **NY: Wiley**, 1997. Disponível em: <<http://scholar.google.com/scholar?hl=en&btnG=Search&q=intitle:Cybernetic+Trading+Strategies#1>>. Acesso em: 28/6/2014.

SIMEÃO DE MEDEIROS, J. FACULDADE DE FILOSOFIA, LETRAS E CIÊNCIAS HUMANAS. **filosofia.fflch.usp.br**, 1999. Disponível em: <http://filosofia.fflch.usp.br/sites/filosofia.fflch.usp.br/files/graduacao/progs_pdf/1984/FLF165_1_1984.PDF>. Acesso em: 28/6/2014.

SVOZIL, D.; KVASNICKA, V.; POSPICHAL, J. Introduction to multi-layer feed-forward neural networks. **Chemometrics and intelligent ...**, v. 39, p. 43–62, 1997. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0169743997000610>>. Acesso em: 27/6/2014.

TWOMEY, J.; SMITH, A. Validation and verification. **Artificial neural networks for civil engineers: ...**, n. January 1995, p. 1–29, 1997. Disponível em: <<http://www.eng.auburn.edu/~aesmith/publications/bookch/janchap.pdf>>. Acesso em: 28/6/2014.

CHOU DHURY, A.; VERLAINE J. **FX Traders Facing Extinction as Computers Replace Humans**. Bloomberg, 2014. Disponível em: <<http://mobile.bloomberg.com/news/2014-02-18/fx-traders-facing-extinction-as-computers-replace-humans.html>>. Acesso em: 03/07/2014.

SAAD L. **U.S. Stock Ownership Stays at Record Low**. Gallup, 2013. Disponível em: <<http://www.gallup.com/poll/162353/stock-ownership-stays-record-low.aspx>>. Acesso em: 01/07/2014.

GUEDES C. **Só 39% dos brasileiros têm o hábito de poupar e investir**. O diário, 2011. Disponível em: <<http://www.odiario.com/economia/noticia/388053/so-39-dos-brasileiros-tem-o-habito-de-poupar-e-investir/>>. Acesso em: 01/07/2014.

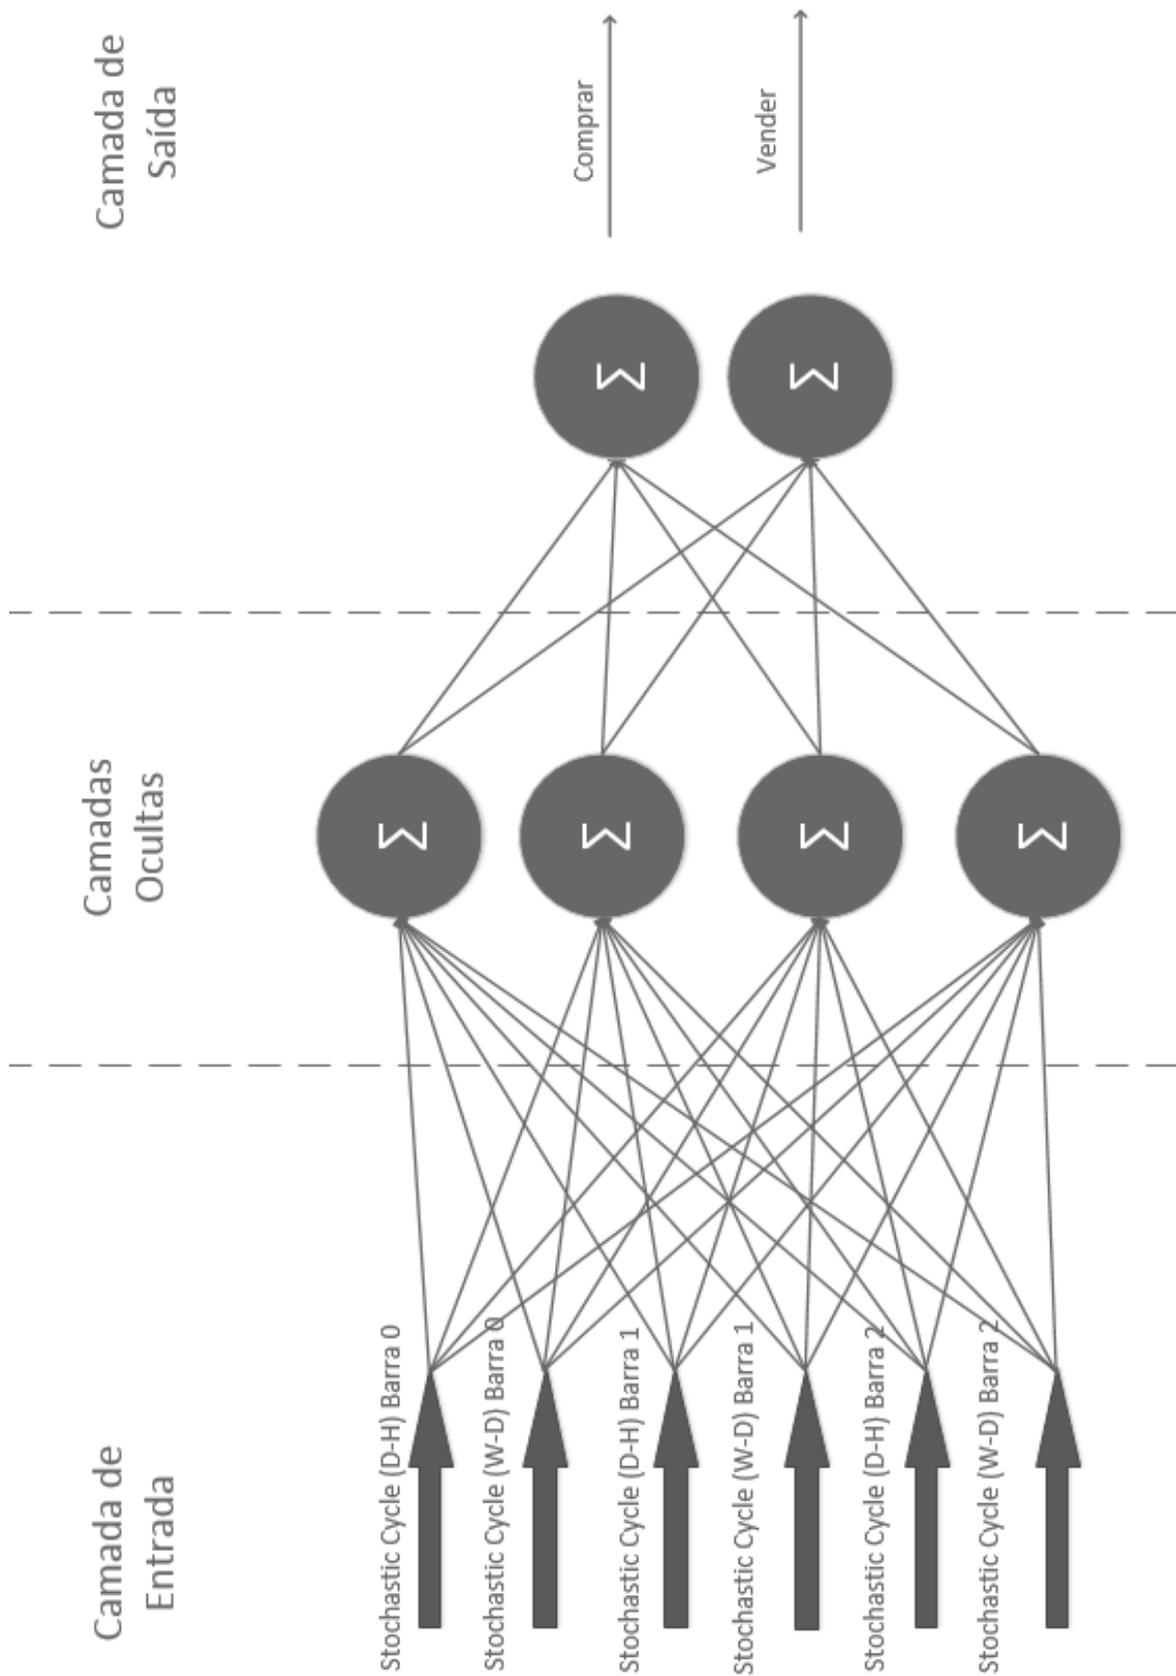
UCHO. **Pesquisa revela que 45% das pessoas não investem na Bolsa por desconhecimento**. Ucho info, 2012. Disponível em: <

<http://ucho.info/pesquisa-revela-que-45-das-pessoas-nao-investem-na-bolsa-por-falta-de-conhecimento>>. Acesso em: 02/07/2014.

EXAME. Retorno real da poupança em 2012 é o 2º menor em 10 anos. Exame, 2013. Disponível em: < <http://exame.abril.com.br/seu-dinheiro/noticias/retorno-real-da-poupanca-em-2012-e-o-2o-menor-em-10-anos>>. Acesso em: 01/7/2014.

BMF&BOVESPA, 2012. **Demonstração de Resultados 2010.** < http://ri.bmfbovespa.com.br/ptb/974/DFsBVMF122010_port.pdf>, acesso em [07/07/2014].

ANEXO I – Modelo 6 x 4 x 2 utilizado na segunda fase de testes.



ANEXO II – Resultados modelo 10 x 8 x 1 x 2

History Quality	99%	Ticks	12212	Symbols	1
Bars	3099				
Initial Deposit	100 000,00				
Total Net Profit	15 891,00	Balance Drawdown Absolute	3 882,00	Equity Drawdown Absolute	5 061,00
Gross Profit	34 733,00	Balance Drawdown Maximal	6 173,60 (5,56%)	Equity Drawdown Maximal	9 932,40 (8,67%)
Gross Loss	-18 842,00	Balance Drawdown Relative	5,56% (6 173,60)	Equity Drawdown Relative	8,67% (9 932,40)
Profit Factor	1,84	Expected Payoff	387,59	Margin Level	3550,45%
Recovery Factor	1,60	Sharpe Ratio	0,20	Z-Score	0,00 (0,00%)
AHPR	1,0038 (0,38%)	LR Correlation	0,88	OnTester result	0
GHR	1,0036 (0,36%)	LR Standard Error	2 893,35		
Total Trades	41	Short Trades (won %)	22 (45,45%)	Long Trades (won %)	19 (52,63%)
Total Deals	82	Profit Trades (% of total)	20 (48,78%)	Loss Trades (% of total)	21 (51,22%)
Largest	profit trade	profit trade	6 422,00	loss trade	-1 906,00
Average	profit trade	profit trade	1 736,65	loss trade	-897,24
Maximum	consecutive wins (\$)	consecutive wins (\$)	6 (15 010,60)	consecutive losses (\$)	4 (-3 235,60)
Maximal	consecutive profit (count)	consecutive profit (count)	15 010,60 (6)	consecutive loss (count)	-4 123,40 (3)
Average	consecutive wins	consecutive wins	2	consecutive losses	2

ANEXO III – Resultados modelo 10 x 4 x 2

History Quality	99%								
Bars	3099	Ticks	12117	Symbols					1
Initial Deposit	100 000.00								
Total Net Profit	-15 232.20	Balance Drawdown Absolute	17 054.40	Equity Drawdown Absolute	17 981.80				
Gross Profit	16 913.00	Balance Drawdown Maximal	17 054.40 (17.05%)	Equity Drawdown Maximal	21 110.80 (20.47%)				
Gross Loss	-32 145.20	Balance Drawdown Relative	17.05% (17 054.40)	Equity Drawdown Relative	20.47% (21 110.80)				
Profit Factor	0.53	Expected Payoff	-448.01	Margin Level	3012.05%				
Recovery Factor	-0.72	Sharpe Ratio	-0.25	Z-Score	0.12 (9.55%)				
AHPR	0.9953 (-0.47%)	LR Correlation	-0.86	OnTester result	0				
GHPR	0.9952 (-0.48%)	LR Standard Error	2 306.30						
Total Trades	34	Short Trades (won %)	15 (20.00%)	Long Trades (won %)	19 (31.58%)				
Total Deals	68	Profit Trades (% of total)	9 (26.47%)	Loss Trades (% of total)	25 (73.53%)				
	Largest	profit trade	4 224.00	loss trade	-2 358.40				
	Average	profit trade	1 879.22	loss trade	-1 285.81				
	Maximum	consecutive wins (\$)	2 (4 920.80)	consecutive losses (\$)	10 (-12 809.00)				
	Maximal	consecutive profit (count)	4 920.80 (2)	consecutive loss (count)	-12 809.00 (10)				
	Average	consecutive wins	1	consecutive losses	4				

ANEXO VII – Resultados modelo 6 x 4 x 2

History Quality	99%								
Bars	3099	Ticks	12068	Symbols					1
Initial Deposit	100 000.00								
Total Net Profit	-11 034.40	Balance Drawdown Absolute	13 057.40	Equity Drawdown Absolute					13 784.00
Gross Profit	23 735.80	Balance Drawdown Maximal	17 735.60 (16.94%)	Equity Drawdown Maximal					22 313.20 (20.56%)
Gross Loss	-34 770.20	Balance Drawdown Relative	16.94% (17 735.60)	Equity Drawdown Relative					20.56% (22 313.20)
Profit Factor	0.68	Expected Payoff	-183.91	Margin Level					3170.87%
Recovery Factor	-0.49	Sharpe Ratio	-0.11	Z-Score					-1.09 (72.43%)
AHPR	0.9982 (-0.18%)	LR Correlation	-0.72	OnTester result					0
GHPR	0.9981 (-0.19%)	LR Standard Error	2 878.80						
Total Trades	60	Short Trades (won %)	22 (13.64%)	Long Trades (won %)					38 (21.05%)
Total Deals	120	Profit Trades (% of total)	11 (18.33%)	Loss Trades (% of total)					49 (81.67%)
	Largest	profit trade	6 754.00	loss trade					-2 521.00
	Average	profit trade	2 157.80	loss trade					-709.60
	Maximum	consecutive wins (\$)	2 (4 184.60)	consecutive losses (\$)					29 (-12 194.80)
	Maximal	consecutive profit (count)	6 754.00 (1)	consecutive loss (count)					-12 194.80 (29)
	Average	consecutive wins	1	consecutive losses					6

ANEXO VIII – Resultados modelo 6 x 12 x 2

History Quality	99%								
Bars	3099	Ticks	12010	Symbols					1
Initial Deposit	100 000.00								
Total Net Profit	12 065.40	Balance Drawdown Absolute	5 197.00	Equity Drawdown Absolute					5 961.00
Gross Profit	52 518.60	Balance Drawdown Maximal	6 189.80 (6.08%)	Equity Drawdown Maximal					9 112.00 (8.83%)
Gross Loss	-40 453.20	Balance Drawdown Relative	6.08% (6 189.80)	Equity Drawdown Relative					8.83% (9 112.00)
Profit Factor	1.30	Expected Payoff	137.11	Margin Level					3506.30%
Recovery Factor	1.32	Sharpe Ratio	0.09	Z-Score					1.02 (69.23%)
AHPR	1.0014 (0.14%)	LR Correlation	0.93	OnTester result					0
GHPR	1.0013 (0.13%)	LR Standard Error	2 100.81						
Total Trades	88	Short Trades (won %)	56 (37.50%)	Long Trades (won %)					32 (50.00%)
Total Deals	176	Profit Trades (% of total)	37 (42.05%)	Loss Trades (% of total)					51 (57.95%)
	Largest	profit trade	6 622.00	loss trade					-1 607.00
	Average	profit trade	1 419.42	loss trade					-793.20
	Maximum	consecutive wins (\$)	4 (4 627.40)	consecutive losses (\$)					6 (-6 189.80)
	Maximal	consecutive profit (count)	7 528.60 (2)	consecutive loss (count)					-6 189.80 (6)
	Average	consecutive wins	2	consecutive losses					2

