

UNIVERSIDADE FEDERAL DE SÃO JOÃO DEL-REI
PRÓ-REITORIA DE PESQUISA



CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DE
MINAS GERAIS
DIRETORIA DE PESQUISA E PÓS-GRADUAÇÃO



PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA - PPGELE

PREVISÃO DE CONSUMO ENERGÉTICO E DA CURVA DE DEMANDA DE UM EDIFÍCIO PÚBLICO UTILIZANDO FERRAMENTAS DE INTELIGÊNCIA COMPUTACIONAL

Aluno: Leandro Cristiano Gomes

Orientador: Profa. Dra. Patrícia Romeiro da Silva Jota

Belo Horizonte, setembro de 2017

UNIVERSIDADE FEDERAL DE SÃO JOÃO DEL-REI
PRÓ-REITORIA DE PESQUISA



CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DE
MINAS GERAIS
DIRETORIA DE PESQUISA E PÓS-GRADUAÇÃO



PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA - PPGEL

PREVISÃO DE CONSUMO ENERGÉTICO E DA CURVA DE DEMANDA DE UM EDIFÍCIO PÚBLICO UTILIZANDO FERRAMENTAS DE INTELIGÊNCIA COMPUTACIONAL

por

Leandro Cristiano Gomes

Dissertação de Mestrado submetida à Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em Engenharia Elétrica do Centro Federal de Educação Tecnológica de Minas Gerais, como requisito parcial para obtenção de título de Mestre em Engenharia Elétrica.

Orientador: Profa. Dra. Patrícia Romeiro da Silva Jota

Belo Horizonte, setembro de 2017.


“PREVISÃO DE CONSUMO ENERGÉTICO E DA CURVA DE
DEMANDA DE UM EDIFÍCIO PÚBLICO UTILIZANDO
FERRAMENTAS DE INTELIGÊNCIA COMPUTACIONAL ”

Leandro Cristiano Gomes


Texto da Dissertação de Mestrado submetido à Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em Engenharia Elétrica do Centro Federal de Educação Tecnológica de Minas Gerais, como requisito parcial para obtenção de título de Mestre em Engenharia Elétrica.

Aprovada em 01 de setembro de 2017.


Por:



Prof.ª Dr.ª Patricia Romeiro da Silva (Orientadora)
Centro Federal de Educação Tecnológica de Minas Gerais



Prof. Dr. Eduardo Gonzaga da Silveira
Centro Federal de Educação Tecnológica de Minas Gerais



Prof. Dr. Maury Meirelles Gouvêa Júnior
Pontifícia Universidade Católica de Minas Gerais

AGRADECIMENTOS

Primeiramente agradeço a Deus, pois sem a vontade dele, não teria chegado até aqui. A minha esposa, pela compreensão nos momentos de estudo e dedicação a este trabalho.

Ao meu recém-chegado filho Ângelo, dedico a conclusão deste trabalho.

Aos meus pais pelo incentivo, honestidade, respeito e base de vida que me deram.

Aos meus irmãos também pelo incentivo, em especial ao Leonardo, que me ajudou nas horas mais difíceis.

A professora Patrícia Jota, pela paciência, apoio e ajuda na realização deste trabalho e também pelo exemplo de profissional que é, me inspirando na vida de docente que iniciei na conclusão deste trabalho.

Agradeço ao projeto CMUF - Centro de Monitoramento de Usos Finais, cujo coordenador geral, Prof. Fábio Gonçalves Jota (UFMG), permitiu o acesso e uso dos dados coletados durante a execução do projeto, financiado pela FINEP e CEMIG.

Ao Ademir e Rodrigo Borsali da empresa ABEC Engenharia, que apostaram em mim como profissional e incentivo no início dos estudos do Mestrado.

Agradeço ao CEFET-MG, pela oportunidade que me deram em estudar nesta instituição no Ensino Técnico e agora na Pós-Graduação, pelo conhecimento transmitido pelos professores e disponibilidade das instalações de sala de aula e laboratórios.

Agradeço a CAPES pelo financiamento para participar dos congressos e palestras, para divulgar as pesquisas realizadas durante este trabalho.

Aos colegas do CPEI (Centro de Pesquisa em Energia Inteligente) pela ajuda e companheirismo ao longo do curso.

Agradeço a todos que de forma direta e indiretamente contribuíram para realização deste trabalho!

“Disse então ao homem: No temor do Senhor está a sabedoria, e evitar o mal é ter entedimento. ”

RESUMO

Recentemente, no setor elétrico tem ocorrido desenvolvimentos tecnológicos que contribuem para a sua modernização, segurança e qualidade. A automação, coleta de dados e seu processamento em todo o sistema, desde a geração, transmissão e distribuição de energia, vem sendo trabalhada dentro do conceito de *Smart Grid*, onde há o surgimento de novos equipamentos, para a proteção, controle e medição de energia. Medidores inteligentes estão sendo desenvolvidos para atender esse novo conceito de distribuição de energia, não medindo apenas a energia fornecida pelas concessionárias para o consumidor, mas também aquela gerada pelo consumidor e fornecida ao sistema admitindo a existência de um fluxo bidirecional de energia. A quantidade de dados gerados por estes medidores e armazenados em banco de dados aumentará consideravelmente após a instalação em escala. Estes dados contêm informações relevantes que, mesmo já sendo armazenados, ainda não são processados, por falta de estudos e pesquisas nessa área. Este trabalho propõe uma metodologia para processamento de dados, utilizando ferramentas de inteligência computacional, com o objetivo de extrair informações relevantes para o desenvolvimento de novos serviços para consumidores e geradores de energia. Apresenta-se uma metodologia para a estimação do consumo energético e da curva de demanda de um edifício público, visando auxiliar o consumidor, a concessionária e o setor energético no nível de planejamento e tomadas de decisões futuras. Para exemplificar e validar a metodologia proposta, foram utilizadas as ferramentas de inteligência computacionais aplicadas em um estudo de caso, sendo demonstradas suas características, configurações e comparações entre desempenhos dos diferentes algoritmos utilizados, destacando-se o uso da lógica *Fuzzy* e das Redes Neurais Artificiais. Resultados promissores foram conseguidos com a metodologia descrita, demonstrando a eficiência dos métodos e dos algoritmos apresentados neste trabalho e também servindo como base para futuros estudos nessa área de estimação de energia utilizada pelos diferentes tipos de consumidores.

Palavras-chave: Processamento de Dados, Inteligência Computacional, Estimação de Consumo.

ABSTRACT

Lately, in the electrical sector there have been technological developments that contribute to its modernization, safety and quality. All of the automation, data collection and processing throughout the system, from the generation, transmission and energy distribution, has been worked within the concept of Smart Grid, in which there is the emergence of new equipment, for protection, control and measurement power. Smart Metering is being developed to fulfill this new concept of energy distribution, not only measuring the energy supplied by utilities to the consumer, but also that generated by the consumer and supplied to the system assuming a bidirectional flow of energy. The number of data reproduced by these meters and stored in the database will increase considerably after the scale installation. These data contain relevant information that, even though they are already stocked, are still not processed, due to lack of studies and research in this area. This work proposes a methodology for the data processing, using computational intelligence tools, in order to extract relevant information for the development of new services for consumers and power generators. It presents a methodology for evaluation the energy consumption and the demand curve of a public building, aiming to assist the consumer, the concessionaire and the energy sector in the level of planning and future decisions. To exemplify and validate the proposed methodology, the computational intelligence tools were used in a Case Study. The Fuzzy Logic and the Artificial Neural Networks are also described in this work, showing their characteristics, configurations and comparisons between performances of the different algorithms used. Promising results were achieved with the methodology described, proving the efficiency of the methods and algorithms presented in this work and also serving as a basis for future studies in this area of energy mensuration used by different types of consumers.

Keywords: Data Processing, Computational Intelligence, Consumption Estimate

LISTA DE FIGURAS

Figura 1 – Associação do modelo à Série Temporal [11]	5
Figura 2 – Exemplo de uma série de dados em função do tempo [13]	6
Figura 3 – Padrões de Séries Temporais [6]	7
Figura 4 – Sistema Dinâmico [12]	8
Figura 5 – Distribuição do conjunto de dados, identificação dos pontos de vizinhança próxima	16
Figura 6 – Função de Pertinência	18
Figura 7 – Operações entre conjuntos fuzzy	19
Figura 8 – Classificação dos conjuntos ou variável linguística no universo de temperatura [43]	20
Figura 9 – Definição tridimensional de um conjunto fuzzy [41]	21
Figura 10 – Sistema Lógico Fuzzy [43]	21
Figura 11 – Regra e Inferência Fuzzy [40]	23
Figura 12 – Dados para análise do Fuzzy c-Means, Clusterização pelo algoritmo Fuzzy C-Means	26
Figura 13 – Neurônio Biológico [52]	27
Figura 14 - Neurônio Artificial [51]	27
Figura 15 - Função de limiar estrito, Função degrau [53]	28
Figura 16 - Função linear com saturação, Sem saturação da saída.....	28
Figura 17 – Função sigmoidal unipolares, Sigmoidal bipolar.....	29
Figura 18 – Rede alimentada adiante com camada única, rede alimentada diretamente com múltiplas camadas, redes recorrentes [49]	29
Figura 19 – Rede Back-Propagation [49]	31
Figura 20 – Posição dos neurônios, distância entre os neurônios	35
Figura 21 – Distribuição de dados por neurônio	35
Figura 22 – Fluxograma da metodologia	37
Figura 23 – Esboço de curva de carga típica de uma edificação comercial	39
Figura 24 – Análise de uma curva de carga	39
Figura 25 – Dados que podem influenciar na estimacão de energia	41
Figura 26 – Correlação entre energia e temperatura	43
Figura 27 – Vista do edifício	46
Figura 28 – Curva de consumo energético típico do edifício analisado	47
Figura 29 – Relação entre a temperatura (faixa de 12h) com a energia consumida.....	49
Figura 30 – Agrupamento pelo algoritmo SOM através do Matlab	51

Figura 31 – Grupos de classificação da curva de carga normalizada.....	52
Figura 32 – Consumo médio por hora de um dia [62]	53
Figura 33 – Curva média típica [62]	54
Figura 34 – Agrupamento pelo algoritmo KNN.....	55
Figura 35 – Mapeamento utilizando na lógica Fuzzy	57
Figura 36 – Mapeamento da Inferência dos conjuntos Fuzzy	58
Figura 37 – Conjuntos das partições Fuzzy	59
Figura 38 – Conjuntos de respostas Fuzzy	59
Figura 39 – Regras Fuzzy através do Matlab.....	60
Figura 40 – Eliminação de alguns conjuntos Fuzzy	61
Figura 41 – Arquitetura da RNA através do Matlab.....	63
Figura 42 – Estimação dos dias 6 de Abril e 11 de Maio (Outono).....	65
Figura 43 – Estimação dos dias 3 de Julho e 4 de Setembro (Inverno)	65
Figura 44 – Estimação dos dias 23 de Setembro e 9 de Novembro (Primavera)	65
Figura 45 – Estimação dos dias 15 de Fevereiro e 7 de Março (Verão).....	66
Figura 46 – Boxplot de erros MAPE de Outono	66
Figura 47 – Boxplot de erros MAPE de Inverno	67
Figura 48 – Boxplot de erros MAPE da Primavera.....	68
Figura 49 – Boxplot de erros MAPE do Verão	69
Figura 50 – Histograma de estimação energética anual	71
Figura 51 – Histograma de estimação da demanda máxima diária.....	71

LISTA DE TABELAS

Tabela 1 - RMSE entre energia x temperatura.....	49
Tabela 2 - Mediana e Percentil 75% do Boxplot de Outono.	67
Tabela 3 - Mediana e Percentil 75% do Boxplot de Inverno.....	68
Tabela 4 – Mediana e Percentil 75% do Boxplot da Primavera.....	69
Tabela 5 - Mediana e Percentil 75% do Boxplot do Verão	70
Tabela 6 - Mediana e Percentil 75% do Boxplot Anual.....	70

LISTAS DE ABREVIATURAS E SIGLAS

SEP	Sistema Elétrico de Potência
TI	Tecnologia da Informação
CMUF	Centro de Monitoramento de Usos Finais
<i>KNN</i>	<i>K-Nearest Neighbor</i>
<i>FCM</i>	<i>Fuzzy C-Means</i>
RNA	Redes Neurais Artificiais
<i>SOM</i>	<i>Self Organizing Maps</i>
INMET	Instituto Nacional de Meteorologia
DER	Departamento de Estradas de Rodagem
<i>RMSE</i>	<i>Root Mean Square Error</i>
<i>MLP</i>	<i>Multi Layer Perceptron</i>
<i>MAPE</i>	<i>Mean Absolute Percentage Error</i>
4C	Quarto Critério de Classificação
ARIMAX	Autoregressivo Integrado de Médias Móveis

SUMÁRIO

CAPÍTULO 1 - INTRODUÇÃO	1
1.1 Contextualização	1
1.2 Relevância do Tema em Investigação	2
1.3 Objetivos: Geral e Específicos.....	3
1.4 Organização do Texto	4
CAPÍTULO 2 – PREVISÃO DE DADOS	5
2.1 Introdução	5
2.2 Previsão de Dados no Sistema Elétrico de Potência.....	9
2.3 Previsão de Dados em Edifícios	10
2.4 Armazenamento de Dados para Previsão.....	11
2.4.1 Big Data	12
2.5 Considerações Finais do Capítulo.....	12
CAPÍTULO 3 - INTELIGÊNCIA COMPUTACIONAL	14
3.1 K-Nearest Neighbor (KNN).....	15
3.2 Lógica Fuzzy	17
3.2.1 Conjuntos Fuzzy	17
3.2.2 Sistema Base de Regras Fuzzy	21
3.3 Fuzzy C-Means (FCM).....	24
3.4 Redes Neurais Artificiais (RNA)	26
3.4.1 Neurônio Bilógico x Artificial	27
3.4.2 Arquitetura da Rede.....	29
3.4.3 Regras de Aprendizado	30
3.4.4 Treinamento da Rede	32
3.5 Mapas de Kohonen (SOM)	32
3.6 Considerações Finais do Capítulo.....	35
CAPÍTULO 4 - METODOLOGIA	36
4.1 Introdução	36
4.2 Pré-Processamento	37

4.2.1	Normalizaçãao dos Dados.....	37
4.2.2	Retirada do Stand-by.....	38
4.2.3	Correlacionar os Dados Levantados	40
4.3	Estimação da Curva de Consumo	41
4.3.1	Mapa de Kohonen (SOM)	42
4.3.2	K-Nearest Neighbor (KNN)	42
4.3.3	Lógica Fuzzy	42
4.3.4	Maior Frequência de Ocorrência	42
4.4	Estimação de Energia	43
4.4.1	Regressão Polinomial	43
4.4.2	Redes Neurais Artificiais (RNA)	44
4.4.3	Reconstrução da Curva	44
4.5	Considerações Finais do Capítulo.....	45
CAPÍTULO 5	- ESTUDO DO CASO E ANÁLISE DOS RESULTADOS.....	46
5.1	Pré-Processamento	47
5.1.1	Aplicação da Retirada da Energia em Stand-By	48
5.1.2	Aplicação da Temperatura Prevista	48
5.1.3	Correlação entre Dados.....	48
5.2	Estimação da Curva de Consumo	50
5.2.1	Aplicação do Mapa de Kohonen.....	50
5.2.2	Aplicação do K-Nearest Neighbor	54
5.2.3	Aplicação da Lógica Fuzzy	56
5.2.4	Aplicação da Maior frequência de Ocorrência.....	61
5.3	Estimação de Energia	62
5.3.1	Aplicação da Regressão Polinomial	62
5.3.2	Aplicação das Redes Neurais Artificiais	63
5.3.3	Reconstrução da Curva	64
5.4	Resultados	64
5.4.1	Período da Estação de Outono	66
5.4.2	Período da Estação de Inverno	67
5.4.3	Período da Estação de Primavera.....	68
5.4.4	Período da Estação de Verão.....	69
5.4.5	Período Anual	70
5.5	Considerações Finais do Capítulo.....	72
CAPÍTULO 6	- CONCLUSÕES E PROPOSTAS DE CONTINUIDADE	73
6.1	Conclusões	73
6.2	Propostas de Continuidade	75
6.2.1	Estimação de Consumo Energético de Forma Dinâmica.....	75
6.2.2	Estimação de Consumo Energético Utilizando o Método ARIMAX	76
REFERÊNCIAS BIBLIOGRÁFICAS	77	

APÊNDICE 1 – MÉTODO BOX & JENKINS (ARIMA E ARIMAX).....	82
APÊNDICE 2 – GRÁFICOS DO MAPEAMENTO FUZZY	89
APÊNDICE 3 – CONFIGURAÇÕES E PARAMETROS DOS ALGORITMOS	94

CAPÍTULO 1 - INTRODUÇÃO

1.1 Contextualização

Com o avanço da tecnologia no setor elétrico, novos equipamentos de medição, proteção e controle, que fazem a transdução de grandezas analógicas em dados digitais, começa a ser realidade. Esses equipamentos trazem uma perspectiva diferente quanto a modernização e automação nas redes de distribuição de energia. Não apenas a automação no setor elétrico deve ter relevância, mas com o aumento da demanda, é preciso que o setor elétrico evolua, ou seja, o processamento dos dados coletados no sistema elétrico se faz necessário. Proporcionando mais qualidade, eficiência, segurança, uso consciente e geração renovável, essa exigência por uma rede elétrica inteligente deu origem ao conceito de *Smart Grid* [1].

O conceito de *Smart Grid* pode se estender a vários segmentos da energia elétrica, desde as diferentes formas de geração distribuídas [2], como às fontes renováveis, exemplo: usina fotovoltaica, eólica, de ondas, biomassa; tanto em pequena quanto em grande escala, que são ligadas a rede, sendo pequenos sistemas de distribuição de energia, operando ora em paralelo com o sistema elétrico principal, ora de forma isolada da rede, denominadas de microrredes [3].

Incluí-se as modernizações dos equipamentos elétricos, como medidores inteligentes de energia ou *Smart Meters*, sensores, telas de supervisão, conversores de corrente contínua para alternada e a comunicação entre eles, até chegar na transmissão e distribuição da energia, com maior eficiência das linhas que integram a rede, diminuindo as distâncias entre geradores e consumidores e também as perdas de transmissão.

Garantindo assim a segurança e a qualidade da energia transmitida, com uma análise do fluxo de potência, que passa a ser considerada de forma bidirecional no contexto de redes inteligentes [4].

O valor do consumo energético é uma informação básica que os consumidores obtêm das concessionárias de distribuição, sendo convertida no valor a ser cobrado. Equipamentos mais modernos para a medição de energia, denominados de *Smart Meter*, possuem a capacidade de coletar e enviar para as concessionárias dados referentes ao fluxo de energia dos consumidores em tempo real.

A análise dos dados digitais coletados por esses *Smart Meters*, a comunicação e a informatização desenvolvida para estes equipamentos é denominada como Tecnologia da Informação e Comunicação (TI) [5].

Na área de TI, onde acontece toda a interpretação dos dados, para extrair informações detalhadas de como o sistema está operando, permitindo a construção de aplicativos de auxílio ao consumidor, obtenção de novos parâmetros de qualidade do serviço, controle de cargas e outras funcionalidades, através da informação adquirida por estes *Smart Meters*.

Dos diversos serviços que podem surgir e serem oferecidos aos consumidores comerciais, residenciais ou industriais, a estimação do consumo energético e da curva de demanda diária tem uma importante contribuição para permitir o uso mais racional da energia. O estudo sobre previsões de dados futuros está relacionado à orientação de qual tomada de decisão deverá ser estabelecida para um comportamento futuro, sendo comum no tratamento de problemas cujas decisões a serem tomadas são funções de fatos antecedentes [6].

Com dados sendo estruturados, a sua análise pode trazer informações cada vez mais concretas com o desenvolvimento da comunicação e do envio das informações. Com equipamentos que assegurem este tráfego de dados sem a interferência de possíveis invasores do sistema tecnológico, ou *hackers*, obtém-se uma maior confiabilidade dos dados. Assim, serviços como o de previsões da demanda elétrica podem ser desenvolvidos com um erro mínimo, auxiliando os consumidores e as concessionárias, melhorando a segurança do sistema elétrico, reduzindo os custos da geração e distribuição e incentivando o investimento de estudos e pesquisas nesta área.

1.2 Relevância do Tema em Investigação

A eficiência nas medições e previsões de consumo energético devem influenciar gerentes ou responsáveis de outras edificações e também consumidores comerciais e industriais a seguir o mesmo passo de analisar e processar os dados oriundos das medições contínuas. Buscando-se informações relevantes que não são identificadas facilmente, podendo trazer melhorias na qualidade da energia consumida, diminuindo a demanda e os valores pagos às concessionárias de energia.

A correta previsão do fluxo entre o consumidor local e a rede principal é a questão chave para o *Smart Grid*, segundo Bagnasco et al. [7]. A gestão destas estimativas levará a controlar o desequilíbrio na rede, tendo, assim, grande importância na operação mais eficiente das redes e nas configurações das microrredes. Os autores consideram o caso de um ambiente de trabalho de uma instalação hospitalar, onde há o uso elevado e contínuo de

energia, sendo esta definida como uma organização altamente complexa com diversos equipamentos tecnológicos. Em suas análises, afirma que uma política econômica de energia consideraria a previsão de consumo energético, sendo esta previsão uma das questões de maior importância para eficiência e qualidade da energia consumida [7].

Com isso, a precisão de modelos de previsão de consumo energético tem papel importante na operação e planejamento de empresas e companhias para melhorar seus desempenhos energéticos e aumentar a competitividade. A previsão de carga de curto prazo no sistema elétrico pode ajudar a estimar o fluxo de carga, prevenir sobrecargas e também contribuir com informações a fornecedores de energia, instituições financeiras e outros participantes deste ramo nos vários níveis, tais como: geração, transmissão e distribuição de energia elétrica [8].

A previsão de carga em uma edificação permite que o gerente de energia programe manutenções, evite sobrecargas, rearranje cargas evitando ultrapassagem de demanda contratada, dentre outros.

As técnicas de previsão de curva de carga já são largamente utilizadas pelas concessionárias para grandes blocos de energia, como por exemplo, alimentadores de subestações. Os usos destas técnicas em edificações ainda são pouco exploradas. A variação do comportamento em grandes blocos é bem menor que quando se observa o comportamento de grupos menores de consumidores ou mesmo para um único consumidor. A previsão de cargas para edifícios apresenta maior variabilidade de comportamento de consumo, trazendo mais dificuldade na estimação da curva de carga [9]. Por isso, gerentes de energia e profissionais da área têm um grau elevado de interesse em metodologias para a estimação do consumo energético e da curva de demanda diária de edificações.

Muitos métodos de previsão usam técnicas estatísticas ou algoritmos de inteligência computacional para regressões não lineares, redes neurais e lógica *Fuzzy*. Outros detalhes de diferentes algoritmos de inteligência computacional, usados para previsão, serão apresentados no Capítulo 3.

1.3 Objetivos: Geral e Específicos

Este trabalho propõe uma metodologia de processamento de dados históricos obtidos através de um sistema de monitoramento contínuo de energia elétrica, onde é realizada a estimação de consumo energético e levantamento da curva de demanda diária do consumidor final de energia. Usando para isso diversas ferramentas de inteligência computacional, tendo destaque para a Lógica *Fuzzy* e para as Redes Neurais Artificiais. Dentre essas ferramentas

de Inteligência Computacional utilizadas é feito uma comparação dos resultados conseguidos, demonstrando qual método teve melhor desempenho e quais contribuíram para a diminuição do erro de estimação avaliado.

Pretende-se assim demonstrar através da análise de um banco de dados de medições históricas do consumo de energia e da temperatura máxima e mínima por dia que um processamento destes dados pode ser estruturado de forma a obter-se informações relevantes, informações essas que não são observadas apenas com uma simples análise dos dados.

1.4 Organização do Texto

O trabalho desenvolvido está estruturado em 6 capítulos.

O Capítulo 1 apresenta a contextualização do assunto, abordando a sua importância, a relevância, os objetivos do trabalho e a estrutura dessa dissertação.

O Capítulo 2 enfatiza os conceitos gerais sobre previsão de dados históricos através de um levantamento bibliográfico sobre como este tema é abordado no Sistema Elétrico de Potência para grandes blocos de energia e nas unidades consumidoras, na perspectiva das Redes Inteligentes ou *Smart Grids*.

Uma contextualização teórica sobre os algoritmos utilizados da parte da inteligência computacional, com destaque sobre a lógica *Fuzzy* e as Redes Neurais Artificiais são apresentados no Capítulo 3.

No Capítulo 4, é descrito a metodologia desenvolvida, detalhando os passos para o processamento e análise dos dados.

A aplicação da metodologia no estudo de caso deste trabalho, o detalhamento de como foram configurados os algoritmos, as funções utilizadas pelo software Matlab® e os resultados obtidos são apresentados no Capítulo 5.

No Capítulo 6, é apresentada uma análise sobre os resultados das estimações obtidas e são descritas as conclusões sobre o que foi apresentado nessa dissertação. Também são relatadas, as propostas para continuação do estudo deste tema em trabalhos futuros.

CAPÍTULO 2 – PREVISÃO DE DADOS

Para se obter dados futuros ou uma previsão de dados de um sistema analisado é necessário a aquisição e análise de dados históricos desse sistema, a partir de uma série temporal. Este capítulo mostra o conceito de séries temporais para a previsão de dados, assim como sua importância para o SEP e para grandes consumidores, como um edifício público, e uma abordagem sobre a aquisição de dados na atualidade.

2.1 Introdução

Uma série temporal é uma série de observações de uma quantidade de interesse, como por exemplo: temperatura, velocidade do vento, radiação solar, potência elétrica, entre outros e que variam ao longo do tempo.

Para realizar uma previsão de dados, no contexto de consumo energético, é necessário que se façam modelamentos matemáticos de séries temporais. Estas séries temporais utilizadas para estimação ou previsão de energia, necessitam de outras séries temporais incorporadas aos dados analisados, como temperatura ambiente, histórico do comportamento de consumo energético, além de outras variáveis que relatam efeitos aleatórios [10].

Tendo as informações dos comportamentos reais destas variáveis, faz-se o caminho inverso, no qual existe um banco de dados das variáveis observadas ou monitoradas sequencialmente, identificando-se por Y_t . Assim, descobre-se qual modelo matemático corresponde ao processo do sistema que fez gerar esses dados, conforme a Figura 1.




Figura 1 - Associação do modelo à Série Temporal [11].

Estabelecido um modelo operacional para representar uma série de valores estocásticos e_t em uma sequência de valores padronizados Y_t , obtém-se um modelo ajustado

que traduz os dados do passado em indicativos do que se deve esperar no futuro. Assim, pode-se dizer que este modelo matemático representa o processo analisado [11].

Estes dados podem ser aleatórios ou não em relação ao tempo, que normalmente é definido em curto, médio e longo prazo, como, por exemplo: horas ou dias, semanas ou meses ou anos respectivamente [12]. Dessa forma, se x_i é uma variável aleatória de interesse em um instante de tempo i , sendo que as observações ocorrem nos tempos $i = 1, 2, \dots, t$, então os valores observados ($X_{(1)} = x_1, X_{(2)} = x_2, \dots, X_{(t)} = x_t$) são uma série temporal. A Figura 2 ilustra um exemplo de uma série temporal.




Figura 2 – Exemplo de uma série de dados em função do tempo [13].

Um procedimento lógico adotado é utilizar o modelo matemático encontrado para gerar previsões [6]. Em processos reais, geralmente o modelo exato que gera a série temporal é desconhecido, por isso, faz-se necessário escolher um modelo aproximado. Para escolher qual modelo irá se aproximar do comportamento do sistema observado, é necessário observar padrões de uma série temporal. Alguns padrões típicos, segundo Nogueira [6], são :

A – Série de tempo gerada por um processo com valor constante sobreposto a flutuações estocásticas.

B – Série de tempo gerada por um processo linear sobreposto a flutuações estocásticas.

C – Série de tempo gerada por um processo com valor constante sobreposto a variações sazonais e flutuações estocásticas.




Figura 3 – Padrões de Séries Temporais, adaptado de [6].

Na Figura 3(a), tem-se um gráfico que se assemelha a um controle de fração de defeitos, utilizado em controle estatístico de qualidade de um processo. Assim, é possível averiguar se o processo está estável ou aleatório. Caso existam pontos aleatórios fora dos limites aceitáveis desse controle, é dito que o processo está instável e imprevisível, precisando haver uma atuação sobre o processo para fazer as correções necessárias [14].

Na Figura 3(b), pode-se observar uma tendência crescente com uma sucessão regular de “picos e vales”, dessa forma, identificam-se dois padrões que podem tornar a ocorrer no futuro: crescimento e flutuações. Tais padrões podem ser incorporados a um modelo matemático, possibilitando fazer previsões que auxiliam na tomada de decisões.

Na Figura 3(c), observa-se uma aleatoriedade de forma cíclica, não havendo neste caso tendência crescente ou decrescente e sim uma sazonalidade. Mesmo assim é possível identificar o comportamento desta série até em longo prazo com o modelo matemático adequado.

Verifica-se então que a exibição da série temporal em forma de gráficos permite a análise por especialistas com o objetivo de buscar características importantes da série, tais como estacionariedade, tendências e sazonalidades.

Quando se obtém uma série temporal, descrito por $\{Z(t_1), \dots, Z(t_N)\}$, onde se observa os instantes $t_1, \dots, t_N$, pode-se estar interessado nos seguintes casos [15]:

- Investigar o mecanismo gerador da série temporal;
- Fazer previsões da série, podendo ser em curto ou até em longo prazo;
- Descrever apenas o comportamento da série através de gráficos;
- Procurar periodicidades relevantes nos dados;
- Encontrar relações da série com outras séries temporais.

Nestes casos, pode-se construir modelos probabilísticos ou estocásticos, no domínio do tempo ou no domínio da frequência. Também deve-se construir modelos simples e com o menor número de parâmetros possível, não apresentando dificuldades aos interessados em manipulá-los [12].

Em diversas situações envolvendo ciências físicas, engenharias, ciências biológicas e sociais que revelam o conceito de sistema dinâmico, caracterizam-se por uma série de entradas, $X(t)$, uma série de saídas, $Z(t)$, e uma função de transferência, $v(t)$, [12], conforme ilustra a Figura 4.




Figura 4 – Sistema Dinâmico [12].

Uma importância particular são os sistemas lineares, onde a saída é relacionada com a entrada através de uma função linear, $v(t)$. Um exemplo típico é dado na Equação (1), [11], também chamado de “Modelo de Função de Transferência”:

$$Z(t) = \int_{\tau=0}^{\infty} v(t)x(t - \tau) \quad (1)$$

Dentre alguns interesses que podem ser levantados são:

- a) Estimar a função de transferência, $v(t)$, conhecendo $X(t)$ e $Z(t)$;
- b) Fazer previsões da série, $Z(t)$, com o conhecimento de observações de $X(t)$;
- c) Estudar o comportamento da série, simulando-se $X(t)$;
- d) Controlar a série, $Z(t)$, de modo a trazê-la para o ponto mais próximo possível de um valor desejável, controle esse que é normalmente feito em sistemas dinâmicos.

Para previsão de consumo energético de curto prazo, vários fatores devem ser considerados, como fatores temporais, o clima do dia e as possíveis configurações do local a ser analisado [8]. Os fatores temporais incluem o ano, o dia da semana e a hora do dia. Há uma importante diferença no consumo energético entre finais de semana e dias de semana. O consumo de diferentes dias da semana também pode ser diferente. Por exemplo: segunda-feira e sexta-feira ficam próximos do final de semana, mas podem ser estruturalmente diferentes em comparação com o consumo dos dias de terça até quinta-feira. Há uma significativa particularidade durante a estação do verão e feriados sendo difíceis de estimar precisamente em relação aos dias comuns, devido a sua baixa frequência de ocorrência durante o ano.

Condições climáticas influenciam o consumo energético, dessa forma a previsão de parâmetros climáticos são os mais importantes fatores da previsão de curto prazo. Uma quantidade grande de variáveis do clima pode ser considerada para a previsão de consumo

energético. Temperatura e umidade do ar são usados frequentemente na previsão desses dados. Um estudo sobre previsão de consumo energético [16] indica que dos 22 levantamentos realizados, 13 fazem uso somente da temperatura, 3 fazem uso da temperatura e umidade, 3 fazem uso de parâmetros climáticos adicionais e 3 usam somente parâmetros do consumo energético analisado.

Muitos consumidores de eletricidade utilizam ou consomem diferentes quantidades de energia, como os residenciais, comerciais e industriais, sendo assim classificados em diferentes classes de consumidores.

2.2 Previsão de Dados no Sistema Elétrico de Potência

No Sistema Elétrico de Potência – SEP, o monitoramento do fluxo de energia pelas concessionárias é uma exigência básica para os processos de operação e planejamento das mesmas. Espera-se que os setores que trabalham com a geração, transmissão e distribuição possam fornecer energia de boa qualidade, de maneira segura e econômica. Com este propósito, novas ferramentas estão sendo desenvolvidas para melhorar a resolução de problemas técnicos e operacionais, como, por exemplo, a previsão de carga.

Pesquisas e estudos de previsão de carga estão sendo levadas em consideração como uma ferramenta de importante relevância, para o planejamento e operação das concessionárias de energia. Não apenas no Brasil, mas em nível global, pois prever a demanda além de contribuir para a tomada de decisões das empresas energéticas, conforme [17] pode, por exemplo, aumentar a geração de energia em um determinado horário do dia ou até definir quantas usinas deverão ser demandadas a longo prazo, com isso refletindo de maneira positiva em toda a economia industrial de um país.

As concessionárias de geração de energia visam cada dia mais a eficiência do fornecimento de energia elétrica aos consumidores. Devido aos custos que se apresentam no cenário brasileiro, que atualmente, tendem a elevar-se, em decorrência, da falta de planejamento, à escassez de chuvas, o esvaziamento das represas de hidrelétricas e também de acionamento de termoeletricas, elevando assim o custo do kWh.

Muitas variáveis podem influenciar a previsão de consumo energético, como condição climática, tipo de consumidor e tipo de carga a ser analisada. Conforme [18], a previsão de carga que está sendo mais frequentemente levantada é previsões de curto prazo, sendo este horizonte definido por horas ou dias. Investimentos na previsão até em tempo real também estão sendo desenvolvidos [19]. Novas ferramentas, com o foco especial em inteligência computacional, estão fornecendo algoritmos com a possibilidade de previsões de médio e em

longo prazo, podendo ter um horizonte definido por semanas, meses ou anos, dependendo do tamanho do banco de dados a ser analisado.

Segundo Zavala [20], outra importante questão para as empresas concessionárias de energia é em relação ao custo. Como o levantamento desses dados de previsão de carga, em relação às condições climáticas, podem trazer um valor econômico para elas? Questões como eficiência e precisão desse sistema de previsão de carga são colocadas como fatores para averiguação da rentabilidade de custo para as empresas energéticas.

Por envolver dados que podem ter sua variabilidade alta, esse sistema de previsão é consideravelmente complexo, mesmo a previsão sendo realizada em barramentos da rede elétrica [21], dependendo das variáveis disponíveis para análise e de qual escala de previsão, de curto, médio ou longo horizonte. Levando isso em consideração, o cuidado com prováveis erros de precisão é de elevada importância, já que uma previsão errada pode ser ampliada e levar a perdas de custos operacionais das empresas energéticas.

2.3 Previsão de Dados em Edifícios

Grandes construções ou edificações certamente estão entre alguns dos grandes consumidores de energia elétrica. Regiões que apresentam clima quente-úmido requerem estratégias de arquitetura para projetos de edifícios, como seu *layout*, orientação quanto a aberturas e dimensionamentos para ambientes internos, propriedades térmicas de paredes e coberturas. Estratégias como estas podem beneficiar quanto ao conforto dos usuários e na economia de energia do edifício.

Algumas variáveis, conforme foi citado em [18], podem influenciar no consumo energético também de uma edificação. Não apenas o clima, mas também o funcionamento interno de edifícios e de outras construções possuem relevância na previsão [9]. Dessa forma em eventos atípicos, como feriados, greves, eventos culturais podem alterar as rotinas de consumo do estabelecimento [22]. Portanto, a variabilidade na rotina deve ser considerada um elemento dificultador em um sistema de previsão de carga em edifícios.

O estudo de caso deste trabalho foi realizado em um edifício público localizado em Belo Horizonte – Brasil, onde foi instalado um sistema de monitoramento contínuo realizado pelo Centro de Monitoramento de Usos Finais (CMUF) [23] , [24] , [25], desenvolvido para acompanhamento e apuração do desempenho energético de edificações, permitindo assim um estudo mais detalhado do consumo de energia.

Ferramentas de inteligência computacional estão sendo propostas em diversas literaturas e pesquisas sobre a previsão de consumo energético em edifícios. Não somente

um modelo é utilizado, como as Redes Neurais Artificiais [7], mas a união de métodos matemáticos computacionais, como séries temporais com lógica *Fuzzy* [26] e Redes Neuro-Fuzzy [27], que são denominados como métodos híbridos. Variáveis monitoradas e disponibilizadas em pesquisas realizadas incluem além da medição de energia, o monitoramento da temperatura ambiente, a irradiação solar, a umidade relativa do ar, a velocidade do vento e a pressão atmosférica [28].

Dentre as literaturas citadas, pode-se observar que nos estimadores de índices de erro utilizados entre os dados reais e os dados que foram previstos, ficaram numa faixa de erro entre 2 a 7% para previsões de curto prazo.

Estudos recentes nessa área tem mostrado a implementação de algoritmos genéticos para previsão de cargas, com resultados promissores, ficando com uma margem do indicativo de erro utilizado abaixo de 2% [29].

2.4 Armazenamento de Dados para Previsão

O consumo energético mensal é uma informação básica que os consumidores obtêm das concessionárias de distribuição, sendo esta informação apenas quantitativa para conhecimento do valor cobrado por kWh. O desenvolvimento de equipamentos para a medição contínua, denominados de *Smart Meters*, dentro do conceito de *Smart Grids*, e que neste trabalho foi realizado pelo CMUF, possuem a capacidade de coletar e disponibilizar estes dados para pessoas qualificadas que irão analisar e transformar estes dados em informações relevantes para as concessionárias de energia, referentes ao fluxo de energia dos consumidores.

Não apenas dados de fluxo de energia podem ser coletados, mas conforme citado anteriormente, diversos parâmetros podem ser monitorados [28]. Incluindo a estes dados monitorados, outros eventos que são cíclicos, como férias, período escolar e horário de verão e também eventos aleatórios, como shows, feriados, grandes eventos esportistas, como, por exemplo, a copa do mundo de futebol, influenciam consideravelmente o consumo de energia e consequentemente os dados monitorados. Por isso, o sistema que analisará os dados deve ser preparado para identificar estas modificações ou o analista estar ciente destas condições quando for processar os dados.

Supondo um cenário onde houvesse diversos medidores inteligentes nos estabelecimentos, um aumento significativo de dados digitais coletados para a análise das concessionárias seria esperado, fazendo surgir o conceito de *Big Data*.

2.4.1 Big Data

O conceito de *Big Data* surgiu como sendo um conjunto ou um banco de dados amplo, necessitando de ferramentas preparadas para lidar com grandes volumes de informações [30]. Muitos dados de hoje não estão em um formato estruturado. A organização, recuperação, modelagem e análise são outros desafios fundamentais do *Big Data*.

Segundo Davenport [31], a análise dos dados é um gargalo em muitas aplicações devido à falta de escalabilidade dos algoritmos e à complexidade dos dados a serem analisados. A apresentação dos resultados e sua interpretação por especialistas de domínio técnico é fundamental para a extração de conhecimentos relevantes.

O volume de dados aumenta mais rápido do que recursos de computação e as velocidades dos processadores atualmente, o que acarretará em um maior tempo de processamento e análise dos dados.

A privacidade é outra preocupação, pois há um receio do uso inadequado de dados pessoais, ou o monitoramento de como é o padrão de comportamento do usuário ao longo do tempo, tornando um problema técnico e sociológico.

Portanto, uma infraestrutura que suporte o volume de transmissão desses dados, a comunicação, a interoperabilidade dos medidores, a confiabilidade dos dados e a proteção ou segurança das informações contra-ataques cibernéticos se faz necessário, visto que uma infraestrutura desse porte, no cenário atual, ainda é deficiente. Além disso, a falta de pessoal qualificado, software e pesquisas para estruturar e analisar esses dados compromete esse desenvolvimento. Estudos apontam que apenas 0,5% dos dados digitais gerados por dispositivos que possuem esse monitoramento e coleta de dados contínuo no ano de 2012, foram estruturados [31].

O investimento em *Big Data* levará a uma nova onda de avanços tecnológicos que serão incorporados nas próximas plataformas de análise, produtos e sistemas. A análise de grandes volumes de dados que se tornam cada vez mais disponíveis eleva o potencial de avanços rápidos na tecnologia e em informações relevantes para diversas empresas.

2.5 Considerações Finais

Neste capítulo descreveu-se a teoria sobre previsão de dados, de um sistema analisado qualquer, no qual é estabelecida uma série temporal com os dados levantados. Uma revisão bibliográfica sobre como este conceito é aplicado no Sistema Elétrico de

Potência em um aspecto geral e especificamente quando é aplicado no consumo energético de edificações foi apresentada. O conceito de *Big Data* foi apresentado neste capítulo mostrando como está o processamento de dados digitais e seu armazenamento atualmente e tendências tecnológicas neste contexto.

CAPÍTULO 3 – INTELIGÊNCIA COMPUTACIONAL

Atualmente são encontrados alguns problemas em diversas áreas da ciência e tecnologia que exigem um grande esforço computacional com algoritmos sendo desenvolvidos para resolvê-los. Mesmo tendo uma capacidade de cálculo elevada, podem levar até anos para se chegar em uma solução ótima.

Com a popularização dos computadores na década de 60, Zadeh (1965) propõe a lógica *Fuzzy*, sendo para alguns autores o início da Inteligência Computacional, pois começou-se a tratar com questões de incerteza. O desenvolvimento da informática e de computadores com maior capacidade de processamento permitiu a criação de softwares mais complexos, como as Redes Neurais Artificiais, onde destacam-se trabalhos de Kohonen (1972), Hopfield (1982), Haykin (1994) entre outros.

Atualmente estão sendo desenvolvidos os algoritmos de computação evolutiva, baseado na genética, ou em comportamentos coletivos de colônias de formigas, abelhas, rotas de voo de pássaros [32]. Portanto, algoritmos elaborados para crescerem e evoluírem automaticamente sem a intervenção do homem, no qual denomina-se por algoritmos com escalabilidade. Dessa forma, a integração de todas estas técnicas têm levado a uma nova forma de representação da Inteligência Computacional.

A fonte ou obtenção de conhecimento é a extração de dados coletados ou preexistentes sobre um determinado assunto de interesse. Portanto, é uma metodologia desenvolvida para a computação que demonstra a capacidade de aprender e comparar novas situações, de modo que o sistema apresente certo nível de raciocínio, como generalização, descobertas, associação e abstração [32].

Segundo Pérez [32], a inteligência computacional é um sistema de métodos e infraestruturas que melhoram a inteligência humana, aprendendo e descobrindo novos

padrões em ambientes dinâmicos para resolver problemas práticos, sendo uma ferramenta colaborativa com o ser humano, conduzindo a melhorar a inteligência humana.

A seguir serão apresentados os algoritmos utilizados neste trabalho, descrevendo sua base teórica e seu funcionamento.

3.1 K-Nearest Neighbor (KNN)

O algoritmo de Proximidade de Vizinhança ou do inglês *Nearest Neighbor* foi proposto por Cover e Hart (1966) e uma de suas variantes é o *K-Nearest Neighbor*, que realiza uma classificação de densidade simples e de fácil implementação segundo Webb [33], usando k-vizinhos mais próximos de um dado padrão [34].

O seu funcionamento inicia-se fornecendo ao algoritmo um conjunto de dados que servirá como treinamento $TR = \{X_1, \dots, X_n\}$ onde n é o número de padrões armazenado em TR, e um vetor X pertencente a base TR que será tomado como um padrão e a partir disso testa-se todos os vetores de TR, classificando os k-vizinhos mais próximos do X padrão.

O KNN realiza essa classificação determinando um volume V contendo estes k-vizinhos mais próximos do padrão X. V será uma esfera centrada em X e com raio igual à distância métrica entre X e X_k sendo X_k o k-ésimo vizinho de X.

O cálculo realizado para medir a distância entre os pontos, pode ser feito por vários métodos, tais como: Distância de Mahalanobis, de Minkowski, de Hamming, Euclidiana, entre outras. O método utilizado para o cálculo foi a distância Euclidiana entre dois pontos, conforme Equação 2 [35], [36].

$$d(X, X_k) = \sqrt{\sum_{i=1}^n (X_i - X_{k_i})^2} \quad (2)$$

A esfera V de raio r em n-dimensões, é dado pela seguinte equação

$$V = \frac{2r^n \pi^{n/2}}{n \Gamma(n/2)} \quad (3)$$

Sendo $\Gamma(x)$ a função gama [37], dado pela equação

$$\Gamma(n+1) = \int_0^\infty x^n e^{-x} dx \quad (4)$$

Para definir a quantidade k de pontos vizinhos a ser considerado na classificação, é necessário considerar dois aspectos. Caso o número k seja pequeno, a classificação fica precisa admitindo apenas pontos com maior proximidade, como pontos afetados por pequenos ruídos. Se o número k for grande, a classificação pode considerar além dos pontos vizinhos outros pontos pertencentes a outras classes do universo de dados tratados [35].

Para exemplificar, será demonstrado a sequência de classificação, realizado pelo algoritmo KNN utilizando o *software Matlab®*.

É apresentado um conjunto de dados para treinamento, no qual será considerado um vetor X com os pontos padrões, sendo identificado por pares ordenados representados pelos quadrados na Figura 5a. Em seguida, este conjunto e os pontos padrões são apresentados ao algoritmo KNN. A identificação dos pontos próximos à vizinhança dos pontos quadrangulares é demonstrado por círculos conforme a Figura 5b.




Figura 5 a) Distribuição do conjunto de dados, b) Identificação dos pontos de vizinhança próxima (*MathWorks, Matlab®*).

Os pontos padrões são contabilizados, identificando assim uma sequência quantitativa de pontos identificando um padrão daquele conjunto. A classificação pela semelhança de comportamento de um conjunto de pontos padrões X , por uma outra sequência comparativa X_k se dá pela contabilização da quantidade de pontos próximos ou vizinhos ao do conjunto padrão. Quanto maior for a quantidade de pontos vizinhos mais semelhante a sequência X_k está da sequência X .

3.2 Lógica Fuzzy

A Lógica *Fuzzy* é um método matemático, no qual é inserido um nível de aproximação de valores, onde até então existia apenas duas respostas extremas: falso ou verdadeiro, ou lógica binária: 0 e 1. Essa aproximação é realizada através do conceito de conjuntos *Fuzzy*, onde foram desenvolvidos métodos e algoritmos de modelagem, que tornaram possíveis a solução de problemas que eram intratáveis com a lógica clássica.

Segundo Heisenberg [38], esta ferramenta de inteligência artificial é muito semelhante ao modelo de raciocínio humano, levando em conta as aproximações, incertezas e suposições que cercam as decisões humanas.

A lógica *Fuzzy* ficou amplamente conhecida com a publicação do artigo do professor Lofti Zadeh [39], ganhando aplicação em muitos campos da engenharia e computação, nas áreas de controle de processo, classificação e estimação.

Decisões que apresentam um grau de incerteza e que não podem ser contemplados pela lógica clássica, pois haveria perda de informações, são altamente recomendáveis para a lógica *Fuzzy*, que apresenta um modelo capaz de combinar a imprecisão associadas aos eventos naturais e o poder computacional, produzindo assim respostas inteligentes, como afirma Cox [40].

3.2.1 Conjuntos Fuzzy

Alguns elementos podem pertencer parcialmente a um conjunto. Dessa forma introduziu-se termos relativos e abstratos nos conceitos de conjuntos.

Zadeh propôs que os elementos dentro de um universo analisado são mais membros de um conjunto do que outros. De fato o valor de pertinência assume qualquer valor entre 0 e 1, sendo que o valor zero indica que dado elemento está fora do conjunto e o valor 1 representa total pertinência ao conjunto.

Caso um elemento x no universo U analisado, seja membro de um conjunto A ou não, através de uma regra de filiação, que pode ser indicado matematicamente como uma função [41].

$$U_A(x) = \begin{cases} 1, & \text{se } x \in A \\ 0, & \text{se } x \notin A \end{cases} \quad (5)$$

Para qualquer valor de x , é considerado um erro percentual de aproximação, que é denominado por grau de pertinência (μ_A). A amplitude desse erro percentual é definida pelo conjunto A . Por exemplo, todo número dentro dessa faixa delimitada pelo conjunto A , terá um fator de pertinência, e todo número fora dos limites desse conjunto terá um grau de pertinência 0. Caso esse erro percentual seja nulo, ou seja, o número é 100% preciso com o valor de x , então seu grau de pertinência será 1, onde sua função é dado por [41] :

$$\mu_A(x) \in [0,1] \quad (6)$$

E ilustrado conforme a Figura 6.




Figura 6 – Função de Pertinência (Próprio Autor).

A notação para o conjunto *Fuzzy*, no universo de discurso, U , é discreto e finito, com a seguinte definição [41] :

$$A = \left\langle \frac{u_A(x_1)}{x_1} + \frac{u_A(x_2)}{x_2} + \dots \right\rangle = \left\langle \sum_i \frac{u_A(x_i)}{x_i} \right\rangle \quad (7)$$

$$A = \left\langle \int \frac{u_A(x_1)}{x_1} \right\rangle \quad (8)$$

Onde $u_A(x_1)$ representa o grau de pertinência de x_1 em um conjunto A .

O valor do grau de pertinência (u_A) pode então assumir qualquer valor entre 0 e 1, quando o número analisado estiver próximo de x , e pertencendo ao conjunto A , que está inserido no universo de discurso U . Em um universo U , pode haver mais de um conjunto, onde estes conjuntos são associados a um conceito linguístico que classifica ou define um valor impreciso, que esteja entre 0 e 1. Pode ocorrer que para um determinado conjunto de pontos, haja uma ou mais funções triangulares, conforme foi dito, dependendo da definição de quantos pontos de inferência máxima existem na partição *Fuzzy* analisada. Quanto mais próximo estiver u_A do valor unitário, mais preciso será sua classificação em relação ao conjunto ou variável linguística.

Na lógica *Fuzzy*, dentro de um universo U podem existir vários conjuntos que realizam operações clássicas entre si. Segundo Ross [41] dado 2 conjuntos A e B , a união entre eles é denotado por $A \cup B$, indicando que todos os elementos de U estão em A , em B , ou em A e B , também chamada de lógica OR. A interseção entre eles é denotado por $A \cap B$, representa que todos os elementos de U estão simultaneamente nos conjuntos A e B , também chamado de lógica AND. O complemento de A denotado por $\bar{A}$ define todos os elementos de U que não estão em A e a diferença entre A e B é denotado por $A|B$ indicando que todos os elementos do universo U que estão em A não estão em B . Estas quatro operações entre os conjuntos são mostradas a seguir.

União	$A \cup B = \{x x \in A \text{ or } x \in B\}$	(9)
-------	--	-----

Interseção	$A \cap B = \{x x \in A \text{ and } x \in B\}$	(10)
------------	---	------

Complemento	$\bar{A} = \{x x \notin A, x \in U\}$	(11)
-------------	---------------------------------------	------

Diferença	$A B = \{x x \in A \text{ and } x \notin B\}$	(12)
-----------	---	------

Em termos de função, segundo Gupta e Qi [42] estas operações são dadas como (o símbolo $\vee$ é o operador de máximo e o $\wedge$ é de mínimo):

União	$A \cup B \rightarrow U_{A \cup B}(x) = U_A(x) \vee U_B(x) = \max(U_A(x), U_B(x))$	(13)
-------	--	------

Interseção	$A \cap B \rightarrow U_{A \cap B}(x) = U_A(x) \wedge U_B(x) = \min(U_A(x), U_B(x))$	(14)
------------	--	------

Complemento	$\bar{A} \rightarrow U_{\bar{A}}(x) = 1 - U_A(x)$	(15)
-------------	---	------




Figura 7 – Operações entre conjuntos fuzzy: (a) Conjuntos A e B , (b) União (c) Interseção e (d) Complemento, (Próprio Autor).

Para dois conjuntos do mesmo universo, dizemos que A esta contido em B quando

$$\text{Contenção} \quad A \subseteq B \rightarrow U_A(x) \leq U_B(x) \quad (16)$$

A classificação de um conjunto *Fuzzy* por uma variável linguística se dá, por exemplo, quando analisamos o universo da temperatura, onde o conjunto A_1 é definido como Muito Frio, o conjunto A_2 como Frio, até chegar ao conjunto A_5 definido como Muito Quente.




Figura 8 – Classificação dos conjuntos ou variável linguística no universo de temperatura, adaptado de Aguado [43].

Uma partição *Fuzzy* corresponde a uma variável monitorada que está sendo analisada. Quando envolver a relação de duas variáveis sendo analisadas paralelamente se faz necessário a criação de uma partição *Fuzzy* para cada variável [41].

Uma família de conjuntos *Fuzzy* $\{A_1, A_2, \dots, A_n\}$, constitui uma partição A em um universo U. A partição A cobre todo o universo U, se todos os elementos de U possuem um conjunto dessa partição e um grau de pertinência diferente de zero, matematicamente expresso por [44] :

$$\forall_U \exists i / \mu_{A_i}(x) > \varepsilon, x \in U \quad (17)$$

Onde ε define que o grau de pertinência de qualquer x no universo U é sempre maior ou igual a ε em qualquer conjunto A_i da partição A.

Segundo Almeida [44], uma das propriedades de definição dos conjuntos *Fuzzy* diz que os conjuntos de A devem ser unimodais, ou seja, ter um máximo global único, por exemplo representado pela função triangular, conforme a Figura 6 e também ser convexo, de forma que

$$\mu_A[\lambda.x_1 + (1-\lambda).x_2] \geq \min[\mu_A(x_1), \mu_A(x_2)] \quad (18)$$

Onde

x_1 e x_2 são dois pontos quaisquer dentro do conjunto A_i

λ é um valor escalar positivo no intervalo de $[0,1]$.

Neste contexto, uma maneira de ilustrar como são definidos os conjuntos em cada

partição é mostrado na Figura 9 com uma função triangular. Portanto, tem-se como exemplo as partições f e d , onde a base da pirâmide tridimensional define os limites do conjunto A_i com inferência μ_{A_i} mínima ou zero na base da pirâmide e a inferência máxima ou 1 na ponta da pirâmide. Na Figura 9 a inferência $\mu_{A_i} = 1$ está localizado na coordenada $f,d(3,3)$.




Figura 9 – Definição tridimensional de um conjunto *Fuzzy* nas partições f e d , adaptado de Ross [41].

3.2.2 Sistema Base de Regras Fuzzy

Segundo Cox [40], o sistema lógico *Fuzzy* se resume em três operações, conforme ilustra a Figura 10.




Figura 10: Sistema Lógico *Fuzzy*, adaptado de Aguado [43] .

Fuzzificação: Os dados de entrada são transformados em variáveis linguísticas, considera-se todos os dados de imprecisão, com seu respectivo grau de pertinência.

Inferência: São criadas regras de proposições, que são as relações entre os conjuntos *Fuzzy* de agregação das condições de antecedente (parcela SE, que define o peso de ativação da regra) e composição do consequente (parcela ENTÃO, que define o resultado obtido de através de um mecanismo de inferência).

Dessa forma uma base de regras *Fuzzy* pode ser representada por uma família de relações *Fuzzy* $R_i \rightarrow [0,1]$, representando cada regra.

Ross [41] afirma que a relação de uma composição *Fuzzy* pode ser definida da seguinte forma: Supondo que R é a relação *Fuzzy* de um plano cartesiano $X \times Y$, S é a relação *Fuzzy* de $Y \times Z$ e T é a relação *Fuzzy* de $X \times Z$, sendo que Z corresponde aos graus de pertinências de R . Dessa forma todos os graus de pertinência podem ser representados por uma matriz R no plano $X \times Y$.

$$R = \begin{bmatrix} \mu_R(X_1, Y_1) & \mu_R(X_1, Y_2) & \cdots & \mu_R(X_1, Y_n) \\ \mu_R(X_2, Y_1) & \mu_R(X_2, Y_2) & \cdots & \mu_R(X_2, Y_n) \\ \vdots & \vdots & \cdots & \vdots \\ \mu_R(X_m, Y_1) & \mu_R(X_m, Y_2) & \cdots & \mu_R(X_m, Y_n) \end{bmatrix} \quad (19)$$

Para a composição do grau de inferência de uma relação *Fuzzy*, é utilizada a composição Max-Min e também a Max-Prod. [39], sendo estas as mais comuns de serem utilizadas. Um exemplo é demonstrado a seguir, por Ross [41] :

$$T = R \circ S$$

$$\text{Max-Min} \quad \mu_T(x, z) = \text{MAX}_{y \in Y} (\mu_R(x, y) \wedge \mu_S(y, z)) \quad (20)$$

$$\text{Max-Prod.} \quad \mu_T(x, z) = \text{MAX}_{y \in Y} (\mu_R(x, y) \cdot \mu_S(y, z)) \quad (21)$$

Outras formas de operação para a composição *Fuzzy*, estão sendo propostas conforme Ross [41] . Para exemplificar, uma operação de composição $B = A \circ R$, onde A é a entrada ou o antecedente definido no universo X , B é a saída ou consequente definido no universo Y e R é a relação *Fuzzy* entre entrada(x) e saída(y):

$$\text{Min-Max} \quad \mu_B(y) = \min_{x \in X} \{ \max[\mu_A(x), \mu_R(x, y)] \} \quad (22)$$

$$\text{Max-Max} \quad \mu_B(y) = \max_{x \in X} \{ \max[\mu_A(x), \mu_R(x, y)] \} \quad (23)$$

$$\text{Min-Min} \quad \mu_B(y) = \min_{x \in X} \{ \min[\mu_A(x), \mu_R(x, y)] \} \quad (24)$$

$$\text{Max-Média} \quad \mu_B(y) = \frac{1}{2} \max_{x \in X} [\mu_A(x) + \mu_R(x, y)] \quad (25)$$

$$\text{Sum-Prod} \quad \mu_B(y) = f \{ \sum_{x \in X} [\mu_A(x), \mu_R(x, y)] \} \quad (26)$$

Onde $f(.)$ é uma função lógica (sigmoidal ou degrau), que limita o valor da função no intervalo $[0,1]$, sendo esta composição muito utilizado em aplicações com Redes Neurais Artificiais.

Defuzzificação: Os valores das variáveis linguísticas são convertidos em números reais, que resultará em um conjunto de saída definido matematicamente, através do método centroide ou centro de gravidade.

É representado na Figura 11 os processos citados anteriormente, para duas partições do mesmo universo U , onde os conjuntos definidos se relacionam diferentemente em cada partição.




Figura 11: Regra e Inferência Fuzzy, adaptado de Cox, [40].

Em geral temos a seguinte regra, conforme foi proposto por Mandani [45] :

$$\text{Regra } i: \text{ Se } x_1 = A_1 \text{ E } x_2 = A_2 \text{ E } \dots \text{ E } x_p = A_p \text{ Então } y = B_i \quad (27)$$

Para exemplificar, baseado na Figura 11, tem-se a seguinte definição, segundo Ross [41] :

Fuzzificação: Se x_i é A_1 E x_j é A_2 Então B_i

Inferência: $uA_1 \cdot uA_2 = uB_i$ ($i=1,2$)

Defuzzificação:

$$C(\text{centroide}) = \frac{\int_{x \in U} x \cdot uB_i(x)}{\int_{x \in U} uB_i(x)} \quad (28)$$

3.3 Fuzzy C-Means (FCM)

O algoritmo *Fuzzy C-Means* é considerado um sistema híbrido, ou seja, que combina características de duas ou mais técnicas de Inteligência Computacional em um único modelo segundo Rocha [46]. Neste caso, o algoritmo combina métodos matemáticos de *clustering* com a parte de inferência dos conjuntos *Fuzzy*, assim realizando agrupamentos de dados considerando um índice de quanto cada objeto pertence a um grupo ou a outro.

O algoritmo foi proposto por Bezdek [47], havendo atualmente aplicações em processamentos de imagens, análise de sistemas de energia e reconhecimento de padrões [46].

O seu funcionamento, assim como as representações matemáticas serão descritos a seguir, conforme Rocha [46]. O objetivo do algoritmo é minimizar uma função J_{FCM} encontrando a menor distância entre os dados e os centros dos grupos aos quais tais dados pertencem com alguma pertinência [48]. Tal função é dado por:

$$J_{FCM}(U_f, M) = \sum_{i=1}^c \sum_{j=1}^n (\mu_{ij})^m d(\vec{m}_j, \vec{x}_j)^2 \quad (29)$$

Onde

j: é a identificação de um dado

i: é a identificação do grupo

n: é o número de elementos de um conjunto de dados X

c: é o número de agrupamentos

μ_{ij} : é o grau de pertinência de $\vec{x}_j$ ao i-ésimo grupo *Fuzzy* de X, definido por

$$\mu_{ij} = \mu_i(\vec{x}_j), \quad 1 \leq i \leq c, \quad 1 \leq j \leq n \quad (30)$$

Satisfazendo três condições

$$0 \leq \mu_{ij} \leq 1, \forall i, j \quad (31)$$

$$\sum_{i=1}^c \mu_{ij} = 1, \forall j \quad (32)$$

$$0 < \sum_{j=1}^n \mu_{ij} < n, \forall i \quad (33)$$

m: é um número real positivo, tal que $m \in (1, \infty)$

$d(\vec{m}_j, \vec{x}_j)$: é a distância entre o vetor de dados $\vec{x}_j$ e o vetor protótipo ou de centroides representante da i-ésima partição *Fuzzy* $\vec{m}_i$

U_f : é uma matriz de pertinências *Fuzzy*, de dimensões c x n, definido como

$$U_f = \begin{bmatrix} \mu_{1,1} & \mu_{1,2} & \cdots & \mu_{1,n} \\ \mu_{2,1} & \mu_{2,2} & \cdots & \mu_{2,n} \\ \vdots & \vdots & \vdots & \vdots \\ \mu_{i,1} & \mu_{i,2} & \cdots & \mu_{i,n} \\ \vdots & \vdots & \vdots & \vdots \\ \mu_{i+1,1} & \cdots & \cdots & \cdots \\ \vdots & \vdots & \vdots & \vdots \\ \mu_{c,1} & \mu_{c,2} & \cdots & \mu_{c,n} \end{bmatrix} \quad (34)$$

A construção e atualização desta matriz acontece durante o processo de minimização da Equação (30), a atualização de μ_{ij} acontece conforme a equação a seguir

$$\mu_{ij}^{t+1} = \frac{1}{\sum_{l=1}^c \left(\frac{d(\vec{c}_l, \vec{x}_j)}{d(\vec{c}_i, \vec{x}_j)} \right)^{\frac{1}{1-m}}} \quad (35)$$

Sendo t o contador de iterações, e C é um conjunto finito tal que $C = C_1, \dots, C_c$ ($c \leq n$), com isso duas exceções devem ser tratadas

$$\mu_{ij}^{t+1} = \begin{cases} 1 & \text{se } d(\vec{c}_1, \vec{x}_j) = 0 \\ 0 & \text{se } d(\vec{c}_l, \vec{x}_j) = 0, (l \neq i \text{ e } 1 \leq l, i \leq c) \end{cases} \quad (36)$$

M: é uma matriz de protótipos de grupos. $\vec{m}_i$ são vetores protótipos. A matriz possui dimensões c x p e é definida por

$$M = \begin{bmatrix} \vec{m}_1 \\ \vec{m}_2 \\ \vdots \\ \vec{m}_c \end{bmatrix} = \begin{bmatrix} m_{1,1} & m_{1,2} & \cdots & m_{1,p} \\ m_{i,1} & m_{i,2} & \cdots & m_{i,p} \\ m_{i+1,1} & \cdots & \cdots & \cdots \\ m_{c,1} & m_{c,2} & \cdots & m_{c,p} \end{bmatrix} \quad (37)$$

A inicialização dessa matriz é aleatória e sua atualização ocorre durante o processo de minimização da Equação (30), a atualização de $\vec{m}_i$ acontece conforme a equação a seguir

$$\vec{m}_i^{t+1} = \frac{\sum_{j=1}^n (\mu_{ij}^{t+1})^m \vec{x}_j}{\sum_{j=1}^n (\mu_{ij}^{t+1})^m} \quad (38)$$

Onde i = 1, ..., c e j = 1, ..., n, t é um contador de iterações inicializado em 0 e $\vec{x}_j$ é o vetor representante do dado x_j que é analisado em relação às suas pertinências aos grupos.

Inicialmente é fornecido ao algoritmo um banco de dados amostrais, onde é informado a coordenada de cada objeto dentro do universo analisado, conforme Figura 12a. Em seguida é definido quantos pontos centrais serão estabelecidos dentro deste universo de dados, delimitando assim a quantidade de agrupamentos dentro deste universo, com seu respectivo ponto central. Este ponto central é um ponto equidistante que minimiza a distância entre todos os objetos existentes em sua proximidade, podendo ser utilizado para tal o cálculo da distância Euclidiana. A Figura 12b ilustra a definição de dois agrupamentos com seus respectivos pontos centrais, feitos com os dados iniciais da Figura 12a.




Figura 12 - a) Dados para análise do *Fuzzy C-Means*, b) Clusterização pelo algoritmo *Fuzzy C-Means* (MathWorks, Matlab®)

Segundo Rocha [46], o algoritmo *C-Means* é fortemente dependente de sua inicialização, ou seja, da matriz M inicial de inferência de cada objeto. Sendo assim, não se garante que a otimização realizada pelo algoritmo encontrou o mínimo global, podendo ser frequentemente encontrados mínimos locais. Por isso, é aconselhável a repetição desse processo e verificação dos resultados conseguidos.

3.4 Redes Neurais Artificiais (RNA)

É um algoritmo inspirado nos neurônios do cérebro humano, pois estes processam informações de uma forma completamente diferente do computador digital, segundo Haykin [49]. Motivado pela capacidade do cérebro humano em reconhecer padrões, aprender e generalizar informações, surge essa linha de desenvolvimento computacional que originou um neurônio artificial, para que trabalhasse semelhantemente ao neurônio biológico.

Basicamente, são sistemas de computação em paralelo, que possuem a capacidade de coletar dados, e através de um processo de aprendizagem, os pesos sinápticos dos neurônios são modificados por iterações entre informações nos pares de entradas e saídas. Assim generalizam o conhecimento contido nas amostras de dados e respondem de forma adequada quando dados diferentes ao da amostra forem apresentado a esta rede neural [50].

Nos últimos anos, várias pesquisas utilizando a RNA tem ganhado interesse em áreas da indústria, economia e engenharia. Devido à sua capacidade de generalização de dados, cada vez mais complexos, e baixo tempo computacional, estas redes podem ser usadas quando um modelo matemático de um processo é difícil de ser obtido segundo Zárate [51].

3.4.1 Neurônio Biológico x Artificial

O cérebro humano possui uma rede neural, estruturada de forma interativa entre si, armazenando e tomando decisões a partir das informações recebidas. O neurônio biológico é dividido nas seguintes partes:

- Corpo da célula: Contêm o núcleo celular e o citoplasma;
- Dendritos: Correspondem aos receptores da célula nervosa;
- Axônio: Transmitir informação na forma de pulsos elétricos regenerativos no sistema nervoso;
- Sinapse: Permite propagar informação apenas numa única direção, podem ser excitadoras ou inibidoras.




Figura13 – Neurônio Biológico, adaptado de Stemmer [52] .

O neurônio artificial, Figura 14, é denominado modelo MCP, pois foi proposto por McCulloch e Pitts e era uma simplificação do que se sabia até então do neurônio biológico. Para o modelo no neurônio artificial temos:




Figura 14 – Neurônio Artificial, adaptado de Zárate [51] .

Sendo

x_1 x_2 e x_3 : Dados de entrada do neurônio;

w_1 w_2 e w_3 : Pesos sinápticos de cada entrada;

S : é definido como $S = (\sum_{i=1}^n w_i \cdot x_i - \theta)$


θ : Valor de disparo, assim ativando o neurônio e pode contribuir para o disparo de outros conectados a ele.

Y: saída do neurônio, definido como $Y = f(S)$, especificada para cada neurônio;

A regra de disparo desse neurônio é descrita, em termos matemáticos por Almeida [44] :


$$y^{(k+1)} = \begin{cases} 1, & \text{se } \sum_{i=1}^n w_i \cdot x_i^{(k)} \geq \theta \\ 0, & \text{se } \sum_{i=1}^n w_i \cdot x_i^{(k)} < \theta \end{cases} \quad (39)$$

Sendo k o instante de tempo de um impulso na entrada. O f representado na saída y do neurônio também é chamado de Função de Ativação. Outras funções de ativação são utilizadas em aplicações com os neurônios, as mais relevantes são, segundo Braga [53] :



a


$$y = \begin{cases} 1, & \text{se } S \geq 0 \\ 0, & \text{se } S < 0 \end{cases} \quad (40)$$



b


$$y = \begin{cases} 1, & \text{se } S \geq 0 \\ -1, & \text{se } S < 0 \end{cases} \quad (41)$$

Figura 15 - a) Função de limiar estrito, b) Função degrau [53] .



a

$$y = \begin{cases} 1, & \text{se } S > 1 \\ S, & \text{se } -1 < S < 1 \\ -1, & \text{se } S < -1 \end{cases} \quad (42)$$



b

$$y = \lambda \cdot S \quad (43)$$

Figura 16 - a) Função linear com saturação, b) Sem saturação da saída [53] .




Figura 17 - a) Função sigmoidal unipolares, b) Sigmoidal bipolar [53] .

3.4.2 Arquitetura da Rede

Uma arquitetura se difere pelos seguintes elementos: Número de camadas da rede (podendo ser única ou de múltiplas camadas), número de neurônios em cada camada, função de ativação e o algoritmo ou regra de aprendizado. No geral pode-se classificar três tipos diferentes de redes [49] :




Figura 18 - a) Rede Alimentada Adiante com Camada Única , b) Rede Alimentada Diretamente com Múltiplas Camadas, c) Redes Recorrentes, adaptados de Haykin [49] .

Considerando uma rede de camada única, conforme Figura 18a, ela é considerado uma organização simples de neurônios, onde existe apenas um fluxo do sinal sendo da entrada para a saída, assim considerando um vetor de entradas $x = [x_1 \ x_2 \ x_3 \ \dots \ x_m]$ e um vetor de saída $y = [y_1 \ y_2 \ y_3 \ \dots \ y_n]$, cada peso w_{ij} conecta uma entrada ao neurônio, sendo que a indicação i indica o neurônio de destino e o j indica a origem de cada peso. Portanto a regra de ativação desta rede será [44] :

$$S_i = \sum_{j=1}^m w_{ij} \cdot x_j \quad \text{para } i = 1, 2, 3, \dots, n. \quad (46)$$

E a saída de cada neurônio desta rede é:

$$y_i = f(w_i \cdot x) \quad \text{para } i = 1, 2, 3, \dots, n. \quad (47)$$

Sendo $w_i = [w_{i1} \ w_{i2} \ w_{i3} \ \dots \ w_{im}]$.

A rede de múltiplas camadas, conforme Figura 18b, é uma representação da rede com mais de uma camada de neurônio no fluxo do sinal da entrada até a saída. Normalmente estas camadas que ficam localizados em pontos intermediários são chamados de camadas invisíveis. Assim a saída de uma camada alimenta a entrada da próxima camada, sendo representado matematicamente por [44] :

$$h_1 = \tau_1[W_1 \cdot x], \ h_2 = \tau_2[W_2 \cdot h_1], \ \dots \ y = \tau_k[W_k \cdot h_{k-1}] \quad (48)$$

Sendo

h: a camada de neurônio

τ : operador matricial de $[W \cdot x]$, definido por

$$\tau = \begin{bmatrix} f() & 0 & 0 & \dots & 0 \\ 0 & f() & 0 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & f() \end{bmatrix} \quad (49)$$

W: matriz de pesos, definido por

$$W = \begin{bmatrix} w_{11} & w_{12} & w_{13} & \dots & w_{1m} \\ w_{21} & w_{22} & w_{23} & \dots & w_{2m} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ w_{n1} & w_{n2} & w_{n3} & \dots & w_{nm} \end{bmatrix} \quad (50)$$

Uma rede recorrente, conforme mostra a Figura 18c, é uma rede obtida por uma ou mais camadas, sendo realimentada, conectando os neurônios da saída aos de entrada. É inserido um operador de atraso Δ para que haja um intervalo entre os ciclos de amostragens. O vetor de entrada apenas inicializa a rede, depois ela processa o ciclo do sinal de forma autônoma até a rede se estabilizar [44] .

$$y^{(t+\Delta)} = \tau[W \cdot y^{(t)}] \quad (51)$$

3.4.3 Regras de Aprendizado

Um subconjunto de dados é utilizado para treinar a rede por meio de um algoritmo apropriado [49] . Essa fase do projeto da rede é chamada de aprendizagem de uma rede neural, que pode ser:

- Supervisionada: são aplicados dados de entrada e a saída é conhecida, o supervisor confere se a resposta da rede está aproximando da resposta real. Nesse processo ocorre a adaptação dos pesos entre os neurônios, para que a diferença seja cada vez menor.

- Não Supervisionada: a saída não é conhecida, ficando a rede responsável por encontrar e distinguir classes e padrões diferenciados dos dados de entrada [50] .

Uma das técnicas de correção de pesos utilizada é chamada de *Back-Propagation* ou retropropagação [49] . Este aprendizado procura através de iterações finitas o menor erro entre a saída encontrada e a saída desejada, para o caso de ser supervisionado. Um sinal de estímulo é aplicado à primeira camada da rede e este é propagado até a camada de saída. Assim ocorre a comparação entre a saída gerada y_k e a desejada d_k e a diferença entre elas ou o erro e_k . Este erro é retropropagado da camada de saída para cada elemento das camadas anteriores, com isso os pesos sinápticos são atualizados de modo a fazer a rede convergir para o valor de saída desejada. Sua representação é ilustrada na Figura 19.




Figura 19 – Rede Back-Propagation, adaptado de Haykin [49].

Sua representação matemática é definida como:

$$e_k(n) = d_k(n) - y_k(n) \quad (52)$$

Sendo

k: a identificação do neurônio

n: número da iteração

O primeiro modelo de neurônio com a capacidade de aprendizado foi denominado de *Perceptron* por Franklin Rosenblatt em 1958. Este aprendizado ocorre com sucessivos ajustes nos pesos w_i de conexão das entradas x_i . Considerando a equação (anterior), se o erro $e_k(n)$ é positivo, é necessário aumentar a saída $y(n)$ do Perceptron, caso contrário é necessário diminuir a saída $y_k(n)$. Dessa forma considerando que cada peso w_k contribui para a saída com uma parcela $w_k \cdot x_k$ temos que o ajuste do vetor peso $w_k(n)$ define a forma da regra de aprendizagem por correção de erro, ou a Regra de Aprendizado do *Perceptron*, pela seguinte equação [49] :

$$w_k(n+1) = w_k(n) + \alpha[d_k(n) - y_k(n)]x_k(n) \quad (53)$$

Sendo

α : o parâmetro da taxa de aprendizagem, restrito ao intervalo de [0,1].

Assim o parâmetro α determina a velocidade de ajuste dos pesos da rede Perceptron.

3.4.4 Treinamento da Rede

Para realizar a parte de treinamento da rede neural, com o objetivo de aprender o comportamento de variáveis de dados históricos, é aconselhável usar para essa fase de treinamento cerca de 70 a 80% dos dados disponibilizados, escolhidos de forma aleatória. Como os pesos dos neurônios são definidos inicialmente de forma aleatória pelo algoritmo, recomenda-se repetir essa fase de treinamento no mínimo por 3 vezes consecutivas, para que haja uma estabilização dos pesos de cada neurônio, segundo Zárate [51] .

Assim, com essa base de treinamento da rede realizado, é necessário averiguar se a rede está oferecendo respostas na saída da RNA próximas das saídas dos dados reais ou de referência. Para essa fase de averiguação, são utilizados os 30 ou 20% de dados que não foram utilizados na fase de treinamento, para averiguar se a RNA está se comportando com respostas aproximadas com as dos dados históricos.

Após isso, espera-se que generalizando os dados de entrada da RNA, a rede ofereça respostas coerentes com o modelamento dos dados reais treinados.

3.5 Mapas de Kohonen (SOM)

O mapa auto-organizável foi desenvolvido por Teuvo Kohonen [54]. Este algoritmo faz parte de um grupo de redes neurais chamado de redes baseados em modelos de competição, ou apenas de redes competitivas, segundo Fausett [55], combinando a competição como uma forma de aprendizagem para ajuste dos pesos sinápticos.

Denominado em inglês por *Self-Organizing Maps*, o SOM utiliza um treinamento não-supervisionado, onde a rede busca encontrar similaridades baseado nos padrões recebidos com os dados de entrada, sendo seu principal objetivo o agrupamento dos dados de entrada dessa rede, semelhantes entre si [53], formando classes ou clusters. Esta aplicação é utilizada em reconhecimento de voz, análise exploratória de dados e otimização combinatória [56].

Os mapas auto-organizáveis de Kohonen ou simplesmente mapas de Kohonen geram mapeamentos de espaços multidimensionais em estruturas com dimensões topológicas menores, normalmente uni ou bidimensional [49], preservando as relações de vizinhança dos dados de entrada e facilitando a visualização dos agrupamentos.

Segundo Braga [53], a competição existente entre os neurônios é dita como *winner-take-all*, o vencedor leva tudo, ou seja quando um neurônio vence a competição, produzindo

o maior valor de saída para uma dada entrada, não apenas ele, mas os neurônios localizados na sua vizinhança tem seus pesos ajustados.

O seu funcionamento, assim como as representações matemáticas serão descritos a seguir, conforme Haykin [49]. Um vetor de entrada é fornecido ao SOM, representado por $x = [x_1 \ x_2 \ x_3 \ \dots \ x_m]$ junto com um vetor de pesos sinápticos, $w_j = [w_{j1}, w_{j2}, \dots, w_{jm}]$, com $j = 1, 2, \dots, l$, sendo j o número do neurônio e l o número total de neurônios da rede.

É realizado uma comparação do produto de $w_j \cdot x$ para encontrar o neurônio de maior valor, identificando os neurônios vizinhos a este que serão excitados. O maior valor do produto de $w_j \cdot x$ equivale a minimizar a distância euclidiana entre os vetores x e w_j . Usando $i(x)$ para identificar o neurônio vencedor, dado um vetor de entrada x , temos que

$$i(x) = \arg \min_j \|x - w_j\| \quad (54)$$

Assim um neurônio vencedor tende a excitar mais os neurônios de sua vizinhança, ficando este centralizado. Considerando que h_{ji} represente a vizinhança centrada do neurônio vencedor i e j um neurônio dessa vizinha, e também que d_{ij} represente a distância entre o neurônio vencedor i e o excitado j , temos que a vizinhança possui uma simetria sendo h_{ji} seu ponto de máximo, definido por $d_{ij} = 0$ e que h_{ji} decresce monotonamente com o aumento de d_{ij} , ou seja a vizinhança em torno do neurônio i decai suavemente com a distância, conforme Lo [57] e Ritter [58].

Dessa forma h_{ji} é um função gaussiana da distância d_{ij} , descrita por

$$h_{j,i(x)} = \exp\left(-\frac{d_{j,i}^2}{2\sigma^2}\right) \quad (55)$$

Onde

σ : é a largura efetiva da vizinhança, que diminui com o passar do tempo.

$d_{j,i}^2$: é definido por $d_{j,i}^2 = \|r_j - r_i\|^2$ com r_j sendo a posição no plano do neurônio excitado e r_i sendo a posição no plano do neurônio vencedor.

A dependência de σ com o tempo discreto n é o decaimento exponencial, descrito por Ritter [58] e Obermayer [59]:

$$\sigma(n) = \sigma_0 \exp\left(-\frac{n}{\tau_1}\right) \quad n = 0, 1, 2, \dots \quad (56)$$

Onde

σ_0 : é o valor de σ na inicialização

τ_1 : é uma constante de tempo

Assim quando o tempo n , ou o número de iterações aumenta, a largura $\sigma(n)$ decresce a uma taxa exponencial e a vizinhança diminui de maneira correspondente. Consequentemente a vizinhança assume uma forma variável no tempo:

$$h_{j,i(x)}(n) = \exp\left(-\frac{d_{j,i}^2}{2\sigma^2(n)}\right), \quad n = 0, 1, 2, \dots \quad (57)$$

Portanto, usando o tempo discreto, dado o vetor peso $w_j(n)$ do neurônio j no tempo n , o vetor de peso atualizado $w_j(n+1)$ no tempo $n+1$, chega-se a equação aplicada a todos os neurônios da rede que se encontram dentro da vizinhança do neurônio i , definido por Kohonen e Ritter:

$$w_j(n+1) = w_j(n) + \alpha(n) h_{j,i(x)}(n)(x - w_j(n)) \quad (58)$$

Sendo

$\alpha(n)$: o parâmetro da taxa de aprendizagem

Como $\alpha(n)$ deve ser variável no tempo, e o seu valor inicial α_0 deve decrescer gradualmente com o aumento do tempo n , temos que

$$\alpha(n) = \alpha_0 \exp\left(-\frac{n}{\tau_2}\right) \quad n = 0, 1, 2, \dots \quad (59)$$

Sendo

τ_2 : outra constante de tempo do algoritmo SOM.

Resumindo, cada vetor de dados é a entrada da rede e o número de saídas é representada pela quantidade de neurônios. No treinamento, a rede determina qual saída responderá melhor ao vetor de entrada, até ser escolhida a saída vencedora. Assim, o vetor de pesos para o neurônio vencedor e de seus vizinhos tem os valores atualizados, segundo Silva [60].

A Figura 20a mostra a localização dos dados e os pesos dos vetores. A figura ainda indica a distribuição dos neurônios no espaço bidimensional. A Figura 20b ilustra outra visualização indicando as distâncias entre os neurônios vizinhos, onde os hexágonos azuis são os neurônios, as linhas vermelhas mostram as conexões entre os neurônios vizinhos, as cores mais escuras representam distâncias maiores e as cores mais claras indicam pequenas distâncias.




Figura 20 - a) Posição dos Neurônios, b) Distância entre os Neurônios (*MathWork, Matlab®*).

Na Figura 21, pode-se ver a quantidade de dados que foram agrupados em cada neurônio, sendo esta visualização a melhor para observar a distribuição de quantos dados teve cada neurônio ou *cluster*.




Figura 21 – Distribuição de dados por Neurônio (*MathWork, Matlab®*).

3.6 Considerações Finais do Capítulo

Este capítulo descreveu os algoritmos de inteligência computacional utilizados neste trabalho, suas características, configurações e aplicabilidade em diversas áreas. Tendo um destaque maior para a lógica *Fuzzy* e para as Redes Neurais Artificiais.

CAPÍTULO 4 – METODOLOGIA

Neste capítulo será abordada a metodologia desenvolvida para a estimação de consumo energético e da curva de demanda de um edifício público que tem seu procedimento descrito a seguir explicando cada passo da construção da mesma.

4.1 Introdução

Conforme ilustrado na Figura 22, a metodologia é dividida em três áreas distintas, onde foram utilizados métodos matemáticos e algoritmos que fazem parte da inteligência computacional, para o seu desenvolvimento.

As aquisições dos dados históricos de energia consumida e de outras variáveis que serviram para a metodologia entram na fase de Pré-Processamento. Onde é realizada a preparação dos dados para serem analisados. Em seguida vem a fase de normalização dos dados, sendo retirada a energia de consumo dos dispositivos elétricos do edifício em *Stand-by*, analisa-se assim apenas a variação de energia no período de trabalho do edifício. Quanto a aquisição de dados das outras variáveis, sendo por exemplo da temperatura ambiente, é realizado uma correlação com os dados históricos para análise de quanto uma variável esta relacionada a outra, sendo eliminada do processamento as que tiverem correlação fraca.

Após o pré-processamento dos dados, são aplicados algoritmos de inteligência computacional para a fase de estimação da curva, sendo inicialmente classificado pelo algoritmo do Mapa de Kohonen e a partir dessa primeira classificação um segundo processo de classificação é feito pelo algoritmo KNN, realizado para averiguar possíveis divergências quanto à curva pertencer a certo agrupamento. Com base na classificação feita pelo KNN é construído e configurado a lógica *Fuzzy* para a terceira classificação, como intuito de encontrar divergências entre curvas e agrupamentos. Em seguida um quarto processo é realizado para a estimação da curva, verificando a maior quantidade de vezes, que uma curva foi escolhida para um dado dia, sendo este o ultimo critério de estimação da curva.

A próxima fase da metodologia corresponde a estimação da demanda diária do edifício, tendo como entrada os dados do pré-processamento e da definição da curva estimada. Nesta fase são estimadas as demandas por regressão polinomial e por Redes Neurais Artificiais, onde é realizada uma reconstrução da curva com o valor estimado pelo

ajuste polinomial e pela RNA, servindo para critério de comparação e análise de qual método apresentará menor erro de estimação.

A seguir é detalhado cada passo da metodologia desenvolvida, sendo ordenado por área e subáreas conforme ilustrado na Figura 22.




Figura 22 – Fluxograma da metodologia.

4.2 Pré-Processamento

4.2.1 Normalização dos Dados

O primeiro passo para analisar dados energéticos (curvas de carga ou de demanda) coletados ao longo de um período temporal e armazenados em um banco de dados é selecionar um intervalo amostral com características repetitivas/cíclicas, revelando as variabilidades sempre dentro do mesmo intervalo. Assim seleciona-se uma quantidade de pontos observados, na maioria das vezes em função do tempo, podendo ser uma janela amostral de uma hora, um dia, uma semana, um mês, um ano, etc.

A normalização dos dados serve para observar as variabilidades que podem acontecer dentro de um espaço amostral, mas não levando em conta os valores máximos de comportamento das variáveis analisadas e sim para comparar suas formas, observando sua semelhança ou não.

A normalização de dados pode ser feita analisando a amplitude dos valores ou sua dispersão, segundo Rodrigues [61]. Neste trabalho, foi utilizada a normalização segundo a amplitude, para colocar todas as curvas no mesmo intervalo [0-1]. Para cada intervalo de dados (um dia), determinou-se a curva normalizada ou a curva por unidade. Assim a demanda a cada minuto é dividida pelo valor máximo da demanda do dia considerada como valor base, conforme a Equação (60). Desta forma, elimina-se os valores das demandas e passa-se a observar as proporções entre demandas para um mesmo dia.

$$Di_{pu} = \frac{D_{id}}{D_b} \quad (60)$$

Onde:

Di_{pu} - demanda no intervalo i por unidade

D_{id} - demanda observada a cada intervalo de tempo i

D_b - demanda máxima observada no dia sob análise.

Objetivando realizar a previsão do uso energético em edificações, é necessário selecionar os dados por características semelhantes. No estudo de edificações comerciais e de serviços, onde o período de trabalho se resume aos dias úteis, os dados referentes aos finais de semana ou feriados devem ser separados dos demais. Outro ajuste importante é o do horário de verão. Os sistemas e dispositivos eletrônicos que coletam os dados de energia não alteram o relógio. Como as atividades humanas ocorrem de forma distinta, é essencial considerar o horário de verão para que os usos energéticos sejam ajustados para o horário de expediente, e possam ser processados sem distinção.

4.2.2 Retirada do *Stand-by*

Uma amostra típica de um período diário da curva de carga de uma edificação comercial é apresentada na Figura 23. A curva possui características distintas no período de expediente e fora deste período. O aumento da demanda (y) ocorre próximo ao horário de início do expediente, devido à preparação da edificação para o início das atividades, tais como: limpeza, resfriamento antecipado da edificação, ligação de elevadores, chegada antecipada de funcionários. Assim, o aumento da demanda se dá antes do expediente e de forma gradativa, dependendo da edificação [64]. O uso energético pode ser diferente no

período da manhã e da tarde dependendo dos recursos utilizados, podendo ainda apresentar um vale no período do almoço. É comum outros equipamentos elétricos ficarem ligados fora do horário de expediente, como geladeiras, bebedouros, lâmpadas, computadores usados como servidores em determinadas empresas, equipamentos de segurança eletrônica como sensores e alarmes.




Figura 23 – Esboço de curva de carga típica de uma edificação comercial.

Considerando o consumo energético de uma edificação, algumas análises podem ser feitas sobre este gráfico da curva de consumo, conforme diz Capehart [62]. A Figura 24 ilustra uma dessas análises.




Figura 24 – Análise de uma curva de carga.

Sendo:

h_i – horário de início das atividades no edifício

h_f – horário fim das atividades no edifício

D_{sb} – Consumo de energia em Stand-by

E_{sb} – Energia em Stand-by consumida entre $0h < t < h_i$ e $h_f < t < 24h$

E_{base} – Energia de base: Energia consumida entre $h_i < t < h_f$ considerando a D_{sb} neste período

E_{tr} – Energia consumida no horário de trabalho, retirada a Ebase.

A E_{base} não pode ser considerada como uma energia de *stand-by* uma vez que os equipamentos neste horário estão em funcionamento efetivo e portanto realizando trabalho. Por exemplo, o óleo do compressor de um sistema de ar-condicionado deve permanecer aquecido para atingir a viscosidade correta de trabalho. Antes de se ligar um sistema de condicionamento de ar, deve-se ligar o sistema (em repouso) por pelo menos 30 minutos antes da partida da máquina. Este e outros dispositivos consomem energia mesmo sem a máquina estar ligada gerando frio. Esta energia é considerada de *stand-by* enquanto a máquina estiver desligada e de base quando esta estiver funcionando. Assim, a demanda solicitada (D_{sb}) por estes sistemas auxiliares é a mesma ao longo das 24h, caso permaneçam ligados por todo este período, mas a energia consumida fora do horário de trabalho é denominada *stand-by* e no horário de trabalho é denominada Energia de Base. Desta forma, após a determinação de D_{sb} pode-se determinar facilmente E_{tr} , eliminando E_{base} e E_{sb} . Como a E_{base} e E_{sb} são praticamente constantes, a previsão de carga deve ser feita para E_{tr} , evidenciando os valores que se alteram de um dia para outro.

A partir deste levantamento feito nos dados observados, é possível estabelecer a quantidade de energia consumida pelo edifício em períodos cíclicos, por exemplo diariamente, mensalmente e sazonalmente. Com isso tem-se o perfil de comportamento energético do edifício ou do consumidor analisado, servindo como base para a transformação desses dados em informações relevantes.

4.2.3 Correlacionar os Dados Levantados

Na previsão de carga é necessário determinar quais fatores externos que influenciam na variabilidade encontrada no consumo energético. Assim, é necessário levantar outras fontes de dados deste edifício e avaliar seus efeitos no uso energético, como por exemplo: o fluxo de pessoas no edifício, quantos e quais são os equipamentos eletrônicos utilizados, como é feito o acionamento destes equipamentos, de forma manual ou automática, a temperatura e a umidade do ar interna e externa do ambiente do edifício.

Estes novos dados podem ser obtidos através de sistemas de monitoramentos no qual não apenas a energia elétrica é monitorada, mas também diversos outros dados relevantes, conforme foi citado. Em outros casos deve ser considerado que o sistema de monitoramento, coleta dados apenas de energia, sendo necessário então buscar em outros sistemas de monitoramento dos dados para a complementação da análise.

Dados como a temperatura diária e umidade do ar externa ao ambiente do edifício podem ser obtidas através de centros de medições meteorológicas que estejam nas proximidades da edificação. Outros tipos de dados como fluxo de pessoas e tipo de

acionamento dos equipamentos elétricos dependem de sistemas de monitoramento mais específicos, e difíceis de serem implantados devido ao alto custo e disponibilidade do edifício. Na impossibilidade, são feitas entrevistas e observações para auxiliar no processo de análise.

Obtendo-se os dados levantados das diversas variáveis disponibilizadas, faz-se uma análise para averiguar a correlação entre os dados observados com o consumo energético, este tido como um comportamento de referência. A Figura 25 ilustra os diferentes tipos de dados que podem influenciar o consumo de energia da edificação.




Figura 25 – Dados que podem influenciar na estimativa de energia.

Após verificada a relação entre as variáveis disponibilizadas, faz-se uma análise para averiguar quais das variáveis monitoradas possuem uma correlação forte com a variável de consumo energético, sendo esta a variável de saída. Assim como o objetivo desta metodologia é estimar valores de consumo energético, toma-se como referência nesta análise a variável que normalmente mais influência nas variações da energia em edificações climatizadas que é a temperatura externa do edifício.

4.3 Estimativa da Curva de Consumo

Nesta fase é necessário analisar os diferentes comportamentos das curvas de cargas obtidas diariamente e classificá-las conforme as características apresentadas. Para isso utiliza-se ferramentas da inteligência computacional para agrupá-las de forma a identificar as semelhanças de cada curva. A seguir apresenta-se métodos de Inteligência Computacional que foram utilizados.

4.3.1 Mapa de Kohonen (SOM)

Inicia-se a definição de quantos grupos de curvas serão usados pelo algoritmo de Mapas Auto-Organizáveis de Kohonen, ou do inglês *Self Organizing Maps* (SOM), de forma empírica, até que se chegue à uma quantidade de grupos de curvas que apresentem características semelhantes significativas, justificando a separação e criação de agrupamentos.

4.3.2 K-Nearest Neighbor (KNN)

A partir da classificação anterior utiliza-se um segundo algoritmo para validar este primeiro processo, denominado de *k-Nearest Neighbor* (KNN), com isso averigua-se possíveis curvas que apresentam características diferentes, daquele agrupamento no qual fazem parte.

4.3.3 Lógica Fuzzy

Usando como base a classificação feita pelo algoritmo KNN, inicia-se o algoritmo da lógica *Fuzzy* para realizar a terceira classificação das curvas. Com a definição dos agrupamentos é construído por um mapeamento com outro algoritmo proveniente da lógica *Fuzzy*, denominada de *Fuzzy C-Means*. Auxiliando nas definições e configurações de qual tipo de curva predominou para uma determinada faixa de temperatura.

Sendo esta variável determinada como partição do universo *Fuzzy* analisado, já que a variável temperatura externa, teve maior correlação com a curva de demanda. Dessa forma são definidos os conjuntos *Fuzzy* utilizados nesta lógica e configurado os demais parâmetros.

4.3.4 Maior Frequência de Ocorrência

Após obter-se estes três critérios de agrupamento é realizado um quarto e último processo para classificar as curvas. Neste último critério, a classificação é feita baseado nas respostas oferecidas pelos três algoritmos utilizados, SOM, KNN e *Fuzzy*, identificando para cada dia qual foi a curva que se repetiu mais vezes dentro dos três critérios utilizados.

Caso em um dado dia, cada um dos critérios apresentar curvas diferentes entre si, apenas um dos critérios de classificação deve ser utilizado como referência. Para isso deve-

se verificar separadamente qual dos critérios de classificação utilizados (SOM, KNN e *Fuzzy*) apresentou o menor índice de erro em comparação com os comportamentos das curvas de dados históricos. Com o banco de dados analisado, obteve-se um total de 134 curvas no período anual averiguado.

4.4 Estimação de Energia

4.4.1 Regressão Polinomial

Conforme Jota [63], os dados monitorados da temperatura externa e o consumo de energia de edifícios condicionados possuem normalmente uma correlação forte. A Figura 26 ilustra uma análise entre a energia e a temperatura externa.




Figura 26 – Correlação entre energia e temperatura

Sendo:

t_i – temperatura inferior

t_s – temperatura superior

R_1 – Região 1: O consumo energético independe da variação de temperatura

R_2 – Região 2: O consumo energético se correlaciona com a temperatura

R_3 – Região 3: O consumo energético satura, não havendo aumento do consumo de energia com o aumento de temperatura.

Para este tipo de análise, algumas observações devem ser destacadas. Nas regiões R_1 e R_3 , observa-se que o consumo de energia, identificado pelos valores do eixo Y, praticamente não se altera com a temperatura. Espera-se que para climas temperados, em dias com temperatura abaixo de t_i não ocorra o acionamento de equipamentos de condicionamento de ar e portanto, não há correlação entre temperatura e energia nesta faixa

de temperatura. Para temperaturas altas, espera-se que todos os equipamentos de condicionamento de ar já estejam trabalhando no máximo da sua capacidade, não possibilitando que o aumento de temperatura acima de t_s cause aumento na energia consumida (efeito de saturação).

Assim, caso possam ser detectados regiões como R_1 e R_3 , deve-se ter tratamentos diferenciados para dias que apresentem temperaturas nesta faixa. Normalmente a energia consumida nestes dias não irá variar com a temperatura. Para temperaturas médias localizadas na região R_2 , deve-se ajustar uma curva que melhor represente os dados coletados. Neste caso, pode-se realizar o ajuste polinomial e realizar a estimativa do consumo do dia em função da temperatura média prevista para o dia.

4.4.2 Redes Neurais Artificiais (RNA)

O funcionamento do algoritmo ocorre com a definição das variáveis que esta rede neural irá utilizar. Utilizando as variáveis de temperatura externa e consumo energético, a primeira é fornecida à rede neural como a entrada de dados do algoritmo. Já na saída da rede é fornecido os valores de consumo energético. Fazendo-se assim, para um dado valor de temperatura a rede neural deve estimar o consumo de energia diária (E_T).

Desta maneira treina-se o algoritmo com o objetivo da RNA aprender o comportamento destas variáveis de dados históricos e a partir da generalização dos dados de entrada, ou seja, com novos valores de temperatura fornecidos através da previsão meteorológica, estimar qual será o consumo energético diário do edifício.

Obtêm-se assim dois parâmetros de estimação (regressão polinomial e por redes neurais artificiais) para comparação e análise de qual apresentará menor erro de previsão.

4.4.3 Reconstrução da Curva

Nesta última fase da metodologia, de posse da energia estimada pelos polinômios e pela RNA e da curva mais provável normalizada pelo quarto critério de classificação mencionado, passa-se para a fase de reconstrução da curva final estimada. Nesta fase, a curva normalizada é reconstruída com o valor da demanda estimada, conforme a Equação (61).

$$D_{max} = \frac{E_T}{\frac{1}{60}(\sum D_{ipu})} \quad (61)$$

Onde

D_{max} - é a demanda máxima do dia

E_T - é a energia diária estimada

D_{ipu} - é a demanda no intervalo i por unidade.

Com a demanda máxima (D_{max}) corrigida de 1 pu (100%) para o valor calculado pela Equação (61), todos os demais valores de demanda (D_{ipu}) serão corrigidos automaticamente, pois são proporções de D_{max} .

4.5 Considerações Finais do Capítulo

A metodologia apresentada descreve como foi desenvolvido o processo de previsão de dados de consumo energético de uma edificação. Essa metodologia também pode ser implementada para outros tipos de consumidores de energia para estimação de curva de carga desde que seguidos os procedimentos apresentados. No próximo capítulo, um estudo de caso utilizando a metodologia será apresentado para ilustrar os passos propostos.

Um detalhamento a respeito dos parâmetros e configurações dos algoritmos utilizados, será detalhado no Apêndice 3 deste trabalho.

CAPÍTULO 5 – ESTUDO DE CASO E ANÁLISE DOS RESULTADOS

Neste capítulo é apresentado um estudo de caso e análise dos resultados obtidos pela aplicação da metodologia para previsão da curva de consumo energético e de demanda de uma edificação.

O edifício público do DER (Departamento de Estradas de Rodagem), que foi estudo de caso deste trabalho, encontra-se em Belo Horizonte localizado no hipercentro da cidade, próximo ao Parque Municipal e região dos hospitais. O edifício apresenta um formato retangular com uma área total de 10159 m², distribuídos em dez andares. Parte da sua iluminação é obtida de forma natural, através de painéis de vidro que revestem uma de suas fachadas, podendo proporcionar ventilação também, pois os painéis de vidro apresentam aberturas, conforme a Figura 27 [63].



Figura 27 – Vista do edifício DER/MG.

Suas atividades principais se concentram no horário comercial entre os dias da semana, trazendo uma padronização ao sistema de trabalho do edifício. Este tipo de edifício apresenta durante o dia um padrão sazonal de perfil de consumo. Durante a noite, feriados e finais de semana, o consumo energético é baixo. Também apresenta um padrão de consumo energético no início e no fim do dia de trabalho e no horário de almoço. O sistema de Ar Condicionado do edifício é controlado manualmente com critérios subjetivos do operador para se controlar a temperatura [65], sendo este o caso do edifício em estudo.

5.1 Pré-Processamento

Os dados de medição energética foram obtidos através de monitoramento de forma contínua durante um ano pelo projeto CMUF – Centro de Monitoramento de Usos Finais [25], o qual monitorou de forma estratificada 53 tipos de cargas diferentes do edifício com uma taxa de amostragem de um minuto.

O CMUF foi concebido para atender à demanda das edificações que passam por processos de efficientização. Possibilita que o consumo de energia seja detalhado tanto quanto necessário. Para isso, sensores especialmente desenvolvidos são espalhados pela edificação, medindo tensão e corrente elétrica, fator de potência em circuitos ou cargas que forem necessárias. Pode ser também medidas variáveis ambientais como temperatura, umidade interna e externa, luminosidade, de forma a correlacionar os dados buscando a causa-e-efeito do consumo de energia.

Um levantamento da curva de carga diária do edifício foi realizado, assim podendo ser analisado as suas variações ao longo de um ano, considerando as sazonalidades de consumo, em decorrência da variação do clima, influenciando o acionamento do sistema de ar condicionado existente [63] , [66] e de eventos atípicos que alteram a rotina de trabalho deste edifício. A curva de carga de um dia útil desse edifício é apresentada na Figura 28.




Figura 28 – Curva de carga típica do edifício analisado.

5.1.1 Aplicação da Retirada da Energia em *Stand-By*

O edifício apresenta uma energia consumida em modo *Stand-by* (D_{sb}) elevada, consumindo energia fora do horário de funcionamento do edifício. Como dito no capítulo anterior, a maior parte do consumo da energia em modo *Stand-by* se deve ao sistema de ar-condicionado que mantém ligado partes do sistema mesmo que o mesmo seja considerado desligado [63]. Este por sua vez é acionado manualmente conforme a sensação térmica dos ocupantes ao longo do dia. Em decorrência disso, espera-se que a temperatura externa possa estar relacionada ao consumo de energia deste edifício, já que temperaturas externas elevadas fazem com que o condicionamento de ar seja acionado.

Entretanto, por ser acionado manualmente, o acionamento não ocorre sempre no mesmo horário, apresentando curvas com características de consumo diferenciadas.

Para o processamento desses dados, foi retirada a parte de energia correspondente ao consumo de equipamentos em *Stand-by* (D_{sb}) do edifício, que representa uma faixa contínua de demanda com um consumo de aproximadamente 1,64 MWh. Dias atípicos, finais de semana, feriados e férias, por apresentarem comportamentos de consumo fora dos padrões, não foram analisados neste trabalho.

5.1.2 Aplicação da Temperatura Prevista

Para avaliar essa dependência do consumo com as variáveis climáticas, foram coletadas as temperaturas na região próxima do edifício diariamente, durante o ano analisado. Esta temperatura foi monitorada pelo centro de medição meteorológico INMET [67], onde obteve-se a temperatura para três horários distintos durante o dia, sendo uma medição realizada às 0 h, outra às 12 h e a última às 18 h.

5.1.3 Correlação entre Dados

Propôs-se analisar a correlação entre as temperaturas nas faixas de 0, 12 e 18 horas (horários disponíveis para análise) e o consumo diário de energia do edifício.

Verificou-se que a temperatura possui forte correlação com a variação de energia consumida neste edifício. Não apenas a temperatura foi considerada para esta análise de estimação de consumo, mas também fatores como dias úteis, finais de semana e estações do ano.

Observou-se uma melhor correlação entre os dados de temperatura nas faixas de 12 e 18 horas e a energia consumida diariamente. Por isso foram utilizadas duas variáveis sendo cada uma, as faixas de monitoramento de 12 e 18 h da temperatura. A Figura 29 ilustra a curva de ajuste da correlação entre a temperatura às 12 h com o consumo energético diário, que apresentou o menor Erro Médio Quadrático (*Root Mean Square Error* - RMSE).




Figura 29 - Relação entre a temperatura (faixa de 12h) com a energia consumida.

Foram feitos ajustes polinomiais de segunda ordem, entre as variáveis e avaliou-se o RMSE, Tabela 1.

	TEMPERATURA		
	0h	12h	18h
RMSE	140,4	108,1	112,2

Tabela 1 - RMSE entre energia x temperatura.

5.2 Estimação da Curva de Consumo

Neste passo, os dados históricos da medição de energia do edifício são analisados para levantar as diferentes curvas de carga ao longo do ano. Para realizar esta classificação, as curvas foram normalizadas e classificadas utilizando técnicas de agrupamento, de diferentes algoritmos de inteligência computacional.

Antes de se aplicar qualquer técnica de cálculo de proximidade, deve-se normalizar todos os dados, uma vez que deseja-se comparar o formato da curva e não os valores assumidos em cada caso.

A fase de agrupamento ou *clustering*, denominado em inglês, das características semelhantes das curvas levantadas, se deu através de uma série de implementações de técnicas e algoritmos que utilizam ferramentas da inteligência computacional para tal finalidade. A separação de um conjunto de objetos em grupos de itens que são mais semelhantes entre si do que itens de outros grupos de forma automática definem afinidades e similaridades entre os elementos do grupo, colocando os mais semelhantes no mesmo grupo [68].

Dessa forma, o *clustering* se torna uma ferramenta útil para análises de dados em diversas situações podendo ser usado para redução de dados e extração de características escondidas dos dados, assim podendo ser desenvolvidos hipóteses a respeito da natureza dos mesmos.

A seguir é descrito como se deu todo o processamento dos dados para esta classificação.

5.2.1 Aplicação do Mapa de Kohonen

Inicialmente, na fase de processamento de classificação dos dados, utilizou-se o algoritmo de Mapas Auto-Organizáveis de Kohonen (*Self Organizing Maps*) SOM através da função “selforgmap” do *software Matlab®*. Para a fase de agrupamento, foi realizada, primeiramente, a averiguação da utilização de quatro neurônios para classificar as curvas, obtendo a seguinte distribuição das quantidades de curvas por neurônio.




Figura 30 – Agrupamento pelo algoritmo SOM através do *Matlab*® (configurado pelo autor).

Outros testes foram realizados aumentando a quantidade de neurônios utilizados, para que fosse justificado a utilização de quatro neurônios. Percebeu-se que quando novos neurônios são criados, ocorre uma subdivisão das curvas com a mesma característica, gerando agrupamentos de curvas de carga que se repetem em agrupamentos menores. Apenas os grupos com menor quantidade de curvas sofrem essa partição, não justificando a criação de novos grupos.

Acredita-se que a segregação dos grupos em grupos menores se deve ao tamanho da área que a curva proporciona, mas como estas pequenas variações não descaracterizam o comportamento da curva, não justificando a segregação desse grupo.

Dessa forma, foram caracterizados 4 perfis de curvas que se alternam ao longo do ano, como pode ser visualizado na Figura 31.




Figura 31 - Grupos de classificação da curva de carga normalizada.

Com o agrupamento de curvas realizado, foi calculado dentro de cada agrupamento a curva média referente as curvas classificadas em cada grupo, sendo denominadas neste trabalho como curvas típicas.

Segundo Capehart [62], a representação da curva média de cada grupo, estabelece os comportamentos padrões das curvas típicas que acontecem ao longo do ano analisado. Uma análise estatística da energia consumida é calculada por hora, estabelecendo assim um gráfico de *boxplot* por hora. O conjunto de todas as horas do dia ilustra o comportamento médio de consumo. A Figura 32 demonstra este comportamento de consumo médio das curvas pertencentes do grupo 1. Observa-se as medianas, representadas pelos círculos destacados ao centro das caixas azuis e os percentis 75 e 25 %, extremos das caixas azuis. Os círculos azuis, de menor frequência de ocorrência, representam os *outliers*.




Figura 32 – Consumo médio por hora de um dia [62].

Na Figura 33 é ilustrado o comportamento de consumo médio dos 4 agrupamentos. Os pontos em azul representam os valores medidos a cada minuto de cada um dos dias, chegando a mostrar os pontos máximos e mínimos do agrupamento e a parte em negrito representa as caixas (percentis entre 75 e 25%) dos valores medidos para cada minuto. Não é possível visualizar os valores medianos, entretanto é possível acessar este dado.




Figura 33 – Curva média típica [62].

5.2.2 Aplicação do *K-Nearest Neighbor*

De posse das curvas típicas para cada agrupamento obtidas no item anterior, foi utilizado o algoritmo de Pontos por proximidade de vizinhança (*k-Nearest Neighbor*) KNN, para averiguar a proximidade dos pontos que compõe as curvas típicas com as curvas obtidas durante o ano e comprovar se certa curva estaria coerente de pertencer ao agrupamento que foi destinado pelo algoritmo SOM. A seguir, é apresentado um exemplo de averiguação de um dia que apresentou uma divergência de agrupamento. Esta averiguação é realizada a partir da análise dos pontos que estão próximos das curvas típicas testadas. Cada ponto considerado próximo é marcado com um círculo. Quanto maior é o número de círculos, mais

pontos estão próximos das curvas tidas como referência, ou seja as curvas típicas. Para utilização desse algoritmo foi utilizado a função “rangesearch” do *software Matlab®*.

A curva em vermelho representa a curva típica de cada grupo e a curva em negrito representa um dia testado, neste caso sendo o dia 3 de Abril, e a parte em cinza refere aos pontos da curva diária que estão próximos da curva típica.




Figura 34 - Agrupamento pelo algoritmo KNN.

Percebe-se que há um critério diferenciado quanto a classificação, sendo que pelo algoritmo SOM, o dia 3 de Abril pertenceria ao grupo 4 (526 pontos próximos) e por KNN este dia pertenceria ao grupo 1, que só apresentou 514 pontos próximos. Esse tipo de divergência aconteceu em 35% dos dias analisados, caracterizando uma baixa divergência entre as curvas classificadas, tanto pelo algoritmo SOM quanto pelo KNN.

5.2.3 Aplicação da Lógica Fuzzy

Para utilizar o critério de classificação por lógica *Fuzzy* foi necessário realizar um mapeamento de qual tipo de curva típica teria maior tendência em acontecer para uma determinada faixa de temperatura analisada. Por averiguar a proximidade dos pontos discretos das curvas ou séries temporais, o critério de classificação KNN foi utilizado como referência para a utilização da lógica *Fuzzy*, (qualquer um dos critérios utilizados poderia ser usado para classificação *Fuzzy*). Assim foi utilizado a classificação KNN para a caracterização das curvas e mapeamento por estação do ano em relação às temperaturas medidas nas faixas de 12 e 18h. Observa-se, assim, a necessidade de utilizar um critério de agrupamento para auxiliar no algoritmo desenvolvido com a lógica *Fuzzy*.

Para configurar os parâmetros utilizados na lógica *Fuzzy*, foi necessário realizar primeiramente o mapeamento de qual curva típica aconteceu para determinadas faixas de temperaturas, assim cada tipo de curva foi identificado por uma cor. Para cada conjunto de pontos com a mesma cor era definido um ponto central, no qual ele seria equidistante entre todos os pontos apresentados por aquele agrupamento. Para definir esse ponto central foi utilizado o algoritmo *Fuzzy C-Means* que indica o ponto central-equidistante daquele agrupamento através da identificação “X”, com a cor correspondente a aquele agrupamento. Esse algoritmo foi utilizado com a função “fcm” do software *Matlab*®. Em alguns casos havia uma grande concentração de pontos ficando inviável definir apenas um único ponto central, neste caso foi configurado para o algoritmo *Fuzzy C-Means* definir dois pontos centrais, sendo que os pontos centrais eram definidos onde houvesse uma região com maior quantidade de pontos. A configuração dos parâmetros do algoritmo da lógica *Fuzzy*, segue ao que foi apresentado por Gomes e Jota [69], e também é mostrado no Apêndice 3 deste trabalho. O mapeamento da estação de Inverno é demonstrado na Figura 35 para exemplificar o processo.




Figura 35 – Mapeamento utilizando na lógica *Fuzzy*.

Dessa forma foi adotado que os pontos centrais definem a inferência máxima do conjunto *Fuzzy*, ou seja, tem o valor de 1, decrescendo o valor dessa inferência conforme o distanciamento para os outros pontos naquela região do agrupamento. Visualmente é definido como o formato de uma pirâmide, sendo o pico da pirâmide o ponto máximo ou de inferência 1 e a base da pirâmide tem a inferência mínima ou zero. A Figura 36 ilustra essa visualização.




Figura 36 – Mapeamento da Inferência dos conjuntos *Fuzzy*.

Conforme observa-se na Figura 36 a sombra das pirâmides configuram os limites das temperaturas na função triangular dos conjuntos *Fuzzy* na partição de 12 h (que tem as temperaturas de 14 até 26°C) e na partição de 18 h (que tem as temperaturas de 16 a 32°C). As definições do mapeamento *Fuzzy* das outras estações do ano, são mostradas no Apêndice 2 deste trabalho.

Através do toolbox da função “fuzzy” do software *Matlab*®, foi possível configurar os conjuntos das partições conforme as sombras das pirâmides demonstrados na Figura 36 como podemos observar na Figura 37.




Figura 37 – Conjuntos das partições *Fuzzy* através do Matlab® (configurado pelo autor)

As temperaturas mínimas e máximas de cada partição *Fuzzy* foi configurado para ter a inferência máxima ou 1 nas suas extremidades para que não ocorresse o problema de ter uma faixa de temperatura que não estivesse contemplada por um conjunto *Fuzzy*, inviabilizando o funcionamento da mesma. A escolha das curvas acontece com a resposta defuzzificada, indicando qual grupo ou qual curva típica, pertenceriam os dados de temperatura estimados, conforme mostra a Figura 38.




Figura 38 – Conjuntos de respostas *Fuzzy* através do Matlab® (configurado pelo autor)

As regras de inferência *Fuzzy* são definidas com o cruzamento entre a faixa de temperatura que uma das pirâmides engloba na partição 12 h com a faixa de temperatura da partição de 18h, dessa forma não ocorre à possibilidade de que alguma faixa de temperatura não tenha uma curva típica estabelecida. Na Figura 39 é demonstrado as regras de inferência *Fuzzy*.




Figura 39 – Regras Fuzzy através do *Matlab*® (configurado pelo autor)

A elaboração das regras *Fuzzy*, aconteceu da seguinte forma: Analisando um dado (temperatura) da partição de 12h, verifica-se o grau de inferência que este dado possui em relação aos conjuntos *Fuzzy* (variáveis linguísticas), acontecendo o mesmo procedimento para a partição de 18h. Depois do resultado defuzzificado, foi determinado faixas de respostas de 0 a 1, que define a qual conjunto *Fuzzy* de resposta (ao grupo de curva), aquela temperatura pertence.

Exemplo: SE (T12 $\in$ G1) E (T18 $\in$ G3) ENTÃO (curva $\in$ G3).

Assim percebe-se que a parte da elaboração da lógica *Fuzzy*, não acontece de forma automática como acontece com os outros algoritmos que precisam receber apenas um banco de dados. A utilização da lógica *Fuzzy* neste trabalho depende de ajustes feito por um especialista, para depois de configurado, utilizar como dados de entrada as duas

temperaturas previstas diariamente nas faixas de 12 e 18 h e consequentemente ter como saída do algoritmo *Fuzzy* a indicação da curva típica estimada.

Averiguando algumas sobreposições de conjuntos *Fuzzy* nas partições mencionadas, foi realizado também um teste, eliminando alguns conjuntos *Fuzzy* que estavam sobrepostos a outros, refazendo também o sistema base de regras *Fuzzy*, conforme é mostrado na Figura 40.




Figura 40 – Eliminação de alguns conjuntos *Fuzzy*.

Não houve diferença significativa nas respostas obtidas com a eliminação de alguns conjuntos sobrepostos, sendo que a maioria das classificações conseguidas com a defuzzificação coincidiram com os conjuntos sobrepostos, conforme mostrado na Figura 37.

5.2.4 Aplicação da Maior Frequência de Ocorrência

Após o processo de classificação e caracterização das curvas de consumo energético (primeiramente por estações do ano, considerando sua sazonalidade e em seguida dentro de cada estação do ano analisando o comportamento de consumo do edifício analisado), estabeleceu-se três algoritmos para classificação das curvas típicas de consumo energético da edificação analisada neste trabalho.

Onde para cada dia analisado, verificou-se qual curva de consumo seria prevista para o próximo dia.

Como descrito anteriormente, o primeiro passo de classificação se deu através do algoritmo SOM (*Self Organizing Maps*), que utiliza a arquitetura das redes de Kohonen. Também foi utilizado o algoritmo de classificação KNN (*k-Nearest Neighbor*) contribuindo para mais um critério de classificação e terceiro foi a lógica *Fuzzy* que classificou as curvas de consumo energético típicas conforme o par de temperaturas previstas diariamente nas faixas de 12 e 18 horas.

Um quarto critério de classificação foi criado considerando o maior número de repetições das curvas que acontece conforme as três classificações estabelecidas para cada dia analisado, e que neste trabalho será denominado de 4C. Para exemplificar, considere que para o dia 8 de novembro, teve-se a seguinte classificação: SOM = curva 2, Fuzzy = curva 1 e KNN = curva 1, como a curva 1 teve a maior quantidade de repetições então para este quarto critério utilizado, no dia 8 de novembro fica previsto que aconteceria a curva 1. Caso em um dado dia analisado cada um dos critérios apresente curvas diferentes, ficou estabelecido para este trabalho que a classificação feita pelo algoritmo SOM, seria a referência, por ter apresentado o menor erro de classificação entre os algoritmos que verificam o banco de dados automaticamente.

5.3 Estimação de Energia

5.3.1 Aplicação da Regressão Polinomial

Construiu-se duas curvas, sendo que a primeira relaciona o consumo de energia com a temperatura medida às 12 h e a outra com a temperatura medida às 18h. Estas temperaturas podem ser obtidas previamente, através de estações de monitoramento e previsão meteorológicas. Portanto, obtém-se os valores de temperatura prevista para estes horários e estima-se a energia a ser consumida pela edificação, a partir dos polinômios ajustados, extraídos através da regressão não linear por mínimos quadrados. O ajuste de curvas em relação aos dados foi realizado com a função “cftool” do *software Matlab®*. As Equações (62) e (63) apresentam os polinômios encontrados para a edificação em estudo.

$$E_{12}(T_{12})=33,32*T_{12}^2-1015*T_{12}+8835 \text{ (kWh)} \quad (62)$$

$$E_{18}(T_{18})=21,37*T_{18}^2-770,5*T_{18}+8070 \text{ (kWh)} \quad (63)$$

Onde

E_{12} e E_{18} - energia estimada no dia, tendo como variável a temperatura no horário de 12 h e de 18 h respectivamente,

T_{12} e T_{18} - temperatura prevista em graus Celsius, para as respectivas faixas de horários.

A estimação da energia final do dia é obtida através da Equação (64), adicionando ainda o consumo dos equipamentos presentes no edifício que ficam em *Stand-by*, identificado por energia base,

$$E_T = \frac{E_{12}(T_{12}) + E_{18}(T_{18})}{2} + E_{sb} + E_{base} \text{ (kWh)} \quad (64)$$

Onde:

E_T é a energia diária estimada

E_{sb} é o consumo da energia em *Stand-by*, fora do horário de trabalho.

E_{base} é o consumo da energia em *Stand-by*, no horário de trabalho.

Com o objetivo de realizar uma comparação, foi proposto o uso de outra ferramenta para prever valores de Y ou de consumo energético, que utiliza Redes Neurais Artificiais para realizar essa segunda fase de estimação.

5.3.2 Aplicação das Redes Neurais Artificiais

A arquitetura de Redes Neurais Artificiais utilizada foi a *Multi-Layer Perceptron* (MLP), sendo utilizado 5 neurônios nas duas camadas intermediárias [70], conforme ilustra a Figura 41. A configuração da quantidade de camadas e dos neurônios utilizados nas respectivas camadas é feita de forma empírica, onde deve ser considerado a questão para qual a RNA está sendo utilizada e a experiência do analista. Os dados das temperaturas T_{12} e T_{18} e os históricos de medições de energia foram apresentadas para treinamento dessa rede, sendo que as entradas da rede são duas, as temperaturas T_{12} e T_{18} e a saída da rede é a energia estimada no dia (E_T).




Figura 41 – Arquitetura da RNA através do *Matlab*® (configurado pelo autor).

Foi utilizado neste estudo de caso, a função “feedforwardnet” do *software Matlab®*, para a construção da rede neural e a sua configuração. Testou-se os diversos parâmetros e funções de ativação do neurônio até a rede fornecer respostas, que fiquem próximas dos dados reais; portanto, deve-se configurar o algoritmo para obtenção de melhores resultados.

5.3.3 Reconstrução da Curva

Neste último passo, obtendo-se a energia estimada diariamente (E_T) pela regressão polinomial e pela RNA e da curva típica mais provável, escolhido pelo critério 4C de classificação, ou seja, pelo maior número de vezes que é estimada uma certa curva através dos critérios SOM, KNN e *Fuzzy*, passa-se para a reconstrução da curva final estimada, utilizando a Equação (61), estabelecendo assim dois parâmetros de estimação de demanda e contribuindo para uma maior precisão das previsões.

Dessa forma, os valores normalizados das curvas típicas, definidos com uma amplitude dentro do intervalo entre 0 e 1, correspondem proporcionalmente aos valores de demanda mínimo (D_{min}) e máximo (D_{max}).

5.4 Resultados

Na avaliação da precisão das curvas previstas com as curvas dos dados históricos, foi utilizado um indicador de erro de previsão denominado Erro Percentual Médio Absoluto ou MAPE (*Mean Absolute Percentage Error*) que representa a média percentual da divisão entre o erro dos dados previstos e os dados reais. Com esse indicador, foi gerado um gráfico do tipo boxplot e as tabelas que mostram a relação da mediana e do percentil 75% de erro de cada critério de classificação, por estação do ano. Também foram elaborados gráficos com histograma da relação percentual de erros pela quantidade de eventos, na estimação de energia e da demanda máxima.

As próximas Figuras 42 a 45 ilustram os resultados obtidos, com a estimação das curvas pelos algoritmos e de demanda diária, feitas por polinômio e por RNA.




Figura 42 – Estimação dos dias 6 de Abril e 11 de Maio (Outono)

Observa-se na Figura 42 que as curvas estimadas utilizando polinômios e RNA se aproximaram do comportamento do dia real.




Figura 43 – Estimação dos dias 3 de Julho e 4 de Setembro (Inverno)

O gráfico do dia 4 de setembro da Figura 43 apresentou curva distinta em alguns pontos em relação aos modelos típicos. Apesar disso a energia estimada apresenta baixo erro.




Figura 44 – Estimação dos dias 23 de Setembro e 9 de Novembro (Primavera)

O primeiro gráfico da Figura 44 apresentou um ajuste adequado, enquanto que o segundo gráfico apresenta um número de horas de trabalho medido superior ao previsto, fazendo com que o gráfico real tenha mais horas do que o estimado.




Figura 45 – Estimação dos dias 15 de Fevereiro e 7 de Março (Verão).

Na primeira curva da Figura 45, observa-se um erro elevado antes do início do expediente e também ao final, estimando um consumo de *stand-by* acima do real.

Nas próximas seções, são apresentados os resultados obtidos pelas classificações das curvas pelos métodos de inteligência computacional por período do ano.

5.4.1 Período da Estação de Outono

É apresentado na Figura 46 os resultados obtidos do erro MAPE do período da estação de Outono.




Figura 46 – Boxplot de erros MAPE de Outono.

	Classificação - Outono				Estimação - Outono	
	Fuzzy	SOM	KNN		4C	RNA
Mediana	2,12	1,3175	2,0373	Mediana	1,4784	1,8361
Erro Percentil 75%	2,8342	3,3512	3,3512	Erro Percentil 75%	2,8214	2,9022

Tabela 2 – Mediana e Percentil 75% do Boxplot de Outono.

Analisando a estação de Outono, observa-se que o critério de classificação SOM apresentou a menor mediana em comparação aos outros dois critérios de classificação. O percentil 75% ou seja, dos 75% dos dados analisados o que apresentou o menor erro foi o método *Fuzzy*. A estimação feita com a classificação 4C e a estimação de demanda diária feita pela RNA apresentaram uma baixa mediana de erro, obtendo assim estimações de consumo energético com uma diferença de aproximadamente de 1,84% entre os dados reais. No resultado geral desta estação, obteve-se respostas com erros MAPE abaixo de 5,5% entre os dados previstos e os reais.

5.4.2 Período da Estação de Inverno

É apresentado na Figura 47 os resultados obtidos do erro MAPE do período da estação de Inverno.




Figura 47 – Boxplot de erros MAPE de Inverno.

	Classificação - Inverno				Estimação - Inverno	
	Fuzzy	SOM	KNN		4C	RNA
Mediana	2,4068	2,5783	3,6683	Mediana	1,6206	1,8681
Erro Percentil 75%	6,0291	6,0937	7,0527	Erro Percentil 75%	6,0937	5,9327

Tabela 3 – Mediana e Percentil 75% do Boxplot de Inverno.

Analisando a estação de Inverno, observa-se que o critério de classificação *Fuzzy* teve a menor mediana de erros MAPE e também o menor erro percentil 75% em comparação com os outros dois (SOM e KNN). A estimação da classificação 4C apresentou uma mediana de erros com valor próximo de 1,62%, da mesma forma que a estimativa de demanda diária feita pela RNA, apresentando uma baixa mediana de erro MAPE, ficando com aproximadamente 1,86% de erros entre os dados estimados e os reais. Nesta estação a faixa de erro geral ficou abaixo de 13%, destaca-se, no entanto por apresentar pontos de disparidade de erro na faixa de 33%.

5.4.3 Período da Estação da Primavera

É apresentado na Figura 48 os resultados obtidos do erro MAPE do período da estação de Primavera.




Figura 48 – Boxplot de erros MAPE da Primavera.

	Classificação - Primavera				Estimação - Primavera	
	Fuzzy	SOM	KNN		4C	RNA
Mediana	4,2086	5,1446	5,1446	Mediana	5,1446	4,9289
Erro Percentil 75%	8,0522	8,0522	8,0522	Erro Percentil 75%	8,0522	7,5872

Tabela 4 – Mediana e Percentil 75% do Boxplot da Primavera.

Na análise da estação da Primavera, observa-se que o critério de classificação que apresentou menor erro de mediana MAPE foi pelo método *Fuzzy*, no entanto o percentil 75% de todos os três critérios (*Fuzzy*, *SOM*, *KNN*), demonstraram uma faixa de erro com valores aproximados. A mediana de erro MAPE do critério 4C também apresentou uma faixa de erro idêntica aos critérios *SOM* e *KNN*. A estimativa de consumo diário feita pela RNA apresentou uma mediana de erro abaixo do valor apresentado pela estimativa polinomial do 4C. A faixa de erro geral desta estação ficou abaixo de 16%, destacando-se por apresentar uma quantidade de dados de disparidade maior, chegando a 38% de erro entre os dados estimados e os reais.

5.4.4 Período da Estação de Verão

É apresentado na Figura 49 os resultados obtidos do erro MAPE do período da estação de Verão.




Figura 49 – Boxplot de erros MAPE do Verão.

	Classificação - Verão				Estimação - Verão	
	Fuzzy	SOM	KNN		4C	RNA
Mediana	3,3556	3,2749	3,2749	Mediana	3,2749	2,7151
Erro Percentil 75%	4,3523	4,3523	4,3523	Erro Percentil 75%	4,3523	3,6545

Tabela 5 – Mediana e Percentil 75% do Boxplot do Verão.

Na estação do Verão observa-se que três critérios de classificação (SOM, KNN e 4C) obtiveram igualmente as menores medianas de erro MAPE e o percentil 75% dos quatro critérios (*Fuzzy*, SOM, KNN e 4C) também apresentaram a mesma faixa de erro. A estimativa de consumo diário feita pela RNA apresentou uma baixa mediana de erro em comparação com a estimação polinomial do 4C. Esta estação apresentou no geral uma faixa de erros abaixo de 5,3% entre os dados que foram estimados e os dados reais.

5.4.5 Período Anual

Para englobar os dados de todas as estações do ano, foi levantado o índice anual de cada critério de classificação, correspondente a mediana e ao percentil 75% dos erros MAPE levantados, conforme mostra a Tabela 6.

	Classificação - Anual				Estimação - Anual	
	Fuzzy	SOM	KNN		4C	RNA
Mediana	3,0227	3,0788	3,5312	Mediana	2,8796	2,837
Erro Percentil 75%	5,3169	5,4623	5,7021	Erro Percentil 75%	5,3299	5,0191

Tabela 6 – Mediana e Percentil 75% do Boxplot Anual.

Foram elaborados gráficos de histograma relacionando o percentual de erro pela quantidade de eventos, ou dias, durante todo o ano analisado. O erro percentual da estimação energética é demonstrado a seguir, com os métodos polinomial e por RNA.




Figura 50 – Histograma de estimação energética anual.

Com uma análise estatística obteve-se no histograma polinomial cerca de 72,36% dos dias com erro de estimação menor que 10%. Entretanto, no histograma RNA cerca de 81,4% dos dias apresentam erro de estimação menor que 10%.

Ambos os gráficos de histograma demonstram comportamentos semelhantes, onde observa-se que o menor percentual de erro de estimação energética, ocorreu com maior frequência de ocorrência, e o maior percentual de erro da estimação aconteceu com menor frequência, caracterizando um gráfico decrescente.

O método de estimação feito com RNA, apresentou melhores resultados, tendo aproximadamente 9% dos dias analisados com erro de estimação de consumo energético abaixo de 10% a mais que o método polinomial.

A Figura 51 apresenta os gráficos de histograma do percentual de erro da estimação da demanda máxima diária, analisados durante o ano.




Figura 51 – Histograma de estimação da demanda máxima diária.

Com uma análise estatística obteve-se no histograma polinomial cerca de 44% dos dias com erro de estimação menor que 10%. E no histograma RNA cerca de 60,5% dos dias com erro de estimação menor que 10%.

Novamente uma característica de que a maioria dos dias analisados tiveram baixo erro de estimação da demanda máxima, é observado nos gráficos da Figura 51, havendo um comportamento melhor do método que utilizou a RNA para fazer as estimações de demanda máxima. Com os dados analisados do RNA observa-se que aproximadamente 16,5% dos dias tiveram erro de estimação de demanda máxima abaixo de 10%, a mais que o método polinomial. Como esperado, observa-se que é mais difícil a determinação da demanda máxima do que a energia consumida. Isto ocorre porque os equipamentos não possuem controle automático e podem ser ligados de forma livre dentro da edificação, sendo que parte da variação não pode ser explicada apenas pela variação da temperatura e sim por outros fatores aleatórios não tratados neste trabalho.

5.5 Considerações Finais do Capítulo

Este capítulo descreveu como foi aplicada a metodologia neste estudo de caso, informando a utilização de algoritmos, seus parâmetros e configurações, conforme especificados no Apêndice 3, para a classificação das curvas de carga em agrupamentos e a estimação da demanda diária do edifício em questão. Também foram apresentados os valores encontrados utilizando os algoritmos de inteligência computacional descritos neste trabalho, e a comparação entre os valores para verificação de qual teve melhor desempenho.

CAPÍTULO 6 – CONCLUSÕES E PROPOSTAS DE CONTINUIDADE

Neste capítulo são apresentadas as conclusões do trabalho desenvolvido, assim como sugestões para a continuidade da pesquisa.

6.1 Conclusões

Trabalhos e pesquisas realizados no contexto de estimação de energia estão recebendo mais atenção dos órgãos de planejamento energético e também concessionárias de energia, por auxiliarem nas tomadas de decisões futuras e na operação do sistema elétrico de potência. No nível do consumo, tem-se um interesse crescente dos usuários no conhecimento do seu perfil de consumo bem como realizar a previsão do consumo, principalmente para consumidores submetidos a tarifas horosazonais. Foi demonstrado, neste trabalho que não apenas as medições de energia devem ser consideradas neste tipo de estudo, mas também variáveis exógenas ao sistema, como temperatura, rotinas diárias, mensais e anuais, aspectos construtivos das edificações, etc. Cada tipo de consumidor irá apresentar um padrão de curva de carga diferente, conforme o seu perfil de consumo, que deverá ser analisado e processado para tal finalidade.

Levantamentos da curva de consumo energético em edifícios públicos como apresentado neste trabalho, podem ainda ser considerados raros, visto a falta de tradição de acompanhamento sistemático e portanto da existência de um sistema de monitoramento contínuo de energia em empreendimentos. Entretanto, novos edifícios que buscam a sustentabilidade, começam a implantar sistemas de monitoramento.

Realizou-se, nesta dissertação, a estimação do consumo energético e das curvas de demanda diária a partir de dados históricos armazenados no banco de dados disponibilizado pelo projeto CMUF. Os critérios de classificação utilizados neste trabalho, baseado em ferramentas da inteligência computacional, demonstraram ser bem eficazes na sua implementação. Destaca-se o método *Fuzzy* para a classificação das curvas que apresentou o menor erro estimado em comparação aos outros métodos utilizados nas estações de

Inverno e Primavera e o método SOM que apresentou menor erro para as estações de Outono e Verão.

A ocorrência da maior quantidade de pontos discrepantes dos erros MAPE nas estações de Inverno e Primavera se deve ao histórico meteorológico dessas estações em Belo Horizonte não apresentar sazonalidades bem definidas, como chuvas e períodos de calor ou dias de temperatura elevadas em apenas uma parte do dia além do veranico que pode ocorrer tanto durante o inverno quanto na primavera. No caso de Belo Horizonte é comum ter-se o dia mais quente do ano em plena primavera. Estes fenômenos alteram o comportamento do acionamento do sistema de ar-condicionado afetando a previsão. Adicionando a isso, a não automação dos condicionadores de ar do edifício, sendo ativados por intervenção humana justificam o aparecimento de erros com valores elevados. Estes pontos aparecem em menor quantidade, visto a totalidade de dados gerados neste trabalho. A utilização de banco de dados mais longo diminuiria estes erros, pois, estes casos poderiam ser tratados separadamente das estações do ano.

Quanto ao padrão das curvas típicas apresentados neste trabalho, não se espera que eles venham a se repetir para levantamentos feitos em outros edifícios públicos. Cada consumidor apresentará curvas típicas e comportamentos diferenciados, pois deve-se levar em consideração aspectos de consumo energético próprio de cada consumidor. Assim como a frequência com que os equipamentos elétricos são acionados, se há um sistema automatizado, ou se é manual, o tipo do consumidor sendo comercial, industrial ou residencial e a quantidade de pessoas no ambiente são fatores que influenciam no perfil de consumo.

Aspectos construtivos das edificações também influenciam no consumo energético, como estrutura com maior ou menor capacidade térmica, levando em consideração a sazonalidade do clima da região onde está localizada a construção, pode contribuir ou não no consumo e nas curvas de comportamento energético.

Não se observa uma predominância de um dos métodos utilizados neste trabalho para classificação das curvas típicas, sendo que alguns dias haviam coincidência das escolhas das curvas feitas por mais de um dos critérios adotados, justificando a criação de outro método de classificação levando em consideração a maior quantidade de repetições que havia para um mesmo dia, denominado de 4C. Neste novo critério de classificação observou-se um baixo valor da mediana em comparação com os outros critérios de classificação, conforme foi demonstrado, mostrando que o critério 4C contribuiu na obtenção de uma precisão maior na estimativa.

Portanto o critério de classificação 4C estabeleceu uma definição para as diferentes classificações que podem ocorrer de curvas para um mesmo dia, indicando também a maior tendência de qual curva típica predominará na estimativa. Vale salientar que nos dias em que

cada critério de classificação (*Fuzzy*, SOM e KNN) apresentou uma curva distinta, o critério adotado como referência foi o SOM.

Quanto à metodologia de estimação da energia, observou-se que a faixa de erro apresentada pela RNA ficou menor em relação ao Polinomial. Assim, as RNA também contribuíram para um maior refinamento dos dados previstos, aumentando a confiabilidade da metodologia proposta. No aspecto geral, os resultados obtidos ficaram dentro da faixa de 2 a 7% de erro, conforme foi verificado nas literaturas consultadas.

Em uma instalação futura de medidores inteligentes, a infraestrutura no sistema de transmissão de dados destes medidores deve garantir a qualidade e a proteção destes dados, para que a confiabilidade dos dados seja adequada.

6.2 Propostas de Continuidade

A metodologia proposta neste trabalho abordou um processamento de dados para estimação da curva de demanda e do consumo energético diário para um edifício público. Este trabalho foi baseado em um banco de dados histórico proveniente de um monitoramento contínuo do consumo energético de cargas estratificadas dentro desse edifício no período de um ano. A seguir é proposto alguns trabalhos futuros que podem ser implementados dentro da metodologia demonstrada.

6.2.1 Estimação de Consumo Energético de Forma Dinâmica

O levantamento das estimações foi realizado com dados históricos utilizando métodos de comparação e averiguação dos resultados em um tipo de sistema estático para comprovação da metodologia adotada. Uma aplicação em tempo real dessa metodologia consideraria um sistema de averiguação de séries temporais de forma dinâmica, ou seja, com atualizações diárias, semanais ou mensais do banco de dados analisado. Dessa forma os dados de um mês, por exemplo, seriam acrescentados ao banco de dados históricos e uma comparação diária das curvas de demanda do mesmo mês de anos anteriores, assim estabelecendo curvas médias ponderadas, tendo um peso maior os dados mais atuais para depois entrar no pré-processamento e em seguida por toda a metodologia apresentada neste trabalho.

Os algoritmos da metodologia devem ter seu funcionamento de forma autônoma e sequencial. Apenas o algoritmo da lógica *Fuzzy* não poderia funcionar de forma automática, como os outros algoritmos, pois como mostrado neste trabalho a definição das partições e dos conjuntos *Fuzzy*, necessita da análise de um especialista, definindo os limites, os pontos de inferência de cada conjunto e o sistema de regras *Fuzzy* conforme as temperaturas observadas diariamente. Portanto um trabalho futuro seria desenvolver um algoritmo de configuração automática desses parâmetros e regras de inferência *Fuzzy*, assim auxiliando a dinamicidade da metodologia proposta. Artigos como de Wang e Mendel [71] e Almeida [17], trazem um método proposto para extração de regras *Fuzzy* de um banco de dados de forma automática.

6.2.2 Estimação de Consumo Energético Utilizando o Método ARIMAX

A adequação da metodologia apresentada neste trabalho com a teoria proposta para estimação e previsão de séries temporais por Box e Jenkins [11], seria outra proposta para trabalhos futuros. Box-Jenkins propõe diversos modelamentos matemáticos para a finalidade demonstrada neste trabalho. A construção e os principais modelamentos propostos pertencentes à família ARIMAX (Autoregressivo Integrado de Médias Móveis Exógenas) é apresentado no Apêndice 1 deste trabalho. Assim, este trabalho seria desenvolvido, extraindo-se parâmetros e constantes matemáticas das curvas de consumo energético trabalhada que configurassem as equações apresentadas no modelo ARIMAX.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] GUNGOR, V.C., SAHIN, D., KOCAK, T., ERGUT, S., BUCCELLA, C., CECATI, C., HANCKE, G.P. *Smart Grid technologies: communication technologies and standards*. IEEE, 2011.
- [2] LORA, E.E.S., HADDAD, J. *Geração distribuída: aspectos tecnológicos, ambientais e institucionais*. Ed. Interciência - RJ, 2006.
- [3] LOPES, J.A.P. et.al. *MicroGrids large scale integration on micro-generation to low voltage grids*. Emergency Strategies and Algorithms, 2004.
- [4] FRAMEWORK, N. *Roadmap for smart grid interoperability standards*. NIST (National Institute of Standards and Technology) Special Publication, 2012.
- [5] RAMOS, S. *Tecnologias da Informação e Comunicação – Conceitos Básicos*, 2008.
- [6] NOGUEIRA, F. *Modelagem e Simulação: Modelos de Previsão*. Notas de Aula. UFJF, Juiz de Fora, 2009.
- [7] BAGNASCO, A., FRESI, F., SAVIOZZI, M., SILVESTRO, F., VINCI, A. *Electrical consumption forecasting in hospital facilities: an application case*. Energy and Buildings, 2015.
- [8] FEINBERG, E.A.; GENETHLIOU, D. *Load Forecasting*. State University of New York, Stony Brook. Disponível em: <<http://almozg.narod.ru/bible/lf.pdf>>. Acesso em: 13 dez. 2016.
- [9] REDDY, T.A., CLARIDGE, D.E. *Using synthetic data to evaluate multiple regression and principal component analyses for statistical modeling of daily building energy consumption*. Energy Build, 1994.
- [10] GUIRELLI, C.R. *Previsão da carga de curto prazo de áreas elétricas através de técnicas de inteligência artificial*. USP – Tese Doutorado em Engenharia, 2006.
- [11] BOX, G.E.P; JENKINS, G.M; REINSEL, G.C. *Time series analysis: forecasting and control*. 4ª Ed. Jhon Wiley & Sons, Inc, 2008.
- [12] MORETTIN, P.A.; TOLOI, C.M.C. *Modelos para previsão de séries temporais*. IMPA, Rio de Janeiro, 1981.
- [13] Banco Central do Brasil. *Série histórica da taxa de juros implícita - DLSP*. Disponível em: <<http://www.bcb.gov.br/htms/infcon/seriehistDLSPJuros.asp>>. Acesso em: 18 jan. 2016.
- [14] REIS, M.M. *Análise de séries temporais. INE - UFSC*”, Disponível em: <<http://www.inf.ufsc.br/~marcelo.menezes.reis/Cap4.pdf>>. Acesso em: 2 set. 2015.
- [15] BEZERRA, M.I.S. *Apostila de análise de séries temporais*. DMEC/ FCT/ UNESP”, 2006.

-
- [16] HIPPERT, H.S.; PEDREIRA, C.E.; SOUZA, R.C. *Neural networks for short-term load forecasting: a review and evaluation*. IEEE Transaction on Power Systems, 2001.
- [17] ALMEIDA, V.A. *Previsão de carga através de modelos neuro-fuzzy*. UFRJ – Projeto de graduação, 2013.
- [18] LAZOS, D., SPROUL, A.B., KAY, M. *Optimization of energy management in commercial buildings with weather forecasting inputs: a review*. Renewable and Sustainable Energy, 2014.
- [19] MOHAMED, M.I.; MOUSTAFA, H.M.A. *Artificial neural network approach compared with stochastic modelling for electrical load forecasting* - ICMIC, 2013.
- [20] ZAVALA, V.M.; CONSTANTINESCU, E.M.; ANITESCU, M. *Economic impacts of advanced weather forecasting on energy system operations*. In: Proceedings of the innovative smart grid technologies conference, SGT. Gaithersburg, MD, United states: IEEE Computer Society; IEEE PES–Power and Energy Society, 2010.
- [21] SALGADO, R.M. Carga por Barramento. In: *Sistema de suporte à decisão para análise e previsão de carga por barramento*. Campinas: UNICAMP, 2009. cap-3.
- [22] REZENDE, S.O. *Sistemas Inteligentes – Fundamentos e Aplicações*. Ed. Manole, 2003.
- [23] JOTA, F.G., JOTA, P.R.S., ROCHA, D.A. *Monitoramento e controle remotos de consumo e geração de energia em tempo real via internet*. VI CIERTEC, 2009.
- [24] SILVA, V.R.B., JOTA, P.R.S. *Predicting load using cluster analysis*. WSEAS Transactions on Systems, 2004.
- [25] JOTA, F.G.; JOTA, P.R.S.; NOBRE, E.C. *Centro de Monitoramento de Usos Finais*. I Congresso Brasileiro em Eficiência Energética, Belo Horizonte, 2005.
- [26] LEE, W.J.; HONG, J. *A hybrid dynamics and fuzzy time series model for mid-term power load forecasting*. Electrical Power and Energy Systems, 2014.
- [27] MORDJAOUI, M.; BOUDJEMA, B.; BOUABAZ, M.; DAIRA, R. *Short term electric load forecasting using neuro-fuzzy modeling for nonlinear system identification*, 2010.
- [28] AMBER, K.P.; ASLAM, M.W.; HUSSAIN, S.K. *Electricity consumption forecasting models for administration buildings of the UK higher education sector*, 2015.
- [29] CHEN, L.G.; CHIANG, H.D.; DONG, N.; LIU, R.P. *Group-based chaos genetic algorithm and non-linear ensemble of neural networks for short-term load forecasting*. IET Generation, Transmission & Distribution, 2016.
- [30] ALECRIM, E. *O que é Big Data?* Info Wester, 2013. Disponível em: <<http://www.infowester.com/big-data.php>>. Acesso em: 4 mar. 2016.
- [31] DAVENPORT, T.H. *“Big Data: The Future of Information and Business*, Disponível em: <<http://www.cin.ufpe.br/~tcmn/DW/Semin%E1rio/E12B387F.tmp>>. Acesso em: 7 mar. 2016.
- [32] PÉREZ, J.M. *Inteligencia computacional inspirada em la vida*. Universidad de Málaga – Espanha, 2010.

-
- [33] WEBB, A. *Statistical pattern recognition*. Wiley. Malvern. UK.pp.81-12, 2002.
- [34] BEZERRA, M.E.R. *Método baseados na regra do vizinho mais próximo para reconhecimento de imagens*. POLI-UPE, 2006.
- [35] LIMA, E.S. *Inteligência artificial, K – Nearest Neighbor*. Notas de Aula – PUC -RJ, 2014.
- [36] PUERTA, J.A.B. Distâncias entre Términos. In: *Aplicación de distancias entre términos para datos planos y jerárquicos*. Valência: Universidad Politécnica de Valencia, 2011. cap.3.
- [37] DUDA, R.O., HART, P.E., STORK, D.G. *Pattern classification 2ed*. New York, 2000.
- [38] HEISENBERG, W. *A imagem da natureza na física moderna*. Lisboa: Ed. Do Brasil, 1980.
- [39] ZADEH, L. *Fuzzy Sets*, Journal Information and Control, 1965.
- [40] COX, E. *The fuzzy system handbook: a practitioner's guide to building, using, and maintaining fuzzy system*. New York: AP Professional, 1994.
- [41] ROSS, T.J. *Fuzzy logic –with engineering applications*, Thrid Edition. Ed. Wiley 2010.
- [42] GUPTA, M., QI, J. *Theory of t-norms and fuzzy inference methods*. Fuzzy Sets Syst.”, 1991.
- [43] AGUADO, A.G., CANTANHEDE, M.A. *Lógica Fuzzy – Notas de Aula de Inteligência Artificial*. UNICAMP, 2010.
- [44] ALMEIDA, P.E.M. *Lógica fuzzy e representação do conhecimento – Notas de Aula*. CEFET-MG, 2011.
- [45] MANDANI, E.H. *Application of fuzzy logic to approximate reasoning using linguistic synthesis*, 1974.
- [46] ROCHA, T., PERES, S.M., BÍSCARO, H.H., MADEO, R.C.B., BOSCARIOLI, C. “ *Fuzzy c-means e fuzzy learning vector quantization: abordagens híbridas para tarefas de agrupamento e classificação* - UFRGS, 2012.
- [47] BEZDEK, J.C., TSAO, E.C., PAL, N.R. *Fuzzy Kohonen clustering networks*. In IEEE International Conference on Fuzzy Systems, 1992.
- [48] XU, R., WUNSCH, D. *II survey of clustering algorithms*. In IEEE Transactions on Neural Networks, 2005.
- [49] HAYKIN, S. *Redes neurais, princípios e prática*. 2ªed. Bookman, 2001.
- [50] YUKIE, V. *Curso de redes neurais utilizando o Matlab*. Belém do Pará, 2012.
- [51] ZÁRATE, L.E. *Projeto e aplicação de redes neurais artificiales*, 2011.
- [52] STEMMER, M.R., *Redes neurais artificiais para controle e automação*. Notas de Aula - UFSC, 2011.

-
- [53] BRAGA, A.P., CARVALHO, A.P.L.F., LUDERMIR, T.B. *Redes Neurais Artificiais: Teoria e Aplicações*. Ed LTC, 2000.
- [54] KOHONEN, T. *Self-Organization and Associative Memory*. Springer, Berlin, Heidelberg, 1995.
- [55] FAUSETT, L.V. *Fundamentals of Neural Networks: Architectures, Algorithms and Applications*, 1994.
- [56] KASKI, S. *Data Exploration Using Self-Organizing Maps*. Acta Polytechnica Scandinavia, 1997.
- [57] LO, Z.P., FUJITA, M., BAVARIAN, B. *Analysis of neighborhood interaction in Kohonen neural networks*, 1991.
- [58] RITTER, H., MARTINETZ, T., SCHULTEN, K. *Neural computation and self-organizing maps: an introduction*, Reading, MA: Addison-Wesley, 1992.
- [59] OBERMAYER, K., RITTER, H. SCHULTEN, K. *Development and spatial structure of cortical feature maps: a model study*, 1991.
- [60] SILVA, L.N.C. Treinamento de RNA. In: *Análise e síntese de estratégias de aprendizado para redes neurais artificiais*. Campinas: FEEC - UNICAMP, 1998. cap.4.
- [61] RODRIGUES, L.C.; SILVA, P.P.C.; LINDEN, R. *Séries temporais no consumo de energia elétrica no estado do Rio de Janeiro*. Disponível em: <http://www.fsma.edu.br/visoes/ed02/Ed02_Artigo5_Luciene_Paula_Ricardo.pdf>. Acesso em: 13 jun. 2015.
- [62] CAPEHART, B.L. *Information Technology for Energy Managers*, The Fairmont Press, Inc. 2004.
- [63] JOTA, P.R.S.; FREITAS, M.E.A.; BRACARENSE, M.S.S.; SILVA, A.A.P.; JOTA, F.G. *Análise dos índices de desempenho energético em sistemas de ar condicionado em edificação pública*. II CBEE. 2007.
- [64] JOTA, F.G., JOTA, P.R.S., ROCHA, D.A. *Monitoramento e controle remotos de consumo e geração de energia em tempo real via internet*. VI CIERTEC, 2009.
- [65] MASSANA, J., POUS, C., BURGAS, L., MELENDEZ, J., COLOMER, J. *Short-term load forecasting in a non-residential building contrasting models and attributes*. Energy and Building, 2015.
- [66] PAPA, R.P., JOTA, P.R.S. *Evaluation of influences of the external temperature in the building energy consumption*. PALENC, 2005.
- [67] BDMEP. *Banco de dados meteorológicos para ensino e pesquisa*, Disponível em: <<http://www.inmet.gov.br>>. Acessado em: 11 mar. 2016.
- [68] JOTA, P.R.S., SILVA, V.R.B., JOTA, F.G. *Building load management using cluster and statistical analyses* – Electrical Power and Energy Systems, 2011.
- [69] GOMES, L.C.; JOTA, P.R.S. *Metodologia para processamento de dados para previsão de energia e curva de carga em edificações*. IV CBSF – Campinas, SP, 2016.

-
- [70] GOMES, L.C.; JOTA, P.R.S. *Processamento de dados para estudo de consumo energético*. X CBPE – Gramado, RS, 2016.
- [71] WANG, L. X.; MENDEL, J. M. *Generating fuzzy rules by learning from examples*. IEEE Transactions On Systems Man, And Cybernetics, Vol 22, 1992.

APÊNDICE 1

Método Box & Jenkins (ARIMA e ARIMAX)

1. Introdução

Uma Série Temporal se resume em uma sequência de observações de um fenômeno qualquer, ordenadas por um intervalo de tempo determinado. Podemos encontrar estas séries em várias áreas de estudo, como em uma produção industrial, índices econômicos, diversos parâmetros de engenharia e medicina, e em ciências naturais, como meteorologia. O comportamento destas séries temporais pode apresentar características paramétricas (com um número finito de parâmetros [1]) ou estocásticas (valores analisados que dificilmente se repetem), conforme o intervalo de tempo observado.

O interesse pelo estudo de Séries Temporais teve um aumento significativo, devido às varias aplicações que podem ser feitas, como a determinação de modelos para estas séries ou funções de transferência, intervenções de outras variáveis de entrada em um processo serial ou dinâmico, análises de séries temporais multivariáveis (ex.: parâmetros físicos que estão correlacionados com espaço e volume) e sistemas de controle discretos [2], mas a principal aplicação é a de previsão de valores futuros.

2. A Série Temporal

Uma série temporal descreve, por exemplo, o comportamento de consumo elétrico nos dias uteis e também nos finais de semana, conforme mostra a Figura 1. Esta série temporal caracteriza-se como sendo uma série discreta e estacionária.




Figura 1 - Série Temporal do Consumo Elétrico.

A estacionariedade é frequentemente encontrada nas séries temporais, caracterizando-se por desenvolver-se aleatoriamente em torno de uma média constante, que pode ser de períodos longos ou curtos [1], como podemos observar na Figura 2, que demonstra este tipo de comportamento de consumo de energia durante um dia útil da semana.




Figura 2 - Períodos estacionários em uma série temporal.

3. Modelo Auto Regressivo

O processo de auto regressão é usado para calcular pontos consequentes ou futuros, utilizando uma base de pontos antecedentes, ou seja, a identificação de padrões não aleatórios de uma variável de interesse e a observação do comportamento passado, nos permite realizar previsões, auxiliando nas tomadas de decisões.

Considerando a parâmetro t , como sendo o tempo, para certa variável observada, em função linear do tempo Z_t temos a descrição de uma série temporal $Z_t = \{Z_1, Z_2, Z_3, \dots, Z_n\}$. Uma vez obtida a série, observada nos instantes $t_1 \dots t_n$, o interesse será fazer previsões futuras desta série, como o de curto prazo. Um modelo autoregressivo pode ser escrito da seguinte forma:

$$Z_t = \emptyset_1 Z_{t-1} + \emptyset_2 Z_{t-2} + \dots + \emptyset_p Z_{t-p} + \alpha_t \quad (1.1)$$

Onde Z_t é a variável de interesse, $Z_{t-1}, Z_{t-2}, \dots, Z_{t-p}$ são parâmetros independentes de α_t , t é um ponto qualquer da série a ser encontrado, $\emptyset$ é o peso dos parâmetros e α_t é o ruído branco existente na série, e p é a ordem do processo autoregressivo, que será denominado neste trabalho por processo AR(p), podendo ser de primeira ordem ($p=1$) ou de segunda ordem ($p=2$)[2].

$$1^{\text{a}} \text{ ordem: } Z_t = \emptyset_1 Z_{t-1} + \alpha_t$$

$$2^{\text{a}} \text{ ordem: } Z_t = \emptyset_1 Z_{t-1} + \emptyset_2 Z_{t-2} + \alpha_t$$

Segundo Moretin e Tolo [1], o valor de previsão de um tempo futuro é representado por Z_{t+h} , onde $t+h$, significa o tempo futuro a ser analisado. Dessa forma temos que

$$Z_{t+h} = W_{t+h} \emptyset + \alpha_{t+h} \quad (1.2)$$

Onde

$$W_{t+h} = (Z_{t+h-1} \ Z_{t+h-2} \ \dots \ Z_{t+h-k}) \quad (1.3)$$

Assim, simplificando obtemos:

$$\hat{Z}_t(h) = W_{t+h} \emptyset = \int_{j=1}^k \emptyset_j Z_{t+h-j} \quad (1.4)$$

Onde

$$\hat{Z}_{t+h-j} = \begin{cases} Z_t(h-j), & \text{se } h-j > 0 \\ Z_{t+h-j}, & \text{se } h-j \leq 0 \end{cases} \quad (1.5)$$

Para auxiliar no desenvolvimento do método autoregressivo, pode-se utilizar o software Matlab® da MathWorks, com a função “ar”, configurada para ser trabalhada com a técnica de aproximação por mínimos quadrados e também a função “forecast” para a determinação do ponto futuro, com a base de dados gerada pela função “ar”.

4. Modelo ARIMA

Segundo Box-Jenkins [2], a utilização de modelos autoregressivos, juntamente com o cálculo de médias móveis, e aplicando diferenças a esta série, de forma a deixá-la estacionária, resulta em um modelo denominado ARIMA, utilizada para modelamento de séries temporais com o objetivo de se prever dados futuros ou a estimação do comportamento da série analisada, em um curto espaço de tempo.

O modelo ARIMA pode ser utilizado em séries temporais estacionárias e não estacionárias, sendo, portanto, um modelo flexível a estes dois tipos de comportamento, realizando cálculo de pontos futuros baseado em valores passados desta série.

Será descrito sucintamente, a base matemática que define este modelo ARIMA.

4.1. Auto Regressivo (AR)

Conforme definição do processo AR dado anteriormente, podemos escrever a equação (1.1), da seguinte forma [2] :

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) Z_t = \alpha_t \quad (2.1)$$

ou

$$\phi(B) Z_t = \alpha_t \quad (2.2)$$

que implica

$$Z_t = \frac{1}{\phi(B)} \alpha_t = \phi^{-1}(B) \alpha_t \equiv \psi(B) \alpha_t \quad (2.3)$$

A função $\psi(B)$ é usado quando na entrada de dados da série, é inserido um ruído branco α_t em todos os pontos observados.

4.2. Médias Móveis (MA)

Considerando a série Z_t , onde a função $\psi(B) = -\Theta$ em uma série de comportamento linear finita e sendo $\psi \neq 0$, é denominado de médias móveis de ordem q , o seguinte modelo [2] :

$$Z_t = \alpha_t - \theta_1 \alpha_{t-1} - \theta_2 \alpha_{t-2} - \dots - \theta_q \alpha_{t-q} \quad (3.1)$$

Onde Z_t é a variável de interesse, $-\theta_{t-1}, -\theta_{t-2}, \dots -\theta_q$ são parâmetros de peso do modelo, t é um ponto qualquer da série a ser encontrado, α_t é o ruído branco existente na série, e q é a ordem do processo, que será denominado neste trabalho por MA(q), podendo ser de primeira ordem ($q=1$) ou de segunda ordem ($q=2$) [2].

$$1^{\text{a}} \text{ ordem: } Z_t = \alpha_t - \theta_1 \alpha_{t-1}$$

$$2^{\text{a}} \text{ ordem: } Z_t = \alpha_t - \theta_1 \alpha_{t-1} - \theta_2 \alpha_{t-2}$$

Se for acrescentado 1 unidade nas variáveis $\alpha_t, \alpha_{t-1}, \alpha_{t-2}, \dots, \alpha_{t-q}$, será obtido a estimação de Z_{t+1} , ou seja, as variáveis irão ter intervalo de tempo a frente $\alpha_{t+1}, \alpha_t, \alpha_{t-1}, \dots, \alpha_{t-q+1}$.

O cálculo das médias móveis da série temporal pode ser escrita conforme segue

$$Z_t = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) \alpha_t \quad (3.2)$$

ou

$$Z_t = \Theta(B) \alpha_t \quad (3.3)$$

A função $\Theta(B)$ é usado quando na entrada de dados da série, é inserido um ruído branco α_t em todos os pontos observados.

4.3. Autoregressivo de Médias Móveis (ARMA)

Uma série onde as duas partes descritas anteriormente, podem ser aplicados é denominada de autoregressivo de médias móveis, assim se obtém uma série temporal mais geral, que é descrito da seguinte forma

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + \alpha_t - \theta_1 \alpha_{t-1} - \theta_2 \alpha_{t-2} - \dots - \theta_q \alpha_{t-q} \quad (4.1)$$

Onde Z_t é a variável de interesse, ϕ e θ são parâmetros de peso do modelo, t é um ponto qualquer da série a ser encontrado, α_t é o ruído branco existente na série, e p e q é a ordem do processo, que será denominado por ARMA(p,q), podendo ser de primeira ordem (p,q=1,1) ou de segunda ordem (p,q=2,2) [2]. Por exemplo, se for de 1ª ordem o processo autoregressivo e também o de médias móveis, temos ARMA(1,1) que é representado da seguinte forma

$$Z_t = \phi_1 Z_{t-1} + \alpha_t - \theta_1 \alpha_{t-1} \quad (4.2)$$

4.4. Autoregressivo Integrado de Médias Móveis (ARIMA)

A maioria das séries existentes, dificilmente são estacionárias, com exceção de algumas séries que apresentam ruídos, ligados a fenômenos físicos que acabam fazendo uma certa compensação dos dados [1]. Nestas séries não estacionárias, uma forma para torna-las estacionárias, é aplicando diferenças quantas vezes for necessário até a série ficar estacionária. Por exemplo, séries Z_t que derivando-se por um número finito de vezes, d , torna-se estacionárias [3], é escrita da seguinte forma.

$$w_t = Z_t - Z_{t-1} = (1-B) Z_t = \Delta Z_t \quad (5.1)$$

$$w_t = \Delta^d Z_t \quad (5.2)$$

Representando w_t pelo modelo ARMA(p,q), teríamos

$$\emptyset(B) w_t = \theta(B) \alpha_t \quad (5.3)$$

Sendo w_t uma derivada de Z_t , então Z_t é uma integral de w_t , assim temos que Z_t segue um modelo autoregressivo integrado de médias-móveis, ou ARIMA, onde $w_t = \nabla Z_t$. Dessa forma temos

$$\emptyset(B) \nabla^d Z_t = \theta(B) \alpha_t \quad (5.4)$$

Assim, se o termo autoregressivo $\emptyset(B)$ é de ordem p , a quantidade de derivadas é d e o termo de médias móveis $\theta(B)$ é de ordem q , podemos dizer que o modelo ARIMA é de ordem (p,d,q) , ou simplesmente um processo ARIMA(p,d,q) [2].

Quando derivamos uma série temporal, tornando-a estacionária, dizemos que estas séries são não estacionárias homogêneas. Os casos mais comuns são descritos a seguir.

Para $d=1$, dizemos que a série é não estacionária quanto ao nível, ou seja, oscilam ao redor de um nível médio durante algum tempo e depois saltam para outro nível temporário.

Para $d=2$, dizemos que a série é não estacionária quanto à inclinação, ou seja, oscilam numa direção por algum tempo e depois mudam para outra direção temporária.

Neste trabalho, o processo ARIMA a ser analisado será de ordem $(1,1,1)$, dessa forma o modelo geral da série será

$$(1-\emptyset_1 B) \nabla Z_t = (1-\theta_1 B) \alpha_t \quad (5.5)$$

5. Modelo ARIMAX

O modelo ARIMAX engloba todas as variações que o modelo ARIMA pode ter, por exemplo, AR, MA, ARI, IMA, ARMA e ARIMA, acrescentando uma ou mais entradas exógenas ao processo, ficando assim: ARX, MAX, ARIX, IMAX, ARMAX e ARIMAX. O X da palavra exógena é que identifica a abreviação ARIMAX (Autoregressivo Integrado de Médias Móveis com entradas Exógenas) e o termo “r” representa a ordem da equação da entrada exógena ARIMAX (p,d,q,r) . Pode-se também generalizar para representar mais de uma entrada exógena, identificando-se assim os termos por $r_1, r_2, r_n \dots$ etc [4].

Para compreender esse método considere que se tenha uma série temporal Z_t a ser analisada, e que pode ser influenciada por outros processos externos. Sendo um desses processos também representado como uma série temporal X_t , é feito uma correlação entre as duas séries, para averiguar se a correlação entre as duas séries é fraca ou forte. Sendo considerada forte, certamente a série X_t , influencia no comportamento de Z_t . Dessa forma X_t

é definido como um variável externa da série Z_t , que ao ser considerado nos cálculos realizados, participa como uma entrada de dados exógena à série principal Z_t . Assim a representação de valores futuros vai ser influenciada por ambos os valores de Z_t e X_t , obtendo a seguinte representação:

$$\sum_{j=0}^p d_j \Delta^d Z_{t-j} = b_0 + \sum_{j=1}^r b_j \Delta^d X_{t-j} + \sum_{j=0}^q c_j \Delta^d a_{t-j} \quad (6.1)$$

Onde o p é a ordem da parte auto regressiva, d é o peso definido a cada posição j da série Z_t , Δ^d é o numero de diferenças na qual a série foi submetida, b_0 é o peso definido para a entrada exógena, r é a ordem da equação da entrada exógena, b é o peso definido a cada posição j da série X_t , q é a ordem da parte de médias móveis, c é o peso definido a cada posição j da série a_t .


6. Bibliografia

- [1] MORETTIN, P.A; TOLOI, C.M.C. *Modelos para previsão de séries temporais*. IMPA, Rio de Janeiro – RJ, 1981.
- [2] BOX, G.E.P; JENKINS, G.M; REINSEL, G.C. *Time series analysis: forecasting and control*. 4ª Ed. Jhon Wiley & Sons, Inc, 2008.
- [3] BEZERRA, M.I.S. *Apostila de Análise de Séries Temporais*. DEMC/FCT/UNESP, São Paulo – SP”, 2006.
- [4] FERRARI, S.M. Modelamento dos Sinais. In: *Identificação on-line de motores de indução através de modelo discreto para sinais senoidais*. Florianópolis: CCT-UDESC, 2006. cap. 4. Disponível em: <http://www.tede.udesc.br/tde_busca/arquivo.php?codArquivo=448>. Acesso em: 17 dez. 2015.


APÊNDICE 2

Gráficos do Mapeamento Fuzzy


VERÃO – Mapeamento e Conjuntos Fuzzy



PRIMAVERA – Mapeamento e Conjuntos Fuzzy





Mapeamento realizado pelo Fuzzy C-Means




Conjuntos referente as 12h

Definição dos limites dos conjuntos fuzzy de forma Tridimensional




Conjuntos referente as 18h




Conjuntos referente aos Agrupamentos


INVERNO – Mapeamento e Conjuntos Fuzzy




Mapeamento realizado pelo Fuzzy C-Means




Conjuntos referente as 12h



Definição dos limites dos conjuntos fuzzy de forma Tridimensional




Conjuntos referente as 18h




Conjuntos referente aos Agrupamentos


OUTONO – Mapeamento e Conjuntos Fuzzy




Mapeamento realizado pelo Fuzzy C-Means




Conjuntos referente as 12h



Definição dos limites dos conjuntos fuzzy de forma Tridimensional



Conjuntos referente as 18h



Conjuntos referente aos Agrupamentos

APÊNDICE 3

Configurações e Parâmetros dos Algoritmos

1. Mapa de Kohonen (SOM)

Configurações:

```
net = selforgmap([2 2]); % quantidade de neuronios
net.trainParam.epochs = 500;
net.trainFcn = 'trainbu'; %função de treinamento
net.performFcn = 'mse'; %calculo de erro
net.performParam.ratio=0.5;
net.trainParam.goal = 1e-4; %erro desejado
net.trainParam.lr = 0.5; %taxa de aprendizagem
net.trainParam.show = 10; %atualização de tela
net.trainParam.max_fail = 2000; %validation check
net.trainParam.min_grad = 1e-10; %gradiente
net.trainParam.min_step = 1e-60; %minimo step
net.trainParam.initNeighbor = 1.5;
```

2. K-NearestNeighbor (KNN)

Configurações:

```
[n,d] = rangesearch(x,y,0.05); %0.05 é a distância máxima para considerar
o ponto próximo, da coordenada x,y
```

3. Lógica Fuzzy

Configurações:

```
modelo Fuzzy = Mandani;
operador AND das regras = MIN;
operador de implicação = MIN;
agregação das saídas = MAX;
defuzzificação = centroide;
```

4. Fuzzy C-Means (FCM)

Configurações:

```
[center,U] = fcm(dados,x); % x é a quantidade de centroides que se deseja
dos dados
```

5. Redes Neurais Artificiais (RNA)

Configurações:

```
net = feedforwardnet([5 5]) % quantidade de neuronios e camadas
net.layers{1}.transferfcn='tansig';
net.layers{2}.transferfcn='logsig';
net.layers{3}.transferfcn='tansig';
net.trainFcn = 'traincgb';
net.trainParam.epochs = 2000;
net.trainParam.goal = 1e-4; %erro desejado
net.trainParam.lr = 0.5; %taxa de aprendizagem
net.trainParam.show = 10; %atualização de tela
net.trainParam.max_fail = 2000; %validation check
net.trainParam.min_grad = 1e-10; %gradiente
net.trainParam.min_step = 1e-60; %minimo step
```