



Pós-Graduação em Ciência da Computação

JOÃO FERREIRA DA SILVA JÚNIOR

**Estratégias para Analisar e Estimar a Eficiência do Consumo de Energia em
Centros de Dados**



Universidade Federal de Pernambuco
posgraduacao@cin.ufpe.br
<http://cin.ufpe.br/~posgraduacao>

Recife
2019

JOÃO FERREIRA DA SILVA JÚNIOR

Estratégias para Analisar e Estimar a Eficiência do Consumo de Energia em Centros de Dados

Tese apresentada ao Programa de Pós-Graduação em Ciências da Computação da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do título de Doutor em Ciências da Computação.

Área de Concentração: Redes de Computadores e Sistemas Distribuídos.

Orientador: Prof. Dr. Paulo Romero Martins Maciel

Recife
2019

Catálogo na fonte
Bibliotecária Monick Raquel Silvestre da S. Portes, CRB4-1217

S586e Silva Júnior, João Ferreira da
Estratégias para analisar e estimar a eficiência do consumo de energia em
centros de dados / João Ferreira da Silva Júnior. – 2019.
108 f.: il., fig., tab.

Orientador: Paulo Romero Martins Maciel.
Tese (Doutorado) – Universidade Federal de Pernambuco. CIn, Ciência da
Computação, Recife, 2019.
Inclui referências e apêndice.

1. Redes de computadores. 2. Sistemas distribuídos. 3. Consumo de
energia. I. Maciel, Paulo Romero Martins (orientador). II. Título.

004.6 CDD (23. ed.) UFPE- MEI 2019-112

JOÃO FERREIRA DA SILVA JÚNIOR

**Estratégias para Analisar e Estimar a Eficiência do Consumo
de Energia em Centros de Dados**

Tese de Doutorado apresentada ao
Programa de Pós-Graduação em
Ciência da Computação da Universidade
Federal de Pernambuco, como requisito
parcial para a obtenção do título de
Doutor em Ciência da Computação.

Aprovado em: 15/03/2019.

Orientador: Prof. Dr. Paulo Romero Martins Maciel

BANCA EXAMINADORA

Prof. Dr. Nelson Souto Rosa (Examinador Interno)
Centro de Informática /UFPE

Prof. Dr. Eduardo Antônio Guimarães Tavares (Examinador Interno)
Centro de Informática /UFPE

Prof. Dr. Ermeson Carneiro de Andrade (Examinador Externo)
Departamento de Estatística e Informática/ UFRPE

Prof. Dr. Luiz Affonso H. Guedes de Oliveira (Examinador Externo)
Departamento de Engenharia de Computação e Automação/ UFRN

Prof. Dr. Henrique Pacca Loureiro Luna (Examinador Externo)
Instituto de Computação/IFAL

Dedico essa tese a minha família, base de meu crescimento profissional, em especial:
filho, esposa e mãe.

AGRADECIMENTOS

Agradeço a Deus e aos espíritos de luz por permitirem e favorecerem, de todas as formas (materiais e espirituais), a realização e conclusão deste trabalho. Por me iluminarem, guiarem e tornarem claras as decisões que tomei nesse período.

Ao meu orientador, Paulo Romero Martins Maciel, que confiou em minha capacidade, me incentivou e me acolheu, fazendo com que me tornasse um integrante do grupo de pesquisa MoDCS (Modeling of Distributed and Concurrent Systems), agradeço-lhe pela oportunidade de crescimento profissional e intelectual. Tenho certeza que levarei um pouco de seu estilo de trabalho por toda a vida.

Ao amigo e parceiro desde o primeiro período da graduação, Gustavo Callou, por seu incentivo, compartilhamento de conhecimento e pelo trabalho desenvolvido em conjunto do mestrado ao doutorado. Agradeço pela ajuda nas atividades acadêmicas e pela parceria nos poucos momentos de lazer que tivemos nesses últimos anos.

Ao amigo Jamilson Dantas, pelas horas compartilhadas em laboratórios, salas de aula, e lazer, desde o mestrado. Aos colegas Juarez Gomes e Michel Saturnino, sou-lhes grato pelo apoio necessário a continuação e conclusão do curso.

Agradeço a Creusa Diniz, minha mãe, por seu apoio, orgulho e exemplos de moral e ética durante toda a vida. Agradeço a Simone Diniz, minha esposa e companheira de todas as horas, pelo incentivo, força, apoio, auxílio e por entender minhas infinitas horas ausentes de sua vida, ao longo dessa jornada. Agradeço também ao meu filho Kevin Diniz, por sua compreensão (mesmo que relutante por vezes) pelas várias horas dedicadas a este trabalho e ausência em seus alegres e contagiantes momentos de diversão.

Aos amigos que conquistei no grupo de pesquisa MoDCS. Em especial a Jean, Rubens, Julian, Renata, Carlos Melo, Ronierison, Danilo, Érico, Júlio, Breno, Paulo Roberto, Airton, Aline, Iuri, Maria Clara, Kadna, Jair, Vandi, Bruno Silva, Bruno Nogueira, Ermeson, Débora e tantos outros, agradeço pelas palavras de incentivo quando foi preciso, pelos momentos de dificuldades e ao mesmo tempo de descontração em meio a tanto trabalho e estudo, pelo auxílio quando precisei e, claro, pela amizade, que espero não acabar com o fim do curso de doutorado.

Agradeço a todos aqueles, que de forma direta ou indireta contribuíram para a realização deste trabalho, que me incentivaram e apoiaram nesse período tão importante para a minha formação acadêmica.

A todos, meu sincero agradecimento.

RESUMO

Os avanços tecnológicos acontecem por intermédio de pesquisas e estudos, podem inclusive ocorrer através da criação de novos paradigmas, como a computação em nuvem. Em alguns casos, grandes centros de dados são utilizados para suportar esses paradigmas. Dessa forma, estes grandes centros de dados tornaram-se elementos críticos no desenvolvimento de tarefas diárias, o que sugere que, a cada dia, utilizamos mais seus recursos, aumentando a demanda e, conseqüentemente, o consumo elétrico. Atualmente, o consumo de energia é uma questão de interesse comum. Pesquisas demonstram que, como consequência da constante evolução e expansão da tecnologia da informação, os centros de dados são grandes consumidores de energia elétrica. Com esse alto consumo, destacam-se as questões de sustentabilidade, custo e preocupações para o futuro. Neste contexto, a presente tese propõe estratégias para melhorar a eficiência e estimar o consumo energético de centros de dados. Um algoritmo de distribuição de corrente elétrica em profundidade (PLDA-D) é proposto para otimizar a distribuição de energia nas infraestruturas elétricas. O PLDA-D é suportado pelo ambiente denominado Mercury, que é capaz de realizar uma avaliação integrada das métricas de disponibilidade, custo e sustentabilidade. O PLDA-D otimiza, mais especificamente, a distribuição da corrente na infraestrutura elétrica dos centros de dados. A modelagem de fluxo elétrico (EFM) permite estimar métricas de sustentabilidade e custo das infraestruturas elétricas de centros de dados, respeitando as restrições de capacidade de energia que cada dispositivo é capaz de fornecer (considerando o sistema elétrico) ou extrair (considerando o sistema de refrigeração). Além disso, usamos uma rede neural artificial multicamada (com o perceptron), que é capaz de prever o consumo de energia do centro de dados, com base no histórico. Para demonstrar a aplicabilidade das estratégias propostas, dois estudos de caso são apresentados. O primeiro estudo analisa quatro infraestruturas de energia. Os resultados obtidos mostram uma redução de cerca de 3,8% no impacto de sustentabilidade e nos custos operacionais. O segundo estudo calcula as emissões de CO₂ e os custos operacionais de um centro de dados usando o mix de energia adotado no Brasil, na China, na Alemanha e nos EUA.

Palavras-chaves: Heurística. Disponibilidade. Consumo de energia. Centro de dados. Redes Neurais Artificiais. Perceptron.

ABSTRACT

Technological advances happen through research and studies, including the creation of new paradigms such as cloud computing. In some cases, large data centers are used to support these paradigms. Thus, these data centers have become critical elements in the development of daily tasks, which suggests that, every day, we use more resources, increasing demand and hence the power consumption. Nowadays, energy consumption is an issue of common interest. Research demonstrates that as a consequence of the constantly evolving and expanding field of information technology, data centers are now major consumers of electrical energy. Such high electrical energy consumption emphasizes the issues of sustainability, cost and concerns for the future. Against this background, the present thesis proposes strategies to improve and estimate the efficiency of the energy consumption of a data center. A Power Load Distribution Algorithm in Depth search (PLDA-D) is proposed to optimize the distribution of energy in data center electrical infrastructures. The PLDA is supported by an environment called Mercury, capable of performing the integrated evaluation of dependability, cost and sustainability. PLDA-D optimizes, more specifically, the electrical distribution in the electrical infrastructure of data centers. The energy flow models are responsible for estimating sustainability and cost issues of data centers infrastructures without crossing the restrictions of the power capacity that each device can provide (power system) or extract (cooling system). In addition, we use a multilayer artificial neural network (with the perceptron), which is able to forecast the power consumption of the data center, based on history. To demonstrate the applicability of the proposed strategy, two case studies are presented. The first analyzes four energy infrastructures. The results obtained show a reduction in sustainability impact and operating costs of around 3.8%. The second computes the CO_2 emissions and operating costs of a data center using the energy mix adopted in Brazil, China, Germany and the USA.

Keywords: Heuristic. Availability. Power consumption. Data center. Artificial Neural Networks. Perceptron.

LISTA DE FIGURAS

Figura 1 – Subsistemas de centro de dados	30
Figura 2 – Árvore de Dependabilidade Adaptada de Avizienis (AVIZIENIS et al., 2004)	33
Figura 3 – Exemplo de RBD	35
Figura 4 – CTMC Simples	37
Figura 5 – Matriz Q	38
Figura 6 – Exemplo de SPN	39
Figura 7 – Metodologia - Visão geral	47
Figura 8 – Exemplo simples de um modelo EFM	53
Figura 9 – Principal fonte de energia dos países (ABESCO, 2018)	54
Figura 10 – Exemplo de utilização do Mix Energético	56
Figura 11 – Parâmetros do modelo EFM	58
Figura 12 – Exemplo EFM - Caminho Válido	59
Figura 13 – Melhor rota em profundidade - 1ª Iteração	59
Figura 14 – Melhor caminho em profundidade - 2ª Iteração	60
Figura 15 – Melhor caminho em profundidade - Estado final	60
Figura 16 – Exemplo de execução de PLDA-D, os retângulos azuis destacam os nós em análise	65
Figura 17 – Modelo não linear de um neurônio k. Adaptado de (HAYKIN et al., 2009)	67
Figura 18 – Função sigmóide para parâmetro de inclinação α variável (HAYKIN et al., 2009)	69
Figura 19 – Exemplo do subsistema elétrico do centro de dados classificado como Tier I	72
Figura 20 – Modelo RBD de infraestrutura de energia do Tier Nível I	72
Figura 21 – Modelo EFM do Tier I	72
Figura 22 – Modelo SPN para energia elétrica e sistema de gerador (UP + GS)	74
Figura 23 – Modelo em CTMC do sistema de UPS em cold standby (UPS System)	75
Figura 24 – Exemplo do subsistema elétrico do centro de dados classificado como Tier II	76
Figura 25 – Modelo RBD da infraestrutura elétrica do Tier II	76
Figura 26 – Modelo EFM do Tier II.	77
Figura 27 – Exemplo do subsistema elétrico do centro de dados classificado como Tier III	78
Figura 28 – Modelagem RBD dos Subsistemas X, Y e P, referente ao Tier III	78
Figura 29 – Modelo RBD Completo do Tier III	79
Figura 30 – Modelo EFM do Tier III.	80

Figura 31 – Exemplo do subsistema elétrico do centro de dados classificado como Tier IV	81
Figura 32 – Modelagem RBD dos Subsistemas Z/Z2 e PS, referente ao Tier IV . . .	81
Figura 33 – Modelo RBD Completo do Tier IV	82
Figura 34 – Modelo EFM do Tier IV	82
Figura 35 – Comparação antes e após execução do PLDA-D.	87
Figura 36 – Variação energética do Brasil, Alemanha, China e USA	89
Figura 37 – Emissões de CO ₂ por ano em toneladas	90
Figura 38 – Custo operacional anual em USD: EUA, Brasil, Alemanha e China . . .	90
Figura 39 – Previsões do ARIMA(3,2,2)	91
Figura 40 – Consumo Real x Consumo Previsto	92
Figura 41 – Previsões para 12 meses usando o MLP	92
Figura 42 – Visualização das opções da RNA no Mercury	105
Figura 43 – Criação da RNA no Mercury	106
Figura 44 – Treinamento da RNA no Mercury	107
Figura 45 – Predições da RNA no Mercury	107
Figura 46 – Gráfico da RNA no Mercury	108

LISTA DE TABELAS

Tabela 2 – Comparação de heurísticas relacionadas ao consumo de energia dos centros de dados	23
Tabela 3 – Comparação de RNAs e ARMA relacionadas ao consumo de energia dos centros de dados	26
Tabela 4 – Comparação com linhas de pesquisa semelhantes	28
Tabela 5 – Valores de energia e exergia para diferentes modalidades energéticas . .	42
Tabela 6 – Material usado na geração de energia x emissões de CO_2	55
Tabela 7 – Valores de MTTF e MTTR em horas.	85
Tabela 8 – Capacidade e Eficiência	85
Tabela 9 – Resultados da execução do PLDA-D com melhoria em %.	86
Tabela 10 – Relação entre Custo/Kw antes/após PLDA e PLDA-D.	87
Tabela 11 – Mix energético, custo elétrico e emissões de CO_2	89
Tabela 12 – Previsões ARIMA e MLP para os próximos 12 meses (2015)	93

LISTA DE ABREVIATURAS E SIGLAS

ARIMA	<i>Autoregressive integrated moving average</i>
ARMA	<i>Autoregressive Moving Average Model</i>
CRAC	<i>Computer Room Air Conditioner units</i>
CTMC	<i>Continuous Time Markov Chain</i>
DCiE	<i>Data Center Efficiency</i>
DSPN	<i>Deterministic and Stochastic Petri Nets</i>
DTMC	<i>Discrete Time Markov Chain</i>
EFM	<i>Energy Flow Model</i>
GSPN	<i>Generalized stochastic Petri nets</i>
LSTM	<i>Long Short-Term Memory</i>
MLP	<i>Multilayer perceptron</i>
MOPS	<i>Multi-Objective Power-and-SLA</i>
MTTF	<i>Mean Time to Fail</i>
MTTR	<i>Mean Time to Repair</i>
PDU	<i>Power Distribution Unit</i>
PLDA-D	<i>Power Load Distributed Algorithm in Depth Search - PLDA-D</i>
PUE	<i>Power Usage Effectiveness</i>
QoS	<i>Quality of service</i>
RBD	<i>Reliability Block Diagram</i>
RNA	<i>Artificial Neural Network</i>
SLA	<i>Service Level Agreement</i>
SPN	<i>Stochastic Petri Net</i>
STS	<i>Static Transfer Switch</i>
UPS	<i>Uninterruptible Power Supply</i>
VMs	<i>Virtual Machines</i>

LISTA DE SÍMBOLOS

γ	Letra grega Gama
$\in$	Pertence
δ	Delta
θ	Teta
σ	Sigma
μ	Mi

SUMÁRIO

1	INTRODUÇÃO	16
1.1	CONTEXTO	16
1.2	MOTIVAÇÃO E JUSTIFICATIVA	18
1.3	OBJETIVOS	18
1.4	CONTRIBUIÇÕES	19
1.5	ORGANIZAÇÃO DO TRABALHO	20
2	TRABALHOS RELACIONADOS	21
2.1	HEURÍSTICAS PARA REDUÇÃO DO CONSUMO DE ENERGIA	21
2.2	RNA E CONSUMO DE ENERGIA EM CENTROS DE DADOS	23
2.3	CONSUMO DE ENERGIA EM INFRAESTRUTURAS ELÉTRICAS	26
2.4	CONSIDERAÇÕES FINAIS	28
3	REFERENCIAL TEÓRICO	29
3.1	INFRAESTRUTURA DE CENTRO DE DADOS	29
3.2	DEPENDABILIDADE	31
3.2.1	Diagrama de Blocos de Confiabilidade	35
3.2.2	Cadeias de Markov	36
3.2.3	Redes de Petri Estocásticas	38
3.3	SUSTENTABILIDADE	40
3.4	MODELAGEM DE FLUXO ELÉTRICO	42
3.5	REDE NEURAL ARTIFICIAL	43
3.5.1	Perceptron	44
3.6	ARIMA	44
3.7	CONSIDERAÇÕES FINAIS	45
4	METODOLOGIA	46
4.1	ENTENDER O SISTEMA	46
4.2	CRIAR MODELOS DE DISPONIBILIDADE E FLUXO ELÉTRICO	48
4.3	ESCOLHER ESTRATÉGIA	49
4.4	CONSIDERAR MIX ENERGÉTICO	49
4.5	OTIMIZAR A DISTRIBUIÇÃO DO FLUXO COM O PLDA-D	50
4.6	PREVER CUSTOS E IMPACTO AMBIENTAL COM RNA	50
4.7	ANALISAR OS RESULTADOS	51
4.8	APLICAR OUTRA ESTRATÉGIA?	52

4.9	CONSIDERAÇÕES SOBRE A METODOLOGIA	52
5	ANÁLISE DO CONSUMO ENERGÉTICO E MELHORIA DA EFICIÊNCIA DA INFRAESTRUTURA ELÉTRICA	53
5.1	CONTEXTUALIZAÇÃO	53
5.2	ANÁLISE DO CONSUMO, CONSIDERANDO MÚLTIPLAS FONTES ENERGÉTICAS	54
5.2.1	Exemplo de uso	56
5.3	PLDA-D - ALGORITMO DE DISTRIBUIÇÃO DE CARGA ELÉTRICA EM PROFUNDIDADE	57
5.3.1	Caminho Válido	58
5.3.2	Fase I - Inicialização do PLDA-D	61
5.3.3	Fase II - Cálculos de Kernel	62
5.3.4	Fase III - Busca em Profundidade	63
5.3.5	Execução do PLDA-D	65
5.4	APLICANDO REDES NEURAS ARTIFICIAIS PARA PREVISÃO DE CONSUMO DE ENERGIA	67
5.5	CONSIDERAÇÕES FINAIS	70
6	MODELOS	71
6.1	MODELAGEM DO TIER I	71
6.2	REDUNDÂNCIA	73
6.3	MODELAGEM DO TIER II	75
6.4	MODELAGEM DO TIER III	77
6.5	MODELAGEM DO TIER IV	80
6.6	CONSIDERAÇÕES SOBRE OS MODELOS	83
7	ESTUDOS DE CASO	84
7.1	ESTUDO DE CASO I	84
7.2	ESTUDO DE CASO II	88
7.2.1	Variação de fontes energéticas, emissões de CO2 e custos	88
7.2.2	Previsões da Rede Neural Artificial	91
7.3	CONSIDERAÇÕES	93
8	CONCLUSÃO	95
8.1	CONTRIBUIÇÕES	97
8.2	TRABALHOS FUTUROS	97
8.3	CONSIDERAÇÕES FINAIS	98
	REFERÊNCIAS	99

APÊNDICE A – APRESENTAÇÃO DA RNA IMPLEMENTADA	
NO MERCURY	105

1 INTRODUÇÃO

Este capítulo apresenta uma breve introdução sobre o consumo de energia dos centros de dados, destacando aspectos de sustentabilidade, disponibilidade e custo a serem apresentados no decorrer do trabalho. Em seguida, são apresentados os objetivos e as motivações desta tese e por fim, tem-se a estrutura geral.

1.1 CONTEXTO

O acesso à Internet amplamente disponível, o crescente mercado de dispositivos móveis e os avanços na tecnologia da computação em nuvem estão gerando uma enorme quantidade de dados. O universo digital é grande, contendo quase tantos bits digitais quanto estrelas no universo e, além disso, está em expansão para incluir não apenas o crescente número de pessoas e empresas que fazem tudo on-line, mas também todos os dispositivos inteligentes conectados à Internet.

O tamanho do universo digital dobra a cada dois anos e, até 2020, estima-se que chegue a 44 zettabytes ou 44 trilhões de gigabytes (TURNER, 2014), apesar de apenas 53% da população mundial possuir acesso à internet em 2018 (KEMP, 2018), exigindo, portanto, demandas sem precedentes no consumo de energia para os próximos anos.

Os centros de dados são a espinha dorsal da economia moderna, com salas de servidores que oferecem elementos críticos ao desempenho de tarefas diárias, como computação em nuvem, acesso a redes sociais, comércio eletrônico e armazenamento de informações, contribuindo para o aumento do consumo de energia. Essa grande quantidade de conteúdo digital acaba por tornar estes centros em consumidores de eletricidade que mais crescem no mundo e um dos principais impulsionadores na construção de novas usinas de energia, utilizando as mais variadas matérias-primas.

O consumo energético nestes centros aumentou significativamente nos últimos anos, influenciado pela crescente demanda por capacidade de armazenamento e processamento de dados (AGENCY, 2007; ABBASI; VARSAMOPOULOS; GUPTA, 2010; AL-QAWASMEH, 2012). Em 2013, os centros de dados nos Estados Unidos consumiram cerca de 91 bilhões de quilowatts-hora de eletricidade (DELFORGE'S PIERRE, 2014) e espera-se que esse consumo continue a crescer nos próximos anos. Para a Europa Ocidental, há uma estimativa do aumento na demanda energética de 56 TWh, aferido em 2007, para 104 TWh, a ser alcançada em 2020 (ELLIS DANIEL PERRE; HOXTELL, 2009). A demanda por energia dos centros de informações é uma das responsáveis por parte significativa desse contínuo aumento energético.

Os centros de dados se subdividem em três áreas: infraestrutura tecnológica, infraestrutura elétrica e infraestrutura de refrigeração. O escopo desse trabalho está na in-

fraestrutura elétrica e seus componentes, muitos dos quais podem afetar diretamente a disponibilidade do sistema. Mecanismos tolerantes a falhas, tais quais a replicação de dispositivos, são técnicas fundamentais para o manuseio de equipamentos com disponibilidade limitada. O instituto Uptime (TIME, 2015) classifica a infraestrutura do centro de dados com base em arquiteturas e características de redundância e tolerância a falhas, subdividindo-a em quatro níveis (Tier I, Tier II, Tier III e Tier IV). Neste trabalho, todos os níveis foram analisados, considerando diferentes arquiteturas de camadas para o subsistema de energia.

Paralelamente, existe a preocupação com o aumento do impacto ambiental que tem assumido grande importância por parte da indústria, bem como da comunidade científica, preocupação esta motivada pelo aumento do consumo elétrico e por diversas inquietações da sociedade, tais como mudanças climáticas, poluição e degradação ambiental. As emissões de dióxido de carbono (CO_2), por exemplo, podem aumentar e atingir valores entre 9% e 27% em 2030 (EIA, 2011). É importante lembrar que o dióxido de carbono produzido varia de acordo com a matéria-prima utilizada na geração da energia, como carvão, petróleo, gás natural e outros. No Brasil, 70% a 93% da energia elétrica é proveniente de centrais hidrelétricas; uma forma bastante “limpa” e menos agressiva ao meio ambiente na geração de energia elétrica (MARIN, 2011).

Nos Estados Unidos, a queima de carvão gera quase metade da eletricidade consumida, entretanto emite 78% de todo o CO_2 produzido a partir de usinas de energia. Muitos países têm exigido a substituição de fontes energéticas poluentes pelas não poluentes, tais como a energia solar, eólica, hidrelétrica, etc. Com uma preocupação financeira e sustentável por parte das empresas e visando auxiliar na tomada de decisão, é fundamental dispor de meios de avaliação dessas grandes estruturas em fase de projeto.

Algumas métricas importantes para avaliação de um centro de dados são utilizadas no presente trabalho, tais como a disponibilidade, o custo e a sustentabilidade. Para computar essas métricas foram empregados os modelos: Diagramas de Blocos de Confiabilidade (*Reliability Block Diagram* (RBD)) (KUO; ZUO, 2003b) (MACIEL et al., 2011a), Modelo de Fluxo Elétrico (*Energy Flow Model* (EFM)) (CALLOU et al., 2013a), Redes de Petri Estocásticas (SPN) (MOLLOY, 1982a) e Cadeias de Markov (*Continuous Time Markov Chain* (CTMC)) (KLEINROCK, 1975), suportados pelo ambiente Mercury (SILVA et al., 2015). Os modelos CTMC, RBD e de redes de Petri Estocásticas (*Stochastic Petri Net* (SPN)) foram usados para se extrair as métricas de dependabilidade dos sistemas avaliados, a fim de se obter subsídios para avaliação do modelo EFM, que propõe uma nova maneira para se calcular de forma integrada a sustentabilidade, a disponibilidade e os custos de um centro de dados (CALLOU et al., 2011; CALLOU et al., 2013a). O ambiente Mercury (MERCURY..., 2015) adota uma abordagem integrada para questões de sustentabilidade, disponibilidade e custos (FERREIRA; CALLOU; MACIEL, 2013; FERREIRA et al., 2013). A distribuição do fluxo elétrico é moldado através do modelo de fluxo de energia (EFM).

1.2 MOTIVAÇÃO E JUSTIFICATIVA

Observa-se ao longo dos últimos anos um crescimento considerável no consumo de energia em todo o planeta. Os centros de dados, compostos por equipamentos de TI, de infraestrutura elétrica e de refrigeração, são apontados como um dos responsáveis por grande parte desse consumo (MARIN, 2011). A gestão de energia e os impactos ambientais causados por estes centros tornaram-se questões cada vez mais apreciadas pelas empresas, considerando o aumento dos custos de energia e a atenção global voltada para a sustentabilidade. Nos Estados Unidos, onde há muitos centros de dados, existe uma contribuição significativa para as emissões globais de carbono, uma vez que a matéria-prima mais utilizada na geração da energia elétrica é o carvão mineral.

Outrossim, as estimativas de consumo de energia dos centros de dados demonstram um aumento anual entre 4% e 8%. Como a tecnologia da informação, em todos os seus níveis, é responsável por uma fração considerável das emissões globais de carbono, uma pequena redução nos percentuais de consumo de energia dos centros de informações poderá acarretar significativo impacto econômico e ambiental.

Destaca-se, em trabalhos anteriores (SILVA et al., 2015) (CALLOU et al., 2013a), o desenvolvimento da ferramenta Mercury e de uma proposta de avaliação dos centros de dados, que tratam de forma integrada os conceitos de custo, disponibilidade e sustentabilidade. Tal ferramenta suporta modelos formais para avaliações de dependabilidade (RBD, SPN e MC), além de possuir uma visão capaz de permitir a modelagem da infraestrutura elétrica (EFM) de um centro de dados. Entretanto, a elaboração do fluxo da rede elétrica permanece sob a responsabilidade do projetista e, conseqüentemente, sujeito a erros humanos ou sob a responsabilidade da distribuição padrão do Mercury, onde o fluxo é dividido igualmente entre os vértices do modelo. Dessa maneira, sem a precisão matemática necessária para assegurar uma boa resposta na modelagem elétrica dos centros de informações. Além do mais, não há como considerar uma variação de fontes energéticas nos modelos, impossibilitando, assim, uma análise mais precisa sobre as emissões de gases poluentes na atmosfera, decorrentes da infraestrutura elétrica do centro de dados, tampouco a predição para os próximos meses baseado no histórico do ambiente.

Por essa razão, essa tese visa preencher as lacunas existentes nesse método de avaliação (apresentadas na seção 5, fornecendo uma resposta eficaz para o consumo de energia de qualquer modelo de infraestrutura elétrica projetado na ferramenta Mercury, considerando o mix energético que é capaz de estimar o consumo para os próximos meses, por meio de uma rede neural, utilizando o modelo EFM.

1.3 OBJETIVOS

Neste contexto, este trabalho propõe estratégias para melhorar e analisar a eficiência do consumo de energia em centros de dados. A primeira estratégia consiste no Algoritmo

de Distribuição de Carga Elétrica em Profundidade (*Power Load Distributed Algorithm in Depth Search - PLDA-D* (PLDA-D)), que é proposto para otimizar o fluxo de energia entre os componentes elétricos representados pelo modelo EFM, considerando a eficiência elétrica dos dispositivos. De fato, o algoritmo sugerido visa melhorar a utilização de caminhos redundantes no modelo EFM, que possuem níveis diferenciados de eficiência. Com a otimização do fluxo elétrico, podemos reduzir o consumo de energia e o custo operacional, bem como melhorar a sustentabilidade do ambiente. A segunda estratégia consiste na integração de uma rede neural artificial (*Artificial Neural Network* (RNA)) ao EFM. Esta RNA avalia os custos operacionais e estima os impactos ambientais (emissões de CO₂) dos centros de dados. Ademais, é possível considerar representações com várias fontes energéticas, cada uma com diferentes impactos ambientais.

Essas estratégias (PLDA-D e RNA) são adotadas para análise e redução ou otimização do consumo de energia elétrica em centros de dados. Com essa redução há economia de recursos financeiros (limitados e preciosos em qualquer organização) e o mais importante; uma redução do impacto ambiental pelos centros de dados, considerando o mix energético para produção da energia.

Para validar as estratégias propostas, foram conduzidos dois estudos de caso: o primeiro compara duas soluções, uma na qual o fluxo elétrico é dividido igualmente pelos dispositivos que compõem a estrutura, com outra em que a divisão do fluxo é baseada nas eficiências de cada componente. Já o segundo estudo faz uso de uma rede neural artificial para estimar os custos e impactos ambientais pelos próximos 12 meses, baseados no histórico de consumo de 15 anos.

Os objetivos específicos são:

- Propor o PLDA-D para fornecer distribuição eficiente do fluxo energético na infraestrutura elétrica do centro de dados;
- Considerar diversas composições de fontes energéticas na modelagem de fluxo elétrico.
- Analisar o impacto ambiental, considerando a eficiência energética decorrente das diferentes fontes de energia adotadas nos centros de dados.
- Aplicar métodos de previsão (inteligência artificial) para estimar consumo de energia e impacto ambiental do centro de dados.

1.4 CONTRIBUIÇÕES

As principais contribuições desta tese são:

- Uma heurística (PLDA-D) para distribuição eficiente do fluxo elétrico para as infraestruturas elétricas de centros de dados;

- Modelos de disponibilidade para os quatro tipos de centros de dados conhecidos na literatura;
- Considerar o mix energético dos centros de dados para estimar a emissão de gás carbônico emitido na atmosfera pelo consumo de energia dos referidos centros;
- Avaliação de custo, disponibilidade e sustentabilidade para as infraestruturas elétricas dos centros de dados;
- Uso de uma rede neural artificial junto ao modelo de fluxo elétrico, para prever o consumo de energia dos próximos meses, baseado no histórico do ambiente.

1.5 ORGANIZAÇÃO DO TRABALHO

O Capítulo 2 apresenta os trabalhos relacionados encontrados no decorrer desta pesquisa. Já o Capítulo 3 apresenta os principais aspectos teóricos, base deste trabalho, em relação à infraestrutura de centro de dados, dependabilidade, diagrama de blocos de confiabilidade (RBD), redes de Petri estocásticas (SPN), cadeias de Markov (CTMC), sustentabilidade, modelagem de fluxo energético (EFM), Mercury, custos, redes neurais artificiais e ARIMA (*Autoregressive integrated moving average* (ARIMA)).

O capítulo 4 apresenta a metodologia proposta nesta tese, a estratégia geral utilizada na pesquisa. São apresentadas macro atividades que permitem ao leitor a reprodução do estudo em tela. O capítulo 5 apresenta as principais contribuições da presente tese, detalhando o algoritmo de distribuição de carga elétrica em profundidade (PLDA-D), o incremento do mix energético nos modelos EFM e a utilização de uma rede neural artificial (perceptron de múltiplas camadas) integrada ao EFM.

O capítulo 7 apresenta os modelos de disponibilidade e fluxo elétrico propostos nesta tese, para os quatro tipos de centros de dados avaliados, representando os níveis I, II, III e IV. Esses modelos foram utilizados como insumos aos estudos de caso. Nesse capítulo, são também apresentados dois estudos de caso, que representam arquiteturas elétricas de centros de dados, com o objetivo de validar o algoritmo proposto, ilustrando as possíveis melhorias e uma análise dos modelos de centros de dados com previsões. Por fim, o Capítulo 8 apresenta as considerações finais para este trabalho, apontando as contribuições alcançadas, bem como sugere alguns trabalhos futuros.

2 TRABALHOS RELACIONADOS

Nos últimos anos, algumas pesquisas foram desenvolvidas sobre a tentativa de redução do consumo de energia em centros de dados. Nesta tese, as linhas defendidas nessa pesquisa foram organizadas por semelhança em três grupos, para que fosse possível destacar as diferenças da nossa. O primeiro subconjunto considerou o impacto sobre heurísticas aplicadas em centros de dados, o segundo subconjunto apresenta as técnicas de redes neurais, por fim, o terceiro subconjunto exhibe pesquisas correlatas a esta que visam, de alguma forma, reduzir o consumo de energia nos ambientes.

2.1 HEURÍSTICAS PARA REDUÇÃO DO CONSUMO DE ENERGIA

Esta seção apresenta os trabalhos encontrados na literatura que propõem redução do consumo de energia em centros de dados via aplicação de heurísticas.

Marziyeh (BAYATI, 2016) apresentou um algoritmo estocástico de otimização para gerenciar o consumo energético e a qualidade do serviço em um centro de dados modelado por filas discretas de tempo. O algoritmo de otimização sugerido se adapta e dinamicamente ajusta o número de servidores operacionais de acordo com: a variação de tráfego, a carga de trabalho, o custo de manutenção de trabalho no buffer, o custo de perda de trabalho e o custo de energia para realizar uma tarefa.

Os testes foram conduzidos através de várias análises numéricas para vários tipos de entrada. Um exemplo seria a taxa constante, definida por distribuição discreta contínua, especificada por uma distribuição discreta variável ao longo do tempo e modelada por distribuição discreta obtida a partir de rastreamentos reais de tráfego do Google.

Em cada nó do modelo, o algoritmo minimiza uma função objetivo que combina o custo da energia e o custo da qualidade do serviço (*Quality of service* (QoS)), a fim de alterar o número de servidores operacionais de acordo com a variação do tráfego. A estratégia final é que o sistema inicializa os servidores progressivamente quando detecta uma alta taxa de chegada de requisições e desliga gradualmente os servidores quando essa mesma taxa se torna baixa.

Arianyan (ARIANYAN, 2016) abordou o problema da alocação de recursos de múltiplos critérios em centros de dados em nuvem, considerando objetivos importantes, incluindo consumo de energia, violação de acordo de nível de serviço (*Service Level Agreement* (SLA)) e o número de migrações de máquinas virtuais (*Virtual Machines* (VMs)). O autor propôs a política MOPS (*Multi-Objective Power-and-SLA* (MOPS)), baseada em um algoritmo AHP modificado como uma nova solução de alocação de recursos multicritério. O MOPS não apenas aborda a meta de consumo de energia e redução de violação de SLA, mas também tenta reduzir o número de migrações de VMs, uma vez que considera

simultaneamente cinco critérios, incluindo: (1) aumento de energia devido à alocação de uma VM migrando para uma máquina física, (2) capacidade disponível de uma máquina física, (3) número de VMs hospedado em uma máquina física, (4) correlação de recursos entre a VM migrando e as VMs hospedadas em uma máquina física e (5) atraso de migração para uma VM. Os resultados das simulações usando o Cloudsim demonstraram melhorias nos objetivos de saída, incluindo 34,2%, 98,58% e 71,29% de redução no consumo de energia, violação de SLA e número de migrações de VMs, respectivamente.

Dzmitry (KLIASOVICH; BOUVRY; KHAN, 2013) propõe uma metodologia, denominada DENS (acrônimo para programação com reconhecimento eficiente da energia do centro de dados), que combina agendamento eficiente de energia com o reconhecimento da rede. A metodologia DENS equilibra o consumo de energia de um centro de dados, o desempenho individual de uma tarefa e as demandas de tráfego. Essa estratégia é capaz de analisar dinamicamente o *feedback* da rede e tomar decisões para um melhor desempenho, considerando o consumo de energia e o tráfego.

Portanto, o objetivo desse trabalho é conduzir o equilíbrio entre essas métricas, bem como minimizar o número de servidores de computação necessários ao ambiente que fornece suporte aos serviços contratados. Os resultados da simulação obtidos para uma arquitetura de centro de dados de três camadas confirmam a qualidade do DENS e sua capacidade de manter o nível necessário de QoS para o usuário final, em detrimento de um pequeno aumento no consumo de energia.

Ricciardi (RICCIARDI et al., 2011), apresentou o EnergyFarm, um gerenciador de energia que pode ser usado nas infraestruturas de um centro de dados para economizar energia. Em um centro de dados, cada servidor tem uma capacidade de processamento, dependendo essencialmente do número de núcleos e/ou processadores. A carga de trabalho do ambiente é, portanto, representada pelas tarefas que precisam ser processadas em cada momento. Os centros de dados típicos são altamente capacitados para funcionar bem com altas cargas de trabalho. Contudo, os servidores ociosos normalmente são mantidos ativos mesmo se não houver trabalhos a serem processados. Isso representa claramente um desperdício na utilização de energia e um custo desnecessário.

Esse trabalho propõe reduzir o conjunto de servidores ativos para um subconjunto de servidores e desativar os inativos. Os resultados mostraram que uma eficiência na alocação de recursos pode ser alcançada (entre 20% e 68%), permitindo economias significativas de energia, custo e emissões.

Heller et. al. (HELLER et al., 2010) apresentou um mecanismo chamado ElasticTree, concebido como um gerenciador de energia em toda a rede, que ajusta dinamicamente o conjunto de elementos de rede, links e switches, para atender às mudanças nas cargas de tráfego do centro de dados. Nesse trabalho foi considerada a eficiência energética, desempenho e robustez, com traços reais de um site de comércio eletrônico em produção. Os resultados iniciais (abrangendo análise, simulação e protótipos de hardware) demonstram

as compensações entre desempenho, robustez e energia. O parâmetro de margem de segurança fornece aos administradores de rede o controle sobre essas compensações. Todavia, a capacidade do ElasticTree responder a aumentos repentinos no tráfego é atualmente limitada pelo atraso de inicialização do switch, embora os administradores afirmem que essa limitação pode ser abordada de forma relativamente simples, pela adição de um modo de suspensão aos switches.

Ao final, apresentam resultados que demonstram que, para as cargas de trabalho presentes no estudo do centro de dados, o ElasticTree pode economizar até 50% da energia dos ativos de rede, mantendo a capacidade de lidar com os picos de tráfego. A heurística proposta para subconjuntos de redes de computação deve permitir que o ElasticTree seja dimensionado para centros com milhares de nós.

Os trabalhos relacionados as heurísticas encontradas até o presente momento abordam, majoritariamente, sobre a alocação de ativos de rede e equipamentos da infraestrutura de TI dos centros de dados reduzindo, dessa forma, o consumo de energia do ambiente. Sendo assim, não há trabalho relacionado à implantação de heurística aplicada à infraestrutura elétrica de um centro de dados. A Tabela 2 apresenta um resumo da comparação entre esses trabalhos e a referida proposta.

Tabela 2 – Comparação de heurísticas relacionadas ao consumo de energia dos centros de dados

	Heurística	Infr. Elétrica	Infr. TI	Infr. Rede	Qos	SLA
Marziyeh	X		X		X	
Arianyan	X		X			X
Dzmitry	X			X		
Ricciardi	X		X			
Heller	X			X		
Proposta	X	X				

2.2 RNA E CONSUMO DE ENERGIA EM CENTROS DE DADOS

Esta seção apresenta os trabalhos que se relacionam a esta tese e que usaram técnicas similares, como redes neurais ou médias móveis auto regressivas.

Em Tumer (TÜMER; KOÇER; KOCA, 2016) uma rede neural perceptron multicamada é usada para estimar o consumo de energia elétrica da Turquia. Os dados de entrada considerados pelos autores foram: o número de habitantes, a capacidade instalada, o consumo líquido de eletricidade, o produto interno bruto, o índice de preços ao consumidor e o crescimento real do PIB. Esses dados foram obtidos no site do governo turco e foram relacionados aos anos entre 1970 e 2014.

Os autores treinaram uma RNA de 3 camadas e 1 neurônio e os resultados desse estudo mostraram que a alta correlação entre o consumo real e o previsto de eletricidade chega a 0,95. Assim, a RNA pode ser usada como uma ferramenta eficaz para desenvolver modelos com alta precisão e capacidade de generalização. Além disso, a RNA também pode ser usada como uma ferramenta de avaliação para os tomadores de decisão estimarem o consumo de energia elétrica, fornecendo uma análise eficaz. Nessa pesquisa, foi visto que as redes neurais artificiais são boas como uma ferramenta de previsão e podem produzir bons resultados.

Marwala (MARWALA; TWALA, 2014) usou um modelo de média móvel auto regressiva (*Autoregressive Moving Average Model* (ARMA)), redes neurais multicamadas e sistemas neuro-difusos para prever o consumo de eletricidade na África do Sul. Previsões de curto prazo são usadas para controle e programação do sistema de energia e também são empregadas como entradas para o estudo de fluxo de carga ou análise de contingência. Aplicando os valores mensais de janeiro de 1985 a dezembro de 2011, eles compararam o desempenho dos três sistemas acima mencionados.

A contribuição desse trabalho está na comparação do desempenho das ferramentas de modelagem e da aplicação destas no conjunto de dados específicos da África do Sul. O uso dos dados de demanda de eletricidade em um modelo uni variado se mostrou útil para prever a demanda futura de eletricidade. Os resultados mostraram que o neuro-fuzzy possui uma melhor capacidade de modelar o sistema do que o ARMA ou redes neurais e que as redes neurais, por sua vez, são melhores do que o ARMA.

Zhou (ZHOU et al., 2018) explorou o problema de como modelar com precisão o consumo de energia de um centro de dados em nuvem, propondo um modelo holístico de demanda por energia em um centro de dados em nuvem, baseado na análise dos principais componentes e por meio de métodos de regressão.

A abordagem proposta leva em conta o consumo de energia do processador, da memória, do disco rígido e do NIC (Network Interface Card), bem como as características da aplicação. Os resultados experimentais mostram que: (1) o processo de construção do modelo de consumo de energia, considerando todos os componentes relacionados ao consumo de energia, como CPU, memória, disco e NIC, é mais efetivo do que considerar apenas CPU e memória; (2) considerar características da tarefa, fornecendo um desempenho melhor do que apenas o foco nas tarefas da CPU durante a construção do modelo de potência. Além disso, o modelo de consumo de energia proposto neste trabalho pode ser estendido a outros servidores, a fim de orientar o algoritmo a economizar o consumo de energia.

Shoukourian (SHOUKOURIAN et al., 2017) apresentou uma abordagem de aprendizado de máquina baseada em redes neurais conhecida como Analisador de Dados de Infraestrutura (IDA), que permitiu prever a eficiência da infraestrutura de refrigeração de um dado centro de dados envolvendo interações complexas de vários componentes mecânicos,

elétricos e sistemas de controle. A abordagem sugerida foi validada usando dados operacionais no *Leibniz Supercomputing Center*. As principais contribuições desse trabalho foram: (1) tentativa de identificar os fatores de influência e modelagem da eficiência de resfriamento do centro de dados usando uma abordagem baseada em rede neural; (2) previsão do impacto de várias configurações do circuito de refrigeração na eficiência geral da infraestrutura de resfriamento; (3) quantificação das interdependências de vários componentes que compõem o circuito de refrigeração.

Esse artigo mostrou que a IDA foi capaz de produzir resultados de previsão próximos dos ótimos. Além disso, é planejado treinar a IDA para cenários operacionais específicos, de modo que também englobe as variações ambientais anuais irregulares e tenha um espectro suficiente sobre as condições operacionais do centro de dados.

A fim de mitigar a flutuação e equilibrar a demanda e o suprimento de energia na rede elétrica em tempo real, Liu (LIU; LIN; WANG, 2017) propõe uma regulação de serviços (RS), que permita aos consumidores de eletricidade ajustar dinamicamente seu consumo de energia e reduzir o custo. Os centros de dados podem ser participantes ativos da RS devido a sua flexibilidade e controlabilidade no despacho e agendamento de carga temporal (dentro de um servidor) e espacialmente (entre vários servidores). Os autores adotaram um método baseado na rede neural artificial (RNA) e um método baseado na rede neural de longo prazo (*Long Short-Term Memory* (LSTM)) para a previsão do consumo futuro de energia do ambiente. Com base nos resultados de previsão foi formulado um problema de gerenciamento de energia do centro de dados para minimizar o custo total.

Resultados experimentais demonstram que o custo total pode ser reduzido em até 20,6% em comparação com os sistemas de linha de base. Ao final demonstram que o método proposto ajuda o centro de informações a participar melhor da regulação de serviços e a obter economias monetárias consideráveis, ao passo que permite o gerenciamento do sistema de energia de forma eficaz.

Os trabalhos relacionados a redes neurais artificiais e ARIMA utilizados nesta tese estão listados abaixo e representam uma iteração com as três infraestruturas de centros de dados: TI, Elétrica e de Refrigeração. Acerca destes, o que mais se assemelha a esta proposta é o trabalho de Liu (LIU; LIN; WANG, 2017), entretanto, não tratam sobre a infraestrutura elétrica antes da instalação do centro de dados, como nesta proposta atual. A Tabela 3 apresenta um resumo da comparação entre esses trabalhos com a referida proposta.

Tabela 3 – Comparação de RNAs e ARMA relacionadas ao consumo de energia dos centros de dados

	RNA	ARMA	Infr. TI	Infr. Elétrica	Infr. Refrigeração
Tumer	X				
Marwala	X	X			
Zhou		X	X		
Shoukourian	X				X
Liu	X		X	X	
Proposta	X	X		X	

2.3 CONSUMO DE ENERGIA EM INFRAESTRUTURAS ELÉTRICAS

Esta seção apresenta os trabalhos que se relacionam a esta tese por compartilharem o objetivo da redução do consumo energético na infraestrutura elétrica dos centros de dados. Contudo, vale salientar que os referidos estudos seguem linhas diferentes desta proposta, embora, em alguns casos, se complementem.

Em (AVGERINOU; BERTOLDI; CASTELLAZZI, 2017) os autores analisam e apresentam as tendências atuais de consumo e eficiência de energia em centros de dados na União Europeia, fazendo o uso de dados apresentados por empresas participantes do programa: “European Code of Conduct (CCE)” para eficiência energética.

A análise mostra que a eficiência média do uso de energia (*Power Usage Effectiveness* (PUE)) nas instalações participantes do programa está declinando ano após ano, atingindo o valor 1,64 em 2016. A PUE é comparada com vários parâmetros, como o tamanho da instalação, o ano de construção e a carga elétrica da sala de TI. Conclui-se que os centros de dados de tamanho muito pequeno ou muito grande da amostra atingem a melhor PUE. De acordo com os autores, o código de conduta é uma das políticas mais bem-sucedidas para melhorar a eficiência energética nos centros da União Europeia. Portanto, poderia ser facilmente reproduzida em outros países e regiões, com base nessa experiência, o que confirma que abordagens voluntárias podem ser eficazes na abordagem do clima e das questões energéticas.

Em (PELLEY et al., 2009), os autores afirmam que cinco subsistemas distintos são responsáveis pela maior parte do consumo de energia nos centros de dados: (1) servidores e sistemas de armazenamento, (2) equipamentos de condicionamento de energia, (3) sistemas de refrigeração e umidificação, (4) equipamentos de rede e (5) iluminação física / segurança.

Baseados nesses subsistemas, os estudiosos desenvolveram uma estrutura analítica para modelar a potência total do centro de informações. Foram coletados modelos de energia de várias fontes para cada componente crítico do centro. Desta forma, demonstram a aplicabilidade da proposta por meio de um estudo de caso, em que um cenário demonstra

o potencial do gerenciamento inteligente de resfriamento, quando o sistema de refrigeração é acionado de forma a reduzir o uso da infraestrutura de condicionamento de energia geral. Ao final, foram apresentados modelos de energia paramétrica de componentes de centros de dados adequados ao uso em uma infraestrutura de simulação.

Em (CHALISE et al., 2015), o estudo está dividido em duas partes. A primeira apresenta uma visão geral de informações relevantes e recursos disponíveis para o design e operação eficientes de ambientes críticos. A segunda considera dois grandes centros de dados localizados em Atenas que servem dois grandes bancos como estudos de caso, a fim de investigar e quantificar as medidas potenciais para melhorar seu desempenho energético. Os dois bancos foram auditados e o consumo real de energia foi usado para avaliação.

Foram utilizadas várias medidas de eficiência energética (EEM) para ajudar a melhorar o desempenho energético e operacional dos centros de dados, incluindo: (1) instalação inteira (por exemplo, instalações de auditoria, garantir manutenção regular eficaz, instalar placas sem equipamentos para reduzir a recirculação do ar quente através de aberturas no rack, desligar as luzes); (2) software ou equipamento tecnológico (por exemplo, corredores quentes ou frios, utilização de hardware em conformidade com padrões estabelecidos); (3) equipamentos eletromecânicos (E / S) (por exemplo, gerenciamento e projeto de fluxo de ar, placas de cobertura para eliminar vazamento de ar em racks, separação de equipamentos, zonas ambientais separadas, ventiladores de velocidade variável, iluminação de baixa energia, temperatura e monitoramento de energia); (4) práticas opcionais (por exemplo, selecionar e implantar equipamentos na densidade real de energia para evitar a execução do sistema de refrigeração fora das condições de projeto, sequenciamento de unidades CRAC). De acordo com o estudo, as EEMs investigadas podem melhorar a PUE em 0.38 pontos (de 2.49 para 2.11) e 0.23 pontos (de 1.89 para 1.66) e aumentar a eficiência do centro de dados (*Data Center Efficiency* (DCiE)) em 7%.

(MONDAL; KEISLING, 2012) propõem uma nova topologia de centro de dados caracterizada por ser modular, econômica e com distribuição híbrida (tensão CA e CC) usando UPS DC, fonte de alimentação de servidor com tensão de entrada CC e unidade de distribuição de resfriamento para carga do servidor de TI. De acordo com os estudos, a topologia escalável modular proposta oferece um centro de dados sustentável de custo eficiente e alta efetividade. A aplicabilidade da topologia desenvolvida foi validada por meio de análise.

A Tabela 4 relaciona as principais estratégias encontradas para redução do consumo de energia em infraestruturas elétricas que não utilizam RNA, heurísticas ou ARIMA.

Tabela 4 – Comparação com linhas de pesquisa semelhantes

	CCE	In. TI	In. Elétr.	In. Refr.	RNA	Heurística	ARIMA
Avgerinou	X		X				
Pelley		X		X			
Chalise		X	X	X			
Mondal			X				
Proposta			X		X	X	X

2.4 CONSIDERAÇÕES FINAIS

Nesse capítulo foram apresentados os trabalhos mais relevantes encontrados na literatura que estão relacionados aos temas abordados nessa tese. Os trabalhos foram separados em três grandes áreas: heurísticas para redução do consumo de energia, redes neurais artificiais e consumo de energia em centros de dados e consumo de Energia em Infraestruturas elétricas. Foram apresentadas as principais contribuições e diferenças de cada trabalho.

3 REFERENCIAL TEÓRICO

Este capítulo apresenta os fundamentos teóricos da presente tese. Inicialmente, serão apresentados os conceitos dos centros de dados e suas subdivisões. Em seguida, será proporcionada uma introdução a dependabilidade e aos modelos formais: diagrama de blocos de confiabilidade (RBD), Cadeias de Markov de tempo contínuo (CTMC) e redes de Petri estocásticas (SPN). Algumas definições de sustentabilidade serão apresentadas ao longo do trabalho, bem como um resumo sobre a modelagem de fluxo elétrico utilizada em toda a tese. Por fim, são introduzidos conceitos básicos sobre as redes neurais artificiais, o perceptron e o ARIMA, utilizado para validar o algoritmo proposto nesta tese.

3.1 INFRAESTRUTURA DE CENTRO DE DADOS

Os centros de dados surgiram juntamente com a indústria da computação, quando os primeiros sistemas computacionais exigiam ambientes em condições especiais para funcionamento e pela complexidade em sua operação e manutenção (AUGARSTEN, 1984). Com o passar das décadas, ocorreram muitas alterações, como por exemplo, a organização, armazenamento e processamento dos centros de dados. Na literatura existem várias definições sobre os centros de dados. A definição proposta neste trabalho foi a de Marin (MARIN, 2011) onde centros de dados *“possuem equipamentos responsáveis pelo processamento e armazenamento de informações cruciais para a continuidade de negócios nos mais variados tipos de organizações, sejam elas empresas, instituições de ensino, indústrias, órgãos governamentais, hospitais, hotéis, entre outros”*.

É perceptível o crescimento dos centros de dados, quer com a criação de novas instalações, quer com a expansão das existentes. Há grandes organizações operando vários centros de dados em todo o mundo, cada uma com dezenas ou centenas de servidores. Esses centros de dados armazenam dados, computação, melhoria na comunicação, além de possibilitar a colaboração e permitir o entretenimento. É por essa razão que, os centros de dados devem ser robustos e flexíveis para suportar novos requisitos tecnológicos. Os centros de dados podem ser classificados de acordo com seus níveis de redundância de equipamentos, fluxo elétrico e de refrigeração. Turner, Seader e Brill (IV; BRILL, 2008) afirmam que o projeto global de um centro de dados pode ser classificado em quatro níveis, a saber:

- **Projeto de centro de dados nível I**

Possui um caminho único para refrigeração e distribuição de energia, sem componentes redundantes.

- **Projeto de centro de dados nível II**

Contém componentes redundantes, melhorando a disponibilidade.

- **Projeto de centro de dados nível III**

Possui múltiplas passagens de distribuição de eletricidade para o resfriamento, porém apenas um percurso ativo. Fornecem redundância mesmo durante a manutenção.

- **Projeto de centro de dados nível IV**

Mantém múltiplas trajetórias de distribuição de eletricidade para o resfriamento, além de duas rotas ativas. É dotado de componentes redundantes em cada passagem e suporta qualquer falha de um único equipamento sem impactar em seu funcionamento.

Neste trabalho consideramos a proposta de Arregoces e Portolani (ARREGOCES; PORTOLANI, 2003), onde um sistema de centro de dados genérico é adotado, para fins de representação e modelagem, consistindo, nos seguintes subsistemas: (i) infraestruturas de TI, (ii) infraestrutura de resfriamento, e (iii) infraestrutura elétrica. A Figura 1 exemplifica esta proposta e direciona o fluxo da energia.




Figura 1 – Subsistemas de centro de dados

A seguir, demonstramos um detalhamento sobre estas infraestruturas:

- **(i) Infraestrutura de TI**

Consiste em três componentes principais: servidores, equipamentos de rede e dispositivos de armazenamento. Os serviços de software são normalmente organizados em uma arquitetura multicamadas separadas em servidores web, de aplicações e de banco de dados. A infraestrutura de rede inclui o hardware físico adotado para transmitir dados eletronicamente, tais como switches, hubs, roteadores, pontes e gateways. Os serviços de software são normalmente organizados em uma arquitetura multicamadas, separadas em servidores web, de aplicações e de banco de dados (BARROSO; DEAN; HÖLZLE, 2003).

- **(ii) Infraestrutura de Resfriamento**

É responsável por controlar a temperatura ambiente, removendo o excesso de calor gerado pela dissipação de energia das infraestruturas de TI e elétrica, resfriando, consequentemente, o ambiente. A temperatura é regulada no sistema de resfriamento, a fim de mantê-la entre 20 e 22 graus Celsius (PATTERSON, 2008). A infraestrutura de refrigeração da sala de computação é composta basicamente por ar-condicionado (*Computer Room Air Conditioner units* (CRAC)), chillers e torres de resfriamento.

- **(iii) Infraestrutura Elétrica**

É responsável pelo fornecimento ininterrupto de energia, condicionada à tensão e a frequência corretas, para os equipamentos de TI hospedados em racks de centros de dados, bem como a infraestrutura de refrigeração (FAN; WEBER; BARROSO, 2007). A energia provida pelo sistema público de distribuição passa, normalmente, pelos transformadores, chaves de transferência, fontes de alimentação ininterruptas (*Uninterruptible Power Supply* (UPS)), unidades de distribuição de energia (*Power Distribution Unit* (PDU)) e, por fim, pelas régua de energia do rack (CALLOU et al., 2013a) (KUO; ZUO, 2003a).

3.2 DEPENDABILIDADE

Com o crescimento das tecnologias utilizadas através da Internet, a confiabilidade tornou-se um atributo de grande relevância no desenvolvimento, implantação e operação de hardware ou software utilizado (MACIEL et al., 2011a). A replicação de serviços é normalmente disponibilizada através de hospedeiros distribuídos mundialmente, de modo que, na ocorrência de falha em algum serviço, sua replicação esteja pronta para assumir a demanda (GORBENKO; KHARCHENKO; ROMANOVSKY, 2007). Um serviço é confiável quando implementa a funcionalidade especificada pelo sistema. A falha do sistema ocorre quando não consegue fornecer sua funcionalidade especificada. De fato, o conceito de dependabilidade também se associa à confiabilidade e à tolerância a falhas.

Na literatura é possível encontrar várias definições para dependabilidade, uma delas a define como “o sistema que executará ações específicas ou apresentar resultados específicos

de maneira confiável e em tempo hábil ” (PARHAMI, 1988), nesta tese, adotaremos a que afirma que é “a habilidade de disponibilizar um conjunto de serviços com um determinado nível de confiança” (CALLOU et al., 2012b).

A confiabilidade “é a probabilidade que um sistema desempenhe satisfatoriamente (ou adequadamente) o seu propósito específico por um dado período até a ocorrência da primeira falha” (MACIEL et al., 2011a). Como exemplo, um sistema com confiabilidade de 98% para 8760 horas, significa que há 98% de chance de o sistema não falhar de 0 até 8760 horas de operação.

A disponibilidade de um sistema pode ser entendida como a probabilidade do sistema estar funcionando em um determinado tempo desejado ou durante um período de tempo esperado, considerando falhas e/ou reparos ocorridos nesse intervalo. Em geral, a disponibilidade e a confiabilidade são conceitos relacionados, mas diferem, uma vez que o primeiro pode considerar a manutenção de componentes que falharam (CALLOU et al., 2012b). Em Avizienis (AVIZIENIS et al., 2004), é apresentada uma exposição sistemática dos conceitos de dependabilidade: atributos, meios e ameaças. A Figura 2 exibe essa classificação, onde:

- **Os atributos:** possibilitam a obtenção de medidas quantitativas para a análise dos serviços oferecidos;
- **Os meios:** são as formas pelas quais a dependabilidade é atingida;
- **As ameaças:** compreendem as falhas, erros e defeitos. A falha do sistema é o evento que ocorre quando a entrega do serviço não acontece como desejado.

As métricas de dependabilidade (disponibilidade e confiabilidade) podem ser computadas através de modelos combinatórios, como o RBD, ou de modelos baseados em estados, como o SPN, entre outras formas. Os RBDs permitem estabelecer equações de forma fechada e representar redes de componentes. O objeto da análise sobre as questões de dependabilidade está nos atributos que a compreende: disponibilidade, confiabilidade, segurança, confidencialidade, integridade e manutenibilidade, como exibidos na árvore de dependabilidade (Figura 2). Porém, nesse trabalho apenas a disponibilidade e a confiabilidade serão explicadas em detalhes.

Para cálculo das métricas de confiabilidade e disponibilidade, é necessário conhecer os tempos de falha (Time to Fail - TTF) e o tempo do reparo (Time to Repair - TTR) dos componentes presentes nos modelos. Entretanto, como o tempo de atividade e de inatividade geralmente não são conhecidos, a opção mais plausível é da utilização de uma média sobre essas métricas. Assim, é considerado um tempo médio de falha (*Mean Time to Fail* (MTTF)) e um tempo médio do reparo (*Mean Time to Repair* (MTTR)).

A disponibilidade (A) de estado estacionário pode ser calculada pela equação 3.1:

$$A = \frac{MTTF}{MTTF + MTTR} \quad (3.1)$$




Figura 2 – Árvore de Dependabilidade Adaptada de Avizienis (AVIZIENIS et al., 2004)

Considerando um determinado período de tempo representado pelo intervalo $(0,t)$, $R(t)$ representa a probabilidade do componente funcionar (não falhar) desde 0 até t . Ao considerar o tempo de falha de uma distribuição exponencial, a confiabilidade é representada por:

$$R(t) = \exp\left[-\int_0^t \lambda(t')dt'\right] \quad (3.2)$$

onde $\lambda(t')$ é a taxa de falha instantânea.

Através de análise transiente ou de simulação, a confiabilidade (R) é obtida, e, em seguida, o MTTF pode ser calculado, bem como o desvio padrão (sd) do tempo até a falha (TTF):

$$MTTF = \int_0^\infty t f(t) dt = \int_0^\infty -\frac{dR(t)}{dt} t dt = \int_0^\infty R(t) dt \quad (3.3)$$

$$sd(TTF) = \sqrt{\int_0^\infty t^2 f(t) dt - (MTTF)^2} \quad (3.4)$$

Geralmente utilizamos três tipos de modelos para analisar os mais diversos cenários. O RBD pode ser avaliado através de simulação, sempre que adotadas distribuições mais complexas que a exponencial. Deve-se ter em mente que, para o cálculo da confiabilidade de um determinado serviço do sistema, a atividade de reparação do respectivo serviço não deve ser representada. Além disso, considerando a Equação 3.1 e que a $UA = 1 - A$ (indisponibilidade), a seguinte equação pode ser derivada:

$$MTTR = MTTF \times \frac{UA}{A} \quad (3.5)$$

A derivação padrão do tempo de reparo (TTR) pode ser calculada da seguinte forma:

$$sd(TTR) = sd(TTF) \times \frac{UA}{A} \quad (3.6)$$

Em seguida, $\frac{MTTF}{sd(TTF)}$ e $\frac{MTTR}{sd(TTR)}$ podem ser computadas para a escolha da distribuição polinomial que melhor se adapta as distribuições TTF e TTR.

Ademais, existem técnicas formais que podem ser usadas para modelar sistemas de computador e estimar medidas relacionadas à disponibilidade, confiabilidade e desempenho do sistema. Redes de Petri Estocásticas (SPNs) (MOLLOY, 1982b), Árvores de Falha (O'CONNOR; KLEYNER, 2011), RBDs (O'CONNOR; KLEYNER, 2011) e cadeias de Markov (BOLCH et al., 2006) foram usadas para modelar muitos tipos de sistemas e avaliar várias medidas de disponibilidade e confiabilidade.

SPNs e cadeias de Markov são formalismos de modelagem amplamente adotados na literatura para lidar com questões de desempenho. Os tipos de modelo mencionados podem ser classificados em modelos com e sem espaço de estados (MACIEL et al., 2011b). Modelos sem espaço de estado (por exemplo, RBDs, árvores de falhas) permitem, em geral, uma representação mais concisa do sistema. Modelos com espaço de estados (por exemplo, cadeias de Markov, SPNs, redes de autômatos estocásticos) permitem a representação de relações mais complexas entre os componentes do sistema, como dependências envolvendo subsistemas e restrições de recursos (MACIEL et al., 2011b). Geralmente, os modelos de espaço de estados exigem a solução numérica de um sistema subjacente de equações, que fornecerá informações úteis, como probabilidades de estado, tempo médio de passagem. A simulação de eventos discretos é outra maneira de obter métricas desses modelos. Em alguns casos especiais, respostas de forma fechada podem ser derivadas de modelos de espaço de estados.

Tipos distintos de modelos podem ser combinados hierarquicamente, permitindo a representação de muitos tipos de dependências entre componentes e evitando a questão conhecida de explosão de espaço de estados, ao lidar com sistemas grandes. Um exemplo dessa abordagem hierárquica é o uso de modelos combinatórios para representar a relação

de disponibilidade entre subsistemas independentes, enquanto mecanismos detalhados ou mais complexos de falha e reparo são modelados com modelos baseados em estado. Tal abordagem é vista em (DANTAS et al., 2012), que combina RBDs e cadeias de Markov, em (KIM; MACHIDA; TRIVEDI, 2009) árvores de falhas e CTMCs são combinados. Essa composição é geralmente chamada de modelagem hierárquica heterogênea.

3.2.1 Diagrama de Blocos de Confiabilidade

Os diagramas de blocos de confiabilidade são redes de blocos funcionais conectados de acordo com o efeito de cada falha do bloco na confiabilidade do sistema (MACIEL et al., 2011b). Os diagramas de blocos de confiabilidade (RBDs) indicam como o estado operacional (falho ou funcional) dos componentes do sistema afetam o funcionamento do mesmo. O RBD foi inicialmente proposto como um modelo para calcular a confiabilidade, mas pode ser usado para calcular outras métricas de dependabilidade, como disponibilidade e capacidade de manutenção.

A Figura 3 descreve um exemplo de RBD para um sistema com os componentes: A, B e C. Os RBDs possuem vértices de origem e destino, um conjunto de blocos (geralmente retângulos), onde cada bloco representa um componente; e arcos conectando os componentes e os vértices. O nó de origem é geralmente colocado no lado esquerdo do diagrama, enquanto o vértice de destino é posicionado à direita. Graficamente, o sistema está funcionando corretamente quando há pelo menos um caminho do nó de origem ao nó de destino. Portanto, na Figura 3, o sistema estará operacional se o componente A estiver funcionando e se o componente B ou C também estiver operacional.




Figura 3 – Exemplo de RBD

Em RBDs, o estado do sistema é descrito como uma função booleana de estados de seus componentes ou subsistemas, ela é avaliada como verdadeira sempre que pelo menos o número mínimo de componentes é ativado operacionalmente para executar a funcionalidade pretendida (MACIEL et al., 2011b) (KUO; ZUO, 2003a). O estado do sistema também pode ser descrito pelas respectivas funções de estrutura de seus componentes ou subsistemas, de

modo que a função de estrutura do sistema seja avaliada como 1 sempre que pelo menos o número mínimo de componentes estiver operacional.

Os RBDs foram adotados para avaliar estruturas paralelas em série e mais genéricas, como arranjos de pontes, estrelas e delta.

Considere uma estrutura de série pura composta por n componentes independentes, onde $p_i = P\{x_i = 1\}$ são as probabilidades de funcionamento dos blocos x_i . Essas probabilidades podem ser confiabilidades ou disponibilidades, por exemplo. A Equação 3.7 é usada para calcular a disponibilidade de estado estacionário do sistema da composição em série em um RBD (KUO; ZUO, 2003a). Isso denota que a disponibilidade de um sistema em série é o produto da disponibilidade de cada componente.

$$A_s = \prod_{i=1}^n P\{x_i = 1\} = \prod_{i=1}^n A_i \quad (3.7)$$

onde A_i é a disponibilidade de estado estacionário do bloco x_i .

A confiabilidade de um sistema em paralelo é calculada de maneira similar. A Equação 3.8 é usada para calcular a disponibilidade de uma estrutura paralela pura, composta de componentes independentes de n . Baseia-se no fato de que a probabilidade de falha de um sistema paralelo é o produto das probabilidades de falha ($P\{x_i = 0\}$) de seus componentes.

$$A_p = 1 - \prod_{i=1}^n P\{x_i = 0\} = 1 - \prod_{i=1}^n UA_i = 1 - \prod_{i=1}^n (1 - A_i), \quad (3.8)$$

onde $UA_i = 1 - A_i$ é a indisponibilidade de cada bloco x_i . Para mais conhecimento sobre estruturas paralelas em série, séries paralelas e outras estruturas RBD, recomenda-se ao leitor os livros de Maciel (MACIEL et al., 2011b) ou Kuo (KUO; ZUO, 2003a).

3.2.2 Cadeias de Markov

São modelos usados para representar as interações entre os vários componentes do sistema, tanto para fins descritivos quanto preditivos (MENASCE et al., 2004). Os modelos de Markov têm sido usados intensamente na modelagem de desempenho e confiabilidade desde os anos cinquenta (MACIEL et al., 2011b). Além da Ciência da computação, a quantidade de aplicações dos modelos Markov é muito extensa. Economia, meteorologia, física, química e telecomunicações são alguns exemplos de campos que encontraram neste tipo de modelagem estocástica uma boa abordagem para solucionar vários problemas.

Uma cadeia de Markov pode ser descrito como um diagrama de espaço de estados associado a um processo de Markov, que constitui uma subclasse de processos estocásticos. Um processo estocástico é uma família de variáveis aleatórias $\{X_t : t \in T\}$ onde cada variável aleatória X_t é indexada pelo parâmetro $t \in T$, que é usualmente chamado de parâmetro de tempo se $T \subset R_+ = [0, \infty)$, isto é, T está no conjunto de números reais não negativos. O conjunto de todos os valores possíveis de X_t (para cada $t \in T$) é conhecido como o espaço de estado S do processo estocástico (BOLCH et al., 2006).

Seja $\Pr\{k\}$ a probabilidade de um dado evento k ocorrer. Uma cadeia de Markov é um processo estocástico em que $\Pr\{X_{t_{n+1}} \leq s_{i+1}\}$ depende apenas do último valor anterior X_{t_n} , para todos $t_{n+1} > t_n > t_{n-1} > \dots > t_0 = 0$, e todos os $s_i \in S$. Essa é a chamada propriedade Markoviana (HAVERKORT; MEEUWISSEN, 1995), que significa que a evolução futura do processo de Markov é totalmente descrita pelo estado atual e é independente de estados passados (HAVERKORT; MEEUWISSEN, 1995).

Nesta tese, há apenas interesse em modelos de Markov de espaço de estados discretos (contáveis), também conhecidos como cadeias de Markov, que são distinguidos em duas classes: Cadeias de Markov de Tempo Discreto (*Discrete Time Markov Chain* (DTMC)) e Cadeias de Markov de Tempo Contínuo (CTMCs) (KLEINROCK, 1975). Nas DTMCs, as transições entre estados só podem ocorrer em intervalos conhecidos, isto é, passo a passo. Os sistemas em que as transições ocorrem apenas diariamente, ou após um relógio discreto estrito, são bem representados pelos DTMCs. Se as transições de estado podem ocorrer em instantes de tempo arbitrários (contínuos), a cadeia de Markov é uma CTMC. As propriedades Markovianas implicam que o tempo de transições é conduzido por uma distribuição sem memória (BOLCH et al., 2006). No caso do DTMC, a distribuição geométrica é a única distribuição de tempo discreta que apresenta a propriedade sem memória. No caso do CTMC, a distribuição exponencial é usada.

As cadeias de Markov podem ser representadas como um grafo direcionado com transições rotuladas, indicando a probabilidade ou a taxa na qual tais transições ocorrem. Ao lidar com CTMCs, como o modelo de disponibilidade da Figura 4, as transições ocorrem com uma taxa, em vez de uma probabilidade, devido à natureza contínua desse tipo de modelo.




Figura 4 – CTMC Simple

A CTMC é representada através de uma matriz de transição, ou matriz geradora infinitesimal. Considerando o modelo de disponibilidade de CTMC da Figura 4, as taxas são medidas em falhas por segundo, reparos por segundo e detecções por segundo. A

matriz geradora Q é composta pelos componentes q_{ii} e q_{ij} , onde $i \neq j$ e $\sum q_{ij} = -q_{ii}$. Usando o modelo de disponibilidade que acabou de ser mencionado, considerando um espaço de estados $S = Up, Down, Repair = 0,1,2$, a matriz Q é representada na Figura 5:

$$Q = \begin{pmatrix} q_{00} & q_{01} & q_{02} \\ q_{10} & q_{11} & q_{12} \\ q_{20} & q_{21} & q_{22} \end{pmatrix} = \begin{pmatrix} -0.001 & 0.001 & 0 \\ 0 & -2 & 2 \\ 0.2 & 0 & -0.2 \end{pmatrix}$$

Figura 5 – Matriz Q

A Equação 3.9 e o sistema de Equações 3.10 descrevem o cálculo do vetor de probabilidade de estado, respectivamente para análise transitória (isto é, dependente do tempo) e estado estacionário (ou seja, análise estacionária). A partir do vetor de probabilidade do estado, quase todas as outras métricas podem ser derivadas, dependendo do sistema representado.

$$\underline{\pi}'(t) = \underline{\pi}(t)Q, \text{ dado } \underline{\pi}(0) \quad (3.9)$$

$$\underline{\pi}'Q = 0, \sum_{i \in S} \pi = 1 \quad (3.10)$$

Explicações detalhadas sobre como obter essas equações podem ser encontradas em (BOLCH et al., 2006); (HAVERKORT; MEEUWISSEN, 1995). Para todos os tipos de análise usando cadeias de Markov, um aspecto importante deve ser considerado: a distribuição exponencial das taxas de transição. O comportamento dos eventos em muitos sistemas computacionais pode ser melhor ajustado por outras distribuições de probabilidade, mas em algumas dessas situações a distribuição exponencial é considerada uma aproximação aceitável, permitindo o uso de modelos de Markov. É possível também adaptar a transição em cadeias de Markov para representar outras distribuições por meio de aproximação de fase, como mostrado em (TIWARI; MALIK; WOLFE, 2001). O uso de tal técnica permite a modelagem de eventos descritos por distribuições como Weibull, Erlang, Cox, hipoexponencial e hiperexponencial.

3.2.3 Redes de Petri Estocásticas

Redes de Petri (MURATA, 1989) são uma família de formalismos usados para a modelagem de vários tipos de sistemas, devido à sua capacidade de representar simultaneidade, sincronização, mecanismos de comunicação, bem como atrasos determinísticos e probabilísticos. A rede de Petri original não possui a noção de tempo para análise de desempenho e confiabilidade. A introdução da duração dos eventos resulta em uma rede de Petri temporizada. Um caso especial de Redes de Petri temporizada é a Rede de Petri Estocástica

(SPN) (MOLLOY, 1982b), onde os atrasos de atividades (representados como transições) são considerados variáveis aleatórias com distribuição exponencial.

Um modelo em SPN pode ser traduzido para CTMC, que pode então ser resolvido para obter os resultados desejados de desempenho ou confiabilidade. Isso é especialmente útil porque construir um modelo de Markov manualmente pode ser entediante e propenso a erros, especialmente quando o número de estados se torna muito grande. A família de formalismos da SPN é uma solução possível para lidar com esse problema. (MARSAN; CONTE; BALBO, 1984) propõe uma Rede de Petri Estocástica Generalizada (*Generalized stochastic Petri nets* (GSPN)), que é uma extensão da SPN, que considera dois tipos de transições: temporizadas e imediatas. Um tempo de disparo exponencialmente distribuído é associado apenas a transições temporizadas, uma vez que transições imediatas, por definição, são acionadas em tempo zero.




Figura 6 – Exemplo de SPN

A Figura 6 descreve um exemplo de um modelo GSPN. Os lugares são representados por círculos, enquanto as transições são representadas como retângulos preenchidos (transições imediatas) ou retângulos vazios (transições temporizadas). Arcos (arestas direcionadas) conectam lugares a transições e vice-versa. Tokens (pequenos círculos preenchidos) se localizam em lugares. Um vetor contendo o número atual de tokens em cada local denota o estado global (isto é, marcação) de uma rede de Petri. Um arco inibidor é um tipo de arco especial que representa um pequeno círculo branco em uma borda, em vez de uma seta, e eles são usados para desabilitar transições se houver tokens presentes em um determinado local. O comportamento das redes de Petri em geral é definido em termos de um fluxo de token, no sentido de que os tokens são criados e destruídos de acordo com os acionamentos das transições (GERMAN, 2000). As transições imediatas representam

atividades instantâneas e têm maior prioridade de disparo que transições temporizadas. Além disso, tais transições podem conter uma condição de guarda, e um usuário pode especificar uma prioridade de disparo diferente entre outras transições imediatas.

A Figura 6 representa a disponibilidade de um sistema composto por três servidores computacionais. Cada token no lugar *Servers Up* denota um servidor que está funcionando corretamente. Todos os três servidores podem falhar de forma independente, ao disparar a falha de transição temporizada (exponencial). Um token no lugar *Servers Down* pode ser consumido por transição imediata Reparável (*Repairable*) ou por transição imediata Não reparável (*Non-repairable*). Os pesos são atribuídos a cada uma dessas transições para representar a probabilidade de disparar um ou outro. Quando o servidor com falha pode ser reparado, a transição Reparável (*Repairable*) coloca um token nos Servidores para reparar. Quando o reparo não é possível, a transição Não reparável (*Non-repairable*) coloca o token nos servidores para substituir. As transições reparar e substituir disparam após atrasos exponenciais correspondentes a essas atividades. A probabilidade de ter pelo menos um servidor disponível, o número médio de servidores aguardando reparo ou substituição e outras métricas similares podem ser calculadas a partir do CTMC subjacente gerados a partir desse SPN.

Os SPNs também permitem a adoção de técnicas de simulação para obter métricas de confiabilidade e desempenho como uma alternativa à geração de um CTMC, que às vezes é proibitivo devido à explosão do espaço de estados. Em relação à definição e semântica formal do SPN e do GSPN, o leitor é direcionado a (MOLLOY, 1982b) (MARSAN; BALBO; CONTE, 1986). Esses formalismos foram expandidos para permitir atrasos determinísticos para transições temporizadas, gerando redes de Petri determinísticas e estocásticas (*Deterministic and Stochastic Petri Nets* (DSPN)) (GERMAN et al., 1995). Outras extensões de SPN foram propostas na literatura para permitir outras distribuições de probabilidade, mas a solução desses modelos requer técnicas de simulação e processos não-markovianos, que podem não ser tão computacionalmente eficientes quanto os métodos de solução para as SPNs tradicionais.

3.3 SUSTENTABILIDADE

O termo sustentabilidade tem sido utilizado desde a década de 1980, com o sentido da sustentabilidade humana no planeta Terra. Isso resultou na definição mais utilizada nos dias de hoje, como parte do conceito de desenvolvimento sustentável: “*O desenvolvimento sustentável é o desenvolvimento que satisfaz as necessidades do presente sem comprometer a capacidade das gerações futuras de satisfazerem as suas próprias necessidades*” (COMMISSION et al., 1987).

Nas últimas décadas, com o aumento da preocupação sobre as questões de sustentabilidade em todo o planeta, surgiu o conceito de Computação Verde (Green Computing), que é definida como: “*o estudo e a prática da computação ecologicamente sustentável, in-*

cluindo concepção, fabricação, uso e descarte de computadores, servidores e subsistemas associados (monitores, impressoras, dispositivos de armazenamento e sistemas de comunicação) com eficiência e eficácia. Dessa maneira, causando o menor impacto possível ao meio ambiente” (MURUGESAN, 2008). Muitas pesquisas publicadas nos últimos anos abordam os centros de dados verdes (green data center), mais especificamente os seguintes trabalhos foram publicados com foco na redução do consumo de energia: (CALLOU et al., 2011) (CALLOU et al., 2011) (CALLOU et al., 2013a) (GMACH et al., 2010) (ZHANG et al., 2010), tais trabalhos são altamente relevantes para as empresas de TI e estão em sintonia com este trabalho.

De acordo com Bouley (BOULEY, 2010), para se medir o nível de sustentabilidade de um centro de dados, deve-se primeiramente determinar seu consumo de energia e, em seguida, utilizar uma métrica para fazer a avaliação da sustentabilidade. Na verdade, além do consumo de energia, existem outros métodos interligados de comparação de equipamentos a partir do ponto de vista da sustentabilidade. Entre outros, como exemplo, podem ser citados os materiais utilizados na fabricação dos equipamentos e os prejuízos ambientais irreversíveis para as futuras gerações. O impacto ambiental pode ser quantificado também pela métrica utilizada na segunda lei da termodinâmica, exergia (DINCER; ROSEN, 2007). A exergia é uma métrica que estima a eficiência de um sistema, por exemplo, baseado no consumo elétrico de uma arquitetura de um centro de dados. Como um índice para a avaliação global da sustentabilidade, a propriedade termodinâmica da exergia é de grande importância.

Segundo Dincer (DINCER; ROSEN, 2007), a exergia é definida como “*a fração máxima de energia latente que pode ser teoricamente convertida em trabalho útil*”. Uma ilustração interessante seria comparar a exergia de um kJ de gasolina com a de um kJ de água à temperatura ambiente. A exergia da gasolina é muito maior, uma vez que pode ser usada para movimentar um caminhão, mas a água à temperatura ambiente não. A exergia é calculada como o produto da energia por um índice de fator de qualidade, como mostrado na Equação 3.11.

$$Exergy = Energy \times \alpha \quad (3.11)$$

O índice α é um fator de qualidade representado pela relação da exergia/energia, conforme apresentado na Tabela 5 (DINCER; ROSEN, 2007).

Por cada componente elétrico dissipa uma fração do calor, que não é teoricamente convertida em trabalho útil, denominada então de exergia operacional. A Equação 3.12 é usada para computar o valor da exergia operacional.

$$Ex_{op} = \sum_{i=1}^n Ex_{op(i)} \times T \times (A + \alpha(1 - A)) \quad (3.12)$$

onde $Ex_{op(i)}$ é a exergia operacional de cada dispositivo; T é o período da análise; A é

Tabela 5 – Valores de energia e exergia para diferentes modalidades energéticas

Origem	Energia (J)	Exergia(J)	α
Água a 80 graus Celsius	100	16	0,16
Vapor a 120 graus Celsius	100	24	0,24
Gás Natural	100	99	0,99
Eletricidade	100	100	1

a disponibilidade do sistema e α é o fator que representa a quantidade de energia que continua a ser consumida após a falha de determinado dispositivo.

Cada tipo de dispositivo usa uma equação específica para calcular sua exergia operacional. Assim, a equação usada para avaliar um gerador a diesel é diferente da usada para avaliar uma torre de resfriamento. Nessa tese apenas equipamentos elétricos foram considerados. A Equação 3.13 é utilizada para computar a exergia de cada dispositivo elétrico.

$$Exergy = P_{in} \times (1 - n) \quad (3.13)$$

onde P_{in} é a energia elétrica de entrada de cada equipamento e n é a eficiência informada; Para maiores informações, o leitor deve ler Dincer (DINCER; ROSEN, 2007).

3.4 MODELAGEM DE FLUXO ELÉTRICO

O modelo de fluxo elétrico (Energy Flow Model - EFM (CALLOU et al., 2012a)) quantifica o fluxo de energia entre os componentes de um sistema, respeitando os limites de energia que cada componente pode fornecer (considerando os dispositivos elétricos) ou a máxima capacidade de resfriamento (assumindo os dispositivos de refrigeração). É importante salientar que as unidades de medida utilizadas pela modelagem EFM para mensurar o valor da energia é o kJ para modelos de refrigeração e kW para modelos elétricos. O EFM é representado por um grafo acíclico dirigido, no qual os componentes são modelados como vértices e as respectivas ligações correspondem às arestas. A seguir, a definição formal do EFM, que é representado por um grafo acíclico dirigido, G:

$G = (N, A, w, f_d, f_c, f_p, f_\eta)$, onde:

- $N = N_s \cup N_i \cup N_t$ representam o conjunto de nós (por exemplo: componentes), em que N_s é o conjunto de nós iniciais (source), N_t é o conjunto de nós destino (target) e N_i denota o conjunto de nós intermediários, $N_s \cap N_i = N_s \cap N_t = N_i \cap N_t = \emptyset$;
- $A \subseteq (N_s \times N_i) \cup (N_i \times N_t) \cup (N_i \times N_i) = \{(a,b) \mid a \neq b\}$ denota o conjunto de arestas (por exemplo: as conexões dos componentes).

- $w : A \rightarrow \mathbf{R}^+$ é uma função que associa pesos as arestas (o valor associado a aresta (j, k) é adotado para distribuição da energia associada ao nó j para o nó k de acordo com a relação $w(j, k) / \sum_{i \in j^\bullet} w(j, i)$, onde $j^\bullet$ é o conjunto de nós que partem do nó j);
- $f_d : N \rightarrow \begin{cases} \mathbf{R}^+ & \text{se } n \in N_s \cup N_t, \\ 0 & \text{caso contrario;} \end{cases}$
é uma função que associa a cada nó o calor a ser extraído (considerando modelos de resfriamento) ou a energia a ser suportada (considerando modelos elétricos);
- $f_c : N \rightarrow \begin{cases} 0 & \text{se } n \in N_s \cup N_t, \\ \mathbf{R}^+ & \text{caso contrario;} \end{cases}$
é a função que associa cada nó com sua respectiva capacidade máxima de energia;
- $f_p : N \rightarrow \begin{cases} 0 & \text{se } n \in N_s \cup N_t, \\ \mathbf{R}^+ & \text{caso contrario;} \end{cases}$
é uma função que associa cada nó (um nó representa um componente) com seu preço de venda;
- $f_\eta : N \rightarrow \begin{cases} 1 & \text{se } n \in N_s \cup N_t, \\ 0 \leq k \leq 1, k \in \mathbf{R} & \text{caso contrario;} \end{cases}$
é uma função que associa cada nó com sua eficiência energética.

O modelo EFM adota uma abordagem de profundidade gulosa para percorrer o modelo (grafo) quando computa suas métricas. Além disso, um vetor que contém todos os nós (componentes) do modelo é adotado, para associar a cada nó $i \in N_i$ a energia de corrente elétrica que flui através de cada componente.

3.5 REDE NEURAL ARTIFICIAL

As redes neurais artificiais (RNAs) são sistemas computacionais que visam trabalhar de maneira semelhante ao cérebro humano. As RNAs devem ser capazes de aprender e tomar decisões com base no conhecimento aprendido. Representam uma tentativa de superar as limitações da computação convencional usando certas vantagens do cérebro humano, tais como: alto grau de paralelismo, tolerância a falhas, robustez, adaptabilidade e auto-organização (HAYKIN, 1994).

Uma RNA é baseada em uma coleção de unidades conectadas ou nodos chamados neurônios artificiais, que representam os neurônios em um cérebro biológico. Cada conexão, como as sinapses de um cérebro biológico, pode transmitir um sinal de um neurônio artificial para outro. Um neurônio artificial que recebe um sinal pode processá-lo e depois sinalizar neurônios artificiais adicionais conectados a ele.

Normalmente, os neurônios artificiais são agregados em camadas. Diferentes camadas podem realizar diferentes tipos de transformações em suas entradas. Os sinais viajam da primeira camada (a camada de entrada) até a última camada (a camada de saída), possivelmente depois de atravessar as camadas várias vezes.

O objetivo original da abordagem de RNA era resolver problemas da mesma forma que um cérebro humano faria. No entanto, com o tempo, passou a executar tarefas específicas. Redes neurais artificiais têm sido usadas em uma variedade de tarefas, incluindo visão computacional, reconhecimento de voz, tradução automática, filtragem de redes sociais, jogos de tabuleiro e diagnóstico médico.

3.5.1 Perceptron

O perceptron é a forma de configuração mais simples de uma rede neural artificial, pois consiste em uma única camada neural e um único neurônio. Por meio do processo de treinamento, o perceptron aprende a classificar entradas em dois grupos diferentes. O perceptron só é capaz de resolver problemas que são linearmente separáveis. No entanto, as não-linearidades são inerentes à maioria das situações e problemas reais e, portanto, é necessário utilizar estruturas com características não-lineares para resolver problemas mais complexos (ROSENBLATT, 1958).

Um perceptron multicamadas (*Multilayer perceptron* (MLP)) consiste em três ou mais camadas (uma camada de entrada, uma camada de saída e N camadas ocultas). A camada de saída recebe o estímulo da camada intermediária e constrói a resposta. Os MLPs usam um algoritmo de retro propagação, solução padrão para qualquer aprendizado supervisionado (ROSENBLATT, 1958). Esse algoritmo atualiza não apenas os pesos da última camada de neurônios (saída), mas também os pesos das camadas intermediárias. Portanto, o perceptron pode ser ampliado em camadas, permitindo que problemas mais complexos sejam resolvidos.

3.6 ARIMA

Na análise de séries temporais, um modelo de média móvel autorregressiva integrada (ARIMA) é a generalização de um modelo de auto-regressão de médias móveis (ARMA) (BOX et al., 2015). Ambos os modelos são ajustados aos dados de séries temporais para entender melhor os dados ou prever os pontos futuros da série. Os modelos ARIMA são aplicados em alguns casos onde os dados apresentam evidências de não-estacionariedade, em que uma etapa de diferenciação inicial (correspondente à parte “integrada” do modelo) pode ser aplicada uma ou mais vezes para eliminar a não-estacionariedade (BOX et al., 2015).

A parte auto regressiva (AR) do modelo ARIMA indica que a variável evolutiva de interesse é retornada em seus próprios valores defasados. A parte da média móvel (MA)

indica que o erro de regressão é, na verdade, uma combinação linear dos termos de erro, cujos valores ocorreram contemporaneamente e em vários momentos no passado. A parte integrada (I) indica que os valores dos dados foram substituídos pela diferença entre seus valores e os valores anteriores, este processo de diferenciação pode ser realizado mais de uma vez. O objetivo de cada uma dessas características é ajustar o modelo de dados da melhor maneira possível (PINDYCK; RUBINFELD, 2004).

Os modelos ARIMA não sazonais são geralmente denotados por ARIMA (p, d, q), onde os parâmetros p, d e q são inteiros não negativos, “p” é a ordem (número de lags) do modelo autorregressivo, “d” é o grau de diferenciação (o número de vezes que os valores passados foram subtraídos dos dados) e “q” é a ordem do modelo de média móvel. Para obter mais informações sobre o ARIMA, consulte (BOX et al., 2015) e (PINDYCK; RUBINFELD, 2004).

3.7 CONSIDERAÇÕES FINAIS

Esse capítulo apresentou os fundamentos teóricos necessários a compreensão da tese. Tais definições são fundamentais para que seja proporcionado o conhecimento necessário ao entendimento do algoritmo proposto para otimização do fluxo elétrico nos modelos EFM e do uso das previsões de consumo elétrico e impacto ambiental. Foram abordados os conceitos de centros de dados, dependabilidade, modelos formais (diagrama de blocos de confiabilidade, Cadeias de Markov de tempo contínuo e redes de Petri estocásticas). Ademais, algumas definições de sustentabilidade, modelagem de fluxo elétrico, redes neurais artificiais, perceptron e ARIMA.

4 METODOLOGIA

Este capítulo apresenta a metodologia proposta nesta tese. A estratégia geral utilizada na pesquisa, que delinea a maneira pela qual a mesma deve ser realizada e, entre outras coisas, identifica os métodos a serem aplicados para solucionar o problema geral. Esses procedimentos descritos na metodologia definem os meios para se chegar a um resultado específico (HOWELL, 2012).

A metodologia proposta nesta tese consiste em utilizar estratégias para analisar e estimar o consumo de energia em infraestruturas elétricas de centros de dados. A Figura 7 apresenta uma visão de alto nível da metodologia proposta, destacando suas macro atividades, como: entender o sistema, gerar modelos formais, considerar mix energético, otimizar a distribuição do fluxo, prever custos e impacto ambiental com RNA e analisar os resultados.

A seguir, cada uma das macro atividades será explicada em detalhes, bem como suas atividades internas, insumos e produtos. Dessa forma, objetivamos proporcionar ao leitor a capacidade de reproduzir o procedimento como um todo.

4.1 ENTENDER O SISTEMA

A primeira fase da metodologia diz respeito à análise do sistema, seus componentes, suas interfaces e interações. Nesta fase, o projetista deve absorver o conhecimento necessário sobre centros de dados, para que seja capaz de modelar o ambiente estudado. As seguintes atividades devem ser desenvolvidas nesta etapa:

- **Identificar características do sistema** - Consiste em identificar as principais características associadas ao sistema. Dessa forma, a pré-condição básica desta atividade é a necessidade de se entender os centros de dados, suas características e subdivisões. São insumos de entrada a esta atividade as referências bibliográficas, pesquisas sobre este tema e os centros de dados reais já instalados. A partir dessas informações, o estudo é de fato executado, o que proporciona o entendimento do funcionamento do centro de dados, para que seja possível definir os parâmetros que deverão ser estudados. Assim, o principal produto desta atividade é a compreensão de como o centro de dados funciona e as relações entre seus componentes.
- **Definir escopo** - Com o conhecimento dos relacionamentos existentes em um centro de dados advindos da atividade anterior, deve-se definir o escopo do estudo. Os centros de dados são subdivididos em três grandes áreas: infraestrutura de tecnologia da informação, infraestrutura de refrigeração e infraestrutura elétrica. Nesta fase, delimita-se o estudo do ambiente da infraestrutura elétrica do centro de dados,




Figura 7 – Metodologia - Visão geral

desde a fornecedora de energia elétrica à demanda da sala de computação. Deve-se aprofundar o conhecimento sobre os equipamentos que compõem o escopo, como: UPS (UPS), STS (*Static Transfer Switch* (STS)), geradores, subpanel, junction box, concessionária. UPS é uma fonte de alimentação ininterrupta, um aparelho elétrico que fornece energia de emergência a uma carga quando a fonte de alimentação de entrada ou a rede elétrica falha. PDU é uma unidade de distribuição de energia. STS permite que as cargas de um único cabo sejam energizadas em qualquer momento.

Geradores são basicamente motores movidos a diesel, responsáveis por gerar energia elétrica suficiente para atender a demanda do centro de dados. Subpanel é um mini painel elétrico que atua como um ponto no caminho entre o painel de serviço principal e os circuitos ramificados. Junction Box é um gabinete que contém as conexões elétricas para proteger as conexões e fornecer uma barreira de segurança. Concessionária é um segmento do setor elétrico dedicado à entrega de energia elétrica para um usuário final.

- **Representar em alto nível a infraestrutura elétrica** - Esta atividade visa criar representações em alto nível que simbolizem a arquitetura do centro de dados e permitam que projetistas especifiquem a infraestrutura elétrica. Deve-se utilizar uma ferramenta que possibilite representar os relacionamentos, as direções, os fluxos e as redundâncias entre os componentes.

O produto da macro atividade **Entender o sistema** consiste no conhecimento necessário para uma representação do ambiente em estudo, o qual será formalmente modelado na próxima etapa.

4.2 CRIAR MODELOS DE DISPONIBILIDADE E FLUXO ELÉTRICO

Agora que possíveis lacunas sobre o entendimento do sistema foram preenchidas e que o escopo foi definido, podemos propor modelos formais para obter resultados do sistema como um todo.

Nesta etapa são tratadas as questões necessárias à criação de modelos formais para representar a disponibilidade e o fluxo elétrico do ambiente avaliado. Os insumos desta macro atividade são as representações de alto nível das infraestruturas elétricas dos centros de dados. Estes são os principais modelos para descrever a infraestrutura elétrica do centro de dados e os relacionamentos entre seus componentes.

De forma específica, as seguintes atividades fazem parte desta fase:

- **Criar modelos de disponibilidade** - conhecendo o sistema e seus principais componentes, somos capazes de criar modelos utilizados para representar o comportamento da infraestrutura elétrica do centro de dados. RBDs, CTMCs e SPNs devem representar o funcionamento da infraestrutura elétrica e sua aplicabilidade no mundo real. RBD é um formalismo adequado para a representação das infraestruturas, devido a sua concisão para representar grandes sistemas. Entretanto, é importante ressaltar que modelos hierárquicos podem ser gerados para mitigar a complexidade do modelo final. Alguns comportamentos do sistema não podem ser representados por RBDs, por haver relação de dependência entre os componentes. Por exemplo, para representação do sistema de geradores e seus backups, nesses casos, foi utilizado

o SPN. A partir da avaliação desses modelos, são gerados valores que representam a disponibilidade de cada infraestrutura elétrica como um todo.

- **Criar modelos de fluxo elétrico** - Esta etapa consiste na criação de um modelo de fluxo elétrico e segue as regras formais de definição do modelo, detalhadas na Seção 3.4. Para criação deste modelo, são utilizados os conhecimentos obtidos com a representação em alto nível da infraestrutura elétrica, como: equipamentos utilizados, redundâncias, rotas elétricas e demanda. Para que seja possível avaliar este modelo, faz-se necessário como entrada, o resultado da disponibilidade obtido por meio do modelo de disponibilidade da seção anterior, além da demanda da sala de computação. Essa disponibilidade é utilizada como requisito na geração de outras métricas, que computam valores para custos operacionais, custos de aquisição, consumo exergético e consumo energético, respeitando as restrições do sistema, quantificadas pelo EFM.

Os produtos da fase de **Criação de modelos de disponibilidade e fluxo elétrico** são os modelos de disponibilidade e os modelos de fluxo elétrico. Ambos representam a mesma infraestrutura elétrica do centro de dados, entretanto, com finalidades diferentes.

4.3 ESCOLHER ESTRATÉGIA

Esta decisão recebe como entrada um modelo de fluxo elétrico, que servirá de insumo para uma das próximas macro atividades, como: **Considerar Mix energético, otimizar a distribuição do fluxo e prever custos e impacto ambiental com RNA**. Escolhida alguma das opções, o fluxo segue seu caminho para fazer as devidas alterações no modelo EFM. Vejamos, em seguida, a descrição de cada opção.

4.4 CONSIDERAR MIX ENERGÉTICO

Esta atividade recebe um modelo de fluxo elétrico como entrada e altera as propriedades do *Source Point* (componente do modelo EFM em que é informada a demanda do ambiente). Esta alteração permite representar a variação de fontes energéticas proveniente da concessionária. Com esta alteração há a possibilidade de se obter avaliações mais precisas sobre as questões de sustentabilidade e custo, uma vez que nessa opção é possível definir a quantidade de cada fonte de energia utilizada pelo ambiente. Dessa forma, os custos energéticos e as emissões de CO_2 retratam melhor a realidade dos centros de dados. Essas alterações são apresentadas em detalhes na Seção 5.2.

4.5 OTIMIZAR A DISTRIBUIÇÃO DO FLUXO COM O PLDA-D

Esta fase recebe como entrada um modelo de fluxo elétrico e tem como função principal fazer uma redistribuição do fluxo, alterando os pesos das arestas do modelo, como descritos a seguir:

- **Verificar validade do modelo** - Esta primeira atividade consiste de duas verificações. Primeira, se no modelo EFM recebido como entrada, existe uma demanda positiva no *Target Point* (nó do modelo EFM onde a demanda por energia do ambiente é armazenada). Caso afirmativo, o modelo servirá como entrada para a distribuição do fluxo. Se não houver demanda válida (valor menor ou igual a zero), um erro será lançado no sistema e a macro atividade encerrada.

Segunda, verifica se há caminhos válidos no modelo entre os nós Source (representa a concessionária fornecedora de energia elétrica) e Target para distribuir a demanda. Essa verificação é feita lendo o grafo em profundidade e utilizando as capacidades e eficiências de cada componente. Duas saídas são possíveis para esta atividade. Se a soma de todos os caminhos válidos para distribuição do fluxo elétrico for inferior à demanda, a macro atividade é encerrada e uma mensagem de erro enviada ao sistema. Entretanto, caso haja caminho(s) e demanda, poderemos redistribuir o fluxo, descrito na próxima atividade.

- **Otimizar a distribuição do fluxo** - Esta atividade recebe como entrada um modelo EFM, com demanda válida e caminhos possíveis para a distribuição. A aplicação do algoritmo PLDA-D (Veja Seção 5.3) melhora a distribuição do fluxo elétrico entre os dispositivos da infraestrutura elétrica do centro de dados, alterando os pesos das arestas presentes nos modelos EFM. O principal objetivo deste algoritmo é fornecer automaticamente uma distribuição de energia que ajude os projetistas de centros de dados a definir arquiteturas de energia respeitando as restrições do sistema que são quantificadas pelo EFM. Essa fase fornece, como produto, um novo modelo de fluxo elétrico, com os pesos das arestas otimizados, visando um menor consumo de energia, de acordo com as eficiências de cada componente do modelo. A aplicação do PLDA-D sobre o modelo EFM é explicada em detalhes na seção 5.3.

O produto da macro atividade que otimiza a distribuição do fluxo elétrico com o PLDA-D é um modelo EFM com os pesos das arestas otimizados, quando possível.

4.6 PREVER CUSTOS E IMPACTO AMBIENTAL COM RNA

O insumo desta macro atividade é um modelo EFM e um histórico de consumo de energia do ambiente, que será usado junto a uma rede neural artificial para predição de custos e impactos ambientais. As principais ações desta fase estão descritas a seguir:

- **Validar insumos** - Nesta fase são recebidas e validadas duas entradas: um modelo EFM e uma planilha eletrônica. O modelo de fluxo elétrico deve respeitar as restrições de capacidade do modelo e possuir uma demanda válida. Já a planilha inserida na ferramenta Mercury, utilizada neste estudo, deve possuir o histórico de consumo, nos formatos odt, xls e csv. Essa planilha deve possuir três colunas, a primeira com o ano, a segunda com o mês e a terceira com o consumo de energia do centro de dados. Quanto maior o histórico de consumo, mais precisas serão as previsões, feitas nas próximas fases. A saída dessa atividade é um modelo EFM e uma planilha com as restrições verificadas. Caso a planilha não esteja no formato especificado ou o modelo EFM esteja fora das restrições aceitas, um erro será lançado no sistema e esta macro atividade encerrada.
- **Configurar e treinar RNA** - Esta atividade recebe como entrada um modelo EFM validado e é responsável por fazer a configuração da rede neural artificial. A RNA é dividida em três camadas: entrada, oculta e saída. A quantidade de neurônios da camada de entrada é fixa, cada uma representando um mês do ano, portanto, doze. A camada de saída também é fixa, possuindo apenas um neurônio. Já a quantidade de camadas e neurônios ocultos pode ser configurada pelo usuário, na ferramenta Mercury. Neste estudo, a configuração que resultou em um bom aprendizado foi aquela composta por uma camada oculta e 30 neurônios. O algoritmo *backpropagation* é utilizado para treinar a RNA, por ser amplamente conhecido e obter bons resultados para o tipo de distribuição utilizada nessa tese. A quantidade de iterações (por exemplo, 10000) ou erro percentual absoluto médio (por exemplo, 0,1) são os critérios de parada para o treinamento. Os produtos desta fase são: um modelo EFM e uma RNA treinada.

Os produtos da macro atividade **prever custos e impacto ambiental com RNA** são os resultados das previsões para os próximos doze meses do consumo de energia do modelo EFM.

4.7 ANALISAR OS RESULTADOS

Esta macro atividade pode receber três tipos de entrada: modelo EFM com alterações no Source Point, modelo EFM com otimização dos pesos das arestas ou um modelo EFM e uma RNA treinada. Vejamos, em detalhes, cada tipo de análise a variar de acordo com o input.

- **Modelo EFM com alterações no Source Point** - Esta análise considera a variação das fontes energéticas dos modelos EFM. São computados os custos financeiros e impactos ambientais de forma mais precisa. Por exemplo, é possível analisar de-

talhadamente um centro de dados que usa variação de fontes geradoras de energia, como: 40% de carvão, 35% de hidrelétrica e 20% eólica.

- **Modelo EFM com otimização dos pesos das arestas** - O processo de avaliação é conduzido no modelo para fornecer os resultados da estimativa dos custos operacionais, custos de aquisição, disponibilidade, tempo de inatividade, consumo exergético e consumo energético. O PLDA-D otimiza a distribuição do fluxo e consequentemente o consumo de energia do ambiente, impactando nas demais métricas. De acordo com os estudos feitos nesse trabalho, os valores das métricas, após execução do PLDA-D, são sempre melhores ou iguais aos valores antes da aplicação.
- **Modelo EFM e uma RNA treinada** - Esta análise é responsável por fazer as estimativas das métricas ao longo dos próximos 12 meses. Todas as métricas avaliadas no modelo de fluxo elétrico padrão são estimadas para cada um dos doze meses da predição. Dessa forma, é possível perceber a variação, inclusive sazonal, do consumo de energia no modelo avaliado. O produto desta fase resulta nas predições dos custos e na sustentabilidade do ambiente.

Ao fim das predições, uma validação é feita. Esta atividade usa duas planilhas, uma contendo o histórico do consumo de energia do ambiente (presente no modelo EFM) e outra com as predições da RNA (presente na RNA treinada). Para validar os resultados da RNA, é feita uma comparação aplicando o ARIMA aos mesmos dados. Como produto desta fase, uma nova planilha é gerada, com os resultados de ambas as predições: RNA com o perceptron e ARIMA (3,2,2) com 90% de confiabilidade.

4.8 APLICAR OUTRA ESTRATÉGIA?

Neste ponto da metodologia, há duas opções a serem seguidas. Primeira, o projetista pode escolher aplicar outra estratégia ou a mesma, alterando o modelo de fluxo elétrico e fazendo outra análise. Segunda, caso esteja satisfeito com os resultados obtidos, encerrar o processo.

4.9 CONSIDERAÇÕES SOBRE A METODOLOGIA

Esta metodologia oferece ao designer de infraestruturas elétricas de centros de dados a opção de adotar estratégias para uma análise mais precisa do ambiente. Ademais, oferece opções para melhoria do consumo de energia do centro de dados, reduzindo o custo financeiro e o impacto no meio ambiente. Caso o leitor siga os passos mencionados aqui, conseguirá reproduzir o mesmo cenário. As macro atividades foram detalhadas e cada uma apresenta as entradas e o que deve ser feito para se gerar os produtos esperados.

5 ANÁLISE DO CONSUMO ENERGÉTICO E MELHORIA DA EFICIÊNCIA DA INFRAESTRUTURA ELÉTRICA

5.1 CONTEXTUALIZAÇÃO

Não existe, atualmente, um algoritmo que distribua o fluxo elétrico na infraestrutura elétrica de um centro de dados, baseado nas eficiências de cada componente da rede. A distribuição deste fluxo fica a cargo do projetista do ambiente ou da configuração padrão da ferramenta utilizada. Portanto, havendo interação humana na escolha da distribuição desse fluxo, torna-se possível a existência de casos de falhas, ou se a configuração ficar sob responsabilidade das ferramentas atuais, seguirão suas próprias metodologias para distribuição. Tal imperfeição (humana ou via configuração padrão das ferramentas) pode levar a um maior consumo elétrico, acarretando maiores custos às empresas. Aliada a esta problemática, casos relacionados as emissões de CO_2 na atmosfera causam preocupações globais. Pesquisas apontam que ultrapassamos o valor de 404ppm, ou seja, em cada milhão de moléculas de ar no planeta há 404 do principal gás de efeito estufa (BETTS et al., 2016) (nos últimos 800 mil anos, essa concentração jamais ultrapassou 300 ppm). Visando propor soluções a este problema, foi concebida uma estratégia para analisar (variação energética, rede neural artificial) e melhorar (PLDA-D) a distribuição do fluxo elétrico em modelos EFM, expansível aos centros de dados, responsáveis por um alto consumo de energia no planeta.

A Figura 8, apresenta um modelo EFM simples. Este modelo considera que o fluxo será dividido igualmente entre os componentes da infraestrutura elétrica, informado através dos pesos das arestas. Os pesos 0.5 representam metade do fluxo do componente SDT1 para cada UPS. Logo, a distribuição do fluxo é feita de forma proporcional à quantidade de nós pais. Caso a Figura 8 apresentasse três componentes do tipo UPS (UPS1, UPS2




Figura 8 – Exemplo simples de um modelo EFM

e UPS3) conectados ao componente SDT1, o fluxo seria dividido em três partes iguais, sendo os pesos de 0.33 para cada aresta.

Em muitas situações, não se considera a eficiência energética dos equipamentos, o fluxo é dividido igualmente, entre os caminhos redundantes, incorrendo, possivelmente, em uma distribuição inadequada da energia. Nesta tese, consideramos a variação de fontes energéticas para análise mais precisa do ambiente, além de propormos um algoritmo para fazer uma distribuição otimizada do fluxo, baseado nas eficiências dos componentes, e, por fim, conseguimos estimar o consumo do ambiente para um futuro próximo. Esses conteúdos serão apresentados nas seções 5.2, 5.3 e 5.4, respectivamente.

5.2 ANÁLISE DO CONSUMO, CONSIDERANDO MÚLTIPLAS FONTES ENERGÉTICAS

Nesta seção, é proposta uma solução para a representação da variação de fontes energéticas para modelos EFM, que podem ser utilizados para uma análise mais precisa do impacto ambiental (computado por meio de estimativas de emissões de CO_2) causado pelo consumo de energia de um ambiente. Desta forma, caso o centro de dados possua mais de uma fonte geradora de energia, também poderá ser analisado.

Atualmente, existem diferentes fontes de energia utilizadas pelas usinas, tais como: solar, geotérmica, termoelétrica, biomassa, hidrogênio, combustível, maré, etanol ou melanina. Entretanto, neste trabalho, apenas as fontes mais utilizadas no planeta foram consideradas, como: eólica, carvão, hidroelétrica, nuclear e petróleo. A Figura (ABESCO, 2018) apresenta a composição energética global, considerando o maior grupo de cada país.




Figura 9 – Principal fonte de energia dos países (ABESCO, 2018)

Sendo assim, os grupos devem ser compreendidos da seguinte forma:

- Carvão - Todo carvão e lignito (combustíveis primários ou derivados);

- Petróleo - Energia gerada por óleo bruto ou produtos derivados;
- Gás - considera apenas o gás natural, como GNV;
- Nuclear - Energia gerada em usinas nucleares;
- Hidrelétricas - Energia gerada em usinas hidrelétricas
- Renováveis - Energia geotérmica, solar, marés, ventos, biomassa e biocombustíveis;

Além disso, esta tese também considera a quantidade de emissões de CO_2 de acordo com a fonte de energia usada. A inclusão do mix de energia nos modelos EFM é proposta para uma análise mais detalhada dos custos operacionais e uma estimativa mais real das emissões de CO_2 na atmosfera.

Ao considerar a variação das fontes energéticas no EFM, é possível representar mais detalhes das infraestruturas elétricas de um centro de dados do mundo real. Os projetistas podem considerar mais de uma fonte, que representa o mix de energia da concessionária. Além disso, essa função permite que os custos operacionais e os impactos ambientais do consumo de eletricidade sejam calculados, bem como as emissões de CO_2 do mix adotado.

A Tabela 6 apresenta a relação entre a matéria prima usada para produzir energia e a quantidade de CO_2 emitida por cada uma. Esses valores foram obtidos do trabalho de CALLOU (CALLOU et al., 2013a). A energia renovável escolhida foi a eólica, pois é a de maior representatividade no planeta e conhecemos a quantidade de dióxido de carbono emitido em grama por kWh.

Tabela 6 – Material usado na geração de energia x emissões de CO_2

Fonte Energética	CO_2 (g/kWh)
Vento	10
Carvão	950
Hidrelétrica	20
Nuclear	150
Petróleo	510

Para calcular a quantidade de emissões de CO_2 , a porcentagem de cada fonte energética é multiplicada por seu fator de impacto. Este processo é descrito pela seguinte equação:

$$Emissões de CO_2 = \sum_{i=1}^n (D_a \times P_i \times F_i) \quad (5.1)$$

onde: D_a representa a demanda de energia do ambiente, i é a fonte de energia utilizada (eólica, carvão, hidroelétrica, nuclear ou petróleo), P_i é a porcentagem da fonte de energia e F_i é o fator de agressão ao meio ambiente.

Neste documento, o custo operacional considera o período de operação do centro de dados, a energia consumida, o custo da energia e a disponibilidade do ambiente. A expressão 5.2 denota o custo operacional:

$$CustoOperacional = \left(\sum_{i=1}^n (P_{Input(i)} \times C_{Energy(i)}) \times T \times (A + \alpha(1 - A)) \right) \quad (5.2)$$

onde: i é a fonte de energia (eólica, carvão, hidroeletricidade, nuclear ou petróleo), $P_{Input(i)}$ é a porcentagem de fonte de energia para a fonte i , $C_{Energy(i)}$ é o custo financeiro por kwh, T é o período de tempo considerado, A é a disponibilidade do sistema e α é a porcentagem de energia que continua sendo consumida quando o sistema falha.

5.2.1 Exemplo de uso

A Figura 10 ilustra um modelo EFM com as possíveis variações de fonte energética, podendo ser: eólica, carvão, solar, gás, hidrelétrica, nuclear ou petróleo. Esse modelo EFM representa um centro de dados, com demanda de 100Kwh e possui duas fontes geradoras de energia, hidrelétrica e carvão, divididas em 60% e 40%, respectivamente. Considerando esse cenário, deseja-se saber qual o impacto ambiental e o custo operacional desse exemplo.




Figura 10 – Exemplo de utilização do Mix Energético

Utilizando a Equação 5.1 e a Tabela 6, é possível estimar a quantidade de CO_2 emitida, que pode ser expressa de acordo com a Equação 5.3.

$$\begin{aligned} EmissoesdeCO_2 &= 100kWh \times 0,6 \times 20 + 100kWh \times 0,4 \times 950 \\ EmissoesdeCO_2 &= 39.200(g/kWh) \end{aligned} \quad (5.3)$$

Portanto, esse centro de dados emite 39.200 (g/kWh) de CO_2 na atmosfera. Analogamente, utilizando a equação 5.2, conseguimos verificar o custo operacional desse centro. A disponibilidade pode ser obtida via SPN, RBD ou CTMC, para esse exemplo consideramos 95%. O tempo considerado foi de um ano e o custo da energia 0,18 e 0,23 centavos

por kW, para fonte hidrelétrica e queima de carvão, respectivamente, além do valor de 0.1 para a parcela de energia a continuar sendo consumida mesmo com a falha do sistema. Assim, o custo operacional com eletricidade pode ser expresso de acordo com a equação 5.4, chegando ao valor de 167.316,00 reais ao ano.

$$\begin{aligned} \text{CustoOperacional} &= (60kW \times 0,18 + 40kW \times 0,23) \times 8760h \times (0,95 + 0,1 \times (1 - 0,95)) \\ \text{CustoOperacional} &= (10,8 + 9,2) \times 8760 \times (0,95 + 0,005) \\ \text{CustoOperacional} &= 167.316,00 \end{aligned}$$

5.3 PLDA-D - ALGORITMO DE DISTRIBUIÇÃO DE CARGA ELÉTRICA EM PROFUNDIDADE

Esta seção apresenta o Algoritmo de Distribuição de Carga Elétrica em Profundidade (Power Load Distributed Algorithm in Depth Search – PLDA-D), bem como suas principais funcionalidades e sua aplicabilidade. O algoritmo é proposto para minimizar o consumo de energia elétrica de sistemas representados através dos modelos EFM (CALLOU et al., 2012a). O algoritmo de Bellman-Ford (BELLMAN, 1956) é usado para pesquisar o menor caminho em um dígrafo ponderado, isto é, cujas arestas têm peso, inclusive negativo. O algoritmo Ford-Fulkerson (FORD; FULKERSON, 1962) também é usado quando se deseja encontrar um fluxo máximo que faça o melhor uso possível das capacidades disponíveis na rede em questão. O PLDA-D é uma mistura dos conceitos destes algoritmos, já que utiliza as características do Bellman-Ford para escolher o menor custo, considerando os pesos de cada nó no grafo e a ideia do Ford-Fulkerson para passar a quantidade mais significativa de energia por um percurso específico, neste caso, considerando a eficiência energética de cada equipamento.

O algoritmo (Seção 5.3.2) inicia transcorrendo o grafo em busca da melhor rota entre dois pontos específicos. Se um determinado percurso não possuir capacidade para suportar todo o fluxo exigido, então será transmitida a capacidade máxima possível deste fluxo por esta trajetória e o fluxo residual será redirecionado para ser transferido em uma nova iteração, à procura de outra alternativa. Caso não exista outro caminho capaz de transportar o fluxo residual, mediante as restrições de capacidade dos componentes, não será possível a transmissão desse fluxo através do grafo.

A Figura 11 demonstra a configuração dos parâmetros do modelo EFM. O fluxo a ser distribuído (chamado energia elétrica demandada) é um elemento do modelo EFM. A demanda é inserida no vértice destino (TargetPoint1) e será um critério de parada do algoritmo. Enquanto houver uma demanda energética não alocada, uma rota será avaliada para transmiti-la. A escolha é feita entre os vértices pertencentes ao trajeto mais eficiente, sendo o vértice com a menor capacidade, presente nesse percurso, o limitador do fluxo a ser transmitido.




Figura 11 – Parâmetros do modelo EFM

Ao final de cada iteração, o valor a ser transmitido pelo acesso escolhido é subtraído da demanda. Cada vértice pertencente ao caminho terá o valor da variável responsável por armazenar o seu fluxo aumentado e sua capacidade de armazenar potência decrementada pelo valor transmitido. Todas as alterações são aplicadas a uma cópia do modelo EFM, não sendo realizada qualquer alteração no modelo original.

Foram adotados os seguintes valores para os vértices de origem e destino do grafo, representados na Figura 11 por SourcePoint1 e TargetPoint1: para a potência máxima suportada, o valor de infinito; para a eficiência, o valor de 100% e para o preço e a energia, os valores de 0 (por não serem utilizados neste momento). O campo de demanda é utilizado apenas nos vértices TargetPoint.

Para uma melhor compreensão da distribuição, é necessário que se entenda como o melhor caminho é escolhido dentro do modelo, ou seja, baseado nas eficiências de cada componente, por meio de uma mescla dos conceitos apresentados nos clássicos algoritmos de Bellman-Ford e Ford-Fulkerson.

5.3.1 Caminho Válido

Nesta subseção será ilustrada a função que determina a validade ou não de uma rota, entre os nós Source e Target. Na Figura 12, foram destacadas duas informações com relação a alguns vértices fundamentais para a compreensão da validade da trajetória: capacidade e eficiência dos componentes (ACSource), representadas pelas letras C e E, respectivamente. Essas letras simbolizam as variáveis manipuladas pelo algoritmo para determinação e distribuição do fluxo. O valor atual da variável que armazena a demanda do modelo também é ressaltado no vértice de destino (TargetPoint1). Nesse ponto é identificada a demanda a ser distribuída pelo modelo (TargetPoint1 de 1200kW), a capacidade e a eficiência dos vértices ACSource 1 (capacidade de 700kW e eficiência de 95%) e ACSource 2 (capacidade de 700kW e eficiência de 90%).




Figura 12 – Exemplo EFM - Caminho Válido

Na Figura 13 ressalta-se o melhor caminho válido, de acordo com os rendimentos dos componentes do modelo, analisando toda a rota em profundidade. Para fins didáticos e, considerando a primeira iteração do algoritmo, a cor verde foi atribuída às arestas que identificam a melhor trajetória, de acordo com o PLDA-D. O maior valor possível é distribuído (700kW, que é a menor capacidade de um dos componentes do caminho), acrescido esse valor às arestas (como fluxo corrente na aresta) e subtraindo-o das capacidades dos vértices. O valor distribuído é também subtraído da demanda. Como resultado desses eventos, as variáveis do modelo são alteradas. Veja a Figura 13.




Figura 13 – Melhor rota em profundidade - 1ª Iteração

Na segunda iteração do algoritmo, o percurso encontrado na primeira não é mais considerado válido, devido à restrição da capacidade de fluxo suportada pelo componente ACSource1, ou seja, o componente ACSource1 suporta uma capacidade de 0kW. Essa rota encontra-se, destacada em vermelho, na Figura 14. Assim, o melhor acesso válido, de acordo com as eficiências dos componentes, está destacado na cor verde.

As operações de incremento e decremento nas variáveis do modelo que lidam com o fluxo transcorrido ocorrem de forma semelhante à descrição da primeira iteração. Após a segunda iteração, a variável que armazena o valor da demanda do modelo atinge o valor




Figura 14 – Melhor caminho em profundidade - 2ª Iteração

zero (critério de parada da busca por novos percursos em profundidade), não havendo, dessa forma, mais fluxo a ser distribuído, embora o modelo ainda seja capaz de suportar a distribuição de 200kW pelo componente ACSource 2. A Figura 15 apresenta o resultado das variáveis destacadas no modelo após a execução da parte do algoritmo que escolhe a melhor direção válida, de acordo com uma verificação em profundidade. Neste ponto, a distribuição da demanda pelos melhores caminhos, de acordo com as produtividades dos componentes, chega ao final.




Figura 15 – Melhor caminho em profundidade - Estado final

Neste caso, para as propriedades de uma infraestrutura elétrica do centro de dados, a busca em profundidade implementada no PLDA-D oferece uma solução ótima. O PLDA-D é dividido em três fases:

- Fase I - Inicialização
- Fase II - Cálculos de Kernel

- Fase III - Busca em Profundidade

5.3.2 Fase I - Inicialização do PLDA-D

O Algoritmo 1 (método de inicialização) é um pseudocódigo que representa a leitura do modelo EFM, bem como a inicialização das variáveis, as chamadas ao kernel do PLDA-D e a atualização dos pesos das arestas do modelo. O número de chamadas ao kernel corresponde ao número de nós destinos (target nodes), presentes no modelo EFM G , configurado como parâmetro do algoritmo 1.

Algoritmo 1: *Initialization PLDAD (G)*

```

1:  $R = G$ ;
2: para  $v \in R$  faça
3:    $ccu_v = 0$ ;
4:    $ActualCost_v = \infty$ 
5:    $AccumCost_v = 0$ ;
6:    $Child_v = null$ 
7: fim do para
8: para  $e \in R$  faça
9:    $weight_e = 0$ ;
10: fim do para
11:  $inputPower = 0$ ;
12: para  $t \in V_{target}$  faça
13:    $R = PLDADKernel(R, f_{d(t)}, t, s)$ ;
14: fim do para
15:  $setUpdateWeight(R)$ ;
16: return  $R$ ;

```

O primeiro passo do algoritmo é fazer uma cópia do modelo EFM original G (linha 1). As futuras operações serão realizadas nessa cópia que é representada pela variável R . Posteriormente, um vetor chamado ccu_v (capacidade de potência acumulada), é empregado para associar a cada nó um valor que expressa o quanto de potência está passando por ele.

$ActualCost_v$ de cada nó é inicializado com o símbolo denotando uma quantidade infinita (linha 4) e a variável $Child$ é inicializada com valor nulo (Linha 6).

As linhas 12 a 14 chamam a função PLDA-D para cada vértice do nó de destino (se houver mais de um destino no EFM). O número de chamadas corresponde ao número de nós de destino em G . Se houver mais de um nó de destino, o fluxo de energia será distribuído considerando cada um.

Os pesos de borda do EFM são atualizados considerando o fluxo acumulado de cada componente (Linha 13).

Nas linhas 2 a 6 há uma inicialização da capacidade de potência acumulada de cada nó do modelo (ccu_v), Custo atual ($ActualCost_v$), Custo acumulado ($AccumCost_v$), Nó filho ($Child$ - esta variável é adotada para criar um relacionamento entre nós).

Um vetor, chamado *weight* associa a cada aresta um valor que expressa o fluxo nestas arestas, como demonstrado nas linhas 8 a 10, em que tais variáveis também recebem o valor zero. Na linha 11, a demanda é inicializada via variável *inputPower* com o valor zero.

Uma estrutura de repetição é inicializada na Linha 12, na qual cada nó de destino será um índice dessa iteração ($t \in V_{target}$), portanto, V_{target} representa o conjunto de nós do tipo *Target*, no modelo. A repetição se dá para cada nó (t) pertencente ao conjunto dos nós *Target* (V_{target}), ou seja, dentro dos nós do modelo há um conjunto que representa especificamente aqueles nós de destino (*Target*). Em seguida, o modelo R é alterado pela chamada do método *PLDADKernel*, que será explicado em detalhes na fase seguinte. Nessa chamada, é passado como parâmetro o modelo R, o fluxo demandado pelo nó *target* em questão e o próprio nó *target*.

O PLDA-D foi desenvolvido com a capacidade de avaliar modelos compostos por mais de um nó destino (*target node*), ou seja, no modelo EFM é possível adicionar mais de um destino no mesmo modelo. Por exemplo, imagine o caso onde há duas nuvens (clouds) associadas a uma mesma rede elétrica, onde cada uma das nuvens acaba por consumir valores diferentes de energia. Logo, seria possível a existência de dois nós de destino em um mesmo modelo. A linha 15 é responsável pela realização da atualização dos pesos das arestas do modelo R. Este método será detalhado na Fase III.

5.3.3 Fase II - Cálculos de Kernel

O método *PLDADKernel* (Algoritmo 2) é um pseudocódigo que simboliza o núcleo do algoritmo de distribuição de carga elétrica. Recebe como parâmetros o modelo EFM, representado pela letra R, o fluxo demandado pelo nó destino ($f_{d(t)}$), o próprio nó destino (t) e o nó de origem (*Source* - s).

O PLDA-D inicia com um teste condicional, em que verifica se o fluxo demandado é maior que zero e se existe um caminho válido no grafo R entre os nós destino e origem ($isPathValid(R, t, s)$), caso exista, a função retorna valor verdadeiro, caso contrário, falso. Um percurso válido é aquele no qual as capacidades elétricas de todos os componentes dessa direção sejam respeitadas. Um vetor chamado *ListOfElement* é inicializado (linha 2), onde serão armazenados os elementos que formam o melhor caminho entre dois pontos, detalhada no Algoritmo 3. A variável P é um vetor que armazena os elementos de uma rota válida (linha 3). Uma vez verificada a existência de um acesso, a variável *fp* (fluxo possível) é inicializada com um valor muito alto (linha 4), em seguida, uma estrutura de repetição é utilizada para percorrer todos os nós do caminho e verificar qual o fluxo possível. Uma função chamada *getMinimumCapacity* é responsável por esta resposta e

possui como parâmetros o fluxo possível (pf) e o resultado da subtração da capacidade do fluxo e sua potência acumulada ($capacity(i) - ccu(i)$), que reflete o fluxo ainda suportado pelo nó i .

Algoritmo 2: *PLDAD Kernel*($R, f_{d(t)}, t, s$)

```

1: enquanto ( $R.f_{d(t)} > 0$ ) & ( $isPathValid(R, t, s)$ ) faça
2:    $ListOfElement = null$ ;
3:    $P = getElementsFromBestPath(t)$ ;
4:    $pf = \infty$ ;
5:   para  $i \in P$  faça
6:      $pf = getMinimumCapacity(pf, R.fc_{(i)} - R.ccu_{(i)})$ ;
7:   fim do para
8:   para  $i \in P$  faça
9:      $R.ccu_i = R.ccu_i + pf$ ;
10:    se ( $R.fc_{(i)} - R.ccu_{(i)} = 0$ ) então
11:       $i.reachedLimit()$ 
12:    fim do se
13:  fim do para
14:   $R.f_{d(v)} = R.f_{d(t)} - pf$ ;
15: fim do enquanto
16: retorne  $R$ 

```

O próximo passo do algoritmo será uma nova iteração utilizando o vetor P (linhas 8 a 13), que representa um percurso válido. Neste ponto é realizada uma atualização da potência acumulada em cada nó, somando-se o valor do fluxo possível à potência já acumulada pelo nó. Em seguida, o valor da aresta em que o fluxo está transitando é atualizado, incrementando-se o valor do fluxo possível à aresta, ou seja, o valor que se encontra transitando, no momento, por este nó, é adicionado à aresta correspondente. Na linha 10, a variável $R.fc_{(i)}$, utilizada para identificar a demanda elétrica da arquitetura avaliada é decrementada pela variável da potência acumulada. Caso esse valor atinja zero, significa que não há mais fluxo a se transmitir, a função *reachedLimit()* é chamada, marcando aquele nó como limite atingido. Na próxima consulta por direções válidas, aqueles nós que possuem o limite atingido serão desconsiderados. A energia exigida do nó de destino ($R.f_{d(t)}$) é atualizada (Linha 14), subtraindo os valores do fluxo transmitido anteriormente. As etapas anteriores são repetidas até que todos os percursos válidos tenham sido analisados ou não haja demanda. Finalmente, o grafo residual R é retornado (Linha 16) e somente os pesos das arestas são alterados a partir do grafo original G .

5.3.4 Fase III - Busca em Profundidade

Nesta seção é apresentada uma proposta para calcular fluxo máximo e mínimo, com base nos algoritmos de Bellman (BELLMAN, 1956), Ford e Fulkerson (FORD; FULKERSON, 1962). Todos os caminhos são percorridos da origem até o destino. Um custo é atribuído

a cada nó (componente), baseado nas eficiências de cada equipamento e quanto menor o valor, melhor a rota. Uma vez calculado o custo associado a cada percurso, é possível direcionar o fluxo para os melhores trajetos em relação ao consumo de energia elétrica.

O Algoritmo 3 é responsável por identificar o melhor caminho através do nó *Target* para o *Source*. Na primeira execução, o valor passado como nó atual, *Current Vertice*(CV_i), é o nó *Target*. O vetor chamado *ListOfParents* armazena a lista de nós com um nível de precedência do nó atual, ou seja, a lista de pais do CV_i (Linha 1).

Algoritmo 3: *Search getElementsFromBestPath(CV_i)*

```

1: ListOfParents = getListofParents( $CV_i$ )
2: para  $i \in \text{ListOfParents.size}$  faça
3:    $CP = \text{ListOfParents}[i]$ 
4:   se  $CP.LimitNotReached()$  então
5:      $newCost = 1 / (CV_i.AccumCost * (CP.efficiency/100))$ 
6:     se ( $CV_i = Target$ ) então
7:        $CP.ActualCost(newCost)$ 
8:        $CP.Child(CV_i)$ 
9:        $CP.AccumCost(CP.efficiency/100)$ 
10:    senão
11:      se  $CP.ActualCost > CV_i.ActualCost + newCost$  then
12:         $CP.ActualCost(CV_i.ActualCost + newCost)$ 
13:         $CP.Child(CV_i)$ 
14:         $CP.AccumCost(CP.efficiency/100) * CV_i.AccumCost$ 
15:      fim do se
16:      getElementsFromBestPath( $CP$ )
17:    fim do se
18:  fim do para
19: ListOfElement.addBestChild(Source)
20: retorne (ListOfElement)

```

A linha 2 inicia uma estrutura de repetição para cada nó da lista de pais. A primeira etapa do laço escolhe um item de equipamento de uma lista de pais para iniciar o procedimento (Linha 3). A ordem de escolha não influencia o resultado final do algoritmo. O limite de capacidade é verificado na Linha 4. Se o nó atingiu esse limite, o algoritmo continua procurando outros acessos disponíveis.

A linha 5 calcula o custo de cada nó do componente, no qual o menor valor representa a melhor opção de caminho. A linha 6 verifica se o vértice sob análise (CV_i) é o *Target*, ou seja, um nó de destino do modelo. Nesse caso, os atributos do *Current Parent* (CP) serão atualizados (Linhas 7 a 9). O custo acumulado representa o custo do nó multiplicado pelo custo do trajeto que o precede. Este passo encontra a melhor rota.

Assumindo que o CV_i não é o *Target*, é feito um teste condicional na linha 11, que só é satisfeito quando há pelo menos um percurso com um custo menor a ser atingido.

Nesse caso, o custo CP é atualizado para a soma do custo do CV_i com o $newCost$. O CV_i será o melhor caminho (menor custo) para o CP e o custo acumulado é atualizado considerando este novo caminho (Linhas 12 a 14).

Na linha 16, foi utilizada a recursividade, assim, todo o processo se reinicia, passando o CP como nó atual e o fluxo regressa para a linha 1.

Na Linha 19, uma lista de elementos é preenchida com os filhos do nó *Source*, que corresponde a melhor rota do nó *Target* para o nó *Source*, de acordo com a expressão da Linha 5. Finalmente, uma lista com os elementos do melhor percurso é retornada (Linha 20).

5.3.5 Execução do PLDA-D

A Figura 16 ilustra a execução passo-a-passo do PLDA-D. Desta forma, exibe um modelo EFM composto por três componentes elétricos *A*, *B*, e *C* com uma eficiência de 80, 90 e 95%, respectivamente. *S* é o nó *Source*, representando um equipamento elétrico do modelo EFM e *T* é o nó *Target*, representando a demanda energética de uma sala de computadores.




Figura 16 – Exemplo de execução de PLDA-D, os retângulos azuis destacam os nós em análise

Os valores de demanda (*Dem*) e eficiência (*Ef*) são especificados pelo designer da

infraestrutura elétrica do centro de dados. O valor *AccumCost* do *Target* é definido como um, para inicialização da variável. Os outros custos acumulados (*AccumCost*) são definidos como zero e os pesos das arestas são definidos para o valor padrão, respectivamente, conforme ilustrado na Figura 16-a. A fase um do PLDA-D é representada pela Figura 16-b onde todas as variáveis de todos os vértices são inicializadas.

A segunda fase inicia na Figura 16-c seguindo até Figure 16-h. A melhor trajetória é selecionada de acordo com a eficiência de cada componente. Na Figura 16-c, os valores de custo atual (*ActCost*) e custo acumulado (*Acc*) são calculados e o melhor filho é escolhido de acordo com o valor mais baixo da variável *ActCost*. Esse valor é usado para selecionar o melhor filho para um determinado nó.

Em seguida, um dos pais do nó C é escolhido, a ordem de escolha não influencia o resultado final do melhor caminho. O nó A é selecionado e os valores de *Acc* e *ActCost* foram computados, sendo o melhor filho o nó C, expresso na Figura 16-d.

Os valores de *ActCost* e *Acc* foram calculados de acordo com as Equações (5.4) e (5.5), como apresentado no Algoritmo 3.

$$ActCost = ActCost + \frac{1}{ActCost \times \frac{eficiencia}{100}} \quad (5.4)$$

$$Acc = Acc \times \frac{eficiencia}{100} \quad (5.5)$$

A Figura 16-e apresenta a etapa do algoritmo na qual o *AccumCost*(*Acc*) e *ActCost* de todas as variáveis foram computadas e o melhor filho selecionado. O *Source* é um nó terminal e não tem pai, portanto, o algoritmo retorna para o nó C, que possui dois pais. O nó C não foi completamente pesquisado, porque existe um nó pai não visitado B. A Figura 16-f exibe o passo do algoritmo em que as variáveis para o nó B foram calculadas (pai do nó C, ainda não visitado).

A Figura 16-g descreve a etapa após o cálculo das variáveis *AccumCost*(*Acc*) e *ActCost*. Verifica-se que o custo (*ActCost*) para o caminho atual (3.39) era menor que o *ActCost* da rota anterior (3.68) para alcançar o nó *Source*. Dessa forma, o nó *Source* altera os valores de suas variáveis, pois este caminho é melhor (menor custo) que o anterior, o melhor filho do nó C mostrou ser o nó B e não o nó A. Em outras palavras, o percurso que passa pelo nó B representa uma escolha melhor que o que passa pelo nó A.

Figura 16-h representa o final da fase três, que retorna a melhor rota para a fase dois (PLDAD *Kernel* - Seção 5.3.3). O melhor caminho do destino para o nó de origem é: *Target*, C, B, *Source*. A Figura 16-i apresenta um exemplo de distribuição do fluxo pelo algoritmo proposto.

5.4 APLICANDO REDES NEURAIS ARTIFICIAIS PARA PREVISÃO DE CONSUMO DE ENERGIA

Esta seção apresenta a integração de uma rede neural artificial (perceptron de múltiplas camadas) ao modelo de fluxo elétrico, bem como suas principais aplicações.

A Figura 17 mostra o modelo de um neurônio, que forma a base para projetar uma grande família de redes neurais. Este modelo foi utilizado neste tese e integrado ao modelo de fluxo elétrico por apresentar bons resultados para este tipo de distribuição.




Figura 17 – Modelo não linear de um neurônio k. Adaptado de (HAYKIN et al., 2009)

Onde $x_1, x_2, \dots, x_m$ são os sinais de entrada, representando os doze meses do ano; $w_{k1}, w_{k2}, \dots, w_{km}$ são os pesos sinápticos do neurônio k; v_k é o resultado da função soma; b_k é o bias, que tem o efeito de aumentar ou diminuir a polarização na função de ativação; $\varphi(\cdot)$ é a função de ativação do neurônio e Y é a saída do neurônio k.

Na Figura 17 são identificados três elementos básicos do modelo neural:

- **Um conjunto de sinapses**, cada uma caracterizada por um peso. Especificamente, um sinal X_j na entrada da sinapse j conectada ao neurônio k é multiplicado pelo peso sináptico w_{kj} . É importante notar a maneira como são escritos os índices do peso sináptico w_{kj} . O primeiro índice se refere ao neurônio em questão e o segundo se refere ao terminal de entrada da sinapse à qual o peso se refere.
- **Um somador** para somar os sinais de entrada, ponderados pelas respectivas sinapses do neurônio.
- **Uma função de ativação** para restringir a amplitude de saída de um neurônio. Tipicamente, o intervalo normalizado da amplitude da saída de um neurônio é escrito como o intervalo unitário fechado $[0,1]$ ou alternativamente $[-1,1]$.

O bias, representado por b_k , tem o efeito de aumentar ou diminuir o valor da entrada da função de ativação, dependendo se ele é positivo ou negativo, respectivamente. Em termos matemáticos, podemos descrever um neurônio k escrevendo o seguinte par de equações:

$$\mu_k = \sum_{j=1}^m \omega_{kj} \chi_j, \quad (5.6)$$

$$\gamma_k = \varphi(\mu_k + b_k), \quad (5.7)$$

onde, $x_1, x_2, \dots, x_m$ são os sinais de entrada (Figura 17); $W_{k1}, W_{k2}, \dots, W_{km}$ são os pesos sinápticos do neurônio k ; μ_k (não exibido na Figura 17) é a saída do combinador linear devido os sinais de entrada; b_k é o bias, que tem o efeito de aumentar ou diminuir a polarização na função de ativação; $\varphi(\cdot)$ é a função de ativação do neurônio e Y_k é o sinal de saída do neurônio. O uso do bias b_k tem a função de aplicar uma transformação afim à saída μ_k do combinador linear, como mostrado em:

$$\nu_k = (\mu_k + b_k), \quad (5.8)$$

A função de ativação, representada por $\varphi(v)$, define a saída de um neurônio em termos do campo local induzido v . Existem três tipos básicos de funções de ativação: função de limiar, função linear por partes e **função sigmóide** (HAYKIN et al., 2009). Nesta tese, foi utilizada uma função sigmoidal, por ser a mais comum na construção de redes neurais artificiais. Ela é definida como uma função estritamente crescente, que exibe um balanceamento adequado entre comportamento linear e não-linear. A função sigmoidal implementada no Mercury foi a logística, capaz de recortar grandes magnitudes, a fim de manter a resposta da rede neural delimitada, definida na equação 5.9.

$$\varphi(v) = \frac{1}{1 + \exp(-\alpha v)} \quad (5.9)$$

onde α é o parâmetro de inclinação da função sigmóide. A Figura 18 representa a função sigmoidal com variação do α .

Com a integração de uma RNA ao EFM é possível ampliar os horizontes da estratégia de modelagem adotada em trabalhos anteriores (FERREIRA; CALLOU; MACIEL, 2013), (CALLOU et al., 2013a), (FERREIRA et al., 2013). Essa estratégia permite computar o consumo energético, exegético, os custos operacionais, a potência de entrada e o PUE, além de prever os valores dessas métricas para os próximos meses, com base em uma série histórica.

Vários métodos de previsão foram desenvolvidos nas últimas décadas. O perceptron foi escolhido por ser de simples implementação e resolver adequadamente problemas dessa classe. Os resultados da RNA foram comparados com o ARIMA, calculando-se as previsões obtidas por meio do erro percentual médio absoluto (EPMA).




Figura 18 – Função sigmóide para parâmetro de inclinação α variável (HAYKIN et al., 2009)

O EMPA é comumente usado como uma função de perda para problemas de regressão e na avaliação de modelo, devido à sua interpretação muito intuitiva em termos de erro relativo. De acordo com Heizer (HEIZER; RENDER, 2008), tanto os valores do desvio médio absoluto como do erro quadrático médio dependem da importância do item previsto, o que pode causar problemas ao nível da dimensão dos resultados. Se a previsão do item é medida em milhares, os valores do desvio médio absoluto e do erro quadrático médio podem ser muito grandes. A utilização do erro médio percentual absoluto é uma medida eficaz para resolver esse problema. O EMPA é a média da diferença absoluta entre os valores previstos e atuais. Assim, se existem previsões e valores reais para η períodos, podemos utilizar o erro médio percentual absoluto, que é descrito na equação 5.10:

$$EPMA = \frac{100\%}{\eta} \sum_{t=1}^{\eta} \left| \frac{A_t - F_t}{A_t} \right| \quad (5.10)$$

onde A_t é o valor real e F_t é o valor da previsão. A diferença entre A_t e F_t é dividida pelo valor real A_t novamente. O valor absoluto neste cálculo é somado para cada ponto previsto no tempo e dividido pelo número de pontos ajustados η . Multiplicar por 100% faz com que seja um erro percentual.

O número de neurônios, camadas, grau de conectividade e a presença ou não de conexões de retro propagação definem a topologia de uma rede neural artificial (CARVALHO et al., 2011). Esta etapa é muito importante, uma vez que define diretamente o poder de processamento da rede. Atualmente, não é possível determinar o número exato de neurônios e a quantidade de camadas para problemas gerais. É imprescindível bastante cuidado para que a rede não sofra *overfitting* ou *underfitting*, a depender do excesso ou falta de camadas/neurônios (HAYKIN, 2007).

Overfitting ocorre quando um modelo estatístico ou algoritmo de aprendizado de máquina captura o ruído dos dados. O *overfitting* é muitas vezes o resultado de um modelo

excessivamente complicado, e pode ser evitado através da adaptação de vários modelos e usando validação ou validação cruzada para comparar as suas precisões de previsão nos dados de teste. O *underfitting* ocorre quando um modelo estatístico ou algoritmo de aprendizado de máquina não consegue capturar a tendência subjacente dos dados. O *underfitting* é frequentemente resultado de um modelo excessivamente simples. Portanto, o *overfitting* e o *underfitting* levam a previsões ruins sobre novos conjuntos de dados. Dessa forma, o número de neurônios e camadas deve ser amplamente testado, com diversas configurações de redes neurais, contendo as mesmas tabelas de treinamento.

Uma descrição do uso desta rede neural artificial com o perceptron de múltiplas camadas é apresentado no Apêndice A.

5.5 CONSIDERAÇÕES FINAIS

Este capítulo apresenta o cerne desta tese. Onde, a partir de um modelo de fluxo elétrico, elaborado pelo projetista, é explicado em detalhes como é feito o uso da variação de fontes energéticas, bem como uma exaustiva explicação do algoritmo de distribuição de carga elétrica e, por fim, como a rede neural artificial foi considerada. Todas essas funcionalidades estão integradas ao modelo de fluxo elétrico.

6 MODELOS

Este capítulo apresenta os modelos para avaliação de disponibilidade, custo e consumo de energia (por meio de modelos de fluxo elétrico) utilizados nos estudos de caso. Estes modelos foram criados para representar a infraestrutura elétrica dos centros de dados. Os resultados oferecem suporte à tomada de decisão quanto à escolha da melhor configuração de equipamentos elétricos a serem utilizados para cada nível de centro de dados, podendo ser: Tier I, II, III ou IV. De acordo com a classificação mantida pelo Instituto *Uptime* (TIME, 2015), propomos e analisamos quatro modelos formais para disponibilidade e modelagem de fluxo elétrico.

Os métodos baseados em estados podem representar as dependências entre os componentes de cada modelo, permitindo assim, a representação de mecanismos complexos redundantes. No entanto, sofrem com o problema de explosão do espaço de estado. Portanto, foi utilizada a modelagem hierárquica e heterogênea (baseadas em estados e modelos combinatórios) para representar grandes sistemas com mecanismos complexos de redundância (MACIEL et al., 2011a). Modelos SPN, CTMC, RBD e EFM foram utilizados para avaliar os quatro níveis. A disponibilidade para cada um dos Tiers foi obtida por meio de modelagem hierárquica entre os modelos RBD, CTMC e/ou SPN. As demais métricas foram obtidas pelo EFM. Nas próximas subseções serão apresentados os modelos propostos e a estratégia empregada para representação da redundância entre os componentes, utilizada nos estudos de caso 1 e 2.

6.1 MODELAGEM DO TIER I

Este centro de dados não oferece infraestruturas redundantes de energia e refrigeração. Sua infraestrutura inclui uma área dedicada ao subsistema de TI: um subsistema de energia com uma fonte de alimentação ininterrupta (UPS) para lidar com picos de energia e curtos períodos de inatividade, e um gerador para proteger as interrupções do subsistema de TI. A Figura 19 mostra um exemplo da infraestrutura do sistema de energia para o centro de dados Tier I.

Como esta arquitetura não possui mecanismos de redundância, o Diagrama de Bloco de Confiabilidade (RBD) é utilizado para modelar a infraestrutura elétrica do Tier I. A Figura 20 apresenta a modelagem em RBD da infraestrutura elétrica.

A equação de disponibilidade extraída do modelo apresentado na Figura 20 é demos-




Figura 19 – Exemplo do subsistema elétrico do centro de dados classificado como Tier I




Figura 20 – Modelo RBD de infraestrutura de energia do Tier Nível I

trada na Equação 6.1.

$$Av_{(Inf.Elet.TierI)} = (1 - (1 - Up1) \times (1 - GeneratorSystem)) \times (ATS1) \times (UPS) \times (ATS2) \times (SDT) \times (ATS3) \times (SubPanel) \times (JuctionBox) \times (PowerStrip1) \times (PowerStrip2) \quad (6.1)$$

Uma vez computada a disponibilidade, o modelo de fluxo elétrico apresentado na Figura 21 é adotado para avaliação das métricas de custo operacional, exergia e energia. Com o modelo definido, as métricas geradas a partir do EFM estão diretamente relacionadas à demanda de energia do ambiente avaliado.




Figura 21 – Modelo EFM do Tier I

Para representar os próximos modelos, será necessário utilizar outra forma de modelagem, uma vez que existe dependência entre alguns componentes.

6.2 REDUNDÂNCIA

A redundância é a duplicação de componentes ou funções críticas de um sistema, com a intenção de aumentar sua disponibilidade, ou seja, fornece uma alternativa de funcionamento para uma estrutura, por meio de backup em caso de falha de um componente principal. Existem vários tipos de redundâncias (N , $N + 1$, $2N$, $2[N + 1]$) que normalmente se referem ao número de componentes de energia e refrigeração que compõem os sistemas de infraestrutura do centro de dados (MARIN, 2011). Vejamos a descrição de cada tipo de redundância:

- **N :** Atende aos requisitos de carga básica sem redundância. A falha de qualquer componente causará uma interrupção.
- **$N + 1$:** Uma unidade adicional, módulo e caminho a mais que o requisito base. A falha em uma única unidade não interromperá as operações.
- **$2N$:** Duas unidades completas, módulos e percursos para cada local de demanda. A falha de um sistema inteiro não interromperá as operações nem afetará o desempenho das cargas de dois ambientes.
- **$2(N + 1)$:** Duas unidades, módulos e rotas completas ($N + 1$). A falha de um sistema inteiro ainda deixa este sistema com redundância ($N + 1$) para linhas com dois ambientes.

A redundância $N + 1$ é utilizada nos sistemas de energia e geradores, para os centros de dados dos níveis II, III e até IV. Essa redundância é uma forma de garantir a disponibilidade do sistema no caso de falha do componente. Componentes (N) possuem pelo menos um componente de backup independente ($+1$). Nessa redundância somente um caminho está ativo a qualquer momento, a robustez é fornecida pela disponibilidade de um percurso adicional, se a rota ativa ficar indisponível. Geradores de energia dos centros de dados são ativados quando a fonte de energia normal está indisponível.

A redundância $2 + 1$ ou redundância $3 + 1$ são comuns em sistemas de energia para servidores, em que um número relativamente pequeno de UPSs de alta capacidade alimenta eficientemente um número maior de máquinas. Um exemplo é um servidor que possui três fontes de alimentação. O sistema pode ser configurado para redundância $2 + 1$, de modo que as máquinas possam aproveitar a potência de duas UPSs e ter uma extra disponível, para fornecer redundância, caso uma delas falhe.

O sistema de gerador, nesta tese, foi representado pela redundância $N + 1$. O modelo RBD é utilizado para obter as métricas de disponibilidade da infraestrutura elétrica dos

data centers Tiers II, III e IV. Entretanto, devido à complexidade do sistema com redundância ($N + 1$), responsável pela representação da energia da rede elétrica e do subsistema gerador, foi necessário utilizar uma SPN para modelagem ao invés de um RBD, a Figura 22 mostra o modelo SPN correspondente a esse sistema. Este modelo representa o modo operacional do sistema de energia e gerador, no qual o sistema está operacional se o utilitário de fornecimento de energia estiver funcionando ($\#C_Up = 1$), os dois principais geradores estiverem operando ($\#G12_Up = 2$) ou se um gerador principal e um backup estiverem sendo executados ($(\#G12_Up = 1) \text{ e } (\#Gb_Up = 1)$).

Neste modelo de SPN, a transição que ativa os geradores 1 e 2 (G12 Act) é acionada somente quando o utilitário da fonte de alimentação falha. Da mesma forma, a transição *Gb Act* é capaz de disparar, uma vez que o utilitário de fornecimento de energia e pelo menos um gerador principal falhar.




Figura 22 – Modelo SPN para energia elétrica e sistema de gerador (UP + GS)

A função lógica da disponibilidade obtida pelo modelo SPN é:

$$A = (C_{Up} = 1)OR(G12_{Up} = 2)OR((G12_{Up} = 1)AND(Gb_{Up} = 1)) \quad (6.2)$$

O sistema de UPS é modelado com redundância ($N + 1$), assumindo uma estratégia de “cold standby”. Os componentes do sistema UPS são baseados em um módulo

redundante não ativo que espera ser ativado quando o módulo principal falhar. O modo operacional deste sistema considera que pelo menos dois no-breaks devem estar ativos. Para comprovar a integração da estratégia proposta com outros modelos formais, esta redundância será representada utilizando uma Cadeia de Markov. A Figura 23 mostra o modelo adotado para avaliar a disponibilidade do sistema UPS com redundância ($N + 1$) em “cold standby”.




Figura 23 – Modelo em CTMC do sistema de UPS em cold standby (UPS System)

Na Figura 23, o estado **2** representa o funcionamento de duas UPSs em estado normal de funcionamento e o backup em espera. O estado **1** mostra a detecção de uma falha em um no-break. O estado **2*** representa dois no-breaks em operação (um no-break padrão e um backup). O estado **1*** representa uma falha no UPS padrão ou de backup. O estado **0** representa a falha de todos os no-breaks. Por fim, o estado **0*** mostra a falha de dois no-breaks padrão e o funcionamento do backup.

A taxa de falha é representada por λ , μ é a taxa de reparo, σ é o tempo médio para ativar a UPS de backup.

A equação de forma fechada da disponibilidade obtida pelo modelo CTMC é:

$$A = \frac{(\mu\sigma(4\lambda^3 + 4\lambda^2(\mu + \sigma) + \mu^2(\mu + \sigma) + \lambda\mu(3\mu + 2\sigma)))}{(2\lambda^2\mu^3 + (\lambda + \mu)(2\lambda + \mu)(2\lambda^2 + \mu^2)\sigma + (4\lambda^3 + 4\lambda^2\mu + 2\lambda\mu^2 + \mu^3)\sigma^2)} \quad (6.3)$$

6.3 MODELAGEM DO TIER II

Um centro de dados Tier II incorpora componentes críticos de energia e refrigeração redundantes, mas com uma única infraestrutura de distribuição de energia. Essa infraestrutura suporta atividades de manutenção planejadas sem interromper o serviço, reduzindo, como resultado, o tempo de inatividade do sistema. A Figura 24 exhibe um exemplo em alto nível, da infraestrutura do subsistema de energia assumindo a classificação de Nível II.

Com base no modelo genérico do Tier II, são propostos modelos de SPN, bem como do RBD e CTMC (Apresentados na seção 6.2) para obter a disponibilidade desse centro




Figura 24 – Exemplo do subsistema elétrico do centro de dados classificado como Tier II

de dados. Foram utilizados modelos hierárquicos de dois níveis, nos quais o RBD é usado para representar o sistema geral, e uma rede de Petri e uma cadeia de Markov foram usadas para capturar o comportamento do subsistema, como energia e no-break (O uso desta representação se deve ao fato de demonstrar a capacidade de integração na solução proposta). A Figura 25 mostra o modelo RBD adotado para representar a infraestrutura de energia.




Figura 25 – Modelo RBD da infraestrutura elétrica do Tier II

Os valores do UP1+GS (UtilityPower1 + Generator_System) e do UPS_System usados nos modelos RBD dos Tiers II, III e IV são calculados através dos modelos SPN e CTMC nas Figuras 22 e 23, respectivamente. As disponibilidades dos modelos SPN e CTMC são calculadas e inseridas em cada bloco dos modelos RBD (por exemplo, UP1 + GS).

A equação de disponibilidade extraída do modelo da Figura 25 é apresentada na

Equação 6.4.

$$\begin{aligned}
 Av_{(Inf.Elet.TierII)} = & (UP1 + GS) \times (ATS1) \times (1 - (1 - (UPSSystem) \times (ATS2) \times \\
 & (SDT1) \times (SubPanel1) \times (JunctionBox)) \times (1 - (STD2) \times (SubPanel2) \times \\
 & (JunctionBox2))) \prod_{i=1}^4 PowerStrip_{(i)}
 \end{aligned}
 \tag{6.4}$$

A Figura 26 apresenta o modelo EFM da infraestrutura elétrica do centro de dados Tier II. Há diferenças entre a representação de modelos de confiabilidade e dos modelos de fluxo elétrico, embora ambos retratem o mesmo sistema.




Figura 26 – Modelo EFM do Tier II.

A disposição em série significa que a falha de um componente afeta a operação do centro de dados como um todo. Já a disposição em paralelo significa que o fluxo elétrico é distribuído entre seus pares, respeitando os pesos de cada aresta e que a falha em um componente, não necessariamente, afeta a operação do centro de dados.

6.4 MODELAGEM DO TIER III

Um centro de dados classificado como Tier III não requer desligamentos para substituição ou manutenção de equipamentos. A configuração do Nível III considera o arranjo do Nível II, incluindo um caminho de energia redundante independente (conforme apresentado na Figura 27). Portanto, cada componente de energia pode ser desligado para manutenção sem afetar a operação do sistema de TI. Da mesma forma, um subsistema de resfriamento redundante também é fornecido. Esses centros de dados são suscetíveis a tempo de inatividade para atividades planejadas e causas acidentais. As atividades de manutenção planejada podem ser executadas usando os componentes e recursos redundantes

da distribuição de referência, de modo a garantir a operação segura dos componentes restantes.





Figura 27 – Exemplo do subsistema elétrico do centro de dados classificado como Tier III

Pela dependência e complexidade, a representação hierárquica foi adotada para simbolizar o centro de dados Tier III, considerando o sistema de UPS e o sistema de geração de energia. O modelo Tier III é dividido em seis subsistemas, dois deles representam os sistemas de energia e UPS apresentados anteriormente (Figuras 22 e 23). Um dos caminhos do fluxo elétrico utiliza o sistema UPS com componentes redundantes (Subsistema X - Figura 28-a), o outro caminho não possui componentes redundantes (Subsistema Y - Figura 28-b). Ambos fornecem caminhos possíveis para o conjunto de componentes do fluxo elétrico (Subsistema P - Figura 28-c).



a. Subsistema X



b. Subsistema Y



c. Subsistema P

Figura 28 – Modelagem RBD dos Subsistemas X, Y e P, referente ao Tier III

A Figura 29 apresenta a modelagem completa proposta para esses subsistemas, considerando a hierarquia.




Figura 29 – Modelo RBD Completo do Tier III

As disponibilidades de cada subsistema são apresentadas nas Equações 6.5, 6.6 e 6.7.

$$SubsystemX = ATS1 \times UPSSystem \times ATS2 \times SDT1 \times SubPanel1 \times JunctionBox1 \quad (6.5)$$

$$SubsystemY = SDT1 \times SubPanel2 \times JunctionBox2 \quad (6.6)$$

$$SubsystemP = \prod_{i=1}^6 (PowerStrip_{(i)}) \quad (6.7)$$

A Equação (6.8) apresenta a forma fechada para a disponibilidade do modelo RBD completo, referente ao Tier III.

$$\begin{aligned} Av_{Inf.Elet.TierIII} = & (1 - (1 - (UPS_GS) \times (ATS1 \times UPSSystem \times ATS2 \times SDT1 \times \\ & SubPanel1 \times JunctionBox1))) \times (1 - (UP2) \times (SDT1 \times SubPanel2 \times JunctionBox2))) \\ & \times (\prod_{i=1}^6 (PowerStrip_{(i)})) \end{aligned} \quad (6.8)$$

Uma vez que a disponibilidade é calculada, o modelo EFM pode ser analisado para computar o custo energético e operacional do modelo, bem como para garantir que as restrições de energia de cada dispositivo sejam respeitadas. A Figura 30 representa o modelo EFM de nível III.




Figura 30 – Modelo EFM do Tier III.

6.5 MODELAGEM DO TIER IV

O centro de dados classificado como Tier IV adota a infraestrutura Nível III, no qual sistemas independentes (elétricos e de refrigeração) estão presentes. Este centro de dados é adequado para empresas, que prestam serviços ao cliente 24 horas por dia, 7 dias por semana. Empresas que usam o Tier IV, geralmente baseadas em e-commerce, transações de mercado ou são grandes empresas globais com vários fusos horários em que o acesso de clientes a aplicativos e ao uso de recursos de tecnologia da informação pelos funcionários se mostram uma vantagem competitiva. Em 2014, havia apenas 12 centros de dados em todo o mundo com certificação Tier IV, localizados no Brasil, Arábia Saudita, Luxemburgo, Espanha, EUA, Canadá e África do Sul (TIME, 2015). Atualmente, já existem 47 espalhados pelo mundo. A Figura 31 apresenta uma representação em alto nível do subsistema elétrico de um centro de dados classificado como Tier IV.

Esta configuração apresentada é o nível mais alto de garantia que um centro de dados pode oferecer, uma vez que é totalmente redundante em termos de circuitos elétricos.

O modelo em RBD utilizado para representar o Tier IV segue uma abordagem semelhante ao do Tier III, com modelos hierárquicos. Um modelo é utilizado para representar todo o Tier IV, composto pela integração de cinco subsistemas: UP1+GS, Subsistema Z, UP2+GS, subsistema Z2 e subsistema PS. Dois representando o sistema de energia e UPS (Figuras 22 e 23), dois para o subsistema Z (redundante) e outro o subsistema PS.

Neste Tier, existem dois caminhos redundantes de fluxo elétrico, ambos com sistemas UPS redundantes. Os percursos denominados por Subsistema Z e subsistema z2 (Figura





Figura 31 – Exemplo do subsistema elétrico do centro de dados classificado como Tier IV

32-a) são compostos por ATS1, UPS System 1, ATS2, SDT1, Subpane1 e JunctionBox1. O conjunto de filtros de linha para o centro de dados Tier IV é apresentado na Figura 32-b, chamado Subsystem PS.



a. Subsistema Z / Z2



b. Subsistema PS

Figura 32 – Modelagem RBD dos Subsistemas Z/Z2 e PS, referente ao Tier IV

A disponibilidade para os subsistemas Z, Z2 e PS são calculados pelas Equações 6.9 e 6.10.

$$SubsystemZ = ATS1 \times UPSSystem1 \times ATS2 \times SubPane1 \times JuctionBox1 \quad (6.9)$$

$$SubsystemPS = \prod_{i=1}^8 (PowerStrip_{(i)}) \quad (6.10)$$

Existem duas fornecedoras de energia, cada uma com seu sistema gerador de backup (UtilityPower1 + GeneretorSystem1 e UtilityPower2 + GeneretorSystem2). O modelo RBD final para o subsistema elétrico do Tier IV é apresentado na Figura 33.




Figura 33 – Modelo RBD Completo do Tier IV

A forma fechada da disponibilidade do centro de dados Tier IV é apresentada na Equação 6.11.

$$Av_{Inf.Elet.TierIV} = (1 - (\prod_{i=1}^n (1 - (UtilityPower_GeneretorSys)_{(n)})) \times (ATS1 \times UPSSystem1 \times SubPane1 \times ATS2 \times JuctionBox1)_{(n)}) \times (\prod_{i=1}^8 (PowerStrip_{(i)})) \quad (6.11)$$

Após obtido o valor da disponibilidade do centro de dados Tier IV, o modelo de fluxo elétrico apresentado na Figura 34 é adotado.




Figura 34 – Modelo EFM do Tier IV

6.6 CONSIDERAÇÕES SOBRE OS MODELOS

Este capítulo apresentou modelos de disponibilidade e fluxo elétrico para cada uma das quatro classificações dos centros de dados, de acordo com o instituto *Uptime* (TIME, 2015). Para representar as dependências entre os componentes redundantes de alguns modelos foi utilizada uma modelagem hierárquica, compondo um modelo em RBD com SPN e CTMC. Os modelos propostos representam apenas a infraestrutura elétrica dos centros de dados.

7 ESTUDOS DE CASO

Este capítulo está subdividido em duas seções: estudo de caso 1 e estudo de caso 2. Ambos ilustram a aplicabilidade da metodologia, estratégia e modelos propostos. Os modelos apresentados no capítulo 6 são utilizados para obtenção das métricas de disponibilidade, sustentabilidade e custo.

7.1 ESTUDO DE CASO I

O principal objetivo deste primeiro estudo de caso é a validação dos modelos propostos no Capítulo 6 bem como mostrar a aplicabilidade do algoritmo PLDA-D, considerando a infraestrutura elétrica dos centros de dados classificados como Tiers I, II, III e IV.

Para conduzir a avaliação, o ambiente Mercury é adotado, não só para se obter as métricas de confiabilidade, mas também para estimar o impacto de custo e sustentabilidade, bem como para conduzir a avaliação do fluxo de energia e propor uma nova distribuição de acordo com a otimização gerada pelo algoritmo PLDA-D. Para validação do modelo de centro de dados Tier I, a infraestrutura de energia foi avaliada. O valor da disponibilidade proposta para o centro de dados Nível I, de acordo com o instituto *Uptime* é de 0,9997. A disponibilidade obtida a partir do modelo RBD da Figura 20 foi 0.9952. Para validar o modelo proposto foi usado o erro relativo, para comparar a diferença entre os resultados. Considerando o erro relativo (apresentado na Equação (7.1)), o valor de 0,0015 foi atingido.

$$ErroRelativo = \frac{(ValorTeorico - ValorExperimental)}{ValorExperimental} \quad (7.1)$$

Dessa forma, um valor muito pequeno foi encontrado para o erro relativo, portanto, consideramos o modelo proposto como uma representação precisa do modelo de Nível I. A mesma estratégia foi adotada para validar os demais modelos propostos dos níveis II, III e IV. A Tabela 7 apresenta os valores de MTTFs e MTTRs para cada dispositivo. Estes valores foram obtidos de (BOOK, 1998).

Para demonstrar a aplicabilidade do PLDA-D, foram avaliadas as quatro infraestruturas de energia do centro de dados classificados pelo instituto *Uptime* (TIME, 2015), onde as seguintes métricas foram consideradas:

- (i) Custo Total;
- (ii) Exergia Operacional;
- (iii) Disponibilidade
- (iv) PUE (Eficiência de uso de energia).

Tabela 7 – Valores de MTTF e MTTR em horas.

Equipamento	MTTF(h)	MTTR(h)
Ac Source	5.380	8
Gerenerator	3.190	8
ATS	282.581	8
UPS	60.000	8
SDT	1.412.908	8
SubPanel	404.000	8
Juction Box	5.224.000	8
Power Strip	215.111	8
Cooling Tower	24.816	48
Chiller	18.000	48
Crac	37.059	8

Essas métricas foram calculadas ao longo de um período de cinco anos, entretanto, como o Mercury considera horas como as unidades-padrão de medida em tempo, o seguinte valor foi utilizado: 43.800 horas. Cada métrica foi computada antes e após a execução do algoritmo de distribuição de carga elétrica em profundidade (PLDA-D).

O fluxo elétrico em um centro de dados inicia a partir de uma fonte de alimentação externa (por exemplo, fornecedora de energia), passa por unidades de fonte de alimentação ininterrupta (UPS), transformadores (Step Down - SDT), unidades de distribuição de energia (PDUs) subpanels e, finalmente, para o rack, onde a eletricidade chega aos servidores.

Tabela 8 – Capacidade e Eficiência

Equipamentos	Eficiência(%)	Capacidade(kW)
Utility Power 1	95,3	10000
Utility Power 2	90,0	10000
STS 1	99,5	1500
STS 2	98,0	1500
SDT (or Transformer) 1	98,5	5000
SDT (or Transformer) 2	95,0	5000
Sub Panel 1	99,9	1500
Sub Panel 2	95,0	1500
UPS 1	95,3	5000
UPS 2	90,0	5000
Junction Box 1	99,9	1500
Junction Box 2	98,0	1500
Power Strip 1	99,5	5000
Power Strip 2	95,1	5000

De acordo com a configuração adotada, diferentes níveis de redundância são considerados, o que impacta nas métricas calculadas para este estudo de caso. A Tabela 8 apresenta a eficiência elétrica e a capacidade máxima de cada dispositivo utilizado nesse estudo (CALLOU et al., 2013b).

A Tabela 9 resume os resultados das avaliações de cada infraestrutura elétrica dos centros de dados classificados como Tiers I ao IV, antes e após execução do algoritmo PLDA-D. A linha *Antes* apresenta os resultados obtidos anteriormente à execução do PLDA-D, a linha *Após* apresenta os resultados depois da execução do algoritmo, a linha *Melhoria (%)* representa a melhora alcançada em porcentagem. A coluna *Exergia Oper.* representa a exergia operacional em giga joules (GJ) (considerando 5 anos), a coluna *Custo Total* é a soma do custo de aquisição com o custo de operação em USD (considerando o período de cinco anos). Finalmente, tem-se a coluna *PUE* que é a eficiência do uso de energia em porcentagem, que corresponde à carga total do centro de dados dividido pela carga total dos equipamentos de TI instalados.

Tabela 9 – Resultados da execução do PLDA-D com melhoria em %.

Tiers	-	Exergia Oper. (GJ)	Custo Total(USD)	PUE
Tier I	Antes	4.688	1.173.593	86,84 (%)
	Após	4.418	1.165.323	87,50 (%)
	Melhoria (%)	6,13	0,71	0,77
Tier II	Antes	10.127	2.289.365	85,94 (%)
	Após	8.837	2.249.961	87,50 (%)
	Melhoria (%)	14,59	1,75	1,82
Tier III	Antes	13.242	3.347.222	87,52 (%)
	Após	11.077	3.281.087	89,34 (%)
	Melhoria (%)	19,54	2,02	2,08
Tier IV	Antes	16.252	4.452.412	88,39 (%)
	Após	11.000	4.291.925	91,84 (%)
	Melhoria (%)	47,75	3,74	3,9

O algoritmo PLDA-D é aplicado a cada arquitetura EFM e, como resultado, os pesos apresentados em cada vértice do modelo EFM são atualizados, melhorando o fluxo de energia. O menor valor do fluxo é escolhido, fazendo a varredura em profundidade e assim todas as métricas relacionadas ao consumo de energia são aprimoradas.

A partir da Tabela 9, observa-se, inicialmente, a melhoria obtida após o uso do algoritmo PLDA-D. As métricas de sustentabilidade, de consumo de energia e de custo são melhoradas. Por exemplo, mesmo no centro de dados Tier I, onde nenhum componente redundante é considerado, melhorias foram alcançadas. A exergia operacional foi reduzida em 6,13% e o custo total em 0,71% (o que corresponde a uma economia de 8720 USD), o PUE também melhorou em torno de 0,77%.

O centro de dados Tier II apresenta um avanço nas métricas de custo e sustentabilidade. Por exemplo, a exergia operacional foi reduzida de 10.127 para 8.837 GJ, PUE de 85,94 para 87,50 (%) e o custo diminuiu em 1,75 (%), o que equivale a uma economia de 39.404 dólares. Para o Tier III, observou-se uma redução de quase 20% na exergia

operacional e 2% no custo total, que em recursos financeiros equivale a 66.135 USD. O PUE é melhorado em 2,08%, atingindo 89,34%, um avanço considerável.

O centro de dados classificado como Tier IV é o mais completo em níveis de redundância e segurança. Os valores alcançados são significativos, com uma redução de quase 50% da exergia operacional e quase 160.500 USD em cinco anos. O PUE é melhorado em 3,9%. A Figura 35 apresenta o a redução do custo total e o aumento do PUE, em porcentagem.




Figura 35 – Comparação antes e após execução do PLDA-D.

As melhorias proporcionadas pela aplicação do algoritmo são bastante relevantes. O custo total do Tier Nível II é reduzido em 1,75(%), o que significa USD 39.403 em cinco anos. Além disso, há uma relação entre a classificação dos Tiers e a capacidade do sistema de UPSs. A Tabela 10 apresenta o consumo médio de energia demandado por cada Tier, baseado nos dados de Turner (IV; BRILL, 2008).

Tabela 10 – Relação entre Custo/Kw antes/após PLDA e PLDA-D.

Classificação Tier	Custo/kW	Após PLDA-D
Tier 1	10.000	9.923
Tier 2	11.000	108.702
Tier 3	20.000	19.584
Tier 4	22.000	21.142

A coluna “**Após PLDA-D**” representa os resultados obtidos após a execução do algoritmo PLDA-D, nos quais uma diminuição em comparação ao consumo médio de

energia (coluna “Custo/kW”) pode ser observado. O Tier I apresenta uma redução de 0,77%, ao passo que a segunda arquitetura apresenta uma redução de 1,18%. Para o nível III, o uso do PLDA-D implica uma diminuição de 2,12% e para o Tier IV a melhoria é ainda mais significativa, chegando a uma redução de 4,05% no custo/kW.

Portanto, este estudo de caso mostrou que a abordagem proposta pode ser adotada para restringir o custo operacional e energético de um centro de dados. Neste caso específico, foi apresentada uma redução do custo associado à eletricidade consumida, através da melhoria do fluxo elétrico dentro da infraestrutura do sistema destes centros.

7.2 ESTUDO DE CASO II

Este segundo estudo de caso tem como objetivo estimar os custos operacionais e as emissões de CO₂ de um centro de dados nos EUA, levando em consideração a variação energética do ambiente por um período de 15 anos. Além disso, é possível estabelecer o impacto ambiental do consumo de energia dos centros de dados instalados em diferentes regiões (com variação dos mixes energéticos). Para exemplificar, avaliamos os modelos de um centro de dados classificado como Tier III (apresentado na seção 6.4), por ser o tipo mais representativo no mundo, além de apresentarmos uma comparação das estimativas dos seguintes países: Alemanha, China, Estados Unidos e Brasil. Uma rede neural (perceptron multicamada - MLP) é usada para prever o consumo de energia para os 12 meses seguintes, de acordo com o histórico de consumo do ambiente. Nesse contexto, este segundo estudo aplica as RNAs para prever o consumo de energia com base no histórico do ambiente. Entretanto, é prudente explicar como o mix energético, o custo e as emissões de gás carbônico se relacionam nessa tese.

7.2.1 Variação de fontes energéticas, emissões de CO₂ e custos

O acesso à energia é um pilar fundamental para o bem-estar humano e desenvolvimento econômico. Garantir que todos tenham acesso suficiente é um desafio contínuo e urgente para o desenvolvimento global. No entanto, nossos sistemas de energia causam impactos ambientais importantes. Os sistemas de energia atuais produzem dióxido de carbono (CO₂) e outros gases de efeito estufa, motor fundamental da mudança climática global.

Os níveis de consumo de energia dos centros de dados utilizados nesta tese foram obtidos em (SHEHABI et al., 2016). A Figura 36 mostra a relação entre o tipo de material usado (em porcentagem) para geração de energia no Brasil, na China, na Alemanha e nos Estados Unidos. Foram considerados os cinco tipos de fontes de energia mais utilizadas no mundo: eólica, carvão, hidrelétrica, nuclear e petróleo (a barra “outros” simboliza a combinação de todas as demais fontes de energia adotadas em cada país).

Na Tabela 11 é possível observar a variação de fontes energéticas utilizadas por cada país (Alemanha, Brasil, China e Estados Unidos) para geração de energia. Aliada à fonte geradora, é possível estimar as emissões e custos associados ao CO₂. Os valores para cada




Figura 36 – Variação energética do Brasil, Alemanha, China e USA

item foram obtidos a partir das informações dos governos federais, disponibilizadas por cada país e encontradas em relatórios anuais de consumo de energia (SHEHABI et al., 2016; BURGER, 2017; ADMINISTRATION, 2017; IBERDROLA, 2017).

Tabela 11 – Mix energético, custo elétrico e emissões de CO₂

Fonte de Energia	ALE	BRA	CHN	USA	CO ₂ (g/kWh)
Custo kWh (USD)	0,25	0,18	0,43	0,12	-
Eólica (%)	14,3	1,44	6	4,7	10
Carvão (%)	42,9	1,5	63	33	950
Hidrelétrica (%)	4	69,76	22	6	20
Nuclear (%)	14,7	1,68	1	20	150
Petróleo (%)	0,94	6	2	1	510
Outras (%)	23,16	19,62	6	35,3	-

A Figura 37 mostra uma comparação das emissões de CO₂ de acordo com a variação de fontes energéticas adotadas por cada país (veja Equação 5.1), considerando a mesma demanda por ano. A China apresentou as maiores emissões de CO₂, com 41.445 toneladas por ano em 2014, seguidas pelos EUA e Alemanha, com 37.177 e 35.883, respectivamente. O Brasil, com 8.459 toneladas, provou ser o mais limpo. Devido ao número de rios e topologia, o Brasil é excelente em geração de energia limpa, o que pode representar uma opção interessante para a construção de um centro de dados.

A grande maioria das pessoas ainda está preocupada com os níveis de emissões de CO₂ produzidos pelos EUA, que continuam bastante altos. Ademais, o governo americano mostra pouca preocupação com essas emissões, o que corrobora para os estimados




Figura 37 – Emissões de CO₂ por ano em toneladas

aumentos para os próximos anos.

A Figura 38 ilustra os custos operacionais de um centro de dados por um período de um ano (em USD, de acordo com a equação 5.2). Além disso, este documento também estima os custos operacionais utilizando os dados de consumo dos Estados Unidos e verificando os valores caso esse consumo tivesse sido na China, Alemanha ou Brasil. Por meio desses números, é possível notar que a China apresenta os mais altos níveis de emissões de CO₂, bem como os maiores kWh/ano.




Figura 38 – Custo operacional anual em USD: EUA, Brasil, Alemanha e China

Portanto, considerando apenas a malha elétrica da China, o custo correspondente é 3,5 vezes maior do que se o centro de dados estivesse localizado nos Estados Unidos. Assim, a melhor escolha de acordo com os custos operacionais, considerando o preço da

energia por kWh, é a dos EUA e a pior é a China. Entretanto, considerando tanto os custos operacionais quanto as emissões de CO₂, o Brasil seria a melhor opção.

7.2.2 Previsões da Rede Neural Artificial

O principal objetivo desta subseção é apresentar as previsões feitas usando a ferramenta Mercury com o perceptron multicamada (MLP). Com o objetivo de demonstrar a aplicabilidade do método proposto, um exemplo é apresentado considerando o histórico de consumo de energia de um centro de dados entre 2000 e 2014. Os resultados foram validados por comparação com a ferramenta R usando a média móvel integrada auto regressiva (ARIMA).

Analisando o consumo de energia, identificamos uma tendência de movimento significativa para os dados, o que denota uma série não estacionária. Dessa forma, aplicamos o teste de correlação não paramétrica (coeficiente de spearman (BOX et al., 2015)) para confirmar este fato. Utilizou-se a opção de auto correlação da ferramenta R e os filtros escolhidos para o ARIMA foram (3,2,2), em que o 3 representa o tamanho do fator regressivo, 2 uma quantidade de diferença para o objetivo e 2, a média móvel, respectivamente. A Figura 39 apresenta o consumo de energia do centro de dados Tier III compreendido entre o período dos anos 2000 a 2014 e fornece uma previsão para os próximos 12 meses, destacada em azul com o intervalo de confiança em cinza.




Figura 39 – Previsões do ARIMA(3,2,2)

A Figura 40 mostra uma comparação entre o consumo real e aquele previsto pelo aprendizado da rede neural. Neste caso, a RNA realizou um aprendizado após 100.000 (cem mil) interações, chegando a um erro de $1,58 \times 10^{-4}$. É possível verificar este erro através do gráfico apresentado na figura, o que corresponde a uma pequena diferença e, portanto, pode-se considerar que a RNA demonstrou uma boa aprendizagem.




Figura 40 – Consumo Real x Consumo Previsto

Com os valores de consumo de energia acima mencionados, projetamos o consumo de energia para os próximos meses, usando o perceptron de múltiplas camadas (Figura 41).




Figura 41 – Previsões para 12 meses usando o MLP

Este MLP é configurado para usar 70% das medições para treinamento e 30% para testes (Esta foi a configuração que apresentou os melhores resultados). O MLP é configurado com uma camada de entrada (com doze neurônios, cada uma representando um mês do ano), uma camada oculta (com 30 neurônios internos) e uma camada de saída.

Considerando um intervalo de confiança de 90% para o ARIMA, o consumo de energia pode diminuir em 1,32 ou aumentar em 2,21%. Usando o erro médio padrão no MLP, as mudanças no consumo de energia seriam entre um decréscimo de 1,25% e um aumento de 1,04%. Como é possível verificar, as previsões utilizando a rede neural ficaram dentro do intervalo de confiança projetado pelo ARIMA, o que nos leva a confiar neste método. Portanto, estimamos um aumento nas emissões de CO_2 na atmosfera, o que pode causar problemas de saúde para a população mundial em algumas décadas. A Tabela 12 apresenta as previsões usando o ARIMA e MLP, para os 12 meses seguintes, a partir de janeiro de 2015.

Tabela 12 – Previsões ARIMA e MLP para os próximos 12 meses (2015)

	ARIMA		MLP	
	Inferior	Superior	Inferior	Superior
Jan	64,07	64,59	63,63	63,77
Fev	63,95	64,75	63,23	63,37
Mar	63,82	64,92	63,43	63,57
Abr	63,69	65,10	63,20	63,34
Mai	63,56	65,28	63,20	63,34
Jun	63,42	65,47	63,33	63,47
Jul	63,27	65,66	63,03	63,17
Ago	63,12	65,85	63,53	63,67
Set	62,97	66,05	63,13	63,27
Out	62,81	66,26	63,53	63,67
Nov	62,65	66,47	63,23	63,37
Dez	62,49	66,68	63,83	63,97

7.3 CONSIDERAÇÕES

Este capítulo apresentou estudos de caso para verificar a aplicabilidade do PLDA-D em infraestruturas elétricas de centros de dados. As quatro infraestruturas classificadas como Tier I, II, III e IV foram analisadas e validadas, pois tiveram seu consumo de energia e impactos ambientais reduzidos. O algoritmo proposto se mostrou eficaz, principalmente com o aumento da complexidade do ambiente, gerando uma solução ótima para o problema do melhor fluxo restrito pela capacidade dos componentes em uma rede elétrica.

Em seguida, outro estudo foi apresentado, no qual uma rede neural artificial foi usada para estimar as emissões de gás carbônico emitido na atmosfera, através do consumo de energia dos centros de dados. Esta RNA foi validada por meio de uma comparação com o ARIMA. A modelagem do Tier III foi usada e a variação das fontes geradoras de energia consideradas. Por fim, uma comparação com as malhas elétricas do Brasil, Alemanha, China e Estados Unidos é apresentada.

8 CONCLUSÃO

Com o aumento da dependência dos serviços de Internet nos últimos anos, acompanhado dos novos paradigmas da computação (por exemplo, computação em nuvem), a disponibilidade em centros de dados tornou-se uma preocupação de alta prioridade. Assim, para empresas que possuem grande dependência de suas operações ligadas ao funcionamento da Internet, interrupções de serviço podem ser muito caras, atingindo facilmente os milhões de dólares por hora.

Um princípio de design amplamente utilizado na tolerância a falhas é a introdução de redundância para melhorar a disponibilidade dos ambientes. No entanto, o acréscimo de redundância pode elevar o consumo de energia, incorrendo em um impacto negativo na sustentabilidade e no custo das operações. Entretanto, diante dos altos índices de disponibilidade almejados pelas empresas e seus usuários, há uma preocupação com as questões de sustentabilidade. É importante que as empresas demonstrem seu interesse em possuir alta disponibilidade aliada a estratégias de diminuição do impacto ambiental.

Em centros de dados o impacto ambiental é medido pelo consumo de energia. Quanto maior o centro de dados, mais energia será consumida e maiores podem ser os índices que afetam negativamente a sustentabilidade (emissão de gás carbônico, exergia, etc.). De acordo com a matéria prima geradora da eletricidade, haverá uma variação do impacto ambiental, por exemplo, o impacto através da utilização do carvão mineral, será maior que através de hidrelétricas.

Diante desse problema, um modelo chamado EFM, avalia de forma integrada a disponibilidade, o custo e as questões de sustentabilidade de infraestruturas elétricas. Esse modelo está implementado em uma ferramenta de nome Mercury, que possui ambientes habilitados para a elaboração de modelos formais como RBD, SPN e MC. No entanto, na modelagem EFM a distribuição padrão do fluxo elétrico é feita de forma proporcional à quantidade de vértices ascendentes que cada aresta possui no modelo ou a distribuição fica sob a responsabilidade do projetista do ambiente, sujeito a erros humanos em sua elaboração. Ademais, não há como fazer uma verificação precisa nas questões de sustentabilidade, uma vez que a variação das fontes geradoras de energia não é considerada, ou estimativas do consumo e impacto ambiental para os próximos meses.

Assim, essa tese propôs um algoritmo de distribuição de carga elétrica em profundidade (PLDA-D) (Seção 5.3) visando preencher a lacuna desta modelagem, fornecendo uma boa heurística, reduzindo o consumo de energia (quando possível) de modelos de infraestrutura elétrica projetados na ferramenta Mercury ao utilizar o modelo EFM. Foi proposta também a ampliação de funcionalidades do modelo EFM, na possibilidade de representação da variação das fontes geradoras de energia do ambiente avaliado, bem como integração com uma rede neural artificial, a fim de prever o consumo de energia e impacto

ambiental para um futuro próximo.

A metodologia adotada consiste em uma implementação do algoritmo proposto, consideração do mix energético e integração com RNA, na visão de fluxo elétrico da ferramenta Mercury. Assim, a distribuição do fluxo nos modelos EFM para infraestruturas elétricas é melhorada, incorrendo em uma análise mais precisa do impacto ambiental e previsões.

Com o objetivo de verificar a aplicabilidade das estratégias adotadas, dois estudos de caso foram desenvolvidos, nos quais foram analisadas quatro infraestruturas elétricas dos centros. Estas arquiteturas foram baseadas na classificação dos Tiers, feita pelo instituto *Uptime* (TIME, 2015), que variam de acordo com níveis de redundância da infraestrutura elétrica.

Os resultados da avaliação das métricas das arquiteturas com a aplicação do algoritmo PLDA-D foram melhores ou iguais aos resultados obtidos usando a configuração padrão da ferramenta Mercury. Para os centros de dados Tier I foi alcançada uma redução na exergia de 6,13% e no custo operacional de 0,71%. Já para o Tier II, a redução da exergia foi de 12,7% e do custo operacional foi de 1,75%. Para o Tier III, a redução chegou a quase 20% da exergia e exatos 2% no custo. Finalmente, para o mais redundante, Tier IV, a exergia foi reduzida a metade e o custo operacional em 3,9%.

Os resultados para a implantação do mix energético no modelo EFM também foram satisfatórios, uma vez que possibilitou ao projetista aferir com mais precisão o custo energético e impacto ambiental (emissões de CO₂) de um centro de dados. Neste caso, considerando, um ambiente com, por exemplo, 60% de energia elétrica proveniente de hidrelétricas e 40% proveniente de petróleo, para seu funcionamento.

A integração de uma rede neural artificial implementada a ferramenta Mercury, por meio do perceptron de múltiplas camadas, foi bastante eficiente, chegando, após 100.000 iterações a um erro percentual absoluto médio muito pequeno e gerando resultados dentro do intervalo de confiança do ARIMA.

É importante ressaltar que todos os objetivos traçados no início deste trabalho foram alcançados, como:

- Uma heurística foi proposta para distribuição eficiente do fluxo energético na infraestrutura elétrica do centro de dados;
- A variação das fontes geradoras de energia foi considerada nos modelos de fluxo elétrico.
- O impacto ambiental foi analisado de forma mais precisa, considerando a eficiência energética decorrente do mix adotado nos centros de dados.
- Uma RNA foi integrada ao EFM para previsão do consumo de energia e impacto ambiental do centro de dados.

8.1 CONTRIBUIÇÕES

Como resultado do trabalho apresentado nesta tese, as seguintes contribuições podem ser destacadas:

- Benefícios financeiros com a redução do custo de operação dos ambientes de centro de dados ou nuvens.
- Benefícios globais com a redução do impacto ambiental por intermédio da redução do consumo de energia.
- Arquiteturas energeticamente mais eficientes.
- Precisão na modelagem da infraestrutura elétrica dos centros de dados que utilizam variação de fontes geradoras de energia.
- Possibilidade de previsões baseadas em rede neural artificial para custo e impacto ambiental dos modelos de fluxo elétrico.

8.2 TRABALHOS FUTUROS

Embora esta tese aborde algumas questões relativas à sustentabilidade, disponibilidade e custo de arquiteturas de centros de dados, há muitas possibilidades de melhorar e ampliar o atual trabalho. Os itens a seguir resumem algumas possibilidades:

- **Considerar o ACV dos equipamentos** - O impacto da sustentabilidade foi estimado considerando o consumo exegético durante a fase operacional do centro de dados. Uma extensão possível é considerar o impacto da sustentabilidade durante todo o ciclo (avaliação do ciclo de vida - ACV) do equipamento. Portanto, um estudo relacionado a como obter essas estimativas de consumo de energia durante a fase embarcada pode ser realizado.
- **Generalização do PLDA-D** - Embora o algoritmo de distribuição de carga elétrica em profundidade (PLDA-D) tenha sido proposto para um fim específico, é possível torná-lo genérico. Neste caso, executado em grafos acíclicos dirigidos, sendo uma nova solução para problemas de várias naturezas, como por exemplo, fluxo máximo ou mínimo, que se enquadrem nas mesmas características do fluxo energético.
- **Considerar infraestruturas de resfriamento** - Como esta tese considerou apenas os componentes da infraestrutura elétrica, seria interessante considerar a infraestrutura de resfriamento, responsável por quase 50% do consumo de energia dos centros de dados ou nuvens. Aplicar algoritmos para otimizar seu uso, baseado nas eficiências e capacidade de refrigeração do ambiente, bem como predições.

- **Considerar hardened computing** - Os valores de dependabilidade dos centros de dados podem ser afetados por alguns fatores, chamados de hardened computing, como a variação de temperatura e umidade no ambiente. Os dispositivos elétricos podem sofrer degradações (por exemplo, redução de disponibilidade e confiabilidade) devido ao aumento da temperatura e / ou umidade. Portanto, a relação entre a infraestrutura de refrigeração do centro de dados e o sistema de TI pode ser analisada. Por exemplo, modelos que relacionem essa ligação podem ser propostos para estimar o impacto da variação de temperatura na disponibilidade do sistema de TI.
- **Melhor localização para um centro de dados** - Propor um sistema que avalie várias áreas geográficas informadas pelo usuário e decida qual a melhor (baseada em risco, custo e impacto ambiental) para instalação de um novo centro de dados com maior eficiência energética. Levando em consideração quatro itens fundamentais: topologia e localização; Tipo de matéria prima para produção de energia; custo da energia e distância da demanda.

8.3 CONSIDERAÇÕES FINAIS

Esta tese de doutorado propôs um algoritmo para distribuição da carga elétrica em profundidade (PLDA-D) nos modelos EFM, respeitando os limites de capacidade dos componentes. Assim como a possibilidade de utilizar a variação de fontes energéticas para avaliação do custo e impacto ambiental e integração de uma rede neural artificial ao EFM.

As contribuições deste trabalho giram em torno da redução da exergia operacional e custo operacional das infraestruturas elétricas dos centros de dados representados no EFM.

Dois estudos de caso foram elaborados, considerando questões de disponibilidade, sustentabilidade e custo para validar a aplicabilidade do PLDA-D, a integração com o perceptron e a utilização do mix energético. Embora os resultados alcançados tenham sido bastante satisfatórios, as estratégias apresentadas nesta tese estão abertas ao aproveitamento em outras áreas do conhecimento, não se restringindo apenas ao ambiente mencionado.

REFERÊNCIAS

- ABBASI, Z.; VARSAMOPOULOS, G.; GUPTA, S. Thermal aware server provisioning and workload distribution for internet data centers. In: *ACM International Symposium on High Performance Distributed Computing (HPDC10)*. [S.l.: s.n.], 2010. p. 130–141.
- ABESCO, A. B. das Empresas de Serviços de Conservação de E. *Hidrelétricas, carvão, petróleo: como cada país gera sua energia*. 2018. [http : //www.abesco.com.br/pt/novidade /hidreletricas – carvao – petroleo – como – cada – pais – gera – sua – energia/](http://www.abesco.com.br/pt/novidade/hidreletricas-carvao-petroleo-como-cada-pais-gera-sua-energia/).
- ADMINISTRATION, U. E. I. *International energy data and analysis*. 2017. [https : //www.eia.gov/beta/international/analysis.php?iso = CHN](https://www.eia.gov/beta/international/analysis.php?iso=CHN).
- AGENCY, E. P. *Report to Congress on Server and Data Center Energy Efficiency*. 2007. [Http://www.energystar.gov/ia/partners/prod_development /downlo-ads/EPA_Datacenter_Report_Congress_Final1.pdf](Http://www.energystar.gov/ia/partners/prod_development /downloads/EPA_Datacenter_Report_Congress_Final1.pdf).
- AL-QAWASMEH, A. *Heterogeneous Computing Environment Characterization and Thermal-Aware Scheduling Strategies to Optimize data center power consumption*. Tese (Doutorado) — Colorado State University, 2012.
- ARIANYAN, E. Multi objective consolidation of virtual machines for green computing in cloud data centers. In: IEEE. *Telecommunications (IST), 2016 8th International Symposium on*. [S.l.], 2016. p. 654–659.
- ARREGOCES, M.; PORTOLANI, M. *Data center fundamentals*. [S.l.]: Cisco, 2003. (Fundamentals Series). ISBN 9781587050237.
- AUGARSTEN, S. *Bit by bit: an illustrated history of computers*. [S.l.]: Houghton Mifflin Co., 1984.
- AVGERINOU, M.; BERTOLDI, P.; CASTELLAZZI, L. Trends in data centre energy consumption under the european code of conduct for data centre energy efficiency. *Energies*, Multidisciplinary Digital Publishing Institute, v. 10, n. 10, p. 1470, 2017.
- AVIZIENIS, A.; LAPRIE, J.-C.; RANDELL, B.; LANDWEHR, C. Basic concepts and taxonomy of dependable and secure computing. *Dependable and Secure Computing, IEEE Transactions on*, v. 1, n. 1, p. 11 – 33, jan.-march 2004. ISSN 1545-5971.
- BARROSO, L. A.; DEAN, J.; HÖLZLE, U. Web search for a planet: The google cluster architecture. *IEEE micro*, IEEE, n. 2, p. 22–28, 2003.
- BAYATI, M. Managing energy consumption and quality of service in data centers. In: IEEE. *Smart Cities and Green ICT Systems (SMARTGREENS), 2016 5th International Conference on*. [S.l.], 2016. p. 1–9.
- BELLMAN, R. *On a routing problem*. [S.l.], 1956.
- BETTS, R. A.; JONES, C. D.; KNIGHT, J. R.; KEELING, R. F.; KENNEDY, J. J. El niño and a record co 2 rise. *Nature Climate Change*, Nature Publishing Group, v. 6, n. 9, p. 806, 2016.

- BOLCH, G.; GREINER, S.; MEER, H. de; TRIVEDI, K. *Queueing networks and Markov chains: modeling and performance evaluation with computer science applications*. [S.l.]: Wiley-Interscience, 2006.
- BOOK, G. *Recommended Practice for the Design of Reliable Industrial and Commercial Power Systems*. [S.l.: s.n.], 1998.
- BOULEY, D. Estimating a data center's electrical carbon footprint. *White Paper*, v. 66, 2010.
- BOX, G. E.; JENKINS, G. M.; REINSEL, G. C.; LJUNG, G. M. *Time series analysis: forecasting and control*. [S.l.]: John Wiley & Sons, 2015.
- BURGER, B. *Fraunhofer Institute for Solar Energy Systems ISE*. 2017. [https :
//www.energy – charts.de/](https://www.energy-charts.de/).
- CALLOU, G.; MACIEL, P.; MAGNANI, F.; FIGUEIREDO, J. Estimating sustainability impact, total cost of ownership and dependability metrics on data center infrastructures. In: *Sustainable Systems and Technology (ISSST), 2011 IEEE International Symposium on*. [S.l.: s.n.], 2011. p. 1 –6. ISSN 2157-524X.
- CALLOU, G.; MACIEL, P.; TUTSCH, D.; ARAUJO, J. Models for dependability and sustainability analysis of data center cooling architectures. In: *Dependable Systems and Networks (DSN), 2012 IEEE International Conference on*. [S.l.: s.n.], 2012. p. 1 –6.
- CALLOU, G.; MACIEL, P.; TUTSCH, D.; ARAUJO, C.; FERREIRA, J.; SOUZA, R. *Petri Nets - Manufacturing and Computer Science, Chapter 14 - A Petri Net-Based Approach to the Quantification of Data Center Dependability*. [S.l.]: InTech, 2012.
- CALLOU, G.; MACIEL, P.; TUTSCH, D.; FERREIRA, J.; ARAÚJO, J.; SOUZA, R. Estimating sustainability impact of high dependable data centers: a comparative study between brazilian and us energy mixes. *Computing*, Springer Vienna, p. 1–34, 2013. ISSN 0010-485X. Disponível em: <<http://dx.doi.org/10.1007/s00607-013-0328-y>>.
- CALLOU, G.; MACIEL, P.; TUTSCH, D.; FERREIRA, J.; ARAÚJO, J.; SOUZA, R. Estimating sustainability impact of high dependable data centers: a comparative study between brazilian and us energy mixes. *Computing*, Springer, v. 95, n. 12, p. 1137–1170, 2013.
- CALLOU, G.; SOUSA, E.; MACIEL; MAGNANI, F. A formal approach to the quantification of sustainability and dependability metrics on data center infrastructures. In: *Proceedings of DEVS*. San Diego, CA, USA: SCS, 2011. p. 274–281.
- CARVALHO, A.; FACELI, K.; LORENA, A.; GAMA, J. Inteligência artificial–uma abordagem de aprendizado de máquina. *Rio de Janeiro: LTC*, 2011.
- CHALISE, S.; GOLSHANI, A.; AWASTHI, S. R.; MA, S.; SHRESTHA, B. R.; BAJRACHARYA, L.; SUN, W.; TONKOSKI, R. Data center energy systems: Current technology and future direction. In: *IEEE. Power & Energy Society General Meeting, 2015 IEEE*. [S.l.], 2015. p. 1–5.
- COMMISSION, B. et al. *World commission on environment and development. Our common future*. [S.l.]: Oxford, United Kingdom: Oxford University Press, 1987.

- DANTAS, J.; MATOS, R.; ARAUJO, J.; MACIEL, P. An availability model for eucalyptus platform: An analysis of warm-standby replication mechanism. In: IEEE. *2012 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*. [S.l.], 2012. p. 1664–1669.
- DELFORGE'S PIERRE, W. J. *Data Center Efficiency Assessment*. 2014. [https :
//www.nrdc.org/sites/default/files/data-center-efficiency-assessment-IP.pdf](https://www.nrdc.org/sites/default/files/data-center-efficiency-assessment-IP.pdf).
- DINCER, I.; ROSEN, M. *Exergy: energy, environment and sustainable development*. [S.l.]: Elsevier Science, 2007.
- EIA, U. E. I. A. *Sustainability Review - 2010*. [S.l.], 2011.
- ELLIS DANIEL PERRE, A. L. J. H. L. G. E. B. R.; HOXTELL, A. The green grid energy policy research for data centres: France, germany, the netherlands and the united kingdom. *White paper*, 2009.
- FAN, X.; WEBER, W.-D.; BARROSO, L. A. Power provisioning for a warehouse-sized computer. In: ACM. *ACM SIGARCH computer architecture news*. [S.l.], 2007. v. 35, n. 2, p. 13–23.
- FERREIRA, J.; CALLOU, G.; DANTAS, J.; SOUZA, R.; MACIEL, P. An algorithm to optimize electrical flows. In: IEEE COMPUTER SOCIETY. *Proceedings of the 2013 IEEE International Conference on Systems, Man, and Cybernetics*. [S.l.], 2013. p. 109–114.
- FERREIRA, J.; CALLOU, G.; MACIEL, P. A power load distribution algorithm to optimize data center electrical flow. *Energies*, Multidisciplinary Digital Publishing Institute, v. 6, n. 7, p. 3422–3443, 2013.
- FORD, L.; FULKERSON, D. R. *Flows in networks*. [S.l.]: Princeton Princeton University Press, 1962. v. 1962.
- GERMAN, R. *Performance analysis of communication systems with non-Markovian stochastic Petri nets*. [S.l.]: John Wiley & Sons, Inc., 2000.
- GERMAN, R.; KELLING, C.; ZIMMERMANN, A.; HOMMEL, G. Timenet: a toolkit for evaluating non-markovian stochastic petri nets. *Performance Evaluation*, Elsevier, v. 24, n. 1, p. 69–87, 1995.
- GMACH, D.; CHEN, Y.; SHAH, A.; ROLIA, J.; BASH, C.; CHRISTIAN, T.; SHARMA, R. Profiling sustainability of data centers. In: IEEE. *Sustainable Systems and Technology (ISSST), 2010 IEEE International Symposium on*. [S.l.], 2010. p. 1–6.
- GORBENKO, A.; KHARCHENKO, V.; ROMANOVSKY, A. On composing dependable web services using undependable web components. *International Journal of Simulation and Process Modelling*, Citeseer, v. 3, n. 1-2, p. 45–54, 2007.
- HAVERKORT, B. R.; MEEUWISSEN, A. M. H. Sensitivity and uncertainty analysis of markov-reward models. *IEEE Transactions on Reliability*, IEEE, v. 44, n. 1, p. 147–154, 1995.
- HAYKIN, S. *Neural networks: a comprehensive foundation*. [S.l.]: Prentice Hall PTR, 1994.

- HAYKIN, S. *Redes neurais: princípios e prática*. [S.l.]: Bookman Editora, 2007.
- HAYKIN, S. S.; HAYKIN, S. S.; HAYKIN, S. S.; HAYKIN, S. S. *Neural networks and learning machines*. [S.l.]: Pearson Upper Saddle River, 2009. v. 3.
- HEIZER, J. H.; RENDER, B. *Operations management*. [S.l.]: Pearson Education India, 2008. v. 1.
- HELLER, B.; SEETHARAMAN, S.; MAHADEVAN, P.; YIAKOUMIS, Y.; SHARMA, P.; BANERJEE, S.; MCKEOWN, N. Elastictree: Saving energy in data center networks. In: *Nsdi*. [S.l.: s.n.], 2010. v. 10, p. 249–264.
- HOWELL, K. E. *An introduction to the philosophy of methodology*. [S.l.]: Sage, 2012.
- IBERDROLA. *Neoenergia Group, Grupo Neoenergia*. 2017. *http* : [//www.neoenergia.com/](http://www.neoenergia.com/).
- IV, W. P. T.; BRILL, K. G. Cost model: Dollars per kw plus dollars per square foot of computer floor. *white paper, Uptime Institute*, 2008.
- KEMP, S. Digital in 2018. In: HOTSUIT. [S.l.], 2018.
- KIM, D. S.; MACHIDA, F.; TRIVEDI, K. S. Availability modeling and analysis of a virtualized system. In: IEEE. *Dependable Computing, 2009. PRDC'09. 15th IEEE Pacific Rim International Symposium on*. [S.l.], 2009. p. 365–371.
- KLEINROCK, L. *Queueing systems, vol. 1*. [S.l.]: Wiley, New York, 1975.
- KLIAZOVICH, D.; BOUVRY, P.; KHAN, S. U. Dens: data center energy-efficient network-aware scheduling. *Cluster computing*, Springer, v. 16, n. 1, p. 65–75, 2013.
- KUO, W.; ZUO, M. J. *Optimal Reliability Modeling - Principles and Applications*. [S.l.]: Wiley, 2003. ISBN 047139761X.
- KUO, W.; ZUO, M. J. *Optimal reliability modeling: principles and applications*. [S.l.]: John Wiley & Sons, 2003.
- LIU, N.; LIN, X.; WANG, Y. Data center power management for regulation service using neural network-based power prediction. In: IEEE. *Quality Electronic Design (ISQED), 2017 18th International Symposium on*. [S.l.], 2017. p. 367–372.
- MACIEL, P.; TRIVEDI, K.; MATIAS, R.; KIM, D. Performance and dependability in service computing: Concepts, techniques and research directions. In: _____. [S.l.]: Information Science Reference, 2011. cap. 3 - Dependability Modeling, p. 53–97.
- MACIEL, P.; TRIVEDI, K.; MATIAS, R.; KIM, D. Performance and dependability in service computing: Concepts, techniques and research directions, ser. *Premier Reference Source*. Igi Global, 2011.
- MARIN, P. S. Data centers: Desvendando cada passo: conceitos, projeto, infraestrutura física e eficiência energética. *Editora: Érica*, 2011.
- MARSAN, M. A.; BALBO, G.; CONTE, G. Performance models of multiprocessor systems. *The MIT Press, Cambridge, MA*, 1986.

- MARSAN, M. A.; CONTE, G.; BALBO, G. A class of generalized stochastic petri nets for the performance evaluation of multiprocessor systems. *ACM Transactions on Computer Systems (TOCS)*, ACM, v. 2, n. 2, p. 93–122, 1984.
- MARWALA, L.; TWALA, B. Forecasting electricity consumption in south africa: Arma, neural networks and neuro-fuzzy systems. In: IEEE. *Neural Networks (IJCNN), 2014 International Joint Conference on*. [S.l.], 2014. p. 3049–3055.
- MENASCE, D. A.; ALMEIDA, V. A.; DOWDY, L. W.; DOWDY, L. *Performance by design: computer capacity planning by example*. [S.l.]: Prentice Hall Professional, 2004.
- MERCURY Tool. 2015. [http : //www.modcs.org/?page_id = 1397](http://www.modcs.org/?page_id=1397).
- MOLLOY, M. Performance Evaluation Using Stochastic Petri Nets. *IEEE Trans. Comput*, v. 31, n. 9, p. 913–17, 1982.
- MOLLOY, M. K. Performance analysis using stochastic petri nets. *Computers, IEEE Transactions on*, IEEE, v. 100, n. 9, p. 913–917, 1982.
- MONDAL, S.; KEISLING, E. Efficient data center design using novel modular dc ups, server power supply with dc voltage and modular cdu cooling. In: IEEE. *Power Electronics, Drives and Energy Systems (PEDES), 2012 IEEE International Conference on*. [S.l.], 2012. p. 1–6.
- MURATA, T. Petri nets: Properties, analysis and applications. *Proc. IEEE*, v. 77, n. 4, p. 541–580, April 1989.
- MURUGESAN, S. Harnessing green it: Principles and practices. *IT professional*, IEEE, v. 10, n. 1, 2008.
- O'CONNOR, P.; KLEYNER, A. *Practical reliability engineering*. [S.l.]: John Wiley & Sons, 2011.
- PARHAMI, B. From defects to failures: a view of dependable computing. *ACM SIGARCH Computer Architecture News*, ACM, v. 16, n. 4, p. 157–168, 1988.
- PATTERSON, M. The effect of data center temperature on energy efficiency. In: *ITHERM'08*. [S.l.: s.n.], 2008.
- PELLEY, S.; MEISNER, D.; WENISCH, T. F.; VANGILDER, J. W. Understanding and abstracting total data center power. In: *Workshop on Energy-Efficient Design*. [S.l.: s.n.], 2009. v. 11.
- PINDYCK, R. S.; RUBINFELD, D. L. *Econometria: modelos & previsões*. [S.l.]: Elsevier, 2004.
- RICCIARDI, S.; CAREGLIO, D.; SOLE-PARETA, J.; FIORE, U.; PALMIERI, F. et al. Saving energy in data center infrastructures. In: IEEE. *Data Compression, Communications and Processing (CCP), 2011 First International Conference on*. [S.l.], 2011. p. 265–270.
- ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, American Psychological Association, v. 65, n. 6, p. 386, 1958.

- RUMELHART, D. E.; HINTON, G. E.; MCCLELLAND, J. L. et al. A general framework for parallel distributed processing. *Parallel distributed processing: Explorations in the microstructure of cognition*, v. 1, p. 45–76, 1986.
- SHEHABI, A.; SMITH, S.; SARTOR, D.; BROWN, R.; HERRLIN, M.; KOOMEY, J.; MASANET, E.; HORNER, N.; AZEVEDO, I.; LINTNER, W. United states data center energy usage report. 2016.
- SHOUKOURIAN, H.; WILDE, T.; LABRENZ, D.; BODE, A. Using machine learning for data center cooling infrastructure efficiency prediction. In: IEEE. *Parallel and Distributed Processing Symposium Workshops (IPDPSW), 2017 IEEE International*. [S.l.], 2017. p. 954–963.
- SILVA, B.; MATOS, R.; CALLOU, G.; FIGUEIREDO, J.; OLIVEIRA, D.; FERREIRA, J.; DANTAS, J.; LOBO, A.; ALVES, V.; MACIEL, P. Mercury: An integrated environment for performance and dependability evaluation of general systems. In: *Proceedings of Industrial Track at 45th Dependable Systems and Networks Conference, DSN*. [S.l.: s.n.], 2015.
- TIME, U. *Up Time Institute*. 2015. <https://uptimeinstitute.com/>.
- TIWARI, V.; MALIK, S.; WOLFE, A. Power Analysis of Embedded Software: A First Step Towards Software Power Minimization. *Readings in Hardware/Software Co-Design*, Morgan Kaufmann, 2001.
- TÜMER, A. E.; KOÇER, S.; KOCA, A. Estimation of the electricity consumption of turkey trough artificial neural networks. In: IEEE. *Computational Intelligence and Informatics (CINTI), 2016 IEEE 17th International Symposium on*. [S.l.], 2016. p. 000315–000318.
- TURNER, V. The digital universe of opportunities: Rich data and the increasing value of the internet of things. In: EMC. *EMC Digital Universe*. [S.l.], 2014.
- ZHANG, X.; ZHAO, X.; LI, Y.; ZENG, L. Key technologies for green data center. In: IEEE. *Information Processing (ISIP), 2010 Third International Symposium on*. [S.l.], 2010. p. 477–480.
- ZHOU, Z.; ABAWAJY, J. H.; LI, F.; HU, Z.; CHOWDHURY, M. U.; ALELAIWI, A.; LI, K. Fine-grained energy consumption model of servers based on task characteristics in cloud data center. *IEEE access*, IEEE, v. 6, p. 27080–27090, 2018.

APÊNDICE A – APRESENTAÇÃO DA RNA IMPLEMENTADA NO MERCURY

Este apêndice apresenta em detalhes o funcionamento da rede neural implementada na ferramenta Mercury. Esta funcionalidade pode ser usada para se estimar o consumo de energia de um centro de dados para os próximos meses.

A Figura 42 apresenta a visão do usuário sob estas fases na ferramenta Mercury e como configurar a rede neural artificial.




Figura 42 – Visualização das opções da RNA no Mercury

- **Carregar e normalizar dados** - Para que seja possível fazer as previsões, é necessário que tenhamos uma base de dados onde a RNA será posteriormente treinada. Nesta ferramenta, a base de dados deve conter o histórico do consumo de energia do ambiente avaliado. O Mercury foi configurado para aceitar planilhas nos formatos *odt*, *xls* e *csv*, com três colunas, organizadas em: ano, mês e consumo de energia, respectivamente. Quanto maior o histórico, mais precisa será a previsão.
- **Criar uma rede neural artificial** - Nesta fase, os parâmetros básicos para a criação da rede neural artificial são definidos (por exemplo, número de neurônios na camada de entrada, número de neurônios na camada oculta e número de neurônios

na camada de saída). O teste empírico com a rede neural de retro propagação MLP (RUMELHART et al., 1986) não demonstra uma vantagem significativa no uso de duas camadas ocultas em vez de uma para pequenos problemas. Portanto, este tipo de problema considera apenas uma camada oculta. A Figura 43 apresenta um exemplo de escolha para as camadas da RNA, disponíveis na ferramenta Mercury. Essa configuração apresenta uma RNA com 3 camadas. Há doze neurônios na camada de entrada, pois utilizamos 12 meses, uma entrada referente a cada mês. Uma camada oculta, com 30 neurônios e uma camada de saída, com um neurônio. Ao final da imagem estão visíveis os métodos da biblioteca encog, utilizados para criar a RNA.





Figura 43 – Criação da RNA no Mercury

- Treinando a RNA** - A propriedade mais importante das redes neurais é a capacidade de aprender em seu próprio ambiente e, assim, melhorar seu desempenho de forma incremental. Isso é feito através de um processo iterativo de ajustes aplicados a seus pesos e treinamento. O algoritmo de treinamento backpropagation é o mais popular para as RNAs de múltiplas camadas e consiste de duas etapas: propagação e retro propagação. Na primeira etapa, um vetor de entrada é aplicado à camada de entrada e seu efeito se propaga pela rede, produzindo um conjunto de saídas. A resposta obtida pela rede é subtraída da resposta desejada para produzir um sinal de erro. O segundo passo propaga este sinal de erro na direção oposta às conexões sinápticas, ajustando-as para aproximar as saídas da rede. Além disso, com a integração da RNA ao EFM é possível definir os critérios de parada de treinamento para uma taxa de erro específica ou um número fixo de iterações. A Figura 44 apresenta a taxa de erro atingida para cada iteração. A medida que o número de iterações aumenta, o erro diminui, podendo chegar a um determinado limiar informado pelo usuário, que será o critério de parada do aprendizado.
- Predição** - Esta opção produz previsões relacionadas ao consumo de energia do




Artificial Neural Network Training

Time 1	Error rate 0.340112216687945
Time 2	Error rate 0.3185793171888322
Time 3	Error rate 0.2687573555931206
Time 4	Error rate 0.18262847332223353
Time 5	Error rate 0.08192078747124798
Time 6	Error rate 0.04040561056322908
Time 7	Error rate 0.06590378970861546
Time 8	Error rate 0.10088277921552904
Time 9	Error rate 0.12420720854178367
Time 10	Error rate 0.13753488240830014
Time 11	Error rate 0.14498416715405393
Time 12	Error rate 0.14922625488051244
Time 13	Error rate 0.15171604766205776
Time 14	Error rate 0.15322194644095272
Time 15	Error rate 0.15415375721644672
Time 16	Error rate 0.1547346231277891
Time 17	Error rate 0.15508817676130862
Time 18	Error rate 0.15528276324596468
Time 19	Error rate 0.15535392223919262
Time 20	Error rate 0.1553154170903318
Time 21	Error rate 0.15516363155010732
Time 22	Error rate 0.15487728180606905
Time 23	Error rate 0.15441259562116347
Time 24	Error rate 0.15369251781530513

Figura 44 – Treinamento da RNA no Mercury

ambiente nos próximos doze meses. Após uma certa quantidade de repetições, a RNA aprende o padrão da distribuição em estudo, ajustando seus pesos, a fim de correlacionar os dados de entrada para obter previsões eficientes. Com os novos pesos, constitui-se a fase de aprendizado e o sistema usa o que “aprendeu” para gerar os resultados da previsão. A escolha dos valores das variáveis **momentum** e **taxa de aprendizado** influenciam bastante na qualidade da previsão. A Figura 45 apresenta a janela com as previsões disponíveis no Mercury, composta por 4 colunas: Ano, mês, consumo real (kWh) e consumo previsto(kWh). Ao final das previsões, o erro percentual absoluto médio é exibido.



Predicted

Mean Absolute Percentage Error: 0.008689756802178853

Year	Month	Real Consumption (kWh)	Consumption Predicted (kWh)
2009	10	62,400000	62,426920
2009	11	63,500000	62,430564
2009	12	62,500000	62,461570
2010	1	62,500000	62,505523
2010	2	62,600000	62,537852
2010	3	62,600000	62,516545
2010	4	62,600000	62,497232
2010	5	62,700000	62,527368
2010	6	62,700000	62,564096
2010	7	62,800000	62,599693
2010	8	62,800000	62,541509
2010	9	62,800000	62,605565
2010	10	62,900000	62,654929
2010	11	62,900000	62,642723
2010	12	63,000000	62,619045
2011	1	63,000000	62,640820
2011	2	63,000000	62,654445
2011	3	63,100000	62,669310
2011	4	63,100000	62,679862
2011	5	63,200000	62,694650
2011	6	63,200000	62,715882
2011	7	63,200000	62,729153
2011	8	63,400000	62,743645
2011	9	63,400000	62,756507
2011	10	63,400000	62,776126

Figura 45 – Previsões da RNA no Mercury

- **Gráfico** - Esta opção permite ao usuário visualizar graficamente os valores de consumo de energia do ambiente avaliado a cada mês. Para facilitar a interpretação dos dados, os consumos reais são apresentados em linha de coloração vermelha (dados do histórico de consumo, informado pelo usuário), ao passo que os valores previstos pela rede neural, de acordo com o MPL, são destacados na cor azul. A Figura 46 exibe uma das formatações possíveis para essa função de gráfico.




Figura 46 – Gráfico da RNA no Mercury