



UNIVERSIDADE ESTADUAL DE CAMPINAS
Faculdade de Engenharia Química

RENATA DE CASSIA FERREIRA SILVA

DESENVOLVIMENTO DE UM MODELO MATEMÁTICO NEURO FUZZY PARA A
PREDIÇÃO DO CONSUMO DE ENERGIA ELÉTRICA DA LINHA DE BASE DE UM
CENTRO DE DISTRIBUIÇÃO REFRIGERADO

*DEVELOPMENT OF A NEURO FUZZY MATHEMATICAL MODEL FOR PREDICTING
THE ELETRIC POWER CONSUMPTION FROM THE BASELINE OF A REFRIGERATED
DISTRIBUTION CENTER*

CAMPINAS
2019

RENATA DE CASSIA FERREIRA SILVA

DESENVOLVIMENTO DE UM MODELO MATEMÁTICO NEURO FUZZY PARA A
PREDIÇÃO DO CONSUMO DE ENERGIA ELÉTRICA DA LINHA DE BASE DE UM
CENTRO DE DISTRIBUIÇÃO REFRIGERADO

*DEVELOPMENT OF A NEURO FUZZY MATHEMATICAL MODEL FOR PREDICTING
THE ELETRIC POWER CONSUMPTION FROM THE BASELINE OF A REFRIGERATED
DISTRIBUTION CENTER*

Dissertação de Mestrado apresentada à
Faculdade de Engenharia Química da
Universidade Estadual de Campinas, como
parte dos requisitos exigidos para a obtenção
do título de Mestra em Engenharia Química.

*Master Dissertation presented to School of
Chemical Engineering of the University of
Campinas to obtain the M.S. grade on
Chemical Engineering.*

Orientador: PROF. DR. FLÁVIO VASCONCELOS DA SILVA

ESTE EXEMPLAR CORRESPONDE À VERSÃO
FINAL DA DISSERTAÇÃO DEFENDIDA PELA
ALUNA RENATA DE CASSIA FERREIRA SILVA, E
ORIENTADA PELO PROF. DR. FLÁVIO
VASCONCELOS DA SILVA.

CAMPINAS

2019

Agência(s) de fomento e nº(s) de processo(s): Não se aplica.

ORCID: <https://orcid.org/0000-0002-4709-9728>

Ficha catalográfica
Universidade Estadual de Campinas
Biblioteca da Área de Engenharia e Arquitetura
Rose Meire da Silva - CRB 8/5974

Si38d Silva, Renata de Cassia Ferreira, 1983-
Desenvolvimento de um modelo matemático neuro fuzzy para a predição do consumo de energia elétrica da linha de base de um centro de distribuição refrigerado / Renata de Cassia Ferreira Silva. – Campinas, SP : [s.n.], 2019.

Orientador: Flávio Vasconcelos da Silva.
Dissertação (mestrado) – Universidade Estadual de Campinas, Faculdade de Engenharia Química.

1. Lógica fuzzy. 2. Energia - Consumo. 3. Energia - Consumo - Modelos matemáticos. 4. Eficiência energética. I. Silva, Flávio Vasconcelos da, 1971-. II. Universidade Estadual de Campinas. Faculdade de Engenharia Química. III. Título.

Informações para Biblioteca Digital

Título em outro idioma: Development of a neuro fuzzy mathematical model for predicting the electric power consumption from the baseline of a refrigerated distribution center

Palavras-chave em inglês:

Fuzzy logic

Energy - Consumption

Buildings - Energy consumption - Mathematical models

Energy efficiency

Área de concentração: Engenharia Química

Titulação: Mestra em Engenharia Química

Banca examinadora:

Flavio Vasconcelos da Silva

Douglas Fernandes Barbin

Newton Libânio Ferreira

Data de defesa: 21-02-2019

Programa de Pós-Graduação: Engenharia Química

Folha de Aprovação da Dissertação de Mestrado defendida por Renata de Cassia Ferreira Silva e aprovada em 21 de fevereiro de 2019 pela banca examinadora constituída pelos seguintes doutores:

Prof. Dr. Flavio Vasconcelos da Silva

FEQ / UNICAMP

Prof. Dr. Douglas Fernandes Barbin

FEA / UNICAMP

Dr. Newton Libânio Ferreira

Departamento de Engenharia Química – FEI

*A ATA da Defesa com as respectivas assinaturas dos membros encontra-se no SIGA/Sistema de Fluxo de Dissertação/Tese e na Secretaria do Programa da Unidade.

*“Toda manhã na África, a gazela acorda.
Ela sabe que precisa correr mais rápido que o mais rápido dos leões para sobreviver.
Toda manhã um leão acorda.
Ele sabe que precisa correr mais rápido que a mais lenta das gazelas senão morrerá de fome.
Não importa se você é um leão ou uma gazela. Quando o sol nascer, comece a correr.”*

Provérbio Africano

AGRADECIMENTOS

Agradeço a Deus por influenciar todas as minhas decisões, as quais me trouxeram até aqui. Agradeço as pessoas especiais que Deus colocou na minha vida e que mesmo sem eu me dar conta contribuíram para a concretização deste sonho.

Agradeço aos meus pais, Ferreira e Inácia, que mesmo em sua simplicidade, acreditaram no meu potencial, incentivaram e apoiaram em todas as minhas aventuras acadêmicas, mesmo aquelas que pareciam ser impossíveis.

Agradeço ao Professor Doutor José Célio Dias, orientador do meu trabalho de conclusão de curso na graduação, que me deu o melhor conselho que recebi na minha carreira: “Mesmo que você tenha um grande potencial para a pesquisa, vá para o mercado de trabalho antes de ingressar no mestrado. Assim, antes de realizar sua pesquisa, você irá absorver a realidade onde ela será aplicada”. Talvez não com essas palavras, mas depois de 12 anos é assim que eu me lembro.

Agradeço ao Professor Doutor Flavio Vasconcelos, que desde minha primeira visita na FEQ-UNICAMP, em 2013, entendeu e apoiou minha posição de realizar pesquisas aplicadas a realidade da indústria. Entendeu todos os momentos pessoais que vivi e ajudou a conciliá-los com minhas responsabilidades acadêmicas. Foi ele também que me ofereceu a oportunidade de participar de um ambiente de pesquisas científicas, mesmo que em pouquíssimos momentos, conviver com os pesquisadores do grupo abriu horizontes que na indústria não pude encontrar. Agradeço aos membros do grupo por essa nova perspectiva e pelo café fresco depois do almoço.

Agradeço aos pesquisadores que em algum momento fizeram parte da startup RVT Energia, pois independente do tempo, frequência ou papel desempenhados na empresa, me ensinaram lições que vou levar para a vida. Trouxeram equilíbrio para meus devaneios e força quando pensei em desistir. Aqui destaco a Patrícia Pereira Silva e Filipe Aparecido que estiveram comigo durante toda a caminhada.

Aos meus filhos, João Pedro e Samuel, que mesmo sem saber me enriqueceram com muita motivação. Agradeço especialmente ao João, por todos os fins de semana sem passeio no parque e pelas noites sem “filminho”. Ao Vanilton, a pessoa que escolhi para me acompanhar nas minhas aventuras, com quem compartilho meus planos e quem me apoiou em todas as decisões, certas ou erradas, e assumiu as consequências ao meu lado. Agradeço o café fresco todas as manhãs e por acreditar em mim, mesmo quando nem eu mesma sabia do que era capaz.

Por fim, agradeço aos colegas da GreenYellow que em determinado momento desta caminhada passaram a fazer parte dela, e me ofereceram a oportunidade de aplicar minhas descobertas no contexto da empresa, disponibilizando os dados necessários para estruturação do estudo de caso.

RESUMO

O Protocolo Internacional de Medição e Verificação de Performance (PIMVP) é uma metodologia para apuração de resultados após a implementação de Ações de Eficiência Energética (AEEs). Para aplicação desta metodologia é necessário desenvolver um modelo matemático para ajuste da linha de base do consumo de energia conforme novas condições ambientais e operacionais. Neste trabalho foi desenvolvido um modelo *Neuro Fuzzy* para ajuste da linha de base para um centro de distribuição refrigerado. O modelo foi validado segundo os critérios do PIMVP (EVO, 2012). Para fins de comparação, outros modelos matemáticos da linha de base foram desenvolvidos utilizando a técnica tradicional regressão linear (RL). Os modelos foram comparados segundo os mesmos critérios e o modelo *Neuro Fuzzy* apresentou melhor resultado em termos de coeficiente de determinação (R^2), atingiu 0,88 contra 0,72 do modelo RL; e de erro padrão (EP) da estimativa, alcançando 6,89 contra 10,19 do modelo RL. Os resultados obtidos mostram que com a aplicação da modelagem *Neuro Fuzzy* é possível reduzir a incerteza na previsão do consumo de energia total da planta, sendo possível calcular qual seria o consumo de energia se as AEEs não tivessem sido implementadas. O modelo foi desenvolvido para suportar a estratégia de Medição e Verificação (M&V) adotada para o projeto de eficiência energética que foi realizado em um Centro de Distribuição Refrigerado.

Palavras-chave: *Neuro Fuzzy*, Consumo de Energia, Linha de Base, PIMVP.

ABSTRACT

The International Performance Measurement and Verification Protocol (IPMVP) is a methodology for assessing results after the implementation of energy saving measures (ESMs). To apply this methodology it is necessary to develop a mathematical model to adjust the baseline of the energy consumption according to new environmental and operational conditions. In this work, a Neuro Fuzzy model was developed to adjust the baseline to a refrigerated warehouse. The model was validated according to IPMVP (EVO, 2012) criteria. For comparison purposes, other mathematical models of the baseline were developed using the traditional linear regression (RL) technique. The models were compared according to the same criteria and the Neuro Fuzzy model presented better result in terms of coefficient of determination (R^2), reached 0.88 against 0.72 of the RL model; and standard error (EP) of the estimate, reaching 7.12 against 10.19 of the RL model. The results show that with the application of the Neuro Fuzzy model it is possible to reduce the uncertainty in the forecast of the total energy consumption of the plant, being possible to calculate what would be the energy consumption if the ESAs had not been implemented. The model was developed to support the Measurement and Verification (M&V) strategy adopted for the energy efficiency project that was carried out in a Refrigerated Distribution Center.

Keywords: Neuro Fuzzy, Energy Consumption, Baseline, IPMVP.

LISTA DE FIGURAS

Figura 1: Exemplo de Histórico de Energia.	20
Figura 2: Modelos regressivos, lineares e estacionários, que usam o conceito de “ponto de mudança”,	27
Figura 3: Distribuição do consumo de energia elétrica no período da linha de base do Centro de Distribuição.	35
Figura 4: Distribuição relativa da economia esperada com as AEEs.	36
Figura 5: Processo de seleção da opção (simplificada).	37
Figura 6: Processo de escolha da “Opção C”, utilizando a lógica sugerida pelo PIMVP (EVO, 2012).	44
Figura 7: Distribuição do consumo de energia normalizado do Centro de Distribuição Refrigerado.	46
Figura 8: Distribuição do valor de GDR.	49
Figura 9: Distribuição do valor de movimentação de pallets.	49
Figura 10: Distribuição dos dados de consumo de energia em função de GDR em comparação com o modelo linear.	51
Figura 11: Valores de consumo de energia simulados com modelo de regressão linear em função de GDR comparados com os valores reais de consumo de energia.	51
Figura 12: Distribuição dos dados de consumo de energia em função de movimentação de pallets em comparação com o modelo linear.	52
Figura 13: Valores de consumo de energia simulados com modelo de regressão linear em função de movimentação de pallets comparados com os valores reais de consumo de energia.	52
Figura 14: Valores de consumo de energia simulados com modelo <i>Neuro Fuzzy</i> em função de GDR comparados com os valores reais de consumo de energia (dados de treinamento e teste).	54
Figura 15: Valores de consumo de energia simulados com modelo <i>Neuro Fuzzy</i> em função de movimentação de pallets comparados com os valores reais de consumo de energia (dados de treinamento e teste).	55
Figura 16: Gráfico de superfície do modelo <i>Neuro Fuzzy</i> .	56
Figura 17: Valores de consumo de energia simulados com modelo de regressão linear em função de movimentação de pallets e GDR comparados com os valores reais de consumo de energia.	58
Figura 18: Valores de consumo de energia simulados com modelo <i>Neuro Fuzzy</i> em função de movimentação de pallets e GDR comparados com os valores reais de consumo de energia (dados de treinamento e teste).	58

LISTA DE TABELAS

Tabela 1: Métodos de modelagem energética.	25
Tabela 2: Descrição do Centro de Distribuição 2 – Osasco.	35
Tabela 3: Argumentos da função PROJ.LIN	40
Tabela 4: Argumentos <i>ANFIS</i>	42
Tabela 5: Área e set point de temperatura de cada câmara.	47
Tabela 6: Definição das movimentações de pallet que influenciam a carga térmica.	48
Tabela 7: Argumentos da função PROJ.LIN	50
Tabela 8: Resultados estatísticos dos modelos desenvolvidos utilizando regressão linear simples e com múltiplas variáveis.	50
Tabela 9: Argumentos utilizados para construção dos modelos <i>ANFIS</i> .	53
Tabela 10: Resultados estatísticos dos modelos desenvolvidos utilizando <i>Neuro Fuzzy</i> .	55
Tabela 11: Melhoria dos modelos <i>Neuro Fuzzy</i> em comparação com os modelos com regressão linear.	57

LISTA DE ABREVIATURAS E SIGLAS

ABNT - Associação Brasileira de Normas Técnicas
AEE - Ação de Eficiência Energética
ANFIS - *Adaptative Network based Fuzzy Inference Systems*
ASHRAE - *The American Society of Heating, Refrigerating and Air-Conditioning Engineers*
CEE - Contratos de Eficiência Energética
CG - *Coarse-Grained*
EAM - Erro Absoluto Médio
EMQ - Erro Médio Quadrado
EP - Erro Padrão
EPAM - Erro Percentual Absoluto Médio
EPR - Erro Padrão Relativo
ESCO - *Energy Services Company*
ESM – *Energy Saving Measures*
EVO - *Efficiency Valuation Organization*
F - Economia Total Esperada (%)
FG - *Fine-Grained*
GDA - Graus-dia de Aquecimento
GDR - Graus-dia de Refrigeração
IPMVP – *International Measurement and Performance Verification Protocol*
MDD - *Maximum Dry Density*
MO - *Methyl Orange*
M&V - Medição e Verificação
PCA-ANFIS - *Principal Component Analysis*
PG - Processo Gaussiano
PI - *Plasticity Index*
PIMVP - Protocolo Internacional de Medição e Verificação de Performance
RL - Regressão Linear
RNA - Rede Neural Artificial
RSM - Superfície de Resposta – *Response Surface*
TS - Takagi-Sugeno
TWC - *The Weather Company*

SUMÁRIO

1. INTRODUÇÃO	14
1.1. HIPÓTESE	17
1.2. OBJETIVOS	17
2. REVISÃO BIBLIOGRÁFICA	18
2.1. CENTRO DE DISTRIBUIÇÃO REFRIGERADO	18
2.2. MODELOS DE CONSUMO DE ENERGIA	19
2.2.1. APLICAÇÃO DE MODELOS DE CONSUMO DE ENERGIA	21
2.2.2. DESENVOLVIMENTO DE MODELOS	24
2.3. LÓGICA <i>FUZZY</i>	28
2.3.1. ESTRUTURA DA LÓGICA <i>FUZZY</i> MAMDANI	29
2.3.2. ESTRUTURA DA LÓGICA <i>FUZZY</i> TS	29
2.3.3. APLICAÇÃO DO SISTEMA DE INFERÊNCIA ADAPTATIVA <i>NEURO FUZZY</i>	31
3. MATERIAIS E MÉTODOS	34
3.1. CONTEXTO	34
3.2. DESCRIÇÃO DA INSTALAÇÃO	34
3.3. DEFINIÇÃO DA FRONTEIRA E OPÇÃO DE MEDIÇÃO	36
3.4. DEFINIÇÃO DO PERÍODO DA LINHA DE BASE E ESCALA DE TEMPO	38
3.5. COLETA DOS DADOS DE CONSUMO DE ENERGIA	38
3.6. DEFINIÇÃO DE VARIÁVEIS INDEPENDENTES	39
3.7. DESENVOLVIMENTO DO MODELO COM REGRESSÃO LINEAR MÚLTIPLA	40
3.8. DESENVOLVIMENTO DO MODELO <i>NEURO FUZZY</i>	41
3.9. ANÁLISE COMPARATIVA DOS MODELOS	42
4. RESULTADOS E DISCUSSÕES	44
4.1. DEFINIÇÃO DA FRONTEIRA E OPÇÃO DE MEDIÇÃO	44
4.2. DEFINIÇÃO DO PERÍODO DA LINHA DE BASE	45

4.3.	COLETA DOS DADOS DE CONSUMO DE ENERGIA	45
4.4.	DEFINIÇÃO DE VARIÁVEIS INDEPENDENTES	46
4.5.	DESENVOLVIMENTO DO MODELO COM REGRESSÃO LINEAR MÚLTIPLA	50
4.6.	DESENVOLVIMENTO DO MODELO NEURO FUZZY	52
4.7.	ANÁLISE COMPARATIVA DOS MODELOS OBTIDOS	56
5.	CONCLUSÕES	59
6.	TRABALHOS FUTUROS	60
7.	REFERÊNCIAS BIBLIOGRÁFICAS	61
8.	ANEXO	64

1. INTRODUÇÃO

Um Centro de Distribuição Refrigerado tem como principal objetivo manter a temperatura de produtos perecíveis em níveis adequados. Para tanto precisam de imóveis adaptados para este fim, o que exige sistemas complexos de refrigeração industrial. Normas de higiene, saúde e segurança alimentar exigem aperfeiçoamento contínuo destes sistemas.

Paralelo às exigências das normas, a mudança no estilo de vida faz com que o consumo de produtos refrigerados e congelados seja cada vez mais relevante para o mercado, aumentando ainda mais a exigência por sistemas de refrigeração eficientes. Para atendê-los, se faz necessário o desenvolvimento de novas tecnologias para ampliação da produtividade e melhoria logística da chamada “cadeia do frio”. Uma das atividades neste processo é o investimento em eficiência energética, aplicado principalmente no sistema de refrigeração, pois em média 80% do consumo de energia de um centro de distribuição se concentra nestes sistemas.

Por um lado, é de conhecimento geral que o processo de refrigeração é o principal fator do elevado consumo de energia, representando uma parte significativa de seus custos globais e, por outro, sabe-se que sistemas de refrigeração possuem características que dificultam seu aprimoramento. Destaca-se a não-linearidade e a especificidade de cada projeto industrial como principais barreiras técnicas a serem vencidas.

Complementando este cenário, embora as tecnologias existentes no mercado permitam processos mais eficientes do que os atualmente em operação nas indústrias, que estes sejam financeiramente viáveis e existam programas governamentais de incentivo, ainda persiste a desconfiança dos empresários quanto aos projetos em eficiência energética. As razões podem ser diversas, mas sabe-se que uma delas é a dificuldade de medir a economia proporcionada pelas ações de eficiência energética (AEEs).

Torna-se interessante aos empresários a alternativa que se apresenta, inclusive no Brasil, para redução de riscos associados ao investimento em eficiência energética, que é compartilhar o investimento entre algumas instituições, por exemplo, o consumidor final de energia, bancos de financiamento e ESCO (*Energy Services Company* - Empresa de Serviços de Energia). Esta alternativa torna a dificuldade de avaliação dos resultados econômicos ainda mais relevante.

Entretanto, a crescente aplicação dos conceitos da Indústria 4.0 e o desenvolvimento de novas tecnologias de sensores e dispositivos inteligentes fornecem dados em tempo real, o que permite informações e monitoramento precisos e que podem ser utilizados como base para tomada de decisão. A necessidade que se apresenta é transformar dados em

informações que possam auxiliar os empresários e investidores na tomada de decisão sobre projetos de eficiência energética e que sejam de base suficientemente clara para cálculos econômicos reais.

Frente a estes desafios, alguns indicadores de desempenho energético foram introduzidos historicamente. Cuidado especial deve ser tomado quanto à utilização destes indicadores, pois, além do projeto de eficiência energética, outros fatores podem influenciá-los. Especificamente com sistemas de refrigeração, o clima pode influenciar o consumo de energia, além dos indicadores normalmente utilizados que não separam o consumo fixo do consumo variável, separação importante, pois o aumento de produção pode reduzir consideravelmente o indicador sem que nenhuma Ação de Eficiência Energética (AEE) tenha sido implementada.

Neste contexto foi desenvolvido o Protocolo Internacional de Medição e Verificação de Performance – PIMVP (EVO, 2012), que tem como objetivos documentar termos comuns e métodos para avaliar o desempenho energético de projetos de eficiência, fornecer métodos para determinar economias e especificar o conteúdo de um Plano de Medição e Verificação (M&V). A importância econômica desta metodologia está, principalmente, no fato de que os diretores das empresas podem comprovar as economias financeiras (retorno de capital) de um determinado investimento.

Conforme o PIMVP (EVO, 2012), a economia de energia não pode ser medida diretamente, uma vez que economia representa a ausência do consumo de energia. A economia é determinada comparando-se o consumo medido anteriormente e o consumo medido posteriormente à implementação de um programa, e realizando ajustes adequados às alterações nas condições de uso.

Estes ajustes são calculados utilizando um modelo de consumo de energia do estabelecimento ou equipamento antes de a AEE ser implementada. Para reportarem adequadamente a “economia”, os ajustes devem contemplar as diferenças nas condições entre o período da linha de base e os períodos de determinação da economia. O desafio de se elaborar um plano de M&V reside na determinação de quais são as variáveis que podem influenciar o consumo de energia. Com informações suficientes a respeito de uma instalação existente é possível construir o modelo, que será capaz de representar as mudanças nas condições e nos parâmetros operacionais, de forma que os “ajustes” possam ser efetuados.

O PIMVP não especifica os métodos que devem ser utilizados para cálculo dos ajustes de rotina, mas pontua que podem ser tão simples como um valor constante (sem ajuste), ou tão complexos como várias equações não-lineares, de parâmetros múltiplos, cada uma correlacionando energia com uma ou mais variáveis independentes (EVO, 2012). O PIMVP

ainda exige a utilização de técnicas matemáticas válidas e orienta sobre a avaliação da validade ou não dos métodos matemáticos (EVO, 2012). O método usual para modelagem de consumo de energia é construir um modelo de regressão linear.

A incerteza da estimativa, fornecida por ferramentas estatísticas tradicionais, pode ser bastante ampla e, embora existam vários trabalhos sobre modelagem de M&V de economia de energia em edificações residenciais e comerciais (Shonder e Hughes, 2006; Carpenter et al., 2010; Kim e Haberl, 2015; e, Subbarao et al., 2011), não há muitos trabalhos no sentido de redução desta incerteza em instalações industriais, na base de dados pesquisada somente Carpenter et al. (2010) utilizaram este tipo de instalação como estudo de caso. Isto é importante porque quanto menor for a incerteza, maior credibilidade é dispensada para o cálculo das economias quantificadas após a implementação do projeto de eficiência energética.

O PIMVP destaca ainda que quando se utilizam modelos de regressão, um dos erros que pode ser introduzido é o modelo matemático utilizar uma forma funcional inadequada (EVO, 2012). Modelar uma relação não linear com um único modelo linear introduz um erro desnecessário.

Dada a quantidade de técnicas matemáticas disponíveis atualmente para modelagem e a necessidade de simplificar e acelerar o processo, uma das tarefas do profissional de M&V é escolher a técnica matemática mais adequada para a aplicação desejada. Assim, propôs-se neste trabalho um método para modelagem da linha de base utilizando *Neuro Fuzzy*, método este que vem sendo aplicado na engenharia para resolução de diversos problemas (GHAEDI et al., 2013; MANDAL et al., 2015; REBOUH, BOUHEDDA e HANINI, 2016; QASAIMEH et al., 2012). Muitos destes problemas caracterizados por não apresentarem solução fenomenológica ou estas não serem viáveis na prática. Portanto, *Neuro Fuzzy* foi escolhido como método para desenvolver o modelo da linha de base para suportar a estratégia de M&V adotada para o projeto de eficiência energética realizado em um Centro de Distribuição Refrigerado do Grupo Pão de Açúcar.

A aplicação de *Neuro Fuzzy* nestes tipos de problema se explica pois processa informações imprecisas com a ajuda de funções de pertinência e regras do tipo “se-então”. Enquanto a lógica clássica postula que um elemento sempre pertence ou não pertence a um grupo, a lógica *Fuzzy* permite um estado gradual de pertinência.

Para mensurar a qualidade do modelo desenvolvido, o mesmo foi comparado com modelos de regressão linear clássicos (RL), metodologia normalmente utilizada em M&V. Os parâmetros de comparação utilizados serão os mesmos sugeridos pelo PIMVP (EVO, 2012): análise do coeficiente de determinação (R^2) e comparação do EPR da estimativa.

A implementação da metodologia aqui proposta desenvolveu um modelo *Neuro Fuzzy* do comportamento do consumo de energia elétrica do centro de distribuição refrigerado, com maior representatividade do que o modelo linear clássico. Assim, estendendo a aplicação de inteligência artificial para o mercado de eficiência energética, especificamente para modelar o consumo de energia no período de linha de base.

1.1. Hipótese

A seguinte hipótese foi verificada nesta dissertação:

“Para a modelagem do consumo de energia de um centro de distribuição refrigerado, um modelo Neuro Fuzzy apresenta maior representatividade do que o método convencional, baseado em regressão linear múltipla.”

Para efeito de comparação, foram utilizados os critérios estabelecidos pelo PIMVP (EVO, 2012), sendo a análise do coeficiente de determinação (R^2) e comparação do erro padrão relativo (EPR) da estimativa.

1.2. Objetivos

Esta dissertação teve como objetivo principal o desenvolvimento de um modelo matemático da linha de base para o Centro de Distribuição Refrigerado, válido segundo os critérios do PIMVP (EVO, 2012), utilizando uma das técnicas de inteligência artificial, o sistema de inferência *Neuro Fuzzy*.

Como objetivos secundários, tem-se:

- Determinar a melhor opção de M&V e de fronteira de medição de acordo com as particularidades da instalação, a economia de energia estimada e as AEEs executadas;
- Definir o período da linha de base que melhor representa todos os modos de funcionamento da instalação;
- Tratar os dados de consumo de energia e definir as variáveis independentes que explicam o comportamento energético da instalação;
- Desenvolver modelos com RL;
- Desenvolver os modelos Neuro Fuzzy.

2. REVISÃO BIBLIOGRÁFICA

2.1. Centro de Distribuição Refrigerado

Diversos produtos demandam por cuidados especiais durante sua cadeia produtiva, como exemplos os alimentos, que são os produtos perecíveis mais conhecidos, mas não podemos ignorar os remédios, as flores, os cosméticos e as obras de arte. Estes produtos perecíveis exigem que a temperatura seja mantida em níveis adequados durante todo o processo de produção, transporte e armazenagem, até seu consumo final.

Para cumprir seu papel, além de armazenar e distribuir os produtos, a cadeia produtiva e de logística refrigerada deve manter a temperatura adequada dos produtos perecíveis, portanto precisa imóveis e veículos adaptados com equipamentos de refrigeração especialmente projetados para este fim. A cadeia produtiva exige que sistemas complexos de refrigeração sejam projetados e operados adequadamente, segundo normas específicas de higiene e saúde. Tais normas vêm sendo aperfeiçoadas para prevenir doenças, degradação precoce de produtos e insalubridade do ambiente de trabalho (ABNT, 2014).

Paralelo ao aperfeiçoamento das normas, a mudança no estilo de vida, o aumento da renda per capita, a introdução de alimentação rápida e a menor disponibilidade de mão de obra doméstica para preparo de alimentação nas residências, fizeram com que o consumo de produtos refrigerados e congelados seja cada vez mais relevante para o mercado. Para atender este mercado crescente, faz necessário o desenvolvimento de novas tecnologias para ampliação de produtividade neste setor. A ampliação desta produtividade passa necessariamente pela redução de custos operacionais, que inclui a aplicação de ações de eficiência energética (AEEs).

O funcionamento dos centros de distribuição refrigerados está incontestavelmente ligado ao consumo de energia sob diversas formas (ZAJAC, 2016). Sabe-se que, em média, 80% do consumo de energia de um centro de distribuição se concentra nos sistemas de refrigeração, assim estudar eficiência energética nestes estabelecimentos é aperfeiçoar os sistemas de geração, distribuição e consumo de frio.

2.2. Modelos de Consumo de Energia

Idealmente, a diminuição do custo energético seria visível na redução das contas de energia, não sendo sempre o caso. Fatores como mudanças no volume de produção, podem causar acréscimo substancial na conta de energia. No entanto, contas de energia aumentando, após um projeto para redução ser implementado, são problemas que podem levar a questionamentos sobre a eficácia do projeto e se as reduções nos gastos estão sendo atingidas (SHONDER e HUGHES, 2006).

O conceito de Medição e Verificação (M&V) foi desenvolvido com o objetivo de se criar uma metodologia para mensurar a eficácia das ações de eficiência energética implementadas em diversas instalações, podendo ser residenciais, comerciais ou industriais (LEITE, 2010). A utilização deste conceito separa a influência dos fatores externos ao projeto de eficiência energética, evidenciando o impacto do mesmo nas contas de energia.

O conceito de M&V pode ser utilizado em uma empresa: (i) como parte de um contrato de desempenho, ou documento equivalente, firmado entre uma ESCO e seu cliente (SILVA, 2011); (ii) para controlar o consumo de energia em processos de produção, para decidir sobre ações de eficiência energética, para acompanhar mudanças e melhorias em eficiência energética (BUNSE et al., 2011); (iii) para analisar se a meta inicial de um projeto de eficiência energética foi atingida e, conseqüentemente, determinar o sucesso do mesmo (XIA e ZHANG, 2013). Estas atividades de M&V de economias de energia são guiadas pelo Protocolo Internacional de Medição e Verificação de Performance – PIMVP (EVO, 2012).

Um dos propósitos do PIMVP (EVO, 2012) é aumentar os investimentos em eficiência energética em todo o mundo, ao documentar termos comuns e métodos para avaliar o desempenho energético de projetos de eficiência e ao fornecer métodos para determinar as economias de maneira padronizada. Assim, diretores de empresas podem comprovar as economias financeiras em função de um determinado investimento, tomando decisões baseadas em estimativas com baixa incerteza pois são calculadas utilizando fatos, valores medidos e metodologia padronizada internacionalmente.

Conforme o PIMVP (EVO, 2012), a economia de energia não pode ser medida diretamente, uma vez que economia representa a ausência do consumo desta. A economia é determinada comparando-se o consumo medido anteriormente e o consumo medido posteriormente à implementação de um programa, e realizando ajustes adequados às alterações nas condições de uso. Segundo Osés et al. (2016), a abordagem mais comum é desenvolver um modelo de consumo de energia antes da AEE ser implementada e, em seguida, comparar o

consumo medido após a implementação da AEE com a estimativa resultante da aplicação do modelo para as condições climáticas e operacionais pós-AEE.

Para ilustrar o processo de M&V, o PIMVP (EVO, 2012) propõe o gráfico da Figura 1, que mostra o histórico do consumo de energia de uma planta industrial fictícia, antes e depois da implementação de uma AEE. Neste caso, após a execução da AEE, a produção da fábrica também aumentou. A fim de mensurar adequadamente o impacto da AEE, o efeito do aumento de produção deve ser eliminado. Assim se deve analisar a relação entre consumo de energia e o volume de produção antes da AEE ser implementada, relação denominada como no modelo energético da linha de base. Utilizando o modelo da linha de base é possível estimar, com certa precisão, qual teria sido o consumo energético no período de determinação (pós-AEE), caso a ação não tivesse sido implementada. Este consumo energético é denominado de linha de base ajustada (EVO, 2012).

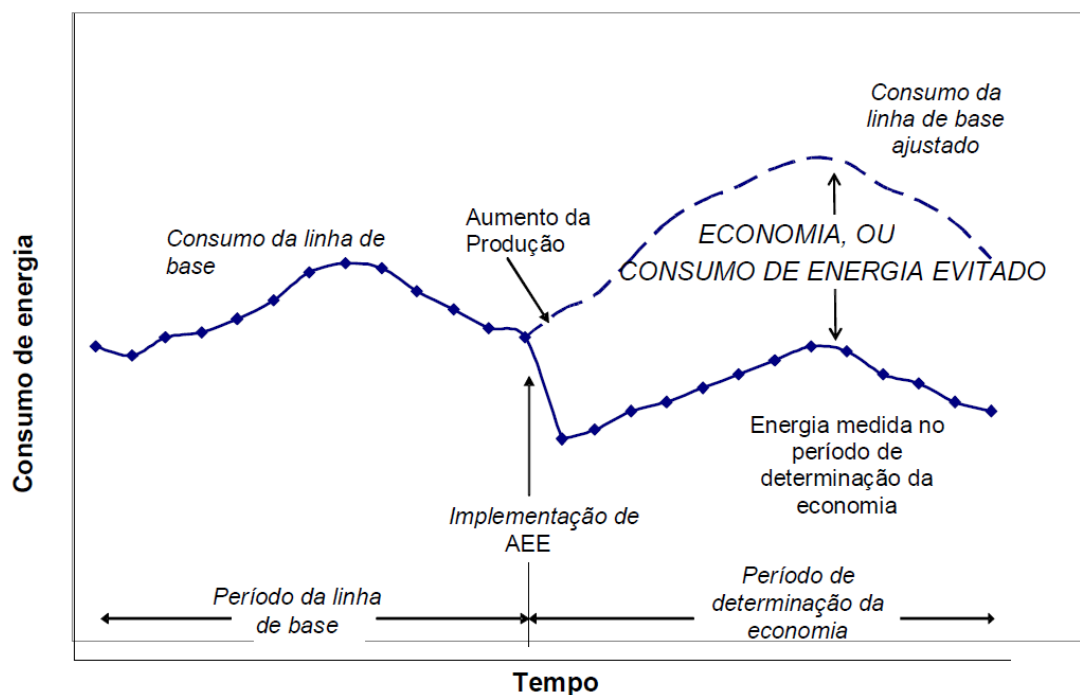


Figura 1: Exemplo de Histórico de Energia.
Fonte: EVO (2012)

O “consumo de energia evitado” (economia) é a diferença entre o consumo da linha de base ajustado e a energia que foi realmente consumida, medido durante o período de determinação da economia. No exemplo da Figura 1, sem o ajuste, a economia de energia teria sido calculada como inferior a economia real (EVO, 2012).

Para reportar adequadamente a ‘economia’, os ajustes devem contemplar as diferenças nas condições entre o período da linha de base e os períodos de determinação da economia. O desafio no desenvolvimento do modelo da linha de base reside na determinação

de quais são as variáveis que podem influenciar o consumo de energia e, assim, distorcer o cálculo da economia, no caso de as mesmas não serem contabilizadas nos ajustes. Como no exemplo citado do volume de produção, mas podem ser quaisquer outras variáveis (climáticas ou tempo de utilização), chamadas variáveis independentes (EVO, 2012).

O PIMVP (EVO, 2012) não especifica os métodos que devem ser utilizados para modelagem da linha de base, mas pontua que podem ser tão simples como um valor constante (sem ajuste), ou tão complexa como várias equações não-lineares, de parâmetros múltiplos, cada uma correlacionando energia com uma ou mais variáveis independentes. Por outro lado, o PIMVP (EVO, 2012) exige a utilização de técnicas matemáticas válidas e orienta a utilização de técnicas estatísticas para avaliação da validade ou não dos métodos matemáticos.

Para avaliar até que ponto um modelo particular explica a relação entre o consumo de energia e as variáveis independentes, o PIMVP (EVO, 2012) propõe alguns testes, sendo eles:

- Análise do coeficiente de determinação (R^2), considerando que um valor superior a 0,75 é indicativo razoável de uma boa relação causal entre a energia e as variáveis independentes. Quando o modelo apresentar um R^2 baixo, o PIMVP (EVO, 2012) sugere a inclusão de variáveis independentes adicionais ou uma forma funcional diferente.
- Comparação do EPR da estimativa com o valor de consumo médio, onde valores de erro menores que 10% do valor de consumo médio são aceitáveis.

O PIMVP (EVO, 2012) destaca ainda que quando se utilizam modelos de regressão, um dos erros que pode ser introduzido é o modelo matemático utilizar uma forma funcional inadequada. Por exemplo, uma relação linear pode ser utilizada incorretamente na modelagem de uma relação física fundamentalmente não linear. Modelar uma relação não linear com um único modelo linear introduz um erro desnecessário. Em vez disso, pode ser adequado tentar relações de ordem mais alta, outras formas funcionais ou ainda modelos não convencionais.

Dada a quantidade de técnicas matemáticas disponíveis atualmente para modelagem, e a necessidade de simplificar e acelerar o processo, uma das tarefas do profissional de M&V é escolher a técnica matemática mais adequada para a aplicação desejada.

2.2.1. Aplicação de Modelos de Consumo de Energia

Segundo Oses et al. (2016), o método usual para modelagem de consumo de energia é agregar os dados por período de comparação (por exemplo, dia ou mês) e construir um modelo

de regressão linear com os dados agregados. Em seguida, a incerteza é medida usando estatísticas tradicionais e teoria de regressão linear. Modelos deste tipo foram desenvolvidos com sucesso por Shonder e Hughes (2006), Carpenter et al. (2010), Kim e Haberl (2015) e Franconi e Jump (2017).

Shonder e Hughes (2006) utilizaram dados mensais das contas de energia para determinar a economia de consumo, demanda e custo de energia após a implementação de um projeto de bomba de calor geotermal em áreas residenciais de uma base militar. Os dados foram utilizados para desenvolver um modelo de regressão linear múltipla, utilizando como variáveis independentes graus dia de refrigeração e de aquecimento (GDR e GDA), similar aos modelos sugeridos pela ASHRAE (2002). Os autores utilizaram o valor de R^2 para analisar os resultados e conseguiram resultados acima do recomendado pelo PIMVP (EVO, 2012), R^2 na ordem de 0,97.

Carpenter et al. (2010) examinaram se modelos de regressão com dados de consumo de energia mensais podem ser utilizados para calcular o consumo diário e analisaram o quanto a escala de tempo dos dados afeta os esforços para entender a performance energética fundamental de edifícios. Com este propósito os autores compararam modelos de regressão diários e mensais para quatro edifícios comerciais e uma instalação industrial. Os coeficientes dos modelos diário e mensal se mostraram aproximadamente semelhantes para três dos quatro edifícios comerciais. Entretanto, para um dos edifícios comerciais os coeficientes apresentaram divergência pois o edifício tem perfil de ocupação diferente aos finais de semana, portanto o modelo mensal não pôde ser utilizado para calcular o consumo diário neste caso. Os autores propuseram que em situações parecidas é necessário criar modelos de regressão diferentes para cada tipo de dia ou, sugerem ainda, que se utilizem dados com maior frequência, como dados diários, se estiverem disponíveis.

Kim e Haberl (2015) propuseram um modelo para o consumo de energia mensal, utilizando regressão, para edifícios com diferentes perfis de consumo energético devido aos diferentes perfis de ocupação dos mesmos. O modelo foi desenvolvido para edifícios comerciais. Para considerar a ocupação no desenvolvimento do modelo, eles utilizaram o número de feriados como uma variável independente adicional, além das temperaturas máxima e mínima, que representam a influência da variação climática no consumo de energia dos edifícios. Neste trabalho, como descrito no item Materiais e Métodos, foi utilizada a movimentação de pallets como variável independente considerando a ocupação ao desenvolver o modelo.

Kim e Haberl (2015) analisaram a metodologia proposta aplicando-a em um edifício de escritórios no centro do Texas. Dados do consumo de energia armazenados previamente a cada 15 minutos foram utilizados para desenvolver um modelo diário do consumo e para comparação com o consumo mensal. A temperatura de bulbo seco externa horária foi utilizada para definir a média mensal das temperaturas, além das mínimas e máximas diárias, esses dados foram utilizados como variáveis independentes no modelo mensal. Os dados foram utilizados para desenvolver dois modelos distintos, ambos utilizando regressão linear múltipla, com a diferença de um modelo possuir um termo a mais, o “número de feriados”. O resultado obtido mostra que o modelo que considera o número de feriados é estatisticamente mais preciso, desta maneira, o modelo introduz menos incerteza no cálculo de economias energéticas quando comparado ao modelo com apenas a temperatura externa como variável independente.

No trabalho de Carpenter et al. (2010), foi utilizada a regressão linear com múltiplas variáveis. Os autores investigaram a generalidade dos resultados, comparando modelos de regressão utilizando somente a temperatura externa como variável independente com modelos que utilizam outras variáveis independentes. Os resultados indicam que a variação no uso de energia causada pela radiação solar, umidade do ar externo e perda de calor para o solo é maior na escala de tempo diária do que na escala de tempo mensal. No entanto, essas variáveis são suficientemente correlacionadas com a temperatura do ar externo, de modo que a capacidade preditiva geral dos modelos baseados na temperatura do ar externo ainda é bastante boa.

Subbarao et al. (2011) sugeriram que modelos com múltiplas variáveis independentes são mais apropriadas para determinados casos e ilustraram o método desenvolvido com dois estudos de caso: (i) utilizando dados diários gerados por um modelo de um grande hospital gerado em *DOE 2.1E*; e (ii) para o consumo real de dois grandes edifícios comerciais. Ambos modelos foram desenvolvidos para estimar a carga térmica de resfriamento utilizando RNA como método de modelagem.

Por sua vez, Heo et al. (2013) propuseram uma abordagem diferenciada, baseada no Processo Gaussiano (PG) que pode representar o comportamento não linear do consumo de energia, interações multivariáveis e correlações temporais, enquanto quantifica a incerteza associada às previsões ponto-a-ponto. O período pós-retrofit analisado pelos autores apresentou uma variação de temperatura maior do que no período da linha de base. Esta diferença, não impossibilitou a utilização do modelo, mas fez com que nos meses mais frios, novembro, dezembro e janeiro, a incerteza resultante fosse maior do que nos meses mais quentes do ano. Ainda assim, a incerteza da economia anual ficou dentro do estabelecido pelo PIMVP (EVO,

2012). Na prática, projetos de M&V enfrentam a escassez de dados, o que pode ter os efeitos reduzidos com o cálculo da incerteza ponto a ponto.

Heo et al. (2013) concluíram que as técnicas de modelagem estatística comumente usadas para M&V têm duas limitações. Em primeiro lugar, elas não capturam as interações entre as variáveis independentes. Consequentemente, comportamentos complexos de energia podem não ser adequadamente previstos pelos modelos usados para M&V.

Kreider e Haberl (1994) analisaram modelos criados para uma competição criada pela ASHRAE e concluíram que a maioria dos algoritmos melhor classificados foram desenvolvidos com base em redes neurais e o algoritmo vencedor usou como base a modelagem Bayesiana utilizando redes neurais.

Morales (2012) conclui que na maioria das vezes, a modelagem altamente precisa do consumo de energia não se enquadra nas restrições do orçamento de projeto. Nesse caso, é responsabilidade do gerente do projeto administrar as expectativas do cliente, além do tempo e do esforço do analista de energia, para atender às necessidades do projeto, mantendo-se dentro do orçamento.

2.2.2. Desenvolvimento de Modelos

A modelagem matemática é utilizada em M&V para preparar o termo dos ajustes de rotina. A modelagem implica encontrar uma relação matemática entre variáveis dependentes e independentes. A variável dependente, habitualmente o consumo de energia, é modelada como sendo regida por uma ou mais variáveis independentes X_i (EVO, 2012).

Morales (2012) resumiu os métodos de modelagem energética em três tipos, Fenomenológica ou Progressiva (*forward*), Regressiva ou Inversa (*inverse*) e Híbrida (*hybrid*) descritos na Tabela 1. A modelagem fenomenológica utiliza equações fundamentais de engenharia (por exemplo, método de equilíbrio de calor) e documentação de projeto disponíveis, para criar uma representação matemática do consumo de energia. Por sua vez, a modelagem regressiva utiliza dados de consumo de energia reais (por exemplo, contas de energia) e dados reais de variáveis independentes (por exemplo, temperatura externa) para desenvolver uma curva de regressão que atenda aos requisitos de precisão mínima.

A modelagem híbrida é uma combinação das técnicas de modelagem Fenomenológica e Regressiva. Morales (2012) diz ainda que a modelagem fenomenológica pode ser muito detalhada e demorada, dependendo da complexidade da instalação e das necessidades do projeto. A modelagem regressiva, também pode ser demorada, dependendo da complexidade e da variância da operação da instalação. A modelagem híbrida, por sua vez,

combina os benefícios de cada um dos outros dois tipos de modelagem, não é tão detalhado quanto à modelagem fenomenológica, mas os resultados podem ser gerados mais rapidamente.

Tabela 1: Métodos de modelagem energética.

Fenomenológica	Regressão	Híbrida
Equações de engenharia fundamentais (por exemplo, método de equilíbrio de calor) e documentação de construção disponível usada para criar uma representação matemática de um edifício.	Dados de construção reais (por exemplo, contas de serviços públicos, dados de tendência do sistema de automação predial) usados para criar um modelo de regressão implícito de um edifício.	Combinação de técnicas de modelagem direta e inversa.
Equações fundamentais de engenharia usadas para estimar a energia consumida por uma instalação.	Dados reais e correlações suficientes para variáveis independentes (por exemplo, temperatura do ar externa) usados para desenvolver uma curva de regressão que atenda aos requisitos de precisão mínima (por exemplo, Guia ASHRAE 1402002, Medição de Energia e Demanda de Economia).	Combinação de equações fundamentais de engenharia e dados de consumo real usados para estimar a economia de energia.
Pode ser muito detalhado e demorado, dependendo da complexidade do edifício e das necessidades da equipe do projeto.	Pode ser demorado, dependendo da complexidade e da variância da operação predial.	Não tão detalhado quanto a modelagem progressiva: os resultados podem ser gerados mais rapidamente do que com os outros dois métodos.
Pode ser flexível, permitindo o ajuste/alteração de muitos parâmetros/variáveis.	Relativamente rígida, pois há poucos parâmetros ou variáveis para ajustar, se houver.	A parte regressiva do modelo é muito rígida, pois é baseada em dados e correlações reais. A parte fenomenológica pode ser flexível, dependendo do nível de detalhes.
Pode fornecer detalhes do sistema e dos equipamentos para diagnosticar deficiências operacionais.	Normalmente, não fornece detalhes do sistema ou dos equipamentos.	Pode fornecer detalhes do sistema e dos equipamentos para diagnosticar deficiências operacionais.
Os modelos podem ser holísticos, usados para estimar os efeitos da radiação solar, padrões de ocupação e carga térmica interna.	Os efeitos da radiação solar, dos padrões de ocupação e da carga térmica interna podem ser estimados apenas se forem variáveis independentes que afetam a precisão da curva de regressão.	Modelos não são holísticos. Normalmente, eles são apenas de nível de sistema um sistema ou de um equipamento. Como tal, eles não consideram nem estimam os efeitos de interação dos sistemas.

Fonte: Morales (2012).

Embora o PIMVP (EVO, 2012) não especifique o método de modelagem que deve ser utilizado, os modelos de linha de base publicados recentemente empregaram o método da regressão linear, usando as equações propostas pelo guia ASHRAE (2002), é o caso por exemplo dos modelos desenvolvidos para aplicação do conceito de M&V em instalações que utilizam aquecimento, refrigeração ou ar condicionado. O guia propõe formas simples de modelos regressivos, lineares e estacionários, e usam o conceito de “ponto de mudança”,

incluindo um valor constante independente do clima, um ou mais parâmetros dependentes do clima e “pontos de mudança”, nos quais o modelo alterna de dependente para independente do clima. A Figura 2 mostra graficamente algum destes modelos propostos pela ASHRAE (2002), com legenda abaixo de cada um dos gráficos apresentados (simples de um parâmetro, dois parâmetros, três parâmetros aplicado a instalações que utilizam aquecimento, três parâmetros para o uso de energia para resfriamento, quatro parâmetros para aquecimento, quatro parâmetros para resfriamento, cinco parâmetros onde há pontos de mudança separados para o uso de energia de aquecimento e resfriamento).

Os modelos propostos pelo guia pressupõem correlação linear entre temperatura ambiente e consumo de energia. Portanto, Franconi e Jump (2017) relataram que esses modelos fornecem uma abordagem simples e poderosa para entender a relação do clima com o consumo de energia, mas não consideram o comportamento dinâmico do consumo de energia.

Para reduzir a incerteza dos modelos propostos pela ASHRAE (2002), pode-se adotar três abordagens, sendo elas: (i) incluir outras variáveis independentes, principalmente aquelas que representam a variação das condições operacionais da instalação; (ii) utilizar outras formas funcionais; e (iii) utilizar modelos que consideram o atraso no efeito das variáveis sobre o consumo de energia no tempo, como fizeram Heo et al. (2013), que utilizaram valores de três tempos (t , $t-1$ e $t-2$) para capturar este efeito.

Franconi e Jump (2017) descrevem que dados amplamente disponíveis e os recentes avanços no poder da computação estão fomentando o desenvolvimento de novas tecnologias que agilizam a coleta de dados e realizam análises avançadas. A abordagem está subjacente aos métodos de medição e verificação (M&V) da próxima geração, aos quais referem-se como M&V avançada. A M&V avançada tem vantagens sobre a análise das contas de energia baseada em regressão tradicional, incluindo feedback mais rápido, melhor resolução e maior precisão do modelo devido a muitos mais pontos de dados.

Franconi e Jump (2017) investigaram, através de um estudo de caso, se a aplicação de métodos avançados de M&V pode ter um benefício adicional, ou seja, se a economia após a execução da AEE pode ser determinada com precisão suficiente para ser discernível usando dados disponíveis nos sistemas de automação das instalações. Os mesmos autores observam que desenvolvimentos recentes na modelagem de M&V incluem novas formas de modelos de regressão que incorporam variáveis indicadoras do comportamento dinâmico do consumo de energia. Por exemplo, alguns modelos consideram o horário da semana como variável independente no consumo de energia. Este tipo de modelo pode capturar a relação não-linear entre a temperatura do ar externo e a carga térmica.




Figura 2: Modelos regressivos, lineares e estacionários, que usam o conceito de “ponto de mudança”.
Fonte: ASHRAE (2002).

Segundo Oses et al. (2016), na literatura existem muitas abordagens diferentes que se baseiam em simulações fenomenológicas e modelos determinísticos com diversos objetivos de melhoria de processos industriais, em termos de qualidade, tempo e matéria-prima. Mas os autores complementam que técnicas de simulação de regressão têm contribuído para a melhoria contínua da competitividade no setor de manufatura. Tais modelos têm sido utilizados para

identificar possíveis melhorias sem a necessidade de se recorrer a pesados cálculos fenomenológicos.

Como exemplo da aplicação do modelo citado anteriormente, o trabalho de Oses et al. (2016) desenvolveu um modelo para o consumo de energia de uma máquina de injeção em uma fábrica, utilizando os conceitos de M&V avançado. O resultado alcançado foi um modelo com incerteza reduzida, uma vez que fornece limites mais estreitos para os possíveis valores da estimativa da energia consumida. Esta melhor aproximação da gama de valores possíveis para a estimativa foi conseguida combinando as estatísticas tradicionais e os métodos de aprendizagem automática.

Independentemente do método de modelagem utilizado, um planejamento adequado dos experimentos para coleta de dados pode determinar o sucesso da modelagem de um sistema. Para aplicação industrial, um dos desafios a se superar na área de modelagem de sistemas é a necessidade de se impor perturbações conhecidas e controladas a estes, o que na prática pode ser inviável em sistemas em operação. A solução proposta por Isermann (2006) considera que para processos com perturbação inerentes à sua operação normal, o método de identificação pode ser aplicado diretamente, eventualmente sob condições suficientemente ricas de perturbação.

2.3. Lógica *Fuzzy*

A teoria *fuzzy* foi introduzida pela primeira vez por Lotfi Zadeh em 1965, desenvolvendo a teoria dos conjuntos clássicos. De acordo com a teoria clássica dos conjuntos, uma variável pertence a um conjunto ou não. A teoria *fuzzy* não dá uma resposta precisa, mas permite que a pertinência seja parcial em diferentes conjuntos. As funções contínuas de pertinência, que variam entre 0 e 1, são empregadas para quantificar o pertencimento parcial.

Isermann (2006) explica que o processamento de informações por um ser humano baseia-se em regras que não são formuladas precisamente. Elas são construídas a partir de experiências quantitativas e qualitativas e não tão claramente estruturadas como a programação de computadores requer. A lógica *Fuzzy* se apresenta, neste contexto, como uma abordagem que permite o processamento da experiência e conhecimentos humanos utilizando computadores digitais. A lógica *Fuzzy* processa informações imprecisas com a ajuda de funções de pertinência e regras do tipo “SE-ENTÃO”.

A lógica *Fuzzy* pode ser entendida como uma extensão da lógica clássica. Enquanto a lógica clássica postula que um elemento sempre pertence ou não pertence a um grupo, a lógica *Fuzzy* permite um estado gradual de pertinência (ISERMANN, 2006). Os sistemas difusos,

incluindo a lógica *Fuzzy* e a teoria do conjunto *fuzzy*, são uma alternativa às noções tradicionais de teoria e lógica de conjuntos que têm suas origens na filosofia grega antiga, além de apresentarem aplicações na vanguarda da Inteligência Artificial. O conceito principal dos sistemas *fuzzy* é estender a clássica modelagem de valores para modelagem de conceitos e atributos como alto, rápido ou velho, em um sentido de verdade parcial. Isso significa que uma pessoa não é apenas vista como alto ou não alto, mas tão alto para um certo grau entre zero (0) e um (1) (LI, 2006).

Os modelos *fuzzy* se dividem basicamente em duas categorias, que diferem entre si fundamentalmente em suas habilidades para representar diferentes tipos de informação. A primeira categoria inclui modelos linguísticos, que são conhecidos como modelos *fuzzy* Mamdani. Por sua vez, a segunda categoria de modelos *fuzzy* baseia-se no método de raciocínio Takagi-Sugeno (TS). Estes modelos são formados por regras lógicas que têm uma parte antecedente *fuzzy* e um conseqüente funcional. São combinações de modelos *fuzzy* e não-*fuzzy*.

2.3.1. Estrutura da Lógica *Fuzzy* Mamdani

Nos modelos *fuzzy* Mamdani, as quantidades *fuzzy* são associadas com rótulos linguísticos, ou seja, um modelo *fuzzy* é essencialmente uma expressão qualitativa do sistema. A configuração básica de um modelo de lógica *Fuzzy* é composta por um fuzificador, uma base de regras *fuzzy*, uma função de ativação e um defuzificador, onde a base de regras *fuzzy* consiste de uma coleção de regras “se-então”. A função de ativação usa estas regras *fuzzy* para determinar uma relação entre as entradas e as saídas (LI, 2006). As regras *fuzzy* têm a forma dada na Equação 1:

$$R^i: SE x_1 \text{ é } \Gamma_1^i \text{ e } \dots \text{ e } x_n \text{ é } \Gamma_n^i \text{ então } y \text{ é } G^i \quad (1)$$

Onde:

Γ_j^i e G^i : são conjuntos *fuzzy*

$x = (x_1, \dots, x_n)^T \in U$: são variáveis linguísticas de entrada

$y \in V$: são variáveis linguísticas de saída, $i = 1, 2, \dots, q$

q : é o número de regras.

2.3.2. Estrutura da Lógica *Fuzzy* TS

A principal desvantagem dos sistemas de lógica *Fuzzy* é a falta de uma metodologia sistemática de modelagem e controle. A análise de estabilidade de sistemas *fuzzy* é difícil e a sintonia de parâmetros é geralmente um processo demorado, devido à natureza não-linear e multiparamétrica dos sistemas de controle *fuzzy*. Para resolver esses problemas, um sistema

linear pode ser adotado como parte de uma regra *fuzzy*, o que leva ao modelo *fuzzy* TS (TAKAGI e SUGENO, 1985).

Modelos baseados no método TS integram a capacidade dos modelos linguísticos para a representação do conhecimento qualitativo com grande potencial para expressar informação quantitativa. Além disso, este tipo de modelo permite uma aplicação relativamente fácil de várias técnicas de aprendizagem poderosas para a identificação do sistema (LI, 2006).

Cada uma das regras de um modelo *fuzzy* possui uma dependência linear intrínseca com as variáveis independentes do modelo, o método TS se apresenta como a solução capaz de atuar como supervisor de interpolação entre vários modelos lineares específicos para diferentes faixas das variáveis independentes. Segundo Li (2006), um sistema *fuzzy* TS é adequado para modelar sistemas não-lineares interpolando entre múltiplos modelos lineares. As funções de pertinência de saída são lineares ou constantes no modelo TS, fazendo com que seja o método preferido para análise matemática e tem maior eficiência computacional.

Li (2006) relata que, em vez de usar conjuntos nebulosos na saída, as regras no sistema fuzzy TS adotam funções lineares, que representam relações de entrada-saída. Uma regra fuzzy TS é descrita como (Equação 2 e Equação 3):

$$R_T^1: \text{SE } x_1 \text{ é } F_1^1 \text{ e } \dots \text{ e } x_n \text{ é } F_n^1, \quad (2)$$

$$\text{então } y^1 = c_0^1 + c_1^1 x_1 + \dots + c_n^1 x_n, \quad (3)$$

Onde:

F_i^1 são conjuntos fuzzy

c_i são parâmetros de valores reais

y^l é a saída do sistema, onde $l = 1, 2, \dots, q$.

Ou seja, nas regras *fuzzy* TS, a entrada é nebulosa, mas a saída é nítida, ou seja, a saída é uma combinação linear das variáveis de entrada. Neste contexto, em geral, é difícil determinar empiricamente as equações lineares para a saída. Portanto, frequentemente as regras são obtidas com técnicas de modelagem usando dados de entrada e saída, como é o caso do *Neuro Fuzzy* ou *ANFIS* (*Adaptive Neuro-Fuzzy Inference System*), um tipo de modelo TS, que utiliza as técnicas de aprendizagem da Rede Neural Artificial (RNA) para determinar, de forma adaptativa, os parâmetros do modelo, a fim de estabelecer a relação entre variáveis de entrada e de saída.

Tanhaei et al. (2017) justificou a utilização do sistema de inferência *ANFIS* por ser uma abordagem poderosa para modelar/mapear a relação de entrada e saída em sistemas

complexos e não lineares, possuindo algoritmo de aprendizado eficiente e por apresentar maior velocidade de convergência, comparando com outros modelos.

Por sua vez, Lerkkasemsan (2015) justificou a utilização do sistema de inferência *ANFIS* pois, enquanto a Rede Neural Artificial (RNA) tem a capacidade de aprender através de dados reais de um sistema, o conhecimento da RNA é apresentado de forma de difícil interpretação. Por outro lado, o sistema de inferência *fuzzy* é capaz de traduzir o conhecimento da RNA para uma linguagem humana de fácil entendimento. No entanto, o autor ponderou que o sistema *fuzzy* por si só carece de uma capacidade de aprendizagem. Portanto, a combinação de RNA e sistema de inferência *fuzzy* criam um aproximador que tem a capacidade de aprender com dados reais e traduzir o resultado ilegível para a linguagem humana.

2.3.3. Aplicação do Sistema de Inferência Adaptativa *Neuro Fuzzy*

Nos últimos anos, o sistema de inferência *Neuro Fuzzy (ANFIS)*, como uma técnica de inteligência artificial, tem sido utilizado com sucesso para modelagem e simulação de vários tipos de processos (GHAEDI et al., 2013; MANDAL et al., 2015; REBOUH, BOUHEDDA e HANINI, 2016; QASAIMAH et al., 2012). Ghaedi et al. (2014) relataram o uso do modelo adaptativo de sistema de inferência *Neuro Fuzzy* para adsorção de 1,3,4-tiadiazol-2,5-ditiol em carbono ativado por nanopartículas de ouro. Eles também estudaram a aplicação da análise de componentes principais - sistema de inferência *Neuro Fuzzy* adaptativo (PCA-*ANFIS*) na adsorção de azul de metileno por carvão ativado (GHAEDI et al., 2013).

Em outro estudo, Mandal et al. (2015) utilizaram o *ANFIS* para modelar a remoção adsorptiva de íons As (III) e Cr (VI) em modo de lote e coluna usando o adipato de óxido de zircônio e etilenodiamina. Além disso, Rebouh, Bouhedda e Hanini (2016) aplicaram a técnica *ANFIS* para a previsão da capacidade de remoção de íons metálicos a partir de solução aquosa por um bioissorvente de palha de trigo. Qasaimah et al. (2012) explorou a *ANFIS* para avaliar as condições necessárias para sistemas aquáticos servirem como sumidouro para a remoção de íons metálicos.

Lilly Mercy e Prakash (2016) utilizaram modelagem *Fuzzy-ANFIS* para apoiar a análise da influência de três variáveis na resistência ao cisalhamento de peças de fibra de vidro com microcápsulas de auto reparação. As variáveis analisadas foram o tamanho e a concentração das microcápsulas e a concentração de catalizador adicionados na fabricação das peças, conduzindo 27 experimentos, conforme o planejamento de experimentos Ortogonal de Taguchi (três variáveis com três níveis). O modelo matemático gerou uma regressão com um R^2 de 0,9569 (LILLY MERCY e PRAKASH, 2016).

Lerkkasemsan (2015) utilizou o *ANFIS* para relacionar o efeito de três principais composições químicas, que são celulose, hemicelulose e lignina, para a reação de pirólise total de Pongomia em Nitrogênio. O R^2 do modelo gerado foi de 0,92. Isso demonstra que o modelo pode prever a pirólise de Pongomia em Nitrogênio com boa precisão.

Tao et al. (2016) utilizaram *ANFIS* para prever os parâmetros físico-químicos de tomates cerejas parcialmente desidratadas durante o período de estocagem. O *ANFIS* foi usado para prever o licopeno, o conteúdo fenólico total, cor e contaminação microbiana. Os coeficientes de determinação para todos os modelos *ANFIS* foram superiores a 0,86 e apresentaram melhor desempenho para predição quando comparados com os modelos desenvolvidos pela metodologia de superfície de resposta. Utilizando os modelos criados, foi possível visualizar os efeitos causados pelas condições de estocagem nos tomates cereja secos. Os autores concluíram com este estudo que modelagem utilizando *ANFIS* pode ser uma ferramenta eficaz para estudo da redução da qualidade e contaminação microbiológica de tomates cereja secos durante a estocagem, assim como identificar as condições ideais de conservação. Usando os modelos *ANFIS* construídos, os valores dos atributos físico-químicos e microbiológicos mencionados de tomates cereja parcialmente secos durante o armazenamento, dentro da faixa experimental atual, podem ser previstos sem análise química.

No conteúdo do estudo de Kayadelen et al. (2009), investigou-se a aplicabilidade do *ANFIS* para a predição do potencial de inchamento dos solos. Os conjuntos de dados experimentais de solos compactados retirados de diferentes locais de Niğde na Turquia foram utilizados para desenvolver os modelos *ANFIS*. Os valores de fração de grão grosseiro (*Coarse-Grained - CG*), fração de grão fino (*Fine-Grained - FG*), índice de plasticidade (*Plasticity Index - PI*) e densidade seca máxima (*Maximum Dry Density - MDD*) dos solos foram apresentados como parâmetros de entrada para os modelos *ANFIS*. Enquanto os 78 conjuntos de dados foram empregados para treinamento, 20 conjuntos de dados foram usados para testes. Após finalização das análises, observou-se que os valores previstos dos modelos *ANFIS* estão em concordância satisfatória com as contrapartes experimentais.

Tanhaei et al. (2017) utilizaram o sistema adaptativo de inferência neuro-fuzzy (*ANFIS*) para a modelagem da remoção adsorvente de *Methyl Orange (MO)* por quitosana magnética preparada. O desempenho da predição da *ANFIS* foi comparado com os resultados experimentais utilizando os valores do EAM, do EMQ, do EPAM e do coeficiente de correlação (R^2). Os modelos *ANFIS* desenvolvidos mostraram uma excelente análise de regressão com um $R^2 > 0,99$, bem como uma boa adequação dos valores previstos e experimentais para o processo estudado.

Como visto, estudos têm sido conduzidos no sentido de aplicar o sistema ANFIS para modelagem de diferentes sistemas e processos, modelando saídas em função de variáveis independentes. Esta relação entre entradas e saídas pode ser comparada ao comportamento do consumo de energia em função de variáveis climáticas e operacionais. Mas, embora os melhores modelos da linha de base tenham utilizado RNA como metodologia de regressão e que se saiba que o ANFIS apresenta como resposta um modelo de mais fácil interpretação do que um modelo RNA, não se encontra na base de dados pesquisada a aplicação deste tipo de abordagem para desenvolvimento de modelos para a linha de base do consumo de energia.

3. MATERIAIS E MÉTODOS

3.1. Contexto

A autora participou do estudo de viabilidade de um projeto de eficiência energética que foi aplicado ao Centro de Distribuição Refrigerado do Grupo Pão de Açúcar, localizado na cidade de Osasco-SP. O objetivo do projeto era economizar aproximadamente 20% de energia elétrica, sendo que, somente o conjunto de AEEs aplicadas ao sistema de refrigeração industrial fosse responsável por aproximadamente 90% desta economia e os outros 10% correspondessem às contribuições das economias no sistema de iluminação e sistemas menores de refrigeração.

Este projeto foi financiado pela empresa GreenYellow do Brasil, que tem como objetivo reduzir o consumo de energia dos estabelecimentos, garantindo esta eficiência a partir da entrega do projeto. Os serviços foram baseados em um Contrato de Eficiência Energética (CEE) na forma de *turnkey*. Contratos deste tipo englobam: estudo e concepção; execução e implementação; financiamento integral do projeto, monitoramento permanente do consumo para detecção em tempo real de anomalias e ações corretivas imediatas; garantia da eficiência durante a vigência do contrato; e compartilhamento de economia.

Para sustentar o CEE, foi necessário estabelecer um Plano de M&V, do qual o modelo desenvolvido para esta dissertação faz parte. O Plano de M&V estabeleceu como objetivo mensurar e monitorar a economia diariamente após a finalização do projeto. Para tanto, foi estabelecido como estratégia de M&V a opção C do PIMVP (EVO, 2012), que pressupõe o desenvolvimento de um modelo energético para o período de linha de base, que foi utilizado posteriormente para ajuste desta linha e comparado ao consumo energético após a implementação das AEEs. Esta comparação foi utilizada para quantificar a economia realizada no período de determinação.

Como descrito no item Centro de Distribuição Refrigerado na Revisão Bibliográfica, o consumo de energia de um Centro de Distribuição Refrigerado é influenciado por diversos fatores, fazendo com que o modelo seja não-linear e inviável de se conduzir por um viés fenomenológico.

3.2. Descrição da Instalação

O Centro de Distribuição, objeto de estudo deste trabalho, está localizado na cidade de Osasco – SP (Brasil), e a cada ano movimentada em média 205 milhões de toneladas de alimentos resfriados e congelados. Além das câmaras congeladas e resfriadas, o complexo abriga ainda duas casas de máquinas de refrigeração, laboratórios, escritórios administrativos, estacionamento para caminhões e carros, refeitório e academia.

A área total do terreno é de 70.000 m², com área total construída de 35.881 m². As câmaras resfriadas do galpão principal correspondem a aproximadamente 51% da área total construída; as câmaras congeladas do galpão principal correspondem a aproximadamente 25%; e as câmaras resfriadas do galpão de pescados respondem por outros 6% da área total construída. A Tabela 2 e a Figura 3 resumem as principais características do Centro de Distribuição.

Tabela 2: Descrição do Centro de Distribuição 2 – Osasco.

Área total do terreno	70.000 m ²
Área total construída	35.881 m ²
Usos e fontes de energia	<ul style="list-style-type: none"> ▪ Eletricidade <ul style="list-style-type: none"> ▪ 49% - Frio Industrial ▪ 15% - Ventilação e resistências das câmaras ▪ 07% - Bombeamento ▪ 05% - Iluminação ▪ 05% - Ventilação e ar condicionado ▪ 03% - Refrigeração galpão de pescados ▪ 16% - Outros
Consumo de energia no período da linha de base (1 ano)	16.891 MWh
Intensidade de energia no período da linha de base	0,471 MWh/m ² de área construída / 0,572 MWh/m ² de área refrigerada

Fonte: Autoria própria.

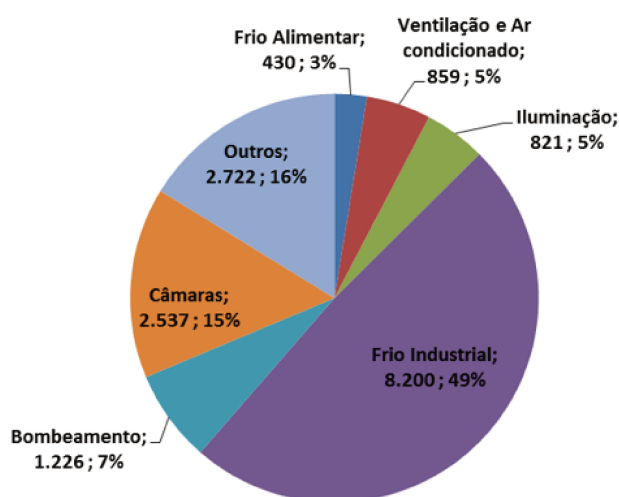


Figura 3: Distribuição do consumo de energia elétrica no período da linha de base do Centro de Distribuição.

Fonte: Autoria própria.

Foram executadas diversas AEEs no Centro de Distribuição, objeto de estudo deste trabalho. A economia total esperada (F), após a finalização destas AEEs, foi de 19,8%. A Figura 4 apresenta a distribuição da economia esperada.

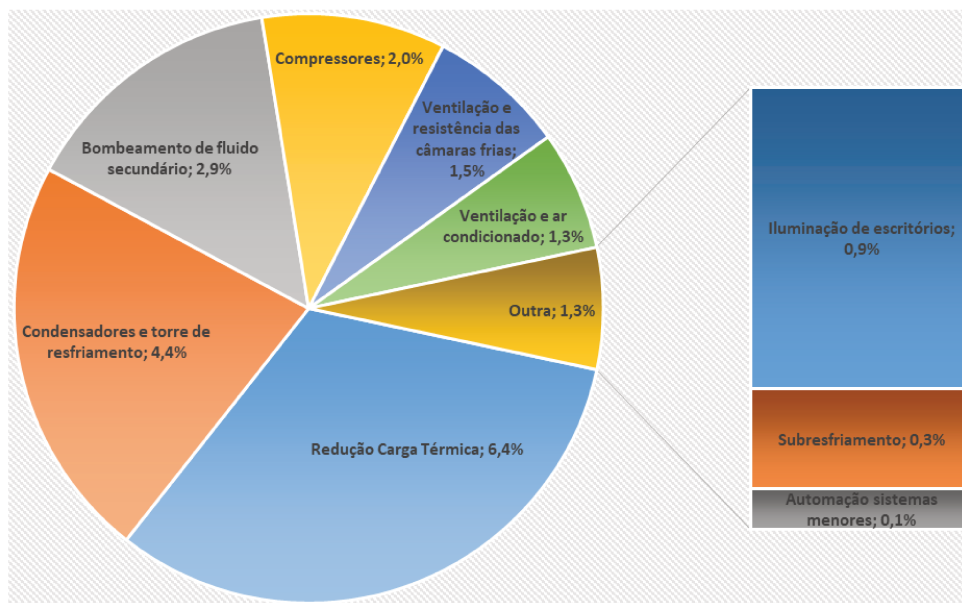


Figura 4: Distribuição relativa da economia esperada com as AEEs.

Fonte: Autoria própria.

3.3. Definição da Fronteira e Opção de Medição

Fluxos de energia estão presentes em diversos locais e de diversas maneiras dentro de uma instalação. Quando se deseja medir a economia de energia é necessário estabelecer quais os tipos de fluxos de energia que serão controlados. A esta etapa, o PIMVP (EVO, 2012), dá o nome de “Definição da Fronteira de Medição”.

O PIMVP (EVO, 2012) estabelece duas opções de fronteira de medição, ou seja, a economia pode ser determinada para toda a instalação ou para parte desta, dependendo dos objetivos da M&V. A fronteira pode ser tão estreita quanto o fluxo de energia através de um tubo ou condutor elétrico, ou tão larga quanto o consumo total de energia de uma ou muitas instalações.

Se o objetivo da M&V for ajudar a gerir apenas os equipamentos afetados pelo programa de economia, deverá ser estabelecido uma ou várias fronteiras de medição em torno destes equipamentos. Por outro lado, se o objetivo for ajudar a gerir o desempenho energético de toda a instalação, os medidores que medem o fornecimento de energia de toda a instalação poderão ser usados para avaliar o desempenho energético e a economia. A fronteira de medição neste último caso engloba toda a instalação.

Tendo definido a fronteira de medição, escolheu-se a opção que foi utilizada para M&V. O PIMVP (EVO, 2012) fornece quatro métodos para determinar a economia, denominados “Opção A”, “Opção B”, “Opção C” e “Opção D”. A escolha entre estas opções implica muitas considerações, principalmente a dimensão da fronteira de medição. Se for

decidido determinar a economia total da instalação, a “Opção C” ou a “Opção D” serão favorecidas. No entanto, se apenas é considerado o desempenho energético de um equipamento ou de um sistema, uma técnica de medição isolada pode ser mais adequada (“Opção A”, “Opção B” ou “Opção D”).

Para auxiliar a escolha de uma opção, o PIMVP (EVO, 2012) sugere uma lógica que leva em consideração todo o conjunto de condições, análises, orçamentos e avaliação profissional do projeto. A Figura 5 descreve essa lógica de maneira simplificada.




Figura 5: Processo de seleção da opção (simplificada).

Fonte: EVO (2012).

3.4. Definição do Período da Linha de Base e escala de tempo

O PIMVP (EVO, 2012) diz que o período de tempo a ser utilizado como o período da linha de base deve ser selecionado cuidadosamente, pois o período selecionado deve:

- Representar todos os modos de funcionamento da instalação. Este período deve cobrir um ciclo de funcionamento completo. Ao escolher o período, deve-se ter atenção ao fato de que o consumo de energia pode ser afetado significativamente pelas condições climáticas. De modo geral, é necessário, no mínimo, um ano de dados no período da linha de base para caracterizar um ciclo completo de operação;
- Incluir apenas períodos de tempo para os quais sejam conhecidos todos os fatores relativos à instalação que regem a energia;
- Coincidir com o período imediatamente anterior a execução da AEE.

Além disso, a escala de tempo pode ser tão curta quanto períodos sub horários, ou tão longas como uma escala mensal. Carpenter et al. (2010), indicam que, embora o uso de energia seja impulsionado por fatores que mudam na escala de tempo sub horária, esses efeitos são distribuídos de maneira bastante uniforme ao longo do tempo. Assim, modelos baseados em dados de escala de tempo mais longos podem caracterizar com precisão o uso de energia de uma instalação.

De acordo com Franconi e Jump (2017), a maior resolução dos dados (horário ou diário) pode proporcionar maior quantidade de pontos do que dados mensais. Como regra geral, quanto maior o número de pontos utilizados para desenvolver o modelo, mais preciso será o mesmo. Mas os autores observam que, conforme a resolução aumenta, a presença de correlação nos dados também aumenta. Este comportamento reduz a independência dos pontos e pode aumentar a incerteza no cálculo das economias.

Por sua vez, Heo et al. (2013) ponderam que desenvolver modelos para uma resolução fina dos dados (como exemplo, resolução horária) requer atenção especial para desenvolver um grupo de variáveis independentes que possibilitem o modelo capturar o comportamento energético complexo.

3.5. Coleta dos dados de consumo de energia

Após a escolha da opção, foi planejada e realizada a coleta de dados conforme recomendação do PIMVP (EVO, 2012) para a opção desejada.

O PIMVP (EVO, 2012) destaca que podem ser utilizados vários medidores para medir o fluxo de energia em uma instalação. Se um medidor fornece energia a um sistema que

interage com outros sistemas de energia, direta ou indiretamente, os dados deste medidor devem ser incluídos na determinação da economia. Por sua vez, podem ser ignorados os medidores que registram fluxos de energia não-interativos com os fluxos onde se aplica a AEE.

Com frequência os dados disponíveis apresentam falhas de medição, principalmente devido ao longo período necessário para avaliar um ciclo completo de operação, que normalmente é de, pelo menos, um ano. Nestes casos, o PIMVP (EVO, 2012) pondera que dados com problemas no período da linha de base não deverão ser substituídos por dados modelados, exceto quando se usar a Opção D. Quando os dados do período da linha de base estão em falta ou são inadequados, é necessário demandar outros dados reais para substituí-los, ou mudar o período da linha de base a fim de que contenha apenas dados reais. O Plano de M&V deve documentar a fonte de todos os dados da linha de base.

3.6. Definição de Variáveis Independentes

O PIMVP (EVO, 2012) explica que variável independente é um parâmetro que pode mudar regularmente e causar impacto mensurável no consumo de energia de um sistema ou instalação. Por exemplo, uma variável independente comum que rege o consumo de energia do edifício é a temperatura exterior. Do mesmo modo, em uma fábrica, o número de unidades produzidas em determinado período é frequentemente uma variável independente que afeta significativamente o consumo de energia.

A modelagem matemática pode ser utilizada para avaliar variáveis independentes se estas forem cíclicas, pode também ajudar a determinar quantas e quais as variáveis independentes devem ser utilizadas. Os parâmetros que têm efeito significativo no consumo da linha de base devem ser considerados na modelagem e analisados se possuem efeitos positivos no modelo ao serem considerados. Deve-se ainda registrar a faixa de variação das variáveis independentes para o qual o modelo é válido.

A escolha das variáveis independentes consideradas para o modelo requer conhecimento sobre a instalação a ser modelada e experiência na análise energética de instalações similares, para evitar a escolha de variáveis irrelevantes. Pois, variáveis irrelevantes podem causar dois tipos de problemas ao modelo: (1) enviesar os coeficientes das variáveis independentes correlacionadas, é o caso por exemplo de incluir humidade e temperatura de bulbo úmido; (2) no caso de não serem correlacionadas, mas simplesmente irrelevantes, o custo de coleta e tratamento de dados pode onerar o projeto. O PIMVP (EVO, 2012) diz ainda que avaliar a relevância das variáveis independentes requer experiência e intuição.

O PIMVP (EVO, 2012) ressalta que as variáveis independentes devem ser medidas e registradas ao mesmo tempo que os dados de energia. Por exemplo, os dados do clima devem ser registrados diariamente a fim de que possam ser totalizados para corresponder ao período mensal de medição de energia exato, o qual pode diferir do mês do calendário. A utilização de dados mensais médios da temperatura, para um período de medição de energia de um mês que não corresponda ao do calendário, introduz erros desnecessários na análise.

Como explicado anteriormente, com frequência os dados disponíveis apresentam falhas de medição, nestes casos, deve-se ter maior atenção para que os dados das variáveis independentes coincidam com os dados de energia. Além da recomendação de não utilizar dados modelados.

3.7. Desenvolvimento do Modelo com Regressão Linear Múltipla

Equações lineares simples e de múltiplas variáveis foram desenvolvidas utilizando a função PROJ.LIN do Excel. A função PROJ.LIN utiliza o método dos mínimos quadrados para calcular uma linha reta que melhor se ajusta aos dados e retorna uma matriz que descreve essa linha. A matriz retornada pela função PROJ.LIN tem a seguinte forma: $\{m_{GDR}, m_{mov}, b\}$, sendo m_{GDR} o coeficiente que multiplica o vetor GDR, m_{mov} o coeficiente que multiplica o vetor “movimentação de pallet” e b o consumo de energia mínimo necessário, ou, segundo outra nomenclatura, o consumo fixo da planta. A sintaxe da função PROJ.LIN necessita dos argumentos descritos na Tabela 3.

Tabela 3: Argumentos da função PROJ.LIN

Argumento	Descrição
val_conhecidos_y	Conjunto de valores y na relação $y = mx + b$.
val_conhecidos_x	Conjunto opcional de valores x que talvez seja conhecido na relação $y = mx + b$. Pode incluir um ou mais conjuntos de variáveis.
Constante	Valor lógico que especifica se a constante b será ou não forçada a se igualar a 0. Se constante for VERDADEIRO ou for omitido, b será calculado normalmente. Se constante for FALSO, b será definido como igual a 0 e os valores m serão ajustados para se adaptarem a $y = mx$.
Estatísticas	Valor lógico que especifica se estatísticas de regressão adicionais serão retornadas. Se estatísticas for VERDADEIRO, PROJ.LIN retornará as estatísticas de regressão adicionais. Se estatísticas for FALSO ou estiver omitido, PROJ.LIN retornará somente os coeficientes m e a constante b.

Fonte: Autoria própria.

A função PROJ.LIN também pode retornar diversas estatísticas de regressão adicionais, das quais as seguintes foram utilizadas para auxiliar a análise crítica dos modelos gerados:

- Os valores de erro padrão para os coeficientes m e para a constante b ;
- O coeficiente de determinação R^2 que compara os valores y estimados e reais. Se for 1, existe uma correlação perfeita no exemplo - não há diferença entre o valor y estimado e o valor y real. No outro extremo, se o coeficiente de determinação for 0, a equação de regressão não será útil na previsão de um valor y ;
- O valor de erro para a estimativa de y .

A precisão da linha calculada pela função PROJ.LIN depende do grau de dispersão dos dados. Quanto mais lineares forem os dados, mais preciso o modelo de PROJ.LIN.

3.8.Desenvolvimento do Modelo *Neuro Fuzzy*

As amostras de treinamento e teste devem ser diferentes e selecionadas aleatoriamente no conjunto de dados original. De acordo com Kayadelen et al. (2009), na maioria dos estudos anteriores, é comum o uso de porcentagens variando entre 15-25%, e muitos softwares de inteligência artificial, usam porcentagens semelhantes para o estágio de teste.

Segundo Tao et al. (2016), para garantir uma boa generalização do modelo *ANFIS* em relação a dados não vistos, o número de variáveis independentes precisa ser menor que o número de amostras de treinamento (RAHMAN et al., 2012). No entanto, nos casos de tamanho pequeno do conjunto de dados de treinamento, ainda pode ser aceitável se os desempenhos dos modelos *ANFIS* avaliados usando dados de treinamento e testes forem satisfatórios (AKBARPOUR et al., 2016; MOTAHARI-NEZHAD e MAZIDI, 2016).

A modelagem *ANFIS* foi realizada em MatlabR2015a (The MathWorks, Inc., MA, EUA) usando a *toolbox fuzzy*. Os argumentos necessários para construção dos modelos são apresentados na Tabela 4.

Dois tipos de métodos, *grid partition* e *sub. clustering*, podem ser utilizados para gerar as funções de pertinência para o desenvolvimento do modelo *ANFIS* (DUBOIS e PRADE, 1980; SHAHIN et al., 2003; ABDULSAMET et al., 2004; YILMAZ e MAHMUT, 2006; TOPÇU e SARIDEMIR, 2007). No método de *grid partition*, os números de regras difusas são gerados exponencialmente dependendo do número de entradas e do número de funções de pertinência. Isso é marcado como o recurso inconveniente e resulta em uma arquitetura *ANFIS* com estrutura mais complexa. Não é preferível principalmente se o número de parâmetros de

entrada for maior que seis (6) (NAYAK et al., 2004; PADMINI et al., 2008). Por outro lado, no particionamento de dispersão, resultados satisfatórios podem não ser obtidos quando nenhum dado pertencer ao cluster difuso e estiver longe do centro do cluster. Esse problema não está em questão para os métodos de *grid partition*, pois avalia toda a gama de dados na determinação da estrutura *ANFIS* (PADMINI et al., 2008).

Tabela 4: Argumentos *ANFIS*

Argumentos	Descrição
Saída	Conjunto de valores de saída conhecidos.
Variáveis independentes	Conjunto de valores conhecidos das variáveis independentes. Pode incluir um ou mais conjuntos de variáveis.
Método de geração da estrutura <i>Neuro Fuzzy</i>	<i>Grid Partition</i> ou <i>Sub. Clustering</i>
Número de funções de pertinência das variáveis de entrada	Estabelece a quantidade de funções de pertinência de cada variável de entrada.
Tipo de função de pertinência das entradas	Estabelece o tipo de função de pertinência das variáveis de entrada. Todas as variáveis terão o mesmo tipo de função de pertinência.
Tipo de função de pertinência da saída	Estabelece o tipo de função de pertinência da variável de saída.
Método de otimização	<i>Backpropagation</i> (método básico de aprendizado, pode ser lento e ficar preso no mínimo local) ou <i>Hybrid</i> (combina o estimador de mínimos quadrados e o <i>backpropagation</i>).
Tolerância	Limite de aceitação para o erro.
Épocas	Estabelece o número de iterações que serão executadas antes de finalizar o treinamento.

Fonte: Autoria própria.

O desempenho dos modelos *ANFIS* é fortemente dependente do número e tipo de funções de pertinência, bem como do número de épocas de treinamento (TAO et al., 2016). Portanto, a escolha dos argumentos necessários para a construção do modelo deve ser realizada com atenção.

3.9. Análise Comparativa dos Modelos

Com o intuito de analisar a melhoria alcançada ao utilizar modelos *ANFIS* desenvolvidos, os resultados estatísticos foram comparados, a saber, R^2 , conforme Equação 4.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_{i,sim} - y_{i,real})^2}{\sum_{i=1}^n (y_{i,real} - \bar{y}_{i,real})^2} \quad (4)$$

A confiabilidade do modelo *ANFIS* também foi avaliada pelo valor do EP (Equação 5), que é um critério estatístico que mostra uma medida de desvio em torno da linha de regressão. Isso é importante para as estatísticas, assim como para o valor R^2 , porque, às vezes, um modelo com o valor R^2 alto pode exibir um valor alto de EP. É desejável que um modelo forneça um valor R^2 alto e um valor baixo de EP.

$$EP = \sqrt{\frac{\sum_{i=1}^n (y_{i,sim} - y_{i,real})^2}{n - p - 1}} \quad (5)$$

O PIMVP (EVO, 2012) recomenda comparar o EP com a economia estimada, pois caso a economia seja pequena pode ser confundida com o EP do modelo. Portanto, o EP foi comparado a economia estimada, resultando no EPR, conforme Equação 6:

$$EPR = \frac{EP}{economia\ estimada} \quad (6)$$

A melhoria de cada modelo foi estabelecida em termos percentuais de R^2 em relação ao modelo similar desenvolvido com regressão linear, conforme Equação 7:

$$Melhoria_{modelo} = \frac{R^2_{modelo} - R^2_{RL}}{R^2_{RL}} \times 100 \quad (7)$$

4. RESULTADOS E DISCUSSÕES

4.1. Definição da Fronteira e Opção de Medição

A estratégia de M&V adotada foi a Opção C de acordo com o PIMVP (EVO, 2012). Esta opção de medição foi escolhida porque foram realizadas ações de eficiência energética (AEEs) em diversas áreas do Centro de Distribuição, e essa opção determina a economia total para todas as AEEs. Esta escolha é compatível com a recomendação do PIMVP (EVO, 2012), pois a economia esperada é maior do que 10% do consumo da planta. Na Figura 6 é mostrado o processo de escolha da “Opção C”, utilizando a lógica sugerida pelo PIMVP (EVO, 2012).

Outro fato que viabilizou a utilização da opção C foi a disponibilidade do histórico de medições de consumo para um período maior do que um ano (período da linha de base), com uma frequência de coleta a cada 15 minutos. Tendo sido adotada a opção C, a fronteira de medição ficou sendo toda a instalação.




Figura 6: Processo de escolha da “Opção C”, utilizando a lógica sugerida pelo PIMVP (EVO, 2012).
Fonte: Autoria própria.

4.2. Definição do Período da Linha de Base

A execução das AEEs no Centro de Distribuição teve início em junho de 2017, portanto para coincidir com o período imediatamente anterior, foi determinado o fim do período da linha de base em 31 de maio de 2017.

Para definir o início do período foi necessário definir a extensão do mesmo e, portanto, considerar os modos de funcionamento da instalação. Neste contexto, foi definido o período de um ano, pois o clima tem grande influência no consumo de energia do Centro de Distribuição Refrigerado, devido aos sistemas de refrigeração, ventilação e ar condicionado serem responsáveis por 79% do consumo de energia da instalação. Esta influência é explicada tanto pelo efeito da variação da carga térmica, quanto pela alteração na pressão de condensação.

A operação sazonal, além de ser dependente do clima, sofre influência de datas festivas que ocorrem ao longo do ano, como nos meses que antecedem o Natal, quando aumenta a demanda por aves congeladas e nos meses que antecedem a Páscoa, quando aumenta a demanda por peixes e chocolate.

Portanto, o período da linha de base foi determinado como iniciando em 1 de junho de 2016, completando a extensão de um ano para a linha de base, período necessário para análise de um ciclo completo das estações climáticas e da operação sazonal da instalação.

Além disso, a escala de tempo diária foi determinada para facilitar o acompanhamento de desvios no consumo de energia após a execução das AEEs e permitir tomada de ação imediata para evitar desperdícios. Os dados de energia e das variáveis independentes estudadas estão disponíveis para o período e escala de tempo selecionados. Todos os fatores relativos à instalação que regem a energia puderam ser estudados neste período.

4.3. Coleta dos dados de consumo de energia

Após selecionada a “Opção C” do PIMVP (EVO, 2012), foi determinado a utilização dos dados de energia do medidor da concessionária de energia elétrica, uma vez que é a única fonte de energia da instalação e o foco do projeto de eficiência energética estar concentrado neste tipo de energia.

Os dados do medidor da concessionária são armazenados e geridos pela empresa de gestão de energia, *FollowEnergy*. Este medidor está em conformidade com requisitos do PIMVP (EVO, 2012), que sugere que a seleção da “Opção C” implica a utilização de medidores da concessionária, medidores de toda a instalação ou submedidores.

O medidor selecionado determinou a economia coletiva de todas as AEEs executadas na instalação. Além de ter incluído os efeitos positivos ou negativos de todas as alterações feitas na instalação, mesmo as não relacionadas com as AEEs. Portanto, a economia deve ser grande o suficiente quando comparada com as variações não explicadas no modelo da linha de base, sendo fácil identificar a economia. Como regra geral, o PIMVP (EVO, 2012) sugere que a economia deve ultrapassar 10% do consumo da linha de base. Neste sentido, o estudo de caso deste trabalho permitiu a utilização deste tipo de estratégia pois obteve a previsão de economia de 19,8% do consumo da linha de base.

O Desvio Padrão dos dados de consumo foi de 19,01, o que representou 24% da média do consumo diário, sendo maior do que 10% significando que existem fatores externos que influenciaram o consumo de energia e devem ser estudados para que no período pós-AEEs estes fatores não comprometam o cálculo da economia. O PIMVP (EVO, 2012) sugere que sendo o desvio padrão menor do que 10% da média do consumo diário, o modelo pode se resumir a um valor fixo constante, o que não foi o caso para esta instalação.

Os dados de consumo de energia foram normalizados entre 0 e 100, sendo que zero representa ausência de consumo e cem (100) representa o consumo máximo apresentado pela instalação no período. Na Figura 7 é mostrada a distribuição do consumo de energia do centro de distribuição refrigerado, pode-se ver no histograma que existem dois picos, o que ocorre devido a diferença de operação entre os diferentes tipos de dias da semana.

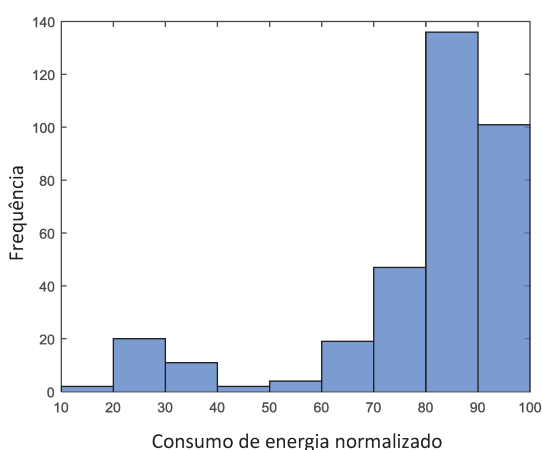


Figura 7: Distribuição do consumo de energia normalizado do Centro de Distribuição Refrigerado.
Fonte: Autoria própria.

4.4. Definição de Variáveis Independentes

Para criar os modelos do consumo de energia, as variáveis independentes obedeceram a dois critérios: relevância e disponibilidade de dados. Uma variável relevante é aquela que tem influência no consumo de energia. Para o estudo proposto, o GDR foi

claramente relevante, pois representou três comportamentos que influenciam o consumo de energia elétrica em Centros de Distribuição Refrigerados:

- Carga térmica;
- Pressão de descarga do sistema de refrigeração;
- Número de horas de funcionamento do sistema de refrigeração.

O GDR estava disponível de maneira acessível e confiável, por isso foram utilizados os dados da estação meteorológica IBARUERI3, localizada a menos de 10 km de distância em linha reta do Centro de Distribuição, disponível no site do The Weather Channel (TWC, 2017).

Para calcular o GDR foi necessário estabelecer uma referência que representasse a temperatura acima da qual os equipamentos de refrigeração são ligados e, portanto, alteram o perfil de consumo de energia. Como o Centro de Distribuição possui dois grandes sistemas de refrigeração, cada um atendendo diferentes câmaras frias, foi necessário adotar um cálculo razoável para estabelecer a referência para o GDR. Para isso, foi estabelecido como referência a média ponderada do set point de temperatura das câmaras, ponderada pela área ocupada por cada uma delas, ficando então a referência estabelecida como 3,5°C, conforme mostra a Tabela 5.

Tabela 5: Área e set point de temperatura de cada câmara.

Câmara	Área (m²)	Temp. (°C)
1	1.365	0
2	2.240	0
3	1.100	0
4	100	0
8	1.679	0
9	505	12
11	622	0
Antecâmara 1	3.353	6
Antecâmara 2A	1.714	6
Antecâmara 2B	2.413	6
Antecâmara 2x	305	6
Antecâmara 4	370	6
Antecâmara 5	370	6
Média ponderada:		3,5

Fonte: Autoria própria.

Além da influência da temperatura externa, a carga térmica é influenciada por fatores como número de pessoas, atividade de empilhadeira e tempo de porta aberta. Estes fatores podem ser representados por qualquer variável relacionada com “volume de produção”.

Em entrevista com funcionários do Centro de Distribuição, foi identificado que a única variável deste tipo registrada em frequência diária é a “movimentação de pallets”.

O histórico de movimentação de pallets foi armazenado pois a cada alteração de posição de um pallet realizada por um colaborador, o mesmo registra esta operação com o propósito de manter a rastreabilidade dos produtos. Dentre as movimentações registradas podem existir tipos específicos que não influenciam a carga térmica, portanto, entrevistas com os colaboradores identificaram quais tipos utilizar para compor esta variável independente. Foram escolhidas somente tipos de movimentações que pudessem influenciar a carga térmica. Na Tabela 6 estão apresentados de forma resumida os tipos de movimentações de pallet que foram selecionadas (foi mantida a nomenclatura das movimentações utilizada pelo software gerenciador da operação do centro de distribuição).

Tabela 6: Definição das movimentações de pallet que influenciam a carga térmica.

Descrição da movimentação de pallet no sistema de coleta de dados	Influencia a carga térmica?
Geração do pallet	NÃO
Conferência do pallet na recepção da mercadoria	NÃO
Movimentação para a rua de armazenagem (chão)	SIM
Armazenagem do pallet na posição de <i>picking</i>	SIM
Armazenagem do pallet na posição de reserva	SIM
Baixa da reserva para o <i>picking</i>	SIM
Rebast. - prx. Pallet selec. (pallet desprezado)	NÃO
Rebast. - prx. Pallet selec. (pallet substituto)	NÃO
Liberação de posição vazia no inventário	NÃO
Troca fabric./produto dos pallets (sit. anterior)	NÃO
Liberação de reserva por pallet	NÃO
Remanejamento de pallet	SIM
Geração manual do pallet	NÃO
Desbloqueio de pallet (gq)	NÃO
Bloqueio de pallet (adm)	NÃO
Desbloqueio de pallet (adm)	NÃO
Movimentação de plt fechado (expedição)	SIM
Atualização da quantidade da posição no inventário	NÃO
Alteração da posição do pallet	SIM
Solicitação de abastecimento do <i>picking</i>	NÃO
Movimentação da rua 90 para rua de reserva	SIM
Bloqueio automático fefo	NÃO
Desbloqueio de pallet no inventário	NÃO
Ajuste manual de qtde caixas no pallet	NÃO
Cancelamento movimentação	NÃO
Bloqueio por pulo	NÃO
Reserva p/ separação plt fechado	NÃO
Desbloqueio "pulo"	NÃO

Fonte: Autoria própria.

Neste contexto, para criação dos modelos, foram avaliadas como variáveis independentes o GDR e a quantidade de movimentação de pallets, em conjunto e individualmente. Os dados de GDR e de movimentação de pallets foram normalizados entre 0 e 100, sendo que zero representa valores iguais a zero e 100 representa o valor máximo de cada variável registrado no período.

Nas Figuras 8 e 9 são mostradas a distribuição dos valores de GDR e de movimentação de pallets, respectivamente. Pode-se observar nestas figuras a dispersão dos valores destas variáveis, o que também pode ser comprovado pela análise do desvio padrão, sendo 23% para os dados de GDR e 44% para os dados de movimentação.

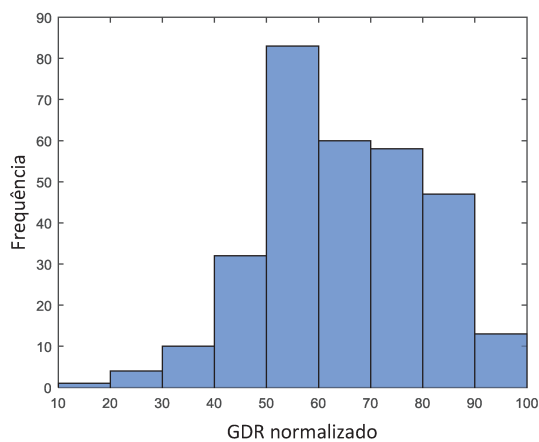


Figura 8: Distribuição do valor de GDR.
Fonte: Autoria própria.

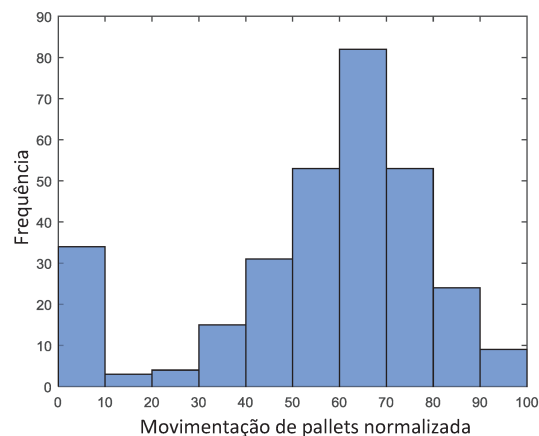


Figura 9: Distribuição do valor de movimentação de pallets.
Fonte: Autoria própria.

4.5. Desenvolvimento do Modelo com Regressão Linear Múltipla

Equações lineares simples e de múltiplas variáveis foram desenvolvidas utilizando a função PROJ.LIN do Excel e utilizaram os argumentos conforme descrito na Tabela 7.

Tabela 7: Argumentos da função PROJ.LIN

Argumento	Dados neste contexto
val_conhecidos_y	Consumo de energia diário
val_conhecidos_x	GDR e Movimentação de Pallet
Constante	VERDADEIRO
Estatísticas	VERDADEIRO

Fonte: Autoria própria.

Com base na experiência e conhecimento prévios sobre o comportamento energético de instalações similares, sabe-se que existe um consumo fixo base que é independente do clima e da operação do Centro de Distribuição. Assim, para que o modelo fosse capaz de identificar este consumo fixo base, o valor lógico, que especifica se a constante b será ou não forçada a se igualar a 0, foi determinado como VERDADEIRO.

Por sua vez, o valor lógico que especifica se estatísticas de regressão adicionais serão retornadas foi especificado como VERDADEIRO, para que a função PROJ.LIN retornasse as estatísticas de regressão adicionais e permitisse a análise dos modelos gerados.

A função PROJ.LIN poderia ser combinada com outras funções para calcular as estatísticas de outros tipos de modelos, incluindo séries polinomiais, logarítmicas, exponenciais e de potência, o que não foi utilizado no contexto desta dissertação, uma vez que estas combinações não são normalmente utilizadas e não é objetivo da mesma estudar com profundidade os métodos de modelagem por regressão linear, e sim, comparar os resultados da modelagem *Neuro Fuzzy* com o método correntemente utilizado.

A Tabela 8 apresenta os resultados estatísticos dos modelos gerados. Os três modelos gerados utilizando regressão linear apresentaram resultados estatísticos incompatíveis com as recomendações do PIMVP (EVO, 2012). Sendo que o modelo que apresentou o melhor R^2 (0,708) foi o modelo que utilizou as duas variáveis independentes (GDR e movimentação de pallets). A tabela apresenta também os coeficientes b , m_{GDR} e m_{mov} , para cada modelo.

Tabela 8: Resultados estatísticos dos modelos desenvolvidos utilizando regressão linear simples e com múltiplas variáveis.

Variáveis independentes	R^2	EP	EPR	b	m_{GDR}	m_{mov}
Recomendação PIMVP	>0,75	-	<0,50	-	-	-
GDR	0,029	18,84	1,20	65	0,21	-
Movimentação de pallets	0,71	10,34	0,66	43	-	0,66
GDR e Mov. de pallets	0,72	10,19	0,65	35	0,12	0,65

Fonte: Autoria própria.

Os modelos de regressão linear foram utilizados para uma análise qualitativa, com o objetivo de entender melhor o comportamento a ser modelado e obter informações relevantes para subsidiar a elaboração dos modelos *Neuro Fuzzy*.

O modelo linear, tendo como única variável independente o GDR, é apresentado na Figura 10 em comparação com os dados reais. Verifica-se que a relação se aproxima de uma relação linear para diversos pontos acima de 70, mas abaixo deste valor existe certa dispersão dos valores de consumo, que aparenta não depender do GDR. Esta dispersão revela que o consumo de energia depende de outras variáveis além do GDR. O modelo por sua vez fica distorcido inclusive para os dados acima de 70, pois sofre influência dos demais dados. Esse comportamento é resumido pelo baixo valor de R^2 deste modelo (0,029)




Figura 10: Distribuição dos dados de consumo de energia em função de GDR em comparação com o modelo linear (dados normalizados).

Fonte: Autoria própria.

A análise visual do gráfico apresentado na Figura 11 também revela os dois efeitos, pois o modelo não foi capaz de simular baixos consumos e deslocou os altos consumos para pouco abaixo do valor real.




Figura 11: Valores de consumo de energia simulados com modelo de regressão linear em função de GDR comparados com os valores reais de consumo de energia.

Fonte: Autoria própria.

Por sua vez, o modelo linear, tendo como única variável independente a movimentação de pallets, é apresentado na Figura 12 em comparação com os dados reais. Verifica-se que a relação se aproxima de uma relação logarítmica, mas pode ser separada pelo menos em dois modelos lineares, com ponto de mudança próximo em movimentação de pallets igual a 30. Ainda assim, observa-se dispersão em torno do modelo linear, portanto o

comportamento do consumo de energia aparenta não depender somente da movimentação de pallets. O modelo linear fica distorcido devido ao consumo de base, próximo de 30, que existe independente da operação do Centro de distribuição. Devido a simplificação do modelo linear, o consumo de base é fixado em 43, acima da média dos valores reais e para dias com grande movimentação de pallets o consumo será superestimado.




Figura 12: Distribuição dos dados de consumo de energia em função de movimentação de pallets em comparação com o modelo linear.

Fonte: Autoria própria.

A análise visual do gráfico apresentado na Figura 13 também revela estes efeitos, pois o modelo calculou o consumo fixo em 43 para os dias sem operação no Centro de Distribuição e superestimou o consumo para dias com grande movimentação, amostras entre 150 e 200, que antecede o Natal e o Réveillon (dias com os menores consumos registrado no ano).




Figura 13: Valores de consumo de energia simulados com modelo de regressão linear em função de movimentação de pallets comparados com os valores reais de consumo de energia.

Fonte: Autoria própria.

4.6. Desenvolvimento do Modelo Neuro Fuzzy

O conjunto de dados disponíveis foi dividido em dois conjuntos: (i) 80% dos dados foram utilizados para treinamento do modelo; e (ii) 20% foram utilizados para testar o desempenho do mesmo. Neste trabalho, estavam disponíveis 308 dias com dados confiáveis de clima e operação. Portanto, 246 dias foram usados para treinamento e 62 dias foram usados para teste do modelo *ANFIS* obtido.

A modelagem *ANFIS* foi realizada em MatlabR2015a (The MathWorks, Inc., MA, EUA) usando a *toolbox fuzzy*. Os argumentos utilizados para construção dos modelos são apresentados na Tabela 9.

Tabela 9: Argumentos utilizados para construção dos modelos *ANFIS*.

Argumento	Dados neste contexto		
	Modelo 1	Modelo 2	Modelo 3
Saída	Consumo de Energia	Consumo de Energia	Consumo de Energia
Variáveis independentes	GDR	Movimentação de pallets	GDR e Movimentação de pallets
Método de geração da estrutura <i>Neuro Fuzzy</i>	<i>Grid Partition</i>	<i>Grid Partition</i>	<i>Grid Partition</i>
Número de funções de pertinência GDR	3	-	3
Núm de funções de pertinência Movimentação de pallets	-	3	3
Tipo de função de pertinência das entradas	trimf	Trimf	trimf
Tipo de função de pertinência da saída	linear	Linear	linear
Método de otimização	<i>Hybrid</i>	<i>Hybrid</i>	<i>Hybrid</i>
Tolerância	0	0	0
Épocas	100	100	100

Fonte: Autoria própria.

O método *grid partition* foi usado como método de geração da estrutura *Neuro Fuzzy*, uma vez que este é um método adequado para classificar os dados quando poucas variáveis de entrada são consideradas. Determinou-se que uma quantidade ímpar de funções de pertinências seriam utilizadas para que os valores médios do espectro da variável pudessem ser consideradas em uma delas, portanto o número de funções de pertinência das variáveis independentes foi estabelecido como sendo o menor valor ímpar adequado, ou seja, 3. A função de pertinência triangular (trimf) foi utilizada para todas as variáveis independentes devido a simplicidade e facilidade de interpretação. Por sua vez, a função de pertinência da saída usada

foi uma função linear devido a simplicidade e facilidade de interpretação. Além disso, o algoritmo de aprendizado híbrido (estimador de mínimos quadrados combinado com método *backpropagation*) foi utilizado para determinar os parâmetros do sistema de inferência Takagi-Sugeno, pois o método *backpropagation* sozinho poderia ficar preso no mínimo local. Além disso, todos os modelos foram treinados para até 100 épocas, de forma a minimizar a medida de erro. Estes parâmetros foram determinados conforme sugestões de TAO et al. (2016).

Após o treinamento, o *ANFIS* gerou 3 modelos, ou seja, determinou as funções de pertinência, as regras e as funções de saída para cada conjunto de argumentos.

Valores de consumo de energia simulados com modelo *Neuro Fuzzy* em função de GDR comparados com os valores reais de consumo de energia são apresentados na Figura 14, separados em dados de treinamento e teste. Observa-se que o modelo *Neuro Fuzzy* não foi capaz de simular baixos consumos de energia e não teve bom ajuste dos valores de consumo, mesmo para valores de consumo acima de 70.




Figura 14: Valores de consumo de energia simulados com modelo *Neuro Fuzzy* em função de GDR comparados com os valores reais de consumo de energia (dados de treinamento e teste).

Fonte: Autoria Própria.

Por sua vez, na Figura 15 são apresentados valores de consumo de energia simulados com modelo *Neuro Fuzzy* em função de movimentação de pallets comparados com os valores reais de consumo de energia, separados em dados de treinamento e teste.




Figura 15: Valores de consumo de energia simulados com modelo *Neuro Fuzzy* em função de movimentação de pallets comparados com os valores reais de consumo de energia (dados de treinamento e teste).

Fonte: Autoria Própria.

Observa-se que o modelo representa melhor os consumos de energia em dias sem operação, tanto com os dados de treinamento, quanto para o conjunto de dados de teste, o que era desejado.

Os resultados estatísticos são apresentados na Tabela 10. Dentre os três modelos gerados utilizando *Neuro Fuzzy*, apenas o modelo que utilizou ambas variáveis independentes (GDR e movimentação de pallets) apresentou resultado estatístico compatível com as recomendações do PIMVP (EVO, 2012), a saber R^2 de 0,85 e EPR de 0,45 (considerando todas as amostras). O modelo utilizando somente GDR como variável independente continua com resultado baixo de R^2 (0,05), portanto não se pode considerar o resultado como sendo um modelo.

Tabela 10: Resultados estatísticos dos modelos desenvolvidos utilizando *Neuro Fuzzy*.

Variáveis independentes	R^2	EP	EPR
Recomendação PIMVP	> 0,75	-	<0,50
GDR - treinamento	0,06	17,67	1,13
GDR - teste	0,05	23,02	1,47
GDR	0,05	18,79	1,20
Movimentação de pallets - treinamento	0,78	8,47	0,54
Movimentação de pallets - teste	0,90	6,67	0,43
Movimentação de pallets	0,81	8,12	0,52
Ambas - treinamento	0,84	7,22	0,46
Ambas - teste	0,88	6,89	0,44
Ambas	0,85	7,12	0,45

Fonte: Autoria própria.

Uma vez obtido o modelo *ANFIS* com capacidade preditiva satisfatória, foi possível gerar um gráfico de superfície onde é possível analisar o efeito do GDR e da movimentação de pallets no consumo de energia elétrica do Centro de Distribuição. O gráfico de superfície em questão é apresentado na Figura 12, observa-se que a movimentação de pallets tem maior influência sobre o consumo de energia, o que era esperado, pois em dias sem operação no Centro de Distribuição o consumo é aproximadamente um terço do consumo apresentado em dias de operação normal. O modelo *Neuro Fuzzy* corrige as distorções presentes nos modelos lineares pois apresenta cálculos específicos para cada região dos dados e apresenta comportamento mais próximo do logarítmico em função da movimentação de pallets, o que reduz a tendência de superestimar o consumo para dias com operação acima do normal.

Observa-se também, no gráfico de superfície apresentado na Figura 16, que o comportamento do consumo de energia em função do GDR é aproximadamente constante quando a movimentação de pallets é baixa e também quando GDR é alto, mas tem grande influência quando a movimentação de pallets é média e alta.




Figura 16: Gráfico de superfície do modelo *Neuro Fuzzy*.
Fonte: Autoria própria.

4.7. Análise comparativa dos Modelos obtidos

Durante o processo de desenvolvimento dos modelos avaliou-se a relevância matemática de cada uma das variáveis independentes e definiu-se que ambas fossem utilizadas. A melhoria de cada modelo foi estabelecida em termos percentuais de R^2 em relação ao modelo desenvolvido com regressão linear correspondente, conforme Equação 8.

$$Melhoria = \frac{R_{Neuro\ Fuzzy}^2 - R_{RL}^2}{R_{RL}^2} \quad (8)$$

Na Tabela 11 são apresentados os resultados obtidos para os modelos criados. O modelo com ambas as variáveis (GDR e movimentação de pallets) apresentou melhoria de 23%,

além de ter sido alcançado os parâmetros recomendados pelo PIMVP (EVO, 2012), R^2 de 0,88 maior do que 0,75 e EPR de 0,44 menor do que 0,5.

Tabela 11: Melhoria dos modelos *Neuro Fuzzy* em comparação com os modelos com regressão linear.

Variáveis independentes	R^2	EP	EPR	Melhoria
Modelos Regressão linear - Referência				
Movimentação de pallets	0,71	10,34	0,66	-
GDR e Movimentação de pallets	0,72	10,19	0,65	-
Modelos <i>Neuro Fuzzy</i>				
Movimentação de pallets – dados de teste	0,9	6,67	0,43	27%
Ambas – dados de teste	0,88	6,89	0,44	23%

Fonte: Autoria própria.

A regressão linear múltipla gerou o modelo descrito na Tabela 7, e a Figura 16 mostra o gráfico de superfície do modelo *Neuro Fuzzy* gerado pela ferramenta *ANFIS*. A curva do modelo *Neuro Fuzzy* mostra que a variação do consumo tem maior dependência com a variação da movimentação de pallets do que com a variação climática (GDR), o que também pode ser observado no modelo linear. Este efeito está coerente com o esperado do comportamento do consumo de energia, pois o consumo de energia sofre mais influência da quantidade de compressores que necessitam ficar ligados devido a carga térmica, em comparação com a influência da temperatura externa na pressão de descarga e na carga térmica por condução de calor pelas paredes.

Além da condução de calor pelas paredes, a carga térmica é influenciada também pelo carregamento de produtos com temperatura acima da temperatura da câmara, pela respiração e transpiração das pessoas, pela infiltração de ar ambiente quando as portas são abertas e pela emissão de calor das empilhadeiras. Uma vez que estes fatores são nulos nos dias de baixa ou nenhuma produção (representada neste modelo pela movimentação de pallets), se explica o comportamento do consumo de energia ser fortemente dependente da movimentação de pallets.

Em uma análise qualitativa, foram comparadas as Figuras 17 e 18, nas quais são apresentados os valores de consumo de energia reais comparados com os valores simulados tanto com o modelo de regressão linear (Figura 17), quanto com o modelo *Neuro Fuzzy* (Figura 18), ambos em função de movimentação de pallets e GDR.

Ao comparar as figuras, pode-se verificar que, ainda que o consumo de base no modelo de regressão linear múltipla seja 35, ou seja, mais próximo do valor de consumo de base real, o modelo *fuzzy* representou melhor o consumo de energia nos dias com baixo consumo de energia (destaque com linha tracejada), como era desejado. Este comportamento

se explica, pois, o modelo considera o comportamento não linear do consumo de energia, quando separa os dados em três grupos.

Na Figura 17 está destacada em linha contínua pontos onde o modelo de regressão linear calculou valores de consumo de energia superestimados. Os dias que apresentam este comportamento são dias com grande movimentação, período entre os dias 150 e 200, que antecede o Natal e o Réveillon (dias com os menores consumos registrado no ano). Este efeito também foi observado no modelo de regressão linear com apenas movimentação de pallets como variável independente (Figura 12).




Figura 17: Valores de consumo de energia simulados com modelo de regressão linear em função de movimentação de pallets e GDR comparados com os valores reais de consumo de energia.

Fonte: Autoria própria.

Por sua vez, na Figura 18, onde é apresentada a mesma comparação, agora para o modelo *Neuro Fuzzy*, não se observa valores superestimados de consumo de energia nem para o conjunto de dados de treinamento, nem para o conjunto de dados de teste. Esta melhoria é alcançada devido ao comportamento aproximadamente logarítmico apresentado na curva de superfície da Figura 16.




Figura 18: Valores de consumo de energia simulados com modelo *Neuro Fuzzy* em função de movimentação de pallets e GDR comparados com os valores reais de consumo de energia (dados de treinamento e teste).

Fonte: Autoria Própria.

5. CONCLUSÕES

Para verificar a hipótese de que, para a modelagem do consumo de energia de um centro de distribuição refrigerado, um modelo *Neuro Fuzzy* apresentaria maior representatividade do que o método convencional, três modelos de regressão linear e três modelos *Neuro Fuzzy* foram desenvolvidos e comparados entre si utilizando os critérios estabelecidos pelo PIMVP (EVO, 2012), sendo a análise do coeficiente de determinação (R^2) e comparação do erro padrão relativo (EPR) da estimativa.

O modelo *Neuro Fuzzy* também corrige as distorções presentes nos modelos lineares pois apresenta cálculos específicos para cada região dos dados e apresenta comportamento mais próximo do logarítmico em função da movimentação de pallets, o que reduz a tendência de superestimar o consumo para dias com operação acima do normal.

O modelo mostra também que o comportamento do consumo de energia em função do GDR é aproximadamente constante quando a movimentação de pallets é baixa e também quando GDR é alto, mas tem grande influência quando a movimentação de pallets é média e alta.

O modelo *fuzzy* representou melhor o consumo de energia nos dias com baixo consumo de energia, como era desejado. Este comportamento se explica, pois, o modelo considera o comportamento não linear do consumo de energia, quando separa os dados em três grupos.

O modelo de regressão linear com movimentação de pallets como variável independente calculou valores de consumo de energia superestimados em dias que apresentam operação acima do normal, período que antecede o Natal e o Réveillon. Por sua vez, o modelo *Neuro Fuzzy* corrigiu tal comportamento e não se observa valores superestimados de consumo de energia nem para o conjunto de dados de treinamento, nem para o conjunto de dados de teste.

Com a implementação da metodologia *Fuzzy* foi possível desenvolver um modelo do comportamento do consumo de energia elétrica do centro de distribuição refrigerado, com maior representatividade do que o modelo linear clássico.

Assim, concluímos que o modelo *fuzzy* pode ser aplicado para desenvolvimento de modelo para ajuste da linha de base do consumo de energia em instalações com características energéticas não lineares. O que pode beneficiar o mercado de eficiência energética, especificamente para modelar o consumo de energia no período de linha de base quando se utiliza a opção C do PIMVP (EVO, 2012).

6. TRABALHOS FUTUROS

Para continuidade do estudo objeto desta dissertação, sugerimos a aplicação da modelagem *Neuro Fuzzy* em outros estabelecimentos. Recomendamos ainda, a comparação do modelo desenvolvido com outros modelos, incluindo outras variáveis independentes, como por exemplo levar em consideração a influência dos feriados ou da temperatura dos produtos ao serem entregues no centro de distribuição. Outros métodos de modelagem não linear também podem ser analisados.

7. REFERÊNCIAS BIBLIOGRÁFICAS

- ABDULSAMET, H; MEHMET, Y; OMER, C; ISMAIL, E. *Adaptive neuro-fuzzy modeling of transient heat transfer in circular duct air flow*. International Journal of Thermal Sciences 431075–1090, 2004.
- ABNT. *Gestão e Segurança de Alimentos – Produtos ABNT Editora*, 2014. Disponível em <<http://www.abnt.org.br/noticias/6060-alimentos>>. Acessado em 03 de agosto de 2018.
- AKBARPOUR, H; MOHAJERI, M; AKBARPOUR, M. *Pore diameter of nanoporous anodic alumina experimental study and application of ANFIS and MLR*. Chemometr Intel Lab 15382–91, 2016.
- ASHRAE. *ASHRAE Guideline 14. Measurement of Energy and Demand Savings*. Atlanta s.n, 2002.
- BUNSE, K., VODICKA, M., SCHÖNSLEBEN, P., BRÜLHART, M., ERNST, F. O., *Integrating energy efficiency performance in production management – gap analysis between industrial needs and scientific literature*, Journal of Cleaner Production, v.19, p.667-679, 2010.
- CARPENTER, K., SERYAK, J., KISSOCK, K.; MORAY, S., *Profiling and Forecasting Daily Energy Use with Monthly Utility-Data Regression Models*, ASHRAE Transactions, Volume 116, 2010.
- DUBOIS, PRADE, *Fuzzy sets and systems*. Academic Press, New York, 1980.
- EFFICIENCY VALUATION ORGANIZATION, *Protocolo Internacional de Medição e Verificação de Performance*. s.l.s.n, 2012.
- FRANCONI, E. & JUMP, D. *Leveraging Smart Meter Data & Expanding Services*. ASHRAE Journal, Setembro, pp. 18-26, 2017.
- GHAEDI, M., GHAEDI, A.M., ABDI, F., ROOSTA, M., VAFAEI, A., ASGHARI, A. *Principal component analysis-adaptive neuro-fuzzy inference system modeling and genetic algorithm optimization of adsorption of methylene blue by activated carbon derived from Pistacia khinjuk*. Ecotoxic. Environ. Safety 96, 110–117, 2013.
- GHAEDI, M., HOSAININIA, R., GHAEDI, A.M., VAFAEI, A., TAGHIZADEH, F. *Adaptive neuro-fuzzy inference system model for adsorption of 1,3,4-thiadiazole-2,5-dithiol onto gold nanoparticles-activated carbon*. Spectrochim. Acta Part A 131, 606–614, 2014.
- HEO, Y. et al. *Cost-effective Measurement and Verification Method for Determining Energy Savings under Uncertainty*. ASHRAE Annual Conference, 2013.
- ISERMANN, R., *Fault-Diagnosis Systems An Introduction from Fault Detection to Fault Tolerance*, Verlag Berlin Heidelberg Springer, 2006.
- KAYADELEN, C., TASKIRAN, T., GÜNAYDIN, O. & FENER, M. *Adaptive neuro-fuzzy modeling for the swelling potential of compacted soils*. Environ Earth Sci, pp. 109-115, 2009.
- KIM, H. & HABERL, J. *Improving Monthly Weather-Normalized Energy Use Model Building Energy Use Classification Based on Occupancy*. s.l., s.n, 2015.
- KREIDER, J., AND HABERL, J. *The great energy predictor shoot-out II measuring retrofit savings, overview and discussion of results*. ASHRAE Transaction, 96419-435, 1994.

LEITE, F.C. *Modelamento da eficiência energética para o gerenciamento sustentável no setor industrial pela medição e verificação*. Tese de Doutorado. Universidade de São Paulo, 2010.

LERKKASEMSAN, N. *Predicting Conversion from Pyrolysis of Pongmia*. Energy Procedia, pp. 192-195, 2015.

LI, Z., *Fuzzy Chaotic Systems Modeling, Control and Applications*, Verlag Berlin Heidelberg Springer, 2006.

LILLY MERCY, J. & PRAKASH, S. *Experimental Investigation and Neuro Fuzzy Modeling of Inplane Shear Strength for Self Healing GFRP*. The Indian Institute of Metals, 11 January, pp. 1483-1491, 2016.

MANDAL, S., MAHAPATRA, S.S., PATEL, R.K. *Neuro fuzzy approach for arsenic (III) and chromium (VI) removal from water*. J. Water Proc. Eng. 5, 58–75, 2015.

MATHWORKS, <https://www.mathworks.com/products/fuzzy-logic/features.html#working-with-the-fuzzy-logic-toolbox>, acessado em 16/07/2017.

MORALES, C. M. *Existing-Building Energy Modeling*. HPAC Engineering, pp. 26-29, 2012.

MOTAHARI-NEZHAD, M., MAZIDI, M.S. *An Adaptive Neuro-Fuzzy Inference System (ANFIS) model for prediction of thermal contact conductance between exhaust valve and its seat*. Appl Therm Eng 105613–621, 2016.

NAYAK, P. C., SUDHEER, K. P., RANGAN, D. M., RAMASASTRI, K. S. *A neurofuzzy computing technique for modeling hydrological time series*. J Hydrol 291(1–2)52–66, 2004.

OSÉS, N., LEGARRETAETXE BARRIA, A., QUARTULLI, M., GARCÍA, I., SERRANO, M. *Uncertainty reduction in measuring and verification of energy savings by statistical learning in manufacturing environments*, Int J Interact Des Manuf, v. 10, pp. 291-299, 2016.

PADMINI, D., ILAMPARUTHI, K., SUDHEER, K. P. *Ultimate bearing capacity rediction of shallow foundations on cohesionless soils using neurofuzzy models*. Computers and Geotechnics 3533–46, 2008.

QASAIMÉH, A., ABDALLAH, M., HANI, F.B. *Adaptive neuro-fuzzy logic system for heavy metal sorption in aquatic environments*. J. Water. Resour. Protect. 4, 277–284, 2012.

RAHMAN, M. S., RASHID, M. M., HUSSAIN, M. A. *Thermal conductivity prediction of foods by Neural Network and Fuzzy (ANFIS) modeling techniques*. Food Bioprod Process 90333–340, 2012.

REBOUH, S., BOUHEDDA, M., HANINI, S. *Neuro-fuzzy modeling of Cu (II) and Cr (VI) adsorption from aqueous solution by wheat straw*. Desalin. Water Treat. 57, 6515–6530, 2016.

SHAHIN, M. A., MAIER, H. R., JAKSA, M. B. *Settlement prediction of shallow foundations on granular soils using B-spline neurofuzzy models*. Computers and Geotechnics 30637–647, 2003.

SHONDER, J. A. & HUGHES, P. J. *Estimating Energy, Demand, and Cost Savings from a Geothermal Heat Pump ESPC Project Through Utility Bill Analysis*. ASHRAE Transactions, Volume 112, 2006.

SILVA, R. P. B. D. *Análise do uso da energia elétrica em instalações industriais do segmento de Alimentos e Bebidas*. Campinas Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas, 2011.

SUBBARAO, K., LEI, Y., REDDY, T. A. *The Nearest Neighborhood Method to Improve Uncertainty Estimates in Statistical Building Energy Models*. ASHRAE Transactions, pp. 459-471, 2011.

TAKAGI, T.; SUGENO, M. *Fuzzy identification of systems and its applications to modeling and control*. IEEE Transactions on Systems, Man, and Cybernetics. SMC-15(1)116-132, 1985.

TANHAEI, B., ESFANDYARI, M., AYATI, A. & SILLANPÄÄ, M.. *Neuro-fuzzy modeling to adsorptive performance of magnetic chitosan nanocomposite*. J Nanostruct Chem, pp. 29-36, 2017.

TAO, Y. et al. *Neuro-fuzzy modeling to predict physicochemical and microbiological parameters of partially dried cherry tomato during storage effects on water activity, temperature and storage time*. Association of Food Scientists & Technologists, pp. 3686-3694, 2016.

THE WEATHER COMPANY. Weather Underground. Disponível em <https://www.wunderground.com/>. Acessado em 07 de junho de 2017.

TOPÇU, I. B., SARDEMIR, M. *Prediction of rubberized concrete properties using artificial neural network and fuzzy logic*. Construction and Building Materials, Elsevier (in press), 2007.

XIA, X., ZHANG, J., *Mathematical description for the measurement and verification of energy efficiency improvement*, Applied Energy, v.111, p.247-256, 2013.

YILMAZ, Y., MAHMUT, B. *Adaptive neuro-fuzzy based modelling for prediction of air pollution daily levels in city of Zonguldak*. Chemosphere 631575–1582, 2006.

ZAJAC, P., *The Energy Consumption in Refrigerated Warehouses*, Paulina Glowinski, Poznan, Poland Springer, 2016.

8. ANEXOS



TERMO DE AUTORIZAÇÃO E COMPROMISSO PARA USO DE INFORMAÇÕES

Declaramos para os devidos fins, que cederemos à pesquisadora, Renata de Cassia Ferreira Silva, o acesso aos dados de movimentação de pallets contidos no sistema Emulador Mainframe, na opção DP05/08/38/0903/(20) Produtividade Funcionarios(HWW) e aos dados de consumo de energia elétrica contidos no sistema FollowEnergy, sob código 0903, para serem utilizados na pesquisa intitulada "Modelo Matemático Fuzzy do Consumo de Energia Elétrica da Linha de Base de um Centro de Distribuição Refrigerado", que está sob a orientação do Prof. Dr. Flávio Vasconcelos da Silva.

Esta autorização está sendo concedida desde que as seguintes premissas sejam respeitadas: as informações serão utilizadas única e exclusivamente para a execução do presente projeto; a pesquisadora se compromete a preservar a integridade das informações e não repassar os dados em sua íntegra, ou parte dele, à pessoas não envolvidas com esta pesquisa.

Atenciosamente,

Pierre-Yves Mourgue
Diretor-Presidente
GreenYellow do Brasil Energia e Serviços

Claudio Vicente Barbosa
Gerente de Contas Públicas e Planejamento
CIA Brasileira de Distribuição – GPA



TERMO DE COMPROMISSO DE UTILIZAÇÃO DE DADOS (TCUD)

Eu, Renata de Cassia Ferreira Silva, discente de mestrado do Departamento de Engenharia de Sistemas Químicos, da Faculdade de Engenharia Química, da Universidade Estadual de Campinas, no âmbito da dissertação intitulada "Modelo Matemático Fuzzy do Consumo de Energia Elétrica da Linha de Base de um Centro de Distribuição Refrigerado", comprometo-me com a utilização dos dados de movimentação de pallets contidos no sistema Emulador Mainframe, na opção DP05/08/38/0903/(20) Produtividade Funcionarios(HWW) e os dados de consumo de energia elétrica contidos no sistema FollowEnergy, sob código 0903, a fim de obtenção dos objetivos previstos.

Declaro entender que é minha a responsabilidade de cuidar da integridade das informações e de não repassar os dados em sua íntegra, ou parte dele, à pessoas não envolvidas com esta pesquisa.

Por fim, comprometo-me com a guarda, cuidado e utilização das informações apenas para cumprimento dos objetivos previstos nesta pesquisa aqui referida. Qualquer outra pesquisa em que eu precise dos mesmos dados será submetida a novo termo de compromisso e nova autorização.

São Paulo, 24 de Abril de 2017.

Renata de Cassia Ferreira Silva

CPF: 310.983.548-77

RG: 33.735.595-2

RA: 159199