

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**UM FRAMEWORK PARA A PREVISÃO DE CENÁRIOS COM O USO
DE SISTEMAS HÍBRIDOS NEUROGENÉTICOS PARA COMPRA E
VENDA DE ENERGIA ELÉTRICA NO MERCADO FUTURO**

GUILHERME AUGUSTO BARROS CONDE

TD 09/2012

UFPA/ITEC/PPGEE
BELÉM/PA
2012

**UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

GUILHERME AUGUSTO BARROS CONDE

**UM FRAMEWORK PARA A PREVISÃO DE CENÁRIOS COM O USO
DE SISTEMAS HÍBRIDOS NEUROGENÉTICOS PARA COMPRA E
VENDA DE ENERGIA ELÉTRICA NO MERCADO FUTURO**

Tese submetida à Banca Examinadora do Programa de Pós-graduação em Engenharia Elétrica da UFPA para a obtenção do Grau de Doutor em Engenharia Elétrica, elaborada sob a orientação do Prof. Dr. Carlos Renato Lisboa Francês.

TD 09/2012

**UFPA/ITEC/PPGEE
BELÉM/PA
2012**

**UM FRAMEWORK PARA A PREVISÃO DE CENÁRIOS COM O USO DE
SISTEMAS HÍBRIDOS NEUROGENÉTICOS PARA COMPRA E VENDA DE
ENERGIA ELÉTRICA NO MERCADO FUTURO**

GUILHERME AUGUSTO BARROS CONDE

Esta tese foi julgada adequada para o Exame de Defesa de Doutorado em Engenharia Elétrica, na área de Computação Aplicada, e aprovado na sua forma final pela banca examinadora designada pelo Programa de Pós-Graduação em Engenharia Elétrica do Instituto de Tecnologia da Universidade Federal do Pará em 04 de maio de 2012.

Prof. Dr. Carlos Renato Lisboa Francês (PPGEE - UFPA) - ORIENTADOR

Prof. Dr. André Carlos Ponce de Leon Ferreira de Carvalho (ICMC- USP – SÃO CARLOS) - MEMBRO EXTERNO

Prof. Dr. Solon Venâncio de Carvalho (LAC - INPE) - MEMBRO EXTERNO

Prof. Dr. Celso Massaki Hirata (ITA) - MEMBRO EXTERNO

Prof. Dr. Ubiratan Holanda Bezerra (PPGEE – UFPA) - MEMBRO

VISTO:

Prof. Dr. Marcus Vinícius Alves Nunes - Coordenador do PPGEE/CT/UFPA

UFPA/ITEC/PPGEE

BELÉM/PA - 2012

C745 Conde, Guilherme Augusto Barros

Um framework para a previsão de cenários com o uso de sistemas híbridos neurogenéticos para compra e venda de energia elétrica no mercado futuro / Guilherme Augusto Barros Conde; orientador, Carlos Renato Lisboa Francês - 2012.

Tese (Doutorado) – Universidade Federal do Pará, Instituto de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica, Belém, 2012.

1. Previsão de Séries Temporais. 2. Redes Neurais Artificiais. 3. Algoritmos Genéticos. 4. Sistemas Híbridos Inteligentes. 5. Previsão de Cenários Futuros. I. Francês, Carlos Renato Lisboa. Orientador. II Título.

CDD 22. ed. 610.4.16

DEDICATÓRIA

Aos meus Pais Waldemar e Odinéa pelo grande incentivo e exemplo para a minha educação desde o início. À minha esposa Mara por ser uma companheira eterna e sempre me motivar e apoiar. E por último, mas não menos importante, à Samara que nos faz recompensados de todos os esforços da caminhada com a sua felicidade, luz e seu jeito meigo de ser, simplesmente SAMARA.

AGRADECIMENTOS

Primeiramente a DEUS, que mesmo em todas as suas formas de ser sempre está presente em todos os momentos da caminhada, mesmo nos mais difíceis, e nunca nos deixando sós.

Aos meus Pais que sempre me proporcionaram oportunidades para estudar e nunca deixaram de acreditar que um mundo melhor com pessoas melhores se constrói com educação. Obrigado meu Pai pela sua perseverança em mostrar-me o caminho e obrigado minha Mãe pelo seu exemplo de vida e de luta por uma educação melhor que nunca me esquecerei e é fonte de orgulho. Obrigado também aos meus irmãos, que de uma forma ou outra me motivaram.

Aos meus tesouros Mara e Samara, que com todo o amor, compreensão e incentivo de vocês torna cada dia especial e sem o qual esse trabalho não seria possível de se realizar. Do fundo do meu coração registro o meu muito obrigado.

Ao meu orientador e amigo, Renato Francês, que nunca mediu esforços para ajudar e me proporcionou uma orientação de altíssimo nível com sua visão de pesquisa que consegue olhar alguns passos à frente e decidir qual o melhor caminho a trilhar. Obrigado Renato, não só pela boa orientação e apoio deste trabalho mas também pelas oportunidades oferecidas em participação de projetos de pesquisa o que me proporcionou um ganho de experiência e conhecimento ímpar na condução e gerência do processo de pesquisa e desenvolvimento.

Aos amigos do LPRAD, Ádamo, Diego, Marcelino, Edvar, James, Liviane, Ney, Fábio, etc... pela amizade, alegria e conhecimento disponibilizado durante esses anos, além das conversas extremamente produtivas e pelo ótimo convívio que vocês me proporcionaram neste laboratório.

Ao Programa de Pós-Graduação em Engenharia Elétrica que através de seus professores e pessoal técnico, contribuíram diretamente e indiretamente para a execução deste trabalho.

Aos engenheiros da CELPA, Vanja, Pedro e Tupiassú, que nunca mediram esforços para repassar seus valiosos conhecimentos sobre processos de previsão, consumo e mercado de energia elétrica.

À Universidade Federal do Pará e posteriormente à Universidade Federal do Oeste do Pará pela liberação das minhas atividades acadêmicas durante o período de realização deste trabalho como forma de incentivo ao processo de qualificação docente.

À CAPES, pelo apoio financeiro dado a este trabalho.

ÍNDICE

| | |
|--|-----|
| LISTA DE FIGURAS | IX |
| LISTA DE ABREVIATURAS | X |
| RESUMO | XI |
| ABSTRACT | XII |
| 1. INTRODUÇÃO..... | 13 |
| 2. TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL..... | 17 |
| 2.1 - <i>CONSIDERAÇÕES INICIAIS</i> | 17 |
| 2.2 – <i>INTELIGÊNCIA ARTIFICIAL</i> | 17 |
| 2.3 – <i>REDES NEURAIAS ARTIFICIAIS</i> | 19 |
| 2.3.1 – <i>PERCEPTRON MULTICAMADAS</i> | 21 |
| 2.3.2 – <i>ALGORITMO DE TREINAMENTO BACKPROPAGATION</i> | 23 |
| 2.4 – <i>ALGORITMOS GENÉTICOS</i> | 26 |
| 2.4.1 – <i>TERMINOLOGIA</i> | 27 |
| 2.4.2 – <i>COMPONENTES DE UM AG</i> | 28 |
| 2.4.2.1 – <i>REPRESENTAÇÃO DO INDIVÍDUO</i> | 28 |
| 2.4.2.2 – <i>GERAÇÃO DA POPULAÇÃO INICIAL</i> | 29 |
| 2.4.2.3 – <i>FUNÇÃO DE APTIDÃO</i> | 29 |
| 2.4.2.4 – <i>MÉTODO DE SELEÇÃO</i> | 30 |
| 2.4.2.5 – <i>OPERADORES GENÉTICOS</i> | 31 |
| 2.4.2.6 – <i>VALORES DE PARÂMETROS</i> | 33 |
| 2.5 – <i>SISTEMAS HÍBRIDOS INTELIGENTES</i> | 33 |
| 2.6 - <i>CONSIDERAÇÕES FINAIS</i> | 36 |
| 3. TRABALHOS RELACIONADOS | 37 |
| 3.1 - <i>CONSIDERAÇÕES INICIAIS</i> | 37 |
| 3.2 – <i>REDES NEURAIAS ARTIFICIAIS PARA PREVISÃO DE SÉRIES TEMPORAIS</i> | 37 |
| 3.3 – <i>ALGORITMOS GENÉTICOS PARA PREVISÃO DE SÉRIES TEMPORAIS</i> | 40 |
| 3.4 – <i>SISTEMAS HÍBRIDOS NEURO-GENÉTICOS PARA PREVISÃO DE SÉRIES TEMPORAIS</i> | 41 |
| 3.5 - <i>CONSIDERAÇÕES FINAIS</i> | 43 |

| | |
|---|-----|
| 4. UM FRAMEWORK PARA A PREVISÃO DE CENÁRIOS FUTUROS: APLICAÇÕES DE SISTEMAS HÍBRIDOS NEUROGENÉTICOS EM SISTEMAS ELÉTRICOS DE POTÊNCIA | 44 |
| 4.1 - CONSIDERAÇÕES INICIAIS | 44 |
| 4.2 – PREVISÃO DE CENÁRIOS..... | 47 |
| 4.3 – CONTEXTUALIZAÇÃO DA PROPOSTA DE CRIAÇÃO DO FRAMEWORK | 50 |
| 4.4 – MODELO HÍBRIDO NEURO-GENÉTICO | 54 |
| 4.4.1 – MÓDULO PREVISOR VIA RNA | 54 |
| 4.4.2 – MÓDULO PREVISOR DE CENÁRIOS..... | 59 |
| 4.4.3 - VANTAGENS DA ABORDAGEM PROPOSTA..... | 62 |
| 4.5 – CONSIDERAÇÕES FINAIS | 63 |
| 5 – ESTUDO DE CASO: GERAÇÃO DE CENÁRIOS DE CONSUMOS DE ENERGIA ELÉTRICA..... | 65 |
| 5.1 – CONSIDERAÇÕES INICIAIS..... | 65 |
| 5.2 – CONTEZTUALIZAÇÃO DA ESTRATÉGIA PROPOSTA..... | 65 |
| 5.3 – PROCESSO DE COMERCIALIZAÇÃO DE ENERGIA ELÉTRICA NO BRASIL..... | 68 |
| 5.4 – APLICAÇÃO DA ESTRATÉGIA PROPOSTA..... | 70 |
| 5.5 – PREVISÃO DE CONSUMO PARA A ENERGIA REQUERIDA TOTAL..... | 72 |
| 5.5.1 – PREVISÃO COM O USO DE MÉTODOS DE REGRESSÃO..... | 74 |
| 5.5.2 – PREVISÃO COM O USO DE RNAS..... | 76 |
| 5.5.3 – PREVISÃO COM O USO DE RNAS MODELADAS ATRAVÉS DOS CENÁRIOS..... | 78 |
| 5.5.4 – AVALIAÇÃO DOS RESULTADOS DE PREVISÃO | 79 |
| 5.5.5 – GERAÇÃO DOS CENÁRIOS DE PREVISÃO..... | 84 |
| 6 – CONCLUSÕES E TRABALHOS FUTUROS..... | 94 |
| 7 – REFERÊNCIAS BIBLIOGRÁFICAS | 100 |
| ANEXO A RESULTADOS DAS SIMULAÇÕES PARA A CEMAT..... | 107 |
| ANEXO B TABALHOS ACEITOS / PUBLICADOS | 118 |

LISTA DE FIGURAS

| | |
|--|----|
| Figura 2.1 – Arquitetura de uma rede MLP <i>feedforward</i> | 22 |
| Figura 2.2 - Arquitetura de uma rede MLP recorrente..... | 22 |
| Figura 2.3 - Fases do Algoritmo <i>Backpropagation</i> | 23 |
| Figura 2.4 – Diferentes paradigmas e métodos se complementam | 34 |
| Figura 2.5 - Esquema do Modelo Híbrido de Função | 34 |
| Figura 2.6 - Esquema do Modelo Híbrido Intercomunicativo | 35 |
| Figura 2.7 – Esquema do Modelo Híbrido Polimórfico..... | 35 |
| Figura 4.1 – Arquitetura do Framework Proposto | 45 |
| Figura 4.2 – Rede MLP para a previsão de séries temporais | 56 |
| Figura 4.3 – Esquema do processo de aprendizagem supervisionada..... | 58 |
| Figura 5.1 – Autocorrelação e Correlação Parcial da 1 ^a , 2 ^a e 3 ^a diferenciação da série | 73 |
| Figura 5.2 – Histórico do consumo de energia de 1991 a 2006..... | 73 |
| Figura 5.3 – Arquitetura da RNA para histórico do consumo de energia de 1991 a 2006..... | 77 |
| Figura 5.4 – Arquitetura da RNA Modelada com Cenários..... | 79 |
| Figura 5.5 – Valores reais e estimados de Jan/05 a Dez/06 do consumo de energia..... | 80 |
| Figura 5.6 – Valores previstos de consumo, utilizando modelo de regressão..... | 81 |
| Figura 5.7 – Valores previstos de consumo, empregando-se RNA | 81 |
| Figura 5.8 – Valores previstos de consumo, empregando-se RNA, para os anos de 2006..... | 82 |
| Figura 5.9 – Valores previstos de consumo, utilizando RNA modelada por meio de cenários | 83 |
| Figura 5.10 – Valores previstos de consumo, utilizando RNA modelada por meio de cenários | 84 |
| Figura 5.11 – Valores das metas de aumento do consumo para 2006 | 87 |
| Figura 5.12 – Valores dos cenários de consumos para janeiro a dezembro de 2005..... | 88 |
| Figura 5.13 – Valores das metas de aumento do consumo para 2006, caso 2..... | 88 |
| Figura 5.14 – Valores dos cenários de consumos para julho a dezembro de 2005..... | 89 |
| Figura 5.15 – Valores das metas de diminuição do consumo para 2006, caso 3..... | 90 |
| Figura 5.16 – Valores dos cenários de consumos para janeiro a dezembro de 2005..... | 91 |

LISTA DE ABREVIATURAS

| | |
|-------|---|
| RNA | Rede Neural Artificial |
| MLP | Perceptron Multi-Camada |
| AG | Algoritmo Genético |
| IA | Inteligência Artificial |
| SHI | Sistema Híbrido Inteligente |
| ARIMA | Autoregressivo Integrado de Médias Móveis |
| ARMA | Autoregressivo de Médias Móveis |
| CELPA | Centrais Elétricas do Pará |
| CEMAT | Centrais Elétricas Matogrossenses |

Resumo

No contexto da previsão de séries temporais, é grande o interesse em estudos de métodos de previsão de séries temporais que consigam identificar as estruturas e padrões existentes nos dados históricos, possibilitando gerar os próximos padrões da série. A proposta defendida nesta tese é a de desenvolvimento de um framework que utilize ao máximo as potencialidades das técnicas de previsão (redes neurais artificiais) com as técnicas de otimização (algoritmos genéticos) em um sistema híbrido intercomunicativo que aproveite bem as vantagens de cada uma dessas técnicas para a geração de cenários futuros que possam mostrar, além das previsões normais com base nos valores históricos, percursos alternativos das curvas das séries temporais analisadas.

Palavras-chave: Previsão de Séries Temporais; Redes Neurais Artificiais; Algoritmos Genéticos; Sistemas Híbridos Inteligentes; Previsão de Cenários Futuros.

Abstract

In the context of time series forecasting, is great the interest in studies of forecasting methods of time series that can identify existing structures and patterns in historical data, allowing generate the next patterns of the series. The proposal defended in this thesis is the development of a framework that uses the full potential of forecasting techniques (neural networks) with the optimization techniques (genetic algorithms) in a hybrid system that well enjoy the advantages of each of these techniques to the generation of future scenarios that can show, in addition to normal forecasts based on historical values, alternative pathways of the curves of time series analyzed.

Keywords: Time Series Forecasting; Artificial Neural Network; Genetic Algorithms; Intelligent Hybrid Systems; Future Scenarios Forecasting.

1. Introdução

O setor elétrico representa uma das mais importantes peças da economia nacional. O desenvolvimento deste setor através de investimentos e pesquisas é de fundamental importância para a configuração de uma economia próspera, disponibilizando força motriz para a indústria, comércio e serviços. Quando se foca na região amazônica, além da contribuição para o desenvolvimento regional, o setor elétrico, através do Programa Nacional de Universalização do Acesso e Uso da Energia Elétrica (Luz para Todos), contribui intensamente para o desenvolvimento social e econômico em comunidades de baixa renda, favorecendo a redução da pobreza e o acesso a serviços como saúde e educação.

Para as empresas de geração e distribuição de energia, o dimensionamento da variável carga (energia elétrica requerida) se torna fundamental no planejamento das operações elétricas, nos estudos de ampliação e reforço da rede básica de geração e distribuição de energia elétrica. Deste modo, o conhecimento sobre o seu mercado de atuação é de extrema importância para as empresas distribuidoras de energia elétrica, pois quanto mais conhecimento sobre o comportamento das previsões e tendências desses mercados, mais otimizadas serão as compras de energia pelas distribuidoras e melhor será a adequação do sistema elétrico para atender consumidores, quando determinadas demandas se concretizarem em um tempo futuro.

Além disso, utilizando as estratégias de prospecções, como as propostas neste trabalho, as concessionárias de energia elétrica podem prever de maneira satisfatória a compra e venda de energia baseada na demanda futura e nas relações de preços apresentadas pelos fornecedores no mercado elétrico brasileiro, o que pode levar a uma economia financeira substancial, em função da diminuição da diferença entre a quantidade de energia comprada e consumida.

A investigação de métodos, técnicas e ferramentas que auxiliem nos processos decisórios das empresas distribuidoras de energia elétrica têm despertado grande interesse das pesquisas operacionais deste setor e a área de previsão tem sido elemento chave neste processo, uma vez que qualquer decisão depende fortemente dos eventos que a antecedem. Desta forma, é de grande interesse o estudo de métodos de previsão de

séries temporais que consigam identificar as estruturas e padrões existentes nos dados históricos e que sejam capazes de gerar os próximos padrões da série, principalmente no que se refere à previsão de consumo (energia requerida) para uma dada região atendida por uma distribuidora de energia.

O campo da previsão de séries temporais foi e ainda continua sendo uma das áreas de intensa investigação pela comunidade científica, devido a suas inúmeras aplicações nos mais diversos setores de atividades acadêmicas, industriais e comerciais. Uma grande variedade de técnicas tem sido desenvolvidas e empregadas com relativas vantagens e desvantagens de acordo com cada tipo de aplicação. Neste contexto, pode-se apontar a área de previsão de carga em sistemas elétricos de potência como um dos ramos intensamente investigados e, por esse motivo, utilizado como domínio de aplicação da metodologia proposta neste trabalho.

Uma situação ideal para a realização de previsões seria o conhecimento das equações que modelam os mecanismos responsáveis pela geração das séries temporais. No entanto, em muitas situações reais essas informações não estão disponíveis, e não se tem condições ideais para construir equações que governem o comportamento das variáveis de interesse. Quando isso acontece, o usual é utilizar uma abordagem baseada em modelos, na qual se tenta identificar ou aproximar o processo gerador dos dados.

Nas últimas décadas, problemas de previsão de séries temporais têm sido investigados intensamente com a utilização das Redes Neurais Artificiais. Essa tendência se baseia no fato de que essas redes possuem algumas características bastante atraentes para a análise de previsão de séries temporais e que não são encontradas nos métodos estatísticos convencionais utilizados nesses problemas. Algumas dessas características residem no fato de que as Redes Neurais Artificiais possuem a capacidade de reconhecer padrões em sistemas complexos, não-lineares e com quantidade razoável de ruído, além da sua capacidade de generalização, o que a torna um modelo ideal para problemas onde a quantidade de dados históricos é de certa forma limitada.

O processo de tomada de decisão em situações de previsão de séries temporais pode ser melhorado com a utilização da elaboração e análise de cenários futuros, onde a previsão da série temporal é composta por um conjunto de previsões que podem mostrar a influência do domínio de aplicação ou tendências de alteração do comportamento

futuro da série temporal, visualizando-se situações que podem variar de estados otimistas (maximização dos valores da série) a pessimistas (minimização dos valores da série).

Em determinados domínios, como é o caso da geração de cenários futuros de séries temporais, pode-se identificar a necessidade de abordar o problema de formas diferentes que requerem a combinação de diferentes tipos de processamentos, levando a criação e a modelagem de sistemas híbridos inteligentes para a solução do problema. Nesse contexto, a utilização dos sistemas híbridos tem se tornado ferramentas importantes, pois tenta-se unir duas ou mais abordagens, de forma que as vantagens de cada abordagem sejam somadas, enquanto que suas desvantagens sejam subtraídas do sistema híbrido resultante da união das abordagens.

Esta proposta se baseia na concepção e na construção de um framework baseado em sistema híbrido inter-comunicativo neurogenético para a geração de cenários futuros, tendo como locus de aplicação a previsão de consumo de energia das concessionárias Centrais Elétricas do Pará – CELPA.

O problema abordado nesta tese é baseado em uma demanda do mundo real, cujo objetivo principal é realizar previsão do consumo de energia de uma dada região, de modo que os especialistas do domínio possam adequar o sistema elétrico para atender os consumidores, quando tais demandas se concretizarem no futuro. Assim, baseado no histórico das medidas do sistema (principalmente nas informações sobre o consumo), deseja-se obter uma prospecção das necessidades futuras, fornecendo informações que dêem suporte para que as concessionárias de energia elétrica possam estimar, de maneira satisfatória, a compra de energia baseado em suas reais necessidades. Tal possibilidade proporciona à concessionária a capacidade de otimizar as relações de preços apresentadas pelos fornecedores do Brasil, o que pode levar a uma economia financeira substancial, em função da diminuição da diferença entre a quantidade de energia comprada e consumida, ampliando o seu potencial competitivo no mercado.

Para um melhor entendimento dos temas aqui tratados, essa proposta foi organizada conforme é apresentado a seguir.

No capítulo 2, são apresentadas as técnicas de inteligência artificial empregadas para a previsão de séries temporais e geração de cenários futuros utilizada neste

trabalho. Também é ilustrada uma breve apresentação dos conceitos básicos de sistemas híbridos inteligentes e suas formas de acoplamento.

No capítulo 3, são apresentados alguns trabalhos mais relevantes, encontrados na literatura, os quais serviram como base e ponto de apoio para as investigações propostas nesta tese.

No capítulo 4, é apresentada a proposta desta tese que se baseia na construção de um framework baseada em sistema híbrido inter-comunicativo neurogenético para a geração de cenários.

No capítulo 5, é apresentada a contextualização da estratégia proposta e uma breve introdução sobre o processo de comercialização de energia elétrica no Brasil, em seguida são apresentados os modelos do framework proposta na aplicação de um estudo de caso de previsão de energia elétrica da Concessionária de Energia Elétrica do Estado do Pará (CELPA), depois a avaliação dos resultados de previsão e, finalmente, simulações de geração de cenários.

Para finalizar, no capítulo 6, são mostradas as principais contribuições desta tese e os trabalhos futuros.

2. Técnicas de Inteligência Artificial

2.1. Considerações iniciais

Este capítulo descreve um conjunto de técnicas de inteligência artificial (IA) empregadas para a previsão de séries temporais e geração de cenários. É apresentado primeiramente um panorama geral dos paradigmas de IA e posteriormente é realizada uma breve introdução das técnicas empregadas neste trabalho, as redes neurais artificiais e os algoritmos genéticos. Inclui-se também uma breve apresentação dos conceitos básicos de sistemas híbridos inteligentes e suas formas de acoplamento.

2.2. Inteligência Artificial

A busca por sistemas artificiais que apresentam algum tipo de comportamento inteligente, similar ao exibido por muitos sistemas biológicos (incluindo seres humanos), sempre fascinou muitos cientistas. Os sistemas biológicos são resultado de um longo processo de evolução natural, e apresentam características como adaptabilidade, tolerância a falhas e robustez a variações ambientais. Tais características são bastante desejáveis em uma grande variedade de problemas das mais diversas áreas de conhecimento, levando diversos pesquisadores a propor estratégias que procuram emular alguns dos aspectos observados em sistemas biológicos naturais. Neste contexto e com o intuito de desvendar os mistérios relacionados à inteligência, surgiu na década de 50 a IA [Russel e Norvig, 2003].

A IA compreende paradigmas computacionais que procuram desenvolver sistemas que apresentam alguma forma de inteligência similar à exibida por determinados sistemas biológicos. Alguns dos paradigmas que compõem a IA foram de fato inspirados em sistemas biológicos (como as redes neurais artificiais e os algoritmos genéticos), enquanto que outros, apesar de não terem inspiração biológica, tentam gerar sistemas que produzam algum tipo de comportamento próximo ao observado em sistemas naturais (como por exemplo, o raciocínio aproximado dos sistemas nebulosos). A forma como o conhecimento serviu de inspiração para a modelagem computacional da inteligência deu origem aos paradigmas que compõem a IA, onde pode-se destacar como os principais:

Paradigma Simbólico: consiste de um conjunto de símbolos que formam estruturas e um conjunto de regras e processos. Quando o conjunto de regras e processos é aplicado no conjunto de símbolos o sistema produz novas estruturas. Os símbolos têm significados semânticos e podem representar conceitos ou objetos. Para lidar com estes conceitos usa-se a lógica proposicional e a lógica de predicados o que permite a solução de problema usando um sistema baseado em regras. Assim um sistema simbólico é capaz de resolver problemas que envolvem dados e as regras sobre estes dados. Para saber mais consulte [Russel e Norvig, 2003] e [Resende, 2003].

Paradigma Conexionista: tem como premissa a suposição de que o comportamento inteligente está relacionado com a dinâmica das conexões entre pequenos nós denominados neurônios, onde tal dinâmica é capaz de representar o conhecimento. Diferentemente do paradigma simbólico, no modelo conexionista o estado dos neurônios representam um conceito ou um objeto e a dinâmica que leva à representação do conceito ou objeto é que estabelece as regras sobre tais objetos e conceitos. Na prática, os dois paradigmas podem se juntar para formar um terceiro paradigma, uma mistura do sistema simbólico com um sistema Conexionista [Linden, 2008]. Para saber mais consulte [Braga et al., 2007] e [Haykin, 1999].

Paradigma Evolutivo: este paradigma, diferentemente do convencional, não exige, para resolver um problema, o conhecimento prévio de uma maneira de encontrar uma solução. Este paradigma é baseado em mecanismos evolutivos encontrados na natureza, tais como a auto-organização e o comportamento adaptativo. Estes mecanismos foram descobertos e formalizados por Darwin em sua teoria da evolução natural, segundo a qual, a vida na terra é o resultado de um processo de seleção, pelo meio ambiente, dos mais aptos e adaptados, e por isto mesmo com mais chances de reproduzir-se. A diversidade da vida, associada ao fato de que todos os seres vivos compartilham uma bagagem genética comum, pelo menos em termos de seus componentes básicos, é um exemplo eloqüente das possibilidades do mecanismo de evolução natural [Farmer et. al., 1983][Golberg et. al., 1988]. Para saber mais consulte [Sumathi et al., 2008]

Paradigma Nebuloso: A teoria dos conjuntos nebulosos é o modelo mais tradicional para o tratamento da informação imprecisa e vaga. Este paradigma, introduzido em [Zadeh, 1965], tem por objetivo permitir graduações na pertinência de um elemento a uma dada classe, ou seja de possibilitar a um elemento de pertencer com

maior ou menor intensidade àquela classe. Basicamente, isso se faz quando o grau de pertinência de um elemento ao conjunto, que na teoria dos conjuntos “clássica” assume apenas os valores 0 ou 1, passa a ser dado por um valor no intervalo dos números reais $[0, 1]$. Para saber mais consulte [Pedrycz e Gomide, 2007].

2.3. Redes Neurais Artificiais

As Redes Neurais Artificiais (RNA) tem sido empregadas com sucesso para resolver problemas diferentes e de características gerais, tendo como área de aplicação uma gama de bastante extensa. Entre as aplicações usuais das RNAs têm-se: reconhecimento e classificação de padrões, controle, agrupamento, aproximação de funções, otimização, processamento de sinais, análise de imagens, bioinformática, mineração de dados e, o foco deste trabalho, previsão de séries temporais [Braga et al.,2007], [Haykin, 1999].

Séries temporais são representadas por uma sequência de medições relativas a um determinado evento e organizadas cronologicamente, que aparentemente não seguem nenhuma lei ou tendência. No entanto, em séries temporais relacionadas a fenômenos naturais, econômicos ou físicos, pode-se notar certas características que se repetem após determinado período de tempo (sazonalidade) e outras que se mantêm durante o intervalo considerado (tendências), mesmo que não obedeçam a padrões lineares [Box et al., 1994].

Em aplicações de previsões de séries temporais, estimar um valor futuro com um certo grau de precisão é o objetivo almejado. Para que seja possível prever os valores futuros é necessário que se disponha de uma memória histórica de dados ocorridos anteriormente. Todavia, o conjunto de dados, por si só, pode tornar a tarefa de previsão difícil ou até mesmo impraticável para determinadas técnicas pelo alto grau de complexidade embutido na série de dados. Para isso, é necessário a utilização de algoritmos, técnicas ou métodos de previsão de séries temporais, que consigam identificar ou aproximar o processo gerador dos dados da séries, ou seja, consigam identificar as estruturas e padrões existentes nos dados históricos e com isso ser capazes de gerarem os próximos padrões da série.

As RNAs constituem uma ferramenta de grande importância na atualidade, por sua capacidade de “aprender” padrões através de treinamento, o que torna seu uso importante no desenvolvimento da Inteligência Artificial. A principal vantagem de uma rede neural é a sua capacidade de aproximar relações funcionais, particularmente

quando as relações não são bem definidas e/ou são não-lineares, o que torna difícil a utilização de métodos convencionais para a tentativa de prever as variações futuras dessas relações [Cortez, 2002], [Zhang et al.,1998].

Uma RNA é um modelo computacional, inspirado biologicamente no funcionamento/atividade do cérebro, formado por elementos de processamento (chamados de neurônios) e conexões entre esses elementos, com pesos ligados a essas conexões, formando assim uma estrutura neural. Sobre essa estrutura, são implementados algoritmos de aprendizado que ajustam os parâmetros da estrutura de acordo com o tipo de conhecimento a ser codificado na rede. RNAs são chamadas de modelos conexionistas devido à grande importância das conexões entre os neurônios para o processamento da rede. É importante ressaltar que os pesos das conexões são os responsáveis pelo “conhecimento” codificado nas RNAs.

As RNAs possuem algumas características que as tornam alvos de intensas pesquisas, tais como:

- **Aprendizado e Adaptação:** uma das propriedades mais importantes de uma RNA é a capacidade de aprender por intermédio de exemplos e realizar inferências sobre o que aprendeu, melhorando gradativamente o seu desempenho [Braga et al., 2007];
- **Generalização:** RNAs são capazes de generalizar o seu conhecimento a partir de exemplos anteriores e com isso lidar com informações nunca antes vista no conjunto de treinamento;
- **Processamento Paralelo:** característica de processamento intrínseca das RNAs e que foi herdada da sua inspiração biológica, o cérebro;
- **Robustez:** capacidade das RNAs em prover uma saída coerente mesmo sendo alimentadas com dados ruidosos ou incompletos.

Existe uma variedade bastante razoável de modelos de RNAs que executam vários tipos de tarefas. A tarefa de previsão de séries temporais envolve a construção de modelos a partir de dados históricos em um determinado período. Assim, o emprego de RNAs na previsão de séries temporais tem sido enormemente utilizado pela sua capacidade de adaptação ao ambiente de previsão e, assim, modelar o comportamento

da série através do aprendizado dos dados históricos; provendo assim um mapeamento entre as variáveis de entrada e a previsão na saída da rede [Tzafestas e Tzafestas, 2001]. Outro fator favorável às RNAs está relacionado ao fato de não haver para elas grande limitação no número de variáveis de entrada, bem como ser possível aplicá-las em séries não-estacionárias¹ sem o uso de transformações para obter comportamento estacionário [Braga et al., 2007], [Ferreira, 2006].

Neste trabalho, será focada uma estrutura particular das RNAs, a rede Perceptron Multi-camadas (*MultiLayer Perceptron* – MLP), devido a mesma ser amplamente empregada e aceita pela comunidade acadêmica na utilização em aplicações de previsão [Zhang et al., 1998]; [Tzafestas e Tzafestas, 2001];[Adya e Collopy 1998].

2.3.1. Perceptron Multicamadas

A arquitetura da rede MLP (figura 2.1) é composta por neurônios conectados, seguindo uma formação em camadas. Essas conexões são responsáveis por propagar as entradas da RNA. As unidades de entrada, que compõem essa camada, têm o objetivo de difundir o sinal inicial sem nenhuma modificação para a segunda camada. Os dados são apresentados à rede pela camada de entrada, são processados pelas camadas subsequentes e por último a rede gera uma saída para a informação que lhe foi apresentada. É importante salientar que se cada camada de neurônios é somente ligada à camada subsequente (menos a camada de saída, que só recebe ligações) e a informação trafegar em um único sentido, a rede é chamada de *feedforward*, figura 2.1. Caso existam conexões de retorno entre as camadas, posterior para a anterior, a rede é chamada de recorrente, figura 2.2.

Redes MLP apresentam um poder computacional maior do que aquele apresentado pelas redes perceptron que possuem uma única camada [Haykin, 1999], [Braga et al., 2007], [Kasabov, 1996]. Tal poder computacional é conseguido com a adição de uma ou mais camadas intermediárias entre a entrada e a camada de saída. Em [Cybenko, 1988], foi provado que são necessárias, no máximo, duas camadas intermediárias, com um número suficiente de unidades por camada que é definido de forma empírica, para se aproximar qualquer função, seja ela linearmente separável ou

¹ - Uma série temporal é dita não-estacionária se suas propriedades estatísticas mudam com o tempo.

não. Também foi provado que apenas uma camada intermediária é suficiente para aproximar qualquer função contínua.




Figura 2.1. Arquitetura de uma rede MLP *feedforward*.




Figura 2.2. Arquitetura de uma rede MLP recorrente.

Assim, a definição da arquitetura de uma rede MLP apresenta três características distintas:

- **Definição da Estrutura:** determinação do número de camadas intermediárias e das quantidades de neurônios em cada uma dessas camadas;
- **Tipo de Conexão:** determinação do tipo de conexões entre as camadas da rede (*feedforward* ou recorrente);
- **Função de Ativação:** determinação das funções de ativação dos neurônios. Os neurônios da mesma camada apresentam os mesmos tipos de funções de

ativação, enquanto que neurônios de camadas diferentes podem ou não, dependendo do problema de aplicação, apresentar os mesmos tipos dessas funções.

2.3.2. Algoritmo de Treinamento *Backpropagation*

Existem vários algoritmos para treinar redes MLP, porém um dos mais conhecidos difundidos é o algoritmo *backpropagation*. A maioria dos algoritmos de aprendizado para as redes MLPs utilizam variações do algoritmo *backpropagation* [Haykin, 1999], [Kosko, 1992], [Bishop, 1995], [Braga et al., 2007].

O *backpropagation* é um algoritmo supervisionado de propósito geral que utiliza pares de entrada e saída para, através de um mecanismo de correção de erros, ajustar os pesos da rede. O treinamento possui duas fases que percorrem a rede em sentidos opostos, conforme ilustrado na figura 2.3.




Figura 2.3. Fases do Algoritmo *Backpropagation*.

Na fase *forward*, um dado padrão é apresentado à rede, fazendo com que as ativações para este padrão sejam propagadas pela rede até a última camada, onde é gerada uma saída daquele padrão de entrada. Na fase *backward* a saída gerada pela rede é confrontada com a saída desejada para o referido padrão de entrada, sendo esta informação utilizada para atualizar os pesos das conexões entre as unidades. A fase *forward* pode ser resumida nos seguintes passos:

Passo 1. O vetor de entrada \mathbf{x} , tendo como saída desejada o vetor de saída \mathbf{d} , é apresentado à primeira camada da rede.

Passo 2. Os sinais gerados pela primeira camada são propagados através das camadas subsequentes da rede, gerando assim a saída da rede.

Passo 3. As saídas produzidas pelos neurônios da última camada são comparadas com as saídas desejadas para que o erro da rede seja calculado.

A fase *backward*, por sua vez, pode ser resumida nos seguintes passos:

Passo 1. Os pesos entre a camada intermediária e a camada de saída são ajustados de acordo com o erro gerado pela saída da rede.

Passo 2. O erro para as camadas intermediárias e de saída é propagado até a camada de entrada. O erro para os neurônios das camadas intermediárias é calculado utilizando os erros dos neurônios conectados a eles, da camada posterior à camada intermediária atual, ponderados pelos pesos das suas conexões, iniciando pela camada de saída.

O algoritmo *backpropagation*, que faz uso destas duas fases, pode ser descrito da seguinte forma:

Passo 1. Inicializar os pesos da rede.

Passo 2. O vetor de entrada \vec{x}_p é apresentado à rede. Também é apresentada a resposta desejada d_p para o padrão representado por \vec{x}_p .

Passo 3. Os sinais gerados pela primeira camada são propagados através das camadas subsequentes da rede, gerando assim a saída da rede.

Passo 4. O erro correspondente à diferença entre o vetor de saída desejada e o vetor de saída real é calculado através da determinação da função custo E_p . Se o valor de E_p for menor que um limiar ε preestabelecido, o processo de aprendizagem termina, chegando ao **Passo 8**. Caso contrário, segue-se para o **Passo 4**. Existem alguns tipos diferentes de funções custo, entretanto a mais utilizada é o mínimo erro quadrado definido na Equação 2.1 a seguir:

$$E_p = \frac{1}{2} \sum_{j=1}^n (d_{pj} - o_{pj})^2 \quad (2.1)$$

onde n é o número de saídas da rede, o_{pj} é a resposta fornecida pela unidade de saída u_j e d_{pj} corresponde à resposta desejada para esta mesma saída.

Passo 5. Neste passo, faz-se a atualização dos pesos das conexões. O processo ocorre na direção da camada de saída para a camada de entrada, camada após camada. O ajuste dos pesos é dado pela Equação 2.2:

$$\Delta w_{ij} = \eta \delta_j o_i \quad (2.2)$$

onde η representa a taxa de aprendizagem, o_i é a resposta da unidade i que se conecta à unidade j e δ_{pj} corresponde ao erro ocorrido entre a resposta desejada e a resposta fornecida pela unidade j para um dado padrão p do conjunto de treinamento. No caso dos neurônios da camada de saída, o valor de δ_{pj} é dado pela Equação 2.3:

$$\delta_{pj} = f_j'(net_{pj})(d_{pj} - o_{pj}) \quad (2.3)$$

Quando a função de ativação f_j utilizada é a função sigmóide, a Equação 2.3, após o cálculo da primeira derivada f_j' , torna-se:

$$\delta_{pj} = o_{pj}(d_{pj} - o_{pj})(1 - o_{pj}) \quad (2.4)$$

Passo 6. Para as unidades j nas camadas intermediárias, não há como computar diretamente os ajustes em função do erro $(d_{pj} - o_{pj})$, sendo estes pesos calculados em função dos erros δ_k , observados nas unidades das camadas subsequentes, como segue:

$$\delta_{pj} = f_j'(net_{pj}) \sum_k w_{jk} \delta_{pj} \quad (2.5)$$

que, no caso da função sigmóide, torna-se:

$$\delta_{pj} = o_j(1 - o_j) \sum_k w_{jk} \delta_{pj} \quad (2.6)$$

Passo 7. Retornar ao **Passo 2**.

Passo 8. Fim do Treinamento.

O algoritmo *backpropagation* é poderoso, mas bastante dispendioso em termos de processamento computacional para treinamento. Isso ocorre devido ao *backpropagation* usar o método do gradiente descendente de uma função para minimizar o erro global da rede [Haykin, 1999]. Devido à utilização do método do gradiente descendente, o algoritmo *backpropagation* pode apresentar o problema denominado mínimo local, que ocorre quando o processo de aprendizado pára quando o erro se localiza numa região de mínimo local ao invés de mínimo global [Kasabov, 1996].

O algoritmo *backpropagation* apresenta muitas modificações e melhorias propostas por diversos autores, que diferem basicamente em alguns pontos, tais como: cálculo do erro, função de ativação, fórmula de atualização dos pesos. Dessas variações, as mais utilizadas são o *backpropagation* com *momentum*, Quickprop, Levenberg-Marquardt, Rprop, e Newton [Braga et al., 2007].

2.4. Algoritmos Genéticos

Um Algoritmo Genético (AG) é um método de computacional que simula o comportamento evolucionário das espécies, baseado na teoria Darwiniana, cujo objetivo é a otimização de uma dada função objetivo. Foi proposto por John Holland, em 1975, e popularizado por um de seus alunos, David Goldberg, em 1989 [Goldberb, 1989]. Esses algoritmos se destacam por possuírem facilidade de implementação computacional, inexistência de restrições quanto ao tipo de problema (função objetivo pode ser discreta ou não convexa, por exemplo) e a possibilidade de se integrar o algoritmo com aplicativos externos que calculem a função objetivo. Desta forma, a função objetivo do AG pode ser uma “caixa preta”.

Um AG é um procedimento iterativo que mantém uma população de indivíduos, onde cada um desses indivíduos é um candidato à solução de um problema específico. A cada iteração, denominada de geração, os indivíduos da população atual são avaliados quanto à sua aptidão para a solução do problema. Com base nessas avaliações, aplicam-

se alguns operadores genéticos (nomenclatura inspirada na área biológica) aos indivíduos, formando-se uma nova população, que substituirá a atual. Isto é realizado de modo que, quanto maior a aptidão de um indivíduo atual, maior será a sua influência na formação dos indivíduos da nova população.

Desta forma, com o passar do tempo, a seleção tende a fazer com que a população seja formada por indivíduos cada vez melhores (soluções cada vez mais próximas da solução ótima para o problema) [Beasley et al., 1993]. Como critério de parada do AG, geralmente, define-se um limite para o número de gerações. Dentre os indivíduos da última geração, aqueles mais aptos representam a melhor solução encontrada pelo AG. Pode-se também especificar que o AG encerrará quando for gerado algum indivíduo que satisfaça alguma condição mínima de aptidão [Linden, 2008].

O comportamento padrão dos AGs pode ser resumido nos seguintes passos:

1. Geração da população inicial de indivíduos (cromossomos);
2. Avaliação dos indivíduos de acordo com a sua aptidão;
3. Seleção dos melhores indivíduos (cromossomos mais aptos);
4. Aplicação dos operadores genéticos, gerando uma nova população (descendentes);
5. Repetição dos passos 2 a 4 até encontrar uma solução satisfatória ou que sejam executadas um número predeterminado de iterações.

A base do funcionamento de um AG são os operadores genéticos, utilizados para gerar novas soluções (gerações da população) em analogia à evolução natural. Essas operações bem como a terminologia empregada nesse método de otimização, serão descritas nas subseções a seguir.

2.4.1. Terminologia

Como o método de otimização dos AGs se baseia na teoria da evolução, é necessária a compreensão de alguns termos provenientes da área biológica e que são utilizados na programação computacional de um AG.

- Cromossomo: é formado pela estrutura de dados utilizada codificar uma solução do problema proposto e é representado como um indivíduo na população do AG, ou seja, um cromossomo representa um ponto no espaço de busca percorrido pelo AG. Cada cromossomo também possui uma aptidão associada, indicando a qualidade do cromossomo como solução do problema em questão;
- Gene: unidade de hereditariedade transmitida pelo cromossomo, o qual controla as características do organismo. Nos AGs, é um parâmetro codificado (elemento do vetor) no cromossomo;
- Genótipo: é a composição contida no genoma. Na Computação Evolucionária representa a informação contida no cromossomo ou genoma;
- Fenótipo: representa o objeto, estrutura ou organismo construído pelas informações contidas no genótipo (cromossomo decodificado);
- Alelo: é uma das formas alternativas de um gene. Em AG, representa os valores do parâmetro codificado em um gene.

2.4.2. Componentes de um AG

Os AGs possuem alguns componentes clássicos que modelam os seus parâmetros de configuração.

2.4.2.1 Representação do Indivíduo

Os indivíduos do AG, também denominados de cromossomos, representam soluções potenciais de um problema. A representação mais tradicional é a binária, na qual um indivíduo é representado por meio de uma cadeia de 0's e 1's de tamanho fixo. Para problemas nos quais a representação binária não é a mais natural e apropriada, existem outros tipos de representações que podem ser utilizadas tais como a representação com números reais [Michalewicz, 1999], [Linden, 2008].

A representação do indivíduo através da codificação binária de tamanho fixo, tem dominado a pesquisa de AGs desde o seu início. Entretanto, o bom desempenho de um AG na busca de soluções não tem relação direta com a utilização da codificação binária na modelagem da solução do problema. Pelo contrário, existem certas peculiaridades da representação binária, como os abismos de Hamming, que criam

artefatos quando se lida com otimização contínua [Linden, 2008]. Desta forma, o mais indicado é utilizar uma representação mais adequada para o problema em questão. Assim, em muitos problemas do mundo real, como é o caso da previsão de consumo de energia elétrica, o mais natural é utilizar cromossomos que representam diretamente os parâmetros sendo otimizados, como por exemplo os valores de consumos de energia em números reais, de forma que espaços de busca contínuos sejam representados de forma mais direta e, espera-se, mais eficiente pelo AG.

2.4.2.2 Tamanho e Inicialização da População

O desempenho do AG é muito sensível ao tamanho da população, pois caso este número seja pequeno demais, não haverá espaço para se obter uma variabilidade genética suficientemente grande dentro da população, tornando a busca por soluções ótimas difíceis ou até mesmo improvável. Por outro lado, caso o tamanho da população seja grande demais ocasionará *overhead* na execução do AG, tornando o processo parecido com uma busca exaustiva.

A inicialização da população, na maioria dos casos, é realizada da forma mais simples possível, fazendo-se uma escolha aleatória independente para cada indivíduo da população inicial. A inicialização aleatória, de forma geral, leva a uma boa distribuição das soluções no espaço de busca [Linden, 2008].

2.4.2.3 Função de Aptidão

A função de aptidão determina a aptidão de cada indivíduo, ou seja, a qualidade da solução por ele representada para o problema em questão; sendo a responsável por determinar se o indivíduo continuará fazendo parte da população ou não. A escolha da função de avaliação está diretamente relacionada ao domínio do problema e sua configuração deve embutir todo o conhecimento que se possui sobre o problema a ser resolvido, refletindo assim os objetivos a serem alcançados, condições e restrições impostas pelo domínio da aplicação.

2.4.2.4 Método de Seleção

Uma vez que os AGs se baseiam no princípio da seleção natural, eles devem ser capazes de identificar os indivíduos mais aptos, para que permaneçam na população durante o processo de evolução (procedimento iterativo), e os mais fracos, para que sejam excluídos do processo. Existem vários métodos que podem ser utilizados para selecionar indivíduos para formar uma nova população [Michalewicz, 1999], [Linden, 2008].

Um critério de seleção bastante comum em AG é a seleção proporcional, que consiste em selecionar os indivíduos com probabilidade proporcional à sua aptidão. Conceitualmente, a seleção proporcional é equivalente a dividir uma roleta em n partes, sendo n o número de indivíduos da população. Cada uma das partes da roleta é proporcional à aptidão do indivíduo associado aquela parte. A roleta é girada n vezes e, a cada iteração, o indivíduo indicado pelo ponteiro é selecionado para a fase de reprodução. Este método é denominado de método da roleta e é o mais simples dos métodos empregados no processo de seleção dos AG's.

Além do método da roleta existem outros esquemas capazes de simular a seleção natural dentre uma população de um AG. Outro método também bastante conhecido e empregado no processo de seleção dos AG's é o método do torneio [Faceli et al., 2011]. Este método consiste em selecionar n indivíduos através da realização de n torneios. A cada torneio, uma série de K indivíduos da população atual do AG são aleatoriamente escolhidos e o indivíduo que vencer o torneio (possuir a melhor avaliação) é selecionado para a fase de reprodução. Neste método, existe um parâmetro denominado tamanho do torneio (K) que define quantos indivíduos são selecionados aleatoriamente dentro da população para competir. O valor mínimo de K é igual a 2, pois do contrário não haverá competição, mas não há nenhum limite teórico para o valor máximo deste parâmetro [Linden, 2008].

Com o objetivo de preservar e usar na próxima geração as melhores soluções encontradas na geração atual pode-se utilizar a estratégia denominada "elitismo". Essa estratégia consiste em conservar os m_i melhores indivíduos da população na geração t , copiando-os para a geração $t+1$ sem nenhuma alteração, garantindo assim que os melhores indivíduos da geração $t+1$ sejam pelo menos iguais aos melhores indivíduos da geração anterior (no pior caso, em que nenhum melhor indivíduo seja criado). Isto permite garantir que o gráfico da avaliação do melhor indivíduo em função do número

de gerações decorridas seja uma função crescente com relação a aptidão. O restante dos indivíduos, $n_i - m_i$, são normalmente gerados por meio do método de seleção.

2.4.2.5 Operadores Genéticos

Os operadores genéticos, quando aplicados à população, geram novos indivíduos e são os principais mecanismos utilizados pelos AGs para explorar regiões desconhecidas do espaço de busca. *Crossover* e mutação são os operadores genéticos mais utilizados.

Crossover

Esse operador genético permite a troca de informações entre soluções diferentes, através da combinação das características de dois indivíduos pais, selecionados previamente pelo método da roleta por exemplo, para formar dois indivíduos filhos por meio da troca de segmentos correspondentes dos indivíduos pais. Assim como para a representação binária dos cromossomos, no esquema de representação real também existem vários tipos diferentes de *crossover*.

Um dos operadores de *crossover* mais usuais aplicáveis a cromossomos reais é o chamado *crossover* simples, o qual consiste em definir um ponto de corte dentro do cromossomo dos indivíduos pais e tomar os valores de um pai à esquerda do ponto de corte e valores do outro pai à direita do ponto de corte. Como a representação dos cromossomos é real, os pontos de corte estão localizados entre os valores reais, nunca podendo acontecer no meio de um número. No exemplo abaixo, considere os seguinte indivíduos pais representados por uma cadeia de números reais de comprimento 8:

*Pai*₁ 1.2 0.3 1.9 2.07 4.3 9.3 8.2 6.1

*Pai*₂ 4.3 2.0 8.5 9.1 8.5 1.3 2.2 9.6

Aplicando o operador *crossover* depois do terceiro valor,

*Pai*₁ **1.2 0.3 1.9** | 2.07 4.3 9.3 8.2 6.1

*Pai*₂ 4.3 2.0 8.5 | **9.1** 8.5 1.3 2.2 9.6

são gerados os seguinte indivíduos filhos:

*Filho*₁ **1.2 0.3 1.9** 9.1 8.5 1.3 2.2 9.6

O operador de *crossover* não ocorre em todos os pares selecionados. A probabilidade de aplicação do operador de *crossover* pode variar de acordo com uma taxa, conhecida como taxa de *crossover*, que historicamente tem variado entre 60% e 95% [Linden, 2008]. A não ocorrência de *crossover* implica na cópia dos cromossomos pais para a próxima geração, preservando algumas soluções da geração anterior.

Mutação

Na evolução natural, a mutação é um processo randômico em que uma parte do gene é alterada de alguma maneira para produzir uma nova estrutura genética. Em AGs, a mutação é aplicada após o *crossover* e tem como objetivo produzir variações nas características dos indivíduos da população. A mutação é aplicada a cada um dos genes representados nos cromossomos filhos resultantes do operador de *crossover*, alterando de forma aleatória o valor do gene sobre o qual é aplicado e gerando assim um novo indivíduo. Usualmente este operador é aplicado com baixa probabilidade tendo em vista de se tratar de um operador genético secundário [Beasley et al., 1993]. Estas alterações nos cromossomos provocadas pelo operador de mutação, contribui para a inserção e manutenção da variabilidade genética na população, evitando assim que a busca fique estagnada em sub-regiões do espaço de busca e possibilitando também que qualquer ponto do espaço possa ser explorado [Rezende, 2003]

Um dos operadores de mutação mais usuais aplicáveis a cromossomos reais é a chamada mutação aleatória, onde a alteração em um determinado gene é realizada com base em um valor escolhido aleatoriamente entre um intervalo fechado entre um mínimo e um máximo definidos para aquele gene. Os limites para o sorteio devem ser conhecidos a priori e são dados pelas restrições e definições do problema de aplicação, representando assim o espaço de busca para aquele gene.

Considere a representação de um indivíduo formado por uma cadeia de números reais de comprimento 8:

1.2 0.3 1.9 2.07 4.3 9.3 8.2 6.1

Aplicando o operador de mutação na quarta posição é gerado o seguinte indivíduo:

O operador de mutação pode causar uma grande variação no valor do gene sob o qual é aplicado, enfatizando a tática exploratória do AG.

2.4.2.6 Valores de Parâmetros

Dentre os parâmetros mais utilizados pelos AGs estão: o tamanho da população, o número de genes dos indivíduos, a probabilidade de aplicação dos operadores genéticos, o número de gerações e o critério de parada. Os valores para esses parâmetros são dependentes da aplicação e geralmente são definidos de forma empírica.

2.5. Sistemas Híbridos Inteligentes

O conceito de Sistema Híbrido Inteligente (SHI) é bastante amplo e pode englobar diferentes tipos de abordagens. De uma maneira mais geral, pode-se dizer que todo o sistema que integre duas ou mais técnicas diferentes de IA para a solução de um problema é um SHI.

Em SHIs, o objetivo é combinar diferentes abordagens e métodos na solução de um problema. Em geral, tenta-se unir duas ou mais abordagens, de forma que as vantagens de cada abordagem sejam somadas, enquanto que suas desvantagens sejam subtraídas do sistema híbrido resultante da união das abordagens.

Existe pelo menos duas principais razões para se usar um SHI na solução de problemas, [Kasabov, 1996]:

- Para determinados problemas não é possível encontrar uma solução que utilize apenas um único método.
- Existem alguns modelos utilizados em soluções de problemas no ramo da Inteligência Artificial (IA), que não podem ser implementados através de apenas um único método, ou sua implementação poderia apresentar resultados melhores se fossem usados mais de um método na solução do determinado problema.

Diferentes combinações entre os vários tipos de paradigmas da IA é possível em sistemas híbridos, como pode ser visto na figura 2.4. Porém, a escolha dos paradigmas

que servirão de base para um sistema híbrido depende do tipo de problema que este sistema pretende resolver. Além disso, existem várias formas de união, com diferentes graus de acoplamento.




Figura 2.4. Diferentes paradigmas e métodos se complementam

Nos SHIs, em geral, existem três formas de se unir dois paradigmas [Kasabov, 1996], [MCGARY et al., 1999], [Wermter e Sun, 2000], [Goonatilake e Khebbal, 1995],[Braga et al., 2007]:

- **Modelo Híbrido de Função:** trabalham com a composição funcional de uma técnica inteligente simples. Neste modelo, a função principal de uma dada técnica é substituída por outra técnica inteligente de processamento. A motivação para estes SHIs é a técnica da melhoria, ou seja procura-se melhorar alguma limitação da técnica principal ou otimizar sua execução. Esta situação é ilustrada na figura 2.5. Neste tipo de modelo, diferentes partes de um problema podem ser resolvidas, independentemente, por diferentes paradigmas que melhor se adaptem aos subproblemas em questão. Por exemplo, a utilização de um sistema que substitua o mecanismo de mudança de peso no processo de treinamento de uma RNA pelos operadores genéticos de um AG.



Figura 2.5. Esquema do Modelo Híbrido de Função

- **Modelo Híbrido Intercomunicativo:** os paradigmas são usados em diferentes subsistemas, os quais trabalham em colaboração para chegarem a uma solução, ou seja, os paradigmas inteligentes são independentes e estes trocam informações e realizam funções separadas para gerar soluções, conforme

ilustra a figura 2.6. Neste modelo os paradigmas se comunicam com bastante intensidade e frequência. Um exemplo deste tipo de SHI pode ser a utilização de uma RNA, treinada separadamente, como função de aptidão para um AG. A proposta de sistema híbrido abordado nesta tese se encaixa neste modelo de SHI.




Figura 2.6. Esquema do Modelo Híbrido Intercomunicativo

- **Modelo Híbrido Polimórfico:** os paradigmas são misturados em baixo nível, de tal forma que não seja possível separá-los do ponto de vista estrutural e funcional, ou seja, o primeiro paradigma contém o segundo e vice-versa. A figura 2.7 ilustra essa situação. Neste modelo, uma única arquitetura é utilizada para atingir a funcionalidade dos diferentes paradigmas integrados no sistema híbrido, possibilitando assim uma visão enriquecedora das semelhanças fundamentais entre estes paradigmas. Exemplos de híbridos polimórficos são RNAs que tentam realizar tarefas simbólicas tais como inferência passo a passo ou RNAs cujas funções fazem busca genética.




Figura 2.7. Esquema do Modelo Híbrido Polimórfico

SHIs estão recebendo atenção crescente de pesquisadores de IA, mas também possuem razões para gerar ceticismo. Vários trabalhos parecem combinar métodos de forma ad hoc, sem a preocupação em verificar a real vantagem da união de dois ou mais paradigmas [Giles et al., 1998]. Um sistema híbrido pode até possuir bom desempenho, mas isto não significa que os paradigmas originais, quando aplicados isoladamente, não sejam melhores; ou ainda, um sistema híbrido pode estar sendo usado para resolver um problema que apresenta uma solução trivial quando um determinado paradigma é

aplicado de forma isolada, e assim tenta-se complicar algo que pode ser resolvido de forma simples. Portanto, é preciso muita atenção e cuidado no uso de sistemas híbridos, para que erros como os acima não aconteçam na tentativa de se unir dois ou mais paradigmas.

2.6. Considerações Finais

Neste capítulo foram abordadas técnicas de inteligência artificial utilizadas para compor o framework proposta nesta tese. Com esse objetivo foi apresentado uma visão geral da teoria de RNAs, AGs e sistemas híbridos inteligentes. No próximo capítulo será apresentado o estudo de trabalhos correlatos que realiza um apanhado geral, para efeito de comparação com a proposta desta tese, sobre os trabalhos publicados na literatura.

3. Trabalhos Relacionados

3.1. Considerações iniciais

Neste Capítulo é apresentado um levantamento do estado da arte na área de previsão de séries temporais envolvendo as técnicas abordadas neste trabalho. São apresentados alguns trabalhos encontrados na literatura que podem servir de base e ponto de apoio para as investigações propostas nesta tese. Dentre esses trabalhos, pode-se notar que são largamente aceitas e empregadas soluções para a previsão de séries temporais, envolvendo técnicas que vão desde a aplicação de RNAs, passando pelos AGs e sistemas híbridos neurogenéticos.

Os estudos correlatos estão organizados em três categorias, a saber: aplicação de RNAs na previsão de séries temporais, aplicação de AGs na previsão de séries temporais e sistemas híbridos neurogenéticos.

3.2. Redes Neurais Artificiais para Previsão de Séries Temporais

A utilização de RNAs para a previsão de séries temporais vem sendo proposta por diversos autores, entre eles [Lu et al., 1993], [Vermaak, e Botha, 1998], [BACZYNSKI e Parol, 2004], [Kandil et al., 2006], [Akole e Tyag, 2009], [Economou, 2010] e [Bilgili., 2011], mostrando a viabilidade em utilizar esses modelos. Um grande incentivo para o uso das RNAs nesta área, está ligado a sua capacidade de reconhecer padrões em sistemas complexos, não-lineares e com quantidade razoável de ruído, capacidade essa que não é encontrada nos métodos estatísticos convencionais. Outra importante característica das RNAs é o seu poder de generalização, tornando-a um modelo ideal para problemas onde a quantidade de dados históricos é de certa forma limitada [Haykin, 1999],[Kasabov, 1996].

O projeto da RNA é de fundamental importância para o resultado obtido na previsão de séries temporais. Diferentes parâmetros, tais como os retardos temporais utilizados, o número de camadas, o número de neurônios em cada camada, a função de ativação e o algoritmo de treinamento devem ser considerados. Em muitas situações, a

metodologia de tentativa e erro deve ser utilizada para procurar a melhor configuração da rede para um problema específico. Como será visto a seguir, diversos modelos foram propostos no meio científico, identificando seus pontos fortes e suas deficiências.

Em [Zhang et al., 1998] é apresentado o estado da arte das aplicações de RNAs em problemas de previsão. Os autores realizaram uma síntese dos trabalhos publicados nessa área, ressaltando os aspectos levados em consideração no processo de modelagem das RNAs, tais como o tipo de aplicação, a metodologia da solução empregada por cada autor e o tipo de rede utilizada. O trabalho mostrou que as RNAs foram bem sucedidas na maioria das tarefas de previsão quando comparadas com técnicas clássicas de previsão, apresentado como vantagens das RNAs a capacidade de mapear funções arbitrárias e não lineares a partir dos dados históricos. Entretanto, como desvantagens, foram apontados os problemas com a dificuldade de interpretação do conhecimento da rede (comportamento caixa preta), bem como a inexistência de um formalismo que determine qual rede é melhor para cada caso, pois esse processo é ajustado empiricamente baseado em tentativa e erro. Após as análises realizadas nesta revisão, os autores chegaram à conclusão de que as RNAs apresentaram bons resultados em problemas de previsão, o que as tornam ferramentas atrativas para essas aplicações, porém como elas são extremamente dependentes da qualidade dos dados históricos, seu desempenho dependerá do tipo de problema de previsão abordado.

Outro trabalho que realizou um estudo sobre a eficácia das aplicações das RNAs em problemas de previsão foi [Adya e Collopy, 1998]. Neste trabalho os autores avaliaram um total de 48 artigos selecionados referentes a publicações sobre RNAs em aplicações de previsão e predição entre os anos de 1988 e 1994, enfocando duas principais questões. A primeira questão era referente à capacidade efetiva de predição das RNAs propostas em cada um dos artigos selecionados, avaliando desta forma, se a solução proposta era apropriada para o referido tipo de aplicação. A segunda questão era sobre a forma como as RNAs propostas em cada um dos artigos selecionados eram implementadas e simuladas, avaliando-se assim, se as simulações com as RNAs tinham sido exploradas exaustivamente por seus autores e se foram obedecidos os procedimentos de treino e validação.

Os autores chegaram a duas conclusões após as análises dos trabalhos. A primeira conclusão evidenciou que nos artigos selecionados onde os seus autores levaram em consideração a RNA apropriada para a aplicação e além disso tiveram os

devidos cuidados com a implementação e a validação das simulações, os resultados foram promissores e mostraram o potencial das RNAs em problemas de previsão e predição. A segunda conclusão evidenciou que metade dos trabalhos avaliados falharam em pelo menos uma das questões citadas acima, o que levantou suspeita sobre a qualidade dos resultados desses trabalhos analisados devido a forma de avaliação empregada que não evidenciou corretamente a eficácia das RNAs aplicadas.

Em [Steinherz et al., 2001], foi realizada uma investigação sobre a utilização de RNAs para aplicações de curto prazo (variando de horas até dias) de previsão de energia elétrica. Foram analisados trabalhos publicados entre os anos de 1991 e 1999, focando nos tópicos de modelagem e avaliação das RNAs utilizadas. O trabalho conclui que a grande maioria das aplicações de RNAs em aplicações de previsões de curto prazo necessitam de melhorias e padronizações mais rigorosas para apresentarem seus resultados. Outro trabalho comparando as aplicações das RNAs em previsão de energia elétrica pode ser visto em [Metaxiotis et al., 2003].

No trabalho de [Tsekouras et al., 2006] é proposta uma metodologia baseada em RNAs para a aplicação de previsão de energia em médio prazo para o sistema de energia da Grécia. Foram estudados os dados referentes ao consumo anual total de energia do sistema elétrico da Grécia e ao consumo de energia de seis categorias de clientes. Além das RNAs, e para efeito de comparação, também foram realizadas simulações com sete modelos de regressão. Em todos os casos, os modelos baseados em RNAs obtiveram melhores resultados, ou pelo menos resultados semelhantes, em termos de previsão.

Em [Romera, et al., 2006] é proposta uma nova abordagem para a previsão do consumo de energia mensal. Esta nova proposta subdivide o consumo mensal de energia em duas outras séries: uma série de tendência e outra de flutuação do consumo. Para cada uma dessas duas séries é simulada uma RNA para realizar a previsão dos valores de consumo separadamente e posteriormente esses valores previstos serão combinados para gerar a previsão do consumo mensal. Os resultados obtidos com esta proposta obtiveram previsões com maior grau de precisão quando comparados com a previsão realizada com uma única RNA e com a previsão realizada com o método clássico de previsão de séries temporais o modelo Autoregressivo Integrado de Médias Móveis (ARIMA).

Com o objetivo de melhorar a previsão de curto prazo com RNAs, o trabalho de [Fay e RingWood, 2010] propõem a utilização da combinação de modelos de previsão do tempo de forma a gerar dados com menor erro de previsão para que possam ser combinados com as informações de consumo para a melhoria do treinamento das RNAs. Seguindo a idéia de melhorar a performance dos previsores baseados em RNAs com a utilização da combinação de resultados provenientes de diferentes modelos de previsão, os chamados de “Ensemble”, pode-se citar o trabalho de [Felice e Yao, 2011], que faz um estudo comparativo entre os previsores de curto prazo baseados em métodos de combinação com RNAs. Nesta linha pode-se citar também os trabalhos de [Inoue e Narihisafelice, 2000], [Ueda, 2000], [Lima et al., 2002], [Yun et al., 2008], [Wang et al., 2011] .

3.3. Algoritmos Genéticos para Previsão de Séries Temporais

Os AGs não são utilizados diretamente para a previsão de séries temporais, mas sim como apoio a outros métodos e técnicas na busca de uma melhor modelagem e previsão.

No trabalho de [Chai, et al., 1997] foi utilizado um AG para determinar, de forma ideal, os parâmetros e a ordem do método clássico de previsão de séries temporais: o modelo Autoregressivo de Médias Móveis (ARMA). Neste trabalho foram utilizados os dados de uma série temporal real de índices de preços.

Outro trabalho que utilizou AG em aplicações de séries temporais foi [Szipiro, 1997]. Neste trabalho o autor utilizou um AG para encontrar as melhores equações que descrevessem o comportamento de uma série temporal caótica e ruidosa.

Uma outra abordagem da utilização dos AGs em séries temporais pode ser vista em [Povinelli e Feng, 2003]. Os autores empregaram os AGs para o reconhecimento de padrões e estruturas existentes em uma dada série temporal. É realizada uma busca por padrões (ou estruturas) através de uma medida de correlação entre os pontos da série. Neste trabalho a função de aptidão (*fitness*) do AG foi o valor da correlação para as estruturas, sendo que, quanto maior a correlação, mais apta seria a estrutura. Neste sentido, outros trabalhos também podem ser citados como em [Povinelli, 2000] e [Wagner et al., 2007].

3.4. Sistemas Híbridos NeuroGenéticos para Previsão de Séries Temporais

Em sistemas híbridos o objetivo é combinar diferentes abordagens e métodos na solução de um problema. Em geral, tenta-se unir duas ou mais abordagens, de forma que as vantagens de cada abordagem sejam somadas, enquanto que suas desvantagens sejam subtraídas do sistema híbrido. Com este pensamento têm sido investigados modelos neurogenéticos para a aplicação de previsão de séries temporais.

Desta forma, para aprimorar cada vez mais as previsões, utilizam-se as potencialidades das RNAs de reconhecer padrões em sistemas complexos, não-lineares e com quantidade razoável de ruído; e o poder de generalização da rede, com a capacidade dos AGs de realizarem busca e otimização não parametrizada, trabalhando, de forma paralela, com uma população de soluções candidatas.

Na grande maioria dos trabalhos publicados sobre os sistemas híbridos neurogenéticos observa-se basicamente duas abordagens. Na primeira, os AGs são utilizados para ajustar todos os parâmetros da RNA, inclusive os valores das camadas de pesos. Assim, o AG é o responsável por conduzir o processo de treinamento da RNA, como pode ser visto nos trabalhos de [Nag e Mitra, 2002], [Leung et al., 2003], [Bashir e El-Hawary, 2009], [Wang et al., 2010]. Na segunda abordagem o AG fica responsável por ajustar somente os parâmetros estáticos da RNA. Nesta abordagem, o AG interage com a RNA criando várias redes que serão possíveis candidatas a melhores modelos para a solução do problema, mas o treinamento é realizado por um algoritmo de treinamento convencional, como por exemplo, o *backpropagation*.

A seguir são apresentados alguns trabalhos encontrados na literatura que utilizam os sistemas híbridos neurogenéticos na aplicação de previsão de séries temporais.

Em [Huang e Huang, 1996] os autores utilizaram um sistema neurogenético para a previsão de carga em curto prazo. Neste trabalho o AG foi utilizado para incrementar a performance de uma rede neural MLP, atuando no processo de inicialização dos pesos da rede para atingir um estado inicial o mais próximo possível do ponto ótimo. Após a inicialização dos pesos, a rede é treinada com o algoritmo *backpropagation*. Foi utilizada a série temporal da companhia de energia elétrica de Taiwan. Os resultados mostraram boa previsão quando comparados com redes MLPs tradicionais

(inicialização randômica dos pesos), além de apresentarem convergência mais rápida da rede.

Cortez (2002) propôs uma abordagem híbrida neurogenética na previsão de séries temporais, em sua tese de doutorado. Neste modelo foi proposto um esquema de aprendizagem híbrida para as RNAs que utiliza conjuntamente um AG e métodos de gradiente descendentes. Os resultados foram comparados com métodos de previsão tradicionais, como alisamento exponencial e a metodologia Box & Jenkins, aplicados em diferentes séries reais e artificiais, tendo verificado que os modelos híbridos neurogenéticos produziram melhores resultados de previsão.

No trabalho de Ling et al. (2003), é apresentado um modelo híbrido neurogenético para a previsão de carga em curto prazo. Os autores propõem uma RNA *feedforward* que utiliza duas funções de ativação em cada neurônio da camada escondida. Para o treinamento desta rede foi utilizado um AG para ajustar os parâmetros da rede e realizar as alterações nos valores das camadas de pesos. Os resultados mostraram que o modelo proposto obteve melhores resultados de previsão quando comparados com redes MLP tradicionais treinadas com o *backpropagation*, além de apresentarem menor número de neurônios na camada escondida.

Ferreira (2006), em sua tese de doutorado, propôs um novo método para a previsão de séries temporais baseado em um sistema híbrido neurogenético. O método proposto realiza uma busca evolutiva pela dimensionalidade mínima necessária para a reconstrução do espaço de estados da série temporal, com a utilização de um AG modificado que seleciona a topologia de uma RNA conjuntamente com o algoritmo de treinamento aplicado para a previsão de séries temporais. Foram utilizadas séries artificiais e reais nas simulações e os resultados foram comparados com os modelos de Box & Jenkins e RNAs convencionais, superando os resultados obtidos com ambos os modelos. Entretanto, para algumas séries o método proposto obteve um desempenho equivalente às RNAs tradicionais.

O framework proposto nesta tese, tem como base um sistema híbrido neurogenético que não se enquadra nas formas de integração das RNAs e os AGs encontradas na literatura e sua respectiva utilização na previsão de séries temporais. Isto é porque os sistemas neurogenéticos geralmente utilizam os AGs de alguma forma para realizar um ajuste fino das RNAs, seja no ajuste dos parâmetros da rede ou no controle do treinamento. Neste trabalho a proposta é utilizar o AG para realizar a geração de

cenários futuros que a série temporal possa convergir, caso ocorra algum fator externo. Para isso, o AG utilizará de forma independente o módulo previsor baseado em RNA. É importante citar que o módulo previsor é modelado e treinado de forma independente antes da fase de simulação das previsões com o AG ser executado, gerando desta forma um sistema híbrido intercomunicativo.

Outra diferença está relacionada à análise da previsão da série temporal. Nos trabalhos encontrados na literatura, os dados históricos da série balizam a previsão de valores futuros, sem levar em consideração possíveis anomalias decorrentes de fatores externos. Qualquer análise do comportamento da série é realizada de forma manual através das diretrizes definidas por um especialista da área do problema do qual estão sendo realizadas as previsões. Na proposta deste trabalho, um AG é utilizado para guiar o processo de exploração das previsões realizadas pelo módulo neural. Desta forma, além da previsão dos valores futuros gerados pela RNA (cenário normal), pode-se criar cenários futuros otimistas e pessimistas que podem influenciar o comportamento da série temporal.

3.5. Considerações Finais

Neste capítulo, foram abordados alguns trabalhos encontrados na literatura que realizam a previsão de séries temporais com base nas tecnologias de RNAs, AGs e sistemas híbridos neurogenéticos.

A maioria dos trabalhos publicados nessa área não apresenta solução para a análise da previsão realizada por qualquer uma das técnicas de previsão, realizando desta forma simplesmente, porém não trivialmente, a previsão da série de acordo com os valores históricos.

Desse modo, será apresentada no próximo capítulo, uma proposta que visa a investigar cenários de previsões de séries temporais com base em um framework que utiliza as potencialidades dos sistemas híbridos inteligentes.

4. Um Framework para a Previsão de Cenários Futuros: Aplicações de Sistemas Híbridos Neurogenéticos em Sistemas Elétricos de Potência.

4.1. Considerações iniciais

Previsão de séries temporais foi e ainda continua sendo uma das áreas de intensa investigação pela comunidade científica, devido a suas inúmeras aplicações nos mais diversos setores de atividades acadêmicas, industriais e comerciais. Ao longo dos anos, uma grande variedade de técnicas para esse fim tem sido desenvolvida e empregada, observando-se em tais técnicas tanto vantagens quanto desvantagens, de acordo com cada tipo de aplicação.

Neste contexto, uma potencial aplicação é a de previsão de carga em sistemas elétricos de potência, por tratar-se de um dos ramos relacionado à própria sobrevivência das organizações e, por esse motivo, utilizado como foco de aplicação da metodologia proposta nesta tese.

Esta proposta se baseia na concepção e na construção de um framework que utiliza sistemas híbridos intercomunicativos, ver figura 4.1, para a previsão de cenários futuros, tendo como *locus* de aplicação a previsão de consumo de energia da concessionária Centrais Elétricas do Pará - CELPA.

Inicialmente o SHI desenvolvido no *framework* foi baseado nos sistemas híbridos neurogenéticos, entretanto o framework poderia suportar a aplicação de outras combinações de técnicas de previsão com técnicas de otimizações gerando assim outras configurações de SHI. Na figura 4.1, fica evidente que além da técnica de RNA utilizada como base do processo de previsão, pode-se usar outras técnicas de previsão de séries temporais como por exemplo redes bayesianas com correlação no tempo ou máquinas de vetores de suporte. Com relação ao processo de geração de cenários, na figura 4.1 também se pode visualizar que além da técnica de AG, outras técnicas de otimização podem ser empregadas no framework, como por exemplo enxame de partículas ou recozimento simulado.

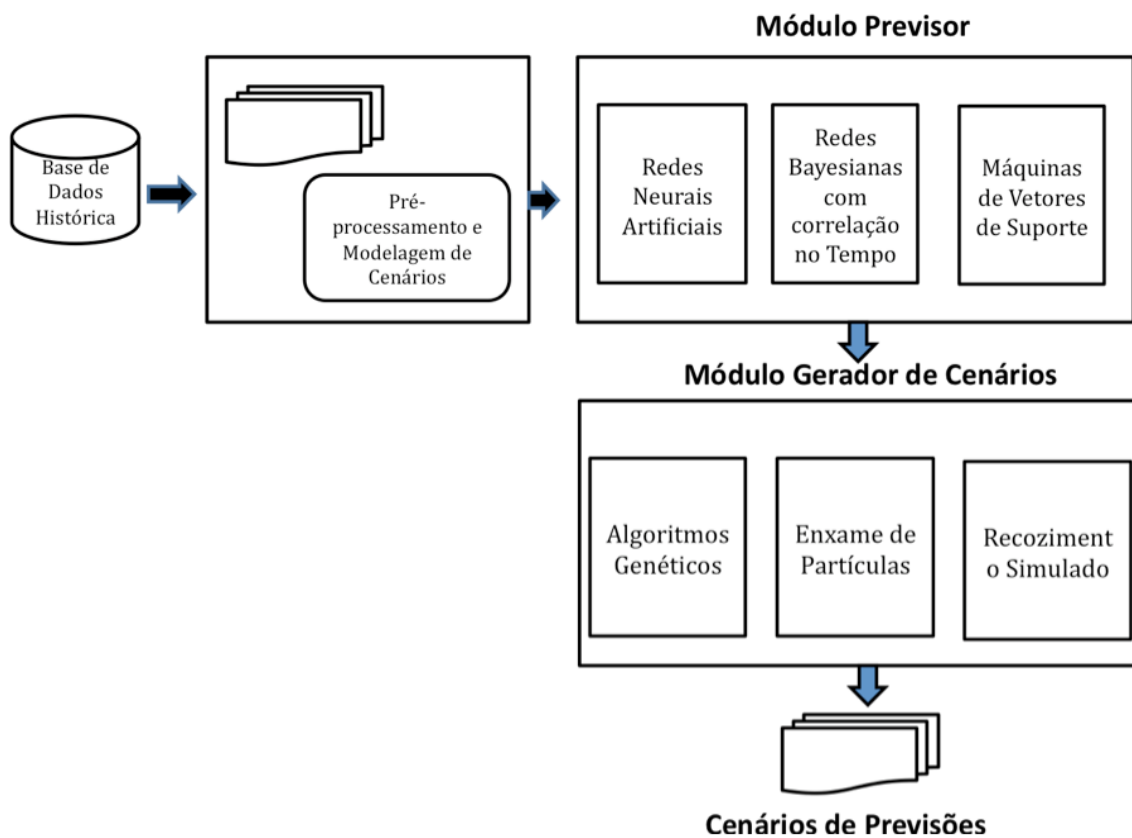


Figura 4.1. Arquitetura do *Framework* Proposto.

O problema abordado nesta tese é baseado em uma demanda do mundo real, cujo objetivo principal é realizar previsão do consumo de energia de uma dada região, de modo que os especialistas do domínio possam adequar o sistema elétrico para atender os consumidores, quando tais demandas se concretizarem no futuro. Assim, baseado no histórico das medidas do sistema (principalmente nas informações sobre o consumo), deseja-se obter uma prospecção das necessidades futuras, fornecendo informações que dêem suporte para que as concessionárias de energia elétrica possam estimar, de maneira satisfatória, a compra de energia baseado em suas reais necessidades. Tal possibilidade proporciona à concessionária a capacidade de otimizar as relações de preços apresentadas pelos fornecedores do Brasil, o que pode levar a uma economia financeira substancial, em função da diminuição da diferença entre a

quantidade de energia comprada e consumida, ampliando o seu potencial competitivo no mercado.

O *framework* proposto nesta tese pode melhorar sobremaneira a previsão do consumo de energia elétrica, por diversos motivos, entre os quais podem ser destacados:

- A utilização de técnicas de elaboração de cenários futuros no problema de previsão do consumo de energia elétrica, possibilita a identificação de tendências, melhorando assim a qualidade da informação analisada;
- O modelo de previsão de consumo pelas empresas distribuidoras de energia da Amazônia, como é o caso da CELPA, é muito ineficaz, pois utiliza métodos estatísticos que não conseguem lidar com a dinâmica do sistema elétrico da região em questão, que possui características diferenciadas do resto do país e está em constante expansão;
- É apresentada a proposta de um novo SHI que combina de uma forma inovadora a técnica de RNA com AG para a geração de cenários futuros de séries temporais, possibilitando assim tomadas de decisões alternativas ao curso normal da curva da série temporal analisada;
- Com a utilização do novo modelo desenvolvido nesta tese, será possível gerar cenários de previsões de consumo de energia e contribuir diretamente para a qualidade da informação gerada, melhorando assim os resultados obtidos pelas empresas nas suas projeções do consumo. Além disso, o modelo proposto poderá fornecer um arcabouço para os especialistas das empresas elaborarem planos de contingências caso o consumo de energia seja afetado por situações adversas do domínio de aplicação ou até mesmo para tentar explicar anomalias de comportamento desse consumo em análise.

O *framework* desenvolvido é baseado em três eixos, conforme a seguir: definição de cenários; seleção e modelagem da técnica de previsão de séries temporais mais adequada ao problema e seleção e modelagem da técnica de otimização empregada na geração dos cenários de previsão, como pode ser visto na figura 4.1.

A definição dos cenários, com a colaboração dos especialistas do domínio, envolve o pré-processamento da base de dados histórica, juntamente com outras variáveis que possam auxiliar o processo de previsão da série temporal em estudo. Nesta

definição é modelada a configuração das entradas e saídas e o tipo de cenário que será analisado, ou seja, quais informações serão utilizadas como entrada para o processo de previsão e quais serão as saídas deste processo, como também a forma como o processo de busca irá trabalhar para gerar os cenários alvos da análise.

A seleção e modelagem da técnica de previsão empregada estão diretamente ligada com a definição dos cenários e envolve um processo de simulação para que possa se determinar qual ou quais as melhores técnicas de previsão para aquele determinado problema de aplicação. Embora a idéia do *framework* desenvolvido nesta tese possa empregar diversas técnicas para realizar o processo de previsão de séries temporais, os estudos foram realizados tendo como foco principal as RNAs como técnicas de previsão, de acordo com as suas características mostradas no capítulo 2.

A seleção e modelagem da técnica de otimização empregada na geração dos cenários de previsão, envolve a escolha da técnica que melhor se comunique com a técnica empregada para realizar a previsão. A idéia central é poder utilizar ao máximo as potencialidades das técnicas de previsão com as técnicas de otimização em um sistema híbrido intercomunicativo para a geração de cenários futuros que mostrem percursos alternativos ao percurso normal das curvas das séries temporais analisadas. Neste tópico, o *framework* desenvolvido também poderá empregar diversas técnicas de otimização e busca, porém a técnica utilizada nos estudos foi a dos AGs, em parte por se tratar de uma técnica que possui um alto grau de acoplamento com as RNAs, como visto no capítulo 3, e em parte pela descoberta de uma nova proposta de utilização das técnicas de AGs e RNAs de uma forma inovadora através da união dessas em um sistema híbrido intercomunicativo, onde as RNAs servem como função de aptidão para os AGs.

Neste capítulo, é apresentada a proposta original de um *framework* baseado em sistemas híbridos inteligentes para a previsão de séries temporais, objeto desta tese de doutorado.

4.2. Previsão de Cenários

A elaboração de cenários consiste em uma estratégia empregada na descrição de sistemas de domínios de aplicação variados, sendo também aplicada no estudo de alternativas de planejamento e tomada de decisões dos mesmos.

De maneira a lidar com os comportamentos futuros de um determinado fenômeno, deve haver a possibilidade de se identificar tendências de sucesso e fracasso ao longo do tempo e, se possível, monitorar e controlar o processo gerador desses possíveis estados [Godet, 1987]. Considerando os diferentes resultados possíveis de um determinado evento a ser realizado como diferentes estados de natureza de um processo, sob situações que variam de otimistas a pessimistas, deve haver sempre um plano contingente elaborado através da especificação geral dos vários resultados possíveis deste processo em relação ao seu comportamento futuro [Varian, 1994].

A elaboração e a análise de cenários são métodos importantes e amplamente utilizados, na área de planejamento e gestão, para o acompanhamento e gerência de processos. Com base nas análises realizadas pela exploração das informações geradas pelas projeções dos cenários futuros, os especialistas podem tomar decisões que levem a um estado satisfatório, ou seja, se consiga alcançar as metas/objetivos para a execução do processo. [GODET e ROUBELAT, 1996]; [GAUSEMEIER et al., 1998]. Sendo assim, a utilização de cenários futuros nos processos de tomadas de decisões em previsão de séries temporais pode contribuir diretamente na qualidade da informação gerada pelas tecnologias de previsão utilizadas nesta tese.

Assim, é descrita a seguir uma metodologia bastante empregada na elaboração e análise de cenários de qualquer domínio de aplicação, de acordo com [GODET e ROUBELAT, 1996]; [GAUSEMEIER et al., 1998] e [WOLLENBERG et al., 2000].

Um cenário é um estudo prospectivo acerca do futuro aliado à organização das informações obtidas, de modo a oferecer um conjunto de informações coerente, sistemático, compreensível e plausível, com o objetivo de descrever um determinado evento e oferecer instrução e suporte à tomada de decisões [COATES, 2000]. Duas grandes categorias podem ser identificadas quando se depara com os mais diversos tipos de cenários produzidos [GODET e ROUBELAT, 1996]:

- **Cenário exploratório:** estudo que considera as tendências observadas no passado e no momento atual, concluindo com a geração de um provável estado futuro (cenário). Neste tipo de estudo a meta é construir as projeções (cenários) a partir de uma base histórica de dados e possíveis alterações que podem ocorrer nestes valores. Pode-se citar como exemplo de cenários exploratórios os cenários gerados para a previsão de consumo de energia elétrica por uma determinada

empresa distribuidora, onde partindo dos dados históricos de consumo mensal, realiza-se a previsão da curva da série temporal (cenário normal). Os especialistas da empresa podem desejar avaliar quais os impactos que alterações nos consumos de determinados meses podem gerar nas previsões de curto prazo (até um ano) dos valores de consumo mensais seguintes. Neste contexto, os cenários modelam os valores de consumos mensais previstos, utilizando para isso variações dos consumos que servem de entrada para o processo de previsão;

- **Cenário antecipatório ou normativo:** construído com base em diferentes pontos de vista acerca do futuro, procura traçar diretrizes para que determinado estado seja alcançado ou evitado. Neste tipo de estudo, se definem metas a serem alcançadas e os cenários irão representar que tipo de estratégia, decisões ou configuração dos valores das variáveis do sistema analisado irão levar até a meta alvo definida no início do processo. Pode-se citar como exemplo de cenários antecipatórios ou normativos, os cenários que definem qual configuração dos valores de consumos diários que levem a um determinado consumo mensal. Neste exemplo, partindo-se de um valor alvo, consumo mensal predeterminado, geram-se os cenários de consumos diários que poderiam levar ao consumo mensal alvo. Neste contexto, os cenários modelam os valores de consumos diários que podem gerar o consumo mensal alvo pré-estabelecido.

Tanto cenários exploratórios como cenários antecipatórios podem e devem ser direcionados por diversas alternativas e depois contrastados entre si e com o ambiente contemporâneo, à medida que incorporam mudanças mais ou menos prováveis, para que se possa efetuar um julgamento acerca de sua plausibilidade.

Deste modo, é razoável considerar, em uma abordagem computacional, que cenários são formatados através do encadeamento de uma ou diversas técnicas de análise de informações, dispostas em uma sequência lógica, com o intuito de se prover material organizado e útil como apoio à tomada de decisões. Assim, os elementos comuns de uma elaboração de cenários, via de regra, seriam sequencialmente os seguintes [WOLLENBERG et al., 2000]:

1. Definição do propósito dos cenários a serem elaborados;

2. Informação sobre a estrutura do sistema em questão e dos grandes direcionadores de mudanças;
3. Geração dos cenários, através da organização estruturada das informações disponíveis;
4. Análise dos cenários e geração de conhecimento útil para o processo de tomada de decisão.

O trabalho resultante desta operação é a geração de cenários, tendências de comportamento no caso de séries temporais, que possibilitem ao usuário final a tomada de decisões fundamentado em seus pressupostos e conclusões, tanto no aspecto de controle e monitoramento, realizados através de ajustes aos desvios da trajetória esperada, como no aspecto da análise gerencial das informações contidas. De fato, a elaboração e o uso de cenários têm sido cada vez mais utilizados pelas mais diversas organizações a partir dos anos 70 [GAUSEMEIER et al., 1998], tanto na orientação do planejamento estratégico de procedimentos, quanto no processo de tomada de decisões.

4.3. Contextualização da Proposta de Criação do Framework

Todos os métodos de previsão partem do princípio de que as experiências do passado servirão de base para o comportamento futuro. Assume-se, assim, que as condições que modelaram o comportamento passado ainda serão válidas, de alguma forma, para modelar o futuro [Cortez, 2002].

Previsão é um elemento chave em processos de tomada de decisão, uma vez que qualquer decisão depende fortemente dos eventos que a antecedem e que, em expectativa, podem a suceder. Desta forma, é de grande interesse o estudo de métodos de previsão de séries temporais que consigam identificar as estruturas e padrões existentes nos dados históricos e que sejam capazes de gerar os próximos padrões da série.

O estudo de previsão de séries temporais normalmente era abordado pela estatística de forma genérica com os modelos lineares e não lineares. Os modelos lineares são muito bem entendidos, mas nem sempre são aplicáveis para a solução de problemas, enquanto que os modelos não lineares, que tentam suprir as deficiências dos

modelos lineares, nem sempre são aplicáveis na prática pelo seu alto grau de complexidade [Ferreira 2006].

No contexto da previsão de séries temporais, a IA vem despontando com o uso de técnicas e procedimentos, geralmente, não lineares e que em termos práticos não apresentam tantas dificuldades técnicas quando comparados com os modelos estatísticos não lineares. Muitas técnicas de IA podem ser aplicadas ao problema de previsão, de forma individual ou de forma a explorar a combinação destas técnicas para a geração de soluções otimizadas com a criação de SHIs. destacando-se na literatura as técnicas [Tzafestas e Tzafestas, 2001], [Senjyu et al., 2005], [Liao e Tsao, 2006], [Amjady, 2007], [Bashir e El-Hawary, 2009], [Hanmandlu e Chauhan, 2011] e [Amjady e Daraeepour, 2012]:

- Redes Neurais Artificiais
- Algoritmos Genéticos
- Sistemas de Lógica Nebulosa (*fuzzy logic*)

Uma situação ideal para a realização de previsões seria o conhecimento prévio das equações que modelam os mecanismos responsáveis pela geração das séries temporais. No entanto, em muitos problemas do mundo real essas informações não estão disponíveis, e não se tem condições ideais para construir equações que governem o comportamento das variáveis de interesse. Quando isso acontece, o usual é utilizar uma abordagem baseada em modelos, na qual se tenta identificar ou aproximar o processo gerador dos dados. Neste contexto, um dos modelos com larga utilização para previsão de cenários são as redes neurais artificiais (RNAs).

As RNAs têm sido amplamente utilizadas nas últimas décadas na previsão de séries temporais, por serem ferramentas bastante atraentes para este tipo de estudo devido às suas características intrínsecas de mapeamento de entradas e saídas. De forma contrária aos métodos baseados em modelos analíticos, as RNAs são modelos adaptativos baseados em dados com nenhuma, ou quase nenhuma, suposição *a priori* da série temporal em estudo. As RNAs realizam o seu aprendizado exclusivamente com exemplos do conjunto de treinamento e assim conseguem capturar os relacionamentos e padrões existentes nos dados, mesmo que tais informações sejam desconhecidas ou de difícil observação por especialistas do domínio da aplicação [Ferreira, 2006]. Desta forma, as RNAs são adequadas para problemas cujas soluções requerem um

conhecimento que não pode ser adquirido de forma simples, mas para os quais existe quantidade de dados estatisticamente representativa, contendo a informação desejada. Neste sentido, as RNAs são tidas como um método estatístico não paramétrico não-linear multivariável [White, 1989].

Outra característica fundamental das RNAs é a sua capacidade de generalização, ou seja, finalizado o processo de aprendizagem com os dados de treinamento as RNAs são capazes de inferirem corretamente padrões que não estavam presentes nos dados de treinamento. Assim, como a previsão de séries temporais é basicamente a determinação do comportamento futuro a partir do seu comportamento passado (dados históricos), esta se torna uma aplicação ideal para as RNAs.

Ainda com relação ao emprego das RNAs em problema de previsão, outra característica favorável se baseia no fato de que as redes são aproximadores universais de funções, ou seja, desde que exista uma base de dados histórica representativa as redes podem aproximar qualquer função com uma precisão desejada [Irie e Miyake, 1998]; [Hornik, 1993]. Assim, como as séries temporais podem ser representadas como uma função matemática dependente do tempo, as RNAs podem ser soluções candidatas para a determinação de tais funções.

Outro ponto importante a ressaltar sobre as RNAs está relacionado com o fato de não haver para elas grande limitação no número de variáveis de entrada, bem como ser possível aplicá-las em séries temporais não-estacionárias sem o uso de transformações para obter comportamento estacionário [Braga et al., 2007].

As técnicas de elaboração de cenários futuros fornecem ferramentas poderosas para o estudo de séries temporais através das análises de tendências de alterações da curva da série causadas por interferências externas provenientes do domínio de aplicação. Tais alterações podem implicar em diversos tipos de variações na curva da série temporal, resultando em mudanças no seu comportamento previsto (cenário normal) que sob determinadas situações pode variar de otimistas (crescimento) à pessimista (decréscimo). Desta forma, uma metodologia capaz de realizar buscas sobre tendências de alterações da curva da série de forma e guiar a previsão de cenários futuros baseados nessas alterações de comportamento da série temporal, contribui diretamente na qualidade da informação disponível para os gestores nos processos de tomadas de decisões.

As técnicas de otimização e buscas geralmente apresentam um espaço de busca onde estão todas as possíveis soluções e uma função de avaliação ou custo que estima, geralmente através de uma nota, a qualidade de cada possível solução. Os AGs, são mecanismos de busca e otimização baseados na teoria da seleção natural e genética que trabalham com um conjunto (população) de possíveis soluções simultaneamente. Neste contexto, a justificativa pela escolha dos AGs para compor o SHI juntamente com as RNAs nos módulos do *framework* é pautada basicamente em quatro aspectos que os diferenciam dos métodos tradicionais de busca e que são altamente desejáveis para o processo de previsão de cenários futuros de séries temporais, como segue:

1. Paralelismo: mantém uma população de soluções que são avaliadas simultaneamente.
2. Otimização Global: não utilizam apenas informação local, o que os torna menos suscetíveis a ficar presos em máximos locais.
3. Não são Totalmente Aleatórios: possuem componentes aleatórios, entretanto, utilizam informação da população corrente para determinar o próximo estado da busca.
4. Utilizam informações de custo ou recompensa e não derivadas de funções na sua evolução, nem necessitam de informação sobre o seu entorno para poder realizar sua busca.

Muitas são as combinações entre as várias técnicas de IA para a criação de SHIs, contudo devido às vantagens da aplicação das RNAs na previsão de séries temporais se optou por utilizar essa técnica em conjunto com AGs para compor os módulos de previsão e geração de cenários, respectivamente, do *framework* proposto nesta tese.

SHIs têm se tornado ferramentas importantes quando se considera a natureza variada do domínio de aplicações. Em determinados domínios, como é o caso de previsão de cenários futuros de séries temporais, pode-se identificar a necessidade de abordar o problema de formas diferentes que requerem a combinação de diferentes tipos de processamentos, levando a criação e a modelagem de SHIs para a solução do problema. A proposta defendida nesta tese é a de um *framework* baseado em SHIs que combina a técnica de RNA com AG (sistema neurogenético) para a previsão de cenários futuros de séries temporais. Este sistema neurogenético representa a combinação do poder das RNAs em realizar previsões com a capacidade dos AGs de realizarem busca e

otimização não parametrizada na descoberta de cenários futuros da série temporal explorando alterações no comportamento da série. As análises desses cenários futuros descobertos, podem fornecer um arcabouço para o gestor elaborar planos de contingências caso a série temporal seja afetada por situações adversas do domínio de aplicação ou até mesmo para tentar explicar anomalias de comportamento da série temporal em análise.

O SHI neurogenético que compõem o *framework* proposto nesta tese é apresentado com mais detalhes na próxima seção.

4.4. Modelo Híbrido NeuroGenético

O foco principal do trabalho desenvolvido nesta tese está relacionado ao desenvolvimento de um framework que inicialmente se baseia em uma nova metodologia de sistema híbrido neurogenético para a previsão de cenários futuros de séries temporais, tendo como aplicação a previsão de consumo de energia em sistemas elétricos de potência.

O modelo híbrido neurogenético proposto nesta tese é inédito e não se enquadra nas formas de integração para construção de SHIs entre RNAs e os AGs encontradas na literatura e sua respectiva utilização na previsão de séries temporais. Nas subseções seguintes este modelo é detalhado.

4.4.1. Módulo Previsor via RNA

Ao longo das últimas décadas vários tipos de métodos convencionais (modelos estatísticos) e baseados em IA foram desenvolvidos e empregados para a previsão de séries temporais. Dentre esses, pode-se destacar os métodos baseados em RNAs, que vem sendo empregados com sucesso nesses problemas de previsão, haja vista, sua capacidade de modelar a série de forma não paramétrica e não-linear, sem que haja grande necessidade de se entender o processo propriamente, e utilizando-se somente amostragens de valores de entrada e saída do sistema em intervalos de tempo regulares [Braga et al., 2007].

Com a utilização das RNAs no módulo previsor, procurou-se explorar ao máximo as características inerentes das redes no que diz respeito à capacidade de

reconhecer padrões em sistemas complexos, não-lineares e com quantidade razoável de ruído, em contraste com os métodos estatísticos convencionais onde essa capacidade não é encontrada. Outra importante característica das RNAs é sua capacidade de generalização, tornando-a um modelo ideal para problemas onde a quantidade de dados históricos é de certa forma limitada.

A aplicação das RNAs para a previsão envolve todo um conjunto de etapas como a análise da série temporal, o pré-processamento dos dados, a escolha do modelo de rede, o treino da rede e a validação do desempenho desta.

No problema de previsão de séries temporais, as entradas da RNA são usualmente as variáveis de predição. Assim, a relação funcional pela RNA pode ser descrita como:

$$y = f(x_1, x_2, \dots, x_n) \quad (4.1)$$

onde x_1, x_2, \dots, x_n são n variáveis independentes e y é uma variável dependente. Nesse sentido a RNA atua de forma equivalente a um modelo de regressão não-linear.

Por outro lado, abordando o problema como uma extrapolação, as entradas da rede são tipicamente as observações passadas da série temporal e a saída é o respectivo valor futuro. Deste modo, a RNA dependerá de uma função de mapeamento esquematizada como:

$$y_{t+1} = f(y_t, y_{t-1}, \dots, y_{t-n}) \quad (4.2)$$

onde y_t é a observação da série temporal no tempo t . Analisando sob este ângulo, a RNA é equivalente a um modelo auto-regressivo não-linear.

Com relação à escolha do modelo de rede, existem diversos tipos de RNAs passíveis de serem aplicadas à previsão de séries temporais. Neste contexto, como o foco de aplicação desta tese se originou a partir de “demandas do mundo real” para solucionar dificuldades de realizar análises e projetar cenários de mercado de energia elétrica, optou-se por utilizar as redes MLP, bastante investigadas neste setor.

A análise da série temporal implica na definição da informação que servirá de entrada para o processo de previsão, como também quais serão os intervalos de previsão. Uma RNA pode incorporar tanto variáveis de previsão como retardos

temporais (*lags*) de uma série temporal, equivalendo-se a um modelo geral de função de transferência, figura 4.2. A utilização desses *lags* nas variáveis de entrada da RNA é chamada de técnica de “janela de tempo”, que é utilizada para adaptar as redes MLP para lidar com tarefas dinâmicas, como é o caso de previsão de séries temporais [Haykin, 1999], [Braga et al., 2007]. O número de *lags* define o tamanho da janela de tempo. O horizonte de previsão é definido na camada de saída da rede e representa a previsão dos próximos valores da série temporal.

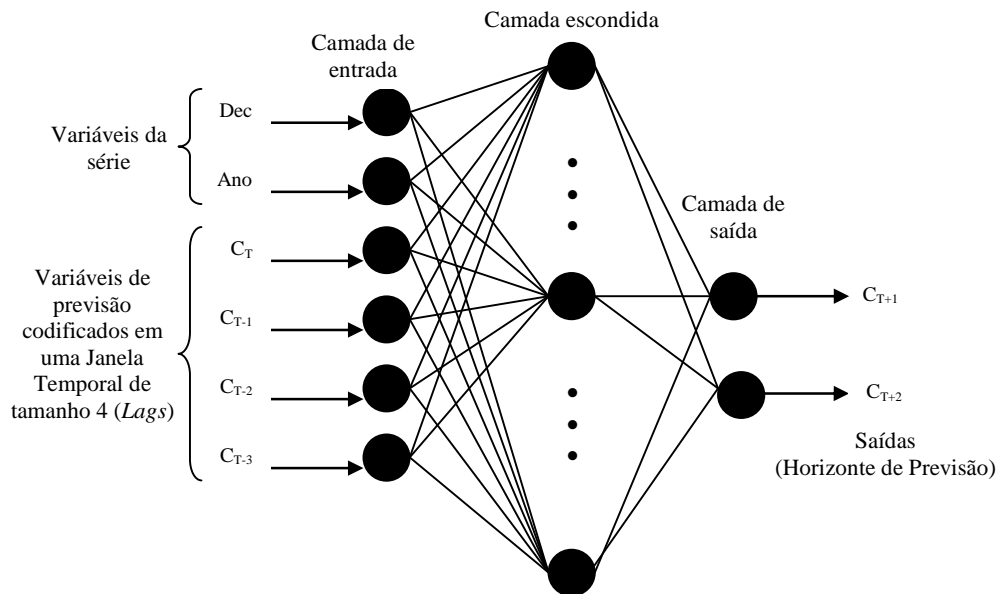


Figura 4.2. Rede MLP para a previsão de séries temporais.

No exemplo mostrado na figura 4.2, uma rede MLP é utilizada para realizar a previsão do consumo de energia elétrica. Na camada de entrada da rede os valores históricos da série temporal foram codificados através de 6 neurônios, sendo os dois primeiros utilizados para representar as variáveis da série, no exemplo em análise informações sobre a data do consumo atual (C_T), e os outros quatros neurônios restantes utilizados para representar a janela de tempo para a variável consumo de energia nos instantes T , $T-1$, $T-2$ e $T-3$. A previsão da rede é expressa na camada de saída através do horizonte de previsão que no exemplo da figura 4.2 foi codificado como sendo os valores previstos da variável consumo nos instantes $T+1$ e $T+2$, ou seja previsão de dois valores futuros da série.

O emprego de uma RNA nas aplicações de previsão de séries temporais tem como ponto de fundamental a definição da arquitetura da RNA. Definido o tipo de rede

utilizada, deve-se configurar a quantidade de camadas, a quantidade de neurônios em cada camada e a quantidade de entradas da rede, que para o problema de previsão é determinada pela quantidade de *lags* relevantes e pela quantidade de variáveis relevantes da série em estudo. Além da janela de previsão também deve ser definido o horizonte de previsão da série temporal, ou seja, até onde se pretende realizar a previsão e em quantos passos será realizada esta previsão até se chegar ao objetivo estabelecido. Por exemplo, pode-se definir que uma determinada série temporal terá seus valores futuros previstos para os próximos 03 anos, utilizando-se para isso previsões mensais.

Outros parâmetros que também devem ser levados em consideração na definição da arquitetura da RNA são as funções de ativação dos neurônios, o algoritmo de treinamento, a definição de medidas de desempenho (definição do cálculo do erro), o pré-processamento dos dados históricos da série temporal com a escolha de transformações e normalização dos dados e a divisão dos dados históricos em conjuntos de treinamento e teste.

A definição dos parâmetros da arquitetura de uma RNA é dependente do problema em questão e na grande maioria dos casos, a arquitetura da rede é definida com base em experimentos preliminares. Entretanto, para o problema de previsão de séries temporais um parâmetro crítico é a definição do número de entradas da RNA que correspondem ao tamanho da janela de previsão (*lags* relevantes) mais, se existirem, as variáveis relevantes para a série. Assim, a definição dos *lags* é um fator chave a ser ajustado, sendo altamente dependente do problema, para uma fiel representação das estruturas temporais inerentes à série temporal analisada.

O número de neurônios da camada de saída da RNA é determinado de acordo com as análises que se deseja realizar para o problema de previsão de séries temporais. Existem basicamente duas formas de previsão que podem ser executadas [Zhang et al., 1998]:

- Previsão de um passo;
- Previsão de múltiplos passos.

A previsão de um único passo utiliza apenas um neurônio na camada de saída da RNA, cuja função será estimar o próximo valor futuro da série (horizonte de previsão unitário). Já para a previsão de múltiplos passos existem dois esquemas possíveis para a sua implementação. O primeiro, denominado de previsão iterativa e comumente

utilizada nos modelos estatísticos, utiliza apenas um neurônio na camada de saída da RNA, onde o valor gerado é então utilizado para construir de forma iterativa o padrão de entrada para a previsão do próximo passo.

O segundo esquema, denominado de previsão direta, consiste em projetar uma RNA com uma quantidade de neurônios de saída igual ao horizonte de previsão, onde cada um destes neurônios é responsável pela previsão de um determinado passo no futuro.

Antes do módulo predictor baseado em RNA realizar qualquer tarefa, a RNA deve passar pelo processo de aprendizagem. Neste processo, uma rede MLP, definida como RNA básica utilizada nesta tese, é treinada de forma supervisionada com o algoritmo *backpropagation*. Assim, para cada padrão de entrada exibido à rede é encontrado um padrão de saída, forçando a rede a ajustar seus pesos (aprendizado) de forma a conseguir realizar o mapeamento entre o padrão de entrada e o padrão de saída, através da minimização do erro entre a saída de rede e a resposta desejada (figura 4.3).

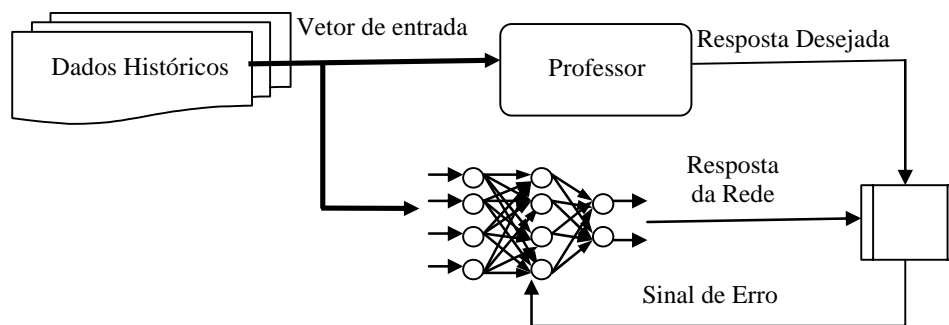


Figura 4.3. Esquema do processo de aprendizagem supervisionada.

A maioria dos trabalhos sobre previsão de séries temporais encontrados na literatura frequentemente empregam somente uma medida de desempenho para avaliar o modelo em estudo. Na maioria das vezes a medida utilizada é o erro quadrado médio (*mean squared error – MSE*), visto na equação 4.3:

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (4.3)$$

Onde N representa o número de exemplos, y o valor histórico real do padrão i e \hat{y} o seu valor estimado.

Uma segunda medida de desempenho também muito relevante é o erro percentual médio absoluto (*mean absolute percentage error* – MAPE), visto na equação 4.4:

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left(\frac{|y_i - \hat{y}_i|}{y_i} \right) \times 100\% \quad (4.4)$$

Onde N representa o número de exemplos, y o valor histórico real do padrão i e \hat{y} o seu valor estimado.

Assim, a avaliação de desempenho das previsões obtidas com as redes MLP neste trabalho foram realizadas de acordo com os erros MSE e MAPE.

Uma vez que o módulo predictor é modelado e treinado para abstrair as características intrínsecas de uma determinada série temporal, pode-se passar para a próxima fase do sistema híbrido neurogenético proposto nesta tese que será apresentado a seguir.

4.4.2. Módulo Gerador de Cenários

Após a conclusão da etapa de criação do módulo de previsão via RNA, tem início a etapa de configuração e simulação do módulo gerador de cenários que consiste em utilizar um AG para guiar a busca por valores dos atributos apresentados à camada de entrada da RNA, para que esta possa gerar (descobrir) os cenários configurados pelos especialistas do domínio.

No módulo predictor de cenários o controle do *framework* baseado no sistema híbrido neurogenético, proposto nesta tese, passa a ser do AG, que será o responsável por guiar o processo de exploração das previsões realizadas pelo módulo neural para gerar os cenários futuros de uma determinada série temporal. Ao contrário do modo como o AG é empregado na maioria dos sistemas híbridos neurogenéticos propostos na literatura, em que o mesmo é utilizado para otimizar a arquitetura da RNA ou o seu treinamento, nesta tese essa combinação ocorre de forma modular e sequencial, onde o AG é empregado para realizar buscas no espaço de previsões da série temporal realizadas pela RNA (treinada no módulo predictor).

Neste sentido, a função de aptidão utilizada pelo AG para avaliar a qualidade dos indivíduos de sua população é o módulo predictor baseado em RNA. Desta forma, o

sistema híbrido neurogenético combina o potencial das RNAs para realizar previsões de séries temporais com o potencial dos AGs de realizar busca otimizada por parâmetros, baseada em mecanismos de seleção natural e genética utilizando um conjunto de possíveis soluções simultaneamente. Essa combinação serve de base para o processo de geração de cenários futuros de séries temporais.

O processo de geração de cenários é iniciado após a finalização do treinamento da RNA definida no módulo predictor, pois a rede gerada realizará o papel de função de aptidão do AG que avaliará a qualidade dos indivíduos (cenários) os quais representam soluções candidatas para o problema em análise e ao término das gerações, os cenários ótimos de acordo com os objetivos traçados para a aplicação, são encontrados na população resultante.

No projeto do AG, a definição de cada indivíduo da sua população irá representar um determinado padrão de entrada para a RNA do módulo predictor do *framework*, onde o seu cromossomo é representado pela codificação dos dados das variáveis de previsão da série temporal utilizados na camada de entrada da RNA (*flags* e variáveis relevantes). Desta forma, a modelagem da janela de previsão utilizada para modelar a camada de entrada da RNA está diretamente ligada à modelagem dos cenários a serem descobertos. Por outro lado, a modelagem da camada de saída da RNA, configurada através do horizonte de previsão, está relacionada com a função de aptidão do AG, pois é a saída da RNA que será utilizada para o cálculo da qualidade de cada indivíduo.

O ponto de partida da execução do AG é a geração aleatória da população inicial *I*, constituída por um conjunto de indivíduos que representam os cenários candidatos que satisfaçam a meta à ser encontrada (cenários exploratórios ou antecipatórios). No passo seguinte cada indivíduo é apresentado para a RNA, para que a rede gere uma previsão para o padrão apresentado (indivíduo) e com isso possa ser calculado a aptidão do mesmo. Ao final desse processo cada indivíduo da população corrente possui uma aptidão calculada pela RNA.

O processo continua com a seleção dos indivíduos da população atual por meio da aplicação do método do torneio. A seleção é realizada de forma que os indivíduos mais aptos sejam selecionados mais frequentemente do que aqueles menos aptos. Em seguida, nesses indivíduos selecionados são aplicados os operadores de cruzamento definidos através da taxa de cruzamento T_c , e de mutação, definido pela taxa de mutação

T_m . O processo se repete até que um número pré-determinado de gerações seja alcançado.

Um ponto importante a ser observado é o cenário previsto pela RNA sem a intervenção do AG e utilizando os dados históricos da série temporal, denominado de cenário normal. É este cenário normal que serve como parâmetro de comparação para a avaliação da aptidão (calculada pela RNA) dos indivíduos da população do AG. Partindo do cenário normal, o AG pode iniciar sua busca pelos cenários futuros que melhor representam as condições indicadas pelos especialistas do domínio, ou seja, o objetivo pode ser, por exemplo, analisar os cenários que maximizem (cenários otimistas) os valores previstos da série temporal pela RNA ou os cenários que minimizem (cenários pessimistas) esses valores. Entretanto, o especialista também pode analisar qualquer outro cenário baseado em taxas de crescimento ou diminuição, definidos por ele, além dos cenários otimistas ou pessimistas, com o objetivo de analisar o comportamento da série temporal sob um amplo espectro de possibilidades de alterações no domínio da aplicação. Outro fator que também pode ser analisado nessa perspectiva são as influências dos atributos apresentados à camada de entrada da RNA durante o processo de previsão da série temporal.

Para que haja sucesso no processo de busca do AG pelos cenários previstos da série temporal que satisfaçam as metas definidas pelos especialistas, a criação dos indivíduos e a obtenção destes através dos operadores de cruzamento e mutação devem satisfazer as restrições que definem a admissibilidade de cada componente do indivíduo (cenário), caso contrário podem ser encontrados cenários que satisfaçam as metas porém sejam impossíveis de acontecerem. Por exemplo, a avaliação de uma série temporal que representa os valores mensais totais de consumo de energia elétrica dentro da área de concessão de uma empresa distribuidora, indicou que as taxas de crescimento dos consumos entre meses consecutivos, considerando até anomalias extremas, seriam em torno de -3% e 10%. Essa informação indicaria que qualquer valor previsto de consumo, dentro de um cenário, que estivesse fora desse intervalo levaria o cenário a representar uma solução fora do espaço admissível e portanto improvável de ser alcançada. Assim, as restrições aplicadas na execução do AG, servem para filtrar valores no espaço de busca admissível para a série temporal.

Durante o processo de previsão de cenários otimistas e pessimistas o importante é a visualização de tendências da série perante as alterações do comportamento histórico

da série temporal, refletindo assim alteração no domínio da aplicação. Tendo como exemplo o mercado de compra de energia essas alterações poderiam representar anomalias provocadas por crises econômicas, saídas e entradas de clientes de grande porte, mudanças de políticas públicas (projeto Luz para Todos do Governo Federal), entre outras alterações que podem interferir diretamente no consumo de energia e, por conseguinte, alterar toda uma programação de previsão de consumo sem que esta informação tivesse algum indicativo nos dados históricos, ou seja, nunca tinha ocorrido antes ou não é frequente.

Assim, com o *framework* para a previsão de cenários proposto nesta tese, é possível disponibilizar um sistema não apenas previsor de séries temporais, mas também de suporte a decisão baseado em cenários de previsão que auxiliem os especialistas do domínio a planejarem suas ações de forma a obter contratos mais vantajosos de compra de energia no mercado futuro.

4.4.3. Vantagens da Abordagem Proposta

Com relação às principais contribuições abordadas nesta tese, é possível citar as seguintes:

- Proposta de desenvolvimento de um framework que utilize ao máximo as potencialidades das técnicas de previsão com as técnicas de otimização em um sistema híbrido intercomunicativo para a geração de cenários futuros que possam mostrar, além das previsões normais com base nos valores históricos, percursos alternativos das curvas das séries temporais analisadas.
- Desenvolvimento de um novo modelo de integração entre RNAs e AGs para a construção de um SHI que aproveite bem as vantagens de cada uma dessas técnicas, como as descritas no capítulo 2 desta tese.
- Construção modular de SHI neurogenético para aplicação em séries temporais. Na proposta do *framework*, o sistema híbrido é baseado em dois módulos distintos, um módulo previsor baseado em RNAs, modelado e treinado na fase inicial de construção do sistema híbrido, e um módulo gerador de cenários baseado em AGs e que realiza a exploração do espaço de previsão da série temporal com base no módulo previsor.

- Previsão de séries temporais com a utilização de um *framework* baseado em SHIs capazes de subsidiar os especialistas do domínio quanto à possibilidade de, antecipadamente, poder analisar os cenários capazes de mostrar tendências de comportamento da série baseada em alterações dos valores atuais (cenários exploratórios) ou os cenários capazes de mostrar quais comportamentos da série poderiam levar ao alcance de um determinado estado pré-estabelecido (cenários antecipatórios).
- Análise de séries temporais através da geração de cenários futuros para os quais a série temporal possa convergir caso ocorra algum fator externo, ou mesmo a identificação de tendências, melhorando assim a qualidade da informação analisada. Essas análises podem ser utilizadas como fonte de informações para que os especialistas possam conduzir estratégias ou medidas de contingências nos processos de tomadas de decisões.
- Melhoria do processo de previsão de consumo de energia elétrica empregado pelas empresas distribuidoras, pois o setor elétrico como um todo possui grandes problemas nesta área de previsão, sendo afetado por diversos fatores e situações adversas do domínio de aplicação. Isso se torna mais evidente quando para a região amazônica, que possui uma dinâmica própria com características diferenciadas do resto do país e está em constante expansão.

4.5. Considerações Finais

Neste capítulo foi apresentada a proposta de um *framework* baseado em um novo modelo de sistema híbrido neurogenético para a previsão de cenários futuros aplicados a problemas de previsão de séries temporais. Foram mostradas as motivações, justificativas e potencialidades do emprego da técnica de RNA juntamente com os AGs para a construção do sistema híbrido em questão. Também foram expostas neste capítulo as contribuições da estratégia proposta para a área de SHIs e previsão de séries temporais, onde pode-se apontar como principal contribuição do *framework* proposto a utilização de um sistema híbrido inédito neurogenético capaz de gerar previsões de cenários futuros que auxiliem o processo de análise das tendências e anomalias de

comportamento das séries temporais, se tornando assim uma importante ferramenta de suporte a decisão para os especialistas da área de previsão de séries temporais.

Em razão de uma das principais motivações para elaboração deste framework ter origem nas necessidades demandadas do setor elétrico, particularmente dos projetos de pesquisa e desenvolvimento (P&D), executados no âmbito do Laboratório de Planejamento de Redes de Alto Desempenho (LPRAD), é demonstrada, no próximo capítulo, a aplicação do método desenvolvido, com vistas, principalmente, à previsão do consumo de energia elétrica e à análise dos impactos nos valores previstos desse consumo com base na geração dos cenários futuros de consumo de energia elétrica.

5. Estudo de Caso: Geração de Cenários de Consumos de Energia Elétrica.

5.1. Considerações iniciais

O mercado de energia elétrica é muito sensível às mudanças sociais, econômicas, ambientais e políticas (domésticas ou internacionais) que ocorrem no presente, bem como às percepções destas no futuro, provocando alterações tanto na oferta como na demanda de energia. A evolução do consumo de energia elétrica representa um valioso indicativo do comportamento sócio-econômico de uma sociedade. Aspectos como crescimento da produção industrial, evolução demográfica e inserção de novos hábitos de conservação estão intimamente ligados ao uso de eletricidade como insumo básico [EPE, 2005]. Desta forma, para as empresas de distribuição de energia o dimensionamento cada vez mais preciso do consumo requerido se torna fator fundamental para o processo de compra e venda de energia.

Neste capítulo, é apresentada a contextualização da estratégia proposta e uma breve introdução sobre o processo de comercialização de energia elétrica no Brasil, em seguida são apresentados os modelos do *framework* proposto na aplicação de um estudo de caso de previsão de energia elétrica da Concessionária de Energia Elétrica do Estado do Pará (CELPA), depois a avaliação dos resultados de previsão e, finalmente, simulações de geração de cenários.

5.2. Contextualização da Estratégia Proposta

As investigações aqui descritas foram originadas a partir das demandas dos projetos de pesquisa e desenvolvimento (P&D) “Predict - Ferramenta de Suporte à Decisão para Predição de Cargas de Sistemas Elétricos” e “Predict II - Estratégias de Melhoria da Interpretabilidade das Inferências Bayesianas Utilizadas no Sistema Predict”, ambos financiados pela “Agência Nacional de Energia Elétrica do Brasil (ANEEL)”, dentro do ciclo de P&D da CELPA, que foi executado entre os anos de 2004 e 2009.

Este projeto, realizado em parceria com o Governo do Estado do Pará e a CELPA, visou, basicamente, a projetar e implementar um sistema de suporte à decisão,

utilizando métodos matemáticos e de IA, para prever as necessidades de compra de energia no mercado futuro e para realizar inferências sobre a situação do sistema elétrico, a partir de dados históricos de consumo e suas correlações com dados sócio-econômicos e climáticos.

O Predict (I e II) se pauta no fato de que a previsão de carga (carga elétrica em MW) é uma estratégia primordial dos sistemas elétricos. É baseada nessa previsão que se planejam e operam esses sistemas, de forma confiável e segura. Tipicamente, em previsão de carga, pretende-se definir qual o consumo de energia futuro de uma dada região, de modo, por exemplo, a projetar ou adequar o sistema elétrico para atender esses consumidores, quando tais demandas se concretizarem no futuro. Assim, baseado no histórico das medidas do sistema (principalmente nas informações sobre o próprio consumo), deseja-se obter uma prospecção das necessidades futuras, com uma precisão aceitável.

Além disso, utilizando as estratégias de prospecções, como a proposta nesta tese, as concessionárias de energia elétrica podem estimar de maneira satisfatória a compra de energia baseada na demanda futura e nas relações de preços apresentadas pelos fornecedores do Brasil, o que pode levar a uma economia financeira substancial, em função da diminuição da diferença entre a quantidade de energia comprada e consumida.

Neste tipo de situação, a previsão de carga deve manipular dados históricos de cargas elétricas registrados em seus bancos de dados. Então, como entrada básica dos estudos tem-se os dados históricos de cargas, obtidos em intervalos de coleta convenientes, no caso das empresas do Grupo REDE a coleta do consumo de energia é armazenada em consumo de energia diária e mensal. Como saída do processo de previsão, tem-se os dados referentes à previsão do consumo de energia a curto prazo e a médio prazo, que no processo de compra de energia no mercado futuro esses prazos são até um ano e de 3 a 4 anos, respectivamente.

Apesar do modelo de previsão de consumo de energia elétrica utilizado pelas empresas distribuidoras de energia ser razoavelmente eficaz, o Predict (I e II) mostrou que ainda existe espaço para melhorar e aperfeiçoar esta previsão com a pesquisa, modelagem e o desenvolvimento de novas técnicas, principalmente com a ajuda de métodos provenientes da inteligência computacional, que consigam lidar com a

dinâmica do sistema elétrico brasileiro, que possui características diferenciadas em cada região e, no caso da Amazônia, está em constante expansão.

Neste ponto, a geração de cenários de consumos de energia elétrica com base em um framework que conseguisse unir técnicas de otimização com as técnicas de previsão de consumo surgiram como solução bastante atrativa para serem aplicadas como ferramentas capazes de analisar e gerar alternativas de planejamento e tomadas de decisões com relação aos impactos das anomalias gerando fenômenos de incremento e decremento das necessidades de oferta de energia elétrica aos consumidores.

Ao longo da execução do Predict, os especialistas do domínio identificaram a necessidade de lidar-se com os possíveis comportamentos futuros, provenientes de consumos anômalos ou mesmo ruidosos, do problema de previsão de consumo de energia nas empresas do grupo Rede, de forma a conseguir identificar tendências de elevação e decréscimo do consumo de energia ao longo do tempo.

Pensando nas diferentes alterações na curva normal do consumo de energia, possíveis alterações desse perfil podem ser melhor analisadas e até previstas, com base nos indicativos das alterações ocorridas nos meses correntes. A exemplo do que ocorreu na crise econômica de 2008, onde os valores dos consumos de energia dos meses de novembro e dezembro de 2008 começaram a indicar queda nos consumos dos meses subsequentes de 2009, porém nenhum sistema de previsão (mesmo a curto prazo – 01 ano) conseguia avaliar o impacto dessa perturbação que começou a ocorrer no final de 2008 para os consumos dos meses de 2009. Com a utilização dos cenários poder-se-ia avaliar melhor como essa tendência de queda poderia alterar a curva de consumo dos meses de 2009.

Durante o processo de geração de cenários otimistas e pessimistas o importante é a capacidade de visualização de tendências da série perante as alterações do comportamento histórico da série temporal, refletindo assim alteração no domínio da aplicação como anomalias provocadas por crises econômicas, saídas e entradas de clientes de grande porte, mudanças de políticas públicas (projeto Luz para Todos do Governo Federal), entre outras alterações que podem interferir diretamente no consumo de energia e por conseguinte alterar toda uma programação de previsão de consumo sem que esta informação tivesse algum indicativo nos dados históricos, ou seja, nunca tinha ocorrido antes ou não é frequente. Entretanto, na previsão do cenário normal é levada

em consideração a precisão do modelo, pois esta é realizada sem alterações dos valores históricos da série temporal.

5.3. Processo de Comercialização de Energia Elétrica no Brasil

O Setor Elétrico Brasileiro, em seu processo evolutivo, vem apresentando significativas mudanças, tanto no que se refere à sua estrutura e regulamentação, quanto a própria composição e gestão empresarial.

Em 2003, teve início a instauração do atual modelo do setor de comercialização de energia elétrica brasileiro, com a publicação das diretrizes da “Proposta de Modelo Institucional do Setor Elétrico” em julho e da Medida Provisória 144 em dezembro. A Medida Provisória 144/2003 originou, em março de 2004, a Lei nº 10.848, que dispõe sobre a Comercialização de Energia. Logo em seguida, a mencionada lei foi regulamentada pelo Decreto 5.163/2004, que juntamente com o decreto 5.177/2004 e pela Resolução Normativa ANEEL nº 109/2004, instituiu a Câmara de Comercialização de Energia Elétrica (CCEE), que a partir dessa data, desempenharia os papéis de contabilização e liquidação das operações de curto prazo do mercado de energia e administração dos contratos de compra e venda de energia dos consumidores regulados.

As relações comerciais entre os agentes (de geração, de distribuição e de comercialização de energia) participantes da CCEE são regidas predominantemente por contratos de compra e venda de energia, e todos os contratos celebrados entre os agentes no âmbito do Sistema Interligado Nacional devem ser registrados na CCEE [Costa e Pierobon, 2008].

A comercialização de energia é dividida, quanto à natureza de seus contratos, em dois ambientes distintos: o Ambiente de Contratação Livre (ACL) e Ambiente de Contratação Regulada (ACR).

O ACR é destinado às empresas que forneçam energia aos consumidores finais de forma regulada. Nesse ambiente a comercialização de energia elétrica acontece por meio de leilões, onde os agentes vendedores (geradores, importadores e comercializadores) podem comercializar a sua energia com as empresas de distribuição, segundo procedimentos definidos pelo Decreto nº 5.163/2004. O agente vendedor que

comercializar sua energia por meio desses leilões deve assinar contratos com todas as distribuidoras que participaram do certame.

Já no ACL, a comercialização de energia é realizada diretamente entre os agentes comercializadores, geradores e consumidores livres, e os termos contratuais são acertados livremente. Em linhas gerais as condições contratuais foram muito pouco alteradas quando comparadas com o formato praticado anteriormente à Lei 10.848/2004. Nas regras do modelo atual incluíram-se algumas restrições com respeito às quantidades contratadas e penalidades, além da obrigatoriedade de adesão à CCEE de todos os Consumidores Livres.

A CCEE contabiliza as diferenças entre o que foi produzido ou consumido e o que foi contratado. As diferenças positivas ou negativas são liquidadas no Mercado de Curto Prazo e valorado ao PLD (Preço de Liquidação das Diferenças). Dessa forma, pode-se dizer que o mercado de curto prazo é o mercado das diferenças entre montantes contratados e montantes medidos.

Com a centralização das aquisições de energia por parte da CCEE, os riscos das distribuidoras aparentemente diminuiriam, decorrente do fato das mesmas deixarem de ser responsáveis por viabilizar projetos de geração e, em consequência, por fazer as aquisições em volume suficiente para atender à demanda de suas áreas de atuação. Entretanto, o novo modelo impõe um risco considerável nas estimativas de energia requerida para atendimento de suas áreas de concessão, levando as empresas a investirem cada vez mais em técnicas mais eficientes de previsão, haja vista que as mesmas são punidas caso cometam erros de previsão [Barros et al., 2009][EPE, 2005].

Além disso, existe o fato de que o valor das punições é calculado com base em uma componente estocástica com alto grau de volatilidade - o PLD, sob a qual as distribuidoras não têm ingerência, visto que o PLD depende de vários fatores, tais como o dos níveis dos reservatórios e a expansão do sistema hidrotérmico. Face à variação do PLD, há um considerável risco na possibilidade de punição decorrente de erros na estimativa da demanda [Rocha, 2009].

Previsões incorretas na compra de energia elétrica podem afetar negativamente as operações das concessionárias. As previsões abaixo do necessário, além de sujeitar essas empresas a multas, ainda as obrigam a celebrar contratos de energia de curto prazo, o que eleva em muito o preço de compra da energia, para atender a demanda dos

seus consumidores. Caso sejam realizadas previsões acima do necessário, também decorrem penalidades da ANEEL. Além do que nem sempre é possível repassar integralmente às tarifas, os custos advindos dessas previsões incorretas.

As regulamentações da ANEEL estabelecem que as distribuidoras de energia devam contratar antecipadamente, por meio de leilões públicos suas necessidades de energia. Essas normas também delineiam as condições gerais para o repasse dos volumes e preços de comercialização de energia. Caso a energia contratada, incluindo aquela comprada em leilões públicos, após aplicação do Mecanismo de Compensação de Sobras e Déficits de Energia (MCSD) for inferior a 100% da necessidade de energia total, as empresas estarão sujeitas a multas. Se a energia contratada for superior a 100% e inferior a 103% da necessidade de energia total, pode-se repassar o volume total de energia comprada para os consumidores. Já no caso da energia contratada ser superior a 103% da necessidade de energia total, tem-se que assumir o risco entre a diferença de preço de compra nos leilões públicos e venda no mercado de curto prazo, não sendo permitido, ainda, repassar esses custos aos consumidores.

Esta seção mostrou que no mercado de energia atual brasileiro, para as empresas de distribuição de energia elétrica a importância do desenvolvimento de sistemas de previsão que consigam cada vez mais realizar previsões mais precisas, mesmo em sistemas em constante expansão como é o caso da Amazônia, é crucial para que se possa realizar contratos de compra e venda de energia mais lucrativos e essencial para o desenvolvimento da região, pois a energia elétrica é tida também como insumo básico [EPE 2005].

5.4. Aplicação da Estratégia Proposta

Para ilustrar a aplicação da estratégia proposta nesta seção serão mostrados dois estudos de casos sobre a previsão de consumo de energia e o processo de geração de cenários, com base nos dados de consumo total de energia elétrica (energia requerida) de uma das empresas do Grupo Rede Energia, a CELPA. No anexo A, são mostrados os estudos de casos para a empresa Centrais Elétrica Matogrossense (CEMAT), também pertencente ao Grupo Rede Energia.

O objetivo do estudo foi aplicar o *framework* para realizar a previsão de consumo de energia elétrica a curto prazo (até um ano), podendo ser estendido para

previsões de médio prazo (até três anos), de acordo com o processo de compra de energia elétrica no mercado futuro gerido pela CCEE. Além de realizar previsões do consumo de energia, o estudo de caso também teve como objetivo analisar possíveis oscilações provenientes de alterações de mercado, crises, entre outras situações não previstas, que pudessem alterar a demanda futura de energia das séries em estudo. É importante frisar que essas oscilações podem representar um forte impacto na demanda de energia, influenciando o consumo para baixo com as crises econômicas, de oferta (acionamento) de energia provocada pelo baixo índice pluviométrico nas usinas hidroelétricas, por exemplo, ou para cima com a expansão da rede elétrica, instalação de novas indústrias, aquecimento global, etc.

Com a aplicação do *framework*, o problema é resolvido em duas etapas. Na primeira etapa, é configurado e treinado o módulo predictor do *framework*, que no estudo atual é baseado em RNAs. Os dados históricos de consumo de energia são utilizados como fonte de informação para iniciar a realização desta tarefa, por meio da divisão dos dados de treinamento e teste. A modelagem desses dois conjuntos de dados impacta diretamente na definição da estrutura da RNA através da configuração da camada de entrada (janela de previsão) e da camada de saída (horizonte de previsão) da rede. Durante a execução desta etapa o objetivo é encontrar a melhor RNA, em termos de erro de previsão sobre o conjunto de teste, para realizar a tarefa do módulo predictor do *framework*.

Na segunda etapa de construção do *framework*, é modelado o AG que guiará o processo de criação dos cenários futuros da série temporal. Nesta etapa são levadas em consideração as configurações das entradas e saídas das RNAs já modeladas e treinadas no módulo predictor, além dos tipos de cenários a serem explorados (cenários exploratórios ou antecipatórios). Isso se deve ao fato de que a técnica de geração de cenários para realizar as buscas por cursos alternativos da série temporal em estudo, utiliza um AG que tem como função de aptidão a RNA treinada anteriormente no módulo predictor.

Uma vez modelado o AG, o próximo passo desta etapa é realizar a busca pelos valores de consumo que maximizem, de acordo com uma meta (cenários otimistas), as previsões dos consumos de energia para um determinado horizonte de previsão, ou por outro lado, que minimizem, também de acordo com uma meta (cenários pessimistas), as previsões dos consumos de energia para um determinado horizonte de previsão. As

previsões realizadas pelo módulo previsor sem a interferência do AG representam os cenários normais de previsão, ou seja, a curva originalmente prevista.

Durante o processo de previsão de cenários otimistas e pessimistas pode-se visualizar tendências da série perante as alterações do comportamento histórico da série temporal, refletindo assim alteração no domínio da aplicação, como anomalias provocadas por crises econômicas, saídas e entradas de clientes de grande porte, mudanças de políticas públicas, entre outras alterações que podem interferir diretamente no consumo de energia e por conseguinte alterar toda uma programação de previsão de consumo, sem que esta informação tivesse algum indicativo nos dados históricos, ou seja, nunca tinha ocorrido antes ou sua ocorrência não é freqüente (uma anomalia/ruído). Por outro lado, na previsão do cenário normal é levada em consideração a precisão do modelo, pois esta é realizada sem alterações dos valores históricos da série temporal.

5.5. Previsão de Consumo para a Energia Requerida Total

Durante a execução do projeto Predict (I e II), o problema de previsão de energia elétrica foi abordado principalmente por meio de técnicas para predição dos modelos de séries temporais por regressão e RNAs.

O método de regressão aplicado incorporou não só o conhecimento dos valores de consumo históricos, mas também o uso de variáveis virtuais e contenção do impacto exercido por anomalias no consumo de energia, no caso específico do Brasil, decorrentes da medida de racionamento de energia, entre os anos de 2001 e 2002 (o “apagão” como é comumente conhecido). Com a utilização da técnica de RNAs, procurou-se explorar ao máximo as características inerentes aos modelos neurais, como aprendizado, generalização a partir dos dados históricos e tratamento de funções contínuas multi-variáveis lineares e não lineares, no problema de previsão do consumo de energia elétrica.

Os dados utilizados nas análises desta seção são referentes ao consumo total de energia elétrica (energia requerida total) para todo o estado do Pará. O estudo realizado se valeu do histórico de dados disponíveis de energia requerida no período de janeiro de 1991 a dezembro de 2006. Como discutido em trabalhos anteriores [Rocha et al 2006], a série do consumo de energia é tendenciosa e não-estacionária. A série ainda, estudando

seus correlogramas (Figura 5.1), não atinge estacionariedade em sucessivas diferenciações.

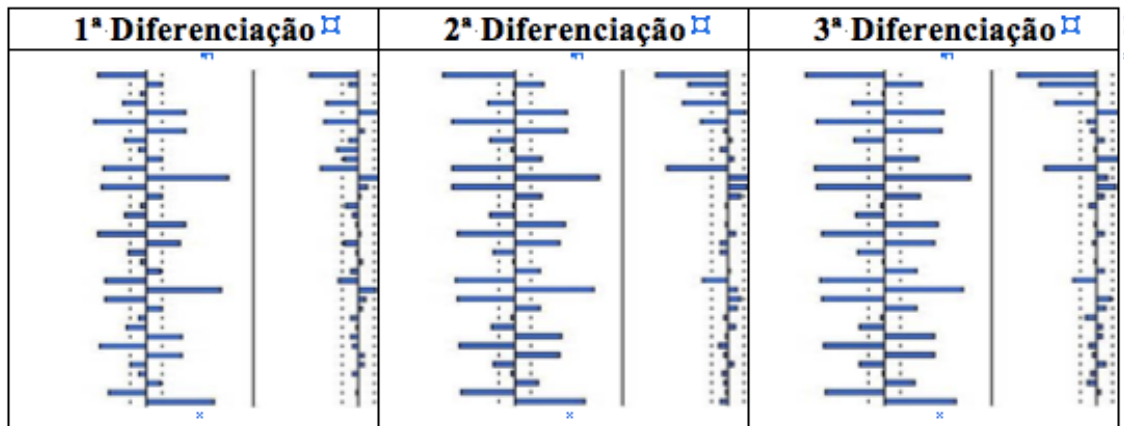


Figura 5.1. Autocorrelação e Correlação Parcial da 1ª, 2ª e 3ª diferenciação da série.

Tendo sido verificado pelo comportamento dos dados que se trata de uma série “explosiva”, e que a mesma, dessa forma, não atingia estacionariedade, observando-a como um todo, os estudos realizados em [Santana et al 2007] utilizou uma nova abordagem, conforme a seguir. Seccionou-se a série única de dados, antes mensal, em doze séries anuais, correspondentes aos meses de janeiro a dezembro. As séries, agora anuais, apresentaram a característica de estacionariedade e um comportamento quase linear para seu crescimento, como pode ser observado na Figura 5.2.




Figura 5.2. Histórico do consumo de energia de 1991 a 2006.

Com base na definição das séries, foram empregados os modelos de previsão. A seguir, será apresentado o modelo baseado em métodos de regressão.

5.5.1. Previsão com o uso de Métodos de Regressão

Segundo o trabalho de [Santana et al 2007] o estimador estabelecido para realizar a predição dos valores futuros de consumo de energia se utilizaram da análise de regressão múltipla (ver [Pindyck e Rubinfeld 1998], [Hair et al 1998], [Rice 1995]), sendo baseada na análise do valor do consumo obtido previamente e de dois termos adicionais. A fórmula geral do modelo de regressão múltipla pode ser especificada da seguinte forma:

$$Y_i = A_0 + A_1 X_{1i} + A_2 X_{2i} + \dots + A_k X_{ki} + u_i \quad (5.1)$$

O sistema geral de regressão múltipla por sua vez pode ser visto como um sistema matricial e representado da seguinte forma:

$$\begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} 1 & X_{11} & X_{12} & \dots & X_{1k} \\ 1 & X_{21} & X_{22} & \dots & X_{2k} \\ \vdots & \vdots & \vdots & & \vdots \\ 1 & X_{n1} & X_{n2} & \dots & X_{nk} \end{bmatrix} \times \begin{bmatrix} A_0 \\ A_1 \\ \vdots \\ A_k \end{bmatrix} + \begin{bmatrix} u_0 \\ u_1 \\ \vdots \\ u_k \end{bmatrix} \quad (5.2)$$

Onde:

Y é um vetor coluna, com dimensão $n \times 1$ de observações ou registros da variável dependente ou variável-alvo Y ;

X é uma matriz de ordem $n \times k$, ou seja, n observações e k variáveis, onde a primeira coluna representa o intercepto A_0 ;

A é um vetor coluna com $k \times 1$ parâmetros desconhecidos;

u é um vetor coluna com $n \times 1$ distúrbios.

Essa especificação objetivou gerar os valores dos parâmetros do vetor A . Para isto, empregou-se o método dos mínimos quadrados ordinários (MQO). Ele permitiu gerar estimativas para os coeficientes de tendência da regressão (parâmetros A) com menor variância e não-viesados. O método de MQO consiste em minimizar a soma dos erros quadrados da regressão estimada.

Como fora apontado, a análise com a série de dados disposta mensalmente é não-estacionária, o que dificulta o seu estudo; razão que motivou a análise de forma anual, seccionando-a em doze séries. No entanto, ao se trabalhar com cada mês

individualmente, é factível a perda de conhecimentos decorrentes de eventos ou situações exógenas ao comportamento padrão do sistema que tenham ocorrido no decorrer dos meses que se seguem até a próxima instância do mês analisado, e que por sua vez podem contribuir para a modificação do seu consumo no ano seguinte. Como exemplo de tais eventos, podem ser citadas as relações de perda ou aquisição de contratos pelas concessionárias de energia, projetos ou gestões governamentais, etc.

Desta forma, com o intuito de considerar na análise o impacto de tais eventos no decorrer do ano e assim obter um valor mais ajustável da predição, juntamente com o consumo anterior, foi adicionada uma variável quantificando a tendência anual de acordo com o comportamento apresentado ao seu decorrer. A variável incluída foi obtida por meio de uma análise fatorial (para uma visão mais completa sobre análise fatorial ver [Dillon et al 1984]), de modo a condensar as informações e tendências ocorridas no ano. A análise fatorial em si denota a redução de um conjunto de variáveis de um domínio para um modelo com alguns poucos fatores sempre tentando manter ao máximo a representatividade e relação entre as variáveis originais. A análise fatorial foi realizada sobre as doze séries anuais, obtendo-se na análise um único fator que melhor representa a série (em torno de 99.6%) e, por sua vez, o comportamento anual.

O segundo termo adicionado diz respeito à contenção do impacto exercido por anomalias existentes no histórico do consumo de energia. No trabalho de [Santana et al 2007], foi abordado o período anômalo no consumo de energia de junho de 2001 a fevereiro de 2002, caracterizado pela ocorrência da medida de racionamento de energia nacional [ANEEL 2003] e que atuou como um ponto de inflexão no crescimento do consumo, como pode ser visto na Figura 5.2, causando, ao seu término, um desvio na tendência de crescimento. Desta forma, foi adicionada às series mensais uma variável artificial binária para considerar a ocorrência do apagão, indicando a presença ou ausência de um valor impactado diretamente pela ocorrência do apagão, ou ainda que divirja da natureza do restante da série, atribuindo valores 1 ou 0, respectivamente. Não somente o período de vigência da medida de racionamento é trabalhado, mas também alguns meses que o seguiram até que a série voltasse à normalidade, persistindo em uma presença de queda no consumo de energia.

O modelo foi aplicado primeiramente de modo a verificar a confiabilidade do estimador, utilizando parte da base de dados histórica existente (Jan/05 a Dez/06) para teste. Assim, foram aplicados alguns testes em cima do modelo de regressão, para

apenas posteriormente realizar a projeção do seu comportamento para os anos de 2005 a 2008, com o objetivo de se avaliar o modelo para previsões acima de 01 ano. Os resultados destes testes, assim como dos outros modelos empregados, serão apresentados na seção 5.5.4.

5.5.2. Previsão com o uso de RNAs

Para a construção do modelo de previsão baseado em RNAs, as análises realizadas durante a execução do projeto Predict tiveram como base a definição de três etapas principais: (a) identificação e definição da informação necessária para representar a série e o horizonte de previsão; (b) modelagem da RNA; (c) escolha do algoritmo de aprendizado da RNA capaz de aprender as características da série e realizar a previsão com sucesso.

Durante o processo de identificação e definição das variáveis de entrada para o processo de previsão, a variável consumo, que representa a energia requerida mensalmente, foi decomposta em doze séries uma para cada mês do ano. Além da variável consumo, foram utilizadas as variáveis data e a taxa de crescimento entre anos consecutivos.

Para realizar a previsão com RNAs empregou-se a técnica de “janelamento” sobre a variável consumo, na qual consiste em usar sequências de valores passados (janela de tempo) da variável sobre a qual se deseja realizar a previsão, bem como o horizonte de previsão, ou seja, os valores a serem previstos. A Figura 5.3 ilustra as entradas e saídas selecionadas para modelar as camadas de entrada e saída das RNAs.

Selecionar uma arquitetura apropriada para o problema é o primeiro passo para um sistema de previsão baseado em RNAs. Neste trabalho, optou-se por utilizar a rede perceptron multicamada feedforward (MLP), com apenas uma camada escondida, devido ao seu amplo emprego em sistemas de previsão [Adya e Collopy 1998], [Haykin, 1999], [Russel e Norvig 2003].

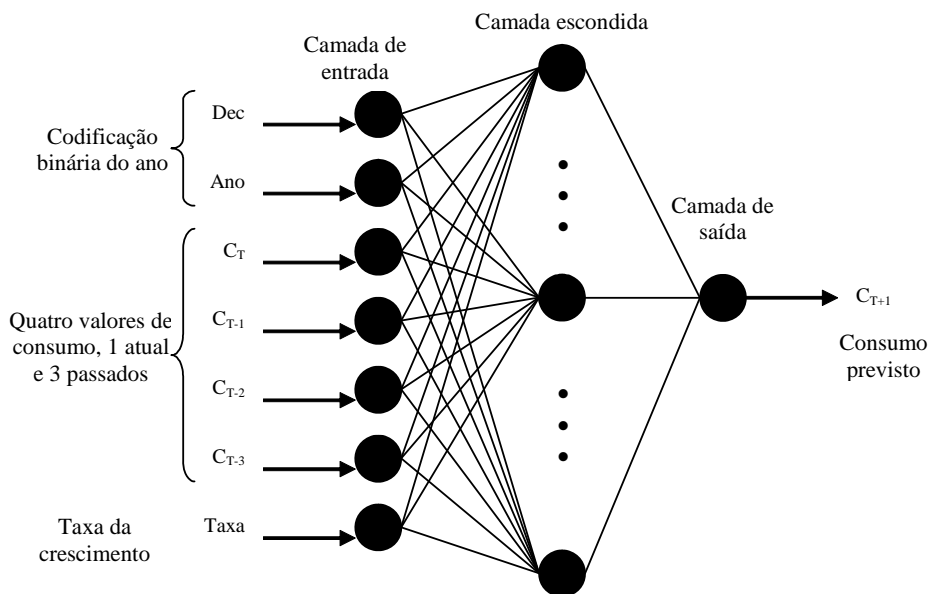


Figura 5.3. Arquitetura da RNA para histórico do consumo de energia de 1991 a 2006.

Após extensas simulações cujo objetivo foi variar o número de neurônios na camada de entrada e de saída da rede, de forma que a série temporal fosse melhor representada, a configuração que obteve melhores resultados foi a rede MLP apresentada na figura 5.3. Assim, a camada de entrada da rede foi composta por dois neurônios para codificar a data (Dec e Ano) do consumo atual (instante T), quatro neurônios para configurar o consumo nos instantes T , $T-1$, $T-2$ e $T-3$, além de um neurônio para representar a taxa de crescimento entre os consumos dos instantes T e $T-1$, totalizando sete neurônios na camada de entrada. A camada de saída foi composta por apenas um neurônio representando a previsão do consumo no instante $T+1$. O número de neurônios na camada escondida foi determinado dinamicamente durante o processo de treinamento da rede MLP.

As séries históricas mensais foram tratadas de forma independente através da previsão multimodelo [Hipper et al 2001]. Neste tipo de modelo, a previsão de cada série mensal é realizada por uma rede MLP diferente. Desta forma, no final do treinamento, são geradas doze redes MLP, uma para cada mês.

O algoritmo de treinamento escolhido para o aprendizado das redes MLP foi o *backpropagation*, um dos algoritmos de treinamento de RNAs mais utilizados em aplicações de previsão de séries temporais [Zhang et al., 1998].

Durante a etapa de treinamento da rede MLP com o algoritmo de treinamento *backpropagation*, o número de neurônios da camada escondida, a taxa de aprendizado da camada escondida e a taxa de aprendizado da camada de saída foram variados repetidamente, entre um mínimo e máximo definidos pelo usuário. Para cada combinação desses parâmetros foi criada uma rede MLP e aplicado separadamente o algoritmo de treinamento *backpropagation*. Desta forma, foi identificada a melhor combinação de parâmetros (melhor rede MLP) para o conjunto de dados utilizado, que, por sua vez, provêem os resultados com os menores erros de previsão sobre os dados de teste. O critério de parada do treinamento para cada configuração foi o erro MAPE sobre o conjunto de teste, garantindo assim melhor poder de generalização da rede. Após a finalização do processo de treinamento, a melhor rede MLP encontrada para realizar as previsões de consumo foi selecionada. Esse processo foi repetido para cada uma das doze séries que representam os consumos mensais.

Após a finalização do processo de treinamento, cada série mensal possui a melhor rede MLP encontrada para realizar as previsões de consumo daquele mês.

5.5.3. Previsão com o uso de RNAs Modeladas Através dos Cenários

Com a utilização das RNAs no módulo predictor da framework proposta neste trabalho, procurou-se explorar ao máximo as características inerentes das redes no que diz respeito à capacidade de reconhecer padrões em sistemas complexos, não-lineares e com quantidade razoável de ruído, em contraste com os métodos estatísticos convencionais onde essa capacidade não é encontrada. Outra importante característica das RNAs explorada foi sua capacidade de generalização, tornando-a um modelo ideal para problemas onde a quantidade de dados históricos é de certa forma limitada.

Durante o processo de identificação e definição das variáveis de entrada para o processo de previsão, e com o auxílio dos especialistas do domínio (analistas de Mercado e engenheiros da companhia), optou-se por realizar as previsões de consumo com base apenas nas informações da variável consumo total, que representa a energia total requerida mensalmente. Escolhida a variável a ser utilizada no processo de previsão, o próximo passo foi definir a janela de previsão e o horizonte de previsão (valores a serem previstos), ambas informações intrinsecamente ligadas à modelagem dos cenários a serem estudados na fase seguinte de aplicação da framework.

Partindo de estudos preliminares e após extensos experimentos, foi definido com a ajuda dos especialistas do domínio (engenheiros da CELPA) que a modelagem dos cenários seria configurada utilizando uma única rede MLP, com a janela de tempo correspondente a 12 valores consecutivos de consumos, representando os consumos dos meses entre janeiro e dezembro de um determinado ano, e o horizonte de previsão configurado em 12 valores consecutivos também, representando valores previstos de energia para os próximos meses (ano seguinte ao ano apresentado para a rede) de janeiro a dezembro. Para exemplificar, considere que seja escolhido como entrada para a RNA os valores dos consumos de janeiro a dezembro de 2005, a saída da rede é composta por 12 valores representando os consumos previstos para janeiro a dezembro de 2006, ver figura 5.4.

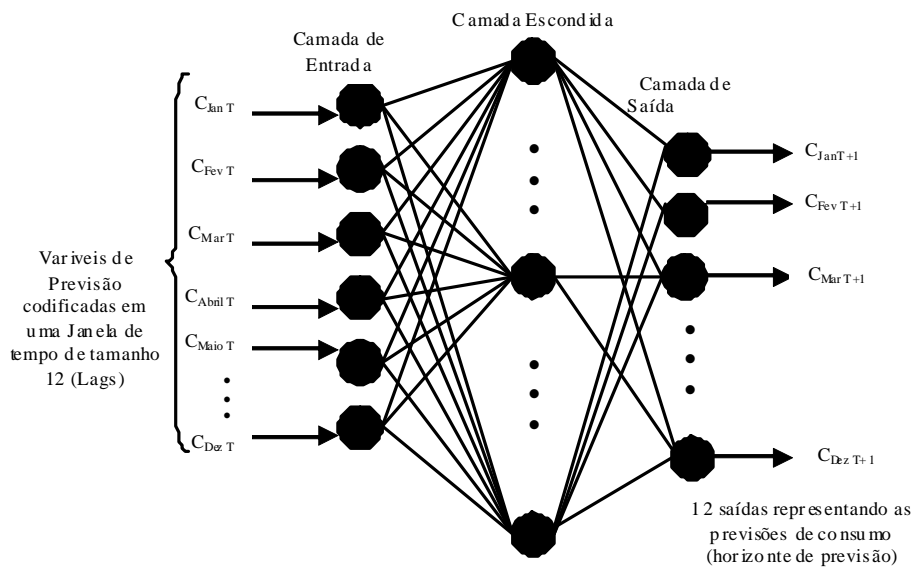


Figura 5.4. Arquitetura da RNA Modelada com Cenários.

No processo de modelagem da rede MLP, o número de neurônios da camada de entrada e saída foram fixados de acordo com a seleção das entradas e saídas. Entretanto, o número de neurônios na camada escondida é determinado dinamicamente durante o processo de treinamento da rede MLP, conforme descrito na seção anterior.

5.5.4. Avaliação dos Resultados de Previsão

Nas simulações realizadas com a regressão múltipla, foi aplicada a regressão utilizando apenas os valores referentes ao intervalo de janeiro de 1991 até dezembro de

2004, realizando com base nos mesmos uma estimaco dos valores para o ano de 2005 e 2006 (Figura 5.5).

O resultado obtido pela estimaco apresentou um erro MAPE de aproximadamente 1,60% para o ano de 2005 e 1.85% para o ano de 2006, valor doravante considerado no so aceitvel, mas tambm inferior aos obtidos pelos mtodos estatsticos utilizados pela concessionria de energia eltrica, os quais giram em torno 4,0% [Rocha et al 2006], [Santana et al 2007]. Para o clculo do erro MSE, os valores dos consumos previsto para os anos de 2005 e 2006 foram normalizados pelo mesmo valor utilizado para normalizar os dados para serem utilizados no treinamento das redes neurais. Desta forma, o erro MSE obtido para o ano de 2005 foi de 1.94×10^{-4} e para o ano de 2006 foi de 3.5×10^{-4} .

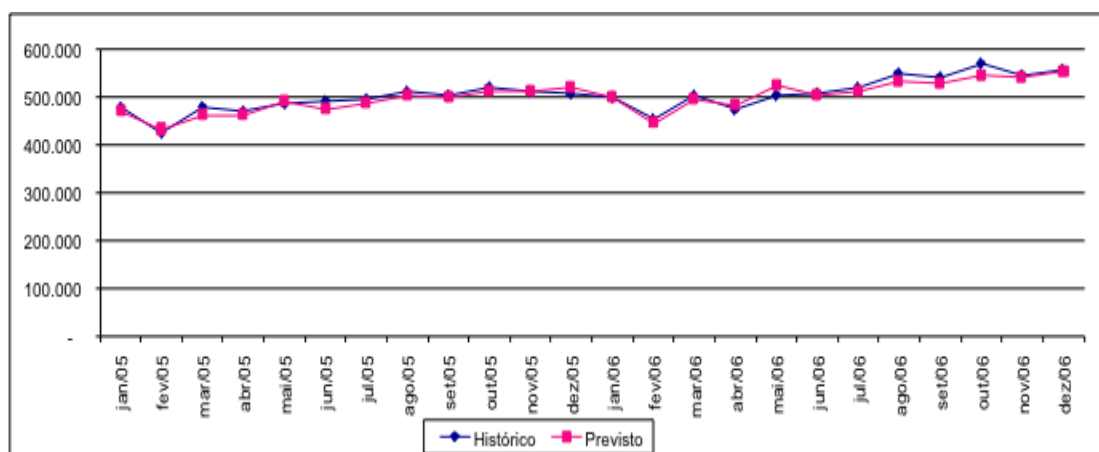


Figura 5.5. Valores reais e estimados de Jan/05 a Dez/06 do consumo de energia, via modelo de regresso

Uma vez verificada a efetividade do modelo de estimaco baseado em regresso para a srie de dados, foi feita uma projecco do seu comportamento para os anos de 2006 a 2008, para avaliar o poder de generalizaco do modelo em previses acima de 01 ano, como pode ser visto na Figura 5.6.

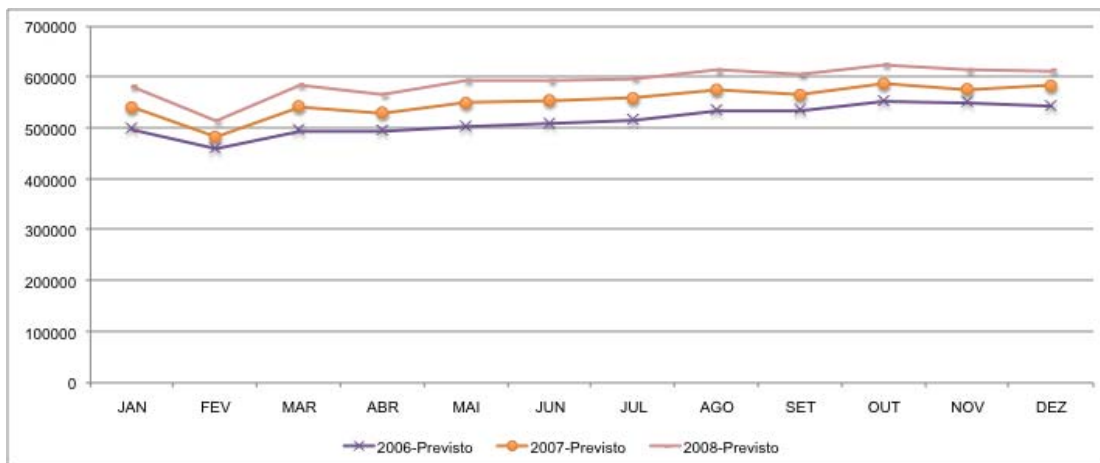


Figura 5.6. Valores previstos de consumo, utilizando modelo de regressão, para os anos de 2006 a 2008.

Para as redes MLP, foram utilizados primeiramente os conjuntos de treino os valores dos dados históricos referentes ao intervalo de 1991 até 2004 e para os conjuntos de teste os dados referentes a 2005. Após o processo de treinamento, para a rede que obteve o melhor desempenho foi realizada a estimação dos valores de consumo para os anos de 2005 e 2006 (Figura 5.7).




Figura 5.7. Valores previstos de consumo, empregando-se RNA para os anos de 2005 a 2006.

Como pode ser observado, o resultado obtido pela estimação apresentou um erro MAPE residual, de aproximadamente $2 \times 10^{-4} \%$, para o ano de 2005, apresentando também com isso, resultados bem superiores aos obtidos nos estudos previamente realizados em [Rocha et al., 2006], que denotaram erros em torno de 4,1%. No entanto, gerou um erro MAPE de 3,74% para o ano de 2006. Os valores apontaram dessa forma

uma estimação precisa para o primeiro ano, mas que, no entanto, declinou para o segundo ano de previsão. Na tabela 5.1 pode ser visualizado a média e o desvio padrão para os erros MAPE e MSE dos 10 melhores desempenhos das redes MLP.

Tabela 5.1. Desempenho da rede MLP para a Previsão dos anos de 2005 e 2006.

| Erro | MLP Seleccionada | Média | Desvio Padrão |
|-----------|------------------------|--------------------------|------------------------|
| MAPE 2005 | $2 \times 10^{-4} \%$ | $2.63 \times 10^{-4} \%$ | 5.90×10^{-5} |
| MAPE 2006 | 3.74 % | 4.31 % | 0.6912 |
| MSE 2005 | 4.37×10^{-12} | 7.91×10^{-12} | 2.92×10^{-12} |
| MSE 2006 | 0.0010 | 0.0014 | 5.11×10^{-4} |

Ato contínuo, o modelo de rede neural foi novamente aplicado, agora tendo como conjuntos de treino os valores dos dados históricos referentes ao intervalo de 1991 até 2005 e para os conjuntos de teste os dados referentes a 2006. A estimação dos valores de consumo foi então realizada para os anos de 2006, 2007 e 2008 (Figura 8), com o objetivo de avaliar o poder preditivo das redes em previsões acima de 01 ano.




Figura 5.8. Valores previstos de consumo, empregando-se RNA, para os anos de 2006 a 2008.

As redes MLPs modeladas através das técnicas de cenários, também foram treinadas utilizando como conjunto de treino os valores dos dados históricos referentes ao intervalo de 1991 até 2004 e para o conjunto de teste os dados referentes a 2005. Após o processo de treinamento, para a rede que obteve o melhor desempenho foi realizada a estimação dos valores de consumo para os anos de 2005 e 2006 (Figura 5.9).




Figura 5.9. Valores previstos de consumo, utilizando RNA modelada por meio de cenários, para os anos de 2005 e 2006.

Como pode ser observado, o resultado obtido pela estimação apresentou um erro MAPE de aproximadamente 0.77 %, para o ano de 2005, e para o ano de 2006 gerou um erro MAPE de 2.41%. Os valores apontaram dessa forma uma estimação muito boa para o primeiro ano, mas que, no entanto, declinou para o segundo ano de previsão. Na tabela 5.2 pode ser visualizado a média e o desvio padrão para os erros MAPE e MSE dos 10 melhores desempenhos das redes MLP modeladas através das técnicas de cenários.

Tabela 5.2. Desempenho da rede MLP/Cenário para a Previsão dos anos de 2005 e 2006.

| Erro | MLP Seleccionada | Média | Desvio Padrão |
|-----------|------------------|--------|---------------|
| MAPE 2005 | 0.77% | 0.77 % | 0.08 |
| MAPE 2006 | 2.41 % | 3.73 % | 0.95 |

| | | | |
|----------|-----------------------|-----------------------|-----------------------|
| MSE 2005 | 6.44×10^{-5} | 5.58×10^{-5} | 1.91×10^{-5} |
| MSE 2006 | 0.00057 | 0.0012 | 5.15×10^{-4} |

Seguindo a mesma metodologia das simulações realizadas anteriormente, as redes MLP modeladas através das técnicas de cenários, foram treinadas com os dados históricos dos anos de 1991 à 2005 e testadas com os dados de 2006. Com o intuito de avaliar o poder de generalização da referida rede, foi realizada a estimação dos valores de consumo para os anos de 2006, 2007 e 2008 (Figura 5.10).




Figura 5.10. Valores previstos de consumo, utilizando RNA modelada por meio de cenários, para os anos de 2006 a 2008.

Os resultados mostraram que a modelagem das RNAs através das técnicas de cenários melhoraram o poder de generalização dessas redes, quando comparados às primeiras simulações com as RNAs, além de apresentar erros de previsão para 1 e 2 anos melhores do que os modelos de regressão, quando comparados com os erros MSE.

5.5.5. Geração dos Cenários de Previsão

Após finalizar a etapa de criação do módulo de previsão via RNA, tem início a etapa de configuração e simulação do módulo gerador de cenários que consiste em

utilizar um AG para guiar a busca por valores dos atributos apresentados à camada de entrada da RNA, para que esta possa gerar os cenários configurados pelos especialistas do domínio.

No caso específico do estudo de caso, foi selecionado o ano de 2006 como alvo para se gerar os cenários de consumo de energia. Deste modo, antes de executar o AG primeiramente foram obtidos os dados necessários para a modelagem do cenário normal, que serve de parâmetro para guiar a busca pelo melhor indivíduo do AG.

O cenário normal é formado pelos valores previstos de consumo de energia elétrica para o ano de 2006 e para isso é necessário passar como entrada para o módulo previsor as informações de consumo do ano de 2005. Os dados de consumo do ano de 2005, podem ser obtidas por previsão (utilizando os dados de 2004 como entrada), ou a partir da base de dados histórica (utilizando valores reais de consumo de 2005), ou mesmo uma composição entre dados reais e previstos, dependendo do tipo de cenário estudado. Nas simulações realizadas, os valores dos consumos de 2005 foram obtidos através de previsão, e esses foram utilizados para como entrada para a RNA gerar a previsão para o ano de 2006, utilizado como previsão normal e base para o cálculo da meta a ser atingida pelo AG.

A interação entre o AG (módulo gerador de cenários) e as RNAs (módulo previsor da série temporal), ocorre de forma que o AG utilize as RNAs como função de aptidão para avaliar os indivíduos da população do AG. Desta forma, um indivíduo é representado como um vetor de 12 valores referentes aos consumos de energia elétrica de janeiro a dezembro de um determinado ano. A avaliação de cada indivíduo é baseada na previsão que a RNA realiza tendo como entrada o próprio indivíduo, ou seja, um indivíduo representa 12 meses de consumo de energia e sua aptidão, calculada pela RNA, representa os valores dos consumos de energia dos próximos 12 meses.

Partindo do cenário normal, os parâmetros usuais do AG (tamanho da população, método de seleção, crossover, etc...) foram configurados de acordo com a informação da tabela 5.3.

Tabela 5.3. Parâmetros utilizados nos AGs.

| Parâmetro | Valores |
|--------------------|---------------------------|
| População Inicial | 1000 indivíduos |
| Número de Gerações | 40 gerações |
| Seleção | Método do torneio com K=3 |
| Crossover | Cruzamento de um ponto |
| Taxa de Crossover | 85% |
| Taxa de Mutação | 0.1% |

As simulações foram realizadas com o objetivo de avaliar cenários de previsões para o ano de 2006 e como esses cenários impactavam nos valores de consumos do ano de 2005. Deste modo, foram levadas em consideração análises de aumento do consumo normal previsto para 2006 (cenários otimistas) e análises de diminuição da previsão desse consumo (cenários pessimistas), ambos de acordo com as taxas de 1.5%, 3.0% e 4.5% para crescimento e diminuição.

Cada indivíduo do AG é representado por 12 valores que fazem referência aos consumos dos meses de janeiro a dezembro do ano de 2005. A função de aptidão do AG, que avalia a qualidade dos indivíduos, é representada pela previsão de consumo para o ano de 2006 realizada pelo módulo predictor (via RNA) tendo como informação de entrada o próprio indivíduo (valores de consumo para 2005). Deste modo, levando-se em consideração as metas de aumento para o consumo de 2006, de acordo com as taxas 1.5%, 3.0% e 4.5%, respectivamente meta1, meta2 e meta3, ver figura 5.11, procurou-se encontrar valores de consumos para os meses de janeiro a dezembro de 2005 que satisfizessem tais metas de aumento para o ano de 2006, ver figura 5.12. O objetivo dessa análise foi avaliar o quanto um possível aumento do consumo para o ano de 2006 poderia modificar os consumos esperados para 2005.




Figura 5.11. Valores das metas de aumento do consumo para 2006.

No gráfico da figura 5.11 é mostrado a curva de consumo previsto para os meses de janeiro a dezembro de 2006 (previsão normal) e os valores de consumo previsto para 2006 encontrados pelo AG, de acordo com as metas de crescimento analisadas. É importante notar neste gráfico que esses valores de previsão para 2006 encontrados pelo AG, implicaram em alterações dos consumos previstos para os meses de janeiro a dezembro de 2005, como pode ser visto na figura 5.12.

Em seguida, foram executadas as mesmas buscas realizadas e mostradas na figura 5.11, mas desta vez tendo como alvo os consumos dos meses de julho a dezembro de 2005, pois os consumos de janeiro a junho ficaram constantes e representados pelos consumos históricos (valores realizados para o ano de 2005) desses meses. A idéia desta análise era avaliar, dado que já foram realizados os consumos de janeiro a junho de 2005, o impacto que possíveis aumentos no consumo do ano de 2006 poderiam acarretar nos valores dos consumos dos meses de julho a dezembro de 2005, o que pode ser visto nas figuras 5.13 e 5.14, respectivamente.




Figura 5.12. Valores dos cenários de consumos para janeiro a dezembro de 2005.

Na figura 5.13, pode-se notar que os valores de consumo de 2006 para as metas 2 e 3 foram os mesmos, pois somente com as alterações permitidas para os meses de julho a dezembro de 2005 não é possível encontrar um aumento do consumo de 2006 que satisfaça a meta de aumento 3 (em torno de 4.5%).




Figura 5.13. Valores das metas de aumento do consumo para 2006, caso 2

Continuando a demonstração do modelo proposto, foi realizada uma nova busca das previsões de energia elétrica, tendo como objetivo agora a diminuição do valor de consumo normal previsto para o ano de 2006 de acordo com as taxas -1.5%, -3.0% e -4.5%, respectivamente sendo representadas pela meta1, meta2 e meta3. Como na análise anterior, primeiramente foram analisados os casos cujos cenários foram compostos pelos valores de consumos de janeiro a dezembro de 2005, ver figuras 5.15 e 5.16.




Figura 5.14. Valores dos cenários de consumos para julho a dezembro de 2005.




Figura 5.15. Valores das metas de diminuição do consumo para 2006, caso 3

No gráfico da figura 5.15 é mostrado a curva de consumo previsto para os meses de janeiro a dezembro de 2006 (previsão normal) e os valores de consumo previsto para 2006 encontrados pelo AG, de acordo com as metas de diminuição analisadas. Como nos casos das metas de aumento do valor previsto de consumo para o ano de 2006, nos casos de diminuição da previsão para 2006 encontrados pelo AG, também implicaram em alterações dos consumos previstos para os meses de janeiro a dezembro de 2005, como pode ser visto na figura 5.16.




Figura 5.16. Valores dos cenários de consumos para janeiro a dezembro de 2005

Também foram realizadas simulações com as metas de diminuição do consumo de 2006 utilizando como alvo para as buscas do AG, os cenários formados pelos meses de julho a dezembro de 2005, ver figuras 5.17 e 5.18.

A figura 5.17, mostra também que tendo como possibilidade somente a alteração dos meses de julho a dezembro de 2005 não é possível atingir a meta de diminuição 3 para a previsão de consumo do ano de 2006.




Figura 5.17. Valores das metas de diminuição do consumo para 2006, caso 4




Figura 5.18. Valores dos cenários de consumos para julho a dezembro de 2005

Partindo de previsões normais, realizadas somente com as RNAs, o módulo gerador de cenários baseado em AGs pôde realizar buscas pelos cenários que melhor representassem as condições indicadas pelos especialistas, com o objetivo de analisar o comportamento da série temporal sob um ângulo de possibilidades de crescimento e

diminuição do consumo de energia elétrica previsto para o ano de 2006 e como essa alteração no consumo previsto impactaria sobre o consumo dos meses de janeiro a dezembro de 2005. As informações obtidas com os cenários gerados servem para melhorar o processo de comercialização de energia, sendo determinantes para o êxito nos processos de compra e venda de energia.

5.6. Considerações Finais

Neste capítulo, foi apresentado a aplicação do *framework* proposto nesta tese em um problema de previsão de consumo de energia da CELPA. Após uma introdução sobre a contextualização da estratégia proposta na solução do problema de aplicação, foi apresentado uma breve abordagem sobre a dinâmica do atual mercado de energia brasileiro, evidenciando ainda mais a importância de pesquisas de novas ferramentas e metodologias que consigam melhorar o poder preditivo das empresas distribuidoras de energia elétrica no processo de compra da energia oferecida aos seus clientes. Em seguida, foram apresentados os resultados de previsão obtidos com o *framework* e a geração dos cenários de oscilação do consumo previsto para os anos de 2005 e 2006.

Outro ponto importante a ser evidenciado neste capítulo, é que o *framework* proposto, embora tenha sido analisada sob o domínio dos dados históricos da CELPA, também pode ser aplicada para outras empresas do setor elétrico brasileiro, ver anexo A. Além disso, o foco da aplicação não está amarrado aos problemas de previsão de consumo de energia elétrica, sendo factível a qualquer problema de previsão de séries temporais que tenha uma base histórica dos valores a serem previstos.

6. Conclusões e Trabalhos Futuros

No atual modelo brasileiro de comercialização de energia elétrica por parte das concessionárias, o planejamento das ações de compra e venda de energia é um ponto chave no processo de tomada de decisão dessas e à sua própria sobrevivência como empresa, pois esse mercado está exposto a grandes variações de formação de preço, oferta e demanda de consumo de energia elétrica. Assim, as concessionárias devem ser capazes de otimizar as relações de preços apresentadas pelos fornecedores do Brasil, com base na compra de energia futura de acordo com suas reais necessidades, o que pode levar a uma economia financeira substancial em função da diminuição da diferença entre a quantidade de energia comprada e consumida, ampliando o seu potencial competitivo no mercado.

Neste contexto, este trabalho apresentou a proposta original de um *framework* baseado em sistemas híbridos inteligentes capaz de não somente realizar o processo de previsão de energia elétrica como também modelar uma solução de geração de cenários de consumos de forma a prover subsídios aos especialistas do domínio para que eles pudessem analisar as previsões com base em informações fora do escopo do histórico de consumo de energia armazenado na empresa. Com isso, estes especialistas podem simular o impacto de fatores externos ao consumo ou até mesmo a entrada ou saída de grandes consumidores do portfólio da empresa.

No processo de modelagem do *framework* para a aplicação de previsão de séries temporais, três pontos fundamentais são abordados na construção da solução. O primeiro ponto é a definição dos cenários, que envolve além do pré-processamento da base de dados histórica a definição das informações que serão utilizadas como entrada para o processo de previsão e quais serão as saídas deste processo, como também a forma como o processo de busca irá trabalhar para gerar os cenários alvos da análise.

O segundo ponto é responsável por realizar a previsão da série temporal e envolve a seleção e modelagem da técnica de previsão, que pode ser resultado de um processo de simulação para que possa se determinar qual ou quais as melhores técnicas de previsão mais adequadas para a previsão da série temporal em análise. Nas análises

realizadas nesta tese, a técnica empregada neste processo foi a RNA, com base nas justificativas abordadas no capítulo 2.

O terceiro ponto envolve a seleção e modelagem da técnica de otimização empregada na geração dos cenários de previsão. Neste tópico, o *framework* desenvolvido também poderá empregar diversas técnicas de otimização e busca, porém a técnica utilizada nas análises desta tese foi a dos AGs, em parte por se tratar de uma técnica que possui um alto grau de acoplamento com as RNAs, como visto no capítulo 3, e em parte pelo desenvolvimento de uma inovadora proposta de utilização das técnicas de AGs e RNAs, através da união dessas em um sistema híbrido intercomunicativo, onde as RNAs servem como função de aptidão para os AGs.

As contribuições deste trabalho podem ser caracterizadas em três aspectos: o primeiro, relacionado ao aperfeiçoamento das técnicas de previsão do consumo de energia elétrica, fornecendo assim ferramentas vantajosas de suporte à decisão aos especialistas do setor elétrico. O segundo, relacionado com a aplicação de técnicas provenientes da IA empregadas ao processo de previsão de séries temporais. Para finalizar, o terceiro aspecto está relacionado às contribuições inerentes ao processo de construção de um trabalho científico desta natureza.

Tomando-se como base o primeiro aspecto, são enumeradas as seguintes **contribuições** desta tese:

- A partir da proposta desenvolvida, é possível gerar cenários de previsões de consumo de energia de forma a contribuir diretamente para a qualidade da informação gerada pelo processo de previsão, melhorando assim os resultados obtidos pelas empresas nas suas projeções do consumo;
- O modelo proposto pode fornecer um arcabouço para os usuários de níveis decisórios das concessionárias de energia elaborarem planos de contingências, e mesmo adequações da previsão de consumo, quando identificadas situações adversas do domínio de aplicação que possam afetar o comportamento da curva de consumo e assim possam estabelecer contratos mais vantajosos no mercado futuro de energia;
- Definição de estratégias que possam melhorar o desempenho do processo de previsão de consumo de energia elétrica em oposição aos modelos de previsão de consumo baseados em técnicas estatísticas utilizados pelas

empresas distribuidoras de energia da Amazônia, como é o caso da CELPA, que demonstram ser muito ineficazes em lidar com a dinâmica do sistema elétrico da região em questão, que possui características diferenciadas do resto do país e está em constante expansão;

- A utilização de técnicas de geração de cenários futuros no problema de previsão do consumo de energia elétrica, possibilita incrementar a fase de pré-processamento e modelagem dos dados históricos de forma a enriquecer a informação repassada às técnicas de predição, melhorando assim o desempenho dessas técnicas;
- Prover um efetivo referencial de análise para pautar decisões relacionadas ao processo de comercialização de energia, onde previsões de consumo de energia baseado em análise de cenários possam apoiar essas previsões, determinantes para o êxito nos processos de compra e venda de energia;

Com relação às contribuições sobre as técnicas inteligentes empregadas no processo de previsão, é possível citar as seguintes:

- Proposta de desenvolvimento de um *framework* que utilize ao máximo as potencialidades das técnicas de previsão com as técnicas de otimização em um sistema híbrido intercomunicativo para a geração de cenários futuros que possam mostrar, além das previsões normais com base nos valores históricos, percursos alternativos das curvas das séries temporais analisadas;
- Desenvolvimento de um novo modelo de integração entre RNAs e AGs para a construção de um SHI que aproveite bem as vantagens de cada uma dessas técnicas, como as descritas no capítulo 2 desta tese;
- Construção modular de SHI neurogenético para aplicação em séries temporais. Nessa proposta, o sistema híbrido é baseado em dois módulos distintos, um módulo previsor baseado em RNAs, modelado e treinado na fase inicial de construção do sistema híbrido, e um módulo gerador de cenários baseado em AGs, que realiza a exploração do espaço de previsão da série temporal com base no módulo previsor;

- Previsão de séries temporais com a utilização de um *framework* baseado em sistemas híbridos inteligentes capazes subsidiar os especialistas do domínio quanto à possibilidade de, antecipadamente, poder analisar os cenários capazes de mostrar tendências de comportamento da série baseada em alterações dos valores atuais (cenários exploratórios) ou os cenários capazes de mostrar quais comportamentos da série poderiam levar ao alcance de um determinado estado pré-estabelecido (cenários antecipatórios);
- Análise de séries temporais através da geração de cenários futuros para os quais a série temporal possa convergir caso ocorra algum fator externo, ou mesmo a identificação de tendências, melhorando assim a qualidade da informação analisada. Essas análises podem ser utilizadas como fonte de informações para que os especialistas possam conduzir estratégias ou medidas de contingências nos processos de tomadas de decisões;

Para referenciar as contribuições inerentes ao processo de consecução de um projeto científico desta natureza, podem ser destacadas:

- Divulgação dos estudos realizados neste trabalho, junto às comunidades nacional e internacional, por meio da publicação de artigos em congressos e periódicos, o que corrobora a importância e contribuições das investigações realizadas. No Anexo I, são apresentadas as publicações realizadas no decorrer do desenvolvimento da tese e que possuem relação com as pesquisas que alicerçaram a mesma.
- Elaboração do documento de tese para disponibilização acadêmica dos estudos, métodos e aplicação desenvolvidos, bem como dos resultados obtidos.
- Desenvolvimento de pesquisas na área de sistemas inteligentes de suporte à decisão, a partir de estudos como os que fundamentam essa tese, e que em parte foram aplicados nas soluções propostas nos projetos Predict I e II. Os resultados acadêmico-científicos dessas investigações e projetos encorajam o fortalecimento da massa crítica local com vistas à consolidação de um grupo de pesquisa especializada em Suporte à Decisão para o Setor Elétrico.

A partir das contribuições aqui identificadas e pela própria natureza do processo de construção de um trabalho científico, há sempre margem para desdobramentos dos estudos executados, aprimoramentos e aplicações que transcendem ao escopo das investigações realizadas. Por essas razões, alguns temas podem ser apontados como sugestões de trabalhos futuros às pesquisas que fundamentam esta tese, os quais são pontuados a seguir.

Como há um interesse intrínseco do grupo do LPRAD/UFPA por aplicações de sistemas de suporte à decisão no setor elétrico e em outras áreas de aplicações, algumas novas aplicações podem ser realizadas, via estratégia de aplicação da framework proposta para a geração de cenários, compondo um possível conjunto de **Trabalhos Futuros** derivados desta Tese:

- Analisar cenários, considerando outras classes de consumidores da CELPA, além de programas para atendimento das outras empresas que compõem o grupo Rede Energia;
- Analisar cenários, considerando outras modelagens dos dados que compõem a configuração dos cenários, como por exemplo, utilizar 12 valores quaisquer de consumos em contrapartida aos 12 valores de consumos representando os meses de janeiro a dezembro;
- Analisar cenários, considerando a inclusão de outras variáveis que estabeleçam algum tipo de correlação com o consumo de energia, como por exemplo investimento;
- Investigação de outros modelos de RNAs mais adequados ao problema de previsão de séries temporais;
- Investigação de outros métodos de previsão de modo a compará-los em termos de desempenho e precisão com as RNAs utilizadas neste trabalho;
- Investigação de outros métodos de otimização de modo a compará-los em termos de desempenho e precisão com os AGs utilizados no processo de geração de cenários deste trabalho;

As sugestões propostas de trabalho futuro podem, evidentemente, ser combinadas, de tal sorte que seja possível utilizar os desdobramentos da estratégia

desenvolvida em aplicações no setor elétrico distintas das que foram apresentadas aqui, bem como em outros domínios de aplicação.

7. Referências Bibliográficas

ADYA, M. e COLLOPY, F. “How Effective are Neural Networks at Forecasting and Prediction? A Review and Evaluation”. *Journal of Forecasting*, 17: 481-495 (1998).

AMJADY, N. “Day-ahead price forecasting of electricity markets by a new fuzzy neural network”. *IEEE Transactions on Power Systems*, Vol. 21, no. 2, pp. 887–896, (2006).

AMJADY, N. “Short-Term Bus Load Forecasting of Power Systems by a New Hybrid Method”. *IEEE Transactions on Power Systems*, Vol. 22, no. 1, (2007).

AMJADY, N. e DARAEPOUR, A. “Midterm Demand Prediction of Electrical Power Systems Using a New Hybrid Forecast Technique”. *IEEE Transactions on Power Systems*, Vol. 26, no. 2, (2011).

AKOLE, M. e TYAGI, B. “Artificial Neural Network based Short Term Load Forecasting for Restructured Power System”. *Third International Conference on Power Systems*, Kharagpur, INDIA December (2009).

BACZYNSKI, D. e PAROL, M. “Influence of artificial neural network structure on quality of short-term electric energy consumption forecast”. *IEEE Proceedings Generation, Transmission & Distribution*, Vol. 151, no2, (2004).

BALKIN, S. D. and ORD, J. K.. “Automatic Neural Network Modeling for Univariate Time Series”. *International Journal of Forecasting*, Vol. 16, pp. 509-515, (2000).

BARROS, M.; MELLO, M. e SOUZA, R. “Aquisição de energia no mercado cativo brasileiro: simulações dos efeitos da regulação sobre o risco das distribuidoras”. *Pesquisa Operacional*, vol.29, n.2, pp. 303-322 (2009).

BASHIR, Z. A. e EL-HAWARY, M. E. “Applying wavelets to short term load forecasting using PSO based neural networks,” *IEEE Transactions on Power Systems*, vol. 24, no. 1, pp. 20–27, (2009).

BEASLEY, D.; BULL, D.R. e MARTIN, R.R. “An overview of Genetic Algorithms: part 1, fundamentals”. *University Computing*, 15(2): 58-69 (1993).

BILGILI, M.; SAHIN, B.; YASAR, A. e SIMSEK, E. “Electric energy demands of Turkey in residential and industrial sectors”. *Renewable and Sustainable Energy Reviews*, Vol. 16, pp. 404-414, (2012).

BISHOP, C. M. *Neural Networks for Pattern Recognition*. Oxford University Press (1995).

BOWERMAN, B. L.; O’CONNELL, R.T. e KOEHLER, A.B.. *Forecasting, Time Series, and Regression*. Belmont, CA: Thomson Brooks/Cole, (2005).

BRADLEY, E. “Analysis of Time Series,” *An Introduction to Intelligent Data Analysis*, M. Berthold and D. Hand, eds., pp. 167-194, New York: Springer, (1999).

BRAMEIER, M. e BANZHAF, W. “A comparison of linear genetic programming and neural networks in medical data mining,” *IEEE Transaction on Evolutionary Computation*, vol. 5, pp. 17–26, (2001).

BRAGA, A. P.; CARVALHO, A. C. P. L. F e LUDEMIR, T. B. *Redes Neurais Artificiais: teoria e aplicações*. 2.ed. –Rio de Janeiro. LTC (2007).

CHAI, C. T.; CHUEK, C. H.; MITAL, D. P. e HUAT, T. T. “Time Series Modelling and Forecasting using Genetic Algorithms”. *First International Conference on Knowledge-Based Intelligent Electronic Systems*, (1997).

CHOUËIKI, M. H.; CAMPBELL, C. A. M. e AHALT, S. C. “Implementing weighted least squares procedure in training a neural network to solve short term load forecasting problem”. *IEEE Transactions on Power Systems*, vol. 12, no. 4, pp. 1689–1695, (1997).

COATES, J.F. Scenario planning. *Technological Forecasting and Social Change*, v.5, p.115-123 (2000).

CORTEZ, P. A. R. *Modelos Inspirados na Natureza para a Previsão de Séries Temporais*. Tese (Doutorado em Informática) – Departamento de Informática, Universidade do Minho, (2002).

COSTA, R.C. e PIEROBON, E.C. *Leilão de Energia Nova: Análise da Sistemática e dos Resultados*. BNDES Setorial. BNDES. Rio de Janeiro, mar. 2008.

CYBENKO, G. Continuous Valued Neural Networks with Two Hidden Layers are Sufficient. Technical report, Department of Computer Science, Tufts University (1988).

DEVORE, J. L. *Probability and Statistics for Engineers and Sciences*, Pacific Grove, CA: Brooks/Cole, (2000).

EMPRESA DE PESQUISA ENERGÉTICA – EPE. *Mercado de energia elétrica 2006-2015*. EPE. Rio de Janeiro. 2005.

EKONOMOU, L. “Greek long-term energy consumption prediction using artificial neural network”. *Energy Vol. 35*, pp. 512–517, (2010).

FACELI, K., LORENA, A. C., GAMA, J. e CARVALHO, A. C. P. L. F. *Inteligência Artificial: Uma Abordagem de Aprendizagem de Máquina*. Rio de Janeiro: LTC, (2011).

FAN, S. e CHEN, L. “Short-term load forecasting based on an adaptive hybrid method”. *IEEE Transactions on Power Systems*, vol. 21, no. 1, pp. 392–401, (2006).

FAY, D. e RINGWOOD, J.V. “On the Influence of Weather Forecast Errors in Short-Term Load Forecasting Models”. *IEEE Transactions on Power Systems*, vol. 25, no. 3, pp. 1751–1758, (2010).

FERREIRA T. A. E.; VASCONCELOS, G. C. e ADEODATO, P. J. L. “A New Hybrid Approach for Enhanced Times Series Prediction”. *XXV Congresso da Sociedade Brasileira de Computação*, 831-840, (2005).

FERREIRA, T. A. E. Uma Nova Metodologia Híbrida Inteligente para a Previsão de Séries Temporais. Tese (Doutorado em Ciência da Computação) – Centro de Informática, Universidade Federal de Pernambuco, (2006).

FELICE, M. D. e YAO, X. “Short-Term Load Forecasting with Neural Network Ensembles: A Comparative Study [Application Notes]”. IEEE Computational Intelligence Magazine, Vol. 6, no. 3, pp. 47-56, (2011).

GATELY, E. “Neural Networks for Financial Forecasting”. New York: Wiley, (1996).

GAUSEMEIER, J.; FINK, A. e SCHLAKE, O. “Scenario management: an approach to develop future potentials”. Technological Forecasting and Social Change, v.59, p.111-130 (1998).

GILES, C. L., SUN, R. e ZURADA, J. M. “Neural Networks and Hybrid Intelligent Models: Foundations, Theory, and Applications”. Guest Editorial, em IEEE Transactions on Neural Networks (9), Setembro, 721-723. (1998).

GODET, M.; ROUBELAT, F.. “Creating the future: the use and misuse of scenarios”. Long Range Planning, v.29, n.2, p.164-171 (1996).

GODET, M.. “Scenarios and Strategic Planning”. Butterworth, London (1987).

GOLDBERG, D.E. Genetic Algorithms in search, optimization and machine learning. Addison-Wesley (1989).

GOLDSCHMIDT, R. R. e PASSOS, E. “Data Mining: Um Guia Prático”. 1. ed. Rio de Janeiro: Campos, (2005).

GOONATILAKE, S. e KHEBBAL, S. editores, Intelligent Hybrid Systems. John Wiley & Sons. (1995).

HANMANDLU, M. e CHAUHAN, B. K. “Load Forecasting Using Hybrid Models”. IEEE Transactions on Power Systems, Vol. 26, no. 1, (2011).

HAYKIN, S. Neural Network – A Comprehensive Foundation. Prentice-Hall, 2.ed. (1999).

HUANG, S. J. e HUANG, C. L. “Genetic-Based Multilayered Perceptron for Taiwan Power System Short-Term Load Forecasting”. Electric Power Systems Research 38: 69-74 (1996).

IBA, H. e SASAKI, T. “Using genetic programming to predict financial data,” in Proceedings of the IEEE Congress on Evolutionary Computation, vol. 1, pp. 244–251, (1999).

IBA, H. e NIKOLAEV, N. “Genetic programming polynomial models of financial data series,” in Proceedings of the IEEE Congress on Evolutionary Computation, vol. 1, pp. 1459–1466, (2000).

INOUE, H. e NARIHISA, H. “Ensemble Self-Generating Neural Networks for Chaotic Time Series Prediction”. Proc. of IPMU2000 (8th Information Processing and

Management of Uncertainty in Knowledge-Based Systems Conference), pp. 1524-1531, (2000).

JEONG, B.; JUNG, H. e PARK, N. “A computerized causal forecasting system using genetic algorithms in supply chain management,” *Journal of Systems and Software*, vol. 60, pp. 223–237, (2002).

JONG, E.; WATSON, R. e POLLACK, J. “Reducing Bloat and Promoting Diversity Using Multi-objective Methods,” in *Proceedings of the IEEE Congress on Evolutionary Computation*, vol. 1, pp. 11–18, (2001).

KANDIL, N.; WAMKEUE, R.; SAAD, M.; e GEORGES, S. “An Efficient Approach for Short Term Load Forecasting Using Artificial Neural Networks,” *International Journal of Electrical Power and Energy Systems*, vol. 28, no. 8, pp. 525–530, (2006).

KANKAL, M.; AKPINAR, A.; KÖMURCU, M. I. e Özşahin, T. S. “Modeling and forecasting of Turkey’s energy consumption using socio-economic and demographic variables”. *Applied Energy*, Vol. 88, pp. 1927-1939, (2011).

KASABOV, N., K. *Foundations of Neural Networks, Fuzzy Systems and Knowledge Engineering*. MIT Press, USA. (1996).

KOSKO, B. *Neural Networks and Fuzzy Systems*. Prentice Hall, Inc. 1992.

LEE, D.; LEE, B. and CHANG, S. “Genetic Programming Model for Longterm Forecasting of Electric Power Demand,” *Electric Power System. Research*, vol. 40, pp. 17–22, (1997).

LEUNG, F. H. F., LAM, H. K., LING, S. H., e TAM, P. K. S. “Tuning of the structure and parameters of the neural network using an improved genetic algorithm”. *IEEE Transaction on Neural Networks*, 14(1):79–88 (2003).

LIAO, G. C. e TSAO, T. P. “Application of a fuzzy neural network combined with a chaos genetic algorithm and simulated annealing to short term load forecasting,” *IEEE Transaction on Evolutionary Computation*, vol. 10, no. 3, pp. 330–340, (2006).

LIMA, C. A. M.; COELHO, A. L. V. e VON ZUBEN, F. J. “Ensembles of Support Vector Machines for Regression Problems”. *Procs. INNS-IEEE International Joint Conference on Neural Networks (IJCNN)*, vol. 3, pp. 2381-2386, (2002).

LINDEN, R. *Algoritmos Genéticos – Uma Importante Ferramenta da Inteligência Computacional*. 2. Ed. – Rio de Janeiro. Brasport (2008).

LING, S. H.; LEUNG, F. H. F.; LAM, H. K.; LEE, Y. S. e TAM, P. K. S. “A Novel Genetic-Algorithm-Based Neural Network for Short-Term Load Forecasting”. *IEEE Transactions on Industrial Electronics*, Vol. 50, Nº 4, Agosto (2003).

LIU, Y. e YAO, X. “Evolving Neural Networks for Hang Seng Stock Index Forecasting,” in *Proceedings of the IEEE Congress on Evolutionary Computation*, vol. 1, pp. 256–260, (2001).

- LU, C. N.; TWU, H. e VEMURI, S. "Neural networks based short term load forecasting". IEEE Transactions on Power Systems, vol. 8, no. 1, pp. 336–342, (1993).
- MANDIC, D. P. e CHAMBERS, J. A. "Recurrent Neural Networks for Prediction: Architectures, Learning Algorithms and Stability". Wiley. (2001).
- MANIEZZO, V. "Genetic evolution of the topology and weight distribution of neural networks". IEEE Transactions on Neural Network, vol. 5, pp. 39–53, (1994).
- MCGARRY, K.; WERMTER, S. e MACINTYRE, J. "Hybrid Neural Systems: From Simple Coupling to Fully Integrated Neural Networks". Neural Computing Surveys 2, 62-93, (1999).
- METAXIOTIS, K.; KAGIANNAS, A.; ASKOUNIS, D.; PSARRAS, J. "Artificial Intelligence in Short Term Electric Load Forecasting: a State-of-the-art Survey for the Researcher". Energy Conversion and Management, 44: 1525-1534 (2003).
- MICHALEWICZ, Z. Genetic algorithms + data structures = evolution programs. 3.ed. Springer-Verlag (1999).
- MOHAMED, Z e BODGER, P. "Forecasting electricity consumption in New Zealand using economic and demographic variables". Energy, Vol. 30, pp. 1833–1843, (2005).
- MORETTIN, P. A. e TOLOI, C. M. C.. "Análise de Séries Temporais". 2 ed. São Paulo: Edgard Blucher, (2006).
- NAG, A. e MITRA, A. "Forecasting daily foreign exchange rates using genetically optimized neural networks," Journal of Forecasting, vol. 21, pp. 501–511, (2002).
- NOGALES, F. J.; CONTRERAS, J.; CONEJO, A. J. e ESPINOLA, R. "Forecasting next-day electricity prices by time series models," IEEE Transactions on Power Systems, vol. 17, no. 2, pp. 342–348, (2002).
- PALIT, A. K. e POPOVIC, D. "Computational Intelligence in Time Series Forecasting". 1. ed. Londres: Springer-Verlag, (2005).
- POVINELLI, R.J. e FENG, X. "Temporal Pattern Identification of Time Series Data using Pattern Wavelets and Genetic Algorithms," Proc. Artificial Neural Networks in Eng. Conf., pp. 691-696, (1998).
- POVINELLI, R.J. e FENG, X. "Data Mining of Multiple Nonstationary Time Series," Proc. Artificial Neural Networks in Eng., pp. 511-516, (1999).
- POVINELLI, R.J. e FENG, X. "Improving Genetic Algorithms Performance By Hashing Fitness Values," Proc. Artificial Neural Networks in Eng. Conf., pp. 399-404, (1999).
- POVINELLI, R. J. "Using Genetic Algorithms to Find Temporal Patterns Indicative of Time Series Events," GECCO 2000 Workshop: Data Mining with Evolutionary Algorithms, pp. 80-84 (2000).

POVINELLI, R. J. e FENG, X. “A New Temporal Patter Identification Method for Characterization and Prediction of Complex Time Series Events”. IEEE Transactions on Knowledge and Data Engineering, 15, N^o. 2, Março/Abril (2003).

RICH, E, e KNIGHT, K. Artificial Intelligence. McGraw Hill, Inc; 1991.

ROMERA, E. G.; MORÁN, M. A. J. e FERNÁNDEZ, D. C. “Monthly Electric Energy Demand Forecasting Based on Trend Extraction”. IEEE Transactions on Power Systems, 21, N^o. 4, Novembro (2006).

RUSSEL, S. e NORVIG, P. Artificial Intelligence – a modern approach. Prentice-Hall (2003).

SAPANKEVYCH, N. I. e SANKAR, R.. “Time Series Prediction Using Support Vector Machines: A Survey”. IEEE Computational Intelligence Magazine, May, (2009).

SENJYU, T.; MANDAL, P.; UEZATO, K. e Funabashi, T. “Next day load curve forecasting using hybrid correction method”. IEEE Transactions on Power Systems, vol. 20, no. 1, pp. 102–109, (2005).

STEINHERZ, H.; PEDREIRA, C. e CASTRO, R. “Neural Networks for Short- Term Load Forecasting: A Review and Evaluation,” IEEE Transactions on Power Systems, vol. 16, no. 1, pp. 44–55, (2001).

SUGANTHI, L. and SAMUEL, A. A.. “Energy models for demand forecasting—A review”. Renewable and Sustainable Energy Reviews, Vol. 16, pp. 1223-1240, (2012).

SZPIRO, G. G. “Forecasting Chaotic Time Series with Genetic Algorithms”. Journal of Physical Review E, Vol 55, N^o. 3, Março. American Physical Society (1997).

TSEKOURAS, G. J.; HATZIARGVRIOU, N. D.; DIALYNAS, E. N. “An Optimized Adaptive Neural Network for Annual Midterm Energy Forecasting”. IEEE Transactions on Power Systems, 21, N^o. 1, Fevereiro (2006).

TZAFESTAS, S. e TZAFESTAS, E. “Computational Intelligence Techniques for Short-Term Electric Load Forecasting”. Journal of Intelligent and Robotic Systems, 31: 7-68 (2001).

UEDA, N. “Optimal linear combination of neural networks for improving classification performance”. IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 22, pp. 207-215, (2000).

VARIAN, H.R.. Microeconomia:princípios básicos. Trad. por Luciane Melo. Rio de Janeiro, Campus (1994).

VERMAAK, J. e BOTHA, E. C. “Recurrent neural network for short term load forecasting”. IEEE Transactions on Power Systems, vol. 13, no. 1, pp. 126–132, (1998).

WAGNER, N.; MICHALEWICZ, Z.; KHOUJA, M. e MCGREGOR, R. R. “Time Series Forecasting for Dynamic Environments: The DyFor Genetic Program Model”. IEEE Transaction on Evolutionary Computation, vol. 11, No 4, (2007).

WANG, Y.; OJLESKA, V.; JING, Y.; K.-GUGULOVSKA, T. e DIMIROVSKI, G. M. "Short Term Load Forecasting: A Dynamic Neural Network Based Genetic Algorithm Optimization". 14th International Power Electronics and Motion Control Conference, EPE-PEMC, (2010).

WANG, Y., XIA, Q. e KANG, C. "Secondary Forecasting Based on Deviation Analysis for Short-Term Load Forecasting". IEEE Transactions on Power Systems, Vol. 26, no. 2, (2011).

WERMTER, S. e SUN, R. "An Overview of Hybrid Neural Systems". Em: Wermter S., Sun R., editores, Hybrid Neural Systems. p. 1-13. Springer, Heidelberg, Germany. (2000).

WOLLENBERG, E.; EDMUNDS, D. e BUCK, L. Using scenarios to make decisions about the future: anticipatory learning for the adaptive co-management of community forests. Landscape and Urban Planning, v.47, p.65-77 (2000).

YUN, Z.; QUAN, Z.; CAIXIN, S.; SHAOLIN, L.; YUANG, L. e YANG, S. "RBF neural network and ANFIS-based short-term load forecasting approach in real time price environment". IEEE Transactions on Power Systems, vol. 23, no. 3, pp. 853–858, (2008).

ZHANG, G.; PATUWO, B. E e HU, M. Y. "Forecasting with artificial neural networks: The state of the art". International Journal of Forecasting, 14: 35-62 (1998).

ANEXO A – RESULTADOS DAS SIMULAÇÃO PARA A CEMAT

Para ilustrar a aplicação do *framework* proposto na previsão de consumo de outra empresa distribuidora de energia elétrica, este anexo mostra os resultados das simulações tendo como fonte de dados a série de consumo total de energia elétrica de outra empresa do Grupo Rede Energia, a CEMAT.

A série de dados utilizada neste anexo, é referente ao consumo total de energia elétrica para todo o estado do Mato Grosso. O estudo realizado se valeu do histórico de dados disponíveis de energia requerida no período de janeiro de 1991 a dezembro de 2006, ver figura A1.




Figura A1. Histórico do consumo de energia de 1991 a 2006.

Seguindo a mesma metodologia empregada no estudo de caso da CELPA, os dados históricos de consumo de energia foram divididos em doze séries temporais, uma para cada mês. Nas simulações realizadas com a regressão múltipla, foi aplicada a regressão utilizando apenas os valores referentes ao intervalo de janeiro de 1991 até dezembro de 2004, realizando com base nos mesmos uma estimativa dos valores para o ano de 2005 e 2006 (Figura A2). Na previsão de consumo para o ano de 2005 os erros MAPE e MSE foram 4.94% e 1.75×10^{-3} , respectivamente. Para o ano de 2006 os erros MAPE e MSE obtidos foram 5.26% e 1.88×10^{-3} , respectivamente. Como ocorreu no estudo de caso da CELPA, uma segunda projeção do consumo foi realizada, levando-se em consideração a previsão para os anos de 2006 a 2008 (figura A3).

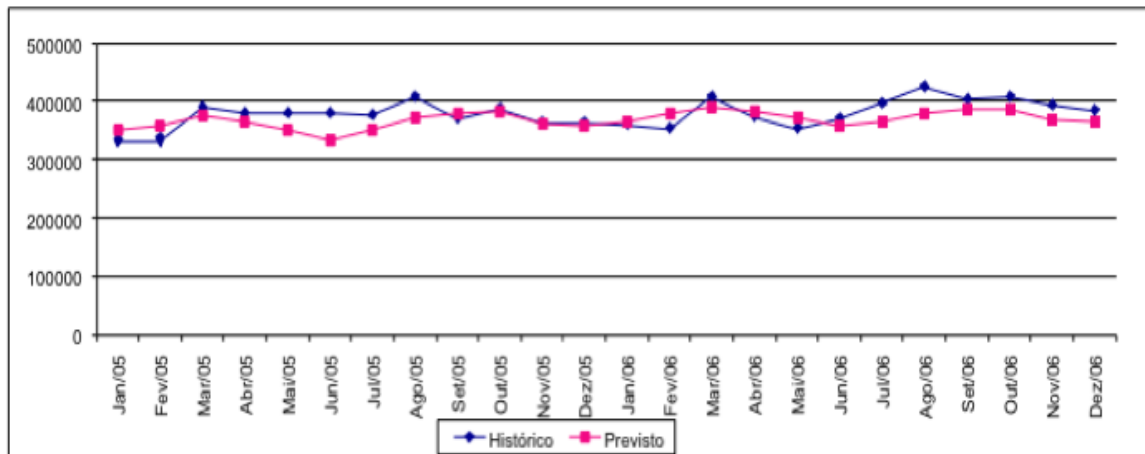


Figura A2. Valores reais e estimados de Jan/05 a Dez/06 do consumo de energia, via modelo de regressão.




Figura A3. Valores previstos de consumo, utilizando modelo de regressão, para os anos de 2006 a 2008.

Para as redes MLP, foram utilizados como conjunto de treino os valores dos dados históricos referentes ao intervalo de 1991 até 2004 e para os conjuntos de teste os dados referentes a 2005. Após o processo de treinamento, para a rede que obteve o melhor desempenho foi realizada a estimação dos valores de consumo para os anos de 2005 e 2006 (Figura A4). Os erros MAPE e MSE podem ser visualizados na tabela A1.

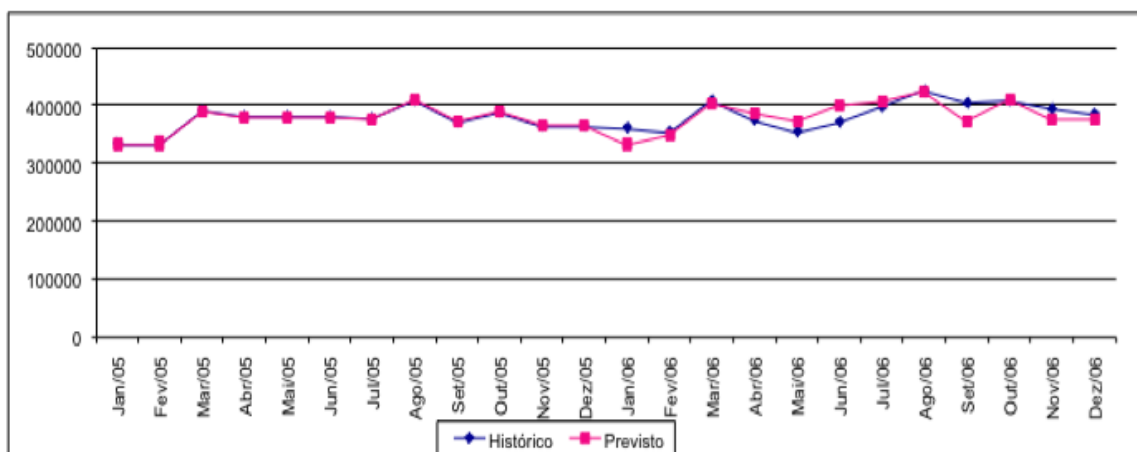


Figura A4. Valores reais e estimados de Jan/05 a Dez/06 do consumo de energia, via modelo MLP.

Tabela A1. Desempenho da rede MLP para a Previsão dos anos de 2005 e 2006.

| Erro | MLP Seleccionada | Média | Desvio Padrão |
|-----------|--------------------------|--------------------------|------------------------|
| MAPE 2005 | $3.79 \times 10^{-4} \%$ | $4.99 \times 10^{-4} \%$ | 1.39×10^{-4} |
| MAPE 2006 | 3.63 % | 3.94 % | 0.24 |
| MSE 2005 | 1.1×10^{-11} | 2.56×10^{-11} | 1.66×10^{-11} |
| MSE 2006 | 1.04×10^{-3} | 1.17×10^{-3} | 1.39×10^{-4} |

Com o objetivo de avaliar o poder preditivo das redes em previsões acima de 01 ano o modelo de rede neural foi novamente aplicado, agora tendo como conjuntos de treino os valores dos dados históricos referentes ao intervalo de 1991 até 2005 e para os conjuntos de teste os dados referentes a 2006. A estimação dos valores de consumo foi então realizada para os anos de 2006, 2007 e 2008 (Figura A5).

Após as simulações com a técnica de regressão linear e as RNAs, foram realizadas as simulações com as redes MLP sendo modeladas através das técnicas de cenários e treinadas utilizando como conjunto de treino os valores dos dados históricos referentes ao intervalo de 1991 até 2004 e para o conjunto de teste os dados referentes a 2005. Após o processo de treinamento, para a rede que obteve o melhor desempenho foi realizada a estimação dos valores de consumo para os anos de 2005 e 2006 (Figura A6). Os valores dos erros MAPE e MSE podem ser visualizados na tabela A2.




Figura A5. Valores previstos de consumo, empregando-se RNA, para os anos de 2006 a 2008.

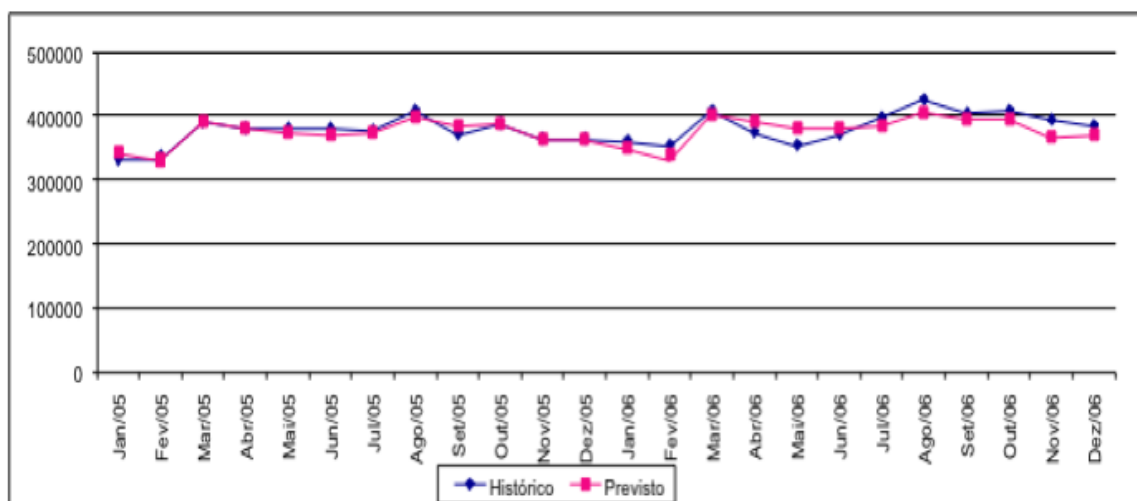


Figura A6. Valores previstos de consumo, utilizando RNA modelada por meio de cenários, para os anos de 2005 e 2006.

Seguindo a mesma metodologia das simulações realizadas anteriormente, as redes MLP modeladas através das técnicas de cenários, foram treinadas com os dados históricos dos anos de 1991 à 2005 e testadas com os dados de 2006. Com o intuito de avaliar o poder de generalização da referida rede, foi realizada a estimação dos valores de consumo para os anos de 2006, 2007 e 2008 (Figura A7).

Tabela A.2. Desempenho da rede MLP/Cenário para a Previsão dos anos de 2005 e 2006.

| Erro | MLP Seleccionada | Média | Desvio Padrão |
|-----------|-----------------------|-----------------------|-----------------------|
| MAPE 2005 | 1.31% | 1.44 % | 0.17 |
| MAPE 2006 | 3.96 % | 4.36 % | 0.45 |
| MSE 2005 | 1.55×10^{-4} | 1.9×10^{-4} | 5.70×10^{-5} |
| MSE 2006 | 9.62×10^{-4} | 1.24×10^{-3} | 2.08×10^{-4} |




Figura A7. Valores previstos de consumo, utilizando RNA modelada por meio de cenários, para os anos de 2006 a 2008.

Na tabela A3, é mostrado um resumo dos melhores desempenhos para as técnicas de previsão utilizadas nos estudo de caso da empresa CEMAT. Os resultados mostraram que as soluções baseadas em RNAs apresentaram melhores desempenhos para o problema de previsão de consumo da empresa CEMAT, quando comparados com o desempenho da regressão linear.

Tabela A.3. Desempenho da rede MLP/Cenário para a Previsão dos anos de 2005 e 2006.

| Erro | Regressão Linear | MLPs Seleccionadas | MLP/Cenário Seleccionada |
|-----------|-----------------------|-------------------------|--------------------------|
| MAPE 2005 | 4.94% | 3.79×10^{-4} % | 1.31% |
| MAPE 2006 | 5.26 % | 3.63 % | 3.96 % |
| MSE 2005 | 1.75×10^{-3} | 1.1×10^{-11} | 1.55×10^{-4} |

| | | | |
|----------|-----------------------|-----------------------|-----------------------|
| MSE 2006 | 1.88×10^{-3} | 1.04×10^{-3} | 9.62×10^{-4} |
|----------|-----------------------|-----------------------|-----------------------|

A.1. Geração dos Cenários de Previsão

Utilizando a mesma metodologia empregada para a geração de cenários de previsões utilizada no estudo de caso da CELPA, foi selecionado o ano de 2006 como alvo para se gerar os cenários de consumo de energia da empresa CEMAT.

Novamente, neste estudo de caso também as simulações foram realizadas com o objetivo de avaliar cenários de previsões para o ano de 2006 e como esses cenários impactavam nos valores de consumos do ano de 2005. Deste modo, foram levadas em consideração análises de aumento do consumo normal previsto para 2006 (cenários otimistas) e análises de diminuição da previsão desse consumo (cenários pessimistas), ambos de acordo com as taxas de 1.5%, 3.0% e 4.5% para crescimento e diminuição.

Deste modo, levando-se em consideração as metas de aumento para o consumo de 2006, de acordo com as taxas 1.5%, 3.0% e 4.5%, respectivamente meta1, meta2 e meta3, ver figura A8, procurou-se encontrar valores de consumos para os meses de janeiro a dezembro de 2005 que satisfizessem tais metas de aumento para o ano de 2006, ver figura A9. O objetivo dessa análise foi avaliar o quanto um possível aumento do consumo para o ano de 2006 poderia modificar os consumos esperados para 2005.




Figura A8. Valores das metas de aumento do consumo para 2006.

No gráfico da figura A8 é mostrado a curva de consumo previsto para os meses de janeiro a dezembro de 2006 (previsão normal) e os valores de consumo previsto para 2006 encontrados pelo AG, de acordo com as metas de crescimento analisadas. É importante notar neste gráfico que esses valores de previsão para 2006 encontrados pelo AG, implicaram em alterações dos consumos previstos para os meses de janeiro a dezembro de 2005, como pode ser visto na figura A9.




Figura A9. Valores dos cenários de consumos para janeiro a dezembro de 2005.

Em seguida, foram executadas as mesmas buscas realizadas e mostradas na figura A8, mas desta vez tendo como alvo os consumos dos meses de julho a dezembro de 2005, pois os consumos de janeiro a junho ficaram constantes e representados pelos consumos históricos (valores realizados para o ano de 2005) desses meses. A idéia desta análise era avaliar, dado que já foram realizados os consumos de janeiro a junho de 2005, o impacto que possíveis aumentos no consumo do ano de 2006 poderiam acarretar nos valores dos consumos dos meses de julho a dezembro de 2005, o que pode ser visto nas figuras A10 e A11, respectivamente.




Figura A10. Valores das metas de aumento do consumo para 2006, caso 2

Na figura A10, pode-se notar que os valores de consumo de 2006 para as metas 1, 2 e 3 foram os mesmos, pois somente com as alterações permitidas para os meses de julho a dezembro de 2005 não é possível encontrar um aumento do consumo de 2006 que satisfaça as metas de aumento de 3.0% e de 4.5%.




Figura A11. Valores dos cenários de consumos para julho a dezembro de 2005.

Além das buscas por cenários otimistas (aumento do consumo normal), também foram realizadas buscas das previsões de energia elétrica, tendo como objetivo agora a diminuição do valor de consumo normal previsto para o ano de 2006 de acordo com as taxas -1.5%, -3.0% e -4.5%, respectivamente sendo representadas pela meta1, meta2 e

meta3. Como na análise anterior, primeiramente foram analisados os casos cujos cenários foram compostos pelos valores de consumos de janeiro a dezembro de 2005, ver figuras A12 e A13.




Figura A12. Valores das metas de diminuição do consumo para 2006, caso 3




Figura A13. Valores dos cenários de consumos para janeiro a dezembro de 2005

No gráfico da figura A12 é mostrado a curva de consumo previsto para os meses de janeiro a dezembro de 2006 (previsão normal) e os valores de consumo previsto para 2006 encontrados pelo AG, de acordo com as metas de diminuição analisadas. Como nos casos das metas de aumento do valor previsto de consumo para o ano de 2006, nos

casos de diminuição da previsão para 2006 encontrados pelo AG, também implicaram em alterações dos consumos previstos para os meses de janeiro a dezembro de 2005, como pode ser visto na figura A13.

Também foram realizadas simulações com as metas de diminuição do consumo de 2006 utilizando como alvo para as buscas do AG, os cenários formados pelos meses de julho a dezembro de 2005, ver figuras A14 e A15.

A figura A14, mostra também que tendo como possibilidade somente a alteração dos meses de julho a dezembro de 2005 não é possível atingir a meta de diminuição 3 (aproximadamente -4.5%) para a previsão de consumo do ano de 2006.




Figura A14. Valores das metas de diminuição do consumo para 2006, caso 4




Figura A15. Valores dos cenários de consumos para julho a dezembro de 2005

Partindo de previsões normais, realizadas somente com as RNAs, o módulo gerador de cenários baseado em AGs pôde realizar buscas pelos cenários que melhor representassem as condições indicadas pelos especialistas, com o objetivo de analisar o comportamento da série temporal sob um ângulo de possibilidades de crescimento e diminuição do consumo de energia elétrica previsto para o ano de 2006 e como essa alteração no consumo previsto impactaria sobre o consumo dos meses de janeiro a dezembro de 2005. As informações obtidas com os cenários gerados servem para melhorar o processo de comercialização de energia, sendo determinantes para o êxito nos processos de compra e venda de energia.

ANEXO B - TRABALHOS ACEITOS/PUBLICADOS

São apresentadas a seguir as referências aos principais trabalhos aceitos/publicados, que guardam relação com esta tese.

Periódicos:

SANTANA, Á. L.; CONDE, G.; REGO, L.; ROCHA, C.; CARDOSO, D. L.; COSTA, J.; BEZERRA, U. FRANCÊS, C. R. L.. “PREDICT – Decision support system for load forecasting and inference: A new undertaking for Brazilian power suppliers”. *Electrical Power and Energy Systems*, Vol. 38, pp. 33–45, (2012).

SANTANA, Á. L. ; REGO, Liviane ; CONDE, G. ; FRANCÊS, Carlos Renato Lisboa ; ROCHA, Cláudio ; SILVA, Marcelino S. da . Comparative Analyses of Computational Intelligence Models for Load Forecasting: a Case Study in the Brazilian Amazon Power Suppliers. *Lecture Notes in Computer Science*, v. 5553, p. 1044-1053, 2009.

REGO, Liviane; SANTANA, Á. L. ; CONDE, G. ; FRANCÊS, Carlos Renato Lisboa ; ROCHA, Cláudio . Predict - Sistema de Suporte à Decisão para Estimção de Cargas e Modelagem de Dependência em Sistemas Elétricos. *Revista Pesquisa e Desenvolvimento da ANEEL*, v. 3, p. 97-100, 2009.

CONDE, Guilherme ; SANTANA, Ádamo de Lima ; FRANCÊS, C. R. L. ; RÊGO, L. P. ; GATO, Vanja ; COSTA, João Crisóstomo Weyl Albuquerque ; CARDOSO, Diego Lisboa ; ROCHA, Cláudio Alex Jorge da . Performance Evaluation of Short and Long Term Load Forecasting Models: a Case Study in the Amazonian Power Suppliers. *Proceedings of SPIE*, v. 6763, p. 34, 2007.

SANTANA, Ádamo de Lima ; ROCHA, Cláudio Alex Jorge da ; CONDE, Guilherme ; FRANCÊS, C. R. L. ; GATO, Vanja ; COSTA, João Crisóstomo Weyl Albuquerque . Comparative studies of statistical and computational intelligence models for short and long term load forecasting: a case study in the Amazonian power suppliers. *Proceedings of SPIE*, v. 6763, p. 18, 2007.

Conferências:

CONDE, G.; SANTANA, Á. L. ; REGO, Liviane ; FRANCÊS, Carlos Renato Lisboa ; ROCHA, Cláudio . Comparative Analyses of Computational Intelligence Models for Load Forecasting: a Case Study in the Brazilian Amazon Power Suppliers. In: International Symposium on Neural Networks (ISNN 2009), 2009, Wuhan. Sixth International Symposium on Neural Networks, 2009.

2- SANTANA, Á. L. ; REGO, Liviane ; CONDE, G. ; FRANCÊS, Carlos Renato Lisboa ; ROCHA, Cláudio . Modelos de Inteligência Computacional Aplicados em um Estudo de Caso de Concessionária de Energia da Amazônia Brasileira para Previsão de Energia Elétrica. In: V CITENEL, 2009, Belém. Anais do V CITENEL, 2009.