

**UNIVERSIDADE FEDERAL DO PAMPA
CAMPUS ALEGRETE**

Carlos Vinicius Machado Silva

**UM MODELO HÍBRIDO-ADAPTATIVO PARA
PREVISÃO DE DEMANDA DE ENERGIA ELÉTRICA
BASEADA EM TÉCNICAS DE INTELIGÊNCIA
ARTIFICIAL**

TRABALHO DE CONCLUSÃO DE CURSO

ALEGRETE,RS.

2011

CARLOS VINICIUS MACHADO SILVA

**UM MODELO HÍBRIDO-ADAPTATIVO PARA
PREVISÃO DE DEMANDA DE ENERGIA ELÉTRICA
BASEADA EM TÉCNICAS DE INTELIGÊNCIA
ARTIFICIAL**

Trabalho de conclusão de curso apresentado
como parte dos requisitos para obtenção do
grau de Bacharel em Engenharia Elétrica pela
Universidade Federal do Pampa.

Orientador: Mauricio Sperandio

ALEGRETE,RS.

2011

CARLOS VINICIUS MACHADO SILVA

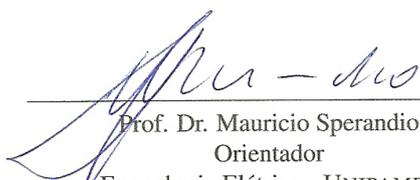
**UM MODELO HÍBRIDO-ADAPTATIVO PARA PREVISÃO DE DEMANDA DE ENERGIA
ELÉTRICA BASEADA EM TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL**

Trabalho de Conclusão de Curso apresentado ao Curso de Engenharia Elétrica da Universidade Federal do Pampa, como parte dos requisitos para obtenção do título de Bacharel em Engenharia Elétrica.

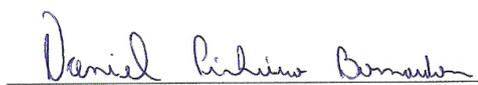
Área de concentração: Engenharias

Trabalho de conclusão de curso defendido e aprovado em: 22 de Junho de 2011.

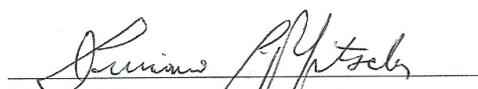
Banca examinadora:



Prof. Dr. Mauricio Sperandio
Orientador
Engenharia Elétrica - UNIPAMPA



Prof. Dr. Daniel Pinheiro Bernardon
Engenharia Elétrica - UNIPAMPA



Prof. Me. Luciano Lopes Pfitscher
Engenharia Elétrica - UNIPAMPA

Humilde e agradecidamente, dedico este trabalho a meus queridos pais, Carlinhos e Vilma, pelos imensos ensinamentos, carinho e amor que sempre me dedicaram. A Maristela e ao Leonardo, os quais fazem parte de minha família do coração. Ainda, dedico a Ju, por todos os momentos, pelo carinho e companheirismo. A vocês dedico esse trabalho, respeito e amor, levando-os sempre em meu coração e pensamentos.

AGRADECIMENTOS

Ao Prof. Diego L. Kreutz, pelos momentos vivenciados no Núcleo de Tecnologia da Informação e Comunicação (NTIC), a quem admiro pelo amor e dedicação em seus trabalhos. Também, por ter me mostrado que meus limites sou eu quem os determina, além de dar provas de quão gratificante pode ser a vida acadêmica. A todos os membros, bolsistas ou funcionários do NTIC, pelos momentos e histórias compartilhados.

Agradeço ao Prof. Mauricio Sperandio pela atenção e dedicação com que sempre me orientou durante as pesquisas, as quais tornaram possível a realização deste trabalho. Ainda, por desafiar-me nos problemas propostos e, principalmente, pelo exemplo que sempre transpareceu.

Aos colegas do Grupo de Energia e Sistemas Elétricos de Potência (GESEP) e aos professores Daniel P. Bernardon, Vinícius J. Garcia e Luciano L. Pfitscher pelos diversos momentos e viagens que podemos compartilhar.

À Empresa Muxfeldt, Marin & Cia (Mux Energia) pelo incentivo financeiro ao desenvolvimento do Projeto de Pesquisa & Desenvolvimento (P&D) que originou esse trabalho.

Também, agradeço ao colegas da Elipse Software, pelos ensinamentos, risadas, almoços elípticos, pelas rodadas de Uno e pelo dia-a-dia que compartilho com vocês.

Ao Sapiranga (Ivandro T. Cavalheiro) por todas as manhãs, tardes e as vezes noites que estudávamos juntos, sempre com a companhia de um bom chimarrão. Aos pais do Sapiranga, Seu Ivo e Dona Evani, por receberem-me em sua casa, de maneira acolhedora e saborosa (ótimos lanches). E pelas diversas vezes que ouvi a frase de incentivo da D. Evani, que não esquecerei: "...vocês vão tirar 100...".

Aos meus colegas da primeira turma de Engenheiros Eletricistas da Universidade Federal do Pampa: Andrews, Antônio, Daniel, Edson, Guilherme, Jeferson, Iuri, Lucas, Paulo André e Raphael.

Aos demais amigos e familiares que auxiliaram e incentivaram-me, tornando possível concluir mais uma etapa.

À Ju, por ser presente, participativa e indispensável em meus dias, mesmo a tantos quilômetros distante.

*“O que me preocupa não é o grito dos maus,
mas sim o silêncio dos bons.”*

Martin Luther King

*“A humildade é a única base sólida de todas
as virtudes.”*

Confúcio

*“Diz-me e eu esquecerei;
Ensina-me e eu lembrar-me-ei;
Envolve-me e eu aprenderei.”*

Provérbio Chinês

*“E o que importa não é o que você tem na
vida, mas quem você tem na vida.”*

William Shakespeare

RESUMO

Entre os desafios das empresas do setor elétrico de potência está o de manter a qualidade e a continuidade no fornecimento de energia elétrica. Para tanto, torna-se necessária a realização de estudos e o desenvolvimento de procedimentos e metodologias para otimizar e aprimorar os serviços prestados por estas empresas. Apresenta-se como uma dessas necessidades o conhecimento da demanda energética em estados futuros, que auxilia operadores, engenheiros e gestores na tomada de decisões. Nesse contexto, um modelo predictor de demanda de energia elétrica, tendo o curtíssimo prazo como horizonte de projeção e considerando a influência de variáveis climáticas, propicia e embasa as decisões da empresa onde é utilizado. Também pode permitir a identificação de possíveis situações de risco de operação do sistema. Para construção do modelo citado, pode-se empregar mais de uma técnica de inteligência artificial, além de contar com o auxílio de métodos probabilísticos, elaborando-se um modelo híbrido-adaptativo. Esse modelo predictor configura seus próprios parâmetros a fim de aprimorar o método, ajustando-se a diferentes cenários, minimizando a diferença entre o valor de demanda prevista e o valor real medido. Para tanto, utilizou-se mapas auto-organizáveis, que permitem a criação de um modelo probabilístico, conhecido como Cadeia de Markov, a partir dos dados históricos de variáveis climáticas. Também se agregaram técnicas de algoritmos genéticos para tornar a metodologia proposta adaptável a diferentes cenários, permitindo a definição dos parâmetros de entrada. As pesquisas que originaram este trabalho foram aplicadas em uma concessionária de energia elétrica do Rio Grande do Sul, interessada em realizar a previsão de demanda energética, considerando o curtíssimo prazo como horizonte de projeção. Assim, apresenta-se um método confiável e robusto na tomada de decisões, auxiliando o planejamento e trazendo benefícios econômicos, devido ao fato de propiciar dados confiáveis para os gestores.

Palavras-chave: Cadeia de Markov, Algoritmos Genéticos, Mapas Auto-Organizáveis, Curtíssimo Prazo, Previsão de demanda.

ABSTRACT

Among the challenges of electrical power sector companies, there is a need to maintain the quality and continuity on electrical power supply. For that, these companies must perform studies and develop procedures and methodologies to optimize and improve services rendered by them. One of these needs is the knowledge of power demand on future states, which helps operators, engineers, and decision-making managers. In this context, a predicting model of electrical power demand, having a very short term as the projection horizon and considering the influence of climate variables, contributes and supports decisions on the company where it is used. It may also allow identifying possible risk situations while operating the system. To build the previously cited model, companies may use more than one artificial intelligence technique, and also count on probabilistic methods, thus developing a hybrid-adaptive model. This predicting model configures its own parameters, in order to improve the method, adjusting itself to different scenarios, minimizing the difference between the value of the estimated demand and the real measured value. For this, we used self-organizing maps, which allow the creation of a probabilistic model, also known as Markov Chain, based on historical data from climate variables. We also added genetic algorithm techniques to make the proposed methodology adaptive to different scenarios, allowing the definition of input parameters. The research originating this work was applied on a power supplier company in Rio Grande do Sul, Brasil, which was interested in performing a power demand prediction, considering a very short term as its projection horizon. Thus, this method is reliable and robust for decision making, and helps on planning and brings economic benefits, since it provides reliable data for decision makers.

Keywords: Markov Chain, Genetic Algorithm, Self-Organizing Maps, Short-term, Demand Forecasting.

LISTA DE FIGURAS

2.1	Modelo de um neurônio genérico.	9
2.2	Função de limiar.	11
2.3	Função Linear por Partes.	11
2.4	Função Sigmóide.	12
2.5	Exemplo de uma estrutura de RNA recorrente.	13
2.6	Exemplo de uma estrutura de RNA não-recorrente.	13
2.7	Esquema da aprendizagem supervisionada.	15
2.8	Esquema da aprendizagem não-supervisionada.	15
2.9	Rede neural artificial auto-organizada.	16
2.10	Transformação $\Phi: E \rightarrow S$ em uma mapa 4x4 com conexões hexagonais.	16
2.11	Mapa hexagonal com 16 neurônio (4x4).	17
2.12	Mapas componentes 6x6 considerando quatro variáveis de entrada.	17
3.1	Exemplo de cromossomo binário com 8 genes.	20
3.2	Exemplo de codificação binária.	21
3.3	Exemplo de codificação inteira ou por permutação.	21
3.4	Exemplo de codificação real.	21
3.5	Exemplo de codificação mista.	21
3.6	Exemplo de codificação através de string de inteiros para o PCV.	22
3.7	Exemplo de mínimos e máximos - locais e globais.	23
3.8	Gráfico da distribuição da função objetivo acumulado	25
3.9	Exemplo de recombinação.	26
3.10	Exemplo de mutação.	26

4.1	Diagrama de estados de uma cadeia de Markov com a Matriz de transição da Tabela 4.1	30
5.1	Fluxograma geral do modelo predictor de demanda.	34
5.2	Exemplo de população inicial.	35
6.1	Comparação entre o melhor indivíduo e a média, segundo a função objetivo, em cada geração e o desvio padrão do EMQ, utilizando-se uma população com 10 indivíduos.	43
6.2	Comparação entre o melhor indivíduo e a média, segundo a função objetivo, em cada geração e o desvio padrão do EMQ, utilizando-se uma população com 15 indivíduos.	45
6.3	Comparação entre o melhor indivíduo e a média, segundo a função objetivo, em cada geração e o desvio padrão do EMQ, utilizando-se uma população com 20 indivíduos.	47
6.4	Mapas componentes obtidos com o melhor indivíduo das simulações de variação do número de indivíduos da população.	49
6.5	Comparação entre a curva de demanda prevista e a real com os parâmetros do melhor indivíduo ao variar-se o tamanho da população.	50
6.6	Comparação entre o melhor indivíduo e a média, segundo a função objetivo, em cada geração e o desvio padrão do EMQ, utilizando-se a Função de Seleção - Código 1.	52
6.7	Comparação entre o melhor indivíduo e a média, segundo a função objetivo, em cada geração e o desvio padrão do EMQ, utilizando-se a Função de Seleção - Código 2.	53
6.8	Comparação entre o melhor indivíduo e a média, segundo a função objetivo, em cada geração e o desvio padrão do EMQ, utilizando-se a Função de Seleção - Código 3.	55
6.9	Mapas componentes obtidos com o melhor indivíduo das simulações de variação da função de seleção.	56
6.10	Comparação entre a curva de demanda prevista e a real com os parâmetros do melhor indivíduo ao variar-se a função de seleção.	57

6.11	Comparação entre o melhor indivíduo e a média, segundo a função objetivo, em cada geração e o desvio padrão do EMQ, utilizando-se a Função de Recombinação - Código 1.	59
6.12	Comparação entre o melhor indivíduo e a média, segundo a função objetivo, em cada geração e o desvio padrão do EMQ, utilizando-se a Função de Recombinação - Código 2.	60
6.13	Comparação entre o melhor indivíduo e a média, segundo a função objetivo, em cada geração e o desvio padrão do EMQ, utilizando-se a Função de Recombinação - Código 3.	62
6.14	Mapas componentes obtidos com o melhor indivíduo das simulações de variação da função de recombinação.	63
6.15	Comparação entre a curva de demanda prevista e a real com os parâmetros do melhor indivíduo ao variar-se a função de recombinação.	64
6.16	Curvas de demanda geradas com os mesmos parâmetros de entrada - Teste 1.	65
6.17	Curvas de demanda geradas com os mesmos parâmetros de entrada - Teste 2.	66

LISTA DE TABELAS

1.1	Resumo dos horizontes de projeção e suas aplicações.	2
1.2	Correlação entre o comportamento de demanda e variáveis climáticas.	3
3.1	Distâncias entre as n cidades no PCV.	22
3.2	Exemplo de comparação entre as funções objetivos de uma população.	24
3.3	Exemplo de população classificada de acordo com a função objetivo acumulado.	25
4.1	Exemplo de matriz de transição P para três estados.	29
5.1	Matriz de exemplo de estados de Markov.	36
6.1	Descrição dos tipos de Função Seleção testados.	39
6.2	Descrição dos tipos de Função Recombinação testados.	40
6.3	Descrição dos tipos de Função Mutação testadas.	41
6.4	Parâmetros estáticos durante a variação do tamanho da população.	41
6.5	População final considerando 10 indivíduos por geração.	42
6.6	Estatísticas para a população com 10 indivíduos.	42
6.7	População final considerando 15 indivíduos por geração.	44
6.8	Estatísticas para a população com 15 indivíduos.	44
6.9	População final considerando 20 indivíduos por geração.	46
6.10	Estatísticas para a população com 20 indivíduos.	46
6.11	Resumo estatístico da variação o número de indivíduos da população.	48
6.12	Parâmetros estáticos durante a variação do tipo de Função Seleção.	50
6.13	População final considerando Função de Seleção - Código 1.	51
6.14	Estatísticas para a Função Seleção - Código 1.	51
6.15	População final considerando Função de Seleção - Código 2.	52

6.16	Estatísticas para a Função Seleção - Código 2.	53
6.17	População final considerando Função de Seleção - Código 3.	54
6.18	Estatísticas para a Função Seleção - Código 3.	54
6.19	Resumo estatístico da variação da Função de Seleção.	55
6.20	Parâmetros estáticos durante a variação do tipo de Função Recombinação.	58
6.21	População final considerando Função de Recombinação - Código 1.	58
6.22	Estatísticas para a Função Recombinação - Código 1.	58
6.23	População final considerando Função de Recombinação - Código 2.	59
6.24	Estatísticas para a Função Recombinação - Código 2.	60
6.25	População final considerando Função de Recombinação - Código 3.	61
6.26	Estatísticas para a Função Recombinação - Código 3.	61
6.27	Resumo estatístico da variação da Função de Recombinação.	63

LISTA DE ABREVIATURAS E SIGLAS

SEP	Sistema Elétrico de Potência,	p. 1
ANEEL	Agência Nacional de Energia Elétrica,	p. 3
DEC	Duração Equivalente de Interrupção por Unidade Consumidora,	p. 3
FEC	Frequência Equivalente de Interrupção por Unidade Consumidora,	p. 3
IA	Inteligência Artificial,	p. 4
RNA	Redes Neurais Artificiais,	p. 4
AG	Algoritmos Genéticos,	p. 4
PDCP	Projeção de Demanda de Energia Elétrica a Curtíssimo Prazo,	p. 4
ID	Índice de Desconforto,	p. 4
P&D	Pesquisa & Desenvolvimento,	p. 4
UNIPAMPA	Universidade Federal do Pampa,	p. 4
PCH	Pequena Central Hidrelétrica,	p. 4
SOM	Self-Organizing Maps,	p. 15
WSOM	Workshop in Self-Organizing Maps,	p. 15
TMA	Tempo Médio de Atendimento,	p. 18
PCV	Problema do Caixeiro Viajante,	p. 21
P_r	Probabilidade,	p. 28
BDtr	Base de Dados para Treinamento,	p. 33
BDt	Base de Dados para Testes,	p. 33
EMQ	Erro Médio Quadrático,	p. 36

SUMÁRIO

1	Introdução	1
1.1	Modelos previsores	4
1.2	Computação natural	5
1.3	Objetivos	5
1.3.1	Objetivos gerais	5
1.3.2	Objetivos específicos	6
1.4	Estrutura do Trabalho	6
2	Redes Neurais Artificiais	8
2.1	Introdução	8
2.1.1	Neurônio artificial	8
2.1.2	Função de ativação	10
2.2	Topologia de Redes Neurais Artificiais	12
2.2.1	Redes recorrentes	12
2.2.2	Redes não-recorrentes	13
2.3	Classificações de redes neurais artificiais	14
2.3.1	Quanto ao tipo de aprendizagem	14
2.4	Mapas auto-organizáveis	15
2.4.1	Aplicação do SOM	18
3	Algoritmos Genéticos	19
3.1	Introdução	19
3.2	Definições	19

3.3	Codificação	20
3.3.1	O problema do caixeiro viajante	21
3.4	Operadores de um algoritmo genético	23
3.4.1	Seleção	23
3.4.2	Recombinação	25
3.4.3	Mutação	26
4	Cadeia ou Modelo de Markov	27
4.1	Introdução	27
4.2	Processos estocásticos	27
4.3	Conceitos e definições	27
4.4	Exemplo de um Modelo de Markov	29
5	Metodologia Proposta	32
5.1	Especificações	32
5.1.1	Variáveis do problema	32
5.1.2	Base de dados	33
5.1.3	Restrições	33
5.2	Módulos do fluxo de dados	33
5.2.1	Inicialização	35
5.2.2	Avaliação	35
5.2.3	Ordenação	37
5.2.4	Reprodução	37
5.2.5	Critério de parada	38
6	Análises Experimentais	39
6.1	Variação do tamanho da população	41
6.1.1	População com 10 indivíduos	42

6.1.2	População com 15 indivíduos	43
6.1.3	População com 20 indivíduos	45
6.1.4	Considerações sobre a variação do tamanho da população	47
6.1.5	Exemplo de resultados - Variação do número de indivíduos da população	48
6.2	Variação da Função Seleção	50
6.2.1	Função de Seleção - Código 1	51
6.2.2	Função de Seleção - Código 2	52
6.2.3	Função de Seleção - Código 3	53
6.2.4	Considerações sobre a variação da função de seleção	55
6.2.5	Exemplo de resultados obtidos - Função de Seleção	56
6.3	Variação da Função de Recombinação	57
6.3.1	Função de Recombinação - Código 1	58
6.3.2	Função de Recombinação - Código 2	59
6.3.3	Função de Recombinação - Código 3	60
6.3.4	Exemplo de resultados obtidos - Função de Recombinação	62
6.3.5	Exemplo de resultados obtidos - Função Recombinação	63
6.4	Análise sobre processo estocástico	64
6.4.1	Estocasticidade - Exemplo 1	65
6.4.2	Estocasticidade - Exemplo 2	65
7	Conclusões e Trabalhos Futuros	67
7.1	Conclusões	67
7.1.1	Sobre as variáveis climáticas	67
7.1.2	Sobre as técnicas utilizadas	68
7.1.3	Sobre o modelo previsor	68
7.2	Trabalhos futuros	69

Bibliografia

70

1 INTRODUÇÃO

Inúmeras técnicas são estudadas para construção de modelos capazes de simular cenários e prever valores futuros. Essas técnicas são aplicadas a diversas áreas do conhecimento como, por exemplo, em empresas do setor financeiro, que simulam comportamento do mercado como auxílio para determinar a liberação de empréstimos ou investimentos em ações financeiras de outra empresa.

Para o sistema elétrico de potência (SEP) há inúmeras aplicações para modelos previsores. Uma dessas aplicações é para a previsão de demanda energética, ou seja, busca-se determinar qual o valor que será solicitado em um determinado intervalo de tempo à frente (horizonte de projeção). Tais modelos são um importante auxílio ao SEP, visto que, idealmente, deve-se gerar o mais próximo do valor que será solicitado pelas cargas. Caso isso não ocorra, pode haver sobre-tensão, nível de tensão acima do ideal, ou sub-tensão (nível de tensão abaixo do considerado normal) (LEONE FILHO, 2006). Ainda, quando o consumo é maior que a geração, ou seja, gera-se menos do que se consome, a frequência síncrona diminui. E, quando a geração é maior que o consumo a frequência síncrona aumenta. Porém, há diversas variáveis que podem interferir nos resultados da demanda como, por exemplo, a região, a estação do ano, os tipos de consumidores (industriais, residenciais, comerciais), fatores climáticos, índices econômicos, além de eventos atípicos (temporais, por exemplo).

Os horizontes de projeção tem relação direta com a aplicação do modelo predictor. Segundo Lima (1996) pode-se classificar os horizontes de projeção em quatro modalidades: longo prazo, médio prazo, curto prazo e curtíssimo prazo. A Tabela 1.1 mostra um resumo da classificação dos horizontes de projeção e suas aplicações.

Os horizontes de previsão de demanda são descritos por Leone Filho (2006), como:

Previsão de curtíssimo prazo: Esse horizonte de projeção destina-se a previsão de alguns minutos a frente até as próximas 24 horas. O conhecimento da tendência de comportamento da carga em um horizonte de curtíssimo prazo pode ser considerado como uma previsão de tempo-real e é utilizada para detectar condições perigosas de operação, além de

auxiliar no desenvolvimento de estratégias de oferta de energia por fontes alternativas (DANESHI & DANESHI, 2008, apud SPERANDIO ET AL., 2010). Também, esse horizonte é de extrema importância para a operação do planejamento de SEP.

Previsão de curto prazo: O curto prazo contempla de algumas horas à dias a frente. Os modelos que utilizam esse horizonte são bastante aplicados para orientar o planejamento da operação, transferência de carga e gerenciamento da demanda.

Previsão de médio prazo: Os horizontes de projeção de alguns meses até um ano, são classificados como médio prazo. As projeções de médio prazo servem como embasamento para reserva de suprimentos de combustíveis, operações de manutenção e de planejamento de intercâmbios.

Previsão de longo prazo: As previsões de demanda de longo prazo consideram um horizonte de alguns anos até os próximos dez anos a frente. Essa classificação de horizonte de projeção é mais abrangente que as demais, servindo de balizador para estudos de investimentos no SEP e decisões comerciais.

TABELA 1.1
Resumo dos horizontes de projeção e suas aplicações.

Horizonte	Intervalo de projeção	Descrição
Longo prazo	Até 10 anos	Destina-se a questões relacionadas a expansão do SEP como, por exemplo, construção de novas linhas de transmissão e usinas.
Médio prazo	Até 1 ano	É utilizada para planejamentos como, por exemplo, definir quais usinas deverão ser despachadas nos próximos meses.
Curto prazo	Até dias a frente	Aplica-se como auxílio no planejamento e da operação, transferência de carga e gerenciamento da demanda.
Curtíssimo prazo	Até 24 horas	Pode ser considerado como uma previsão de tempo-real e é utilizada para detectar condições perigosas de operação, além de auxiliar no desenvolvimento de estratégias de oferta de energia por fontes alternativas

A previsão de demanda serve como auxílio na tomada de decisões, tanto para operadores, principalmente quando necessitam atuar de maneira imediata, como para os engenheiros, vi-

sando satisfazer os índices de qualidade de energia. Tais balizadores, estipulados pela Agência Nacional de Energia Elétrica (ANEEL), buscam melhorar a qualidade e a continuidade da energia fornecida pelas concessionárias. Entre eles estão a Duração Equivalente de Interrupção por Unidade Consumidora (DEC) e a Frequência Equivalente de Interrupção por Unidade Consumidora (FEC), ambos indicadores coletivos. Para as concessionárias de energia elétrica é um desafio permanente atender as metas estipuladas pela ANEEL. Para isso, são necessários um conjunto de estudos e medidas para o cumprimento das metas referentes a qualidade da energia entregue às unidades consumidoras.

Após avaliar a relevância dos modelos previsores de demanda para uma concessionária, apresenta-se nesse trabalho a construção de um modelo previsor de demanda de energia elétrica considerando a influência de variáveis climáticas previamente determinadas. Para isso, escolheu-se o curtíssimo prazo como horizonte de projeção e adotou-se a temperatura, a umidade relativa do ar e a velocidade do vento como variáveis climáticas¹.

Tem-se o conhecimento que entre consumidores residenciais a maior parte da energia demandada é devida a climatização de ambientes, o que corrobora a escolha dessas variáveis. Para comprovar esse comportamento analisou-se os dados de uma concessionária do Rio Grande do Sul, com concessão nas cidades de Tapejara e Ibiaçá, onde constavam valores de demanda e das variáveis climáticas. Observou-se que a temperatura e umidade relativa do ar tem relação direta com o comportamento das cargas. Ou seja, a demanda acompanha o comportamento destas duas variáveis. Já a velocidade do vento apresentou relação indireta. A correlação calculada, a qual mostra a relação entre a demanda e as variáveis climáticas de interesse, é mostrada na Tabela 1.2. Observa-se, também, na Tabela 1.2 que a temperatura é a variável com maior consequência no valor demandado de energia.

TABELA 1.2
Correlação entre o comportamento de demanda e variáveis climáticas.

	Demanda	Temperatura	Umidade	Vento
Demanda	1,0000	—	—	—
Temperatura	0,2483	1,0000	—	—
Umidade	0,1107	0,1930	1,0000	—
Vento	-0,1602	-0,1062	0,0347	1,0000

Fonte: Silva et al., 2010a, p.5.

¹A partir desse ponto entende-se como variáveis climáticas: temperatura, umidade relativa do ar e velocidade do vento.

1.1 Modelos previsores

A complexidade da construção de um modelo previsor de demanda está diretamente relacionada com o número de variáveis envolvidas no processo, com horizonte de projeção adotado e com nível de erro tolerável (SILVA et al., 2010b). A medida que o horizonte de projeção diminui, aumenta-se a necessidade de maiores nível de detalhamento e precisão do modelo. Consequentemente, há aumento do esforço computacional envolvido no processo.

Considerando que o comportamento da carga é não-linear, a aplicação isolada e direta de métodos estatísticos não consegue resolver, com precisão aceitável, o problema da previsão de demanda em curtíssimo prazo, sendo necessário adotar outras técnicas como auxílio. Nas últimas décadas foram propostas inúmeras técnicas baseadas em inteligência artificial (IA) para resolução de situações com complexidade semelhante. Entre elas pode-se citar as Redes Neurais Artificiais (RNA), Algoritmos Genéticos (AG), Lógica Fuzzy e Sistemas Especialistas, relata Campos (2008). Porém, a maioria dos modelos citados na literatura refere-se a sistemas de médio e grande porte, o que não é a realidade da concessionária inicialmente analisada, e consideram horizontes de projeção maiores (SILVA et al., 2010c).

Lima (1996) utilizou RNA para construção de um previsor de demanda nos horários de ponta, o qual foi delimitado no intervalo das 17 às 22 horas. Em 1997, Leite obteve os melhores resultados quando utilizou apenas uma rede estática para tratar todos os dias da semana, ou seja, desconsiderou a classificação entre dias úteis e não-úteis. Leone Filho (2006) comenta que em sistemas complexos, torna-se necessário, muitas vezes, a utilização de mais de uma técnica para construção do sistema previsor de demanda, formando um sistema híbrido ou modular.

A projeção de demanda de energia elétrica a curtíssimo prazo (PDCP) está diretamente associada as variações climáticas, como anteriormente citado, sendo possível, também, determinar seus valores através do índice de desconforto (BORDIN et al., 2010), o qual relaciona a temperatura e a umidade relativa do ar.

A metodologia apresentada surgiu como parte de pesquisas de iniciação científica, oriundas de um projeto de Pesquisa & Desenvolvimento (P&D), através da parceria entre o Grupo de Energia e Sistemas Elétricos de Potência (GESEP), da Universidade Federal do Pampa (UNI-PAMPA), e a concessionária Muxfeldt, Marin & Cia. Ltda (Mux Energia). Na empresa citada, o modelo previsor de demanda é empregado como auxílio na tomada de decisão dos melhores momentos para despacho de um Pequena Central Hidrelétrica (PCH) a fio d'água. O despacho a PCH limita-se a capacidade do reservatório, o qual fica ainda mais comprometido em épocas de estiagem. Desta forma, evita ou minimiza-se possíveis violações de demanda contratada da

supridora de energia elétrica que atende a concessionária citada, através do despacho da PCH nos momentos mais viáveis.

1.2 Computação natural

As pesquisas sobre computação natural começaram na década de 1950. O termo computação natural, também referenciada como computação evolutiva ou evolucionária, é utilizado para descrever sistemas computacionais que são modelados e/ou inspirados na natureza.

A computação evolutiva, pode ser agrupada em três categoria (BACK, 1996, apud Rezende, 2005):

- Algoritmos Genéticos
- Estratégias de evolução
- Programação Genética

Castro e Zuben (2004), enuncia essas categorias como:

Computação inspirada na natureza: contempla as técnicas inspiradas em algum mecanismo e/ou comportamento biológico. Nessa classificação estão as redes neurais artificiais, os algoritmos genéticos e sistemas imunológicos artificiais, por exemplo. Esta é a área mais consolidada e a mais tempo em estudo.

Estudo sobre a natureza através da computação: emprega recursos computacionais para determinar comportamentos e padrões naturais. As principais linhas de pesquisa dessa área são estudos sobre vida e organismos artificiais, e geometria fractal.

Computação com mecanismos naturais: trata de mecanismos naturais onde, como por exemplo, as cadeias de DNA são utilizadas como estrutura de dados. Destaca-se nessa área a computação quântica.

1.3 Objetivos

1.3.1 Objetivos gerais

Considerando o nível de precisão e confiabilidade exigidos pelo horizonte de projeção de curtíssimo prazo, deseja-se integrar mais de uma técnica de IA para construção de uma modelo

previsor de demanda de energia elétrica híbrido-adaptativo. O termo híbrido refere-se a união de mais de uma técnica e o termo adaptativo salienta que o modelo proposto deve adaptar-se aos cenários apresentados, recalculando seus parâmetros a fim de minimizar os erros de previsão. Também, deve permitir o emprego das variáveis climáticas (temperatura, umidade e velocidade do vento) no modelo previsor.

1.3.2 Objetivos específicos

- Qualificar a influência das variáveis climáticas no modelo previsor, de maneira a permitir que tais entradas sejam empregadas ou não no modelo. Desta forma, busca-se concluir o quão relevante e significativo é a utilização de uma ou mais variáveis climáticas em termos de erro percentual no previsor.
- Utilizar mapas auto-organizáveis para discretização e agrupamento dos dados históricos de demanda e das variáveis climáticas, permitindo a construção de uma Cadeia de Markov.
- Empregar técnicas de algoritmos genéticos para otimização e determinação dos parâmetros da metodologia proposta, como as dimensões dos mapas, utilização das variáveis climáticas e número de simulações do modelo.

1.4 Estrutura do Trabalho

Optou-se por distribuir as informações desse trabalho de maneira descrita a seguir:

No Capítulo 2 são apresentados conceitos sobre Redes Neurais Artificiais (RNA), algumas topologias e classificações. Também, aborda-se em especial um tipo de RNA aplicada para classificação e agrupamento de dados.

No Capítulo 3 aborda-se o tema Algoritmos Genéticos, fazendo-se uma introdução e expondo-se conceitos fundamentais ao entendimento do tema.

O Capítulo 4 tem como tema as Cadeias de Markov, as quais são parte fundamental da metodologia proposta nessa trabalho. Ainda nesse capítulo, são apresentados conceitos introdutórios e históricos, bem como um exemplo de aplicação dessa técnica.

No Capítulo 5 expõe-se a metodologia objetivo desse trabalho. Ela emprega os conceitos e fundamentos expostos nos Capítulos 2, 3 e 4.

No Capítulo 6 são mostrados os resultados da implementação do modelo previsor proposto, onde são variados parâmetros e observadas as consequência no sistema de previsão.

Por fim, no Capítulo 7 são expostas as conclusões do trabalho e suas contribuições. Além disso, faz-se sugestões de trabalhos futuros.

2 REDES NEURAIS ARTIFICIAIS

2.1 Introdução

As redes neurais artificiais ou RNA, buscam simular o comportamento do cérebro humano, sendo esta uma estrutura de processamento, naturalmente, complexa, não linear e paralela. O primeiro relato sobre o assunto que se tem conhecimento foi feito no artigo “*A Logical Calculus of the Ideas Immanent in Nervous Activity*”, em 1943, por Warren McCulloch e Walter Pitts, como comenta Haykin (1999).

Entre os inúmeros tipos de RNA, destacam-se: Adaline/Madaline, Backpropagation Perceptron (Feedforward), Time-Delay, Recurrent, BAM (Memória Associativa Bidirecional), Ho-field e Kohonen (LOESCH, 1996).

Salienta-se como benefício do uso de RNA a alta capacidade de generalização de cenários, permitindo a obtenção de respostas precisas para entradas não usadas durante a fase de treinamento (aprendizagem). Assim, as RNA são recomendadas para casos onde haja um histórico de dados com as variáveis de entrada e o resultado obtido frente à elas durante o processo de treinamento da RNA. Dessa forma, é possível a ponderação de pesos sinápticos, os quais, em estados futuros ao treinamento, permitirão a obtenção dos resultados, ou seja, a previsão de estados futuros ou o reconhecimento de padrões.

Então, uma RNA é constituída por um ou mais modelos matemáticos (neurônios) que interagem de acordo com uma topologia definida (SPERANDIO, 2004), ou ainda, como uma estrutura (rede) de processamento altamente conectada (LEONE FILHO, 2006).

2.1.1 Neurônio artificial

Um neurônio artificial, ou no contexto desse trabalho simplesmente chamado de neurônio, é a unidade básica integrante de uma rede neural artificial. Tendo o comportamento inspirado nos neurônios biológicos, os neurônios artificiais recebem um conjunto de entradas as quais após operações matemáticas devem retornar um valor de saída (LIMA, 1996).

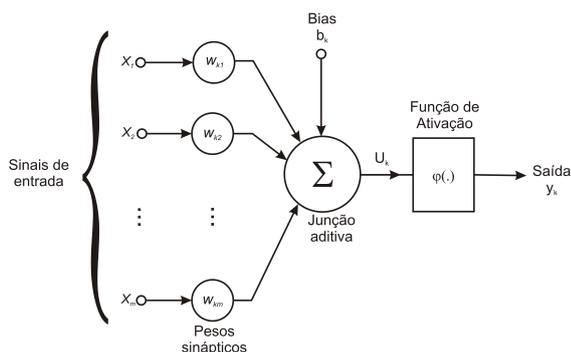


FIGURA 2.1 – Modelo de um neurônio genérico.

Fonte: Haykin, 1999, p. 37.

Segundo Haykin (1999), um neurônio, exemplificado na Figura 2.1, é constituído pelos elementos básicos:

- Pesos sinápticos: determinam a intensidade e o sinal da conexão associada a cada uma das entradas. Os pesos podem assumir tanto valores positivos como negativos.
- Somador: responsável por somar as entradas após a ponderação dos sinais de entrada pelos respectivos pesos sinápticos;
- Função de ativação: tem por função limitar o sinal de saída de um neurônio;
- Bias: é aplicado externamente ao somador com a função de diminuir ou aumentar a entrada líquida da função de ativação.

Um neurônio pode ser modelado matematicamente pelas Equações 2.1, 2.2 e 2.3 (HAYKIN, 1999):

$$u_k = \sum_{j=0}^m W_{kj} \cdot x_j \quad (2.1)$$

$$v_m = u_k + b_k \quad (2.2)$$

$$y_k = \varphi(v_k) \quad (2.3)$$

Onde:

- x_j : sinais de entradas;
 w_{kj} : pesos sinápticos do neurônio k ;
 u_k : saída do somador (combinador linear) sem adição do bias;
 b_k : sinal do bias;
 v_k : saída do somador com adição do bias;
 $\varphi(\cdot)$: função de ativação;
 y_k : sinal de saída do neurônio.

2.1.2 Função de ativação

A função de ativação $\varphi(\cdot)$ tem por objetivo delimitar o valor de saída do neurônio, por isso também pode ser chamada de função restritiva, já que age limitando ou restringindo a amplitude do sinal de saída. Comumente, utiliza-se os valores de saída de um neurônio normalizados no intervalo fechado $[0, 1]$ ou, ainda, $[-1, 1]$ (HAYKIN, 1999).

Entre as funções de ativação mais utilizadas ressaltam-se três: função limiar, função linear por partes e função sigmóide.

Função de limiar

Também chamada de função de Heaviside, pode ser expressa por:

$$\varphi(v) = \begin{cases} 1 & \text{se } v \geq 0 \\ 0 & \text{se } v < 0 \end{cases} \quad (2.4)$$

A saída do neurônio k empregando a função de ativação limiar, representa-se:

$$v_k = \begin{cases} 1 & \text{se } v_k \geq 0 \\ 0 & \text{se } v_k < 0 \end{cases} \quad (2.5)$$

Onde v_k é o campo local induzido do neurônio, dado por

$$v_k = \sum_{j=1}^n w_{kj} \cdot x_j + b_k \quad (2.6)$$

Essa formulação matemática descreve a propriedade tudo-ou-nada do modelo de McCulloch-Pitts, sendo referenciado na literatura com o nome dos autores em homenagem ao trabalho pioneiro dos mesmos.

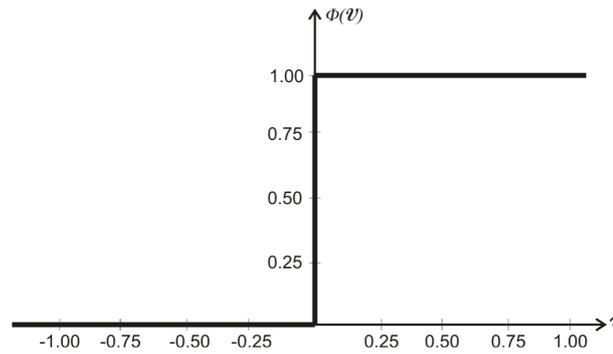


FIGURA 2.2 – Função de limiar.

Função linear por partes

Segundo a literatura, a função linear por partes pode ser vista como uma aproximação de um amplificador não-linear, expressa por

$$\phi(v) = \begin{cases} 1, & v \geq +\frac{1}{2} \\ v, & +\frac{1}{2} > v > -\frac{1}{2} \\ 0, & v \leq -\frac{1}{2} \end{cases} \quad (2.7)$$

Essa função linear por partes pode ser vista como um caso especial quando:

- A região limiar não saturar obtém-se um combinador linear;
- O fator de amplificação da região linear é infinitamente grande, a função linear por partes se reduz a função limiar.

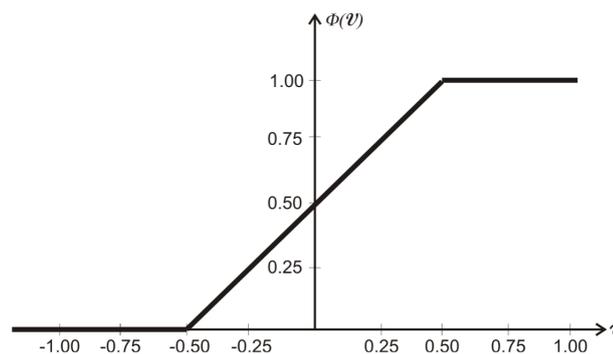


FIGURA 2.3 – Função Linear por Partes.

Função sigmóide

Essa é a função de ativação mais utilizada para implementação de RNA. É definida como uma função estritamente crescente, que possui um balanceamento adequado entre comporta-

mento linear e não-linear. A função logística é um exemplo de uma função sigmóide. É descrita matematicamente por:

$$\varphi(v) = \frac{1}{1 + \exp(-av)} \quad (2.8)$$

Onde, a é o parâmetro de inclinação da função sigmóide. A medida que o parâmetro a tende ao infinito, a função sigmóide se comporta como uma função de limiar. Porém, diferentemente da função de limiar que assume os valores de 0 ou 1, a função sigmóide assume um intervalo contínuo de valores entre 0 e 1. E, ainda, a função sigmóide é diferenciável, ao contrário da função de limiar.

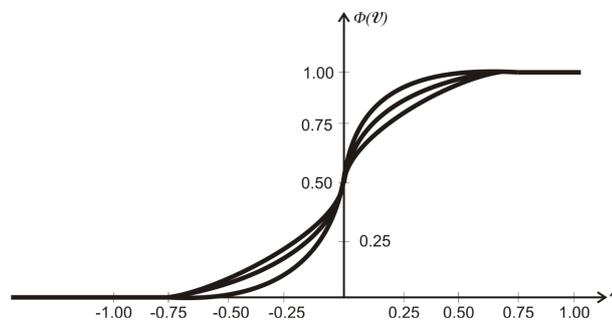


FIGURA 2.4 – Função Sigmóide.

2.2 Topologia de Redes Neurais Artificiais

A topologia ou arquitetura de uma RNA contempla a forma na qual os neurônios estão conectados e de que maneira ocorre o fluxo de dados pela rede. Essa estrutura está diretamente associada aos algoritmos de aprendizagem adotados.

Considerando as diversas topologias existentes, destacam-se as redes recorrentes e as não-recorrentes (LIMA, 1996).

2.2.1 Redes recorrentes

Em uma estrutura de RNA recorrente é permitida a realimentação das saídas como entradas em outros ou no mesmo neurônio. Não é obrigatória a organização em camadas, sendo possível, inclusive, a interligação entre neurônio da mesma camada.

As RNA com estrutura recorrente, podem possuir laços de auto-realimentação. Neste caso, a saída é realimentada como entrada no próprio neurônio (HAYKIN, 1999).

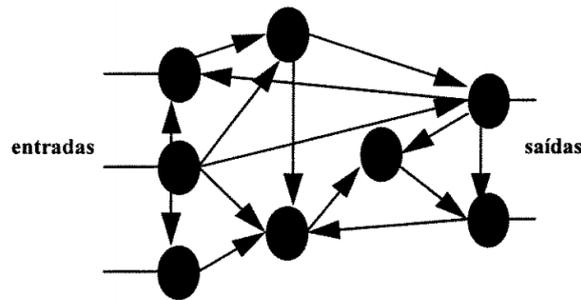


FIGURA 2.5 – Exemplo de uma estrutura de RNA recorrente.
Fonte: Lima, 1996, p. 41.

2.2.2 Redes não-recorrentes

As redes não-recorrentes, também chamadas de “sem memória”, não possuem realimentação das saídas para as entradas. Essa topologia de RNA apresenta uma (camada única) ou mais camadas (multi-camadas). A RNA de única camada é também conhecida como *perceptron* (HERTZ; KROGH; PALMER, 1991).

Considerando uma estrutura de rede não-recorrente, tem-se basicamente:

- Uma camada de entrada;
- Uma ou mais camadas intermediárias ou escondidas;
- Uma camada de saída.

A Figura 2.6 mostra uma topologia de RNA não-recorrente com uma única camada intermediária.

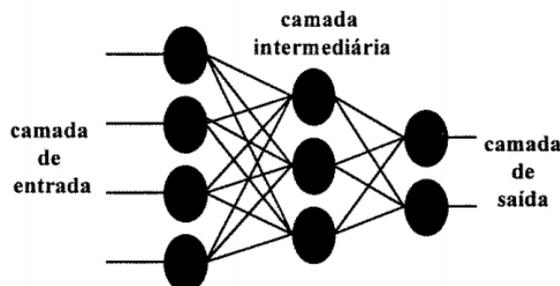


FIGURA 2.6 – Exemplo de uma estrutura de RNA não-recorrente.
Fonte: Lima, 1996, p. 41.

2.3 Classificações de redes neurais artificiais

2.3.1 Quanto ao tipo de aprendizagem

O processo de aprendizagem pode ser definido como:

Um processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado pela maneira pela qual a alteração dos parâmetros ocorre (HAYKIN, 1999, p. 75).

A seguir são descritas três classificações quanto ao tipo de aprendizagem de uma RNA, porém existem outras classificações, entre elas:

- Aprendizagem por correção de erro;
- Aprendizagem baseada em memória;
- Aprendizagem Hebbiana;
- Aprendizagem de Boltzmann.

Aprendizagem competitiva: Como o nome sugere há uma competição entre os neurônios para determinar-se qual neurônio ficará ativo. Assim, apenas um neurônio por vez pode estar ativo, fato pelo qual torna esse tipo de aprendizagem aplicável para casos onde se busca características estatisticamente salientes. Essas características podem ser usadas para classificar um conjunto de entradas.

Aprendizagem supervisionada: Nesse caso, considera-se que o professor, ou supervisor, entende o comportamento do ambiente (conjunto de entradas-saídas). Tendo o conhecimento do ambiente o “professor” é capaz de fornecer a resposta esperada para as novas entradas. Dessa forma, se após o treinamento a rede receber um vetor de entradas conseguirá generalizar o sistema e fornecer uma resposta adequada, de acordo com os padrões do treinamento. A Figura 2.7 mostra o esquema desse tipo de aprendizagem. Observa-se na figura citada um Sinal de Erro, o qual é dado pela diferença entre o valor esperado (dado pelo “professor”) e a resposta da RNA após o treinamento. Esse sinal de erro serve de entrada para o sistema de aprendizagem possibilitando melhores ajustes da RNA.

Aprendizagem não-supervisionada: Também chamada de auto-organizada, essa classificação não possui um supervisor (professor) ou um critério crítico para parada durante o processo de aprendizagem. Porém, deve existir uma ou mais medidas para mensurar

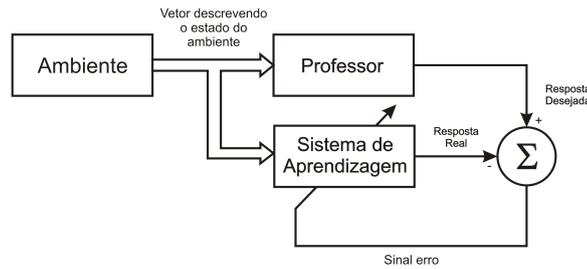


FIGURA 2.7 – Esquema da aprendizagem supervisionada.

o processo de aprendizagem e, ainda, os parâmetros livres da rede baseiam-se nessa(s) medida(s). A Figura 2.8 mostra o esquema da aprendizagem não-supervisionada.

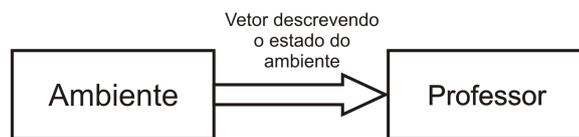


FIGURA 2.8 – Esquema da aprendizagem não-supervisionada.

2.4 Mapas auto-organizáveis

Os mapas auto-organizáveis, mais conhecidos pela sigla SOM *Self-Organizing Maps* são um tipo de RNA, baseada em aprendizagem competitiva. Os algoritmos que definem o comportamento do SOM foram propostos pelo professor Teuvo Kohonen em 1982 (HAYKIN, 1999). Em homenagem ao seu proponente o SOM também é conhecido como Mapa de Kohonen. A partir dos anos 90 surgiram trabalhos mostrando o SOM como um eficaz método para classificação e agrupamento de dados. O grande número de estudos e aplicações do SOM, em diversas áreas do conhecimento, levou a criação de eventos como WSOM (*Workshop in Self-Organizing Maps*) (SPERANDIO, 2004).

Em um mapa auto-organizado normalmente os neurônios estão dispostos em nós de uma grade uni ou bidimensional. É possível a construção de mapas com mais de duas dimensões, mas não é comum sua utilização (HAYKIN, 1999). A Figura 2.9 mostra uma rede auto-organizável.

O algoritmo SOM realiza uma transformação Φ não linear, mapeando o espaço de entradas E contínuo, cuja topologia é definida pela relação métrica dos vetores de dados $D \in E$ para um espaço de saída S discreto, cuja topologia é definida por um conjunto de modelos M dispostos em uma grade bidimensional (SPERANDIO et al., 2010).

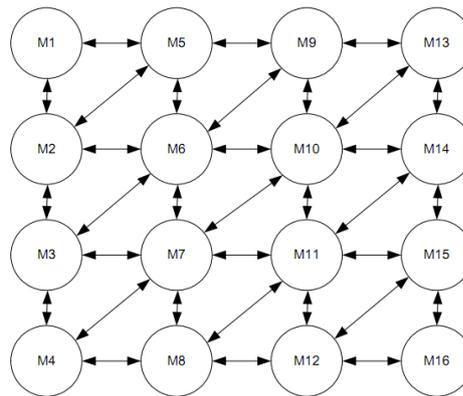


FIGURA 2.9 – Rede neural artificial auto-organizada.
Fonte: SPERANDIO, 2004, p.21.

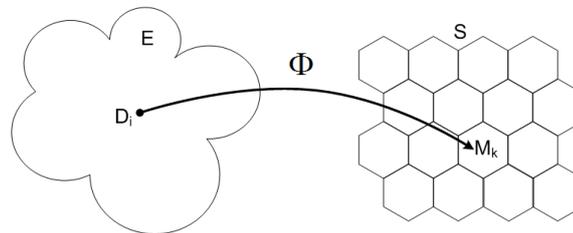


FIGURA 2.10 – Transformação $\Phi: E \rightarrow S$ em uma mapa 4x4 com conexões hexagonais.
Fonte: Haykin, 1999.

O processo de construção de um mapa auto-organizado, definido pelo SOM, acontece em três etapas e consiste em encontrar um modelo que melhor represente um dado de entrada na rede (vendedor). Tais etapas são chamadas de: competição, cooperação e adaptação. Através desses processos são definidas ligações que servem ajustar os modelos dos neurônios próximos ao vencedor (vizinhos) ao padrão de entrada. Assim, após inúmeras iterações o mapa apresenta os dados associados aos seus neurônios. Também, os neurônios da vizinhança apresentam comportamentos ou padrões bastante similares.

A Figura 2.11 mostra um mapa bidimensional onde os neurônios apresentam geometria hexagonal. Essa geometria permite a iteração de um neurônio com até 6 vizinhos. Observe na figura cita que o neurônio M1 tem ligações com os neurônios M2 e M5. Já o neurônio M11 tem como vizinhos os neurônios M6, M7, M8, M10, M12 e M15.

Entre os atrativos dos mapas auto-organizáveis está a possibilidade de fazer-se inferências sobre a relação entre as variáveis. Isto é possível através da análise dos mapas componentes, os quais apresentam uma escala de cores onde pode-se constatar a quantidade de um variável específica em um determinado neurônio. Cabe destacar que a posição de um neurônio é a mesma em todos os mapas componentes, visto que são a representação do mapa treinado com referência a apenas uma das variáveis. Uma representação de mapas componentes 6x6, considerando quatro

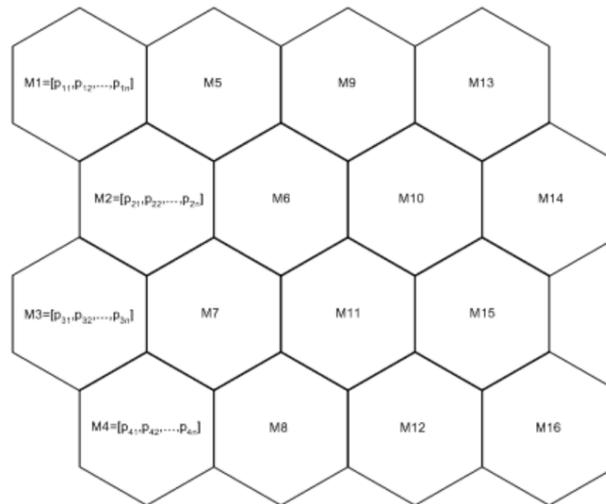


FIGURA 2.11 – Mapa hexagonal com 16 neurônio (4x4).
Fonte: Sperandio, 2004.

variáveis de entrada, é mostrada na Figura 2.12. Nesta figura, observa-se uma escala de cores na lateral direita de cada um dos mapas componentes, representando o valor real de cada uma das variáveis. Os menores valores são representados pela cor azul e a medida que os valores aumentam tendem a cor vermelha, a qual representa os maiores valores da cada variável. Então, pode-se inferir com base na observação da Figura 2.12 que a combinação de temperaturas e umidades altas, aliadas a velocidade do vento moderada, produziram um alto valor de demanda (neurônio superior esquerdo nos mapas componentes).

Deve-se estar atento no momento da escolha das dimensões do mapa, devido ao fato de mapas com menos de um neurônio para cada dez dados de entrada, não revelarem relações topográficas significativas. Porém, formam grupos bem definidos.

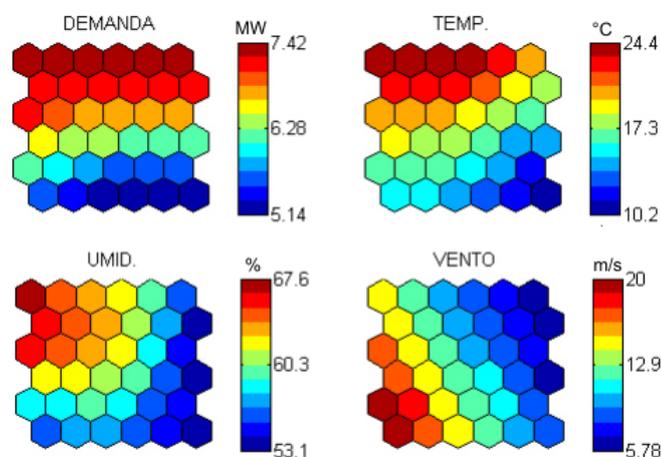


FIGURA 2.12 – Mapas componentes 6x6 considerando quatro variáveis de entrada.

2.4.1 Aplicação do SOM

O SOM destaca-se como uma poderosa e eficiente ferramenta para classificação de dados, permitindo a visualização de correlações entre as variáveis de entrada. É possível, ainda, a abstrair características intrínsecas das variáveis. De acordo com Kohonen (1996) abstração e visualização são necessárias, sobretudo na engenharia, como análise de processos, reconhecimento, controle e comunicação.

Segundo Sperandio (2004) um dos primeiros trabalhos utilizando o SOM na área de Sistemas de Potência foi a classificação de curvas diárias em 1991. O mesmo autor comenta sobre dois trabalhos brasileiros (LIMA et al., 1999, e COELHO et al., 2002, apud SPERANDIO, 2004, p. 40) aplicando SOM. O primeiro tinha por objetivo classificar cargas, a fim de separar perfis de carga associadas a variáveis climáticas. No segundo, o SOM era aplicado sobre duas bases de dados, uma com variáveis climáticas e outro com variáveis técnicas (DEF, FEC, TMA¹ e número de grupos atendidos).

Sendo o SOM aplicável a diversas áreas do conhecimento, destacam-se algumas aplicações (DEBOEK, 1999, apud SPERANDIO, 2004, p. 41):

- análise financeira
- previsão financeira
- análise de oportunidade de investimento
- alocação estratégica de portfólios
- classificação de consumidores
- mapeamento sócio-econômico

¹TMA: Tempo Médio de Atendimento.

3 *ALGORITMOS GENÉTICOS*

3.1 Introdução

O termo algoritmos genéticos foi usado pela primeira vez por John Holland, em 1975, no livro *Adaptation in Natural and Artificial Systems* (HOLLAND, 1975). Comumente referencia-se algoritmos genéticos utilizando a sigla AG ou GA (do termo em inglês, *Genetic Algorithm*). No contexto deste trabalho será adotado a sigla AG.

Os algoritmos genéticos são técnicas computacionais inspiradas na teoria da evolução das espécies de Charles Darwin, apresentadas no trabalho *The Origin of Species* (DARWIN, 1872). Segundo Darwin, os indivíduos com melhores características ou “adaptatividades” tendem a sobreviver. Os AG constituem modelos adaptativos que podem ser usados com eficiência em problemas de busca e otimização, nos quais deseja-se encontrar a melhor solução possível considerando um conjunto de indivíduos.

Os AG simulam processos que podem ocorrer em uma população de indivíduos. Tais processos são essenciais para o aprimoramento da população. Em um ambiente natural os indivíduos competem entre si por alimentos, água, etc. Os indivíduos mais adaptados ao ambiente, mais fortes e resistentes, tendem a sobreviver. Além disso, os seus descendentes, têm maiores chances de boa adaptabilidade. Da mesma forma, em um ambiente computacional, a medida que a população evolui devem permanecer os melhores indivíduos da população, ou seja, aqueles que geram as respostas mais convenientes ao tipo de problema onde são aplicados.

3.2 Definições

Cromossomo : Vetor de caracteres que representa informações relativas as variáveis do problema. Cada cromossomo representa uma solução ou indivíduo da população. O cromossomo é formado por g genes.

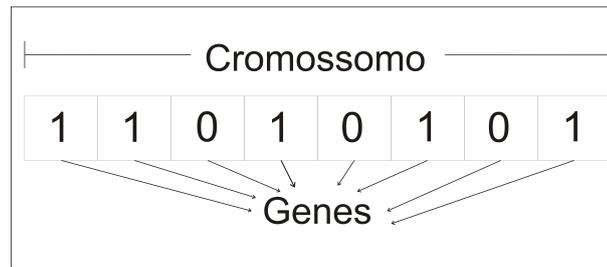


FIGURA 3.1 – Exemplo de cromossomo binário com 8 genes.

Gene : Unidade básica constituinte de um cromossomo referente a uma das variáveis do problema. Cada gene pode ter intervalos limites diferentes de acordo com as restrições de cada variável, podendo assumir valores binários, inteiros ou reais.

População : Conjunto das soluções possíveis. É constituída pelos indivíduos, também chamados de cromossomos.

Geração : Número de populações que serão geradas através dos operadores genéticos.

Operações genéticas : Operações que o AG realiza em cada indivíduo da população buscando encontrar as melhores soluções.

Espaço de busca ou região viável : Compreende o espaço ou conjunto de soluções viáveis ou possíveis de acordo com as restrições impostas como delimitadores do problema.

Função objetivo ou de avaliação : Função a qual se deseja otimizar. O valor da função objetivo é consequência dos valores estabelecidos para cada um dos indivíduos da população. Desta forma, cada indivíduo terá um resultante para função objetivo, pela qual será possível selecionar aqueles que obtiveram os melhores resultados, se for o desejado. Também, é facilmente referenciada na literatura como função *fitness*.

3.3 Codificação

Quando trabalha-se com algoritmos genéticos é necessário definir qual será a forma de representação dos indivíduos (cromossomos). Segundo Castro (1999) nenhuma forma de codificação funciona de forma eficiente para todos os tipos de problemas, devendo ser feita uma análise cuidadosa da melhor representação das soluções.

A forma mais utilizada, devido a facilidade de representação dos indivíduos, é a codificação através de uma *string* binária. Na codificação binária os genes podem assumir apenas dois estados (0 ou 1, por exemplo). A Figura 3.2 mostra um exemplo de codificação binária.

1	0	0	1	1	1	0	1
---	---	---	---	---	---	---	---

FIGURA 3.2 – Exemplo de codificação binária.

Há também outros dois casos de codificações, um adotando *strings* de números inteiros e o outro utilizando *string* de números reais. A codificação utilizando inteiros é também chamada de representação por permutação, tendo uma aplicação bastante conhecida e eficiente no clássico problema do caixeiro viajante (PCV). Nesse caso, cada gene do cromossomo recebe um valor inteiro que representa uma cidade. O objetivo é encontrar a menor rota para visitar um certo número de cidades, passando apenas uma vez por cada uma delas. A Figura 3.3 mostra um exemplo de codificação por permutação. Já o segundo caso, aplica-se a problemas onde as variáveis são contínuas, onde utilizar a codificação binária ou inteira torna os cromossomos longos, conseqüentemente mais lentos. Então, adota-se valores reais para cada gene, visando tornar a busca pela melhor solução mais eficiente e menos dispendiosa computacionalmente. Na Figura 3.4 é mostrado um exemplo de codificação real.

21	0	8	9	17	2	1	41
----	---	---	---	----	---	---	----

FIGURA 3.3 – Exemplo de codificação inteira ou por permutação.

0,1	4,0	5,2	9,7	3,9	2,2	9,5	5,1
-----	-----	-----	-----	-----	-----	-----	-----

FIGURA 3.4 – Exemplo de codificação real.

Em alguns casos as formas de codificação mencionadas anteriormente podem não ser suficientes ou satisfatórias, segundo critérios do programador, para codificar uma solução. Nesses casos, pode-se usar uma codificação mista onde cada um dos genes, ou grupo de genes, de um cromossomo possuem codificações diferentes. Esse é um caso bastante particular de representar-se uma solução, onde os operadores genéricos devem ser adequados aos tipos de codificação adotados. A Figura 3.5 mostra um cromossomo codificado com números reais, inteiros e binários, ou seja, a solução utilizou codificação mista para representar um cromossomo.

1,4	6,1	5	19	0	1	1	0
-----	-----	---	----	---	---	---	---

FIGURA 3.5 – Exemplo de codificação mista.

3.3.1 O problema do caixeiro viajante

O problema do caixeiro viajante (PCV) é um dos primeiros apresentados aos alunos em diversas academias em disciplinas de IA, otimização e afins. Também, é exposto em inúmeros livros como exercício para fixação dos conteúdos apresentados.

O PCV é classificado como um problema de otimização, onde conhecidas as distâncias entre n cidades, ou as suas posições geoespaciais que permitam determinar as distâncias entre as mesmas, deseja-se encontrar a menor rota para visitar as n cidades passando uma única vez por cada uma e retornando a cidade de origem.

A Tabela 3.1 apresenta um exemplo de tabela contendo 5 cidades

TABELA 3.1
Distâncias entre as n cidades no PCV.

Cidades	1	2	3	4	5
1	50	10	49	32	3
2	12	71	7	13	34
3	4	23	66	1	23
4	23	23	9	41	87
5	29	15	55	54	17

Codificação do caixeiro viajante

Um forma simples para codificação do PCV é a utilização de *strings* de inteiros, onde cada gene representa uma cidade. As cidades devem ser percorridas na sequência em que são apresentadas nos indivíduos. Um indivíduo é mostrado na Figura 3.6.

4	1	2	5	3	4
---	---	---	---	---	---

FIGURA 3.6 – Exemplo de codificação através de string de inteiros para o PCV.

Deve-se gerar uma população inicial contendo n indivíduos e para cada um calcula-se o custo ou função objetivo. O custo será a distância total de cada indivíduo, o que resultar no menor valor será a melhor solução. Observe que a primeira e a última cidade ou gene no indivíduo, na forma escolhida de representação, deve ser a mesma, já que é a cidade de origem e o último destino de cada rota. Na forma mostrada de representação, qualquer cidade pode ser a origem. O mais comum é ter-se uma cidade de origem fixa como, por exemplo, representando o depósito de uma empresa, e as demais cidades variáveis.

3.4 Operadores de um algoritmo genético

Embora haja inúmeros métodos e aplicações para as técnicas de AG, algumas são comuns a praticamente todos: população de indivíduos, seleção, recombinação e mutação (MITCHELL, 1999). O operador recombinação tem como principal função encontrar mínimos ou máximos, intensificando a busca. Porém, está sujeito a convergir para mínimos ou máximos locais. Para evitar isso, o operador mutação é uma importante ferramenta, alterando ou diversificando o espaço de busca. A Figura 3.7 exemplifica um caso de mínimos e máximos, locais e globais.

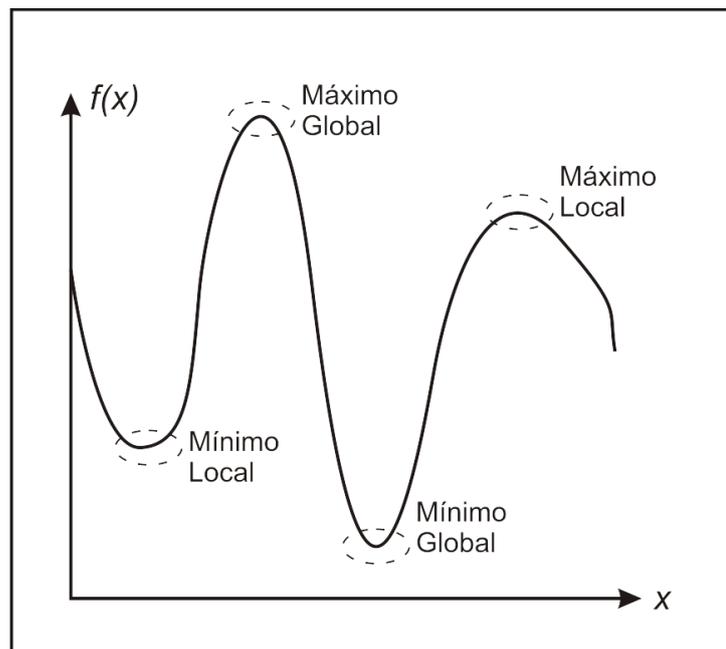


FIGURA 3.7 – Exemplo de mínimos e máximos - locais e globais.

3.4.1 Seleção

Esse operador realiza a seleção dos indivíduos que irão se reproduzir gerando novos indivíduos. Entre os métodos para seleção mais difundidos, destacam-se:

- Seleção aleatória: Nesse caso, serão selecionados indivíduos da população aleatoriamente para o processo de recombinação.
- Seleção por *ranking*: Os indivíduos são classificados de acordo com a função objetivo de maneira a formar um *ranking*. Então, através dessa classificação é realizada a seleção dos indivíduos para serem recombinados.

O método mais conhecido para realizar a seleção dos indivíduos é o Algoritmo de Monte Carlo, também conhecido como método da roleta. Nesse método os indivíduos são distribuídos

de maneira similar a uma roleta ou gráfico de “pizza”, tendo como critério a função objetivo para distribuição das parcelas ou porções, ou seja, quanto melhor classificado pela função objetivo, maior será a porção representativa do indivíduos (CATARINA, 2005). A Tabela 3.2 mostra cinco indivíduos de exemplo e os respectivos valores da função objetivo e objetivo relativo.

TABELA 3.2
Exemplo de comparação entre as funções objetivos de uma população.

S_i	Indivíduo	Objetivo	Objetivo relativo
S_1	10110	2,23	0,14
S_2	11000	7,27	0,47
S_3	11110	1,05	0,07
S_4	01001	3,35	0,21
S_5	00110	1,69	0,11

Para definir o valor da função objetivo relativo utiliza-se a Equação 3.1.

$$V_r(i) = \frac{V(i)}{total} \quad (3.1)$$

Sendo:

$$total = \sum_{k=1}^n (V(i)) \quad (3.2)$$

Onde:

- $V(i)$: Valor da função objetivo do indivíduo i
- $V_r(i)$: Valor da função objetivo relativo do indivíduo i
- n : Número de indivíduos da população

Assim, após cálculo dos valores da função objetivo pode-se classificar os indivíduos através da função objetivo relativo, como mostra a Tabela 3.3. A Figura 3.8 apresenta o gráfico em setores da distribuição da função objetivo relativo.

TABELA 3.3
Exemplo de população classificada de acordo com a função objetivo acumulado.

S_i	Objetivo relativo	Objetivo acumulado
S_3	0,07	0,07
S_5	0,18	0,18
S_1	0,14	0,32
S_4	0,21	0,53
S_2	0,57	1,00

Desta forma, o processo de seleção segundo o algoritmo de Monte Carlo, consiste em:

1. Gerar um número aleatório entre 0 e 1;
2. Verificar em que intervalo, de acordo com a função objetivo relativo, o valor sorteado encontra-se e selecioná-lo.

A Figura 3.8 mostra um gráfico com a distribuição dos valores acumulados. Observando a figura, por exemplo, se o valor sorteado for 0,23, o indivíduo selecionado será S_1 , visto que está compreendido entre o intervalo 0,18 a 0,32.

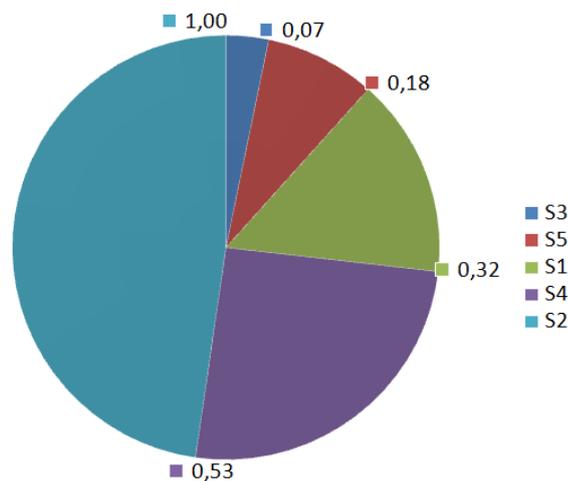


FIGURA 3.8 – Gráfico da distribuição da função objetivo acumulado

3.4.2 Recombinação

Tem a função de definir o local onde os cromossomo será “separado”, de maneira aleatória (randômica) ou pré-determinada para trocar com outro indivíduos um ou um grupo de genes,

gerando novos indivíduos. Pode-se dizer que essa é uma das principais e mais importantes características dos AG (MITCHELL, 1999).

Há diversas técnicas citadas na literatura passíveis para serem usadas como recombinação (*crossover*). Por isso, escolher a melhor não é uma questão simples, estando intimamente relacionada com o tipo de problema que se deseja resolver e, também, com conjunto de valores que cada gene pode assumir.

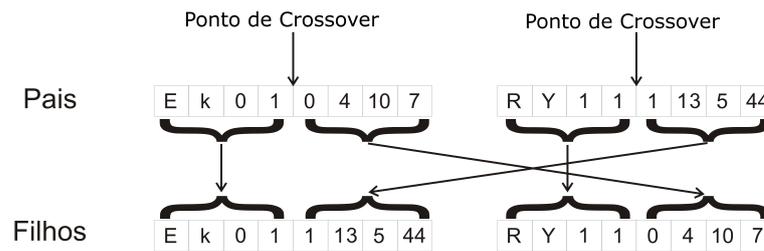


FIGURA 3.9 – Exemplo de recombinação.

3.4.3 Mutação

O operador de mutação tem a função de evitar mínimos ou máximos locais em uma população. Para isso, também de maneira aleatória, realiza um sorteio em um determinado intervalo, o qual irá definir se a mutação deverá ocorrer em um gene da solução selecionada. A mutação consiste em alterar o valor de um ou mais genes. Por exemplo, caso tenha-se um gene binário (pertinente de assumir os valores 0 e 1) o qual foi selecionado para mutação, tenha o valor 0 e devido ao sorteio a mutação deve ocorrer, o gene passará a ter outro valor, nesse caso, assumirá o valor 1.



FIGURA 3.10 – Exemplo de mutação.

4 CADEIA OU MODELO DE MARKOV

4.1 Introdução

Um sistema dinâmico é definido como um conjunto de variáveis cujos valores mudam com o passar do tempo. Em tais sistemas chama-se estado da variável o valor que ela assume em um determinado instante de tempo e o vetor formado pelos estados é denominado estado do sistema dinâmico (ANTON; BUSBAY, 2003).

Em processos dinâmicos na maioria das vezes não é possível determinar o valor preciso de uma variável, ou seja, ocorre um método estocástico. Todavia, é possível calcular as probabilidades das variáveis de interesse atingirem determinado valor. Entre as técnicas que podem ser aplicadas em tais cenários destaca-se a Cadeia ou Modelo de Markov.

As cadeias de Markov recebem esse nome em homenagem ao matemático russo Andrei Andreyevich Markov, o qual desenvolveu essa técnica para analisar as alterações de vogais e consoantes em um poema. Markov acreditava que seu modelo poderia ser aplicado apenas para o fim que ele aplicou. Atualmente, as Cadeias de Markov são utilizadas em diversas aplicações, como nas Teorias Quânticas e Genéticas.

4.2 Processos estocásticos

4.3 Conceitos e definições

Um Modelo ou Cadeia de Markov representa um processo estocástico, geralmente com estados discretos e contínuo no tempo, em que o sistema é modelado a partir de parâmetros observáveis. Segundo Anton e Busbay (2003) uma cadeia de Markov pode ser definida como:

Definição 1. *Sistema dinâmico cujos vetores de estado numa sucessão de intervalos de tempo são vetores de probabilidade e para o qual os vetores de estado em intervalos de tempo suces-*

sivos estão relacionados por uma equação da forma

$$x(k+1) = Px(k) \quad (4.1)$$

na qual $P = [p_{ij}]$ é uma matriz estocástica e p_{ij} é a probabilidade com que o sistema estará no estado i no instante $t = k+1$ se estiver no estado j no instante $t = k$.

Anton e Busbay (2003), lembram que:

A probabilidade de um experimento ou observação produzir certo resultado é aproximadamente a fração de tempo durante a qual este resultado ocorreria se o experimento fosse repetido muitas vezes sobre condições constante.

Ainda, se um acontecimento tiver n soluções possíveis, cada uma delas resultará em uma fração não-negativa, onde a soma das nos n estados possíveis deve resultar em um.

Em outras palavras, de acordo com a Definição 1, uma cadeia de Markov representa uma sequencia de variáveis aleatórias, por exemplo, $X(1), X(2), \dots, X(n)$. O escopo destas variáveis, isto é, o conjunto de valores que elas podem assumir, é chamado de espaço de estados, onde $X(n)$ denota o estado do processo no tempo n (SPERANDIO; GARCIA; BERNARDON, 2010). Se considerarmos que a distribuição de probabilidade condicional de X_{n+1} , nos estado passados é função apenas de X_n , tem-se:

$$Pr(X_{n+1} = x | X_0, X_1, \dots, X_n) = Pr(X_{n+1} = x | X_n) \quad (4.2)$$

Para facilitar a escrita, costuma-se simplificar $X(k)$ por X_k .

Em um modelo de Markov, tendo como estado inicial $x(0)$, os vetores de estados subsequentes podem ser expressos por:

$$\begin{aligned} x(1) &= P \cdot x(0) \\ x(2) &= P \cdot x(1) \\ x(3) &= P \cdot x(2) \\ &\vdots \\ x(k+1) &= P \cdot x(k) \end{aligned} \quad (4.3)$$

Então, os vetores podem ser reescritos em função do vetor de estado inicial $x(0)$, como:

$$x_1 = P \cdot x_0 \quad x_2 = P(P \cdot x_0) = P^2(x_0) \quad x_3 = P(P^2 \cdot x_0) = P^3(x_0), \dots \quad (4.4)$$

Desta forma, resulta:

$$x_k = P^k \cdot x_0 \quad (4.5)$$

Para um espaço de estados discretos, as integrações na probabilidade de transição de k passos são somatórios, e podem ser calculados como a k -ésima potência da matriz de transição. Isto é, se P é a matriz de transição para um passo, então P^k é a matriz de transição para a transição de k passos (SPERANDIO; GARCIA; BERNARDON, 2010).

Também, tem-se um método que não depende dos estados anteriores a $t = t_0$. Após a determinação dos coeficientes da matriz de transição P , pode-se calcular as probabilidades de permanecer ou transitar para outros estados. Assim, o método depende apenas do estado atual para determinar os possíveis estados futuros. por isso, diz-se que a Cadeia de Markov é homogênea (PARDOUXS, 2008).

4.4 Exemplo de um Modelo de Markov

Considere um sistema que pode assumir três níveis de demanda: baixo, médio e alto. De acordo com o levantamento dos dados históricos, concluiu-se que a probabilidade de transição de um nível para outro tem os valores mostrados na Tabela 4.1.

TABELA 4.1
Exemplo de matriz de transição P para três estados.

Nível	Baixo	Médio	Alto
Baixo	0,1	0,4	0,3
Médio	0,3	0,2	0,2
Alto	0,6	0,4	0,5

Os dados mostrados na Tabela 4.1, resultam na matriz de transição P (Equação 4.6).

$$P = \begin{bmatrix} 0,1 & 0,4 & 0,3 \\ 0,3 & 0,2 & 0,2 \\ 0,6 & 0,4 & 0,5 \end{bmatrix} \quad (4.6)$$

Onde:

- $p_{11} = 0,1 =$ Probabilidade da tensão permanecer em nível baixo
 $p_{12} = 0,4 =$ Probabilidade da tensão migrar do nível 2 para 1
 $p_{13} = 0,3 =$ Probabilidade da tensão migrar do nível 3 para 1
 $p_{21} = 0,3 =$ Probabilidade da tensão migrar do nível 1 para 2
 $p_{22} = 0,2 =$ Probabilidade da tensão permanecer em nível médio
 $p_{23} = 0,2 =$ Probabilidade da tensão migrar do nível 3 para 2
 $p_{31} = 0,6 =$ Probabilidade da tensão migrar do nível 1 para 3
 $p_{32} = 0,4 =$ Probabilidade da tensão migrar do nível 2 para 3
 $p_{33} = 0,4 =$ Probabilidade da permanecer em nível alto.

Pode-se representar, graficamente, a Equação 4.6 através do diagrama da Figura 4.1.

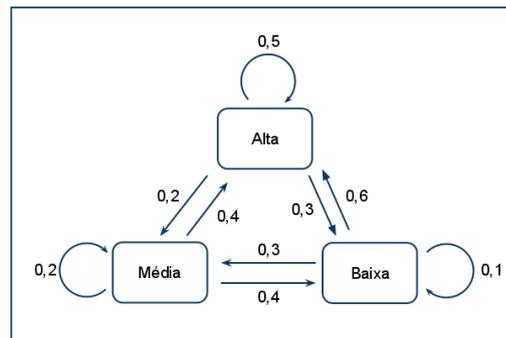


FIGURA 4.1 – Diagrama de estados de uma cadeia de Markov com a Matriz de transição da Tabela 4.1

Após o modelo e a matriz de transição serem definidas, pode-se calcular a probabilidade do sistema estar em um estado após um determinado número de intervalos de tempo, através da Equação 4.5. Considerando que $x_1(k)$, $x_2(k)$ e $x_3(k)$ são as probabilidades da demanda estar em nível baixo, médio e alto, respectivamente, no instante $t = k$. Então,

$$x(k) = \begin{bmatrix} x_{1k} \\ x_{2k} \\ x_{3k} \end{bmatrix} \quad (4.7)$$

Sabendo-se que a demanda está no nível médio no instante $t = 0$, o vetor de estado inicial,

resulta,

$$x(0) = \begin{bmatrix} 0 \\ 1 \\ 0 \end{bmatrix} \quad (4.8)$$

Assim, pode-se calcular a probabilidade do sistema estar em cada estado, por exemplo após três intervalos de tempo. Nesse caso, $k = 2$, tem-se:

$$x_2 = \begin{bmatrix} 0,1 & 0,4 & 0,3 \\ 0,3 & 0,2 & 0,2 \\ 0,6 & 0,4 & 0,5 \end{bmatrix}^2 \cdot \begin{bmatrix} 0 \\ 1 \\ 0 \end{bmatrix} = \begin{bmatrix} 0,24 \\ 0,24 \\ 0,52 \end{bmatrix} \quad (4.9)$$

O vetor resultante na Equação 4.9, indica que há 24,0%, 24,0% e 52,0% de chances da demanda estar em nível baixo, médio e alto, respectivamente, dois intervalos à frente.

5 METODOLOGIA PROPOSTA

Para a construção de um modelo previsor de demanda, considerando a influência de variáveis climáticas e o curtíssimo prazo como horizonte de projeção, propõe-se um modelo computacional híbrido.

Os modelos híbridos nada mais são que a integração de mais de uma técnica para realizar determinada tarefa. No contexto desse trabalho será a união de técnicas de redes neurais artificiais, algoritmos genéticos e Cadeia de Markov. No que se refere a RNAs será usado o algoritmo SOM. Os AGs serão empregados para minimizar a função objetivo através da definição dos melhores valores para as variáveis do problema. Devido a metodologia encontrar valores que minimizam a função objetivo, variando seus próprios parâmetros, pode-se considerá-lo adaptativo.

5.1 Especificações

5.1.1 Variáveis do problema

Foram escolhidas como variáveis do problema:

- M e N: número de linhas e colunas, respectivamente, no mapa auto-organizável;
- Temperatura (t), medida em graus Celsius ($^{\circ}C$);
- Umidade (u), medida em porcentagem (%);
- Velocidade do vento (v), medida em metros por segundo (m/s);
- Demanda de energia elétrica (d), medida em mega watts (MW). É utilizada durante a fase de treinamento da rede neural.
- Número de simulações (ns): número de simulações; delimita o número de iterações do previsor antes de plotar a curva prevista de demanda.

5.1.2 Base de dados

Utilizou-se uma base de dados real contendo valores horários de demanda, temperatura, umidade e velocidade do vento. As informações são provenientes de uma concessionária de energia elétrica com concessão nas cidades de Tapejara e Ibiaçá, Rio Grande do Sul.

A base de dados totalizou 3290 amostras, sendo segmentada em duas partes:

- Base de dados para treinamento (BDtr) da rede neural artificial, contendo 3266 amostras;
- Base de dados para testes (BDt) do modelo previsor, contendo 24 amostras.

5.1.3 Restrições

Definiu-se intervalos de valores que as variáveis de entrada podem assumir. Obedecendo os intervalos estabelecidos o programa deverá gerar, avaliar e encontrar as melhores soluções possíveis, segundo a função custo ou *fitness*.

- Intervalos de valores das variáveis:

M e N : podem assumir valores inteiros entre 5 e 30 de maneira independente, ou seja, não é necessário que as duas variáveis tenham o mesmo valores;

t, u, v : variáveis binárias, pertinentes de assumir os valores 0 (variável não participa das etapas do algoritmo) ou 1 (variável participa das etapas do algoritmo);

ns : passível de assumir valores inteiros entre 5 e 200.

- Caso um indivíduo tenha todos os genes correspondentes as variáveis climáticas iguais a zero, ou seja, nenhuma das variáveis climáticas deveria participar do treinamento da RNA, arbitrariamente escolheu-se que todas irão participar das etapas do algoritmo. Se nenhuma das variáveis pudesse ser usada, o treinamento não seria possível de ocorrer.

5.2 Módulos do fluxo de dados

O fluxo de dados do modelo previsor proposto é mostrado na Figura 5.1 e a explicação de cada um dos módulos componentes do fluxograma são descritos a seguir.

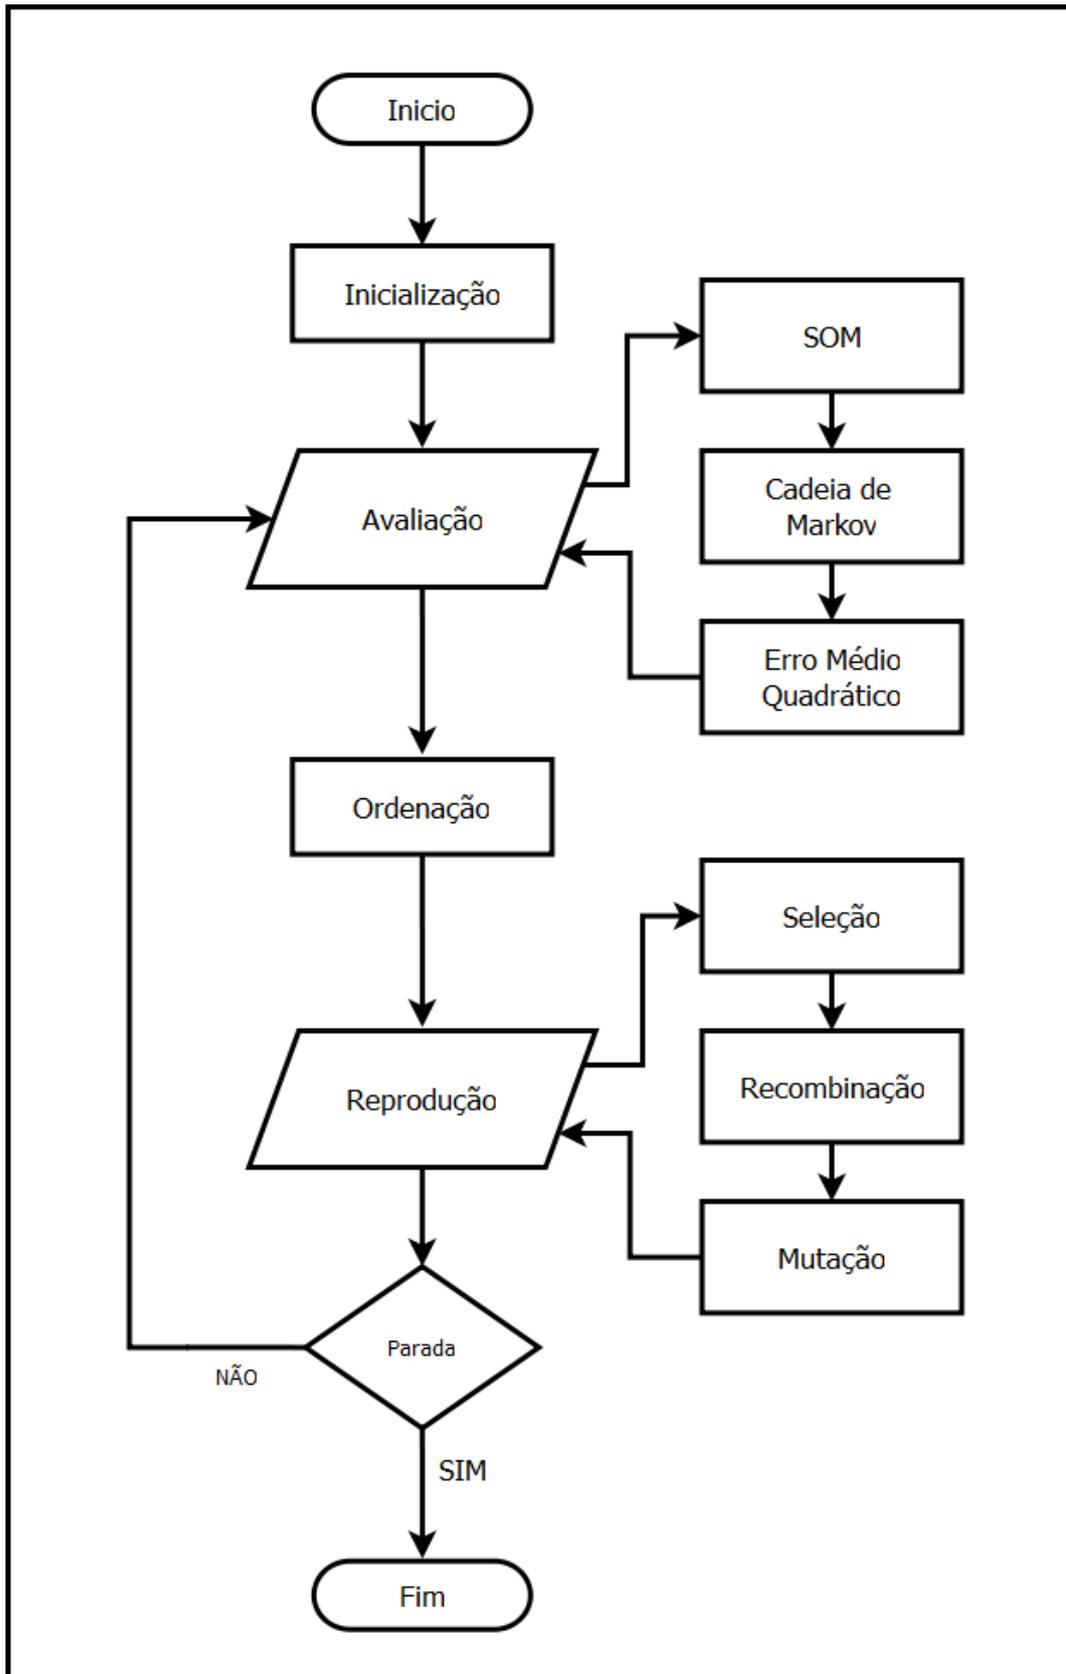


FIGURA 5.1 – Fluxograma geral do modelo predictor de demanda.

5.2.1 Inicialização

Consiste em criar de maneira aleatória um conjunto de P indivíduos (população), observando as restrições previamente estabelecidas para cada uma das variáveis. A população consiste de uma matriz de dados, onde cada linha corresponde a um indivíduo (cromossomo) e as colunas referem-se a uma variável (gene). A Figura 5.2 mostra uma população inicial com vinte indivíduos gerada de acordo com as restrições enunciadas anteriormente.

A população terá seis genes ou variáveis: M, N, t, u, v e ns.

```

population =

```

7	30	0	1	1	175
7	15	0	1	0	183
9	11	0	0	1	118
19	8	1	1	0	105
15	6	0	0	0	52
15	6	1	1	0	100
13	28	0	0	1	81
11	15	0	0	1	192
19	6	0	0	1	8
6	9	1	1	1	93
19	12	1	0	1	40
14	21	1	0	1	157
17	16	0	0	1	105
26	25	1	0	1	109
14	29	1	1	1	120
10	12	0	0	1	43
10	9	0	0	0	185
16	9	1	1	0	26
11	15	1	0	1	144
10	8	0	0	0	104

FIGURA 5.2 – Exemplo de população inicial.

5.2.2 Avaliação

Esse módulo é responsável por calcular o custo de cada um dos P indivíduos. Essa avaliação permitirá a escolha dos melhores parâmetros para o sistema. É através da avaliação que serão escolhidos os indivíduos para participarem da reprodução.

Foi escolhido, arbitrariamente, que os dois indivíduos com menor função custo em cada geração, passam diretamente para a próxima geração.

O módulo de avaliação subdivide-se em outros três: SOM, Cadeia de Markov e Erro Médio.

SOM

Nessa etapa ocorre o treinamento da RNA de acordo com os parâmetros do indivíduo selecionado (M,N,t,u,v, ns). Finda essa etapa, tem-se um mapa auto-organizado (*Self-Organizing Map*), de dimensões M linhas e N colunas, onde cada uma das posições é chamada de neurônio.

O mapa treinado servirá para encontrar o neurônio que melhor represente os dados de entrada em estados futuros, permitindo a localização de um estado na Cadeia de Markov.

Cadeia de Markov

Após o treinamento da RNA, ou seja, criação do mapa auto-organizável, será calculada a taxa de transição de um neurônio i para um j , onde i corresponde ao índice do neurônio de origem e j ao do destino.

Desta forma, cria-se uma matriz T de probabilidades da transição de um estado para outro no Modelo de Markov, onde somente são contabilizadas e consideradas válidas as transições em horários subsequentes. A matriz T terá $(M \times N)$ linhas e $(M \times N)$ colunas, como mostra a Tabela 5.1.

TABELA 5.1
Matriz de exemplo de estados de Markov.

	1	2	...	MxN
1	$T_{(1)(1)}$	$T_{(1)(2)}$...	$T_{(1)(MxN)}$
2	$T_{(2)(1)}$	$T_{(2)(2)}$...	$T_{(2)(MxN)}$
3	$T_{(3)(1)}$	$T_{(3)(2)}$...	$T_{(3)(MxN)}$
⋮	⋮	⋮	⋮	⋮
MxN	$T_{(MxN)(1)}$	$T_{(MxN)(2)}$...	$T_{(MxN)(MxN)}$

Erro Médio Quadrático

Esse módulo irá determinar o Erro Médio Quadrático (EMQ) devido aos parâmetros do indivíduo (cromossomo). Para tanto, as entradas (temperatura, velocidade do vento e umidade), em um instante t , devem encontrar um neurônio, que melhor represente aquelas variáveis no mapa auto-organizável. Então, calcula-se a probabilidade de transição do neurônio atual para outros neurônios, n instantes a frente. O resultado será um vetor com os valores previstos de demanda para os n instantes a frente. Como o objetivo do modelo predictor proposto tem como horizonte de projeção o curtíssimo prazo, será adotado $n = 24$ intervalos horários à frente.

Para o cálculo do EMQ será utilizada a base de dados de testes (BDt). Assim, através da Equação 5.1, é possível calcular-se o erro médio quadrático usando os parâmetros do cromos-

somo.

$$EMQ = \frac{\sum_{n=1}^{24} \sqrt{\left(\frac{Dp_n - Dr_n}{Dr_n}\right)^2}}{24} \quad (5.1)$$

Onde:

Dp_n : valor de demanda resultante do modelo previsor no instante n ;

Dr_n : valor obtidos para demanda na base de dados de testes no instante n ;

EMQ : erro médio quadrático considerando as n posições do vetor de probabilidades;

n : número de intervalos à frente nos quais deseja-se realizar a previsão de demanda.

5.2.3 Ordenação

Os P indivíduos gerados serão ordenados de maneira crescente através da função custo, Equação 5.1. Assim, um cromossomo na posição W , obteve melhores resultados, ou seja, EMQ , que uma solução na posição $(W + 1)$, onde W é a posição do indivíduo na população ordenada.

5.2.4 Reprodução

Essa etapa é responsável por gerar novos indivíduos aplicando os operadores genéticos na população. Subdivide-se em: Seleção, Recombinação e Mutação.

Seleção

Consiste em selecionar alguns indivíduos da população para gerar novos indivíduos. A seleção busca as soluções mais viáveis ou otimizadas, ou seja, aquelas com menor função custo. Desta forma, busca-se aprimorar a população a medida que surgem novas gerações de indivíduos.

Escolheu-se que 70% dos indivíduos melhores adaptados poderão participar do processo de recombinação. Os 30% restante da população sofrerão obrigatoriamente mutação.

Recombinação ou Crossover

Depois da seleção dos cromossomos, haverá a recombinação, a qual consiste em combinar dois indivíduos e gerar dois novos indivíduos. Salienta-se que ao recombinar dois indivíduos

os anteriores deixam de existir. Assim, gera-se uma nova população de soluções que terá no máximo P novas soluções.

Mutação

O operador mutação será aplicado em 30% da população, na seguinte proporção:

- Em 20% ocorrerá mutação em três genes do indivíduo selecionado
- Em 30% ocorrerá mutação em dois genes do indivíduo selecionado
- Em 50% ocorrerá mutação em um gene do indivíduo selecionado

5.2.5 Critério de parada

Para o ciclo de dados terminar deve-se configurar três critérios que irão determinar o fim do processo. Serão testados como critérios de parada:

- Número máximo de gerações
- Tempo máximo de execução
- Mínimo valor para função custo

6 ANÁLISES EXPERIMENTAIS

O modelo apresentado foi implementado no Software MATLAB para propiciar a validação da metodologia, através da comparação e análise de diferentes variações dos parâmetros. Para tanto, foram testadas variações no número de indivíduos da população, tipos de função de seleção e de recombinação, observando-se a consequência na função custo.

Nas Tabelas 6.1, 6.2 e 6.3, são descritos códigos e comportamentos dos operadores genéticos testados.

TABELA 6.1
Descrição dos tipos de Função Seleção testados.

Função	Código	Descrição
Função Seleção	1	Nessa classificação a distribuição das proporções ou chances de um indivíduo ser selecionado é proporcional a contribuição do indivíduo no somatório dos valores da Função Objetivo. Em outras palavras, baseia-se no valor da função objetivo relativo para realizar a distribuição das parcelas.
	2	A distribuição das probabilidades do indivíduo ser selecionado é proporcional a sua contribuição na Função Objetivo relativo, a qual é distribuída ao longo de uma linha. O comprimento da linha será proporcional ao valor da Função Objetivo do indivíduo. No momento de realizar a seleção essa linha é percorrida em intervalos iguais.
	3	Seleção uniforme dos indivíduos, ou seja, não considera o valor da função objetivo. Desta forma, todos os indivíduos da população tem as mesmas probabilidades de serem selecionados. Na prática esse tipo de seleção é pouco usada.

TABELA 6.2
Descrição dos tipos de Função Recombinação testados.

Função	Código	Descrição
Função Recombinação	1	É criado um vetor binário tendo a mesma dimensão de um indivíduo. Um par de indivíduos é selecionado e as posições do cromossomo comparadas com o vetor binário. Nas posições em que o vetor tiver o valor zero, os indivíduos trocam os valores do gene daquela posição. No outro caso, ou seja, quando o valor for um, o respectivo gene dos indivíduos permanecem, ou seja, não ocorrer troca de genes.
	2	É sorteado um valor entre 1 e (n), onde n é igual ao número de genes dos indivíduos, sendo este chamado de ponto de recombinação ou crossover. No ponto sorteado o par de pais selecionado para a recombinação irá trocar o conjunto de genes após o ponto de crossover, na mesma ordem, gerando novas soluções com blocos de genes de cada um dos indivíduos. Observe que caso o valor sorteado seja igual ao número de genes, nenhum gene será trocado.
	3	Similar ao comportamento descrito no item 2, porém com dois pontos de recombinação. Assim, é permitido a troca de uma parcela do indivíduo em vez de todo um bloco. Nessa opção também os pontos são sorteados de maneira aleatória, compreendidos entre 1 e o número de genes dos indivíduos.

TABELA 6.3
Descrição dos tipos de Função Mutação testadas.

Função	Código	Descrição
Função Mutação	1	De maneira arbitrária optou-se que 30% da população sofrerá mutação. Porém, de maneira aleatória é sorteado quantos genes do indivíduo selecionado sofrerão a ação do operador de mutação. As porcentagens escolhidas foram: 50% sofrerá mutação em um gene, 30% em dois genes e os 20% restantes terão três genes mutados. Após definição de quantos genes sofrerão mutação no indivíduo é feita a escolha, também de maneira aleatória, da posição do gene a ser mutado. É importante perceber que os limites de cada gene devem ser respeitados, quando adota-se codificação não uniforme, ou seja, que cada um dos genes varia em intervalos diferentes.

6.1 Variação do tamanho da população

Para analisar a influência do tamanho da população nos resultados obtidos pelo modelo previsor, variou-se o número de indivíduos pertencentes a população em cada geração. Variou-se o tamanho da população em três patamares, sendo eles: 10, 15 e 20 indivíduos.

Os demais parâmetros foram mantidos iguais aos mostrados na Tabela 6.4.

TABELA 6.4
Parâmetros estáticos durante a variação do tamanho da população.

Indivíduos de elite:	2
Número máximo de gerações:	20
Tempo máximo de execução:	3600 segundos
Código da Função Seleção:	2
Código da Função Recombinação:	2
Código da Função Mutação:	1

6.1.1 População com 10 indivíduos

Foram realizadas simulações sendo em todas o critério número máximo de gerações atingido. Em todas as simulações o valor mínimo do EMQ encontrado manteve-se com pouca variação. Os resultados de uma das simulações são apresentados a seguir.

Obteve-se como população final os dados apresentados na Tabela 6.5.

TABELA 6.5
População final considerando 10 indivíduos por geração.

Indivíduo	M	N	t	u	v	ns	EMQ
1	21	16	1	1	0	195	2,5948
2	21	16	1	1	0	195	2,6773
3	23	16	1	1	0	195	3,0450
4	21	16	1	1	0	195	2,5677
5	21	16	1	1	0	195	2,5927
6	21	16	1	1	0	195	2,8214
7	21	16	1	1	0	195	3,0034
8	21	16	1	1	0	195	2,8422
9	21	5	1	1	0	195	4,1842
10	21	16	1	1	0	195	2,9482

A Tabela 6.6 mostra alguns dados estatísticos obtidos considerando uma população com 10 indivíduos.

TABELA 6.6
Estatísticas para a população com 10 indivíduos.

Descrição	Valor
EMQ mínimo	2,5677
EMQ máximo	4,1842
Médio dos erros	2,9277
Desvio padrão	0,4752

Na Figura 6.1 é mostrada a comparação entre o melhor indivíduo e a média dos EMQ em cada geração, curvas em azul e vermelho, respectivamente. Também, na mesma figura, são mostrados os limites segundo o desvio padrão, curva em verde.

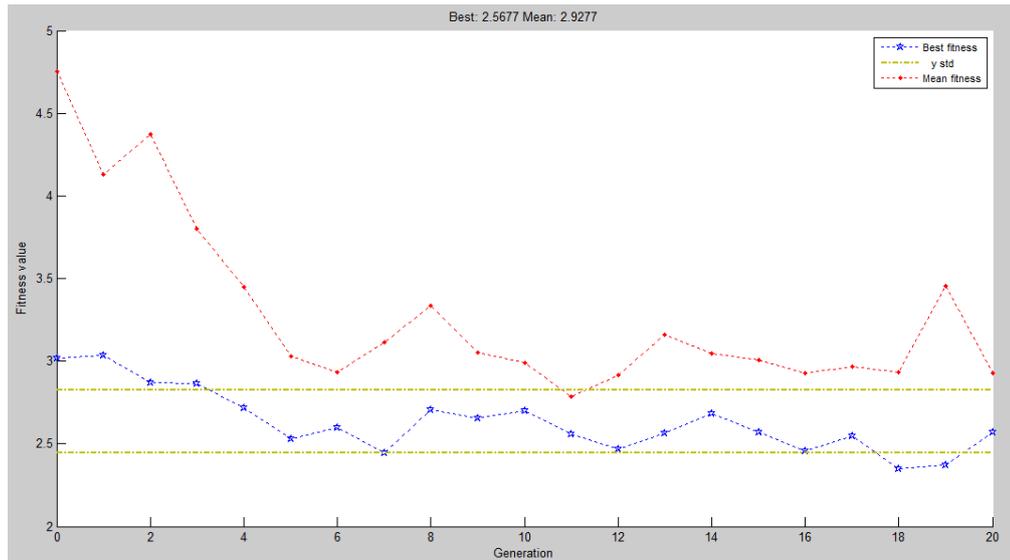


FIGURA 6.1 – Comparação entre o melhor indivíduo e a média, segundo a função objetivo, em cada geração e o desvio padrão do EMQ, utilizando-se uma população com 10 indivíduos.

6.1.2 População com 15 indivíduos

Foram realizadas inúmeras simulações sendo em todas o critério número máximo de gerações atingido. Os resultados de uma das simulações são apresentados a seguir. Nesse caso, também, o valor mínimo do EMQ apresentou pouca variação nas simulações realizadas.

Obteve-se como população final os dados apresentados na Tabela 6.7.

TABELA 6.7
População final considerando 15 indivíduos por geração.

Indivíduo	M	N	t	u	v	ns	EMQ
1	12	13	1	1	0	157	2,5990
2	12	13	1	1	0	157	2,9290
3	12	13	1	1	0	157	2,6958
4	12	13	1	1	0	157	2,8019
5	12	13	1	1	0	157	2,4798
6	12	13	1	1	0	157	2,3941
7	12	13	1	1	0	157	2,4213
8	12	13	1	1	0	157	2,5847
9	12	13	1	1	0	157	2,7260
10	12	13	1	1	0	157	2,7398
11	12	13	1	0	0	157	4,2773
12	12	13	1	1	0	157	2,5579
13	15	7	1	1	0	157	3,4743
14	12	13	1	1	0	157	4,8169
15	12	13	1	1	0	157	2,7562

A Tabela 6.8 mostra alguns dados estatísticos obtidos na simulação.

TABELA 6.8
Estatísticas para a população com 15 indivíduos.

Descrição	Valor
EMQ mínimo	2,3941
EMQ máximo	4,8169
Médio dos erros	2,9500
Desvio padrão	0,7052

A Figura 6.2 mostra os limites estabelecidos pelo desvio padrão. Ainda na mesma figura são mostrados o melhor indivíduo, curva em azul, e a média dos EMQ, curva em vermelho, em cada geração.

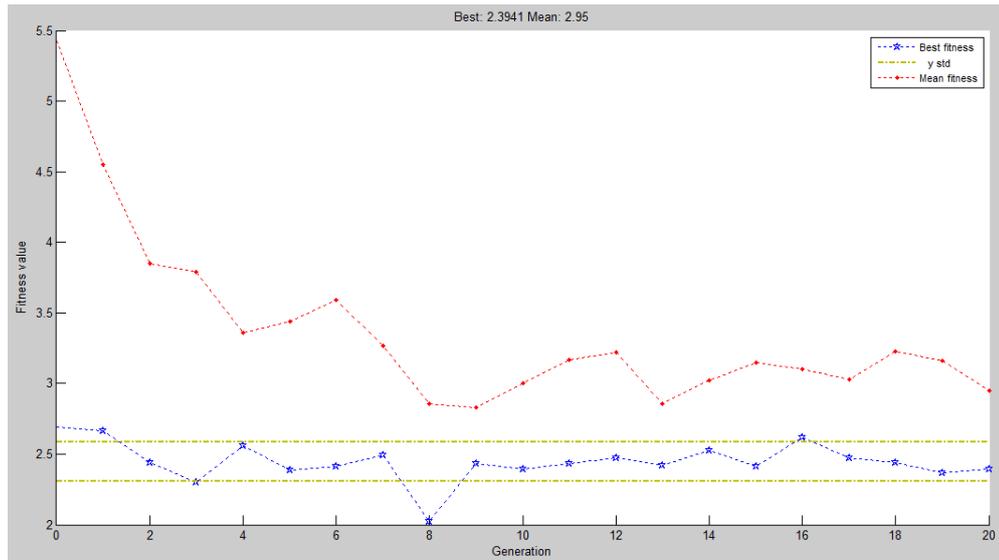


FIGURA 6.2 – Comparação entre o melhor indivíduo e a média, segundo a função objetivo, em cada geração e o desvio padrão do EMQ, utilizando-se uma população com 15 indivíduos.

6.1.3 População com 20 indivíduos

Realizou-se simulações sendo em todas o critério número máximo de gerações foi atingido. Os resultados de uma das simulações são apresentados a seguir.

Obteve-se como população final os dados apresentados na Tabela 6.9.

TABELA 6.9
População final considerando 20 indivíduos por geração.

Indivíduo	M	N	t	u	v	ns	EMQ
1	17	13	1	1	0	124	2,6322
2	13	14	1	1	0	112	2,5244
3	5	14	1	1	0	112	4,4302
4	13	13	1	1	0	124	2,4740
5	13	14	1	1	0	124	2,6834
6	17	13	1	1	0	124	2,8807
7	17	13	1	1	0	124	2,4765
8	17	13	1	1	0	112	2,7748
9	13	14	1	1	0	112	2,8207
10	17	13	1	1	0	112	2,6540
11	17	13	1	1	0	112	2,5087
12	13	7	1	1	0	112	3,3558
13	17	13	1	1	0	124	2,6532
14	13	14	1	1	0	112	2,8889
15	13	14	1	1	0	112	2,9785
16	17	14	1	1	0	112	2,8648
17	7	20	1	1	0	124	3,5359
18	17	14	0	1	0	124	5,3136
19	8	10	1	0	0	112	3,3335
20	15	13	1	1	0	124	2,970

A Tabela 6.10 mostra alguns dados estatísticos obtidos considerando a população final após 20 gerações.

TABELA 6.10
Estatísticas para a população com 20 indivíduos.

Descrição	Valor
EMQ mínimo	2,4740
EMQ máximo	5,3136
Médio dos erros	3,0437
Desvio padrão	0,3180

A Figura 6.3 mostra os limites estabelecidos pelo desvio padrão (curvas em verde). Ainda

na mesma figura são mostrados o melhor indivíduo, curva em azul, e a média dos EMQ, curva em vermelho, em cada geração.

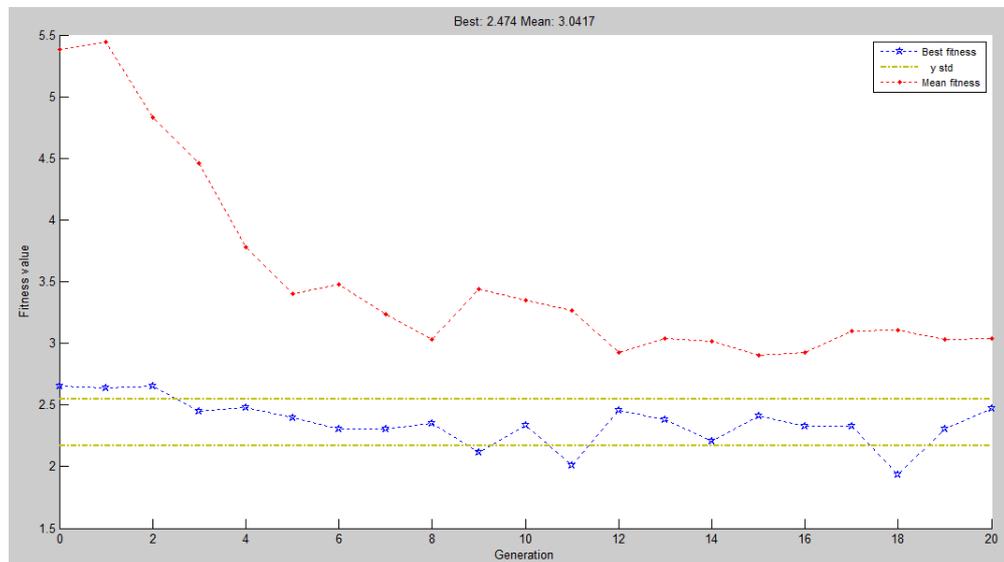


FIGURA 6.3 – Comparação entre o melhor indivíduo e a média, segundo a função objetivo, em cada geração e o desvio padrão do EMQ, utilizando-se uma população com 20 indivíduos.

6.1.4 Considerações sobre a variação do tamanho da população

Analisando-se os resultados da população final obtida, considerando as simulações realizadas, conclui-se que a variável velocidade do vento apresentou-se irrelevante para o consumo de demanda. Tal constatação é propiciada pela análise do gene correspondente a variável citada. Nas simulações com população contendo 10, 15 e 20 indivíduos, a população final possui o gene da variável velocidade do vento igual a zero em todos os casos. Isso indica que a variável não foi utilizada nas etapas do algoritmo.

Observa-se que em todos os casos, ou seja, populações contendo 10, 15 e 20 indivíduos, a média dos EMQ (curva em vermelho) apresentou comportamento satisfatório se for considerado a diminuição do seu valor ao longo das gerações. Com isso, conclui-se que os indivíduos da população, a medida que transcorrem as gerações, estão ajustando seus parâmetros de maneira a obter valores menores para função objetivo.

A Tabela 6.11 apresenta o resumo dos valores obtidos durante a variação do número de indivíduos na população.

TABELA 6.11
Resumo estatístico da variação o número de indivíduos da população.

População	Menor EMQ	Maior EMQ	Desvio padrão	Média dos EMQ
10 indivíduos	2,5677	4,1842	0,4752	2,9277
15 indivíduos	2,3941	4,8169	0,7052	2,9500
20 indivíduos	2,4740	5,3136	0,7180	3,0417

NOTA: Salienta-se que embora o melhor resultado obtido e apresentado na Tabela 6.11 tenha ocorrido com a população contendo 15 indivíduos, os próximos resultados apresentados nesse trabalho consideram 10 indivíduos na população. Essa decisão foi tomada com o objetivo de facilitar as simulações computacionais e, principalmente, pela pequena diferença entre o menor e o maior EQM (aproximadamente, 0,1736%), também observada na tabela citada.

6.1.5 Exemplo de resultados - Variação do número de indivíduos da população

Gerou-se a curva de previsão de demanda com os dados que obtiveram o menor valor para função objetivo (Indivíduo 6 da Tabela 6.7). Sendo eles:

- $M = 12$
- $N = 13$
- Utilizando-se das variáveis temperatura e umidade como entrada
- $ns = 157$

A Figura 6.4 apresenta os mapas componentes, sendo eles representativos das variáveis: demanda, temperatura e umidade. Os mapas mostrados na figura apresentam duas escalas de cores, na vertical estão os valores reais e na horizontal os valores normalizados de cada uma das variáveis.

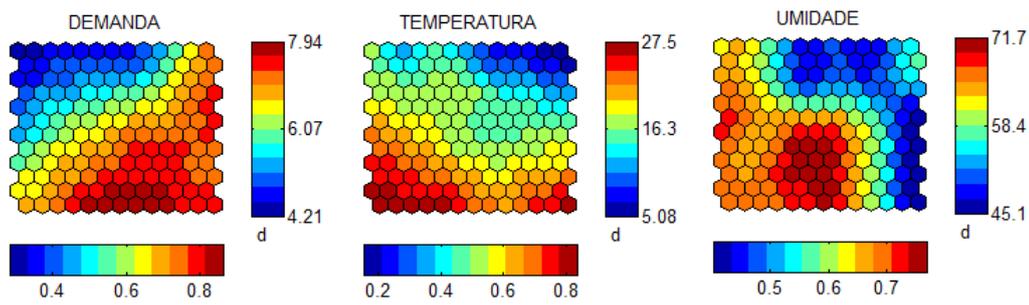


FIGURA 6.4 – Mapas componentes obtidos com o melhor indivíduo das simulações de variação do número de indivíduos da população.

Analisando-se os mapas componentes mostrados, observa-se que os menores valores de demanda ocorreram quando a temperatura estava em torno de 16°C e umidade próxima a 60% (neurônio superior esquerdo nos mapas componentes). Também, a observação mostra que os maiores valores de demanda aconteceram quando a temperatura estava em torno dos 16°C e umidade próxima a 71% (neurônios centrais inferiores nos mapas componentes).

A Figura 6.5 apresenta a demanda prevista, curva em preto, e a demanda real medida, curva em verde. Também, na mesma figura, em azul observam-se as curvas previstas em cada uma das simulações, sendo seu número determinado pela variável ns . Através da média das ns simulações, gera-se a curva de demanda prevista. Em vermelho é mostrado o limiar da demanda contratada a qual é, nesse caso, igual a 8 MW.

Os números em percentual mostrados na parte superior da Figura 6.5 representam a probabilidade da demanda, naquele instante, ultrapassar a demanda contratada.

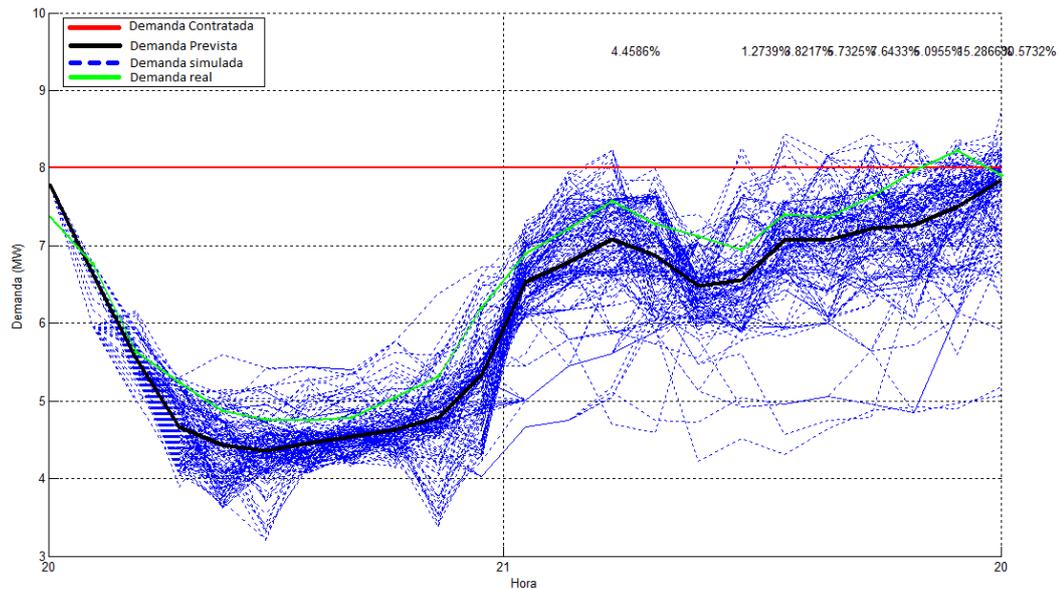


FIGURA 6.5 – Comparação entre a curva de demanda prevista e a real com os parâmetros do melhor indivíduo ao variar-se o tamanho da população.

Deve-se observar que a medida que o tempo transcorre o sistema tende a ser mais suscetível a erros. Considerando que a previsão é horária, ou seja, a cada intervalo horário de tempo a curva de demanda prevista será recalculada, o sistema mostrou-se robusto e satisfatório. Nas primeiras horas a frente a curva de demanda prevista mostra-se bastante próxima da curva real.

6.2 Variação da Função Seleção

Foram realizadas simulações com diferentes tipos de função de seleção e observou-se as consequências no EMQ. Os códigos e descrições das funções de seleção utilizadas encontram-se na Tabela 6.1. Os demais parâmetros foram mantidos iguais aos mostrados na Tabela 6.12.

TABELA 6.12

Parâmetros estáticos durante a variação do tipo de Função Seleção.

Indivíduos de elite:	2
Tamanho da população:	10 indivíduos
Número máximo de gerações:	10
Tempo máximo de execução:	3600 segundos
Código da Função Recombinação:	2
Código da Função Mutação:	1

6.2.1 Função de Seleção - Código 1

A população final obtida quando utilizada a Função de Seleção - Código 1 é apresentada na Tabela 6.13.

TABELA 6.13
População final considerando Função de Seleção - Código 1.

Indivíduo	M	N	t	u	v	ns	EMQ
1	24	9	1	1	0	141	3,0864
2	24	9	1	1	0	141	2,8032
3	24	9	1	1	0	141	2,5555
4	24	9	1	1	0	141	2,9133
5	24	15	1	1	0	141	2,7654
6	24	15	1	1	0	141	2,7917
7	24	9	1	1	1	141	2,7542
8	24	9	1	1	0	141	2,7176
9	16	9	1	1	0	141	3,9976
10	24	9	0	0	1	141	7,1775

A Tabela 6.14 mostra alguns dados estatísticos obtidos na simulação.

TABELA 6.14
Estatísticas para a Função Seleção - Código 1.

Descrição	Valor
EMQ mínimo	2,5555
EMQ máximo	7,1275
Médio dos erros	3,3512
Desvio padrão	1,3859

A Figura 6.6 mostra a comparação entre o melhor indivíduo e a média dos EMQ, curvas em azul e vermelho, respectivamente, em cada geração. Na mesma figura, em verde, são mostrados os limites estabelecidos pelo desvio padrão dos EMQ.

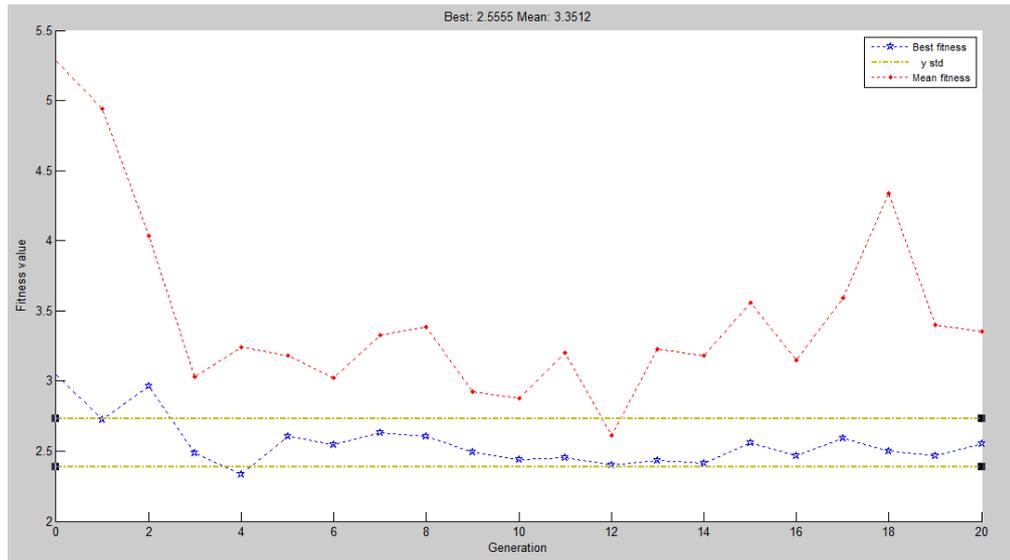


FIGURA 6.6 – Comparação entre o melhor indivíduo e a média, segundo a função objetivo, em cada geração e o desvio padrão do EMQ, utilizando-se a Função de Seleção - Código 1.

6.2.2 Função de Seleção - Código 2

Os resultados apresentados na Tabela 6.15 correspondem a população final obtida em uma das simulações com utilizou-se a Função de Seleção - Código 2.

TABELA 6.15
População final considerando Função de Seleção - Código 2.

Indivíduo	M	N	t	u	v	ns	EMQ
1	17	21	1	0	0	182	2,6476
2	17	21	1	0	0	182	3,1646
3	17	15	1	1	1	182	3,7492
4	17	21	1	0	0	182	2,7701
5	17	21	1	0	0	182	2,5941
6	17	21	1	0	0	182	2,8722
7	17	21	1	0	0	182	2,9711
8	8	21	1	0	0	182	3,2722
9	17	21	1	1	1	182	2,8307
10	14	21	1	0	0	182	2,2710

A Tabela 6.16 mostra alguns dados estatísticos obtidos na simulação, correspondentes a população final representada na Tabela 6.15.

TABELA 6.16
Estatísticas para a Função Seleção - Código 2.

Descrição	Valor
EMQ mínimo	2,3660
EMQ máximo	3,3660
Médio dos erros	2,6600
Desvio padrão	0,2510

Na Figura 6.7 é mostrado o melhor indivíduo de cada geração (curva em azul), ou seja, aquele que segundo a função avaliação obteve o menor EMQ. Também, na mesma figura apresenta-se, em vermelho, a média dos erros (EMQ) dos indivíduos em cada geração, além dos limites determinados pelo desvio padrão (curva em verde).

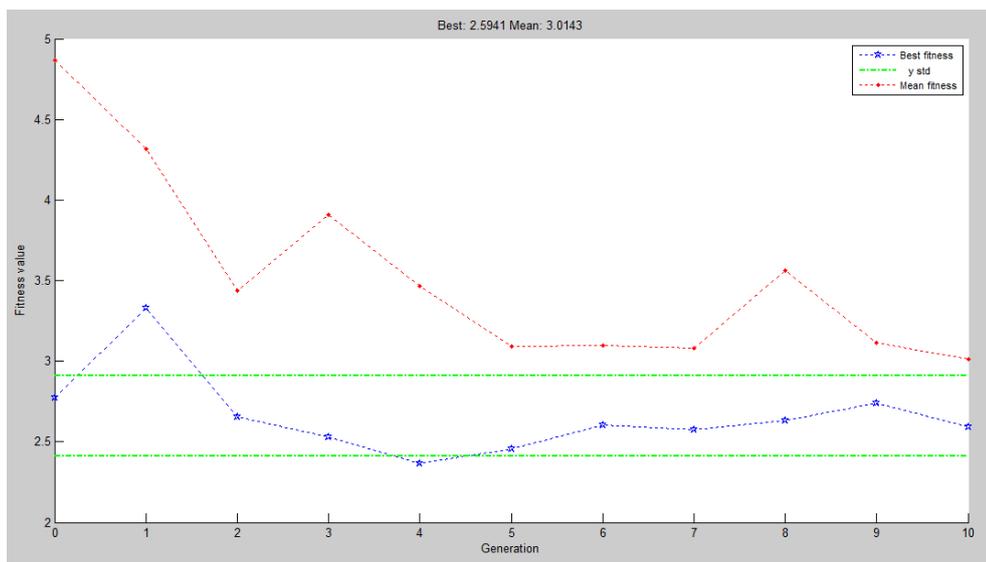


FIGURA 6.7 – Comparação entre o melhor indivíduo e a média, segundo a função objetivo, em cada geração e o desvio padrão do EMQ, utilizando-se a Função de Seleção - Código 2.

6.2.3 Função de Seleção - Código 3

Obteve-se como população final os dados apresentados na Tabela 6.17 quando a Função de Seleção - Código 3 foi empregada.

TABELA 6.17
População final considerando Função de Seleção - Código 3.

Indivíduo	M	N	t	u	v	ns	EMQ
1	12	21	1	1	0	118	2,9226
2	18	11	1	1	0	149	2,8470
3	24	21	1	1	0	118	3,2733
4	17	18	0	1	0	118	5,5424
5	18	11	1	1	0	118	3,3078
6	18	11	1	1	0	118	2,9884
7	18	11	1	1	0	118	2,9876
8	17	11	1	1	0	149	2,3955
9	25	5	1	1	0	149	4,5224
10	24	21	1	1	0	118	3,1872

A Tabela 6.18 mostra alguns dados estatísticos obtidos na simulação para população final descrita na Tabela 6.17.

TABELA 6.18
Estatísticas para a Função Seleção - Código 3.

Descrição	Valor
EMQ mínimo	2,3955
EMQ máximo	5,5424
Médio dos erros	3,3974
Desvio padrão	0,9311

A Figura 6.8 mostra os limites estabelecidos pelo desvio padrão (curvas em verde). Ainda na mesma figura são mostrados o melhor indivíduo, curva em azul, e a média dos EMQ, curva em vermelho, em cada geração.

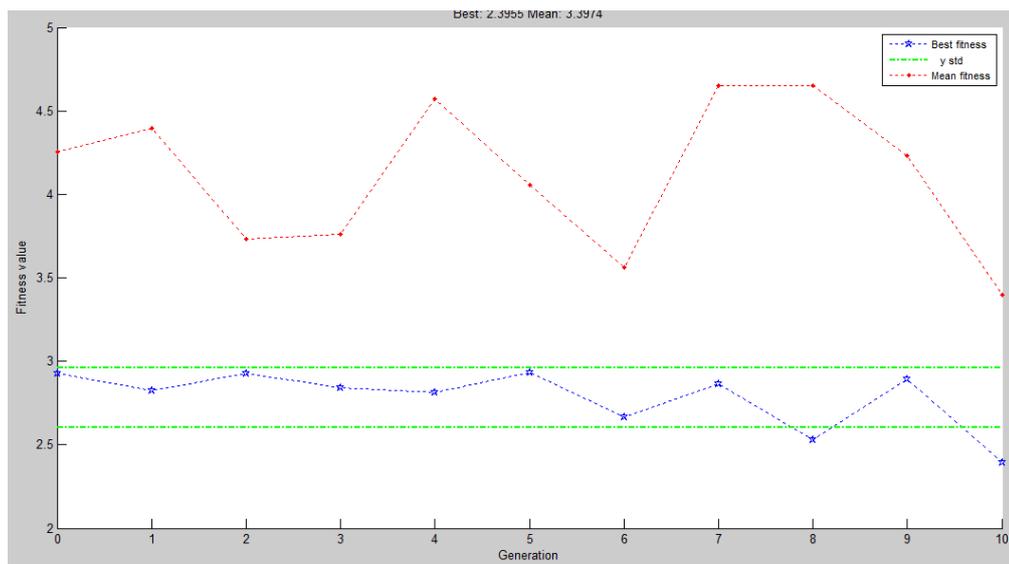


FIGURA 6.8 – Comparação entre o melhor indivíduo e a média, segundo a função objetivo, em cada geração e o desvio padrão do EMQ, utilizando-se a Função de Seleção - Código 3.

6.2.4 Considerações sobre a variação da função de seleção

Os testes variando-se a função responsável pela seleção dos indivíduos, nos três casos testados, resultaram em populações em que a grande maioria dos indivíduos não utilizou a velocidade do vento nas etapas do algoritmo. As funções de seleção representadas pelos códigos 1 e 3, resultaram em populações onde a maioria dos indivíduos necessitam da temperatura e umidade para encontrar os melhores valores segundo a função custo. Já a Função de Seleção - Código 2, resultou em indivíduos que utilizaram apenas a temperatura como entrada do modelo predictor. A Função de Seleção - Código 2 apresentou dois indivíduos que tiveram como entrada todas as variáveis climáticas.

A Tabela 6.19 apresenta um resumo de valores obtidos durante as simulações da variação dos diferentes tipos de função de seleção.

TABELA 6.19
Resumo estatístico da variação da Função de Seleção.

Função Seleção	Menor EMQ	Maior EMQ	Desvio padrão	Média dos EMQ
Código 1	2,5555	7,1275	1,3859	3,3512
Código 2	2,2660	3,3660	0,2510	2,6660
Código 3	2,3955	5,5424	0,9311	3,3074

6.2.5 Exemplo de resultados obtidos - Função de Seleção

Gerou-se a curva de previsão de demanda com os dados que obtiveram o menor valor para função objetivo (Indivíduo 3 da Tabela 6.13). Sendo eles:

- $M = 24$
- $N = 9$
- Utilizando-se das variáveis temperatura e umidade como entrada
- $ns = 141$

Pode-se visualizar na Figura 6.9 os mapas componentes gerados através dos parâmetros descritos anteriormente. Nesse caso, os mapas componentes apresentam maior disparidade entre as dimensões (valores de M e N). A diferença, inicialmente, pode passar a impressão de distorção da figura, fato que não ocorre. Pode-se notar que a população resultante, mostrada na Tabela 6.13 tem seus indivíduos com valores de M e N não próximos.

Visualiza-se na Figura 6.10 o comportamento previsto para a demanda, curva em preto, além da demanda real, curva em verde. Na mesma figura é mostrada a demanda contrata (curva em vermelho) e as ns curvas de previsão de demanda (curvas em azul). A curva em preto é resultado da média ns previsões.

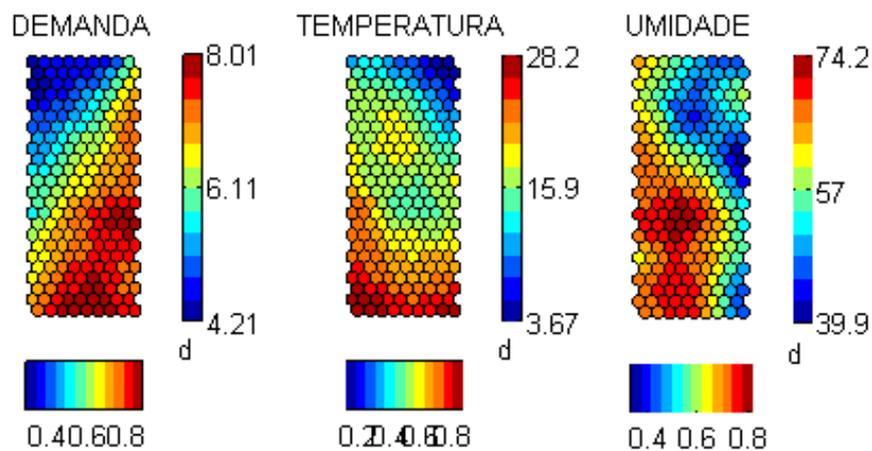


FIGURA 6.9 – Mapas componentes obtidos com o melhor indivíduo das simulações de variação da função de seleção.

Ainda, observando-se a Figura 6.10 fica explícita a proximidade entre a demanda prevista e a demanda real, sobretudo nas horas mais próximas ao início da previsão. Sendo o previsor atualizado a cada hora, sua previsão mostra-se confiável e eficaz.

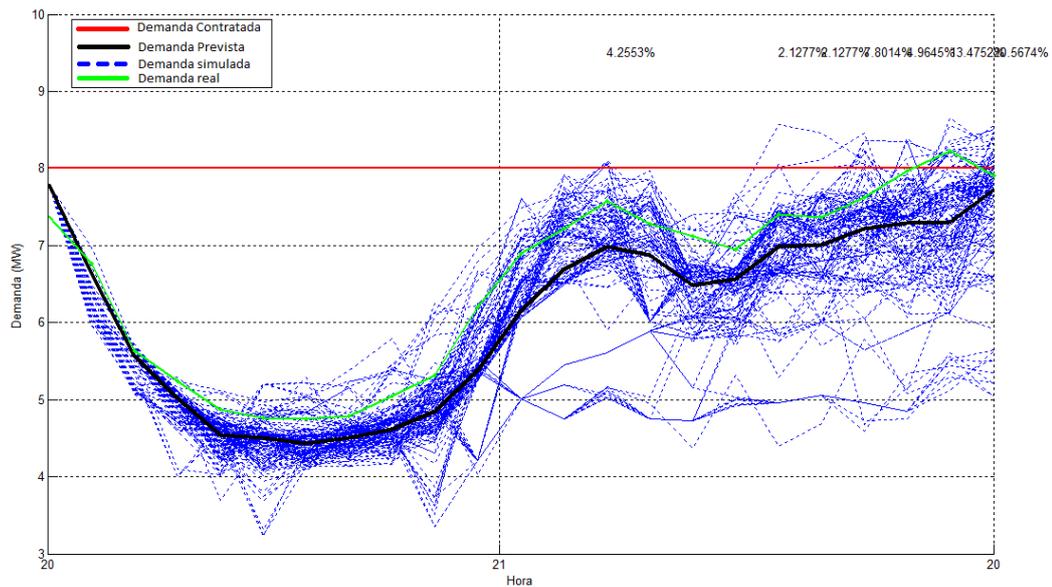


FIGURA 6.10 – Comparação entre a curva de demanda prevista e a real com os parâmetros do melhor indivíduo ao variar-se a função de seleção.

Cabe comentar sobre importância da previsão seguir a tendência da demanda real, ou seja, se a demanda real tende a aumentar, a curva prevista deve seguir esse comportamento. O mesmo deve acontecer quando a demanda real tende a diminuir. O comportamento relatado acontece na grande maioria do horizonte de previsão (24 horas à frente), sendo apenas no último intervalo de tempo a previsão não acompanha a tendência da demanda real.

6.3 Variação da Função de Recombinação

Foram realizadas diversas simulações sendo em todas o critério número máximo de gerações atingido. Os resultados de uma das simulações são apresentados a seguir.

Variou-se o tipo da função responsável pela recombinação dos indivíduos. Os tipos de Função de Recombinação são mostrados na Tabela 6.2. Os demais parâmetros foram mantidos iguais aos mostrados na Tabela 6.20.

TABELA 6.20
Parâmetros estáticos durante a variação do tipo de Função Recombinação.

Indivíduos de elite:	2
Tamanho da população:	10
Número máximo de gerações:	10
Tempo máximo de execução:	3600 segundos
código da Função Seleção:	1
Código da Função Mutação:	1

6.3.1 Função de Recombinação - Código 1

Obteve-se como população final os dados apresentados na Tabela 6.21.

TABELA 6.21
População final considerando Função de Recombinação - Código 1.

Indivíduo	M	N	t	u	v	ns	EMQ
1	20	16	1	0	0	93	2,2336
2	9	25	1	1	0	93	2,8626
3	20	22	1	0	0	93	3,3422
4	24	22	1	0	0	93	5,3755
5	20	16	1	0	0	93	2,4003
6	9	25	1	1	0	93	2,5786
7	20	10	1	0	0	93	2,7206
8	20	16	1	0	0	93	2,5170
9	22	9	1	0	0	93	3,4508
10	8	17	1	1	1	93	6,4035

A Tabela 6.22 mostra alguns dados estatísticos obtidos na simulação.

TABELA 6.22
Estatísticas para a Função Recombinação - Código 1.

Descrição	Valor
EMQ mínimo	2,2336
EMQ máximo	6,4035
Médio dos erros	3,3885
Desvio padrão	1,3941

A Figura 6.11 traz a comparação entre o melhor indivíduo e a média dos EMQ, curvas azul e vermelha, respectivamente. Também, são traçados os limites do desvio padrão da população, delimitados pelas linhas em verde.

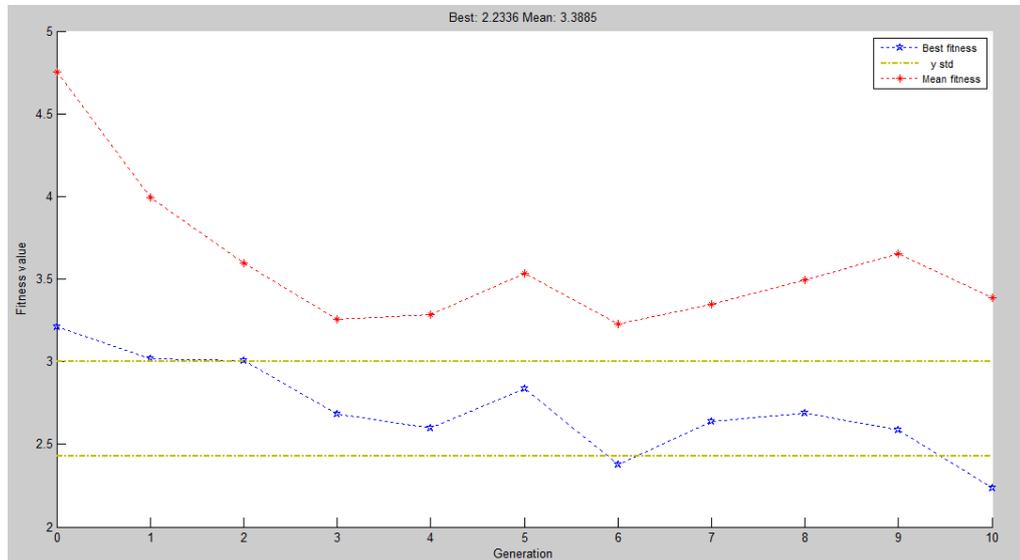


FIGURA 6.11 – Comparação entre o melhor indivíduo e a média, segundo a função objetivo, em cada geração e o desvio padrão do EMQ, utilizando-se a Função de Recombinação - Código 1.

6.3.2 Função de Recombinação - Código 2

Variou-se a função de recombinação para a representada pelo código 2. A população final, após 10 gerações é apresentada na Tabela 6.23.

TABELA 6.23
População final considerando Função de Recombinação - Código 2.

Indivíduo	M	N	t	u	v	ns	EMQ
1	22	25	1	1	1	173	2,5876
2	22	25	1	0	0	173	2,6220
3	22	25	1	1	0	173	2,6051
4	21	25	1	0	0	173	3,5787
5	21	25	1	0	0	173	3,4870
6	22	25	1	0	0	173	2,7191
7	22	25	1	0	0	173	2,8760
8	22	25	1	1	0	173	6,3592
9	21	21	1	1	1	173	4,0742
10	22	25	1	0	0	173	2,9697

A Tabela 6.24 mostra alguns dados estatísticos referentes a população final obtida.

TABELA 6.24
Estatísticas para a Função Recombinação - Código 2.

Descrição	Valor
EMQ mínimo	2,5867
EMQ máximo	6,3592
Médio dos erros	3,3878
Desvio padrão	1,5181

Na Figura 6.12 são mostradas a evolução do melhor indivíduo, curva em azul, e a média dos EMQ, curva em vermelho, ao longo de 10 gerações. A curva em verde mostra os limites do desvio padrão calculado.

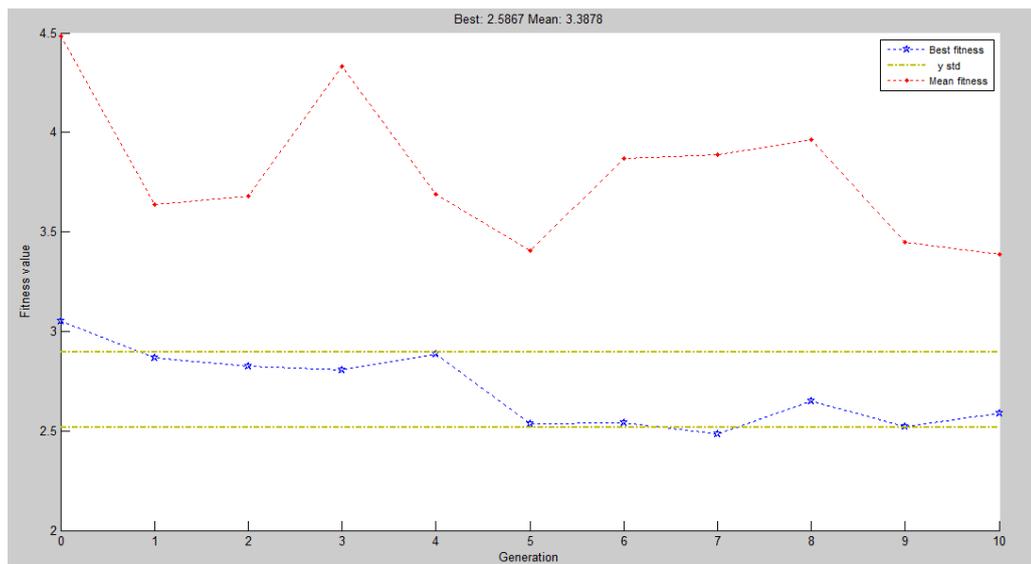


FIGURA 6.12 – Comparação entre o melhor indivíduo e a média, segundo a função objetivo, em cada geração e o desvio padrão do EMQ, utilizando-se a Função de Recombinação - Código 2.

6.3.3 Função de Recombinação - Código 3

Obteve-se como população final os dados apresentados na Tabela 6.25, quando a Função de Recombinação - Código 3 foi utilizada.

TABELA 6.25
População final considerando Função de Recombinação - Código 3.

Indivíduo	M	N	t	u	v	ns	EMQ
1	17	14	1	1	0	80	2,6134
2	15	14	1	1	0	96	2,8943
3	15	14	0	1	0	96	6,0022
4	15	14	1	1	0	96	3,2886
5	17	14	1	1	0	80	2,6734
6	15	14	1	1	0	96	2,7563
7	15	14	1	1	0	96	3,3002
8	15	14	0	1	0	96	5,6124
9	17	14	0	0	0	80	3,8709
10	15	14	1	1	0	96	3,2710

A Tabela 6.26 mostra alguns dados estatísticos obtidos empregando a Função de Recombinação - Código 3.

TABELA 6.26
Estatísticas para a Função Recombinação - Código 3.

Descrição	Valor
EMQ mínimo	2,6134
EMQ máximo	6,0022
Médio dos erros	3,6283
Desvio padrão	1,2121

Visualiza-se na Figura 6.13 o desvio padrão dos EMQ, curva em verde, bem como o menor valor e a média do EQM, em cada geração, curva em azul e vermelho, respectivamente.

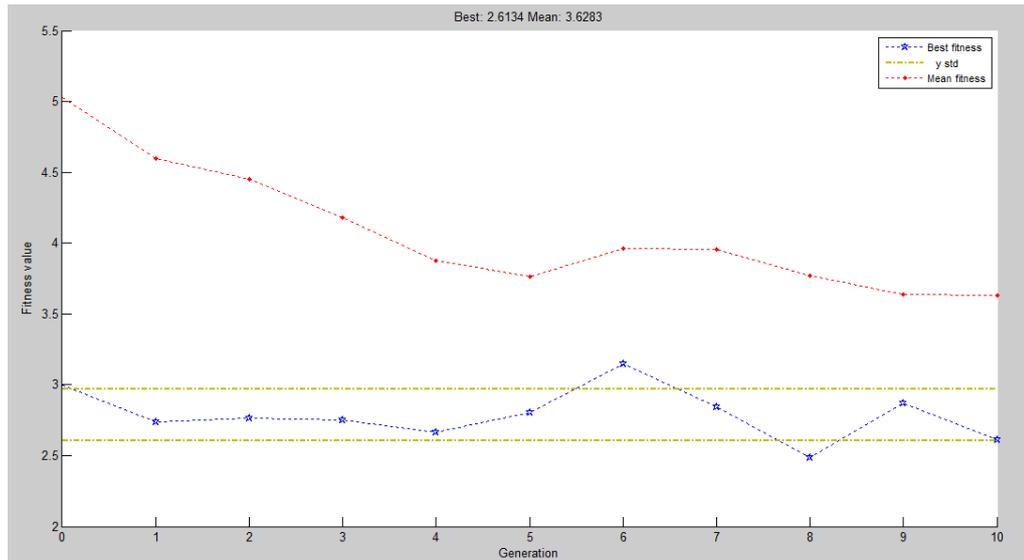


FIGURA 6.13 – Comparação entre o melhor indivíduo e a média, segundo a função objetivo, em cada geração e o desvio padrão do EMQ, utilizando-se a Função de Recombinação - Código 3.

6.3.4 Exemplo de resultados obtidos - Função de Recombinação

O menor e o maior valor para a função objetivo encontrados foram gerados quando a Função Recombinação - Código 1 foi adotada. Porém, observa-se que houve uma pequena variação tanto para o menor como para o maior EMQ quando usada diferentes tipos de função recombinação.

Quando o quesito observado é a evolução da população, a Função de Recombinação - Código 3 mostrou melhor desempenho. Graficamente, chega-se a essa conclusão através da análise da curva em vermelho, a qual representa a média dos EMQ, na Figura 6.13. A curva citada apresenta comportamento decrescente, mostrando que os indivíduos da população estão evoluindo.

Também, a Função de Recombinação - Código 3 foi a que obteve o menor desvio padrão nas respostas, ou seja, apresentou uma população final mais homogênea quando comparada as outras funções recombinação testadas.

A maioria dos indivíduos da população final, quando utilizadas as Funções de Recombinação - Códigos 1 e 2, apresentam os genes referentes a umidade e a velocidade do vento iguais a zero. Desta forma, percebe-se que o algoritmo não as utilizou em suas etapas, resultando em indivíduos evoluídos sem a necessidade das entradas mencionadas. No caso do emprego da Função de Recombinação - Código 2, o gene referente a velocidade do vento também manteve-se em zero na maioria dos indivíduos. Já o gene representativo da umidade foi utilizado em praticamente todos os indivíduos da população.

A Tabela 6.27 apresenta um resumo de valores obtidos durante as simulações da variação dos diferentes tipos de função de recombinação.

TABELA 6.27
Resumo estatístico da variação da Função de Recombinação.

Função Recombinação	Menor EMQ	Maior EMQ	Desvio padrão	Média dos EMQ
Código 1	2,2336	6,4035	1,3941	3,3885
Código 2	2,5867	6,3592	1,5181	3,3878
Código 3	2,6134	6,0022	1,2121	3,6283

6.3.5 Exemplo de resultados obtidos - Função Recombinação

Gerou-se a curva de previsão de demanda com os dados que obtiveram o menor valor para função objetivo (Indivíduo 1 da Tabela 6.21). Sendo eles:

- $M = 20$
- $N = 16$
- Utilizando-se apenas a variável temperatura
- $ns = 93$

A Figura 6.14 mostra os mapas componentes da demanda e da temperatura. Foram obtidos através dos parâmetros do melhor indivíduo quando variou-se a função responsável pela recombinação, permitem algumas análises.

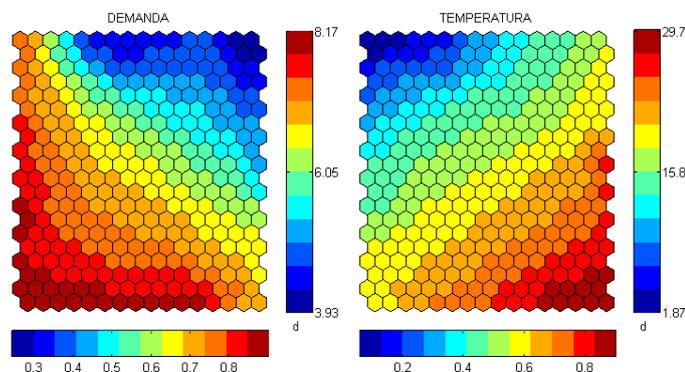


FIGURA 6.14 – Mapas componentes obtidos com o melhor indivíduo das simulações de variação da função de recombinação.

Na Figura 6.15 observam-se as curvas de demanda prevista (em preto) e a curva de demanda real (em verde). Também, é mostrada a demanda contratada, em vermelho, e a ns curvas de demanda simuladas. A curva em preto é resultado da média das ns simulações.

Mais uma vez, os modelo predictor calculou valores próximos a demanda real, evidenciado pela proximidade entre as curvas em preto e verde. A medida que aumenta-se o instante de previsão, ao longo do horizonte de projeção, o sistema mostra um aumento na diferença entre as curvas de prevista e a real. Sendo o predictor horário, o principal foco deve ser as primeiras horas do horizonte de projeção, já que uma nova curva de demanda prevista é gerada em intervalos horários.

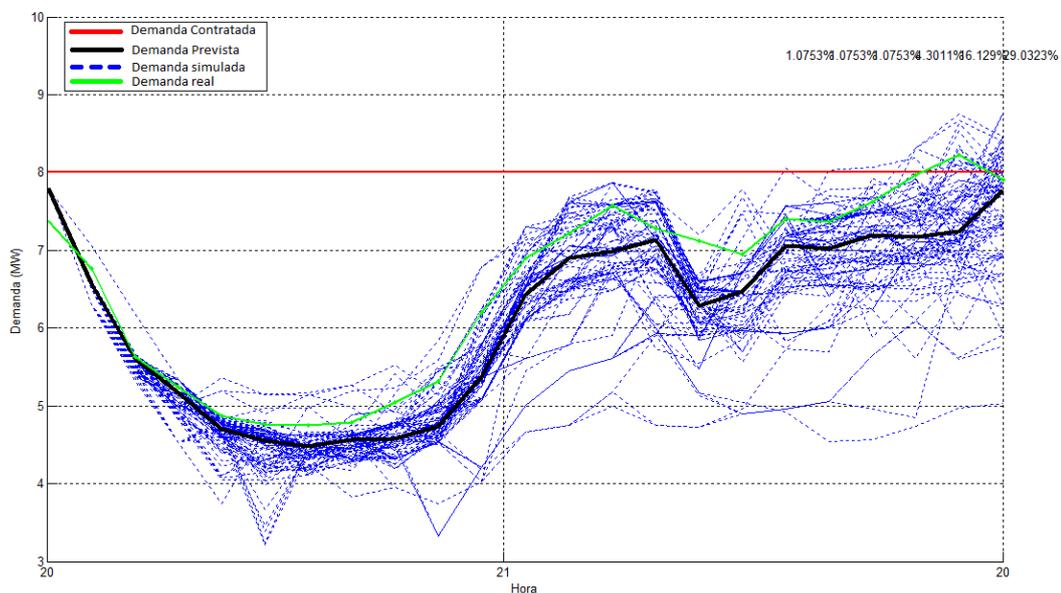


FIGURA 6.15 – Comparação entre a curva de demanda prevista e a real com os parâmetros do melhor indivíduo ao variar-se a função de recombinação.

6.4 Análise sobre processo estocástico

Para comprovação que o predictor considera processos estocásticos realizou-se simulações considerando as mesmas variáveis de entrada e plotou-se as curvas geradas pelo predictor. Sendo o processo estocástico é possível de ser gerado diferentes valores a cada iteração, onde pequenas variações em cada iteração podem ser toleradas sem interferir na confiabilidade e robustez no modelo predictor.

6.4.1 Estocasticidade - Exemplo 1

Gerou-se dez curvas de previsão de demanda considerando os mesmos parâmetros de entrada, sendo eles:

- $M = 15$
- $N = 15$
- Utilizou-se as três variáveis climáticas nas etapas do algoritmo
- $ns = 100$

A Figura 6.16 apresenta as curvas de previsão de demanda geradas com os parâmetros mencionados acima. Nessa figura, é possível observar que utilizando os mesmos parâmetros de entrada obteve-se diferentes curvas de previsão de demanda. Nos primeiros intervalos de previsão as curvas são praticamente iguais. Também, a medida que transcorreu o tempo a diferença entre as curvas aumentou.

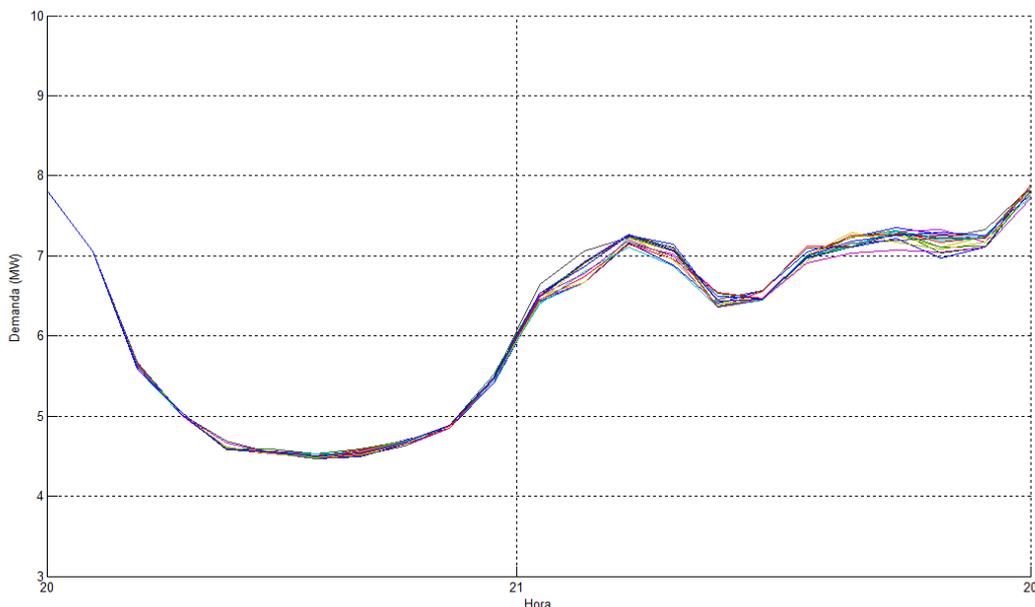


FIGURA 6.16 – Curvas de demanda geradas com os mesmos parâmetros de entrada - Teste 1.

6.4.2 Estocasticidade - Exemplo 2

O segundo exemplo apresentado é semelhante ao primeiro, porém, variou-se as dimensões dos mapas auto-organizáveis e utilizou-se apenas uma das variáveis como entrada do modelo predictor. Também, foram realizadas 10 iterações, com os parâmetros a seguir:

- $M = 20$
- $N = 20$
- Utilizou-se apenas a variável temperatura
- $ns = 100$

As curvas de previsão de demanda geradas são mostradas na Figura 6.17. No segundo exemplo, observa-se maior variação entre as curvas geradas inclusive nos primeiros intervalos de previsão.

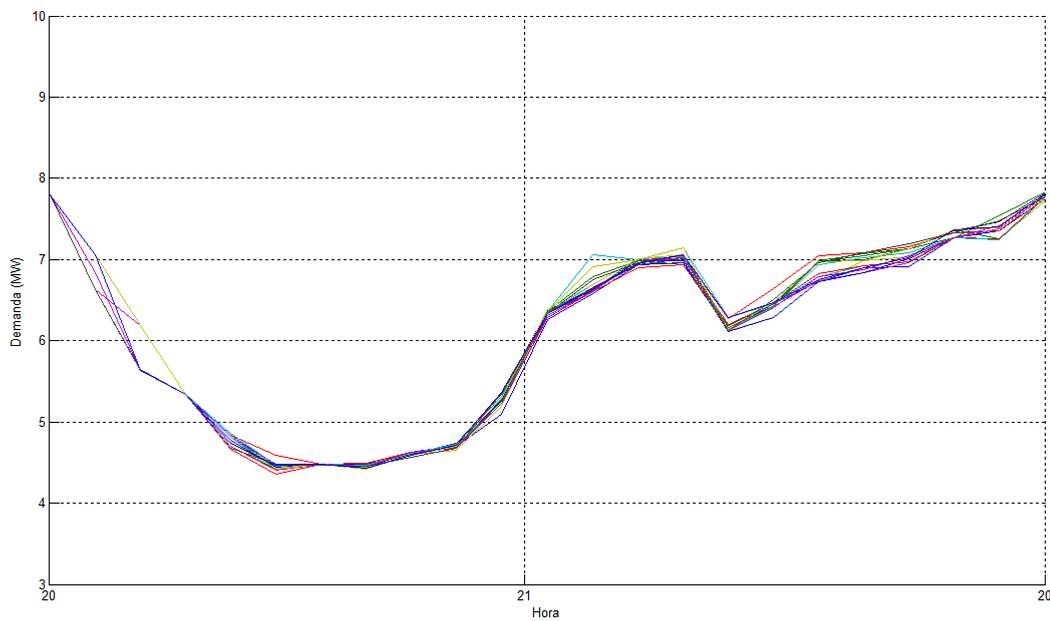


FIGURA 6.17 – Curvas de demanda geradas com os mesmos parâmetros de entrada - Teste 2.

7 CONCLUSÕES E TRABALHOS FUTUROS

7.1 Conclusões

7.1.1 Sobre as variáveis climáticas

Os relatos bibliográficos consultados apresentaram relevante influência das variáveis temperatura, umidade e velocidade do vento, no comportamento da demanda de energia elétrica, considerando-se consumidores residenciais. Porém, os sistemas em questão eram de médio e grande porte, diferentemente do cenário estudado e relatado nesse documento.

Após a aplicação da metodologia descrita nesse trabalho, obteve-se populações com a maioria dos indivíduos não utilizando a velocidade do vento como variável de entrada. Desta forma, pode-se concluir que sua utilização no modelo proposto não trás benefícios significativos. Assim, pode-se dispensar sua utilização nas etapas do algoritmo.

A variável umidade mostrou dois comportamentos distintos. No primeiro, em todos os casos que variou-se o número de indivíduos da população e, também, quando adotou-se as Funções de Seleção - Códigos 1 e 2, e a Função de Recombinação - Código 3, a maioria dos indivíduos resultantes na população utilizou a variável em questão. Já o segundo comportamento observado ocorreu quando empregou-se a Função de Seleção - Código 2 e as Funções de Recombinação - Códigos 1 e 2, resultando em populações onde a maioria dos indivíduos não utilizou a variável umidade.

Por fim, a variável temperatura mostrou-se a de maior relevância para o modelo de previsão de demanda proposto, sendo visualizada na grande maioria dos indivíduos das populações e, em alguns casos, em sua totalidade.

Com isso, pode-se eleger uma escala de prioridades das variáveis estudadas, segundo a influência das mesmas na demanda de energia elétrica, tendo como horizonte de projeção o curtíssimo prazo, sendo ela apresentadas em ordem decrescentes de prioridade:

- A temperatura: deve ser priorizada devido a grande influência na demanda.
- A umidade: tem influência na demanda, porém em menor proporção que a temperatura.
- A velocidade do vento: mostrou-se desnecessária quando considerado o cenário apresentado nesse trabalho.

7.1.2 Sobre as técnicas utilizadas

Mostrou-se possível a construção de um modelo preditor de demanda de energia elétrica híbrido-adaptativo, tendo o curtíssimo prazo como horizonte de projeção, através de técnicas de inteligência artificial.

As RNA, representadas pelos mapas auto-organizáveis, permitiram a discretização dos dados históricos de demanda e das variáveis climáticas. Além disso, através da análise dos mapas componentes pode-se fazer inferências e análise do comportamento das variáveis. Porém, deve-se ter cautela e cuidado no momento de determinar as dimensões dos mapas ou o espaço de busca das variáveis correspondentes às dimensões. É importante determinar-se uma proporção entre o número de amostras históricas e de neurônio que se deseja para evitar neurônios vazios ou mapas que não revelam relações entre as variáveis.

As Cadeias de Markov permitiram a elaboração de uma matriz de probabilidades, contendo as taxas de transição de um neurônio para outro. Assim, através da leitura das variáveis de entrada faz-se a previsão de 24 horas a frente.

Os algoritmos genéticos foram determinantes no momento de analisar as variáveis e seus comportamentos. Também, permitiram qualificar e quantificar a influência das variáveis climáticas e testar algumas combinações de parâmetros. Devido ao processo ser estocástico as respostas não convergem em um único valor. Contudo, pode-se visualizar uma faixa de tolerância onde os melhores indivíduos de cada geração estarão.

Com isso, apresentou-se viável a integração das técnicas citadas acima, permitindo a construção de um modelo preditor híbrido-adaptativo.

7.1.3 Sobre o modelo preditor

Entre os desafios de empresas do setor elétrico está a construção de modelos capazes de realizar a previsão de demanda de maneira confiável e eficaz. Tais modelos são fundamentais para o planejamento e operação do SEP.

Apresentou-se um modelo capaz de adaptar-se a diferentes cenários, elegendo as entradas que geram melhores resultados. Assim, é possível de maneira relativamente simples, determinar e comprovar, numericamente e graficamente, a relação das variáveis.

Nesse processo um ponto que exige atenção é a consolidação e integridade da base de dados para evitar problemas durante a execução do processo.

Com isso, o modelo previsor de demanda de energia elétrica, considerando o curtíssimo prazo, apresentado, pode servir de auxílio na tomada de decisões bem como na identificação de situações de risco de operação.

7.2 Trabalhos futuros

Sugere-se como trabalhos futuros a implementação do modelo previsor, apresentado nesse trabalho, em diferentes topologias e portes de sistemas, comparando-o com outros modelos previsores existentes. Também, espera-se analisar e incluir no modelo outras variáveis, climáticas, econômicas, classe dos consumidores (residenciais e industriais) e a classificação entre dias úteis e não-úteis.

BIBLIOGRAFIA

- ANTON, H.; BUSBAY, R. C. *Álgebra Linear Contemporânea*. [S.l.]: John Wiley & Sons. Inc., 2003.
- BORDIN, G. et al. Projeção de demanda de energia elétrica a curtíssimo prazo considerando o índice de desconforto. *Simpósio Brasileiro de Sistemas Elétricos*, 2010.
- CAMPOS, R. J. *Previsão de séries temporais com aplicações a séries de consumo de energia elétrica*. Dissertação (mestrado) — Universidade Federal de Minas Gerais — UFMG, Belo Horizonte - MG, Abril 2008.
- CASTRO, J. P. *Um algoritmo evolucionário para geração de planos de rotas*. Dissertação (Mestrado) — Universidade Federal de Santa Catarina — UFSC, Florianópolis - SC, 1999.
- CASTRO, L. N. de; ZUBEN, F. J. V. From biologically inspired computing to natural computing. *Recent Developments in Biologically Inspired Computing*, 2004.
- CATARINA, A. S. Algoritmos evolutivos aplicados ao processo de análise de dados geográficos. *Instituto de Nacional de Pesquisas Espaciais - IMPE*, 2005.
- DARWIN, C. *The Origin of Species*. [S.l.]: Republished 2007 by Forgotten Books, 1872.
- HAYKIN, S. *Redes Neurais - Princípios e Prática*. [S.l.]: Artmed Editora S.A., 1999.
- HERTZ, J.; KROGH, A.; PALMER, R. G. *Introduction to the theory of neural computation*. Boston, MA, USA: Addison-Wesley Longman Publishing Co., Inc., 1991.
- HOLLAND, J. H. *Adaptation in Natural and Artificial System*. re-issued by mit press(1992). [S.l.: s.n.], 1975.
- KOHONEN. *Engineering Applications of the SOM*. [S.l.: s.n.], 1996.
- LEITE, F. E. A. *Aplicação de redes neurais artificiais na previsão de curto prazo na carga nodal de sistemas de energia elétrica*. Dissertação (mestrado) — Universidade Estadual de Campinas, Campinas, SP, Maio 1997.
- LEONE FILHO, M. A. *Previsão de carga de curto prazo usando ensembles de previsores selecionados e evoluídos por algoritmos genéticos*. Dissertação (mestrado) — Universidade Estadual de Campinas - UNICAMP, Campinas, SP, Janeiro 2006.
- LIMA, W. da S. *Previsão de carga no período de demanda de ponta utilizando redes neurais artificiais*. Dissertação (mestrado) — Universidade Estadual de Campinas - UNICAMP, Campinas, SP, Junho 1996.
- LOESCH, C. *Redes Neurais Artificiais, Fundamentos e Modelos*. [S.l.]: Editora da FURB, 1996.

MITCHELL, M. *An Introduction to Genetic Algorithm*. [S.l.]: A Bradford Book The MIT Press, 1999.

PARDOUXS, E. *Markov Processes and Applications: Algorithms, Networks, Genome and Finance*. [S.l.]: John Wiley & Sons, 2008.

REZENDE, S. O. *Sistemas Inteligentes: Fundamentos e Aplicações*. [S.l.]: Manole Ltda., 2005.

SILVA, C. V. M. et al. Variáveis climáticas aplicadas à previsão de demanda em curtíssimo prazo. *Internacional Congress on Electricity Distribution - CIDEL*, 2010.

SILVA, C. V. M. et al. Elaboração de um modelo probabilístico previsor de demanda de energia elétrica utilizando cadeias de markov e mapas auto-organizáveis. *Congresso Regional de Iniciação Científica e Tecnologias em Engenharia - CRICTE*, 2010.

SILVA, C. V. M. et al. Metodologia para previsão de demanda de energia elétrica em curtíssimo prazo baseada em um modelo probabilístico discreto. *I Congresso de Iniciação Científica e Pós-graduação - Sul Brasil - CICPG*, 2010.

SPERANDIO, M. *Classificação de conjuntos consumidores de energia elétrica via mapas auto-organizáveis e estatística multivariada*. Dissertação (mestrado) — Universidade Federal de Santa Catarina - UFSC, Florianópolis, SC, Março 2004.

SPERANDIO, M.; GARCIA, V. J.; BERNARDON, D. P. Building forecasting markov models with self-organizing maps. *45th International University's Engineering Conference — UPEC*, 2010.

SPERANDIO, M. et al. Construção de um modelo probabilístico para previsão de demanda a partir de mapas auto-organizáveis. *XVIII Congresso Brasileiro de Automática — CBA*, 2010.